




A Inteligência Artificial Aplicada à Personalização no E-commerce

Bruna Filipa Coelho Gonçalves

09 /2024






A Inteligência Artificial Aplicada à Personalização no E-commerce

Bruna Filipa Coelho Gonçalves

Dissertação de Mestrado apresentado ao Instituto Superior de Contabilidade e Administração do Porto para a obtenção do grau de Mestre em Marketing Digital, sob orientação do Doutor José Luís Reis e co-orientação do Doutor Jorge Remondes



Dedicatória

[Sempre] Por Mim.

[Sempre] Por Vocês – Rosa, Bruno, Renato, Carolina, Miguel, Ermelinda, Augusta, António e Manuel.

[Sempre] Por Si, Amélia, esteja onde estiver.

Agradecimentos

No término da Licenciatura, afirmei:

“Hoje, agradeço.

Após três anos, sou oficialmente LICENCIADA em Ciências da Comunicação. Com nota 19. Agradeço à minha família, ao meu namorado e aos meus amigos por serem o meu suporte.

Ficará, para sempre, a saudade dos momentos incríveis vividos e a certeza que dei o melhor de mim. Agora, um novo ciclo inicia-se.

Hoje, despeço-me.”

O ciclo iniciou-se, numa outra casa. O sentimento de gratidão permanece – seja à família, ao namorado e aos amigos. Porém, cabe-me agradecer de forma individual a duas parceiras leais: Inês e Mariana.

Por fim, um agradecimento por toda a sabedoria ao Professor José Luís Reis.

Resumo:

Esta pesquisa examina o papel da Inteligência Artificial (IA) no e-commerce, com foco sobre como é que essa tecnologia influencia a personalização da experiência do consumidor e, conseqüentemente, direciona a sua intenção de compra.

A revisão da literatura abrange uma ampla gama de tópicos, desde os conceitos básicos de IA e e-commerce até às tecnologias específicas aplicadas, como algoritmos de recomendação e estratégias de personalização utilizadas em plataformas como a Amazon.com. Além disso, são discutidas as características do comportamento do consumidor e a aplicação de análises preditivas para melhorar a personalização.

A metodologia adotada é de natureza quantitativa, tendo sido realizada por meio de um questionário direcionado a utilizadores com experiência direta no website da Amazon, do qual se obtiveram 215 respostas. O objetivo foi determinar de que forma os fatores relacionados ao comportamento do consumidor, influenciados pelas recomendações personalizadas de produtos na plataforma, impactam as decisões de compra. A análise revelou que a implementação de IA no e-commerce aumenta a intenção de compra dos consumidores, melhorando a experiência em cada etapa do processo de compra.

Este estudo contribui para o entendimento de como a IA pode ser utilizada para melhorar a experiência do consumidor, oferecendo orientações para futuras pesquisas sobre o tema.

Palavras chave: Inteligência Artificial; E-Commerce; Personalização; Amazon; Consumidor.

Abstract:

This research examines the role of Artificial Intelligence (AI) in e-commerce, with a focus on how this technology influences the personalization of the consumer experience and, consequently, drives their purchase intention.

The literature review covers a wide range of topics, from the basic concepts of AI and e-commerce to the specific technologies applied, such as recommendation algorithms and personalization strategies used on platforms such as Amazon.com. In addition, the characteristics of consumer behavior and the application of predictive analytics to improve personalization are discussed.

The methodology adopted is quantitative in nature and was carried out using a questionnaire aimed at users with direct experience of Amazon's website, from which 215 responses were obtained. The aim was to determine how factors related to consumer behavior, influenced by personalized product recommendations on the platform, impact purchasing decisions. The analysis revealed that the implementation of AI in e-commerce increases consumers' purchase intent, improving the experience at each stage of the purchasing process.

This study contributes to the understanding of how AI can be used to improve the consumer experience, offering guidelines for future research on the subject.

Keywords: Artificial Intelligence; E-Commerce; Personalization; Amazon; Consumer.

Índice

Capítulo - Introdução.....	1
Capítulo I – Revisão da literatura.....	7
1.1 Inteligência Artificial.....	8
1.2 E-commerce.....	12
1.3 Tecnologias de Inteligência Artificial aplicadas ao E-commerce	16
1.4 Algoritmos de recomendação	24
1.4.1 Sistemas de Recomendação Tradicionais.....	25
1.4.1.1 Métodos de Recuperação e Classificação.....	32
1.4.1.2 Aprendizagem Federada	33
1.4.2 Sistemas de Recomendação com Inteligência Artificial	37
1.5 Personalização da Experiência do Consumidor.....	41
1.5.1 Segmentação de Mercado.....	42
1.5.2 Comportamento do consumidor	44
1.5.3 Análise Preditiva na Melhoria da Personalização	53
1.6 Estratégias no E-commerce com Inteligência Artificial.....	57
1.6.1 Caso Amazon.....	61
1.6.2 Tecnologias de Personalização na Amazon.....	64
Capítulo II – Metodologia.....	68
2 Metodologia de Pesquisa.....	69
2.1 Objetivos.....	69
2.2 Modelo Concetual.....	69
2.3 Método de Recolha de Dados.....	73
Capítulo III – Análise de Resultados	78
3 Resultados.....	79
3.1 Análise Descritiva.....	79
3.2 Teste das Hipóteses	83

3.3	Validação das Hipóteses	95
3.4	Análise de Regressão Múltipla	96
Capítulo IV – Discussão dos resultados		102
4	Interpretações e Recomendações	103
Capítulo V – Conclusões		105
5	Considerações Finais	106
5.1	Principais Conclusões do Estudo	106
5.2	Contribuições do Estudo	107
5.3	Limitações do Estudo e Trabalhos Futuros	108
Referências bibliográficas		110
Apêndices.....		125
Apêndice I – Questionário		126
Apêndice II – Configuração do nome das variáveis no software JASP		133

Índice de Figuras

Figura 1: A expressão efetiva do jogo imitativo.....	9
Figura 2: Subdomínios da IA.....	17
Figura 3: Visão pictórica de algumas áreas de aplicação de IA.	19
<i>Figura 4: Interação entre chatbots e clientes.</i>	<i>22</i>
Figura 5: Soluções baseadas em IA para vários segmentos, de forma a criar um sistema empresarial inteligente.....	23
Figura 6: Abordagens do sistema de recomendação.	28
Figura 7: Estrutura de um sistema de recomendação.	32
Figura 8: Arquitetura da AF.	34
Figura 9: Modelo de Sistema.....	36
Figura 10: Resultado da comparação de taxas de recuperação entre diferentes algoritmos.	40
Figura 11: Resultados da comparação dos resultados da exatidão nos diferentes algoritmos.	40
Figura 12: Antecedentes de Intenção de Compra.....	51
Figura 13: Áreas afetadas pela análise preditiva.	55
Figura 14: Sistema de Recomendação em produtos na Amazon num período de 10 anos.	63
Figura 15: Itens de recomendação com base no histórico de navegação e compra.....	64
Figura 16: Funcionamento do Amazon Lex para bots de centro de atendimento.	66
Figura 17: Modelo Estrutural e Hipóteses de Investigação.	71
Figura 18: Modelo Estrutural e Hipóteses de Lopes et al.....	71
Figura 19: Modelo Hipotético Proposto por Groh.....	72

Índice de Tabelas

Tabela 1: Hipótese do modelo proposto.	72
Tabela 2: Tipo e objetivo das perguntas do questionário.	77
Tabela 3 - Análise Descritiva de Variáveis Influentes - I.....	80
Tabela 4 - Análise Descritiva de Variáveis Influentes - II.	80
Tabela 5 - Análise Descritiva de Variáveis Influentes - III.....	80
Tabela 6- Análise Descritiva de Variáveis Influentes - IV.....	80
Tabela 7 - Análise Descritiva de Características Demográficas.....	82
Tabela 8 - Correlação para verificar se a prática da IA no ambiente de E-commerce impacta positivamente a Personalização da Experiência do Consumidor.....	83
Tabela 9 - Correlação para verificar se existe uma relação significativa entre a Personalização da Experiência do Consumidor no ambiente de E-commerce e a Atitude de Compra.....	84
Tabela 10 - Correlação para verificar se existe uma relação significativa entre a Personalização da Experiência do Consumidor no ambiente de E-commerce e a Satisfação - I.	85
Tabela 11 - Correlação para verificar se existe uma relação significativa entre a Personalização da Experiência do Consumidor no ambiente de E-commerce e a Satisfação - II.....	86
Tabela 12 - Correlação para verificar se a Atitude de Compra exerce um efeito positivo na Satisfação dos utilizadores de E-commerce.....	87
Tabela 13 - Correlação para verificar se existe uma relação significativa entre a Atitude de Compra e a Confiança dos utilizadores de E-commerce.	88
Tabela 14 - Correlação para verificar se a Satisfação exerce um efeito positivo na Confiança dos utilizadores no ambiente de E-commerce.....	89
Tabela 15- Correlação para verificar se a Confiança exerce um efeito positivo na Intenção de Compra dos utilizadores no ambiente de E-commerce.	91
Tabela 16 - Correlação para verificar se a Atitude de Compra exerce um efeito positivo na Intenção de Compra dos utilizadores no ambiente de E-commerce.	93
Tabela 17 - Correlação para verificar se a Satisfação exerce um efeito positivo na Intenção de Compra dos utilizadores de E-commerce.	94
Tabela 18 - Verificação das Hipóteses.	96
Tabela 19 - Regressão Múltipla da Intenção de Compra Futura 1- I.	97

Tabela 20 - Regressão Múltipla da Intenção de Compra Futura 1- II.	97
Tabela 21 - Regressão Múltipla da Intenção de Compra Futura 2 - I.	98
Tabela 22 - Regressão Múltipla da Intenção de Compra Futura 2 – II.	99
Tabela 23 - Regressão Múltipla da Intenção de Compra Futura 3 - I.	100
Tabela 24 - Regressão Múltipla da Intenção de Compra Futura 3 – II.	100

Lista de abreviaturas

ACP – Análise de Componentes Principais

AF – Aprendizagem Federada

B2B – Business to Business

B2C – Business to Consumer

C2C – Consumer to Consumer

DVS – Decomposição do Valor Singular

FC – Filtragem Colaborativa

FM – Factorização Matricial

FMN – Factorização Matricial não Negativa

FMP – Factorização Matricial Probabilística

IA – Inteligência Artificial

IoT – Internet of Things

NC – Neurônios Convolucionais

PM – Perceptrões Multicamadas

RBC – Recomendação Baseada em Conteúdo

CAPÍTULO - INTRODUÇÃO

No capítulo de introdução é apresentado o enquadramento do estudo e respetivas motivações, sendo demonstrados os problemas de investigação e o objetivo, bem como a estrutura do trabalho.

Enquadramento do Estudo

O avanço tecnológico contínuo está a forçar as entidades a mudar as suas operações tradicionais, ajustar os seus processos, adotar novos sistemas de informação e também manter atualizados os sistemas existentes. Ademais, as tecnologias digitais subjacentes ao avanço tecnológico têm a capacidade de interromper determinadas ações e o marketing é peça central nesse processo (Miklosik & Evans, 2020).

O desenvolvimento do marketing, desde o seu conceito às suas práticas de execução, sofreu alterações e metamorfoses significativas. Armstrong & Kotler (2023) referem que a definição mais simples acerca do marketing é o facto de este ser a gestão de relacionamentos lucrativos com o cliente. No decorrer da sua evolução, novas abordagens e ideias orientadas no *online* acrescentam-se a esta.

O *online* proporcionou às marcas novas interessantes formas de saber mais sobre os clientes, assim como rastreá-los e segmentá-los de acordo com as suas necessidades individuais (Armstrong & Kotler, 2023). Levando em consideração os tempos atuais, é cada vez mais importante que as empresas aceitem a noção de que o marketing digital é a área que mais cresce e se destaca.

O marketing digital trata da aplicação dos conceitos de marketing tradicional aos meios digitais (Faustino, 2019). Contudo, numa perspetiva mais ampla, este envolve a criação de estratégias de marketing para promover produtos ou serviços numa variedade de canais digitais, como *websites*, blogues e redes sociais, que são estabelecidos por meio de dispositivos eletrónicos, como computadores e smartphones (Faustino, 2019).

Segundo Kotler et al. (2017), o marketing 1.0 é centrado no produto, o marketing 2.0 é centrado no consumidor, marketing 3.0 é centrado no ser humano e o marketing 4.0 alavanca a conectividade máquina a máquina e a IA com o objetivo de melhorar a produtividade do marketing. Neste último caso, as empresas veem os clientes como seres humanos com todas as facetas físicas e emocionais. No entanto, é importante lembrar que a convergência digital é a principal causa dos avanços nas práticas de marketing.

Hoje em dia, encontra-se estabelecido o marketing 5.0 que, de acordo com os autores Kartajaya et al. (2021), consiste numa abordagem humanizada das tecnologias, através da imitação do ser humano, com o propósito de criar, comunicar, cumprir e potenciar valor em todo o percurso do cliente. Ademais, que há uma combinação de tecnologias que proporcionam o conceito como, nomeadamente, sensores, robótica, IA, realidade aumentada, realidade virtual, entre outros. Por sua vez, o autor Pimentel (2021) defende que o Marketing 5.0 apresenta uma maneira de integrar a evolução tecnológica e o modelo de negócios com as transformações relevantes ocorridas na última década no comportamento do consumidor.

A IA é uma subárea da ciência da computação que se baseia na disponibilização de programas de computadores e máquinas inteligentes capazes de reunir uma ampla quantidade de dados, bem como de interpretar as decisões dos consumidores pelo meio das suas ações e opções (Matias, 2020).

Além disso, a IA possui uma grande influência e impacto em várias áreas do e-commerce, incluindo pesquisa através da voz, ajuda através de assistentes virtuais e segmentação de produtos em tempo real. Portanto, a IA no e-commerce permite que as empresas recolham informações dos clientes e os incentivem a comprar mais, aumentando assim as vendas (Alves, 2023).

O e-commerce facilita a tomada de decisões, assim, as empresas devem estar preparadas para as mudanças rápidas do mercado para que os diferentes públicos reajam positivamente. Com os avanços tecnológicos é fundamental responder às expectativas dos consumidores, porém, por tratar-se de uma tarefa difícil a maior parte das organizações recorrem à IA para solucionar (City et al., 2020).

Todos os dias milhões de utilizadores percorrem inúmeros *websites*, quer sejam de cariz institucional, blogues ou redes sociais, à procura de novos produtos/serviços que consigam satisfazer as suas necessidades pelo meio das plataformas de e-commerce (Silva, 2020).

Novos dados são recolhidos através da IA à medida que um utilizador navega pela internet. Esses dados contêm informações sobre o comportamento, as necessidades e as futuras ações do consumidor (Madeira et al., 2020). Para mais, os algoritmos podem aprender com que frequência determinado indivíduo realiza uma compra ou identificar outros comportamentos, como visitar *websites* específicos para, no momento ideal, exibir

uma campanha, enviar emails marketing ou notificações promocionais (Madeira et al., 2020). Como resultado, a IA pode prever as próximas compras dos consumidores e enviar anúncios de produtos específicos por email ou redes sociais (Paulichi & Cardin, 2020).

Em conformidade com Gabriel (2010), as diversas utilidades possibilitadas pela IA estão a transformar o marketing no geral. Desta forma, os autores referem algumas alterações:

- a) Análise preditiva de padrões de compra: utilizam um grande volume de dados a fim de prever resultados futuros;
- b) *Insights* sobre o público: os sistemas de IA são aptos de identificar os níveis de preferências dos consumidores, com a finalidade de entregar conteúdos, preços, produtos e experiências exclusivas;
- c) Chatbots inteligentes: o atendimento ao cliente é uma dificuldade enfrentada pelas empresas e que, por norma, acarreta insatisfação de clientes;
- d) Análise de sentimento em reconhecimento automático de voz: consiste em tecnologias capazes de identificar o estado emocional do consumidor em tempo real, para oferecer-lhes as soluções mais assertivas.

No fundo, a IA no e-commerce é utilizada com o propósito de possibilitar aos consumidores uma pluralidade de opções que podem ser usadas quando estes fazem uma compra *online*, aprimorando a experiência e o processo de tomada de decisão (Matias, 2020).

Motivação

Devido ao rápido desenvolvimento da área da IA, recheada de implicações e nuances, escolher este tema surge como um grande desafio pessoal e profissional. Trata-se de uma área extremamente moderna e complicada que afeta quase todas os campos, incluindo o e-commerce, que se tornou mais importante após o aparecimento da Covid-19. Além disso, sempre achei estimulante o tema da personalização. A capacidade de segmentar e personalizar a experiência do consumidor, seguindo da percepção se a personalização influencia as decisões de compra sempre me fascinou. No mundo de hoje, especialmente

no campo do marketing digital, onde somos bombardeados com uma quantidade enorme de informação, é fundamental entender como os algoritmos funcionam.

Esta investigação aborda temas que me interessam profundamente, permitindo-me crescer enquanto pessoa e profissional. Há poucos meses iniciei um projeto, uma agência de marketing e comunicação, e acredito que ter uma compreensão profunda do papel da personalização ajudar-me-á a oferecer aos clientes um serviço mais eficiente e personalizado. Assim, este trabalho permite-me ser uma profissional mais eficaz e orientada para resultados, na medida em que me fornece certas habilidades necessárias para implementar estratégias de marketing digital mais eficazes e personalizadas.

Problemas de Investigação e Objetivos

O problema de investigação centra-se na compreensão da experiência de compra dos consumidores numa plataforma de e-commerce através da influência de IA, com foco na recomendação de produtos.

Quanto ao objetivo principal, este estudo pretende analisar como a IA é aplicada para personalizar a experiência do consumidor no contexto do e-commerce, especificamente na plataforma da Amazon.

Estrutura

O estudo encontra-se estruturado em cinco capítulos, além deste primeiro, intitulado – Introdução – composto pelo enquadramento do estudo, motivação, descrição do problema de investigação e objetivos.

No primeiro capítulo, apelidado – Revisão da Literatura – procede-se a uma fundamentação teórica das discussões de outros autores/investigadores acerca dos conceitos essenciais relacionados ao tema central do estudo. Dividido em várias seções, este capítulo oferece uma compreensão aprofundada de diversos tópicos relevantes para a pesquisa, abrangendo desde princípios fundamentais até estratégias avançadas no contexto do e-commerce impulsionado pela IA. A Revisão da Literatura conclui com uma análise das estratégias empregadas no e-commerce impulsionadas pela IA, com destaque para o estudo de caso da Amazon.

No segundo capítulo identifica-se a metodologia de investigação, onde se descreve a abordagem metodológica quantitativa ao pormenor, o instrumento de recolha de dados, a seleção da amostra, entre outros aspectos relacionados à metodologia do estudo.

O terceiro capítulo refere-se aos resultados e recomendações analisados através do tratamento estatístico realizado no *software* JASP que irá validar ou invalidar as hipóteses de investigação. No quarto capítulo, apelidado de recomendações, oferece-se diretrizes práticas para marketing digital e comunicação personalizada para maximizar a personalização, satisfação e confiança dos consumidores.

No quinto e último capítulo apresentam-se as conclusões da investigação e uma reflexão crítica sobre as limitações do trabalho, bem como possíveis propostas a realizar em trabalhos futuros.

CAPÍTULO I – REVISÃO DA LITERATURA

1.1 Inteligência Artificial

Nos dias de hoje, muitos setores dependem da IA para a produção em massa e a gestão de bases de dados. Como resultado, esta é essencial para o sistema empresarial, melhorando significativamente a eficiência das entidades a vários níveis. Um dos níveis mais importantes é que ela facilita a descodificação de padrões complexos por meio da melhoria da sua eficiência de visão analítica até níveis mais profundos (Bohr & Memarzadeh, 2020).

A IA tem sido utilizada em todos os domínios, incluindo automóveis, jogos, agricultura, desporto, cuidados de saúde e monitoramento ambiental. Ademais, tem demonstrado ser uma tecnologia exímia capaz de transformar o estilo de vida dos humanos e oferecer condições de vida muito mais confortáveis (Vinuesa et al., 2020).

Muitos autores de renome e laboratórios associados a partir de meados do século passado propuseram conceitos iniciais sobre a origem da IA. O trabalho de Alan Turing (1950) é, sem sombra de dúvida, um dos mais usados como referência. Este é amplamente considerado como o “pai da IA” devido a ter concebido um teste para determinar se um computador é inteligente, designado por Teste de Turing (Ouyang & Feng, 2022).

Aprofundando a sua origem, a IA começou a ser desenvolvida em 1950 em Dartmouth Summer Research Project on Artificial Intelligence (Paulichi & Cardin, 2020) através do Teste de Turing, porém, apenas em 1956 é que o termo “IA” foi utilizado pela primeira vez num Workshop na Faculdade de Dartmouth (Matias, 2020).

Uma versão do Teste de Turing amplamente difundida descreve-o como um tipo de exame em que um examinador é separado do objeto em teste, que pode ser uma pessoa ou uma máquina, e usa um dispositivo, como um teclado, para fazer perguntas anónimas ao sujeito. Se mais de 30% das respostas não permitirem distinguir as respostas humanas das respostas da máquina, o teste é concluído com sucesso e o aparelho tem inteligência semelhante à humana (Ouyang & Feng, 2022).

Segundo o artigo académico de Turing publicado na revista filosófica *Mind*, o autor sugeriu que se deveria começar por definir os conceitos de máquina e de pensamento quando se aborda se as máquinas podem pensar (Turing, 1950). Achou difícil definir com precisão a mente humana, então propôs um jogo imitativo para substituir a questão inicial.

A Figura 1 mostra a verdadeira expressão do "jogo imitativo", de acordo com o seu próprio documento.




Figura 1: A expressão efetiva do jogo imitativo.

Três indivíduos aparecem na peça de imitação: um homem (A), uma mulher (B) e o indivíduo que faz a pergunta (C). O autor da pergunta e os dois indivíduos que serão interrogados estão em salas separadas. O interrogador usa perguntas para determinar o gênero dos entrevistados (Parnas, 2017).

O texto serve como suporte da comunicação para evitar que o autor da pergunta (C) se baseie na voz para distinguir entre A e B. O homem (A) tenta imitar a mulher para levar o entrevistador (C) a fazer o maior número de julgamentos incorretos possíveis, enquanto a mulher (B) tenta ajudar o autor das perguntas (C) a distinguir o máximo possível. O jogo de imitação do homem (A) é considerado bem sucedido se o interrogador (C) pensar incorretamente que (A) é uma mulher (Ouyang & Feng, 2022).

Esta experiência foi conduzida por Alan Turing por meio da substituição do homem (A) por uma máquina com o objetivo de determinar se alguma coisa aconteceria, ou seja, se o autor das perguntas fez o mesmo número de juízos errados que os dois indivíduos fizeram em experiências anteriores. A máquina era considerada tão boa quanto o homem (A) se o número permanecesse igual. A pergunta inicial foi respondida pela pergunta de imitação (Ouyang & Feng, 2022).

A ideia que Turing pretendia transmitir era a confirmação de que o pensamento era o núcleo da inteligência e que a linguagem era a forma significativa de expressar esse pensamento. Portanto, uma interação linguística poderia ser usada para verificar a inteligência das máquinas. Em outras palavras, ele acreditava que a inteligência de uma máquina era determinada pela sua capacidade de enganar o interrogador com a mesma facilidade que um indivíduo pode fazer usando a linguagem (Ouyang & Feng, 2022).

Em suma, Alan Turing (1950) realizou uma investigação com o propósito de consolidar uma definição de IA, na medida em que esta se baseava num computador a ser interrogado por um humano, sem que este se apercebesse que estava a estabelecer uma conversa com uma máquina. Desta forma, o autor definiu a IA como um sistema com a capacidade e competência de alcançar um desempenho ao nível de um ser humano em todas as tarefas cognitivas, de jeito a realizar a simulação de uma conversa humana com uma pessoa.

O teste do jogo imitativo foi aceite por muitos cientistas como um padrão para a inteligência artificial (Parnas, 2017), embora um número crescente de outros cientistas tenha expressado uma opinião diferente. A experiência de pensamento da casa chinesa proposta pelo filósofo americano John Searle em 1980 é a mais significativa. Apesar de o aparelho ter concluído uma experiência de imitação e ter respondido corretamente às perguntas, ele não compreendeu as perguntas e, portanto, não tinha verdadeira inteligência.

Embora as opiniões e experiências de Turing tenham tido um impacto significativo nas normas gerais de investigação em IA e, ainda, comprovada anos mais tarde (2012) por um engenheiro computacional que conseguiu confirmar e convencer os juizes de jogo que a inteligência artificial era humana (Paulichi & Cardin, 2020), o teste de Turing nunca foi usado como padrão ou definição na história geral da IA (Ouyang & Feng, 2022).

A IA foi formalizada como um objetivo de investigação na Conferência de Dartmouth em 1956, abordada anteriormente. Esta conferência desempenhou um papel muito importante na história da IA porque deu nome à disciplina e, ainda, porque fez emergir os fundadores importantes deste domínio (Ouyang & Feng, 2022). E, nesta área, importa ressaltar que John McCarthy foi também um dos primeiros estudiosos a analisar o conceito e o desenvolvimento da IA e, nos dias de hoje, apresenta-se como um dos principais investigadores neste campo (Alves, 2023).

Nos últimos anos, a IA é um tema que não apresenta uma definição universalmente aprovada em todos os setores da sociedade, sem qualquer controvérsia (Ouyang & Feng, 2022). No fundo, a subárea da ciência da computação acaba por usufruir de diversos conceitos, sendo uma tarefa um pouco difícil a sua compreensão.

IA inclui "artificial" e "inteligência", palavras oriundas do latim. O "artificial" é mais fácil de compreender e menos controverso, significando artificial e não natural. Contudo, "inteligência" é um conceito mais problemático e, de acordo com o autor (Ouyang & Feng, 2022), é o termo mais importante no domínio da IA que, segundo Legg & Hutter (2007) é conotado com mais de 70 definições provindas de psicólogos, sociólogos, biólogos, neurocientistas e filósofos. Perante esta situação, Haenlein & Kaplan (2019) acreditam que não é surpreendente que o termo permaneça tão mal definido e um conceito difuso, apesar da sua recorrente utilização.

A IA, em termos básicos, pode ser definida como um sistema de *software* complexo que executa determinadas tarefas semelhantes às do cérebro humano (Soni, 2020). No entanto, fica muito aquém das suas profundas técnicas. Os autores Stone et al. (2016) afirmam que o termo em questão procura entender a inteligência em seres humanos e, dessa maneira, elaborar sistemas com a finalidade de auxiliar o desenvolvimento de computadores, máquinas, robôs e *softwares*.

De acordo com S. Lee (2021) a IA consiste num método de recolha e simplificação dos dados para obter informações valiosas que ajudem a atingir as metas e os objetivos de uma estratégia pré-definida. Além disso, os autores adiantam que é uma impressão das atividades humanas com a ajuda de máquinas, resultando na resolução de problemas e na aprendizagem.

A IA, uma máquina capaz de reproduzir inteligência humana, pode ser classificada em dois grupos, tais como: IA forte e IA fraca (Chandra et al., 2023). A IA forte também apelidada de IA geral, refere-se a um computador ou sistema que possui lógica, capacidades sensoriais e atenção plena, incluindo também a inteligência em mais do que um domínio. Por sua vez, a IA fraca também designada como IA limitada, diz respeito a máquinas com inteligência limitada a um único domínio (Chandra et al., 2023).

Todavia, os autores Haenlein & Kaplan (2019) acreditam que o conceito passa efetivamente por fases evolutivas, acabando por defender a existência de três estágios

para contextualizar esta evolução: IA limitada (Artificial Narrow Intelligence), IA geral (Artificial General Intelligence) e super IA (Artificial Super Intelligence).

Haenlein & Kaplan (2019) adicionam um último estágio face à perspectiva dos autores (Chandra et al., 2023), indo de encontro da opinião de Hassani et al. (2020) que afirmam, com base no conceito e nas áreas de aplicação, que a IA pode ser classificada como máquinas reativas, memória limitada, teoria da mente e autoconsciência, porém, em termos de força, pode ser classificada como fraca, forte e super IA (Hassani et al., 2020).

A IA limitada, respetivamente, assentará em utilizar a IA para tarefas bastantes específicas como, por exemplo, o Facebook conseguir reconhecer o rosto dos seus utilizadores e identificá-los e também a Siri conseguir identificar a voz de quem fala. A IA geral permitirá que o conceito possa raciocinar, planear e resolver problemas de maneira autónoma em situações para a qual este não foi desenhado. Por último, a super IA, tornar-se-á auto consciente ao ponto de a própria existência do ser humano ser redundante (Haenlein & Kaplan, 2019).

Em suma, a IA é um dos temas mais discutidos em todo o mundo e pode-se afirmar que está em constante expansão, tanto ao nível do conceito inicial quanto à capacidade de processamento e conhecimento (Paulichi & Cardin, 2020).

1.2 E-commerce

Desde a origem da internet até aos dias de hoje começaram a aparecer cada vez mais novas oportunidades de negócios e, por conseguinte, o surgimento de novas profissões e ferramentas num mundo predominantemente digital. Neste paradigma, o e-commerce desempenha um papel de destaque ao produzir lucros nunca antes produzidos pelas empresas (Silva, 2020).

A internet contribuiu para o surgimento do conceito de e-commerce, segundo Delone & Mclean (2004), transformando-se numa ferramenta de comunicação poderosa e amplamente utilizada para promover o consumismo e a eficácia das transações comerciais. Este conceito surge no meio desta revolução, na década de 60, mas é no presente século que acontecem as maiores revoluções do mesmo.

O conceito de e-commerce ainda não possui uma definição clara e unificada, apresentado algumas variações de autor para autor. Em 1995, Abrams salientou que este trata-se do uso de sistemas de comunicação e tecnologia, de processamento de informações digitais para estabelecer transações comerciais e criar/manter relacionamentos para a criação de valor entre indivíduos e organizações.

Ao longo dos anos constata-se concepções de outros autores, por exemplo, Nanekaran, (2013) salienta que o mesmo é a interação entre sistemas de comunicação, sistemas de gestão de dados e segurança que, entre eles, trocam informação sobre a venda de produtos e serviços. Mais recentemente, M. Soares & Sousa (2018) caracterizam-no pela compra e venda de produtos e serviços na internet.

Não importa quanto tempo passe, no sentido geral, pode-se afirmar que diz respeito a qualquer forma de atividade económica através de ligações eletrónicas (Yin & Luo, 2021). Por outro lado, em sentido restrito, relaciona-se a atividades comerciais através da internet a uma escala global.

Segundo Duffy & Dale (2002), o desenvolvimento do e-commerce apresenta três fases: o e-commerce baseado no Eletronic Data Interchange (EDI), o e-commerce baseado na internet e o e-commerce de conceito eletrónico.

Entre os anos 60, o e-commerce apenas fez uso da tecnologia informática para processar e trocar dados nas operações comerciais convencionais. Posteriormente, tornou-se um requisito para o estabelecimento de transações nas organizações. Hoje em dia, a automação digital do comércio é feita com IA baseada na aprendizagem, suprimindo a intervenção humana por meio de uma variedade de aplicações, como assistentes inteligentes, robôs de conversação, logística inteligente e sistemas de recomendação (Yin & Luo, 2021).

As empresas podem usar a tecnologia de aprendizagem para escolher as melhores estratégias de marketing para obter ações mais rentáveis e uma melhor eficiência. Além disso, os marketeers podem também usá-la para realizar uma variedade de tarefas relacionadas ao e-commerce, como serviço inteligente ao cliente e recomendação de produtos (Yin & Luo, 2021). Desta forma, o estudo do e-commerce baseado na aprendizagem é muito importante para os profissionais e investigadores porque permite que eles aprendam mais sobre o que está acontecendo no campo (Duffy & Dale, 2002).

Perante as definições apresentadas e o desenvolvimento do conceito identificam-se quatro categorias de e-commerce: *Business to Business* (B2B), *Business to Consumer* (B2C), *Consumer to Consumer* (C2C) e *Mobile Commerce* (M-Commerce) (Silva, 2020). Estas relações baseiam-se na natureza dos compradores e vendedores e, ainda, da sua posição na cadeia de valor comercial (Matias, 2020).

O B2B refere-se ao comércio eletrónico relacionado com as transações entre empresas (Moriset, 2018), ou seja, trata-se da interação de um negócio com outro negócio. Por exemplo, a venda é realizada a outro intermediário que, em seguida, vende o produto ao cliente final (Pandey & Agarwal, 2014). O B2C ocupa-se do comércio eletrónico entre empresas e consumidores com a finalidade de negociar produtos ou serviços, através de estratégias e técnicas (Moriset, 2018).

O C2C engloba transações eletrónicas entre consumidores individuais, por norma, através de plataformas de terceiros (Moriset, 2018). As empresas funcionam como mediadores entre o comprador e o vendedor, na medida em que fornecem alojamento para os anunciantes produzirem os seus anúncios e promoverem os seus produtos e serviços (Pandey & Agarwal, 2014). De ressaltar que este modelo está a evoluir no meio do e-commerce. Por último, o *M-Commerce* dá-se quando um consumidor individual coloca produtos ou serviços em blogues, fóruns ou *websites* dedicados, a serem comprados ou leiloados pelas empresas (Moriset, 2018), isto é, à utilização de um dispositivo móvel habilitado a realizar transações num ambiente *web*.

O e-commerce crescia a nível global com frequência, porém, com as restrições impostas à circulação física resultantes da pandemia e do confinamento este crescimento tornou-se mais frenético e consistente. A maneira como os clientes compram, trabalham e se relacionam com os outros mudou significativamente devido à COVID-19.

Graças ao inesperado confinamento global de 2020, as páginas *web* de e-commerce foram a saída para satisfazer as necessidades básicas. Como resultado, colocá-las *online* tornou-se primordial e indispensável para todas as empresas. Esta necessidade revelou, por sinal, que muitas entidades não estavam presentes no digital, resultando em grandes perdas. Por outro lado, as organizações que já haviam estabelecido uma presença na internet observaram um aumento repentino nas vendas (Pahadi et al., 2022).

Devido à pandemia, as vendas *online* globais aumentaram cerca de 3,46 biliões de dólares em 2019 e atingiram 4,29 biliões de dólares em 2020. O crescimento anual de

2018 a 2019 foi de 17,9%, mas subiu para 24,1% no ano seguinte, ou seja, de 2019 a 2020 (Zoroja et al., 2020).

A expansão do negócio virtual tornou-se necessária, especialmente após a era da COVID-19. Com o desenvolvimento tecnológico, cada vez mais pessoas estão a deslocar-se para a internet para comprar e atender às suas necessidades. Assim, devido ao crescimento exponencial, as entidades que ainda não tinham uma estratégia de marketing digital acabaram por entender a importância disso e, neste caminho, atingiram um nível respeitável aos olhos dos clientes (Pahadi et al., 2022).

O setor do e-commerce tem vivenciado uma notável evolução, com um impacto significativo tanto nos empresários quanto nas indústrias de pequena dimensão, e por fim, nos consumidores finais. A adoção da internet e do e-commerce tem crescido exponencialmente nos últimos anos (Chaudhry & Chandhok, 2023).

A Ásia possui a maior base de consumidores do mercado de e-commerce, com a Índia ocupando a terceira posição em termos de base de compradores *online*, contando com 150 milhões no ano de 2021. Estima-se que o mercado de e-commerce na Índia alcance um crescimento de 350 mil milhões de dólares até 2030, em comparação com os 46,2 mil milhões de dólares em 2020. Desde moda até mercearias, passando por artigos para o lar, bens eletrónicos e pagamentos de contas, o e-commerce está a dominar o setor retalhista tradicional. Espera-se que o número de utilizadores da internet na Índia aumente para 320 milhões até 2025 (Chaudhry & Chandhok, 2023).

Mishra e Mukherjee (2019), apoiam a perspetiva de crescimento do e-commerce, isto é, afirmam que este cresceu significativamente nos últimos dez anos e está prestes a tornar-se um dos aspetos mais promissores da internet. Espera-se que continue a crescer ao mesmo ritmo, ou até mais nos próximos anos. Assim, se os retalhistas desejam lucrar e destacarem-se dos concorrentes diretos, precisam seguir esta tendência. Caso contrário, correm o risco de serem excluídos do mercado devido à obsolescência (Pahadi et al., 2022).

As descobertas de pesquisas recentes mostram que ter uma presença na internet oferece vários benefícios, como a facilidade de novos mercados e a recolha de dados dos clientes (Pahadi et al., 2022). Nesta perspetiva, segue-se a venda dos produtos e serviços em qualquer altura do dia e do ano e, ainda, a autonomia dos consumidores em selecionar

qual o método de pagamento pretendido ou adicionar um produto à lista de favoritos/compras.

O setor ainda não atingiu todo o seu potencial, apesar do rápido crescimento. A expansão está a ser interrompida por uma série de obstáculos, incluindo o abandono do carrinho de compras, a mudança para plataformas diferentes, preocupações com a privacidade e questões de segurança, custos técnicos elevados sob a forma de infraestruturas, técnicas de grande orçamento, problemas no cálculo do imposto sobre as vendas e barreiras culturais, especialmente quando atuam no mercado global (Chaudhry & Chandhok, 2023).

Além destas complexidades expostas, Duffy & Dale (2002), apresentam também processos críticos ao nível do e-commerce, que incluem a receção de encomendas, a satisfação de encomendas, o controlo financeiro, a integração de centros de atendimento, o comportamento dos consumidores e outros. Existem várias soluções defendidas para colmatar estes obstáculos através de valiosos estudos hipotéticos, porém, a resposta mais eficaz é a aplicação da IA à infraestrutura de e-commerce.

O e-commerce agora é uma opção comum quando se trata de compras *online*. As compras *online* têm muitas vantagens, como entrega ao domicílio, uma grande variedade de produtos, descontos e prémios. No entanto, os compradores *online* de todos os mercados enfrentam dificuldades ao escolher o melhor *website* (Chaudhry & Chandhok, 2023).

1.3 Tecnologias de Inteligência Artificial aplicadas ao E-commerce

A finalidade da IA é estudar, desenvolver e utilizar máquinas para realizarem atividades humanas de maneira autônoma, não é apenas compreender, mas também construir entidades inteligentes (Carvalho, 2023).

Ao longo do processo de desenvolvimento da IA, os seus conceitos foram aplicados numa variedade de contextos, incluindo resolução de problemas, aprendizagem e planeamento de atividades, sistemas especializados e visões de máquinas (N. Singh & Chouhan, 2021). Todavia, o desenvolvimento de dispositivos de computação de elevado desempenho, permitiu que esta começasse a ser utilizada noutras aplicações sensíveis e

típicas, como o processamento da linguagem natural, o reconhecimento da fala e do rosto, a extração de dados, a cibersegurança, e outras (Zawacki-Richter et al., 2019).

Existem vários subdomínios da IA, como se pode ver na Figura 2: aprendizagem automática (*Machine Learning*), aprendizagem profunda (*Deep Learning*), rede neural (*Neural Network*), processamento de linguagem natural (*Natural Language Processing*), computação cognitiva (*Cognitive Computing*) e visão por computador (*Computer Vision*) (Pahadi et al., 2022).

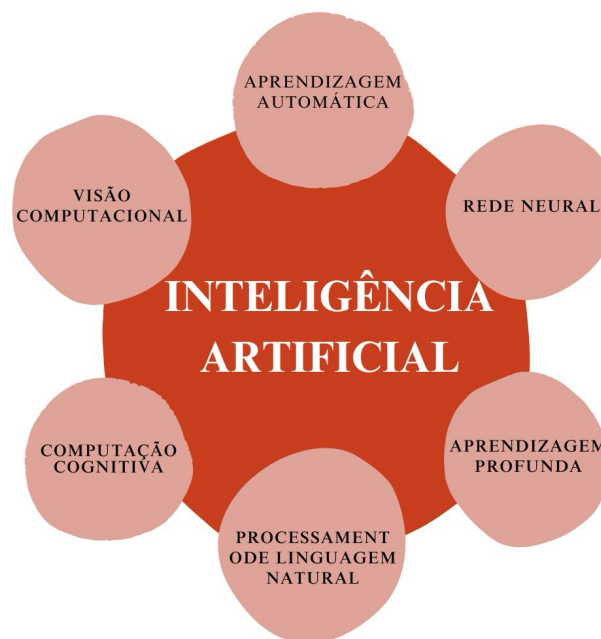


Figura 2: Subdomínios da IA.

A aprendizagem automática é uma técnica de IA que, ao contrário dos programas destinados a realizar uma tarefa específica, permite que os computadores recolham e assimilem dados e informações de todas as situações ou dificuldades com que se deparou (Pahadi et al., 2022). Esta é frequentemente utilizada para o tratamento de grandes quantidades de dados para as empresas (N. Singh & Chouhan, 2021), que usam sobretudo algoritmos para fazer com que as máquinas aprendam primeiro e depois tenham um desempenho melhor e mais rápido.

Este subdomínio liga dispositivos para utilizar o funcionamento da *Internet of Things* (IoT), alimentando fluxos de dados relevantes para as atividades empresariais como, por exemplo: funcionalidade, produção, vendas e marketing, expectativas e respostas dos clientes, entre outras (N. Singh & Chouhan, 2021). Nos sistemas empresariais, a

aprendizagem automática também tem ajudado na identificação de padrões e anomalias pelo meio da utilização de métodos de análise de dados.

A aprendizagem profunda, por sua vez, é uma abordagem que esclarece e analisa os dados de entrada de várias maneiras até que a máquina alcance o resultado esperado. A máquina executa uma série de algoritmos aleatórios para representar graficamente e visualizar a sequência de entrada para a saída (Pahadi et al., 2022). Por exemplo, a identificação, a decisão analítica e as respostas rápidas têm de ser executadas em paralelo para o funcionamento do veículo autónomo e através dos algoritmos de aprendizagem profunda consegue-se tratar estas operações em conjunto. De salientar que os algoritmos desta vão ajudar a melhorar as operações do sistema empresarial no caso de um fluxo de dados cada vez maior (N. Singh & Chouhan, 2021).

O termo "rede neural" refere-se a programas de computador que representam a comunicação entre o cérebro humano e as emoções. Este método de realização da análise de dados também fornecerá uma resposta a várias questões pertinentes que não foram respondidas anteriormente, com a ajuda de diferentes modelos de aprendizagem. Por exemplo, a aprendizagem profunda quando combinada com as redes neuronais pode desvendar as várias folhas de dados ocultos (Pahadi et al., 2022).

Os computadores têm a capacidade de processar, interpretar, encontrar, considerar e analisar a linguagem e os discursos humanos no campo do processamento de linguagem natural. Com a ajuda deste subdomínio são possíveis várias características integradas nas aplicações modernas de e-commerce, por exemplo, a Alexa – pertencente à Amazon – utiliza o processamento de linguagem natural e os clientes podem fazer uma compra ou procurar qualquer item através do microfone, sendo que a IA depois fará o seu trabalho (Pahadi et al., 2022).

A computação cognitiva trata-se de um conjunto de sistemas interativos, contextuais e flexíveis que dão um toque individualizado à experiência do utilizador *online*. No e-commerce, a computação cognitiva é natural e é por isso que é tão eficaz na recolha de dados pessoais ricos. Este subdomínio funciona das seguintes formas: avaliação dos dados do cliente e do seu comportamento de compra *online*, previsão de compras antecipadas, preços ótimos e assistente de voz digital (Pahadi et al., 2022).

A visão por computador facilita às máquinas a identificação espontânea, a supervisão, a exploração e a obtenção de dados visuais a partir de imagens e imagens reais,

capturando-as e interpretando-as. Por exemplo, pode-se carregar uma imagem e o motor de pesquisa reconhece esta e mostra os produtos semelhantes, acabando por detetar o objeto sem problema algum (Pahadi et al., 2022).

As tecnologias associadas à IA têm sido utilizadas por grandes empresas e gigantes financeiros para aprender e treinar os seus dados e conceber modelos de previsão através do historial de dados. Todos os dias, a IA demonstra que funciona como uma tecnologia eficiente para lidar com vários segmentos dos sistemas empresariais, incluindo produção, fabricação, retalhos, compras e moda (Giri et al., 2019). A Figura 3 ilustra várias áreas de aplicação recentes e significativas que têm utilizado os conceitos de IA para atingir os seus objectivos.

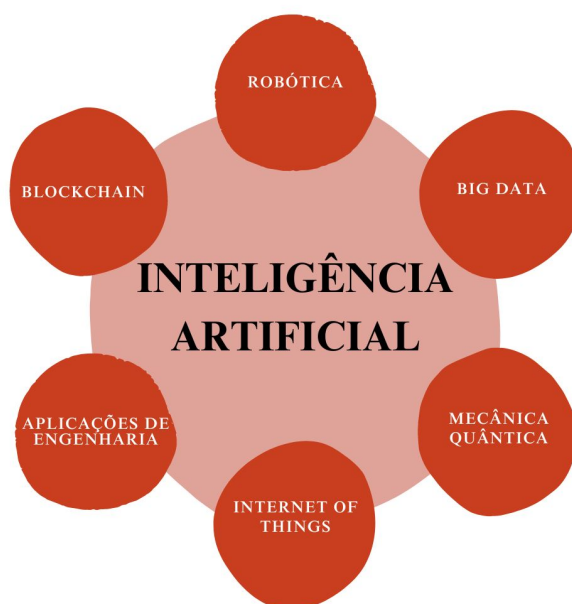


Figura 3: Visão pictórica de algumas áreas de aplicação de IA.

Por exemplo, IoT diz respeito à ideia de que todos os dispositivos estão equipados com sensores e *softwares* que estão ligados entre si de maneira a adquirir, reunir e transmitir dados. Os algoritmos de *big data* são fabricados para processar dados e resolver problemas. Além disso, remetem à conjugação de conjuntos de dados caracterizados por volume, velocidade e variedade, sendo que uma das suas origens é a IoT. Os autores Haenlein & Kaplan (2019) consideram que *big data* é mais abrangente que a IoT, na medida em que agrega dados recolhidos por outras fontes.

As tecnologias baseadas na IA já estão em ação em muitos dos sistemas empresariais, sendo adequadas para a análise de dados que proporciona às organizações obter melhores conhecimentos acerca do sector da automatização (Singh & Chouhan, 2021). Para mais, é exímia para o processamento da linguagem natural como, por exemplo, nos chatbots (Adamopoulou & Moussiades, 2020) que tornam a comunicação livre de qualquer interferência humana.

Os chatbots ajudam a marca a lidar e a responder às perguntas dos clientes, seja por escrito como por voz, utilizando o processamento da linguagem natural para compreender as necessidades do cliente na medida em que os algoritmos estão a ser treinados repetidamente com uma grande variedade de dados (Pahadi et al., 2022). Estes estão a alterar a interação entre as entidades e os consumidores (Pantano & Pizzi, 2020).

O conceito de assistente virtual surgiu no início dos anos 2000 e, indiscutivelmente, foi-se desenvolvendo graças aos recentes avanços tecnológicos da IA. Os chatbots são *softwares* aplicativos utilizados pelas empresas que simulam o atendimento feito por uma pessoa, ou seja, são sistemas conversacionais que empenham-se em comunicar com seres humanos pelo meio do uso de linguagem natural e outros recursos de IA (Madeira et al., 2020).

Um chatbot é um programa de computador projetado para interagir com os consumidores imitando/simulando ao pormenor a conversa (Bohle, 2018). Por exemplo, a Alexa recebe uma ordem e apresenta ao cliente todos os produtos disponíveis, de acordo com os requisitos filtrados e ao preço mais barato (Pahadi et al., 2022).

Inicialmente, os chatbots prestavam apenas apoio ao cliente aquando da navegação num *website* de uma empresa ou aquando da realização de uma compra, características que foram idealizadas na investigação de Alan Turing para a IA. Contudo, ao longo dos anos foi evoluindo e, hoje, não se restringe a um *website* ou página específica pois são também utilizados nas diversas redes sociais para, por exemplo, ajudar a delinear umas férias. Ademais, estes trabalham de forma ininterrupta (Matias, 2020).

Os chatbots, pela primeira vez, foram introduzidos na aplicação de mensagens do Facebook – Messenger – em 2016, com a finalidade de facilitar e acelerar o serviço de atendimento ao cliente. A partir de então, os mesmos passaram a ser reconhecidos como uma ferramenta tecnológica, atribuída de conhecimento acerca de linguagem natural, programados para dialogar com os seus utilizadores e, assim, oferecer informações sobre

determinados produtos e serviços, ou fazer encomendas *online* em tempo real (Martins, 2022).

Esta tecnologia dispõe de diversas características vantajosas: proporciona ao consumidor experiências mais realistas e personalizadas, fornece discursos idênticos com o ser humano, desfruta de uma comunicação em qualquer idioma, proporciona redução de custos, oferece um maior agrado ao indivíduo, fornece respostas inteligentes e contextuais em tempo real, entre outras (Alves, 2023).

Uma das características vantajosas é apoiada pelos autores Bavaresco et al. (2020), uma vez que o estudo realizado por estes assegurou que implementar um chatbot resulta numa poupança nos custos das empresas.

Os chatbots, caracterizados por agentes inteligentes, são utilizados por grande parte das empresas. Marcas de luxo como, nomeadamente, Louis Vuitton, Burberry, Prada e Gucci implementaram estes pois os seus clientes procuram experiências diferenciadoras. Estas têm noção que o atendimento fora do *online* é importante, porém, o atendimento no digital contribui para fortalecer a relação com os consumidores, acabando por satisfazê-los de tal forma que a vontade por comprar aumenta (Chung et al., 2020).

No entanto, não são apenas estas marcas referidas que auferem dos benefícios dos chatbots pois existem outros casos de igual sucesso. Por exemplo, a assistente virtual apelidada de Siri – alusiva à Apple – e, ainda, a Edward – disponibilizada pela cadeia de hotéis Edwardian. Esta última comunica de jeito a guiar os turistas durante as suas viagens (Tussyadiah, 2020).

Nos últimos anos é possível verificar um crescimento exponencial do e-commerce e, portanto, esta é a área onde mais se evidenciou o uso de chatbots (Bavaresco et al., 2020). Estes são responsáveis pela interação dos consumidores com as empresas, conforme mostra a Figura 4 (Chandra et al., 2023), na medida em que os auxiliam na personalização do processo de compra.

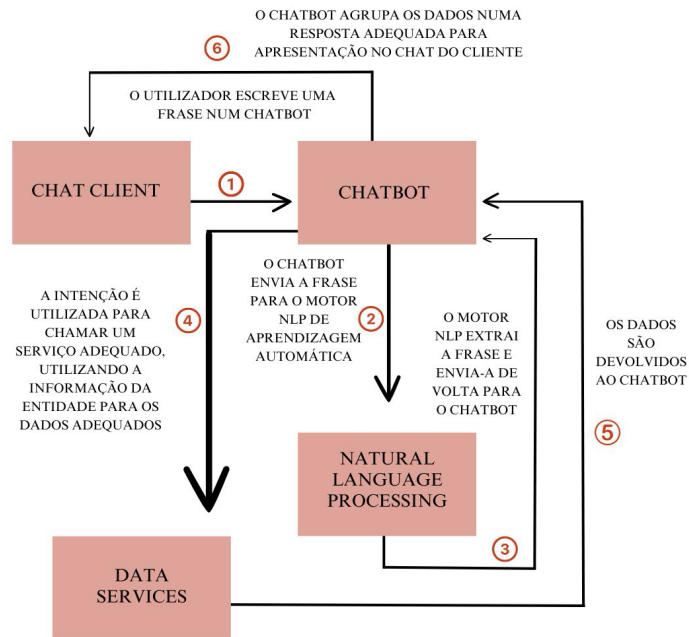


Figura 4: Interação entre chatbots e clientes.

Alguns chatbots são tão naturais e convincentes que é difícil distingui-los da assistência humana ao cliente, sendo que um robô simulado por voz monitora a encomenda e a conclusão da transação, incluindo informações sobre preços e hora de levantamento (Chandra et al., 2023).

Este agente inteligente é um excelente caso da implementação da IA no e-commerce e, indiscutivelmente, encontra-se orientado para o consumidor de forma a proporcionar-lhe uma experiência única. Conforme Araujo (2018), existem evidências de que os chatbots influenciam a maneira com os consumidores encaram a empresa e a própria marca.

São várias as soluções baseadas em IA inerentes nos sistemas empresariais, sendo que na Figura 5 observa-se algumas aplicações importantes e comuns (N. Singh & Chouhan, 2021):

- Gestão e exatidão de dados: transferência e referência;
- Feedbacks e soluções dos clientes;
- Recomendações sobre produtos e previsão do comportamento dos consumidores até certo ponto;

- Chatbots para interação;
- Publicidade e marketing;
- Relatórios de progresso;
- Automatizações de processos;
- Análise em tempo real e medidas de segurança contra burlas e fraudes.



Figura 5: Soluções baseadas em IA para vários segmentos, de forma a criar um sistema empresarial inteligente.

As empresas estão a investir em tecnologias de IA para as suas operações comerciais com vários propósitos: poupar dinheiro e tempo, diminuir a carga de trabalho dos trabalhadores, aumentar a produção, aproximar-se de novos consumidores, aumentar a eficiência e criar novos mercados (N. Singh & Chouhan, 2021).

A IA ocupa um grande espaço no desenvolvimento do e-commerce e, naturalmente, traz mais comodidade e confiança ao utilizador (Chandra et al., 2023). Posto isto, o e-commerce enriquece devido às vantagens que esta subárea da ciência da computação proporciona ao nível da melhoria da experiência de cada consumidor, de jeito a personalizar o seu atendimento e, por conseguinte, tornar mais flexível o processo de compra (Alves, 2023).

1.4 Algoritmos de recomendação

Na esfera da IA, a essência da humanidade é agora representada por um algoritmo desenvolvido a partir das bases lógicas adequadas à interação entre máquina e programa. O "algorítmico" emerge como uma nova forma de organização lógica da vida, um novo paradigma algorítmico para a existência, onde a vida é concebida a partir de um novo conjunto de algoritmos (Carvalho, 2023).

Analisar as previsões de algoritmos de inteligência analítica, inteligência preditiva, análise de dados e de recomendação é crucial porque tratar de IA vai além dos conceitos básicos (Paulichi & Cardin, 2020).

A inteligência analítica realiza a análise de dados previamente captados e, à posteriori, concebe um relatório transformando esses dados em informações padronizadas. Com base nos dados captados e, ainda, nas informações padronizadas a mesma consegue utilizá-las para fornecer ao utilizador anúncios de produtos/serviços em que este já demonstrou interesse (Paulichi & Cardin, 2020).

A análise preditiva utiliza a exploração de dados por meio de estudo, sendo que o material é classificado e preparado para respectiva avaliação. Para mais, a partir da aprendizagem de experiências anteriores sobre o comportamento do consumidor tem a capacidade de antecipar e calcular futuros comportamentos deste, seja em *websites* de compras como em aplicações móveis (Paulichi & Cardin, 2020).

Desde o fim dos anos 60 que a análise de dados é utilizada, porém, de acordo com Sharda et al. (2019) a partir de 2010 instaurou-se um novo método de recolha e uso de dados devido à disseminação da utilização da internet.

Segundo os autores Jr et al. (2022), “a geração de dados acontece em grande volume, oriundos de empresas, organizações e pessoas comuns, a todo tempo e em todos os lugares”. Estes são armazenados em nuvens e de uma forma mais acessível, fácil e com menor custo comparativamente ao realizado há alguns anos atrás.

As tecnologias e dispositivos que utilizam a IA são essenciais neste mundo de recolha de dados a fim de auxiliar as organizações para as respectivas análises de marketing e, ainda, no desenvolvimento de estratégias. Davenport et al. (2020) afirmam que as *analytics* alimentadas através do conceito explanado conseguem prever o que consumidor

estará mais disposto a comprar e, por conseguinte, encaminhar em tempo real promoções para encorajá-lo à decisão de compra.

Ao lidar com grandes quantidades de dados, é fundamental encontrar rapidamente as informações mais úteis para os utilizadores. Para atender às necessidades destes, surgiram vários sistemas de recomendação (Lin et al., 2022).

Os algoritmos de recomendação usam o cálculo de probabilidades para descobrir quais itens são mais interessantes para os utilizadores. Os algoritmos são a base dos sistemas de recomendação, e o uso de algoritmos de recomendação eficientes e precisos é fundamental para obter resultados de recomendação satisfatórios (Lin et al., 2022).

São várias as tarefas que os algoritmos de IA realizam sem qualquer ou nenhuma intervenção humana como: transferência de dados de email para um sistema de armazenamento interno, implementação de transações simples no mercado, leitura de documentos de maneira a extrair informações importantes, entre outras (Davenport et al., 2020).

1.4.1 Sistemas de Recomendação Tradicionais

À medida que a escala da internet continua a expandir-se ano após ano, a disponibilidade de recursos de informação cresce exponencialmente, levando ao fenómeno da "sobrecarga de informação". Este fenómeno dificulta aos utilizadores a obtenção rápida de informações relevantes dentro da vasta quantidade de dados disponíveis. Especificamente no contexto das plataformas de e-commerce, onde há uma enorme quantidade de informações sobre lojas e produtos, os utilizadores enfrentam desafios significativos na navegação, seleção e tomada de decisões. Para enfrentar esse problema crescente de sobrecarga de informação, têm surgido motores de pesquisa e sistemas de filtragem de informações e recomendação, de modo facilitar o acesso dos utilizadores a informações relevantes e personalizadas (Huang, 2022).

Os retalhistas oferecem aos utilizadores uma vasta seleção de produtos (Koren, 2013), no entanto, essa abundância acarreta um problema de excesso de informação para o utilizador (Z. Yang et al., 2016), dificultando a localização das informações de interesse. Neste cenário, os sistemas de filtragem de informações, como os de recomendação, têm-se destacado e demonstrado a sua relevância, permitindo aos utilizadores receber

recomendações personalizadas de itens que correspondem aos seus gostos (Adomavicius & Tuzhilin, 2005) e fornecendo assim a informação desejada.

Os algoritmos de recomendação, desenvolvidos por profissionais de informática, utilizam técnicas matemáticas para prever os interesses dos utilizadores. A história destes remonta a 1992, quando o Palo Alto Research Center da Xerox propôs um sistema de recomendação baseado em filtragem colaborativa para combater o *spam* (Goldberg et al., 1992). Contudo, foi em 2003 que a Amazon revolucionou o e-commerce ao implementar efetivamente algoritmos de recomendação no seu *website* (Linden et al., 2003).

Os sistemas de recomendação nasceram no e-commerce e desenvolveram-se junto com o crescimento desse setor. O conceito de recomendação personalizada surgiu no final dos anos 90, com apresentações de sistemas como o *Web Watcher* e o LIRA, destacando-se na Associação Americana de Inteligência Artificial (Z. Zhang, 2023).

A investigação em algoritmos de recomendação começou com o grupo de pesquisa GroupLens da Universidade do Minnesota nos anos 90, com o objetivo de criar um sistema de recomendação de filmes chamado Movielens que permitisse aos utilizadores personalizar as suas recomendações de filmes (Z. Zhang, 2023).

Tradicionalmente, os sistemas de recomendação são concebidos para identificar padrões entre utilizadores e produtos que ocorrem com frequência, visando recomendar produtos interessantes que um utilizador pode nem saber que está a procurar. Portanto, os principais desafios residem em incorporar as preferências individuais dos utilizadores nas recomendações e lidar com a vasta variedade de produtos e dados de atividade do utilizador (Gomes et al., 2021).

Os sistemas de recomendação encontram produtos ou itens do interesse do utilizador e, ainda, encontram pessoas, amigos ou eventos do seu interesse. Estes têm tido grande aplicação em muitas empresas de e-commerce, tais como: a recomendação de filmes da Netflix (Koren, 2013), a recomendação de produtos da Amazon (Linden et al., 2003), a personalização de notícias e a pesquisa de anúncios da Google (Aggarwal, 2016), entre outras.

A geração de previsões e recomendações são as duas tarefas principais em que os sistemas de recomendação são usados (Aggarwal, 2016). Esta primeira envolve prever se um utilizador gostará ou não de um item e prever a classificação que esse item receberá

do mesmo. A tarefa de geração de recomendações consiste em recomendar um conjunto ou um grupo de itens a um utilizador (Mehta & Rana, 2017).

Os sistemas de recomendação recolhem informações sobre o comportamento passado do utilizador num conjunto de itens e utilizam-nas para a recomendação. As informações apresentam várias nuances: explícitas (como as classificações do utilizador), implícitas (como o histórico de navegação), demográficas, sociais (como amigos, etiquetas, fiduciários ou curadores) ou contextuais (como a hora ou a localização) (Bobadilla et al., 2013).

Ao fornecerem recomendações ou ao gerarem previsões, os recomendadores são avaliados pelo seu grau de exatidão. No entanto, a maioria dos recomendadores enfrenta problemas de arranque a frio e falta de dados, o que dificulta a obtenção de resultados precisos (Mehta & Rana, 2017). Além disso, são menos escaláveis (Adomavicius & Tuzhilin, 2005) e não funcionam bem com dados de alta dimensão (Sarwar et al., n.d.).

São várias as técnicas de recomendação que têm sido desenvolvidas ao longo do tempo para ultrapassar estes problemas como, por exemplo, as técnicas baseadas na abordagem de filtragem colaborativa que estão a ganhar popularidade devido à sua ampla aplicabilidade em diferentes itens.

Adomavicius & Tuzhilin (2006) dividiram os algoritmos tradicionais de recomendação em três categorias principais: Recomendação Baseada em Conteúdo (RBC), Filtragem Colaborativa (FC) e Abordagem Híbrida. Neste seguimento, muitos académicos defenderam-nas como, por exemplo, Adomavicius & Tuzhilin (2005), Bobadilla et al., (2013), Z. Yang et al. (2016). A hierarquia das categorias é apresentada na Figura 6.

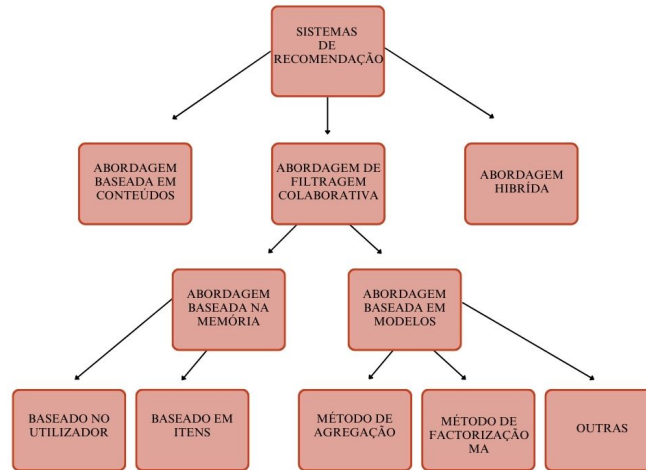


Figura 6: Abordagens do sistema de recomendação.

Todavia, conforme Shah et al. (2016), os algoritmos modernos para sistemas de recomendação são classificados em cinco categorias, ao contrário do que é explicitado por certos autores Adomavicius & Tuzhilin (2005) e Z. Yang et al. (2016) que mencionam apenas a existência de três tipos de métodos. Assim, além dos mencionados anteriormente, deve-se incluir os sistemas baseados em demografia e os baseados em conhecimento.

A filtragem baseada em conteúdo baseia-se na semelhança entre os itens a recomendar (Gomes et al., 2021), ou seja, os utilizadores recebem produtos ou serviços comparáveis aos que eles preferiram anteriormente (Adomavicius & Tuzhilin, 2005). Uma imagem gráfica, um fluxo de áudio, um fluxo de vídeo, etiquetas ou texto podem ser usados para fazer recomendações (Bobadilla et al., 2013).

A informação de conteúdo não é facilmente analisável por máquinas e, devido a isto, as abordagens FBC são menos recomendadas pois frequentemente sofrem de sobre-especialização (Adomavicius & Tuzhilin, 2005) e são difíceis de avaliar.

Goldberg, Nicols, Oki, e Terry introduziram a FC em 1992 e implementaram-na no sistema Tapestry (H. Yang et al., 2022), o qual inicialmente tinha um número limitado de utilizadores.

A FC baseia-se em gostos ou hábitos de compra comparáveis entre os utilizadores. Neste caso, parte-se do princípio de que existem utilizadores com interesses e preferências semelhantes e, por conseguinte, com comportamentos semelhantes (Shah et al., 2016). As recomendações são feitas usando classificações de utilizadores idênticos ou itens e

não há problemas relacionados com o conteúdo analisável por máquinas, ao contrário da FBC. Além disso, os problemas de avaliação e sobre-especialização são reduzidos por estes (Mehta & Rana, 2017) e (Adomavicius & Tuzhilin, 2005), acabando pelos métodos serem amplamente usados por uma variedade de recomendadores.

Esta categoria da abordagem dos sistemas de recomendação é a mais utilizada para recomendar ou sugerir artigos, serviços e anúncios com base em fatores históricos, como padrões de compra, para melhorar as decisões de marketing. Por exemplo, a Amazon tornou este modelo de recomendação famoso com a sua tendência de sugestões: "clientes que gostaram deste produto, também gostaram de (...)" (S. Gupta & Joshi, 2022).

O sistema de recomendação do modelo faz recomendações de produtos personalizados usando técnicas de FC. Ao analisar o histórico de classificações e interações dos consumidores com produtos, este pode identificar padrões e semelhanças entre consumidores e produtos. Isso permite, por exemplo, recomendar produtos a um consumidor específico que possa estar interessado num produto específico, com base nas suas preferências e comportamentos (B. B. Gupta et al., 2024).

Esta categoria provou ser uma maneira eficiente de criar funcionalidades personalizadas como as recomendações, mas também uma forma excelente de saber mais sobre os utilizadores de uma organização e as suas preferências em geral (S. Gupta & Joshi, 2022). Ao fornecer recomendações precisas e relevantes, o sistema visa aumentar a satisfação do utilizador, aumentar o envolvimento e, em última análise, melhorar a experiência geral do utilizador (B. B. Gupta et al., 2024). Aplicativos populares como o Spotify e a Amazon utilizam algoritmos especiais ou abordagens técnicas para organizar e fornecer conteúdos, tais como a FC (S. Gupta & Joshi, 2022).

Dentro da FC existe uma divisão entre abordagem baseada em memória e abordagem baseada em modelo, com fundamento na forma como os dados da matriz de classificação são processados (J. Lee et al., 2012).

A abordagem baseada na memória utiliza medidas de semelhança entre utilizadores (ou itens) para encontrar os seus vizinhos relevantes (Goldberg et al., 1992) e, em seguida, utiliza esses vizinhos para recomendar ou prever itens (ou utilizadores). Esta permite uma fácil implementação e interpretação dos resultados, porém, é menos preferível para dados esparsos e de elevada dimensão.

A abordagem de filtragem colaborativa baseada em modelos ajusta um modelo paramétrico para fornecer recomendações ou previsões (Z. Yang et al., 2016). O processo de aprendizagem de modelos é efetuado em cinco fases. A primeira fase consiste no espaço de hipóteses que inclui a geração de um modelo, isto é, uma regra de previsão. De seguida, a segunda fase e a terceira fase consistem em formar uma função objetivo utilizada para aprender os parâmetros do modelo e, ainda, aplicar-lhe a regularização. A função objetivo pode ser uma função de minimização (perda) ou de maximização, com a recomendação geralmente sendo uma função de minimização.

A quarta fase rege-se pela aplicação de uma estratégia de otimização à função objetivo, de modo a estimar os melhores valores para os parâmetros do modelo. A estratégia de otimização pode ser heurística, como o algoritmo genético e o reconhecimento simulado, ou iterativa, como o método de gradiente descendente e o método dos mínimos quadrados alternados (Mehta & Rana, 2017). Devido à sua convergência rápida, as estratégias iterativas são preferidas. Por último, a quinta fase consiste em validar e testar o modelo que inclui métricas de avaliação, métodos de validação como o erro médio absoluto, a raiz do erro quadrático médio, a precisão, a recuperação, a validação cruzada e as técnicas de validação de espera (Parra & Sahebi, 2013).

A abordagem baseada em modelos aprende e ajusta um modelo parametrizado à matriz de classificação (Mehta & Rana, 2017) como, por exemplo, os modelos baseados em Fatorização Matricial (FM) que são ótimos a lidar com dados de elevada dimensão e a atenuar a esparsidade (Mehta & Rana, 2017).

A FM tornou-se uma solução potente para reduzir a dimensão dos dados, extrair características latentes destes e também atenuar a esparsidade. Devido às suas características, são amplamente utilizadas em sistemas de recomendação.

As técnicas de FM utilizadas nos recomendadores incluem a Análise de Componentes Principais (ACP) (doc.b/15), a Factorização Matricial Probabilística (FMP) (Mehta & Rana, 2017), a Factorização Matricial não Negativa (FMN) (D. Lee & Seung, 1999) e a Decomposição do Valor Singular (DVS) (Sarwar et al., n.d.):

- ACP: gera a matriz de covariância da matriz de classificação do item do utilizador e, de seguida, efetua a redução da dimensão. Não obstante, a capacidade da PCA de utilização de matrizes simétricas tornou a sua aplicação restrita;

- FMP: trata as notações como um modelo gráfico probabilístico, ajustando os dados de classificação de uma forma aproximada;
- FMN: impõe restrições de não-negatividade às matrizes fatoriais, baseando-se no facto de todos os dados do mundo real, como imagens ou vídeos, serem não negativos;
- DVS: é uma realização da NMF sem restrições no sinal dos dados.

A DVS foi utilizada pela primeira vez para sistemas de recomendação em 2000. A DVS reduz a dimensionalidade de uma matriz de classificação utilizador-item e concebe aproximações de matrizes de baixo nível, que representam as características latentes (características ocultas) dos utilizadores e dos itens inerentes à matriz de classificação. De acordo com o autor (Sarwar et al., n.d.), a DVS apresentou um melhor desempenho do que a abordagem baseada na memória, em dados de e-commerce.

Quanto às restantes abordagens de recomendação, a filtragem baseada na demografia utiliza as informações básicas dos utilizadores, incluindo a idade, o sexo e o local de residência, para calcular o grau de correlação entre os utilizadores e, em seguida, fazer recomendações aos utilizadores (Lin et al., 2022). Quando não há informações suficientes disponíveis para fornecer recomendações, os sistemas de recomendação baseados no conhecimento são usados principalmente. As compras caras, como comprar uma casa ou um carro, são exemplos disso. No entanto, as recomendações também podem ser feitas com base em todo o conhecimento que pode ser encontrado no caso de utilização (Shah et al., 2016).

Por último, a abordagem híbrida aproveita as vantagens de cada algoritmo de recomendação, aprende com os pontos fortes de cada um e complementa os pontos fracos, alcançando um melhor efeito de recomendação e melhorando a eficácia do conteúdo recomendado aos utilizadores (H. Yang et al., 2022). De salientar que estes sistemas de recomendação utilizam os dados anteriores de um utilizador para descobrir os seus interesses e, em seguida, visam o conjunto de um utilizador adjacente que é semelhante a esse utilizador e, conforme o utilizador adjacente, recomendam coisas ao utilizador (Ramesh & Vijayalakshmi, 2022).

1.4.1.1 Métodos de Recuperação e Classificação

Para lidar com o desafio de recomendar aos utilizadores artigos de entre milhões de itens disponíveis, um sistema de recomendação geralmente é dividido em duas fases distintas: recuperação e classificação (Zhao et al., 2023).

Na fase de recuperação, o sistema é capaz de rapidamente recuperar centenas de produtos potencialmente relevantes dentro um vasto conjunto de itens disponíveis, formando um conjunto de produtos candidatos. Na fase de classificação, esses produtos candidatos são então avaliados e classificados, e os produtos com as melhores classificações são recomendados aos utilizadores. Essa fase inclui a reavaliação e classificação do conjunto de produtos candidatos, resultando na geração da lista final de recomendação (Zhao et al., 2023). A estrutura geral do processo é ilustrada na Figura 7.

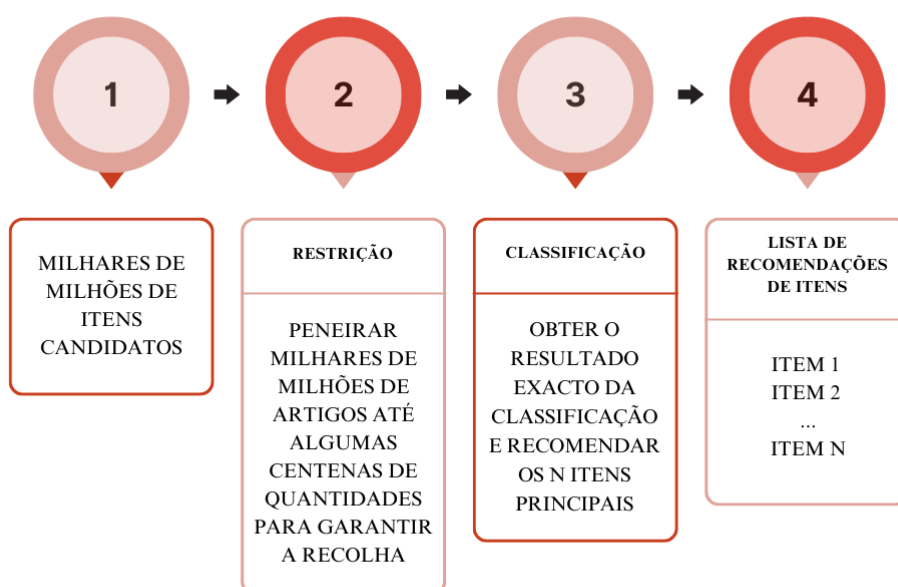


Figura 7: Estrutura de um sistema de recomendação.

A camada de recuperação está exposta a milhões de dados como a primeira fase do sistema de recomendação. O objetivo primordial desta etapa é processar esses dados em grande escala, identificando um conjunto reduzido de produtos candidatos. Isso é feito com o intuito de diminuir o volume de dados que será encaminhado para a próxima fase, a camada de classificação, e conseqüentemente, aumentar a precisão das recomendações (Zhao et al., 2023). Por conseguinte, os algoritmos na fase de recuperação têm principalmente as seguintes características:

- 1) Estrutura simples;
- 2) Capacidade de processar uma grande quantidade de dados com elevada eficiência computacional;
- 3) A exatidão não precisa de ser demasiado elevada.

Dentro das estratégias de recuperação personalizada, a FC destaca-se como um dos algoritmos da aprendizagem automática mais tradicionais e amplamente adotados nos sistemas de recomendação (Zhao et al., 2023). Todavia, com o avanço da aprendizagem profunda, as técnicas de recuperação baseadas nesse campo tornaram-se os métodos mais avançados. A técnica de incorporação é fundamental na aprendizagem profunda, permitindo a transformação de vetores esparsos de alta dimensão em vetores densos de baixa dimensão. Esse processo visa capturar semelhanças de ordem superior nas sequências de comportamento do utilizador (Zhao et al., 2023).

1.4.1.2 Aprendizagem Federada

O setor de eletrónica de consumo tem visto a personalização como um componente vital. A introdução da Aprendizagem Federada (AF) descentralizada trouxe um potencial significativo e ampliou os limites das recomendações personalizadas (B. B. Gupta et al., 2024).

Em termos científicos, segundo a comunidade de investigação no seu conjunto, a aprendizagem federada é uma abordagem de aprendizagem automática que, ao contrário da aprendizagem convencional, treina um algoritmo sem deslocar amostras de dados pelo meio de um grande número de dispositivos ou servidores de ponta distribuídos (B. B. Gupta et al., 2024).

Esta trata-se de um tipo de aprendizagem automática em que vários clientes treinam um modelo único em conjunto com a ajuda de um servidor de coordenação, mas com os dados do modelo armazenados em locais diferentes (DeGroot, 1974). O facto de a AF permitir que vários participantes colaborem para criar um modelo de aprendizagem automática robusto e independente da partilha de dados, inevitavelmente, resolve uma variedade de questões, como privacidade, segurança, direitos de acesso e heterogeneidade de dados (Wang et al., 2024).

A preocupação com a privacidade e a segurança associados à recolha de dados privados de vários clientes é justificada (B. B. Gupta et al., 2024). Como resultado, a AF ganhou rapidamente popularidade, tanto no meio académico como na indústria, devido à sua capacidade de proteger a privacidade dos utilizadores da internet (Pequito et al., 2014).

Antigamente, os modelos de aprendizagem automática centralizados eram usados para construir sistemas de recomendação. Estes modelos caracterizavam-se pela recolha e armazenamento centralizado de informações de utilizadores. No entanto, este método expõe os dados sensíveis dos utilizadores a possíveis violações, ciberataques ou utilização indevida, representando riscos significativos para a privacidade e a segurança (B. B. Gupta et al., 2024).

Devido à sua capacidade de aprender de forma distribuída e independente, os sistemas de recomendação baseados na AF são amplamente utilizados nos dias de hoje (B. B. Gupta et al., 2024). Isso significa que esta abordagem é ideal para a construção de produtos eletrónicos de consumo com sistemas de recomendação incorporados (Freris & Patrinos, 2016).

Neste método, conforme se verifica na Figura 8, os dados do utilizador permanecem no dispositivo e os únicos parâmetros agregados do modelo são enviados para o serviço de nuvem. Isso evita que os dados pessoais saiam do dispositivo e cheguem a terceiros não autorizados (B. B. Gupta et al., 2024).

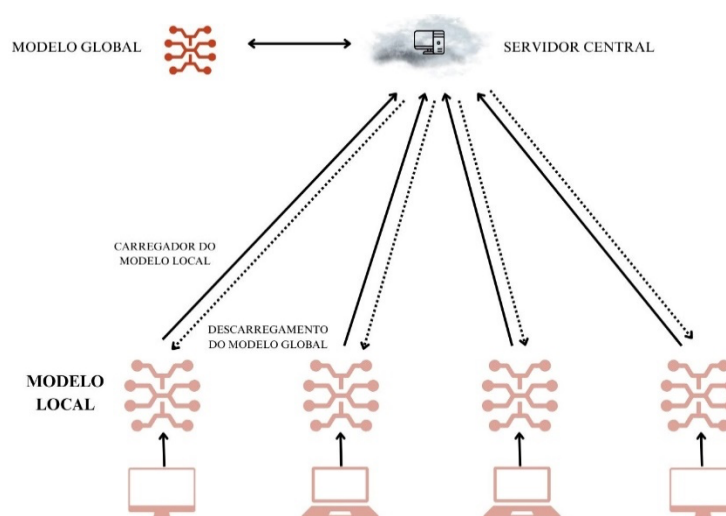


Figura 8: Arquitetura da AF.

Na arquitetura da AF, as preferências e os interesses do utilizador são captados durante a formação do modelo no dispositivo local. Isso significa que os sistemas de recomendação baseados na AF podem fornecer recomendações mais personalizadas. Logo, a implementação de sistemas de recomendação baseados na AF para a criação de sistemas de recomendação individualizados em dispositivos eletrônicos de consumo é um método seguro, privado e eficaz (B. B. Gupta et al., 2024).

De acordo com estes autores (Jonathan & Yehuda, n.d.), a AF e aprendizagem profunda podem melhorar o desempenho de muitos sistemas, como os sistemas de recomendação que melhoram a personalização.

Vários investigadores apresentam os seus métodos. Um quadro de meta-aprendizagem federada para recomendação, apresentado por Liu et al. (2006), partilha informações do utilizador ao nível do algoritmo, mantendo a privacidade do utilizador e utilizando as informações de outros utilizadores para ajudar a modelar a formação. B. B. Gupta et al. (2024) apresenta uma nova abordagem chamada de "*FedFast*", que visa acelerar a aprendizagem distribuída com alta precisão para todos os utilizadores logo no início do processo de aprendizagem. Um esquema de aprendizagem de ponta federada em conjunto, proposto por B. B. Gupta et al. (2024) tem como objetivo melhorar os sistemas de recomendação de maneira eficiente e eficaz, sem comprometer a privacidade dos dados dos utilizadores.

Estes estudos indicam que a AF pode melhorar os sistemas de recomendação, proteger a privacidade do utilizador e reduzir os custos de comunicação (B. B. Gupta et al., 2024). No entanto, é crucial apresentar o modelo de sistema desenvolvido pelos autores B. B. Gupta et al. (2024), que desde o início mantiveram o objetivo de desenvolver um quadro de aprendizagem federado descentralizado seguro e privado para recomendações personalizadas em eletrônicos de consumo.

Para garantir a segurança, integridade e privacidade dos dados durante todo o processo de aprendizagem, o modelo de sistema foi projetado usando tecnologia *blockchain* e criptografia homomórfica, como ilustrado na Figura 9 (B. B. Gupta et al., 2024).

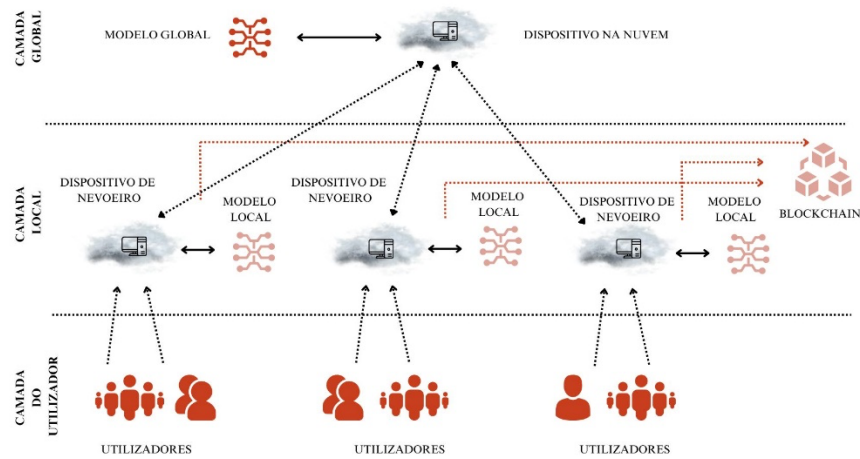


Figura 9: Modelo de Sistema.

Ao explicar o modelo sugerido, são identificadas três camadas separadas:

- Camada do utilizador: A primeira camada do modelo de sistema inclui os utilizadores e os seus dispositivos. Estes primeiros, respetivamente, participam no processo de AF partilhando os seus dados com as camadas superiores. Para proteger a privacidade dos utilizadores, primeiro os dados são encriptados com técnicas de encriptação holomórfica. Isso permite fazer cálculos com dados encriptados sem descriptá-los. Os utilizadores podem prestar os seus dados sem revelar dados confidenciais;
- Camada local: A segunda camada do modelo serve como uma ponte entre a camada global e a camada do utilizador. Inclui dispositivos de nevoeiro que armazenam modelos locais e os atualizam com dados dos utilizadores, mantendo a privacidade. Para atualizar o modelo global, estes modelos locais são depois sincronizados com a camada global. Além disso, a camada local é responsável pelo registo e autenticação dos utilizadores;
- Camada global: A terceira camada do modelo consiste em dispositivos de nuvem que armazenam o modelo global que é uma agregação dos modelos locais refinados recebidos da camada local.

1.4.2 Sistemas de Recomendação com Inteligência Artificial

Com o crescente uso das plataformas de e-commerce, as expectativas dos consumidores em relação à recomendação de produtos estão em constante ascensão. Estes desejam receber sugestões mais personalizadas e direcionadas para encontrar rapidamente os produtos desejados e atender às suas necessidades de compra de forma eficaz (Y. Zhang & Li, 2023).

Os métodos tradicionais de recomendação, como a FC, não conseguem mais atender a essa procura. Assim, a criação de algoritmos personalizados de recomendação, utilizando tecnologia de IA, está a tornar-se uma tendência popular para plataformas de e-commerce (Y. Zhang & Li, 2023).

O algoritmo de recomendação personalizada para o e-commerce baseado na tecnologia de IA introduz métodos e tecnologias inovadoras, como computação distribuída, computação incremental e modelos de aprendizagem profunda para resolver os problemas da elevada complexidade computacional e da lenta velocidade de resposta da FC, decomposição matricial e outros algoritmos no processamento de dados maciços (Y. Zhang & Li, 2023). No fundo, ao usar técnicas como aprendizagem profunda e processamento de linguagem natural para recolher e analisar dados de comportamento do consumidor, é possível identificar os interesses e necessidades do mesmo e fornecer recomendações personalizadas de produtos.

A aprendizagem automática continuou a dominar os sistemas de recomendação em 2014. No entanto, redes de aprendizagem profunda extraordinárias, como a AlexNet, surgiram no campo vizinho em 2012 (Krizhevsky et al., 2017). Esta onda teve um impacto inevitável nos sistemas de recomendação, sendo a aprendizagem profunda oficialmente introduzida nos sistemas de recomendação em 2015.

Os sistemas de recomendação baseados em aprendizagem profunda podem ser diferenciados com base na arquitetura subjacente (S. Zhang et al., 2019). Dada a ampla variedade de abordagens de aprendizagem profunda, destaca-se a utilização de perceptrões multicamadas (PM), redes neuronais convolucionais (RNC), redes neuronais recorrentes, redes de atenção neuronais e incorporações de aprendizagem profunda para melhorar as recomendações.

Os PM formam a base da FC neural, onde redes neurais profundas e FC são combinadas em estruturas de recomendação amplas (He et al., 2017). Outra abordagem é a recomendação com modelos semânticos estruturados profundamente, que também utiliza PM para recomendações, com o objetivo de aprender representações semânticas dos itens (Elkahky et al., 2015; Serrà & Karatzoglou, 2017).

Na sua maioria, as RNC são usadas para extrair características de dados multimídia não estruturados, mas também demonstraram ser capazes de fornecer diretrizes (S. Zhang et al., 2019). Além disso, a FC baseada em CNN (He et al., 2018) podem ser usadas para recomendação. Por outro lado, as redes neuronais recorrentes são utilizadas principalmente para prever o próximo item numa sequência de interações do utilizador (C. Y. Wu et al., 2017; S. Wu et al., 2016). Mais recentemente, foram desenvolvidas abordagens baseadas em recomendadores baseados na atenção neural.

Recentemente, com o avanço da pesquisa na área da tecnologia de aprendizagem profunda, esta tem apresentado resultados promissores em várias aplicações, incluindo reconhecimento de imagens, processamento de linguagem natural, reconhecimento de fala, entre outros campos (Mu et al., 2018).

No fundo, comparativamente aos modelos de recomendação tradicionais, como recomendação baseada em conteúdo, FC e recomendação híbrida, a tecnologia de aprendizagem profunda tem a capacidade de explorar de maneira mais eficaz e profunda as profundas necessidades dos utilizadores, as características dos itens e os registos históricos de interação entre utilizador e item (Mu et al., 2018).

Nos últimos anos, a tecnologia de IA emergiu como um dos algoritmos mais proeminentes no âmbito da recomendação personalizada e-commerce, destacando-se pelas suas avançadas capacidades de processamento de dados, compreensão semântica e habilidade para representar de forma abrangente as características de interesse do utilizador (Sumathi et al., 2021). Ao analisar o histórico de pesquisa, registos de compras, comportamento de navegação e outros dados de diversas fontes, e empregar técnicas como aprendizagem profunda e processamento de linguagem natural, é possível obter uma compreensão mais profunda das necessidades, desejos, preferências e outras informações do utilizador, resultando em recomendações de produtos mais precisas e personalizadas. Além disso, esse algoritmo pode ser ajustado e otimizado em tempo real

para atender às diferentes necessidades ou cenários dos utilizadores, resultando em recomendações mais direcionadas e eficazes (Bosri et al., 2021; R. Singh, 2021).

Comparada com o algoritmo tradicional baseado em FC, a IA demonstra uma capacidade superior para lidar com dados de diversas fontes e uma notável capacidade de adaptação e inteligência, o que resulta em serviços de recomendação mais abrangentes, precisos e personalizados (Y. Zhang & Li, 2023).

Cada vez mais, a recomendação personalizada nas plataformas de e-commerce criada pela IA é de grande importância e valor de aplicação para fornecer uma melhor experiência de compra e fidelidade do utilizador.

Em primeiro lugar, o sistema de recomendação personalizada baseado em IA para e-commerce pode recolher e analisar dados de produtos, análises de encomendas, impactos de marcas e avaliações. Os dados são analisados usando algoritmos de aprendizagem automática, extração de dados e aprendizagem profunda. Em segundo lugar, este pode também fornecer serviços mais inteligentes por meio de perfis de utilizador, otimização do motor de recomendação e previsão, que inclui pesquisa personalizada, atividades de marketing personalizadas, análise emocional, recomendações em tempo real, entre outros. Por último, o sistema continuaria a aprender e a ajustar o modelo do algoritmo usando uma variedade de técnicas, incluindo aprendizagem por reforço, aprendizagem profunda e processamento de linguagem natural (Y. Zhang & Li, 2023).

A partir de uma variedade de produtos e informações, o sistema de recomendação para e-commerce de acordo com a IA escolhe os resultados de recomendação mais adequados e pertinentes ao analisar o comportamento e as preferências do utilizadores Estes sistemas são extremamente precisos, eficientes, diversos e adaptáveis, o que permite uma otimização a longo prazo e atualizações dinâmicas (Y. Zhang & Li, 2023).

Os autores Y. Zhang & Li (2023) realizaram um estudo que visou comparar as vantagens, desvantagens e cenários de aplicação dos algoritmos de FC e da tecnologia de IA em quatro plataformas de e-commerce: Amazon, eBay, Taobao e Jingdong. Deste, ressalta-se a Figura 10 que mostra a matéria da taxa de recuperação.

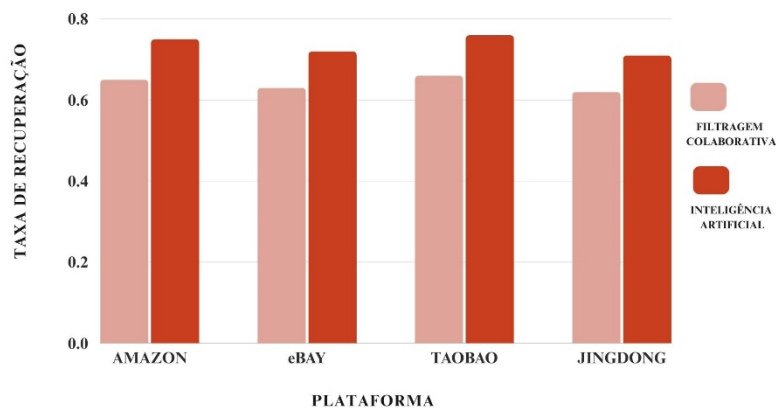


Figura 10: Resultado da comparação de taxas de recuperação entre diferentes algoritmos.

A taxa de recuperação, que representa a proporção de produtos efetivamente comprados em relação ao total de recomendações feitas pelo sistema, foi avaliada no estudo mencionado. Os resultados mostram que os algoritmos de recomendação baseados em IA superaram aqueles baseados em FC em todas as plataformas. A taxa de recuperação dos algoritmos de IA na Amazon e na Taobao foi cerca de 0,1 maior, indicando que eles são mais precisos do que os algoritmos de FC, atendendo aos interesses do utilizador e fornecendo recomendações que melhor atendem às suas necessidades (Y. Zhang & Li, 2023).

Os autores procuraram analisar, ainda, a exatidão dos dois algoritmos nas diversas plataformas conforme se verifica na Figura 11.

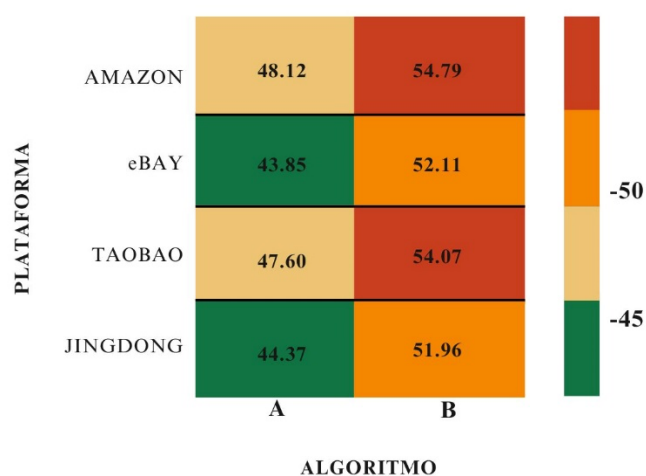


Figura 11: Resultados da comparação dos resultados da exatidão nos diferentes algoritmos.

A exatidão, que avalia a precisão do sistema ao recomendar informações aos clientes, reflete quantos itens recomendados são verdadeiramente de interesse para os utilizadores. Nas quatro plataformas, os algoritmos de recomendação baseados em IA demonstraram uma maior precisão. Especificamente, no eBay, a precisão aumentou de 43,85% para 52,11% após a implementação de algoritmos de IA para recomendações personalizadas, representando um aumento de aproximadamente 8,26% (Y. Zhang & Li, 2023).

Portanto, os resultados mostram que os algoritmos de recomendação baseados na IA têm uma taxa de recuperação aproximadamente 0,1 maior do que os algoritmos de recomendação baseados na FC e a precisão da recomendação do eBay melhorou cerca de 8,26% após o uso de algoritmos de IA para recomendações personalizadas (Y. Zhang & Li, 2023).

1.5 Personalização da Experiência do Consumidor

Atualmente, o uso do e-commerce aumentou significativamente, pois as pessoas preferem fazer compras *online* em vez de deslocarem aos mercados (Shrirame et al., 2020). As empresas de e-commerce podem obter informações e entender as necessidades e intenções dos consumidores por meio de uma análise precisa, com o propósito de personalizar a experiência do utilizador.

A personalização é uma técnica em que o setor do *software* utiliza os dados dos clientes em massa e, em seguida, utiliza esses dados para personalizar os conteúdos e as interfaces de utilizador para o consumidor (Pahadi et al., 2022). “*Marketers see an aggregate rise of 23% in trading when they use data to provide personalized experiences*”, diz um estudo da Monetate que consolida a importância da personalização para os profissionais de marketing.

No que diz respeito a esta perspectiva, várias investigações foram delineadas, por exemplo, a Epsilon afirma que 78% dos clientes têm maior probabilidade de comprar a uma empresa que proporcione experiências personalizadas. Além disso, os inquéritos da Accenture mostram que 83% dos consumidores estão dispostos a partilhar dados para obter uma experiência de compras *online* conveniente e personalizada (Pahadi et al., 2022). A conceituada empresa Netflix ressalta que 80% do conteúdo dos seus

consumidores é baseado em feedback algorítmico, permitindo que os consumidores tomem decisões mais rapidamente e com mais confiança.

No entanto, para uma empresa obter sucesso nas suas estratégias de personalização e, ainda, perceber melhor as necessidades e preferências dos diferentes grupos de clientes é imprescindível que adote a segmentação de mercado que envolve dividir os consumidores em grupos com características semelhantes, como demográficas, geográficas, psicográficas ou comportamentais. Logo, as organizações necessitam de utilizar a segmentação para personalizar a suas abordagens de marketing (Pahadi et al., 2022).

1.5.1 Segmentação de Mercado

Atualmente, muitas empresas de e-commerce enfrentam o desafio de não ter um público-alvo claro nas suas estratégias de marketing. Como resultado, todos os utilizadores são alvos de campanhas publicitárias extensivas e abrangentes, o que pode sobrecarregá-los com uma grande quantidade de mensagens sem diferenciação. A longo prazo, essa abordagem pode levar à resistência psicológica dos utilizadores e resultar na perda dos clientes-alvo. Portanto, há uma tendência geral na indústria do e-commerce de adotar o marketing segmentado baseado na tecnologia de big data (Zhang & Huang, 2022).

Nos últimos anos, a tecnologia de extração de dados tem ganho popularidade em países estrangeiros, o que indica uma tendência em aplicar essa tecnologia na segmentação de mercado (Zhang & Huang, 2022).

No seu estudo sobre extração de dados, Zhu (2023) examinou diferentes abordagens para segmentar os clientes. Uma abordagem revisada para o marketing segmentado na era da internet foi apresentada por Yang & Qiuxiang (2022) sugerindo que a tecnologia da internet pode ser usada para identificar com precisão os clientes e implementar campanhas de marketing personalizadas. Alguns autores discutiram como a tecnologia de extração de dados pode ser usada em atividades de marketing, destacar e guiar estratégias para aumentar os lucros (Zhang & Huang, 2022).

Nos últimos anos, a abundância de dados tem proporcionado novas oportunidades para a área de marketing na definição e segmentação de mercados. Os profissionais de marketing têm acesso a uma quantidade sem precedentes de informações para

fundamentarem as suas decisões. Com o avanço da microinformática, da internet e o desenvolvimento de sistemas de gestão de bancos de dados, o marketing conta agora com uma infraestrutura robusta para essa finalidade (Añaña et al., 2008).

Zhao et al. (2023) enfatizam a importância da recolha de dados para as operações de marketing, particularmente na era dos grandes volumes de dados. Destacam que o papel dos dados é crucial na implementação eficaz de estratégias de marketing. Além disso, alguns autores estudaram métodos de marketing baseados em dados de registro de utilizadores na internet, realçando a importância dos dados na era dos grandes volumes de dados. Esses estudos reforçam a ideia de que a recolha e análise de dados são fundamentais para o sucesso das estratégias de marketing na era atual (Zhang & Huang, 2022).

As comunidades virtuais surgiram como uma fonte rica, mas subutilizada, para identificar diferentes segmentos de mercado e desenvolver estratégias de abordagem mais eficazes. Os membros dessas comunidades revelam detalhes pessoais, sociais e psicológicos que, se interpretados corretamente pelos marketeers, podem fornecer *insights* valiosos para a segmentação de mercado (Añaña et al., 2008).

A proposta da segmentação de mercado, introduzida por Smith em 1956, visa identificar padrões de consumo ao dividir o mercado em subgrupos homogêneos, nos quais os consumidores compartilham necessidades, características e comportamentos semelhantes (Añaña et al., 2008).

A segmentação de mercado, conforme destacado por Kamineni (2005) é crucial para a estratégia de marketing de uma organização, pois o sucesso está ligado à compreensão das diferentes reações dos consumidores a estímulos específicos. Schiffman & Kanuk (2000) identificaram sete bases para a segmentação de mercado, como: geográfica, demográfica, psicográfica, sociocultural, relacionada com o uso, por uso-situação e benefício. Por sua vez, Kamineni (2005) consolidaram essas bases em segmentação geográfica, demográfica, psicográfica e comportamental, oferecendo uma abordagem mais concisa (Añaña et al., 2008).

Na segmentação geográfica, três critérios principais são considerados: país, região e cidade. O país está relacionado à cultura nacional, que pode moldar o comportamento dos consumidores em setores como bebidas, alimentos e entretenimento. Quanto à região, o local de residência do consumidor, seja em áreas urbanas densamente povoadas ou em

regiões mais rurais, pode influenciar as suas necessidades, hábitos e expectativas. A cidade ou até mesmo bairros específicos dentro dela podem ser critérios de segmentação para negócios locais, como restaurantes ou lojas (Añaña et al., 2008).

A segmentação demográfica abrange quatro critérios principais: idade, sexo, classe social e estrutura familiar. A idade é um fator demográfico fundamental que pode definir as necessidades, hábitos e contextos de consumo dos consumidores. O sexo também desempenha um papel importante em certos produtos, enquanto a classe social é determinada por indicadores como educação, ocupação e renda. A estrutura familiar considera os diferentes estágios da vida de um consumidor dentro de sua família (Añaña et al., 2008).

No que diz respeito à segmentação psicográfica, são considerados três critérios: atividades, interesses e opiniões. As atividades englobam trabalho, entretenimento, viagens, compras e esportes. Interesses referem-se a áreas como família, comunidade, moda, alimentação e mídia, enquanto as opiniões abrangem política, sociedade, negócios, educação e cultura (Añaña et al., 2008).

Na segmentação comportamental, três critérios são relevantes: situações de uso, hábitos de consumo e papéis de consumo. As situações de uso referem-se aos momentos em que os consumidores utilizam um produto, como consumidores regulares ou ocasionais de vinho. Os hábitos de consumo dividem os consumidores em categorias com base na frequência e quantidade de consumo, enquanto os papéis de consumo incluem o utilizador, o decisor, o comprador e o influenciador no processo de compra (Añaña et al., 2008).

Graças às variáveis da segmentação de mercado, a IA recomenda e direciona anúncios específicos para os clientes usando a localização, idade e gênero dos clientes, bem como os *links* que clica *online* e os artigos que lê no motor de pesquisa. Além disso, uma das partes mais importante da personalização é feita com base no comportamento dos consumidores que utilizam o *website*.

1.5.2 Comportamento do consumidor

As influências do macroambiente acerca do marketing podem afetar as empresas, neste sentido, as entidades sentiram a necessidade de perceber o comportamento do seu

consumidor que utiliza o e-commerce para direcionar o planejamento em marketing (Rosa et al., 2017).

Com o aparecimento de grandes indústrias e o aumento da produção de produtos, nasceu a exigência de estimular o consumo dos bens produzidos que, por conseguinte, fizeram com que o mercado esteja numa constante procura para corresponder às necessidades do consumidor (Araújo et al., 2023).

De acordo com Soares & Leal (2020), o consumo consiste na aquisição de um bem que é essencial à vida humana. Ademais, este é um aspeto inerente à condição humana que usufrui de características, sendo permanente, necessário, irremovível, intemporal, evolutivo, coletivo e integral no quotidiano de qualquer ser humano. Por outro lado, os autores sublinham que a aquisição de bens foi evoluindo devido à exigência do consumidor e, ainda, devido ao desenvolvimento da tecnologia e, desta forma, o consumo tornou-se não só numa forma de satisfação do que é essencial à vida humana como também do que não é essencial. No fundo, esta forma supérflua baseada no mero prazer denomina-se por consumismo.

O consumidor passou a ser influenciado por várias questões ao nível dos aspetos culturais, sociais e psicológicos que, naturalmente, encontram-se ligados aos grupos e vivências com determinados círculos de pessoas. Desta forma, este processo torna-se fundamental para que o mesmo determine as suas escolhas e desejos (Rosa et al., 2017).

Em 2010, Cerqueira et al. (2010 cit. in Araujo, 2018) afirmaram que o comportamento do consumidor é extremamente importante porque o consumidor é a parte essencial do crescimento e desenvolvimento de uma empresa que fornece serviços ou produtos específicos. Em 2012, Kotler (2012 cit. in Rosa et al., 2017) disse que o comportamento do consumidor é o estudo de como as pessoas, grupos e organizações escolhem, compram, usam e descartam bens, serviços, ideias ou experiências para atender às suas necessidades e desejos. Assim sendo, percebe-se que o ponto de partida é conhecer o consumidor e perceber acerca das suas necessidades e interesses de consumo.

É bem conhecido que vários fatores influenciam o comportamento dos compradores que usam a internet para fazer compras. Em particular, a facilidade de fazer uma procura detalhada de um produto específico em relação às suas especificações e funcionalidades, bem como a grande variedade de produtos disponíveis na rede, aumenta a probabilidade de fazer uma compra (Araújo et al., 2023).

Como mencionado anteriormente, os fatores que influenciam são de cariz cultural, social e pessoal. No entanto, Silva et al. (2021) enfatizam que é necessário prestar atenção a variáveis adicionais. Isso inclui aspetos de natureza política, tecnológica, econômica, ambiental e mercadológica. Este último, respetivamente, diz respeito ao produto, preço, promoção e ponto de distribuição. Como resultado, é claro que os quatro Ps iniciais do marketing estão presentes em termos de influência do comportamento do consumidor.

A cultura é sem dúvida o principal fator que influencia o comportamento das pessoas (Araujo, 2018) e, ainda, determina aquilo que desejam ver nas plataformas digitais, tornando a internet o principal canal de acesso à informação.

Ao nível pessoal sublinha-se os grupos de referência que exercem alguma influência direta, ou seja, presencialmente e, ainda, indireta acerca das atitudes ou comportamentos de um indivíduo. Os grupos que executam influência direta são apelidados como grupos de afinidade e alguns como grupos primários que tratam-se da família, dos amigos, dos vizinhos e dos colegas de trabalho, visto que são os que se interage de modo contínuo e informal (Kotler & Keller, 2012).

Para avaliar os efeitos destes fatores no comportamento dos consumidores *online*, é necessária uma abordagem abrangente. Chaudhry & Chandhok (2023) usaram as técnicas MCDM e o módulo SVTN-DEMATEL para mostrar as relações entre vários critérios e destacar várias áreas que são importantes. Assim, é necessário estudar uma combinação de fatores para explicar o complexo comportamento dos consumidores.

A internet gradualmente ganhou terreno na sociedade e levou as pessoas a relacionarem-se por meio de plataformas digitais (Rosa et al., 2017). Estas facilitam uma relação mais próxima com o consumidor, o que as torna uma ferramenta vital para as estratégias de marketing (Rosa et al., 2017). Atualmente, com as mudanças tecnológicas em andamento, é fundamental entender o comportamento do consumidor *online* para implementar *softwares* de e-commerce baseados na IA, pois esses métodos geram maiores lucros para as empresas e oferecem experiências de compra mais agradáveis para os clientes (J. Silva, 2020).

Conforme Araújo et al. (2023) existem alguns motivos que encaminham os indivíduos para as lojas *onlines*, sendo alguns deles:

- a) Comodidade: não é necessário sair de casa para comprar produtos, podendo fazer através de um computador, telemóvel, entre outros dispositivos móveis;
- b) Praticidade: através de um simples clique consegue-se ter acesso a qualquer coisa da loja, permitindo que não seja necessário passar horas numa loja para encontrar o produto desejado;
- c) Comunicabilidade: pelo meio das páginas de vendas, é possível conferir as opiniões de outros clientes sobre o produto, possibilitando avaliar se o produto realmente corresponde ao oferecido e às necessidades do consumidor;
- d) Comparação de preços: devido à praticidade, pode-se realizar a comparação de preços de um produto que deseja em diversas lojas, aumentando as possibilidades de se realizar um bom negócio;
- e) Economia: um dos principais motivos que encaminham os consumidores a comprarem pela internet, na medida em que os produtos comercializados no mundo digital normalmente são mais baratos graças a menores custos de venda.

No fundo, para que as empresas atinjam sucesso no mercado *online* é primordial que estas desenvolvam estratégias com base no entendimento e compreensão dos mecanismos que impactam o comportamento do consumidor em plataformas digitais (Cucato et al., 2021).

Ping et al. (2019) afirmam que com o aumento da dificuldade em satisfazer os clientes é de extrema importância utilizar-se a IA, dado que é a resposta mais eficiente para combater esse problema. Para mais, os autores prosseguem na conceção que as tecnologias inerentes à IA permitem às organizações serem mais eficazes e estarem disponíveis vinte e quatro horas por dia, automatizando muitas das tarefas e aumentando a satisfação dos clientes.

Através do uso da IA pode otimizar-se o desempenho das organizações mas, para que tal aconteça, as estruturas de marketing precisam mudar os seus processos e comunicação para utilizar essa tecnologia, que permite conhecer o cliente e fornecer anúncios, campanhas e produtos adaptados aos perfis de cada consumidor (Jr et al., 2022).

A compreensão da IA no contexto de e-commerce proporciona uma tomada de decisão mais assertiva e sugere melhorias para o processo de compra do consumidor, resultando numa melhor experiência do cliente. De ressaltar que a experiência do consumidor trata-

se das percepções adquiridas por este após interagir com a empresa, sendo que as mesmas resultam em memórias capazes de impulsionar a lealdade e o valor percebido pelo mesmo (Alves, 2023).

A IA é percebida como uma resposta importante e com valor, visto que ajuda os profissionais de marketing a responder às expectativas dos consumidores e, por conseguinte, enriquece a experiência da jornada de compra destes. Assim, é fundamental analisar as experiências de cada cliente no mercado *online* para que os marketeers consigam qualificar e medir se as atividades estão a ser de facto eficazes no processo de decisão do cliente (Alves, 2023).

Consolidar o ambiente digital que atrai os consumidores de forma única e específica para agregar valor para estes como para as organizações é fundamental (Rosa et al., 2017). Como resultado, surgem mudanças com a necessidade de diferenciação das empresas, como chatbots que respondem rapidamente aos pedidos para aumentar a satisfação do cliente (Martins, 2022).

O cerne do marketing reside na habilidade de satisfazer as necessidades e os desejos dos consumidores, posto isto, percebe-se que a satisfação do cliente com uma empresa e os seus processos e produtos é essencial para garantir a sua lealdade e propensão a realizar transações repetidas (Groh, 2009). Consequentemente, a satisfação do cliente torna-se uma métrica crucial para avaliar o sucesso das estratégias de marketing adotadas pelas empresas.

O construto da satisfação tem sido objeto de teorias que oferecem contribuições tanto académicas quanto práticas na área de marketing. É uma variável de grande importância e amplamente utilizada pelas empresas como um indicador do êxito das suas estratégias (Groh, 2009).

Ao longo dos anos, diversos estudiosos exploraram o conceito de satisfação, destacando a sua relevância num contexto competitivo em constante evolução. A satisfação permeia diversas situações do dia a dia, especialmente aquelas que envolvem decisões de compra e consumo (Groh, 2009).

Solomon (2002) sugere que a satisfação surge durante a utilização ou consumo de um produto ou serviço, ou mesmo após esse período, sendo assim uma resposta à expectativa do consumidor.

Oliver (1989), um dos autores mais influentes sobre o assunto, afirma que existem cinco tipos distintos de satisfação:

1. Contentamento: ocorre quando os sentimentos principais são a aceitação e a tolerância, ou seja, o produto ou a experiência de consumo mostraram-se de acordo com as expectativas;
2. Prazer: trata-se de uma reação afetiva que acontece quando o consumidor recebe algum resultado positivo pelo uso do produto;
3. Alívio: acontece quando o consumo permite a eliminação de resultados negativos;
4. Novidade: diz respeito a produtos ou experiências que são consideradas novas e inesperadas;
5. Surpresa: caracterizada pelo desempenho superior do produto às expectativas.

Solomon (2002) sugere que a satisfação ou insatisfação do consumidor é influenciada pelas atitudes gerais em relação ao produto após a compra, enquanto destaca o processo contínuo de avaliação que os consumidores realizam ao integrar os produtos nas suas rotinas diárias.

No contexto do e-commerce, fatores específicos influenciam a satisfação do cliente. Ballantine (2005) destaca a importância da interatividade, evidenciando que ambientes virtuais de compra com maior interatividade e informações tendem a originar maior satisfação. Szymanski & Henard (2001) mencionam a conveniência como um fator crucial na satisfação do consumidor em lojas virtuais, pois a capacidade de realizar compras sem sair de casa contribui significativamente para esse fim.

A satisfação do cliente gera uma confiança na empresa com a qual ele está a interagir, o que promove o desejo de manter esse relacionamento. Assim, a satisfação está intrinsecamente ligada à confiança e, ainda, exerce um impacto positivo na intenção de compra e repetição (Bai et al., 2008).

A confiança desempenha um papel crucial em diversos aspectos da vida, desde os relacionamentos pessoais até às transações comerciais. Nos círculos pessoais, confia-se em familiares, amigos e parceiros para alcançar objetivos comuns. No campo do consumo, deposita-se confiança na qualidade dos produtos oferecidos pelas marcas (Groh, 2009).

Garbarino & Lee (2003) destacam a crescente importância da confiança em diversas disciplinas, incluindo economia, psicologia, sociologia, administração e, especialmente, marketing. Na literatura de marketing, a confiança emerge como um elemento chave na construção e manutenção de relacionamentos duradouros, cruciais para o sucesso empresarial.

A natureza impessoal do e-commerce amplifica a importância da confiança nesse contexto. Na ausência de interações físicas, a confiança torna-se ainda mais vital, enquanto a falta de contacto pessoal cria desafios adicionais na formação de bases confiáveis. As empresas enfrentam novos desafios, como o uso inadequado de informações e a recolha não autorizada de dados, que podem alterar a confiança do consumidor (B. C. Y. Lee, 2007).

Blackell et al. (2005) afirmam que as atitudes são expressões de preferências e aversões individuais, permeando diversas esferas da vida quotidiana, desde interações pessoais até decisões de consumo. Quando alguém expressa seu agrado ou desagrado por algo, está a revelar um conjunto abrangente de atitudes favoráveis ou desfavoráveis em relação ao objeto em questão.

É evidente a relevância para os profissionais de marketing compreenderem o significado das atitudes tanto para os indivíduos quanto para grupos com características similares. Isso deve-se ao impacto das atitudes no comportamento de compra do consumidor, que abrange desde comportamentos específicos relacionados a produtos até padrões mais amplos de consumo (Solomon, 2002).

As atitudes possuem três características fundamentais (Groh, 2009):

1. São adquiridas, formadas com base em experiências com um objeto ou informações a respeito dele;
2. São relativamente estáveis, permanecendo até que haja uma razão significativa para mudá-las;
3. Influenciam o comportamento, induzindo uma resposta consistente que antecede e influencia as ações.

Adicionalmente, Lee (2007) destaca que a atitude representa uma predisposição aprendida para reagir consistentemente de forma favorável ou desfavorável a um objeto. A noção de que as atitudes são predisposições à resposta estabelece a sua conexão com o

comportamento presente do consumidor (B. C. Y. Lee, 2007). Portanto, quando um consumidor tem uma experiência positiva significativa com uma marca específica, é esperado que ele demonstre uma propensão de futura intenção de compra.

Groh (2009) definem a intenção de compra de uma marca como a convergência entre o interesse do consumidor e a viabilidade de efetuar a compra do produto. Por outro lado, Pavlou (2003 cit in. Groh, 2009) descreve-a como a disposição demonstrada pelo consumidor para se envolver em transações *online* quando há intenção de compra.

A determinação de comprar pode ser moldada pela atitude do consumidor em relação à marca e pelas normas sociais, além de ser influenciada por uma variedade de fatores de marketing, como vendas pessoais, campanhas promocionais e publicidade, entre outros (Camlot, 2014).

Diversas pesquisas foram examinadas e, sem dúvida, o estudo de Lopes et al. (2022) teve um impacto significativo devido ao modelo que eles exploraram, o qual em grande medida fundamenta o que foi discutido até o momento. A Figura 12 ilustra através de ligações simples todos os antecedentes de intenção de compra.

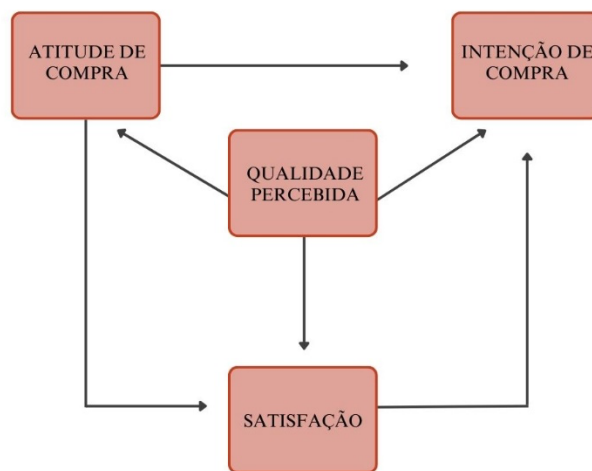


Figura 12: Antecedentes de Intenção de Compra.

A qualidade percebida pode influenciar a atitude de compra no e-commerce, concebendo uma atitude positiva. Portanto, o utilizador ao avaliar a qualidade do *website*, por conseguinte, acaba por considerar a qualidade das informações e da segurança (Brambilla & Gusatti, 2017). Assim sendo, sugere-se que a qualidade percebida num *website*, através da estimativa realizada pelo consumidor a todo o conjunto de dimensões

básicas e externas do produto ou serviço, pode exercer um efeito favorável na atitude de compra dos consumidores em e-commerce (Lopes et al., 2022).

Conforme Md et al (2012), a qualidade percebida de um produto ou serviço contribui significativamente para a atitude de compra dos consumidores em ambientes digitais. A atitude de compra é alcançada pelo meio de sentimentos favoráveis, no momento em que os utilizadores compreendem a qualidade dos *websites* e têm uma maior experiência em compras no meio virtual, produzindo mais segurança no consumo em e-commerce (Bhatnagar et al., 2000).

A medição da qualidade de um *website* encaminha a consideração de várias dimensões como, por exemplo: a facilidade de uso; a segurança; o design estético; a velocidade do processamento; entre outras (Brambilla & Gusatti, 2017).

Com base na literatura, a intenção de compra é entendida como um aspeto da qualidade percebida pelo consumidor. Esta deve-se, ao facto, da perceção do consumidor representar uma maior credibilidade, confiança e segurança em relação ao *website* de compra (Brambilla & Gusatti, 2017). Além desta, a satisfação está relacionada às expectativas face a um produto/serviço e, desta forma, sugere-se que a qualidade percebida pode exercer um resultado positivo na satisfação do consumidor em e-commerce (Viana, 2017).

No entanto, a atitude de compra é entendida como um fator antecedente da intenção de compra e, ainda, da satisfação em e-commerce. Um consumidor quando entende a facilidade de uso e a utilidade de um determinado *website*, de imediato, detém uma atitude favorável que pode encaminhar à intenção de compra (Oliveira, 2013). Quanto à satisfação, sabe-se que uma avaliação precede e produz um comportamento e, conseqüentemente, uma satisfação refletida como o sentimento interno do consumidor (Zakriya et al., 2015).

A satisfação é também um fator antecedente da intenção de compra em e-commerce sendo que a mesma num *website* acaba por refletir um nível maior de intenção de compra, por parte do consumidor (Lopes et al., 2022).

Portanto, a satisfação desempenha um papel fundamental no sucesso de um negócio em e-commerce a vários níveis. Esta não é apenas importante para estimular a intenção de compra como também para garantir transações comerciais bem-sucedidas e, ainda,

desempenhar um papel estratégico na construção de relacionamentos duradouros, na reputação da marca e na diferenciação competitiva

De acordo com Rosa et al. (2017), as entidades ao analisarem o comportamento de cada consumidor conseguem transmitir os valores e os produtos essenciais para o cliente e, ainda, propagar uma sensação de conforto e satisfação ao mesmo.

1.5.3 Análise Preditiva na Melhoria da Personalização

A personalização é definida pela pesquisa realizada (Cannella, 2018). Os autores afirmam que a personalização da IA é essencial para fornecer experiências que ressoem de perto com os consumidores da geração Z e da geração Y e permite que as marcas se envolvam e encantem os seus consumidores a um nível individual e em grande escala. Ademais, este examina uma variedade de aspetos da personalização da IA, incluindo participantes da personalização, tendências de personalização, prioridades e objetivos. Assim, um grau de personalização do cliente será baseado na IA, e a análise preditiva permitirá que o marketing de personalização aprenda tanto sobre os clientes quanto possível, tornando-o fácil, contínuo e tão próximo da automatização quanto possível (Adomavicius & Tuzhilin, 2006).

Os assistentes virtuais, os chatbots, a pesquisa de conteúdo, a análise de sentimentos e a deteção de emoções são alguns exemplos de ferramentas de IA que podem melhorar a personalização, a qualidade do serviço e a experiência do cliente ((Joshi et al., 2014).

Uma das principais prioridades da IA é a análise preditiva, que inclui avaliar os dados e monitorar as previsões. Este tipo de análise avançada é usado para antecipar eventos futuros, ou seja, refere-se ao processo de avaliar a probabilidade de um determinado evento ocorrer no futuro utilizando uma mistura de abordagens, tendências, padrões e análise de dados passados ou atuais (S. Gupta & Joshi, 2022).

A partir do desenvolvimento de modelos de análise de dados que prevêem eventos futuros, a análise preditiva parece ser útil para resolver o problema de analisar uma grande quantidade de *bytes* de dados produzidos regularmente. Identificar o problema, recolher e preparar dados, analisar os dados e desenvolver o modelo, implementar, observar e controlar o modelo são etapas do processo de análise preditiva (S. Gupta & Joshi, 2022).

Existem várias técnicas de análise preditiva que ajudam a categorizar e extrair informações importantes de vários conjuntos de dados de clientes. Esses dados são posteriormente analisados por meio de um motor de automatização que funciona sem a necessidade de intervenção humana (S. Gupta & Joshi, 2022). Nestas, as de adoção da respetiva tecnologia permitem que se conduza a uma maior flexibilidade e transparência nas operações de marketing, contribuindo assim para um melhor desempenho.

Assim, os avanços na tecnologia de análise preditiva estão a beneficiar a função de marketing porque melhoram a experiência do cliente (S. Gupta & Joshi, 2022), predisõem o comportamento do consumidor, personalizam as decisões de compra (Gantz et al., 2017) e garantem um percurso do cliente sem interrupções.

A análise preditiva oferece aos marketeers informações atuais e futuras sobre os desejos, necessidades e exigências dos clientes, bem como tendências do mercado e sinais de intenção (S. Gupta & Joshi, 2022). Cada vez mais as empresas estão a tentar utilizar os dados através da IA para prever resultados futuros (S. Gupta & Joshi, 2022), sendo a análise preditiva a opção para melhorar as decisões de marketing.

A análise preditiva permite que os profissionais de marketing testem experiências personalizadas e prevejam o próximo passo dos clientes, garantindo que o seu conteúdo será mais relevante em termos contextuais do que o dos seus concorrentes diretos. A experiência mais conveniente, relevante, pessoal e humana será proporcionada aos clientes, e a divisão entre o mundo digital e o mundo real será eliminada (S. Gupta & Joshi, 2022).

Neste seguimento, as experiências de vida dos clientes irão além das expectativas, melhorando assim as relações e interações com a empresa. Estas experiências instantâneas e exclusivas acompanham os clientes de um ponto de contato para outro, fazendo com que voltem para mais e melhorem as suas experiências, aumentando a probabilidade de agirem da maneira que desejam (S. Gupta & Joshi, 2022)

As previsões "verdadeiras" do comportamento do consumidor são feitas usando modelos de propensão. Estes prevêm a probabilidade de um determinado tipo de comportamento de compra do cliente, como a probabilidade de um cliente concluir uma compra ao visitar a sua página *web*. Os marketeers podem usá-los para otimizar várias coisas, como a frequência de envio de correio eletrónico e o tempo do pessoal de vendas, bem como atribuir orçamentos a cupões de oferta e desconto (S. Gupta & Joshi, 2022).

Os autores S. Gupta & Joshi (2022) apresentam um exemplo de uma empresa que utiliza o modelo de propensão para análise preditiva. A Fin & Fur é uma empresa *online* que vende artigos para animais de estimação há mais de 15 anos e oferece serviços aos proprietários de animais. A empresa empregou uma estratégia de marketing que oferece a todos os seus clientes um calendário fixo de compras em períodos específicos. No entanto, alguns clientes gostam de fazer compras em diferentes momentos do ano.

Um método de modelo de propensão usado pela Fin & Fur ajudou a diferenciar os seus produtos entre os consumidores. O método incluiu automaticamente dados preditivos, aumentando as vendas e a retenção sem aumentar as despesas. A distinção do cliente foi baseada nas preferências que eles tinham para comprar produtos mais prováveis. Com base nessa classificação, a empresa conseguiu identificar quais os produtos que cada cliente preferiria e usando um procedimento de email automatizado para clientes que eram considerados suscetíveis de comprar, conseguiu maximizar a aquisição de devoluções (S. Gupta & Joshi, 2022).

Como mostra a Figura 13, a análise preditiva exerce um impacto numa variedade de setores que, por conseguinte, afetam o marketing e o comportamento de compra dos clientes (S. Gupta & Joshi, 2022).




Figura 13: Áreas afetadas pela análise preditiva.

- Criatividade: A aplicação de modelos preditivos para prever o comportamento de compra dos clientes ajuda as empresas a serem mais criativas e a desenvolverem novos produtos e serviços para os clientes;
- Percurso do cliente: Os utilizadores esperam encontrar conteúdo que corresponda às suas necessidades e preferências. Como resultado, as empresas podem atender ao desejado porque a análise envolve pesquisa de dados para descobrir padrões de

comportamento dos visitantes e, em seguida, análise dos resultados para criar conteúdo personalizado que facilite a viagem do cliente;

- Email: A ascensão da análise preditiva permitiu aos marketeers aprender mais sobre os seus consumidores, levando-os a automatizar a comunicação com os seus clientes. O marketing preditivo cria ofertas de produtos personalizados observando o comportamento, os interesses e as preferências dos clientes. Além disso, permite que os profissionais de marketing usem sistemas que fazem a curadoria automática de conteúdos de produtos selecionados individualmente para criar e enviar emails personalizados para cada subscritor, aumentando significativamente o número de conversões;
- SEO: Esta trata-se de uma técnica de usar tecnologias de análise preditiva para identificar assuntos que serão populares em breve. Os profissionais de marketing podem usar esta informação para identificar o conteúdo atual para atualização e criar conteúdo novo antes que o assunto se torne mais popular;
- Público-alvo: A segmentação do público-alvo está a ser redefinida pela análise preditiva;
- Investigação: Os dados pesquisados no passado e os resultados que eles produziram são usados para criar modelos preditivos, que podem ser posteriormente previstos usando novos ou diferentes dados.

Os profissionais de marketing precisam de trabalhar rapidamente para se adaptar a este ambiente em rápida mudança, porém, há também todo um novo universo de oportunidades para serem inovadores. No mundo moderno, estes dependem da personalização em várias áreas do marketing, conforme demonstrado, para obter melhores resultados. É inegável que as marcas atuais precisam de fazer mais para atender às expectativas dos consumidores em termos de experiência de compra positiva (S. Gupta & Joshi, 2022).

Conforme os autores S. Gupta & Joshi (2022), todas as pessoas apreciam quando uma empresa as reconhece e responde às suas necessidades específicas pois desejam ser reconhecidas como seres únicos. Assim, a personalização torna-se uma necessidade para as organizações que pretendem melhorar a experiência do consumidor, o que levará a clientes mais satisfeitos, mais receita e mais fidelidade a longo prazo.

A personalização, além destas ligações, agora abrange toda a experiência do cliente e não se limita a ofertas direcionadas. No atual mundo de consumo acelerado, proporcionar uma experiência de compra impecável, bem como uma viagem única e pessoal desde o momento em que chegam a uma página *web* até à realização de uma compra crítica é extremamente importante (S. Gupta & Joshi, 2022).

Por fim, o número de técnicas de análise preditiva de marketing que funcionam para empresas está a crescer rapidamente. À medida que o campo da informática evoluiu e as técnicas informáticas evoluíram, foram desenvolvidas estratégias mais recentes e algoritmos cada vez melhores. As redes neuronais artificiais abriram uma nova era na análise preditiva (S. Gupta & Joshi, 2022).

1.6 Estratégias no E-commerce com Inteligência Artificial

A IA é utilizada em vários setores de atividade económica, mas é principalmente utilizada em áreas como medicina, jogos, e-commerce, tecnologia educacional, marketing e transformação digital. A IA pode ajudar a automatizar processos comerciais e a encontrar informações importantes usando dados anteriores e, ainda, fornecer informações sobre mercados ou consumidores (Jhaveri et al., 2023).

Uma parcela significativa do comércio eletrónico está atualmente a utilizar a IA e as empresas que ainda não o fazem encontram-se no processo de adoção, reconhecendo o impacto positivo que esta pode ter (Pahadi et al., 2022). De acordo com uma pesquisa conduzida pela Tractica, a utilização de IA no e-commerce está a crescer rapidamente, prevendo-se que as receitas globais atinjam 36,8 mil milhões de dólares já no próximo ano, em 2025 (Zoroja et al., 2020).

Vários aspetos do e-commerce, como a personalização com base nos utilizadores, aprimoramento dos serviços ao cliente, recomendações eficientes, gestão de stock e fornecimento, marketing e vendas, podem ser melhorados significativamente com o uso da IA, visando aprimorar a experiência geral dos utilizadores e o seu envolvimento (Pahadi et al., 2022).

Quando uma aplicação acompanha o histórico de pesquisa de um cliente, lembrando-se dos produtos pesquisados, recomenda esses produtos, notifica sobre vendas de itens favoritos ou frequentemente pesquisados, interage por meio de chatbots ou assistentes de

voz, e proporciona uma experiência de navegação personalizada, o cliente está, conscientemente ou não, a participar no processo de aprendizagem automática. Esses momentos são possibilitados pela IA e representam como o setor do e-commerce está a aliar-se à IA, conforme observado por Sophia Martin, "*this is how the e-commerce business sector is joining hands to artificial intelligence*" (C. Yang & Liu, 2021).

A IA facilita aos programadores a criação de aplicações inteligentes que conseguem compreender o mundo como o utilizador e desenvolver um *software* centrado no cliente. O *software* artificialmente inteligente pode identificar palavras-chave, etiquetas, rótulos e conteúdo perceptível na sua base de dados, filtrando características de imagens ou vídeos (Pahadi et al., 2022). Essa capacidade permite que os utilizadores localizem produtos em qualquer imagem *online* e peçam à aplicação que apresente itens semelhantes usando o *software* de reconhecimento de imagem. Devido à sua incrível capacidade visual, a IA ajuda os consumidores a ver produtos inter-relacionados, independentemente das suas características (Pahadi et al., 2022).

O autor Soni (2020) afirma que a IA ajuda as plataformas de e-commerce a atrair e detetar clientes e, ainda, permite que as organizações extraiam informações sobre os mesmos e ofereçam serviços personalizados e de alta qualidade. Desta forma, a subárea da ciência da computação, apresenta-se como uma ferramenta vital para aumentar a participação das empresas no *online*, sendo amplamente presente na indústria do e-commerce devido à sua capacidade de replicar e expandir a inteligência humana (Pahadi et al., 2022).

O raciocínio, a aprendizagem, a resolução de problemas, a inteligência linguística e a perceção são os componentes que compõem a inteligência humana. Todavia, ao contrário dos seres humanos, as máquinas não são capazes de tomar decisões com base em intuição, conhecimento, conteúdo, ambiente e dados visuais. Por outro lado, para alcançar o resultado desejado e apoiar o envolvimento dos clientes no e-commerce, as máquinas usam uma variedade de algoritmos, etapas, aprendizagem automática e dados em atraso pré-definidos (Pahadi et al., 2022).

Harari (2015 cit. in Carvalho, 2023) afirma que haverá uma separação entre a inteligência humana e a consciência. Os algoritmos de máquinas e robôs, e não a inteligência humana, decidirão o futuro do mundo e da humanidade. Assim, haverá uma separação entre a consciência e a IA e inteligência humana.

Existem seis aplicações de IA que requerem inteligência humana no e-commerce, sendo:

- 1) Análise preditiva e prescritiva;
- 2) Publicidade programática;
- 3) Criação de conteúdos e personalização da experiência;
- 4) Previsão de vendas;
- 5) Reconhecimento e pesquisa por voz;
- 6) Chatbots e agentes de inteligência.

A análise preditiva, descrita no subcapítulo 1.3.3, leva a gestão de conversões a um novo estágio. Ajuda a identificar os resultados potenciais usando a grande quantidade de dados disponíveis e analisando as comunicações de entrada (Chandra et al., 2023). É importante destacar que a gestão dos riscos é essencial devido ao grande volume de dados que entram e saem das várias transações (Webb et al., 2020). Por sua vez, a análise prescritiva vai além da análise preditiva ao fornecer recomendações específicas de ações a serem tomadas para otimizar resultados ou alcançar determinados objetivos. Assim sendo, a análise preditiva é frequentemente um componente essencial da análise prescritiva, ajudando a fundamentar as recomendações de ação com base em previsões precisas.

A programação é a base para o método automatizado de compra e venda de inventário de anúncios por meio de uma bolsa. Nos dias de hoje, a negociação de ações em tempo real está predominante em plataformas de visualização, dispositivos móveis, vídeo, televisão e redes sociais (Chandra et al., 2023). As ofertas são assentes em informações baseadas em IA, o que significa que anúncios podem ser personalizados em tempo real usando algoritmos que monitoram o comportamento dos clientes. Para ajudar nas decisões sobre personalização e compra de anúncios, as plataformas de gestão de dados e as plataformas do lado da procura e da oferta recolhem uma variedade de dados, tanto próprios quanto de terceiros (Chandra et al., 2023).

A previsão de vendas é o processo de analisar tendências de dados utilizando variáveis como a altura do mês, os dias da semana, a altura do ano, a data festiva, a estação do ano, as tendências de moda atuais, entre outras. Em seguida, usa um algoritmo de aprendizagem automática para alimentar os dados e descobrir o padrão correlacionado oculto. Isso permite que a empresa faça uma previsão das vendas esperadas para um

determinado período. Naturalmente, ajudará a satisfazer a cadeia de oferta e procura, ao manter em stock os produtos mais procurados durante uma estação (Pahadi et al., 2022).

Os sistemas de reconhecimento de voz como Siri, Alexa e outros melhoraram significativamente o seu vocabulário, linguagem e resposta graças aos investimentos realizados. Vários dispositivos, como motores de pesquisa, navegadores GPS e assistentes domésticos como o Google Home e o Amazon Echo, usam reconhecimento da fala (Chandra et al., 2023).

Ao apresentar aplicações de IA no e-commerce que dependem da inteligência humana, é importante lembrar que quando usadas, essas aplicações trarão benefícios essenciais para qualquer empresa que quer se destacar no mercado *online*, como aumento do envolvimento do cliente, aceleração das transações e aumento das receitas.

O envolvimento efetivo dos consumidores desempenha um papel vital no sucesso de um negócio *online*. Através da IA, uma empresa consegue aprimorar significativamente o envolvimento dos clientes, fornecendo conteúdo relevante e recomendações de produtos. Um exemplo notável é a abordagem adotada pela Stitch Fix, uma loja de roupa, que utiliza algoritmos de IA para personalizar recomendações de vestuário com base nas preferências individuais dos clientes, como estilo e tamanho, bem como nos seus históricos de compras (Kanakamma et al., 2023).

Além disso, a integração de chatbots com capacidades avançadas de processamento de linguagem natural, como os utilizados pela Sephora, representa outra estratégia eficaz para melhorar o envolvimento dos clientes. Estes chatbots podem oferecer suporte imediato aos clientes, respondendo rapidamente às suas perguntas e auxiliando nas decisões de compra (Kanakamma et al., 2023).

A implementação da IA no e-commerce possibilita a criação de ofertas atrativas e relevantes para os clientes. Um exemplo significativo é a abordagem adotada pelo eBay, um mercado *online* que utiliza IA para otimizar os preços dos produtos oferecidos pelos vendedores, incentivando a rápida venda e a obtenção de lucros. Esta dinâmica técnica de fixação promove transações mais eficientes, mas também atrai mais vendedores para o mercado, resultando num aumento das receitas globais. De salientar que o número de transações bem sucedidas na plataforma aumentou 10% em consequência deste método (Kanakamma et al., 2023; Chen & Chungiong, 2021).

As empresas de e-commerce impulsionadas pela IA aumentaram os seus lucros. Por exemplo, a plataforma alimentada por IA da Alibaba, a Taobao, ajudou a entidade a conceber mais de 72 mil milhões de dólares em vendas no ano fiscal de 2020. Outro exemplo, as recomendações personalizadas na Amazon geram mais de 34 mil milhões de dólares em vendas anuais. (Kanakamma et al., 2023).

Os dados de gigantes como a Amazon e a Alibaba, juntamente com o eBay, confirmam a influência da IA no e-commerce. Neste seguimento, o próximo setor abordará a Amazon, uma das principais plataformas de venda *online* no mundo.

1.6.1 Caso Amazon

O desenvolvimento e aplicação da IA têm sido amplamente explorados em diversas áreas, com especial destaque para o e-commerce. A inovação neste campo tem despertado um interesse generalizado nos negócios *online* dos comerciantes. A Amazon, reconhecida como uma das principais retalhistas internacionais *online*, exemplifica de forma notável a integração bem-sucedida da IA no e-commerce (Tran, 2019).

A Amazon, uma gigante multinacional de tecnologia, surgiu da visão empreendedora de Jeff Bezos na sua garagem a 5 de julho de 1994. Inicialmente concebida como uma plataforma *online* para a venda de livros, rapidamente evoluiu para oferecer música e vídeos a partir de 1998. Com o tempo, a sua presença expandiu-se para o Reino Unido e o Canadá, diversificando o seu catálogo para incluir eletrónicos, artigos para o lar, jogos e brinquedos (Shaiju, 2023).

Ao entrar no século XXI, a Amazon ampliou o seu propósito, fornecendo APIs para programadores *web* por meio da Amazon Web Services (AWS), oferecendo recursos de computação em nuvem e armazenamento. Além disso, desenvolveu serviços de assistência virtual, como a Alexa. Em 2006, abriu a sua plataforma para pequenas empresas e indivíduos venderem produtos e, em 2017, consolidou a sua posição ao adquirir a Whole Food Market (Shaiju, 2023).

Atualmente, cerca de 2,14 bilhões de pessoas em todo o mundo utilizam o comércio *online*. A Amazon destaca-se como uma das principais protagonistas do e-commerce, da computação em nuvem e da IA, prometendo um futuro promissor com o seu vasto arsenal de tecnologias avançadas. O seu portfólio de produtos e serviços inclui desde compras

online, Amazon Prime, Kindle, Amazon Pay, até jogos do Amazon Studio, Alexa e Amazon Drive, entre outros (Shaiju, 2023).

A principal atividade da Amazon é a sua loja *online* que, nos dias de hoje, oferece mais de 12 milhões de itens na sua plataforma. Além de comercializar os seus próprios produtos, a empresa também permite que vendedores terceirizados vendam os seus itens por meio da plataforma (Shaiju, 2023).

Para fazer compras na Amazon, os utilizadores precisam de criar uma conta utilizando um endereço de email ou um número de telefone. Em seguida, podem navegar pelos produtos disponíveis, que abrangem diversas marcas e faixas de preço, e selecionar aqueles que desejam adquirir. A plataforma oferece opções de filtragem por categoria de produto e preço, facilitando a seleção dos itens desejados de maneira rápida e conveniente (Shaiju, 2023).

A Amazon utiliza a IA para personalizar as experiências dos consumidores com o seu motor de recomendação. Esta plataforma analisa os dados dos utilizadores, incluindo o histórico de navegação e o comportamento de compra, para fornecer recomendações de produtos personalizadas (Kanakamma et al., 2023; Yang et al., 2021).

Os algorítmicos de IA podem ajustar as atividades de marketing em tempo real, aumentando significativamente o envolvimento dos consumidores. A Amazon, por exemplo, estima que o seu sistema de recomendação representa 35% das vendas, demonstrando os benefícios reais da IA na publicidade direcionada. A Figura 14 mostra as mudanças no nível de receitas líquidas fornecidas pelos sistemas de recomendação num período de dez anos (Kanakamma et al., 2023).




Figura 14: Sistema de Recomendação em produtos na Amazon num período de 10 anos.

No ano de 2020, marcado pela crise pandêmica, as receitas líquidas oriundas dos sistemas de recomendação aumentaram consideravelmente, intensificando uma tendência de crescimento que já vinha ocorrendo desde 2010. Durante o período de confinamento, a atividade da Amazon cresceu rapidamente, impulsionando o mercado de vendas *online* a níveis sem precedentes (Shaiju, 2023).

A plataforma da Amazon é conhecida pela sua interface intuitiva, que facilita a navegação e compra para os utilizadores. Para mais, os clientes têm acesso a informações detalhadas, críticas e avaliações de produtos, o que os ajuda a fazer escolhas informadas. Além da loja *online*, a Amazon expandiu os seus serviços para outros segmentos do e-commerce, incluindo o Amazon Fresh, que oferece entregas de mercearias, e o Amazon Go, uma rede de lojas de conveniência sem caixas. Para mais, a empresa ingressou no mercado de entretenimento com o Amazon Studios, produzindo e transmitindo conteúdo exclusivo (Shaiju, 2023).

A Amazon emprega algoritmos de IA com aprendizagem automática para impulsionar as suas operações de e-commerce. Estas tecnologias permitem que a empresa ofereça aos clientes serviços personalizados e sugestões com base nos seus históricos de navegação e compras. A abordagem visa tornar a experiência de compra mais individualizada, facilitando aos clientes encontrarem os produtos que melhor se adequam às suas necessidades e interesses, conforme mencionado pelos autores do (Tran, 2019).

Neste seguimento, a principal aplicação de IA na Amazon é a sua funcionalidade de recomendação de produtos, que utiliza o histórico de procura e navegação dos clientes,

bem como outros fatores, para sugerir produtos relevantes. Esta estratégia é responsável por cerca de 35% das receitas da empresa (Shaiju, 2023).

A aplicação de IA no *website* da Amazon pode ser caracterizada da seguinte forma: recomendações personalizadas, experiência de compra por voz e atendimento ao cliente, chatbot, detecção de fraudes, análise de imagens e vídeos, manutenção preditiva (Shaiju, 2023).

1.6.2 Tecnologias de Personalização na Amazon

As recomendações personalizadas de produtos da Amazon representam uma das formas mais reconhecidas de aplicação da IA pela empresa. Ao prever de forma eficaz as necessidades dos clientes por meio dessas recomendações personalizadas, a Amazon consegue manter a satisfação do cliente e, ao mesmo tempo, aumentar a sua participação de mercado (Shaiju, 2023).

Quando os clientes acessam ao *website* ou ao aplicativo da Amazon, é apresentado uma lista de produtos sugeridos com base nas suas compras anteriores e comportamento de navegação, como ilustrado na Figura 15. Essas sugestões são concebidas por algoritmos de aprendizagem automática que analisam os dados do cliente na procura de padrões e tendências. A Amazon emprega a FC entre entidades para garantir a eficácia dessa funcionalidade (Shaiju, 2023).

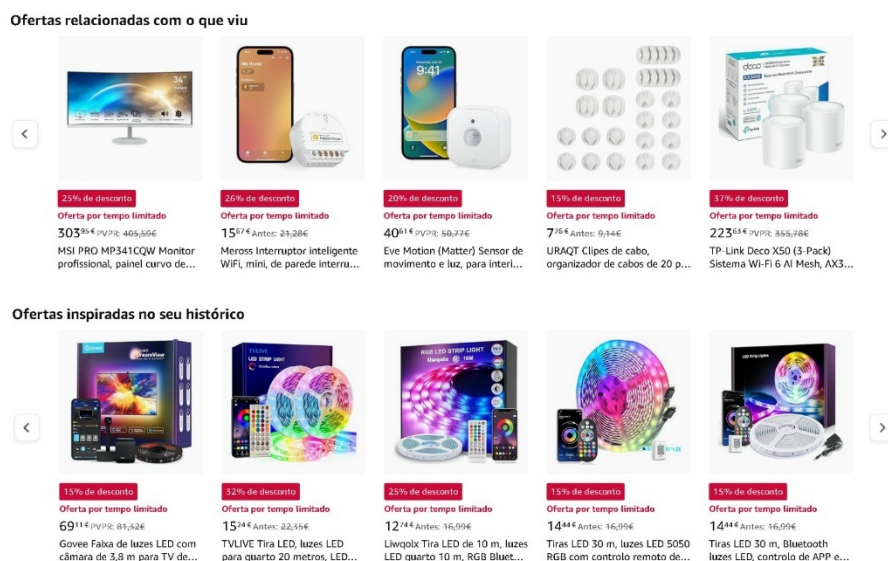


Figura 15: Itens de recomendação com base no histórico de navegação e compra.

A Amazon introduziu o Amazon Personalize como um sistema de recomendação projetado para aprimorar as sugestões de produtos para os clientes com base nas suas experiências de compras *online*. No Amazon Personalize, os clientes têm a capacidade de fornecer um fluxo contínuo de atividades, incluindo informações de compras, visualizações de páginas e preferências de produtos, como livros, música, cosméticos ou vídeos. Além disso, os compradores podem compartilhar dados demográficos adicionais, como idade, sexo e localização geográfica. O sistema processa, analisa e identifica os dados dos clientes, selecionando os algoritmos mais adequados. Por fim, ele otimiza um modelo de personalização adaptado aos dados específicos de cada cliente (Tran, 2019).

Quanto à experiência de compra por voz, a Amazon disponibiliza a Alexa que possibilita aos clientes procurar produtos, fazer compras e completar o processo de *checkout* sem a necessidade de interação física com uma tela. Isto significa que os utilizadores podem concluir o processo de *checkout* sem usar as mãos. Esta implementação de IA tenciona tornar as compras na Amazon mais convenientes e oferecer aos clientes uma experiência de compra semelhante à *offline*, permitindo que criem listas de compras e recebam recomendações diretamente da Alexa (Shaiju, 2023).

Além de auxiliar nas compras, a Alexa apresenta-se também no atendimento ao cliente pois consegue responder a dúvidas sobre produtos e fornecer informações sobre diversos tópicos, como previsão do tempo e condições de tráfego. Integrou-se a uma variedade de produtos da Amazon, incluindo o altifalante inteligente Echo. Ao empregar a IA para lidar com questões de serviço ao cliente, a empresa consegue aliviar a carga de trabalho dos seus recursos humanos, ao mesmo tempo que proporciona aos clientes uma experiência mais eficaz e agradável (Shaiju, 2023).

Portanto, os compradores podem obter experiências e desempenhos de compras modernos com o Amazon Echo, uma ferramenta de assistente virtual de compras conhecida como Alexa, que só precisa de identificar a voz do utilizador para processar a encomenda. Os clientes estão mais satisfeitos quando usam a Alexa para compras *online*, de acordo com o Statistic Portal. De 2016 ao final de 2018, as competências da Alexa cresceram de apenas 130 para mais de 80.000 (Tran, 2019).

O Amazon Lex, um chatbot desenvolvido pela Amazon para ajudar os clientes a conectarem-se aos centros de atendimento, é outro exemplo de auxílio ao cliente. Este foi projetado para ser um dispositivo de conversação que possa usar voz e texto em qualquer

aplicação. As funções de aprendizagem profunda de reconhecimento automático de voz avançado e o processamento de linguagem natural permitem que os clientes criem aplicações com experiências de utilizador atraentes ao transformar vozes em texto. A Figura 16 mostra como decorre o funcionamento deste chatbot (Tran, 2019).

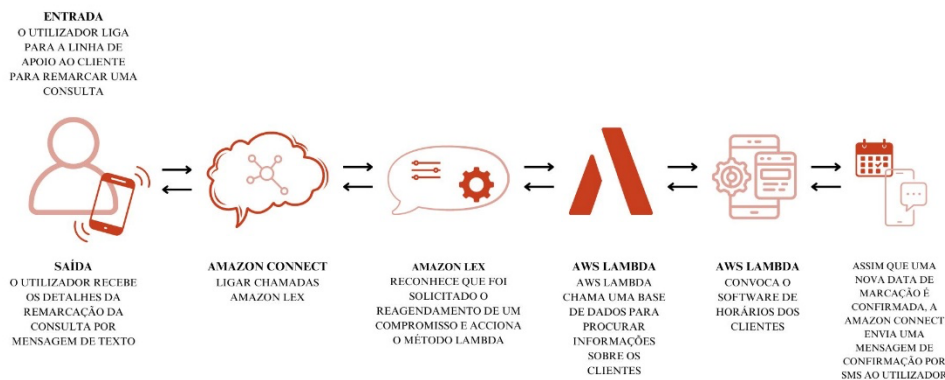


Figura 16: Funcionamento do Amazon Lex para bots de centro de atendimento.

Ao empregar o Amazon Lex, os clientes podem agendar compromissos, modificar informações como nome de utilizador ou senha e solicitar o histórico de compras das suas contas Amazon. Este chatbot é capaz de interpretar a fala do cliente e compreender as suas intenções sem a necessidade de perguntas específicas. Além disso, eles simplificam a execução de diversas atividades diárias, como reservar quartos de hotel ou consultas médicas, e fazer pedidos de livros ou outros produtos pessoais, tudo a partir de dispositivos móveis ou navegadores de internet dos utilizadores (Tran, 2019).

Relativamente à deteção de fraudes, a grande quantidade de transações processadas diariamente na plataforma possibilita que a Amazon enfrente vulnerabilidades à fraude. Para combater esse problema, a empresa utiliza IA para detetar e prevenir atividades de conta suspeitas, bem como para identificar e remover listagens fraudulentas (Shaiju, 2023).

A Amazon emprega também IA para analisar imagens e vídeos, visando aprimorar a precisão das recomendações de produtos e remover conteúdos inapropriados ou ofensivos da sua plataforma. Por exemplo, o cliente ao carregar uma imagem de um produto desejado, um sistema de IA pode identificar o item e sugerir produtos similares. Da mesma forma, o cliente ao carregar um vídeo, se este contiver conteúdo inadequado, o sistema de IA pode sinalizá-lo para revisão por um moderador humano (Shaiju, 2023).

Por último, de forma a garantir o funcionamento sem falhas de seus centros de distribuição, a Amazon utiliza análise preditiva para prever possíveis falhas no equipamento. Ao analisar dados de sensores e outras fontes, os sistemas de IA podem identificar padrões indicativos de possíveis falhas, permitindo que a manutenção seja agendada antes que ocorram problemas (Shaiju, 2023).

A integração da IA na indústria do e-commerce está a proporcionar uma compreensão mais profunda e uma aproximação mais eficaz aos clientes. Com o uso dessas tecnologias avançadas, a maioria das empresas de comércio *online* podem agora aplicar a ciência de dados e a aprendizagem automática para aprimorarem os serviços ao cliente, resultando em impactos significativos na satisfação e na fidelização destes (Tran, 2019).

A Amazon destaca-se como uma empresa líder no e-commerce, em grande parte devido às suas inovações em IA. Ao continuar a desenvolver e aprimorar as suas aplicações de IA, a empresa encontra-se posicionada para manter a sua posição de destaque no mercado (Tran, 2019).

CAPÍTULO II – METODOLOGIA

2 Metodologia de Pesquisa

Este capítulo detalha o modelo de hipóteses e os métodos e procedimentos utilizados para recolher e analisar dados, fornecendo uma compreensão clara de como a pesquisa será conduzida.

2.1 Objetivos

O objetivo principal deste estudo é investigar como a IA pode ser utilizada para personalizar a experiência do consumidor no e-commerce, particularmente na plataforma da Amazon. Contudo, este é amplo e para abordar as motivações da presente investigação foram definidos objetivos específicos, declarando com maior clareza o que se pretende alcançar com a mesma:

1. Analisar como a implementação da IA no ambiente de E-commerce afere preponderância ao nível da Personalização da Experiência do Consumidor.
2. Examinar a relação entre a Personalização da Experiência do Consumidor no ambiente de E-commerce e a Atitude de Compra.
3. Examinar a relação entre a Personalização da Experiência do Consumidor no ambiente de E-commerce e a Satisfação.
4. Verificar como a Atitude Compra contribui na Intenção de Compra dos utilizadores no ambiente de E-commerce.
5. Investigar o impacto da Satisfação na Intenção de Compra dos utilizadores no ambiente de E-commerce.

2.2 Modelo Concetual

Os objetivos específicos alinham-se às hipóteses extraídas da revisão da literatura, porém, estas são mais completas pois visam verificar a existência de uma relação entre as variáveis em estudo. Selecionou-se nove hipóteses, de forma a proporcionar uma estrutura abrangente à condução da investigação. Assim sendo, desenvolveu-se as seguintes hipóteses:

Hipótese 1 (H1): A prática da IA no ambiente de E-commerce impacta positivamente a Personalização da Experiência do Consumidor.

Hipótese 2 (H2): Existe uma relação significativa entre a Personalização da Experiência do Consumidor no ambiente de E-commerce e a Atitude de Compra.

Hipótese 3 (H3): Existe uma relação significativa entre a Personalização da Experiência do Consumidor no ambiente de E-commerce e a Satisfação.

Hipótese 4 (H4): A Atitude de Compra exerce um efeito positivo na Satisfação dos utilizadores de E-commerce.

Hipótese 5 (H5): Existe uma relação significativa entre a Atitude de Compra e a Confiança dos utilizadores de E-commerce.

Hipótese 6 (H6): A satisfação exerce um efeito positivo na Confiança dos utilizadores no ambiente de E-commerce.

Hipótese 7 (H7): A Confiança exerce um efeito positivo na Intenção de Compra dos utilizadores no ambiente de E-commerce.

Hipótese 8 (H8): A Atitude de Compra exerce um efeito positivo na Intenção de Compra dos utilizadores no ambiente de E-commerce.

Hipótese 9 (H9): A Satisfação exerce um efeito positivo na Intenção de Compra dos utilizadores de E-commerce.

O modelo conceitual deste estudo foi construído com base em hipóteses identificadas por Lopes et al. (2022) e, ainda, por Groh (2009), conforme apresentado na Figura 17.

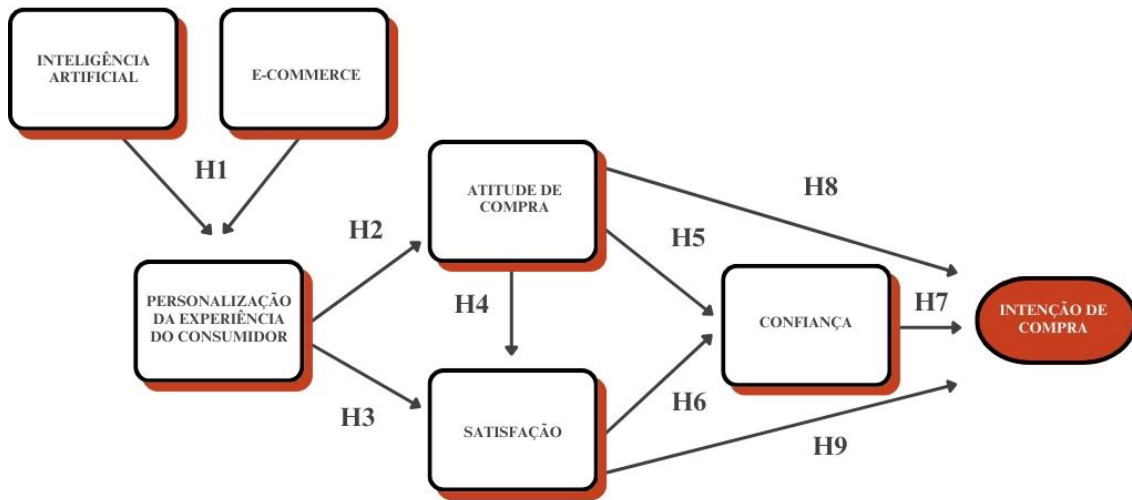


Figura 17: Modelo Estrutural e Hipóteses de Investigação.

A presente investigação pretende responder à recomendação de Lopes et al. (2022): “A replicação do modelo proposto junto a consumidores de um site determinado seria uma boa forma de validar e ampliar os resultados obtidos nesta pesquisa”. O autor, no seu trabalho, procurou compreender o comportamento dos consumidores numa pequena cidade de Floriano, no Piauí (Lopes et al., 2022).

Houve a consideração de olhar para o modelo estrutural da investigação que Lopes et al. (2022) e, ainda, Groh (2009) utilizaram no seu estudo. Estas apresentam algumas hipóteses semelhantes à proposta do presente projeto, conforme se pode verificar nas Figuras 18 e 19.

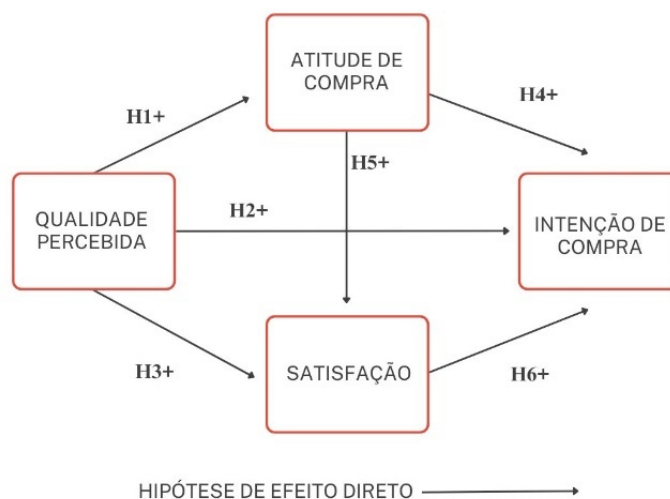


Figura 18: Modelo Estrutural e Hipóteses de Lopes et al.

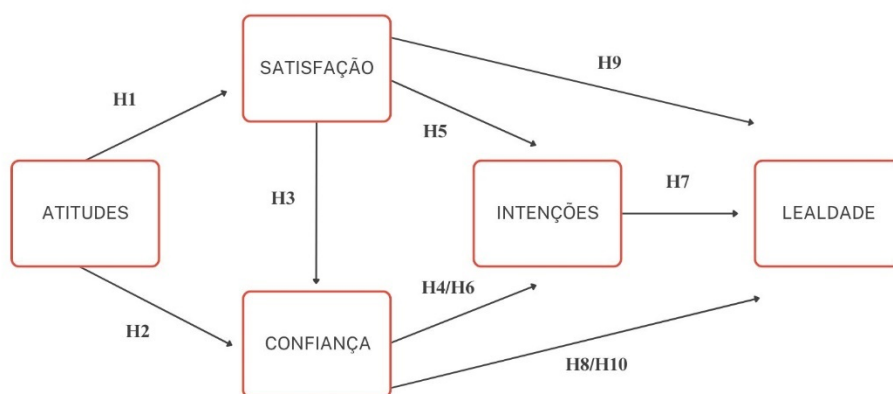


Figura 19: Modelo Hipotético Proposto por Groh.

Após a visualização dos modelos propostos das investigações supra mencionadas, ressalta-se que H4, H8 e H9 do presente estudo apresentam correspondências ao estudo de Lopes et al. (2022) e a H5, H6 e H7 apresentam correspondências ao estudo de Groh (2009). No entanto, acrescentou-se a H1, H2 e H3 para estarem em harmonia com o objetivo principal e, ainda, os objetivos específicos.

Vale ressaltar que as hipóteses mencionadas neste estudo, mesmo algumas testadas noutras investigações, evidenciam relações num contexto diferente do utilizado por Lopes et al. (2022) e Groh (2009) tendo em vista que a amostra utilizada será um consumidor da plataforma *online* da Amazon, ou seja, um género de consumidor específico.

Na Tabela 1 é possível verificar quais as secções que serão utilizadas na validação das hipóteses apresentadas.

Secções	Hipóteses	H1	H2	H3	H4	H5	H6	H7	H8	H9
Secção 2										
Secção 3										
Secção 4		X								
Secção 5		X	X	X						
Secção 6				X	X		X			X
Secção 7						X	X	X		
Secção 8			X		X	X			X	
Secção 9								X	X	X

Tabela 1: Hipótese do modelo proposto.

2.3 Método de Recolha de Dados

A história da pesquisa científica revela que alguns métodos propõem-se em chegar à verdade com segurança e norma. Todavia, existem alguns que com menos segurança, alcançam uma verdade, mesmo que provisória. Próximos destes, existem métodos que procuram obter a compreensão, mas, mais distantes daqueles, também há outros que não conseguem nem a verdade, ampliando horizontes interpretativos (Paula et al., 2016).

Atendendo à orgânica do projeto é primordial explicar, minuciosamente, o rigor metodológico e os métodos usados para a concretização dos objetivos do caminho (Andre, 2014). De acordo com Fortin (1996), a metodologia remete ao conjunto dos métodos e, ainda, das técnicas que direcionam a elaboração de processo de investigação científica. No entanto, de forma mais pormenorizada, o autor adianta que os métodos de investigação harmonizam-se com os diferentes fundamentos filosóficos que carregam as preocupações, assim como as orientações de uma investigação.

Face aos propósitos da presente pesquisa, o estudo de caso apresenta-se como um método de análise pertinente, na medida em que traduz-se numa “investigação aprofundada de um indivíduo, de uma família, de um grupo de sujeitos ou de uma organização” (Fortin, 1996). Ademais, este é utilizado há muito tempo em diferentes áreas de conhecimentos, desde a sociologia à antropologia, sendo que a sua pesquisa possui como foco inicial uma série de questões para a problemática a ser analisada como pontos críticos ou hipóteses provisórias que, por conseguinte, fundamenta-se que o conhecimento adquirido é mais concreto e contextualizado (Andre, 2014).

Existem dois métodos de investigação que facultam o desenvolvimento do conhecimento como o método quantitativo e o método qualitativo (Fortin, 1996). O objetivo do projeto advém da realização de um questionário. Assim sendo, a metodologia mais adequada para esta investigação é a quantitativa.

Para Creswell (2007) o método quantitativo testa teorias objetivas através da análise causal de variáveis, podendo ocorrer pelo meio de instrumentos que proporcionam a capacidade de realizar análises estatísticas dos dados. O autor afirma que as estratégias de investigação deste método usufruem de dois géneros: pesquisas de levantamento que estudam quantitativamente uma amostra da população e pesquisas experimentais que utilizam uma amostra aleatória da população.

A pesquisa quantitativa refere-se à utilização de métodos estatísticos para análise de dados e à utilização de softwares para tabulação e análise, face ao distanciamento do pesquisador, uma vez que a recolha é realizada pelo meio de questionários estruturados aplicados sem a interação do pesquisador com a amostra (Raasch, 2022).

No método quantitativo, por norma, utilizam-se hipóteses para chegar ao objetivo proposto e traçado. Estas hipóteses possuem variáveis que estão dispostas num instrumento de recolha de dados estruturado, normalmente composto por escalas, as quais produzem dados numéricos que, por sua vez, são símbolos das respostas da amostra que são testados estatisticamente a fim de refutar ou não as hipóteses (Raasch, 2022).

Diferente da pesquisa quantitativa que transforma a informação nominal em números que possibilitam a realização de análises para seu fim, a pesquisa qualitativa utiliza as respostas nominais individuais para chegar a conclusões (Raasch, 2022), porém, nesta investigação apenas será utilizada a primeira.

O presente projeto visa apurar a experiência do utilizador quanto à personalização de produtos no ambiente virtual, especificamente no *website* da Amazon. Para alcançar este objetivo, elaborou-se um questionário cuidadosamente estruturado, considerando as tonalidades e particularidades do *online*.

O questionário foi direcionado aos utilizadores que tenham experiência direta com o *website* da Amazon, permitindo obter uma compreensão aprofundada. Quanto à construção deste, foi desenvolvido na plataforma Google Forms e a divulgação assentou nas plataformas sociais do investigador.

O objetivo da formulação de cada pergunta do questionário assentou em descobrir como a personalização de recomendações de produtos na plataforma da Amazon afeta certas variáveis do comportamento do consumidor que, conseqüentemente, encaminham à decisão de compra. Além disso, auferir o conhecimento dos inquiridos quanto a temas submersos do estudo. No fundo, o questionário visou descobrir padrões e correlações que expliquem a influência das recomendações personalizadas no comportamento dos consumidores no e-commerce.

Com base nas respostas dos participantes, o propósito passou por perceber se, de facto, as recomendações personalizadas influenciam positivamente as variáveis do comportamento do consumidor (satisfação, confiança e atitude de compra).

As questões presentes no questionário revelaram um cuidado, na medida em que a linguagem representada era simples e clara para que toda a amostra a compreendesse com a exatidão pretendida. Além do mais, evitou-se a ambiguidade e possíveis desistências dos inquiridos.

O questionário direcionou-se da secção 1 até à secção 11. Contudo, antes de iniciar as secções apresentou-se um texto de cariz introdutório, na medida em que o propósito passou por uma breve explicação sobre o estudo e a importância das respostas e por uma contextualização da investigação. Ademais, apresentou-se a duração prevista para o preenchimento do questionário e uma pergunta com o intuito de perceber se o inquirido pretendia colaborar no estudo.

De seguida, deu-se início às respetivas secções do questionário que apresentaram diferentes questões para responder às diferentes hipóteses que compõem o modelo de pesquisa proposto.

A secção 2 procurou determinar se o inquirido já realizou compras no *website* da Amazon, sendo composta por uma questão de filtro para certificar que apenas indivíduos que se enquadram nas características da amostra definida continuavam a responder ao inquirido. Caso a resposta tenha sido afirmativa, o questionário prosseguiu para a secção 4, onde foi explorado o seu conhecimento sobre IA e e-commerce na plataforma. Caso a resposta tenha sido negativa, o questionário direcionou-se para a secção 3, onde foi solicitado que explicasse as razões pelas quais nunca realizou compras na Amazon através de uma resposta aberta. Após responder, o questionário encaminhou para a secção 10, onde foram recolhidas informações adicionais sobre o respondente.

O propósito da secção 4 passou por avaliar a compreensão e percepção dos participantes acerca do papel da IA na experiência de compra na Amazon. Inicialmente, o inquirido observou uma definição básica de IA e um vídeo elucidativo sobre o tema. De seguida, foi questionado se reconhece a utilização de inteligência artificial no *website* da Amazon. Após isso, apresentou-se um exemplo específico de IA na forma do Amazon Lex, seguido por um vídeo explicativo sobre o seu funcionamento. O inquirido foi convidado a considerar se a IA já o auxiliou nas suas compras *online*.

Na secção 5, o objetivo assentou em entender a experiência do respondente com a personalização das recomendações na Amazon. Este foi questionado sobre a frequência com que compra produtos recomendados pela Amazon e se a personalização das

recomendações influencia positivamente sua experiência de compra. Caso tenha respondido “nunca” na primeira, respetivamente, foi direcionado para a secção 10.

A secção 6 procurou entender a satisfação do inquirido como consumidor na plataforma da Amazon. Este foi solicitado a indicar o seu grau de satisfação com base em diferentes aspectos relacionados às recomendações personalizadas oferecidas pela Amazon. Na secção seguinte, procurou-se avaliar a confiança do respondente como consumidor na plataforma da Amazon, especificamente em relação às recomendações personalizadas. Este foi solicitado a indicar o seu grau de confiança em vários aspectos, como honestidade, competência e consideração aos interesses dos clientes por parte da Amazon no processo de recomendação de produtos.

A objetivo da secção 8 do questionário passou por perceber a atitude de compra do inquirido como consumidor na plataforma da Amazon, especialmente em relação às recomendações personalizadas. Este foi solicitado a indicar o seu grau de atitude numa escala de diferenciais semânticos, que abrange diferentes aspectos da experiência de compra, desde a percepção do valor oferecido até a facilidade de compreensão das recomendações.

A secção 9 iniciou nas futuras intenções de compra do respondente como consumidor na plataforma da Amazon. Este foi solicitado a indicar o seu grau de intenção de compra em relação às recomendações personalizadas da Amazon, bem como a sua disposição para recomendar a plataforma a amigos e familiares. Estas perguntas têm o propósito de avaliar a propensão do inquirido para continuar a utilizar a Amazon para efetuar compras *online*, com base na sua experiência passada com recomendações personalizadas.

A secção 10 revelou questões relacionadas com a identificação do inquirido para que se consiga caracterizar a amostra da investigação: género, idade, residência, habilitações literárias e situação profissional. O inquérito encerrou com um agradecimento final na secção 11, ou seja, uma expressão de gratidão pela participação/contribuição e tempo despendido do respondente na investigação. No Apêndice I apresenta-se na íntegra o questionário que reflete toda a informação apresentada neste subcapítulo.

Na Tabela 2 é possível verificar o tipo e objetivo das perguntas do questionário, de acordo com a secção.

Secção	Tipo de Perguntas	Objetivo da Perguntas
Secção 2	Estruturada – Dicotómica	Filtrar a amostra
Secção 3	Exploratória – Aberta	Perceber a razão dos inquiridos nunca terem realizado compras na Amazon
Secção 4	Estruturada – Dicotómica	Avaliar o conhecimento dos inquiridos
Secção 5	Estruturada – Dicotómica	Filtrar a amostra e perceber a influência das recomendações dos produtos nos inquiridos
Secção 6	Estruturada – Escala de avaliação	Compreender o grau de satisfação dos inquiridos na Amazon
Secção 7	Estruturada – Escala de avaliação	Compreender o grau de confiança dos inquiridos na Amazon
Secção 8	Estruturada – Escala de Diferencial Semântico	Compreender o grau de atitude de compra dos inquiridos na Amazon
Secção 9	Estruturada – Escala de avaliação	Compreender o grau de futuras intenções de compra dos inquiridos na Amazon
Secção 10	Estruturada – Escolha Múltipla	Caracterização Demográfica

Tabela 2: Tipo e objetivo das perguntas do questionário.

CAPÍTULO III – ANÁLISE DE RESULTADOS

3 Resultados

Neste capítulo, será apresentado os resultados com o propósito de apurar a validade das hipóteses com a ajuda do *software* JASP. Além do mais, procede-se a recomendações face aos resultados obtidos.

3.1 Análise Descritiva

Inicialmente, importou-se os dados e configurou-se o nome das variáveis na coluna “Name” – *Software* JASP. O objetivo foi dar um nome claro e conciso para cada variável, utilizando sublinhados (). Através do Apêndice II, configuração do nome das variáveis no software JASP, observa-se o nome da variável usada nas análises e as afirmações/questões correspondentes.

Após a configuração dos nomes das variáveis, foi realizada uma análise descritiva dos dados recolhidos. Este tipo de análise permite determinar os valores mínimo, máximo, média e desvio padrão. Os resultados são apresentados nas Tabelas 3, 4, 5 e 6.

Nesta análise, foi dada prioridade às variáveis diretamente envolvidas nas hipóteses de pesquisa, na medida em que estas influenciam os resultados e precisam ser bem compreendidas antes de se partir para análises mais complexas:

- Personalização da Experiência do Consumidor;
- Atitude de Compra;
- Satisfação;
- Confiança;
- Intenção de Compra;
- Perceção sobre o uso da IA.

Estatísticas Descritivas

Estatísticas descritivas ▼

	Personalizacao_Influencia	Satisfacao_Compra1	Satisfacao_Compra2	Satisfacao_Compra3	Satisfacao_Compra4	Satisfacao_Compra5	Satisfacao_Compra6
Válidos	173	168	168	168	168	168	168
Ausentes	43	48	48	48	48	48	48
Moda	1.000*	1.000*	1.000*	2.000*	2.000*	1.000*	1.000*
Mediana	1.000	1.000	1.000	2.000	2.000	2.000	2.000
Média	1.249	1.607	1.679	2.232	2.202	1.929	2.000
Desvio Padrão	0.562	0.916	0.937	0.928	0.852	1.053	1.038
Mínimo	1.000	1.000	1.000	1.000	1.000	1.000	1.000
Máximo	3.000	5.000	5.000	5.000	5.000	5.000	5.000

* The mode is computed assuming that variables are discreet.

Tabela 3 - Análise Descritiva de Variáveis Influentes - I.

Satisfacao_Compra7	Satisfacao_Compra8	Confianca_Amazon1	Confianca_Amazon2	Confianca_Amazon3	Confianca_Amazon4	Confianca_Amazon5	Confianca_Amazon6
168	168	168	168	168	168	168	168
48	48	48	48	48	48	48	48
1.000*	1.000*	1.000*	2.000*	2.000*	2.000*	3.000*	3.000*
1.000	2.000	1.000	2.000	2.000	2.000	3.000	3.000
1.679	2.006	1.708	2.000	1.970	2.988	2.637	2.357
0.884	1.041	0.962	0.766	0.713	1.528	1.086	0.898
1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
5.000	5.000	5.000	5.000	5.000	5.000	5.000	5.000

Tabela 4 - Análise Descritiva de Variáveis Influentes - II.

Confianca_Amazon7	Confianca_Amazon8	Atitude_Compra1	Atitude_Compra2	Atitude_Compra3	Atitude_Compra4	Intencao_Compra_Futuro1	Intencao_Compra_Futuro2
168	168	170	170	170	170	168	168
48	48	46	46	46	46	48	48
1.000*	1.000*	4.000*	4.000*	4.000*	4.000*	1.000*	4.000*
1.000	1.000	4.000	4.000	4.000	4.000	1.000	4.000
1.679	2.304	3.676	3.641	3.665	3.571	1.577	2.946
0.864	1.702	1.248	1.303	1.259	1.244	0.785	1.225
1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
5.000	5.000	5.000	5.000	5.000	5.000	5.000	5.000

Tabela 5 - Análise Descritiva de Variáveis Influentes - III.

Intencao_Compra_Futuro3
168
48
1.000*
2.000
1.756
0.858
1.000
5.000

Tabela 6- Análise Descritiva de Variáveis Influentes - IV.

Relativamente à variável Personalização e Influência, constata-se que a média é 1,249, a mediana é 1,000, a moda é 1,000 e o desvio padrão é 0,562. Estes valores sugerem que a maioria dos entrevistados concorda que a personalização das recomendações na Amazon tem um impacto positivo na sua experiência de compra, pois a mediana e a moda estão ambas em 1, o que presumivelmente é a resposta mais positiva. Para mais, o desvio padrão relativamente baixo indica uma baixa variabilidade nas respostas

No que diz respeito à variável Satisfação com a Compra, verifica-se que as médias variam de 1.607 a 2.232, com a mediana e a moda frequentemente situadas em 1 ou 2 e os desvios padrão a variar entre 0.852 a 1.053. Através destes valores, percebe-se que as médias são relativamente baixas, indicando que os inquiridos têm uma satisfação moderada a baixa com as suas compras. A mediana e a moda sugerem que muitos

entrevistados tendem a discordar ou a ter uma atitude neutra em relação às afirmações sobre satisfação. O desvio padrão mostra alguma variabilidade, apesar desta não ser excessiva.

Quanto à variável Confiança, as médias situam-se entre 1.679 e 2.988, enquanto a mediana e a moda tendem a estar em 1 ou 2, com algumas variáveis a apresentar medianas e modas de 3. A confiança dos inquiridos nas recomendações personalizadas da Amazon é, em geral, moderada a baixa, de acordo com estes valores. As médias e tendências de moda mostram que muitos clientes estão insatisfeitos ou neutros em relação à confiança que depositaram na Amazon. O desvio padrão de 0,713 a 1.702 mostra pouca variabilidade em algumas variáveis, sugerindo opiniões consistentes entre os entrevistados.

No que diz respeito à variável Atitude de Compra, as médias estão entre 3.571 e 3.676, enquanto a moda e a mediana estão em 4.000. Estes valores mostram que, normalmente, os inquiridos têm uma opinião positiva sobre as compras na Amazon, mas não muito positiva. A moda em 4 indica que a maioria dos entrevistados optou por uma resposta favorável, o que indica uma aceitação moderada. A variabilidade nas respostas é demonstrada pelo desvio padrão de 1.248 a 1.303.

As médias para a variável Intenção de Compra Futura estão entre 1.577 e 2.946, com a moda e a mediana normalmente em 2 ou 4. Esses valores indicam que os inquiridos na Amazon têm uma intenção moderada de compras futuras, com alguns a demonstrar uma intenção mais clara de voltar a comprar produtos recomendados, enquanto outros mostram uma postura mais neutra ou hesitante. O desvio padrão de 0.785 a 1.756 mostra uma certa variabilidade nas respostas, sugerindo que as intenções de compra futura dos inquiridos diferem, com alguns a mostrar uma forte intenção de compra e outros menos inclinados a fazer compras baseadas em recomendações.

Relativamente à variável Intenção de Compra Futura, as médias estão entre 1.577 e 2.946, com a mediana e a moda normalmente em 2 ou 4. A partir destes valores, é evidente que os inquiridos da Amazon têm uma intenção moderada de compras futuras, com alguns a mostrar uma intenção mais clara de voltar a comprar produtos recomendados, enquanto outros parecem hesitar. O desvio padrão, que varia entre 0.785 e 1.756, indica uma certa variabilidade nas respostas, sugerindo que as intenções de compra futura diferem entre os

inquiridos, visto que alguns apresentam uma intenção forte e outros mais fraca para a realização de novas compras baseadas em recomendações.

Em conclusão, a análise descritiva das variáveis relacionadas às hipóteses mostrou que os inquiridos avaliaram a personalização positivamente, indicando que esta pode ter um impacto positivo nas suas percepções. A satisfação e a confiança são um pouco mais baixas quando se trata de personalização, indicando que a Amazon pode melhorar. A atitude é positiva, mas parece que não há intenção de compra futura.

Além da análise descritiva às variáveis que estão diretamente envolvidas com as hipóteses extraídas da investigação, achou-se pertinente obter uma visão geral das características demográficas e outras variáveis de interesse que descrevem os inquiridos (ver Tabela 7):

- Género;
- Faixa Etária;
- Habilitações;
- Situação Profissional.

Estatísticas descritivas

	Gênero:	Faixa Etária:	Habilitações Literárias:	Situação Profissional:
Válidos	215	215	215	215
Ausentes	1	1	1	1
Moda	2.000 ^a	3.000 ^a	2.000 ^a	1.000 ^a
Mediana	2.000	3.000	2.000	1.000
Média	1.614	2.777	2.665	1.544
Desvio Padrão	0.488	1.017	0.814	0.813
Mínimo	1.000	1.000	1.000	1.000
Máximo	2.000	6.000	5.000	4.000

^a The mode is computed assuming that variables are discreet.

Tabela 7 - Análise Descritiva de Características Demográficas.

A análise descritiva da amostra revela que, no que diz respeito ao género, 215 respondentes foram considerados válidos com uma moda e uma mediana de 2, e uma média de 1.614, afirmando que a maioria dos inquiridos pertence ao género codificado como "2" – masculino. A distribuição é homogênea entre os géneros, com um desvio padrão de 0,488, mas o género masculino tem um pequeno predomínio.

Quanto à faixa etária, a moda e a mediana de 3, juntamente com a média de 2.777, sugerem que a maioria dos inquiridos pertence a "3" – entre os 25 a 34 anos. O desvio

padrão de 1.017 denota alguma variabilidade nas idades, mas ainda assim sugere uma amostra relativamente jovem.

No que se refere às habilitações literárias, a moda de 2, com uma mediana de 2 e uma média de 2.665, indica que a maioria dos inquiridos possui um nível de educação correspondente a "2" – ensino secundário. A variação nos níveis de educação na amostra é indicada pelo desvio padrão de 0,814.

Por último, na situação profissional, a moda e mediana de 1 e a média de 1.544 indicam que a maioria dos entrevistados estava numa situação codificada como "1" - estudantes, com um desvio padrão de 0,813.

3.2 Teste das Hipóteses

Após elaborada a Análise Descritiva, procurou-se analisar as correlações entre as variáveis propostas nas hipóteses:

1. Recolher os dados por meio do questionário;
2. Aplicar as técnicas estatísticas adequadas, como análise de correlação;
3. Examinar as relações entre as variáveis.

Para cada hipótese, foram escolhidas as duas variáveis pertinentes à afirmação da hipótese.

a) Hipótese 1

Hipótese 1 (H1): A prática da IA no ambiente de E-commerce impacta positivamente a Personalização da Experiência do Consumidor (ver Tabela 8).

Correlação ▼

<i>r de Pearson Correlações ▼</i>			
Variável		Reconhecimento_IA	Personalizacao_Influencia
1. Reconhecimento_IA	r de Pearson	—	
	p-valor	—	
2. Personalizacao_Influencia	r de Pearson	0.244	—
	p-valor	0.001	—

Tabela 8 - Correlação para verificar se a prática da IA no ambiente de E-commerce impacta positivamente a Personalização da Experiência do Consumidor.

Para a análise desta hipótese, os resultados mostram as correlações entre a variável de Reconhecimento de IA (secção 4 do questionário – ver Apêndice I) e a variável da Influência da Personalização (secção 5 do questionário – ver Apêndice I).

O coeficiente de correlação de Pearson entre Reconhecimento_IA e Personalização_Influência é 0.244. Este valor indica uma correlação positiva fraca, mas existente, entre a percepção do uso da IA no e-commerce e o impacto que a personalização tem na experiência do consumidor. Embora a correlação não seja forte, os consumidores percebem que a personalização tem um efeito positivo na sua experiência à medida que aceitam a IA.

A correlação é estatisticamente significativa, pois o valor-p associado é 0.001. Como resultado, a influência percebida da personalização está positivamente correlacionada com o reconhecimento da IA.

Em suma, a Hipótese 1 (H1) é válida pois os dados indicam uma correlação positiva e significativa entre o reconhecimento da IA e a influência da personalização na experiência do consumidor.

b) Hipótese 2

Hipótese 2 (H2): Existe uma relação significativa entre a Personalização da Experiência do Consumidor no ambiente de E-commerce e a Atitude de Compra (ver Tabela 9).

Correlação

Variável		Personalizacao_Influencia	Atitude_Compra1	Atitude_Compra2	Atitude_Compra3	Atitude_Compra4
1. Personalizacao_Influencia	r de Pearson	—				
	p-valor	—				
2. Atitude_Compra1	r de Pearson	-0.069	—			
	p-valor	0.372	—			
3. Atitude_Compra2	r de Pearson	-0.072	0.761	—		
	p-valor	0.353	< .001	—		
4. Atitude_Compra3	r de Pearson	-0.047	0.740	0.806	—	
	p-valor	0.546	< .001	< .001	—	
5. Atitude_Compra4	r de Pearson	-0.114	0.733	0.798	0.818	—
	p-valor	0.140	< .001	< .001	< .001	—

Tabela 9 - Correlação para verificar se existe uma relação significativa entre a Personalização da Experiência do Consumidor no ambiente de E-commerce e a Atitude de Compra.

Para a análise desta hipótese, os resultados mostram as correlações entre a variável da Influência da Personalização (secção 5 do questionário – ver Apêndice I) e as variáveis de Atitude de Compra (secção 8 do questionário – ver Apêndice I).

Os coeficientes de correlação de Pearson entre Personalização_Influência e as várias medidas de Atitude_Compra são todos negativos e muito próximos de zero. Estes sugerem que praticamente não há relação linear entre a influência da personalização e a atitude de compra. O sinal negativo dos coeficientes indica uma tendência mínima de relação inversa, mas essa relação é muito fraca e sem significância estatística. As correlações não são estatisticamente significativas, pois todos os valores-p são superiores a 0.05.

Em resumo, a Hipótese 2 (H2) é rejeitada porque os dados não mostram uma correlação significativa entre a personalização e a atitude de compra, ou seja, a personalização da experiência de compra na Amazon não está relacionada de maneira significativa com a atitude de compra dos consumidores.

c) Hipótese 3

Hipótese 3 (H3): Existe uma relação significativa entre a Personalização da Experiência do Consumidor no ambiente de E-commerce e a Satisfação (ver Tabela 10 e 11).

Correlação ▼

r de Pearson Correlações ▼		Personalizacao_Influencia	Satisfacao_Compra1	Satisfacao_Compra2	Satisfacao_Compra3	Satisfacao_Compra4
1. Personalizacao_Influencia	r de Pearson	—				
	p-valor	—				
2. Satisfacao_Compra1	r de Pearson	0.281	—			
	p-valor	< .001	—			
3. Satisfacao_Compra2	r de Pearson	0.338	0.613	—		
	p-valor	< .001	< .001	—		
4. Satisfacao_Compra3	r de Pearson	-0.034	0.340	0.396	—	
	p-valor	0.660	< .001	< .001	—	
5. Satisfacao_Compra4	r de Pearson	-0.128	0.356	0.442	0.326	—
	p-valor	0.099	< .001	< .001	< .001	—
6. Satisfacao_Compra5	r de Pearson	0.146	0.468	0.529	0.519	0.530
	p-valor	0.058	< .001	< .001	< .001	< .001
7. Satisfacao_Compra6	r de Pearson	-0.022	0.390	0.326	0.298	0.461
	p-valor	0.781	< .001	< .001	< .001	< .001
8. Satisfacao_Compra7	r de Pearson	0.257	0.508	0.575	0.310	0.214
	p-valor	< .001	< .001	< .001	< .001	0.005
9. Satisfacao_Compra8	r de Pearson	0.084	0.442	0.389	0.420	0.444
	p-valor	0.279	< .001	< .001	< .001	< .001

Tabela 10 - Correlação para verificar se existe uma relação significativa entre a Personalização da Experiência do Consumidor no ambiente de E-commerce e a Satisfação - I.

Satisfacao_Compra5	Satisfacao_Compra6	Satisfacao_Compra7	Satisfacao_Compra8
—			
—			
—			
—			
—			
—			
—			
0.466	—		
< .001	—		
0.502	0.417	—	
< .001	< .001	—	
0.492	0.532	0.516	—
< .001	< .001	< .001	—

Tabela 11 - Correlação para verificar se existe uma relação significativa entre a Personalização da Experiência do Consumidor no ambiente de E-commerce e a Satisfação - II

Para a análise desta hipótese, os resultados mostram as correlações entre a variável da Personalização da Influência (secção 5 do questionário – ver Apêndice I) e as variáveis de Satisfação de Compra (secção 6 do questionário – ver Apêndice I).

Os resultados sugerem que existe uma correlação positiva e estatisticamente significativa entre Personalização_Influência e algumas medidas de Satisfação _Compra, sobretudo, Satisfação_Compra1, Satisfação_Compra2 e Satisfação_Compra7. Os números mostram que os consumidores tendem a ficar mais satisfeitos com aspectos específicos das suas compras quando a experiência de compra é mais personalizada. Os valores-p também mostram alta significância estatística, além do r de Pearson.

As correlações com Satisfação_Compra3, Satisfação_Compra4, Satisfação_Compra5, Satisfação_Compra6, e Satisfação_Compra8 não são significativas ($p > 0.05$), e algumas exibiram coeficientes negativos. Estes resultados sugerem que a personalização não parece ter uma relação significativa ou positiva para estas dimensões particulares de satisfação. Além do r de Pearson, os valores-p indicam que estas correlações não são estatisticamente significativas.

Por fim, a Hipótese 3 (H3) é válida porque a personalização da experiência do cliente está positivamente e significativamente relacionada com certas dimensões da satisfação. No entanto, não há uma correlação significativa ou positiva entre todas as dimensões de satisfação, indicando que a relação entre personalização e satisfação pode ser mais complexa e depender de quais elementos específicos estão a ser medidos.

d) Hipótese 4

Hipótese 4 (H4): A Atitude de Compra exerce um efeito positivo na Satisfação dos utilizadores de E-commerce (ver Tabela 12).

Correlação ▼

r de Pearson Correlações ▼

Variável	Atitude_Compra1	Atitude_Compra2	Atitude_Compra3	Atitude_Compra4
1. Atitude_Compra1	r de Pearson p-valor	— —		
2. Atitude_Compra2	r de Pearson p-valor	0.761 < .001	— —	
3. Atitude_Compra3	r de Pearson p-valor	0.740 < .001	0.806 < .001	— —
4. Atitude_Compra4	r de Pearson p-valor	0.733 < .001	0.798 < .001	0.818 < .001
5. Satisfacao_Compra1	r de Pearson p-valor	-0.036 0.642	0.011 0.886	-0.016 0.842
6. Satisfacao_Compra2	r de Pearson p-valor	0.062 0.425	0.036 0.640	0.020 0.795
7. Satisfacao_Compra3	r de Pearson p-valor	0.033 0.672	0.007 0.925	-0.046 0.555
8. Satisfacao_Compra4	r de Pearson p-valor	0.090 0.248	0.042 0.589	0.019 0.812
9. Satisfacao_Compra5	r de Pearson p-valor	-0.013 0.869	-0.036 0.645	9.552x10 ⁻¹⁰ 1.000
10. Satisfacao_Compra6	r de Pearson p-valor	-0.042 0.588	-0.076 0.329	-0.036 0.639
11. Satisfacao_Compra7	r de Pearson p-valor	-0.088 0.257	-0.071 0.358	-0.080 0.301
12. Satisfacao_Compra8	r de Pearson p-valor	0.025 0.750	-0.030 0.704	0.006 0.938
				-0.016 0.833

Tabela 12 - Correlação para verificar se a Atitude de Compra exerce um efeito positivo na Satisfação dos utilizadores de E-commerce.

Para a análise desta hipótese, os resultados mostram as correlações entre as variáveis de Atitude de Compra (secção 8 do questionário – ver Apêndice I) e as variáveis de Satisfação de Compra (secção 6 do questionário – ver Apêndice I).

As correlações entre Atitude_Compra1 e as diferentes dimensões de Satisfação_Compra são fracas. Assim sendo, Atitude_Compra1 não tem relação estatisticamente significativa com a satisfação do consumidor nas dimensões examinadas.

As correlações entre Atitude_Compra2 e as dimensões de Satisfação_Compra são complexas, na medida em que apenas existe correlação moderada e positiva com as medidas Satisfação_Compra 5 a 8.

Algumas correlações entre Atitude_Compra3 e as dimensões de Satisfação_Compra são estatisticamente significativas. As correlações com Satisfação_Compra6, Satisfação_Compra7 e Satisfação_Compra_8 são moderadas e positivas, sugerindo que uma atitude de compra mais positiva está ligada a uma maior satisfação com a decisão de compra.

Existem algumas correlações significativas entre Atitude_Compra4 e as dimensões de Satisfação_Compra. A Atitude_Compra4 apresenta correlações mais fortes, mostrando que uma atitude de compra mais positiva está ligada a uma experiência de compra mais

satisfatória e a recomendações personalizadas da Amazon. No entanto, algumas correlações são fracas e não significativas.

Em suma, a Hipótese 4 (H4) é válida, na medida em que existe uma relação positiva e significativa entre a atitude de compra e a satisfação dos consumidores em algumas dimensões específicas. Atitude_Compra4 têm conexões mais fortes com vários índices de satisfação, sugerindo que uma atitude de compra mais positiva pode aumentar a satisfação em alguns aspectos da experiência de compra na Amazon.

e) Hipótese 5

Hipótese 5 (H5): Existe uma relação significativa entre a Atitude de Compra e a Confiança dos utilizadores de E-commerce (ver Tabela 13).

Correlação ▼

r de Pearson Correlações ▼

Variável		Atitude_Compra1	Atitude_Compra2	Atitude_Compra3	Atitude_Compra4
1. Atitude_Compra1	r de Pearson	—			
	p-valor	—			
2. Atitude_Compra2	r de Pearson	0.761	—		
	p-valor	< .001	—		
3. Atitude_Compra3	r de Pearson	0.740	0.806	—	
	p-valor	< .001	< .001	—	
4. Atitude_Compra4	r de Pearson	0.733	0.798	0.818	—
	p-valor	< .001	< .001	< .001	—
5. Confiança_Amazon1	r de Pearson	0.058	0.039	0.052	-0.026
	p-valor	0.454	0.617	0.500	0.735
6. Confiança_Amazon2	r de Pearson	-0.165	-0.163	-0.179	-0.225
	p-valor	0.033	0.035	0.020	0.003
7. Confiança_Amazon3	r de Pearson	-0.154	-0.089	-0.137	-0.051
	p-valor	0.047	0.251	0.076	0.514
8. Confiança_Amazon4	r de Pearson	-0.326	-0.274	-0.299	-0.269
	p-valor	< .001	< .001	< .001	< .001
9. Confiança_Amazon5	r de Pearson	-0.126	-0.124	-0.093	-0.170
	p-valor	0.103	0.110	0.231	0.028
10. Confiança_Amazon6	r de Pearson	0.005	-0.017	-0.032	-0.021
	p-valor	0.949	0.828	0.684	0.787
11. Confiança_Amazon7	r de Pearson	-0.051	0.023	0.038	-0.030
	p-valor	0.514	0.764	0.622	0.697
12. Confiança_Amazon8	r de Pearson	0.097	0.140	0.117	0.158
	p-valor	0.210	0.070	0.132	0.041

Tabela 13 - Correlação para verificar se existe uma relação significativa entre a Atitude de Compra e a Confiança dos utilizadores de E-commerce.

Para a análise desta hipótese, os resultados mostram as correlações entre as variáveis de Atitude de Compra (secção 8 do questionário – ver Apêndice I) e Confiança na Amazon (secção 7 do questionário – ver Apêndice I).

A Atitude_Compra1 não apresentou correlações significativas com as variáveis de Confiança (r variando de -0.165 a 0.058, $p > 0.05$), a Atitude_Compra2 também não demonstrou correlações significativas com as variáveis de Confiança (r variando de -0.163 a 0.039, $p > 0.05$), a Atitude_Compra3 apresentou uma correlação negativa e significativa com Confiança_Amazon4 ($r = -0.299$, $p < 0.001$). As outras variáveis de Confiança não apresentaram correlações significativas com Atitude_Compra3, com valores de r a avriar entre -0.179 a 0.052 e $p > 0.05$. Por fim, a Atitude_Compra4 mostrou

relações negativas significativas com Confiança_Amazon2 ($r = -0.225$, $p = 0.003$), Confiança_Amazon4 ($r = -0.269$, $p < 0.001$) e uma relação fraca e significativa com Confiança_Amazon8 ($r = 0.158$, $p = 0.041$). Com valores de r de -0.051 a -0.021 e p superior a 0.05 , as outras variáveis de confiança não mostraram correlações significativas com Atitude_Compra4.

Os resultados mostram que há uma correlação significativa entre várias métricas da Atitude de Compra e algumas dimensões de Confiança na Amazon. No entanto, estas correlações são principalmente negativas, sugerindo que uma atitude mais positiva em relação à compra não se traduz necessariamente numa maior confiança nas recomendações personalizadas da Amazon.

Em suma, a Hipótese 5 (H5) é válida pelos dados pois as relações encontradas não são consistentemente positivas como esperado.

f) Hipótese 6

Hipótese 6 (H6): A Satisfação exerce um efeito positivo na Confiança dos utilizadores no ambiente de E-commerce (ver Tabela 14).

Correlação ▾

r de Pearson Correlações ▾

Variável	Satisfacao_Compra1	Satisfacao_Compra2	Satisfacao_Compra3	Satisfacao_Compra4	Satisfacao_Compra5	Satisfacao_Compra6	Satisfacao_Compra7	Satisfacao_Compra8
1. Satisfacao_Compra1	r de Pearson p-valor	— —						
2. Satisfacao_Compra2	r de Pearson p-valor	0.613 < .001	— —					
3. Satisfacao_Compra3	r de Pearson p-valor	0.340 < .001	0.396 < .001	— —				
4. Satisfacao_Compra4	r de Pearson p-valor	0.356 < .001	0.322 < .001	0.569 < .001	— —			
5. Satisfacao_Compra5	r de Pearson p-valor	0.468 < .001	0.529 < .001	0.519 < .001	0.530 < .001	— —		
6. Satisfacao_Compra6	r de Pearson p-valor	0.390 < .001	0.326 < .001	0.298 < .001	0.461 < .001	0.466 < .001	— —	
7. Satisfacao_Compra7	r de Pearson p-valor	0.508 < .001	0.575 < .001	0.310 < .001	0.214 < .001	0.502 < .001	0.417 < .001	— —
8. Satisfacao_Compra8	r de Pearson p-valor	0.442 < .001	0.389 < .001	0.420 < .001	0.444 < .001	0.492 < .001	0.532 < .001	0.516 < .001
9. Confianca_Amazon1	r de Pearson p-valor	0.202 0.009	0.214 0.005	0.217 0.005	0.189 0.014	0.263 < .001	0.264 0.010	0.199 < .001
10. Confianca_Amazon2	r de Pearson p-valor	0.248 0.001	0.267 < .001	-0.093 0.232	-0.156 0.043	0.030 0.702	-0.023 0.771	0.274 < .001
11. Confianca_Amazon3	r de Pearson p-valor	0.202 0.009	0.183 0.018	-0.107 0.167	-0.148 0.056	-0.083 0.287	-0.016 0.835	0.279 < .001
12. Confianca_Amazon4	r de Pearson p-valor	0.027 0.732	0.060 0.439	-0.061 0.430	-0.118 0.128	0.044 0.570	0.015 0.846	-0.075 0.351
13. Confianca_Amazon5	r de Pearson p-valor	0.199 0.010	0.208 0.007	-0.148 0.056	-0.186 0.016	-0.169 0.028	-0.064 0.412	0.127 0.100
14. Confianca_Amazon6	r de Pearson p-valor	-0.018 0.820	-0.055 0.480	-0.035 0.649	-0.142 0.066	-0.169 0.028	-0.225 0.003	0.032 0.677
15. Confianca_Amazon7	r de Pearson p-valor	0.301 < .001	0.345 < .001	-0.056 0.473	-0.082 0.291	0.159 0.040	0.300 < .001	0.381 < .001
16. Confianca_Amazon8	r de Pearson p-valor	0.096 0.215	0.122 0.116	0.175 0.023	0.209 0.006	0.189 0.014	0.319 < .001	0.133 0.086

Tabela 14 - Correlação para verificar se a Satisfação exerce um efeito positivo na Confiança dos utilizadores no ambiente de E-commerce.

Para a análise desta hipótese, os resultados mostram as correlações entre as variáveis de Satisfação com a Compra (secção 6 do questionário – ver Apêndice I) e as variáveis de Confiança na Amazon (secção 7 do questionário – ver Apêndice I).

A Satisfação_Compra1 demonstrou correlações positivas e significativas com Confiança_Amazon1 ($r=0.202$, $p = 0.009$), Confiança_Amazon2 ($r=0.248$, $p = 0.001$), e Confiança_Amazon3 ($r=0.202$, $p = 0.009$). Estas correlações sugerem que o aumento da satisfação do consumidor está relacionado a um pequeno aumento da confiança. Não foram encontradas correlações significativas entre Satisfação_Compra1 e outras variáveis de confiança; os valores de r foram de 0.027 a 0.199 e p foi superior a 0.05.

A Satisfação_Compra2 mostrou correlações positivas e significativas com Confiança_Amazon1 ($r=0.214$, $p = 0.005$), Confiança_Amazon2 ($r=0.267$, $p < 0.001$), Confiança_Amazon3 ($r=0.183$, $p = 0.018$), e Confiança_Amazon5 ($r=0.208$, $p = 0.007$). Embora estas correlações sejam fracas, sugerem que um aumento na satisfação está ligeiramente relacionado a um aumento na confiança.

A Satisfação_Compra3 demonstrou uma correlação positiva e significativa apenas com Confiança_Amazon1 ($r=0.217$, $p = 0.005$), uma vez que as correlações com as variáveis adicionais de confiança não mostraram nenhuma significância.

Quanto à Satisfação_Compra4, esta apresentou uma correlação positiva e significativa com Confiança_Amazon1 ($r = 0.189$, $p = 0.014$) e Confiança_Amazon8 ($r = 0.209$, $p = 0.006$). Por outro lado, demonstrou correlações negativas e significativas com Confiança_Amazon2 ($r = -0.156$, $p = 0.043$), Confiança_Amazon5 ($r = -0.186$, $p = 0.028$) e Confiança_Amazon6 ($r = -0.142$, $p = 0.066$). Não houve correlações significativas com as outras variáveis de confiança.

Satisfação_Compra5 mostrou correlações positivas e significativas com Confiança_Amazon1 ($r = 0.263$, $p < 0.001$), Confiança_Amazon7 ($r = 0.159$, $p = 0.040$), e Confiança_Amazon8 ($r = 0.189$, $p = 0.006$). Além disso, demonstrou correlações negativas e significativas com Confiança_Amazon5 ($r = -0.169$, $p = 0.028$) e Confiança_Amazon6 ($r = -0.169$, $p = 0.028$). Com r oscilando de -0.083 a 0.044 e p acima de 0.05, as correlações entre as variáveis de confiança não foram significativas.

Satisfação_Compra6 demonstrou correlações positivas e significativas com Confiança_Amazon1 ($r = 0.264$, $p < 0.001$), Confiança_Amazon7 ($r = 0.300$, $p < 0.001$), e Confiança_Amazon8 ($r = 0.319$, $p < 0.001$). Além disso, foi encontrada uma correlação

negativa e significativa com Confiança_Amazon6 ($r = -0.225$, $p = 0.003$). As correlações adicionais com as variáveis de confiança não foram significativas.

Satisfação_Compra7 indicou correlações positivas e significativas com Confiança_Amazon1 ($r = 0.199$, $p = 0.010$), Confiança_Amazon2 ($r = 0.274$, $p < 0.001$), Confiança_Amazon3 ($r = 0.279$, $p < 0.001$), e Confiança_Amazon7 ($r = 0.381$, $p < 0.001$). As correlações com as outras variáveis de Confiança não foram significativas, com r variando de -0.072 a 0.072 e $p > 0.05$.

Satisfação_Compra8 apresentou correlações positivas e significativas com Confiança_Amazon2 ($r = 0.265$, $p < 0.001$), Confiança_Amazon7 ($r = 0.327$, $p < 0.001$), e Confiança_Amazon8 ($r = 0.319$, $p < 0.001$). As correlações entre as outras variáveis de confiança não foram significativas.

Em resumo, a Hipótese 6 (H6) é válida porque a maioria das variáveis de Satisfação apresentou correlações positivas e significativas com as variáveis de Confiança. Conclui-se, portanto, que à medida que os consumidores se sentem mais satisfeitos com as suas experiências de compra, tendem a confiar mais na Amazon.

g) Hipótese 7

Hipótese 7 (H7): A Confiança exerce um efeito positivo na Intenção de Compra dos utilizadores no ambiente de E-commerce (ver Tabela 15).

Correlação

r de Pearson Correlações

Variável	Confiança_Amazon1	Confiança_Amazon2	Confiança_Amazon3	Confiança_Amazon4	Confiança_Amazon5	Confiança_Amazon6	Confiança_Amazon7	Confiança_Amazon8	
1. Confiança_Amazon1	r de Pearson p-valor	— —							
2. Confiança_Amazon2	r de Pearson p-valor	-0.024 0.754	— —						
3. Confiança_Amazon3	r de Pearson p-valor	-0.030 0.696	0.592 < .001	— —					
4. Confiança_Amazon4	r de Pearson p-valor	-0.063 0.414	0.276 < .001	0.214 0.005	— —				
5. Confiança_Amazon5	r de Pearson p-valor	-0.171 0.027	0.619 < .001	0.589 < .001	0.192 0.013	— —			
6. Confiança_Amazon6	r de Pearson p-valor	-0.288 < .001	0.279 < .001	0.204 0.008	0.056 0.475	0.337 < .001	— —		
7. Confiança_Amazon7	r de Pearson p-valor	0.405 < .001	0.389 < .001	0.344 < .001	0.097 0.212	0.175 0.023	-0.099 0.244	— —	
8. Confiança_Amazon8	r de Pearson p-valor	0.292 < .001	-0.349 < .001	-0.205 0.008	-0.105 0.177	-0.345 < .001	-0.530 < .001	0.205 0.008	
9. Intencao_Compra_Futuro1	r de Pearson p-valor	0.414 < .001	0.299 < .001	0.320 < .001	0.131 0.092	0.100 0.198	-0.082 0.291	0.505 < .001	0.132 0.087
10. Intencao_Compra_Futuro2	r de Pearson p-valor	-0.211 0.006	0.064 0.411	0.108 0.164	-0.100 0.199	0.152 0.049	0.235 0.002	-0.203 0.008	-0.216 0.005
11. Intencao_Compra_Futuro3	r de Pearson p-valor	0.363 < .001	0.328 < .001	0.262 < .001	0.235 0.002	0.104 0.182	-0.026 0.737	0.435 < .001	0.137 0.076

Tabela 15- Correlação para verificar se a Confiança exerce um efeito positivo na Intenção de Compra dos utilizadores no ambiente de E-commerce.

Para a análise desta hipótese, os resultados mostram as correlações entre as variáveis de Confiança na Amazon (secção 7 do questionário – ver Apêndice I) e as variáveis de Intenção de Compra (secção 9 do questionário – ver Apêndice I).

Confiança_Amazon1 e Intenção_Compra_Futuro1 apresentam a correlação mais forte entre confiança e intenção de compra futura, com um coeficiente de correlação de 0,414 e um p-valor de 0,001. Como a confiança aumenta, a intenção de comprar na Amazon também tende a aumentar no futuro, conforme demonstrado por estes valores.

Uma correlação positiva e significativa foi encontrada entre Confiança_Amazon2 e Intenção_Compra_Futuro3 ($r = 0.328$, $p = 0.001$). As correlações com Intenção_Compra_Futuro1 e Intenção_Compra_Futuro2 não foram significativas, com r a variar entre 0.064 a 0.299 e $p > 0.05$. A Confiança_Amazon3 demonstrou correlações positivas e significativas com Intenção_Compra_Futuro1 ($r = 0.320$, $p < 0.001$) e Intenção_Compra_Futuro3 ($r = 0.262$, $p = 0.001$), mas não houve uma correlação significativa com Intenção_Compra_Futuro2 ($r = 0.108$, $p = 0.164$).

A Confiança_Amazon4 não mostrou nenhuma correlação significativa com as variáveis de Intenção de Compra Futuro, com r a variar entre -0.105 a 0.192 e $p > 0.05$. Por sua vez, a Confiança_Amazon5 demonstrou uma correlação positiva e significativa com Confiança_Amazon6 ($r = 0.337$, $p = 0.001$) e com Confiança_Amazon7 ($r = 0.175$, $p = 0.023$). Além disso, a correlação positiva e significativa com Intenção_Compra_Futuro2 foi encontrada com r de 0.152 e p de 0.049. De salientar que as outras correlações não foram significativas, com r variando de -0.345 a 0.100 e $p > 0.05$.

A Confiança_Amazon6 e Intenção_Compra_Futuro2 tiveram uma correlação negativa e significativa ($r = 0.235$, $p = 0.002$). As outras correlações não foram concluídas como significativas. Confiança_Amazon7 e Intenção_Compra_Futuro1 ($r = 0.505$, $p = 0.001$) foram correlacionados positivamente e significativamente. As outras correlações não foram significativas. Por último, a correlação positiva e significativa entre Confiança_Amazon8 e Intenção_Compra_Futuro1 foi encontrada ($r = 0.205$, $p = 0.008$). No entanto, existiram também correlações negativas e significativas com Intenção_Compra_Futuro2 ($r = -0.216$, $p = 0.005$) e Intenção_Compra_Futuro3 ($r = -0.216$, $p = 0.005$).

Em resumo, a Hipótese H7 (H7) é válida, na medida em que existem correlações positivas significativas. A confiança dos consumidores na Amazon pode afetar as suas intenções de compra futuras, especialmente com base em métricas de confiança.

h) Hipótese 8

Hipótese 8 (H8): A Atitude de Compra exerce um efeito positivo na Intenção de Compra dos utilizadores no ambiente de E-commerce (ver Tabela 16).

Correlação ▾

r de Pearson Correlações ▾		Atitude_Compra1	Atitude_Compra2	Atitude_Compra3	Atitude_Compra4
Variável					
1. Atitude_Compra1	r de Pearson	—			
	p-valor	—			
2. Atitude_Compra2	r de Pearson	0.761	—		
	p-valor	< .001	—		
3. Atitude_Compra3	r de Pearson	0.740	0.806	—	
	p-valor	< .001	< .001	—	
4. Atitude_Compra4	r de Pearson	0.733	0.798	0.818	—
	p-valor	< .001	< .001	< .001	—
5. Intencao_Compra_Futuro1	r de Pearson	-0.021	0.015	-0.040	-0.066
	p-valor	0.787	0.850	0.605	0.394
6. Intencao_Compra_Futuro2	r de Pearson	-0.047	0.018	-0.046	-0.058
	p-valor	0.546	0.812	0.551	0.453
7. Intencao_Compra_Futuro3	r de Pearson	0.074	0.048	0.029	0.001
	p-valor	0.341	0.540	0.705	0.989

Tabela 16 - Correlação para verificar se a Atitude de Compra exerce um efeito positivo na Intenção de Compra dos utilizadores no ambiente de E-commerce.

Para a análise desta hipótese, os resultados mostram as correlações entre as variáveis de Atitude de Compra (secção 8 do questionário – ver Apêndice I) e as variáveis de Intenção de Compra na Amazon (secção 9 do questionário – ver Apêndice I).

Os coeficientes de correlação (r) são muito próximos de zero em cada par de variáveis, indicando uma correlação muito fraca ou inexistente entre a Atitude de Compra e a Intenção de Compra Futura. Os p-valores para todas as correlações estão acima do nível de significância comum de 0,05, o que indica que não há evidências estatísticas suficientes para sustentar uma relação significativa entre a Atitude de Compra e a Intenção de Compra Futura.

Em suma, a Hipótese 8 (H8) é rejeitada, o que significa que outros fatores além da Atitude de Compra estão a influenciar a Intenção de Compra Futura dos consumidores com mais frequência.

i) Hipótese 9

Hipótese 9 (H9): A Satisfação exerce um efeito positivo na Intenção de Compra dos utilizadores de E-commerce (ver Tabela 17).

Correlação ▾

r de Pearson Correlações ▾		Satisfacao_Compra1	Satisfacao_Compra2	Satisfacao_Compra3	Satisfacao_Compra4	Satisfacao_Compra5	Satisfacao_Compra6	Satisfacao_Compra7	Satisfacao_Compra8
1. Satisfacao_Compra1	r de Pearson p-valor	— —							
2. Satisfacao_Compra2	r de Pearson p-valor	0.613 <.001	— —						
3. Satisfacao_Compra3	r de Pearson p-valor	0.340 <.001	0.396 <.001	— —					
4. Satisfacao_Compra4	r de Pearson p-valor	0.356 <.001	0.322 <.001	0.569 <.001	— —				
5. Satisfacao_Compra5	r de Pearson p-valor	0.468 <.001	0.529 <.001	0.519 <.001	0.530 <.001	— —			
6. Satisfacao_Compra6	r de Pearson p-valor	0.390 <.001	0.326 <.001	0.298 <.001	0.461 <.001	0.466 <.001	— —		
7. Satisfacao_Compra7	r de Pearson p-valor	0.508 <.001	0.575 <.001	0.310 <.001	0.214 <.001	0.502 <.001	0.417 <.001	— —	
8. Satisfacao_Compra8	r de Pearson p-valor	0.442 <.001	0.389 <.001	0.420 <.001	0.444 <.001	0.492 <.001	0.532 <.001	0.516 <.001	— —
9. Intencao_Compra_Futuro1	r de Pearson p-valor	0.401 <.001	0.278 <.001	0.119 <.001	0.039 <.001	0.282 <.001	0.289 <.001	0.282 <.001	0.019 <.001
10. Intencao_Compra_Futuro2	r de Pearson p-valor	-0.174 0.024	-0.156 0.044	0.037 0.631	0.120 0.123	-0.189 0.014	-0.151 0.051	-0.115 0.136	-0.098 0.205
11. Intencao_Compra_Futuro3	r de Pearson p-valor	0.289 <.001	0.282 <.001	0.019 0.808	-0.030 0.696	0.239 0.002	0.309 <.001	0.346 <.001	0.129 0.096

Tabela 17 - Correlação para verificar se a Satisfação exerce um efeito positivo na Intenção de Compra dos utilizadores de E-commerce.

Para a análise desta hipótese, os resultados mostram as correlações entre as variáveis de Satisfação com a Compra (secção 6 do questionário – ver Apêndice I) e as variáveis de Intenção de Compra (secção 9 do questionário – ver Apêndice I).

Uma correlação positiva e significativa foi encontrada entre Satisfação_Compra1 e Intenção_Compra_Futuro1 ($r = 0.401$, $p = 0.001$) e Intenção_Compra_Futuro3 ($r = 0.289$, $p = 0.001$). Ainda assim, a correlação com Intenção_Compra_Futuro2 não foi significativa ($r = -0.174$, $p = 0.044$), sendo uma correlação negativa e muito fraca. A Satisfação_Compra2 sublinhou a existência de uma correlação positiva e significativa com Intenção_Compra_Futuro1 ($r = 0.278$, $p < 0.001$). Todavia, não houve correlação significativa com Intenção_Compra_Futuro2 ($r = -0.156$, $p = 0.125$) e Intenção_Compra_Futuro3 ($r = 0.282$, $p < 0.001$).

A Satisfação_Compra3 apresentou correlações positivas e significativas com Intenção_Compra_Futuro1 ($r = 0.119$, $p = 0.125$) e Intenção_Compra_Futuro3 ($r = 0.019$, $p = 0.808$). Não houve correlações significativas com Intenção_Compra_Futuro2 ($r = 0,037$, $p = 0,453$). Intenção_Compra_Futuro1 e Intenção_Compra_Futuro3 foram correlacionados positivamente e significativamente com Satisfação_Compra4. As correlações com Intenção_Compra_Futuro2 não foram significativas ($r = 0.123$, $p = 0.123$).

A Satisfação_Compra5 demonstrou uma correlação positiva e significativa com Intenção_Compra_Futuro1 ($r = 0.282$, $p < 0.001$) e Intenção_Compra_Futuro3 ($r = 0.239$, $p = 0.002$). Contudo, denotou uma correlação negativa e significativa com Intenção_Compra_Futuro2 ($r = -0.189$, $p = 0.014$). A correlação positiva e significativa entre Satisfação_Compra6 com Intenção_Compra_Futuro1 foi encontrada ($r = 0.289$, $p <$

0.001). Além disso, foram realizadas correlações com Intenção_Compra_Futuro2 ($r = -0.151$, $p = 0.051$) e Intenção_Compra_Futuro3 ($r = 0.309$, $p = 0.001$). No entanto, a relação com Intenção_Compra_Futuro2 foi encontrada apenas marginalmente significativa.

A Satisfação_Compra7 apresentou uma correlação positiva e significativa com Intenção_Compra_Futuro1 ($r = 0.282$, $p < 0.001$) e Intenção_Compra_Futuro3 ($r = 0.346$, $p < 0.001$). Todavia, a correlação com Intenção_Compra_Futuro2 não foi encontrada com significância significativa ($r = -0.115$, $p = 0.136$). Por último, a Satisfação_Compra8 apresentou uma correlação positiva e significativa com Intenção_Compra_Futuro3 ($r = 0.129$, $p = 0.0986$), porém, as correlações com Intenção_Compra_Futuro1 ($r = 0.019$, $p = 0.808$) e Intenção_Compra_Futuro2 ($r = -0.098$, $p = 0.205$) não foram significativas.

Em suma, a Hipótese 9 (H9) é válida, pois várias das combinações de variáveis examinadas apresentam correlações positivas e estatisticamente significativas entre a satisfação e a intenção de compra.

3.3 Validação das Hipóteses

Após realizado o teste das hipóteses, nomeadamente, a análise das correlações determinou-se se os dados apoiam ou refutam as hipóteses do estudo.

Para cada uma das hipóteses, foram examinadas as correlações entre os fatores importantes. A significância estatística das relações foi avaliada por meio da análise dos coeficientes de correlação, permitindo concluir se as hipóteses eram verdadeiras ou não.

Desta forma, procedeu-se à elaboração de uma tabela de resumo, mostrando quais hipóteses foram validadas e quais foram rejeitadas, permitindo que haja uma visão clara e compreensível do resultado final do teste das hipóteses (ver Tabela 18).

	VALIDADA	REJEITADA
H1	X	
H2		X
H3	X	
H4	X	

H5	X	
H6	X	
H7	X	
H8		X
H9	X	

Tabela 18 - Verificação das Hipóteses.

3.4 Análise de Regressão Múltipla

Com base nos objetivos da investigação e nos resultados das análises mencionadas anteriormente, verificou-se que era possível complementar o estudo com outras análises para obter informações mais aprofundadas.

A Análise de Regressão Múltipla ajudará a descobrir quais os fatores que desempenham o maior impacto na intenção de compra, sendo fundamental a mesma para perceber quais são os aspectos da experiência do consumidor que se devem priorizar para melhorar a intenção de compra.

Para realizar a Análise de Regressão Múltipla, foram selecionadas variáveis independentes (preditoras) que podem afetar significativamente a variável dependente (resultado) que se pretende prever:

- Variáveis Dependentes: Intenção de Compra Futura.
- Variáveis Independentes: Satisfação com a Compra; Confiança na Amazon; Atitude de Compra; Personalização e Influência.

As variáveis independentes de satisfação e confiança são estudadas no marketing e conhecidas por afetar a intenção de compra. A disposição geral dos consumidores em relação ao e-commerce é representada pela variável atitude de compra, que pode servir como um forte indicador de comportamento futuro. Finalmente, a experiência de compra do cliente pode ser melhorada pela personalização, o que aumenta a intenção de compra.

a) Intenção de Compra Futura 1 (ver Tabela 19 e 20)

A Intenção de Compra Futura 1 corresponde à primeira afirmação da secção 9 do questionário – Futuras Intenções de Compra do Consumidor na Amazon (ver Apêndice I). Assim, diz respeito a: “Voltaria a realizar uma compra das recomendações personalizadas da Amazon”, onde os inquiridos tinham de indicar o seu grau de futuras intenções de compra com base nas suas experiências de compra na Amazon, numa escala entre 'Discordo Totalmente' e 'Concordo Totalmente'.

Regressão linear ▼

Resumo do modelo - Intencao_Compra_Futuro1

Modelo	R	R ²	R ² ajustado	RMSEA
M ₀	0.000	0.000	0.000	0.785
M ₁	0.703	0.494	0.421	0.598

Nota. M₁ includes Satisfacao_Compra1, Satisfacao_Compra2, Satisfacao_Compra3, Satisfacao_Compra4, Satisfacao_Compra5, Satisfacao_Compra6, Satisfacao_Compra7, Satisfacao_Compra8, Confianca_Amazon1, Confianca_Amazon2, Confianca_Amazon3, Confianca_Amazon4, Confianca_Amazon5, Confianca_Amazon6, Confianca_Amazon7, Confianca_Amazon8, Attitude_Compra1, Attitude_Compra2, Attitude_Compra3, Attitude_Compra4, Personalizacao_Influencia

ANOVA ▼

Modelo		Soma dos quadrados	gl	Média Quadrática	F	p
M ₁	Regressão	50.864	21	2.422	6.784	< .001
	Resíduos	52.130	146	0.357		
	Total	102.994	167			

Nota. M₁ includes Satisfacao_Compra1, Satisfacao_Compra2, Satisfacao_Compra3, Satisfacao_Compra4, Satisfacao_Compra5, Satisfacao_Compra6, Satisfacao_Compra7, Satisfacao_Compra8, Confianca_Amazon1, Confianca_Amazon2, Confianca_Amazon3, Confianca_Amazon4, Confianca_Amazon5, Confianca_Amazon6, Confianca_Amazon7, Confianca_Amazon8, Attitude_Compra1, Attitude_Compra2, Attitude_Compra3, Attitude_Compra4, Personalizacao_Influencia
Nota. O modelo de intercepção está omitido, já que nenhuma informação significativa pode ser mostrada.

Tabela 19 - Regressão Múltipla da Intenção de Compra Futura I- I.

Coefficientes

Modelo		Não padronizado	Erro padrão	Padronizado	t	p
M ₀	(Intercept)	1.577	0.061		26.034	< .001
	(Intercept)	-0.238	0.373		-0.638	0.524
M ₁	Satisfacao_Compra1	0.199	0.072	0.232	2.757	0.007
	Satisfacao_Compra2	-0.187	0.077	-0.223	-2.426	0.016
	Satisfacao_Compra3	0.048	0.068	0.057	0.704	0.483
	Satisfacao_Compra4	-0.103	0.080	-0.111	-1.286	0.200
	Satisfacao_Compra5	0.074	0.068	0.099	1.082	0.281
	Satisfacao_Compra6	0.126	0.063	0.166	1.995	0.048
	Satisfacao_Compra7	0.176	0.079	0.198	2.234	0.027
	Satisfacao_Compra8	-0.114	0.063	-0.151	-1.806	0.073
	Confianca_Amazon1	0.191	0.060	0.234	3.201	0.002
	Confianca_Amazon2	0.062	0.096	0.060	0.643	0.521
	Confianca_Amazon3	0.182	0.093	0.166	1.967	0.051
	Confianca_Amazon4	0.034	0.034	0.066	1.015	0.312
	Confianca_Amazon5	-0.055	0.065	-0.076	-0.845	0.399
	Confianca_Amazon6	-0.020	0.065	-0.023	-0.314	0.754
	Confianca_Amazon7	0.172	0.078	0.189	2.207	0.029
	Confianca_Amazon8	0.013	0.037	0.029	0.361	0.719
Attitude_Compra1	0.082	0.066	0.128	1.236	0.218	
Attitude_Compra2	0.073	0.072	0.120	1.010	0.314	
Attitude_Compra3	-0.089	0.077	-0.144	-1.160	0.248	
Attitude_Compra4	-0.018	0.080	-0.029	-0.229	0.819	
Personalizacao_Influencia	0.211	0.105	0.143	2.021	0.045	

Tabela 20 - Regressão Múltipla da Intenção de Compra Futura I- II.

Uma ampla gama de variáveis independentes, incluindo Satisfação, Confiança, Atitude de Compra e Personalização_Influência, e uma variável dependente, Intenção de Compra Futura 1, foram avaliadas por meio do uso de um modelo de regressão múltipla.

Como resultado, o valor R² ajustado é de 0,421, indicando que o modelo é responsável por 42,1% da variabilidade na intenção de compra futura 1. Mostra-se que o modelo é estatisticamente significativo com um valor F de 6,784 e um p-valor de 0,001.

As variáveis de Satisfação têm vários efeitos mistos; enquanto Satisfação_Compra1, Satisfação_Compra6, e Satisfação_Compra7 têm efeitos significativamente positivos, mas Satisfação_Compra2 tem efeitos significativamente negativos. As variáveis dependentes Confiança_Amazon1 e Confiança_Amazon7 têm um impacto positivo, assim como a Personalização_Influência tem um efeito positivo e significativo na variável dependente.

Estes resultados mostram que a satisfação e a confiança, bem como a personalização, foram os principais fatores na determinação da variável dependente. Todavia, direção e a magnitude desses efeitos mudam de acordo com as diferentes dimensões dessas variáveis.

b) Intenção de Compra Futura 2 (ver Tabela 21 e 22)

A Intenção de Compra Futura 2 corresponde à primeira afirmação da secção 9 do questionário – Futuras Intenções de Compra do Consumidor na Amazon (ver Apêndice I). Assim, diz respeito a: “Pretendo consultar a Amazon para fazer uma compra quando quiser comprar um produto recomendado”, onde os inquiridos tinham de indicar o seu grau de futuras intenções de compra com base nas suas experiências de compra na Amazon, numa escala entre 'Discordo Totalmente' e 'Concordo Totalmente'.

Regressão linear ▼

Resumo do modelo – Intencao_Compra_Futuro2 ▼

Modelo	R	R ²	R ² ajustado	RMSEA
M ₀	0.000	0.000	0.000	1.225
M ₁	0.557	0.310	0.211	1.088

Nota. M₁ includes Personalizacao_Influencia, Satisfacao_Compra1, Satisfacao_Compra2, Satisfacao_Compra3, Satisfacao_Compra4, Satisfacao_Compra5, Satisfacao_Compra6, Satisfacao_Compra7, Satisfacao_Compra8, Confianca_Amazon1, Confianca_Amazon2, Confianca_Amazon3, Confianca_Amazon4, Confianca_Amazon5, Confianca_Amazon6, Confianca_Amazon7, Confianca_Amazon8, Atitude_Compra1, Atitude_Compra2, Atitude_Compra3, Atitude_Compra4

ANOVA

Modelo		Soma dos quadrados	gl	Média Quadrática	F	p
M ₁	Regressão	77.651	21	3.698	3.123	< .001
	Resíduos	172.867	146	1.184		
	Total	250.518	167			

Nota. M₁ includes Personalizacao_Influencia, Satisfacao_Compra1, Satisfacao_Compra2, Satisfacao_Compra3, Satisfacao_Compra4, Satisfacao_Compra5, Satisfacao_Compra6, Satisfacao_Compra7, Satisfacao_Compra8, Confianca_Amazon1, Confianca_Amazon2, Confianca_Amazon3, Confianca_Amazon4, Confianca_Amazon5, Confianca_Amazon6, Confianca_Amazon7, Confianca_Amazon8, Atitude_Compra1, Atitude_Compra2, Atitude_Compra3, Atitude_Compra4

Nota. O modelo de interceptação está omitido, já que nenhuma informação significativa pode ser mostrada.

Tabela 21 - Regressão Múltipla da Intenção de Compra Futura 2 - I.

Coeficientes					
Modelo	Não padronizado	Erro padrão	Padronizado	t	p
M ₀	(Intercept)	2.946	0.094	31.181	< .001
M ₁	(Intercept)	2.906	0.678	4.284	< .001
	Personalizacao_Influencia	-0.514	0.190	-2.700	0.008
	Satisfacao_Compra1	-0.243	0.131	-1.848	0.067
	Satisfacao_Compra2	-0.019	0.140	-0.015	0.893
	Satisfacao_Compra3	0.087	0.125	0.066	0.694
	Satisfacao_Compra4	0.485	0.146	0.337	0.488
	Satisfacao_Compra5	-0.175	0.124	-1.409	0.161
	Satisfacao_Compra6	-0.158	0.115	-1.382	0.169
	Satisfacao_Compra7	0.039	0.143	0.275	0.783
	Satisfacao_Compra8	0.056	0.115	0.484	0.629
	Confianca_Amazon1	-0.096	0.108	-0.884	0.378
	Confianca_Amazon2	0.118	0.175	0.677	0.500
	Confianca_Amazon3	0.221	0.169	1.308	0.193
	Confianca_Amazon4	-0.099	0.061	-1.616	0.108
	Confianca_Amazon5	0.127	0.119	1.068	0.287
	Confianca_Amazon6	0.135	0.119	1.134	0.259
	Confianca_Amazon7	-0.079	0.142	-0.558	0.577
	Confianca_Amazon8	-0.060	0.068	-0.890	0.375
	Atitude_Compra1	-0.157	0.120	-1.302	0.195
	Atitude_Compra2	0.245	0.131	1.865	0.064
	Atitude_Compra3	0.044	0.140	0.312	0.756
	Atitude_Compra4	-0.215	0.146	-1.473	0.143

Tabela 22 - Regressão Múltipla da Intenção de Compra Futura 2 – II.

O valor R² ajustado é de 0,211, indicando que o modelo é responsável por 21,1% da variabilidade na intenção de compra futura 2. Além disso, os resultados mostram que o modelo é significativo com um valor de F de 3,123 e um p-valor de 0,00.

O único componente que tem um impacto positivo e significativo na Intenção de Compra Futura 2 é a Satisfação_Compra4. A Personalização_Influência exerce uma influência significativa e negativa, sugerindo que uma personalização excessiva pode ter efeitos negativos. As variáveis de Atitude de Compra e Confiança mostraram pouco impacto.

Estes resultados mostram que a personalização deve ser combinada com outros elementos, como a satisfação individual do cliente, para maximizar a intenção de compra futura.

c) Intenção de Compra Futura 3 (ver Tabela 23 e 24)

A Intenção de Compra Futura 2 corresponde à primeira afirmação da seção 9 do questionário – Futuras Intenções de Compra do Consumidor na Amazon (ver Apêndice I). Assim, diz respeito a: “Pretendo recomendar a Amazon para compras de recomendações personalizadas a amigos e familiares”, onde os inquiridos tinham de indicar o seu grau de futuras intenções de compra com base nas suas experiências de compra na Amazon, numa escala entre 'Discordo Totalmente' e 'Concordo Totalmente'.

Regressão linear ▼

Resumo do modelo - Intencao_Compra_Futura3 ▼

Modelo	R	R ²	R ² ajustado	RMSEA
M ₀	0.000	0.000	0.000	0.858
M ₁	0.668	0.446	0.366	0.683

Nota. M₁ includes Personalizacao_Influencia, Satisfacao_Compra1, Satisfacao_Compra2, Satisfacao_Compra3, Satisfacao_Compra4, Satisfacao_Compra5, Satisfacao_Compra6, Satisfacao_Compra7, Satisfacao_Compra8, Confianca_Amazon1, Confianca_Amazon2, Confianca_Amazon3, Confianca_Amazon4, Confianca_Amazon5, Confianca_Amazon6, Confianca_Amazon7, Confianca_Amazon8, Atitude_Compra1, Atitude_Compra2, Atitude_Compra3, Atitude_Compra4

ANOVA

Modelo		Soma dos quadrados	gl	Média Quadrática	F	p
M ₁	Regressão	54.842	21	2.612	5.595	< .001
	Resíduos	68.152	146	0.467		
	Total	122.994	167			

Nota. M₁ includes Personalizacao_Influencia, Satisfacao_Compra1, Satisfacao_Compra2, Satisfacao_Compra3, Satisfacao_Compra4, Satisfacao_Compra5, Satisfacao_Compra6, Satisfacao_Compra7, Satisfacao_Compra8, Confianca_Amazon1, Confianca_Amazon2, Confianca_Amazon3, Confianca_Amazon4, Confianca_Amazon5, Confianca_Amazon6, Confianca_Amazon7, Confianca_Amazon8, Atitude_Compra1, Atitude_Compra2, Atitude_Compra3, Atitude_Compra4

Nota. O modelo de interceptação está omitido, já que nenhuma informação significativa pode ser mostrada.

Tabela 23 - Regressão Múltipla da Intenção de Compra Futura 3 - I.

Coefficientes

Modelo		Não padronizado	Erro padrão	Padronizado	t	p
M ₀	(Intercept)	1.756	0.066		26.521	< .001
M ₁	(Intercept)	-0.578	0.426		-1.356	0.177
	Personalizacao_Influencia	0.029	0.120	0.018	0.239	0.811
	Satisfacao_Compra1	0.102	0.082	0.109	1.235	0.219
	Satisfacao_Compra2	-0.014	0.088	-0.015	-0.158	0.874
	Satisfacao_Compra3	-0.070	0.078	-0.075	-0.891	0.375
	Satisfacao_Compra4	-0.202	0.091	-0.201	-2.214	0.028
	Satisfacao_Compra5	0.104	0.078	0.127	1.530	0.186
	Satisfacao_Compra6	0.218	0.072	0.254	3.034	0.003
	Satisfacao_Compra7	0.091	0.090	0.093	1.007	0.316
	Satisfacao_Compra8	-0.112	0.072	-0.136	-1.555	0.122
	Confianca_Amazon1	0.248	0.068	0.278	3.640	< .001
	Confianca_Amazon2	0.244	0.110	0.218	2.218	0.028
	Confianca_Amazon3	0.147	0.106	0.122	1.390	0.167
	Confianca_Amazon4	0.111	0.038	0.198	2.887	0.004
	Confianca_Amazon5	-0.089	0.075	-0.113	-1.196	0.234
	Confianca_Amazon6	0.085	0.075	0.089	1.136	0.258
	Confianca_Amazon7	0.031	0.089	0.031	0.345	0.730
	Confianca_Amazon8	0.067	0.043	0.133	1.579	0.117
	Atitude_Compra1	0.161	0.076	0.231	2.130	0.035
	Atitude_Compra2	-4.027×10 ⁻⁴	0.082	-6.076×10 ⁻⁴	-0.005	0.996
Atitude_Compra3	-0.050	0.088	-0.074	-0.567	0.572	
Atitude_Compra4	0.024	0.091	0.034	0.258	0.797	

Tabela 24 - Regressão Múltipla da Intenção de Compra Futura 3 – II.

O valor R² ajustado é de 0,366, o que indica que o modelo é responsável por 36,6% da variabilidade na intenção de compra futura 3. Por outro lado, os resultados mostram que o modelo é significativo com um valor de F de 5,595 e um p-valor de 0,001.

A Satisfação_Compra6 afeta significativamente a Intenção de Compra Futura 3, enquanto a Satisfação_Compra4 afeta significativamente a Intenção de Compra Futura 4. As variáveis Confiança_Amazon1, Confiança_Amazon2 e Confiança_Amazon4 são preditores significativos e favoráveis para a Intenção de Compra Futura 3. Para mais, a Atitude_Compra1 também tem um impacto positivo na Intenção de Compra Futura 3.

Estes resultados indicam que, embora existam resultados inesperados, a confiança na Amazon e alguns fatores de satisfação e atitude de compra são essenciais para prever a intenção de compra futura 3.

As análises mostram que uma combinação de satisfação, confiança e personalização influencia as intenções de compra futuras, mas os efeitos variam significativamente entre as dimensões e os tipos de intenção de compra. A personalização e alguns fatores de satisfação podem ter efeitos positivos e negativos, enquanto a confiança na Amazon surge como um fator geralmente benéfico. Estes resultados indicam que, para maximizar as intenções de compra futuras, as estratégias de marketing e satisfação do cliente precisam ser equilibradas e ajustadas com cuidado.

CAPÍTULO IV – DISCUSSÃO DOS RESULTADOS

4 Interpretações e Recomendações

Este capítulo apresenta um conjunto de iniciativas estratégicas baseados nos resultados das análises realizadas e nas conclusões que visam melhorar o desempenho das empresas no e-commerce, personalizar a experiência do consumidor e otimizar o uso da IA. As informações recolhidas a partir de correlações e regressões múltiplas servirão de base para as sugestões aqui apresentadas.

A análise descritiva forneceu uma visão geral do comportamento dos respondentes e das percepções em relação a fatores como personalização, satisfação, confiança e atitude de compra. Através desta, constatou-se uma variação nas médias e desvios padrão das variáveis ligadas à satisfação, indicando que, embora muitos consumidores estejam moderadamente satisfeitos, existe espaço para melhorias. Para mais, apesar de grande parte dos inquiridos perceber a personalização como influente, a variação demonstra que nem todos a consideram positiva. Posto isto, esta análise é um bom indicador para que a Amazon comece a personalizar de forma mais precisa como, por exemplo, a utilizar dados de comportamento de compras passadas para certificar que as recomendações sejam de facto relevantes.

A análise das correlações realizadas foram úteis para validar as relações hipotéticas entre as variáveis, tendo havido resultados interessantes. O facto de haver uma correlação positiva significativa entre a confiança e a intenção de compra sugere que os clientes que confiam na Amazon estão mais propensos a fazer compras futuras. Assim, a Amazon deve manter a confiança dos clientes por meio de práticas transparentes e comunicação contínua sobre a confiabilidade dos serviços. Outra observação notável é que, apesar de algumas dimensões da satisfação apresentarem uma correlação positiva com a intenção de compra, outros fatores demonstram uma correlação negativa. Desta forma, percebe-se a importância de otimizar vários aspectos da satisfação. Por último, os resultados indicam que uma abordagem geral não é adequada para a vertente da personalização. É expectável que a personalização melhore a intenção de compra e, portanto, a Amazon deve considerar as diferenças individuais entre os consumidores porque aplicar a personalização de forma uniforme para todos os clientes pode não ser eficaz e, em alguns casos, até ser contraproducente.

A análise de regressão múltipla permitiu identificar quais as variáveis que têm um impacto significativo na intenção de compra futura, oferecendo *insights* sobre onde

concentrar os esforços para melhorar as vendas futuras. Por exemplo, embora a personalização tenha vários efeitos, não é uma boa notícia se prejudicar as intenções de compra futuras. Mais uma vez, reforça-se a ideia que as estratégias de personalização podem não estar a ser bem aplicadas, sugerindo-se uma revisão das mesmas e, ainda, uma segmentação mais precisa. Estes resultados, juntamente com a análise das correlações, mostram que a confiança na Amazon é um dos principais fatores que determinam a intenção de compra futura. De forma semelhante à análise anterior, alguns fatores de satisfação com a compra têm um impacto significativo na intenção de compra futura. Sugere-se que a Amazon foque os esforços de melhoria nas áreas que mostram correlação positiva, porém, também procure problemas que possam afetar negativamente a experiência do consumidor. Por fim, é importante enfatizar a atitude de compra 1 que demonstrou influenciar a intenção de compra futura 3 e, neste sentido, sugere-se a criação de campanhas de marketing que melhorem essa atitude.

No geral, as análises realizadas no âmbito deste trabalho, podem ajudar a entender como é que a Amazon, e outras empresas de e-commerce, poderiam melhorar a satisfação do cliente, a confiança e as intenções de compras futuras. A implementação de algumas destas recomendações poderá melhorar a experiência de compra no e-commerce.

5 Considerações Finais

Este capítulo tem como objetivo apresentar as principais conclusões da pesquisa, resultantes das hipóteses analisadas em relação aos objetivos específicos, que estão alinhados ao objetivo geral do estudo. Assim, serão destacados os principais contributos deste estudo e, ainda, serão discutidas as principais limitações da pesquisa e sugestões para estudos futuros.

5.1 Principais Conclusões do Estudo

O objetivo principal desta investigação era analisar como a IA é aplicada para personalizar a experiência do consumidor no contexto do E-commerce, com foco na plataforma da Amazon. O estudo procurou compreender como essa personalização impacta a satisfação, a confiança, a atitude de compra e, conseqüentemente, a intenção de compra futura dos consumidores.

Neste sentido, a aplicação da IA no E-commerce mostrou-se eficaz na personalização da experiência do consumidor, o que, por sua vez, influencia positivamente a atitude de compra, a satisfação, a confiança e a intenção de compra dos consumidores. Desta forma, os resultados demonstram que a IA é uma ferramenta influente para melhorar a experiência do consumidor e aumentar o envolvimento e a fidelidade do cliente no mundo digital.

Foram validadas sete das nove hipóteses de investigação, demonstrando a interligação entre várias variáveis. A H1 demonstrou uma correlação positiva e significativa entre a prática da IA no ambiente de e-commerce com a personalização da experiência do consumidor, por outro lado, a H2 demonstrou que a personalização, por si só, não é um fator que tenha influência na atitude de compra dos consumidores.

A H3 indicou que a personalização é um fator importante para aumentar a satisfação dos consumidores no E-commerce e, além da personalização, a atitude de compra também contribui no aumento da satisfação, conforme verificada na H4. A H5 foi parcialmente suportada, sugerindo que a atitude de compra é em algumas variáveis um indicador para a confiança dos consumidores no E-commerce.

A H6 apoiou a hipótese de que consumidores mais satisfeitos tendem a confiar mais no ambiente de E-commerce e, neste sentido, estão mais propensos a realizar compras futuras, como se verifica na H7. A H8 demonstrou que a atitude de compra não influencia a intenção de compra futura. Por fim, a satisfação apresentou correlações positivas e significativas com a intenção de compra, isto é, os consumidores que se encontram satisfeitos têm uma forte probabilidade de realizar compras futuras na plataforma da Amazon.

Em suma, ao responder à questão de investigação: "De que modo a aplicação da Inteligência Artificial no E-commerce afeta a experiência de compra e a intenção de compra dos consumidores?", descobriu-se que o comportamento dos consumidores é significativamente afetado pela implementação da IA no e-commerce em várias etapas do processo de compra, aumentando a intenção de compra.

5.2 Contribuições do Estudo

As principais contribuições deste estudo estão intrinsecamente relacionadas com: a exploração da personalização da IA no e-commerce; a relação entre satisfação, confiança e intenção de compra; práticas de e-commerce; validação ou revisão de modelos teóricos e implicações para políticas de e-commerce e IA. Estas contribuições estão baseadas nas análises realizadas e no contexto geral do estudo.

Relativamente à primeira contribuição mencionada, esta investigação fornece uma análise aprofundada sobre como a aplicação da IA, especialmente na personalização da experiência de compra, afeta significativamente a satisfação, a atitude de compra e a intenção de compra dos consumidores. Desta forma, é útil ao nível da literatura existente porque aborda vários efeitos específicos da IA no contexto do e-commerce, sejam positivos ou negativos.

Uma das valências desta pesquisa é a relação que existe entre satisfação, confiança e intenção de compra, no sentido da percepção das complexas relações entre as mesmas. A título de exemplo, a confiança dos consumidores numa plataforma específica, como a Amazon, é um forte indicador de intenções de compra futuras. Para mais, o estudo mostra

que a satisfação dos clientes tem um impacto significativo e direto na confiança, que, por sua vez, afeta as intenções de compra.

Os resultados desta investigação oferecem *insights* práticos e valiosos para empresas de e-commerce, recomendando a implementação de tecnologias de IA para maximizar a intenção de compra e evitar possíveis efeitos negativos. Estas evidências podem ser usadas pelas organizações para modificar as suas estratégias de personalização para garantir que os clientes se sintam beneficiados e não manipulados.

A pesquisa contribui também para validar modelos teóricos relacionados ao comportamento do consumidor no ambiente digital. O estudo testa várias hipóteses e, em alguns casos, desafia ideias já conhecidas, abrindo novas perspectivas para investigações futuras.

Por último, a investigação pode ter um impacto significativo no desenvolvimento de políticas e diretrizes relacionadas ao uso eficaz da IA em plataformas de e-commerce, sobressaindo o quão necessário é o equilíbrio entre o humano e máquina para melhorar a experiência do consumidor.

5.3 Limitações do Estudo e Trabalhos Futuros

Uma das limitações deste estudo está relacionada ao método de recolha de dados, uma vez que foram obtidos por meio de um questionário *online*. Esse método pode ter introduzido um viés de resposta, dado que a amostra foi predominantemente composta por indivíduos familiarizados com tecnologia. Esse viés pode influenciar a representatividade dos resultados, restringindo a generalização das conclusões para um público mais amplo. Além disso, a utilização de métodos quantitativos correlacionais não permite estabelecer relações de causalidade. Embora as correlações entre variáveis indiquem associações significativas, elas não evidenciam uma relação de causa e efeito. Essa limitação aponta para a necessidade de complementar a abordagem quantitativa com uma análise qualitativa, a fim de capturar percepções subjetivas e motivações profundas dos consumidores, que não foram abrangidas nesta investigação.

Para abordar a questão da causalidade, estudos futuros poderiam usar métodos experimentais, como a condução de experiências controladas, nas quais variáveis como personalização e confiança são manipuladas para observar diretamente os seus efeitos sobre a intenção de compra dos consumidores. Quanto à ausência de análise qualitativa, recomenda-se a adoção de metodologias como entrevistas em profundidade ou grupos focais, complementando os dados quantitativos e permitindo uma compreensão mais abrangente dos fatores que influenciam a experiência e a intenção de compra no ambiente de e-commerce.

Outra limitação significativa deste estudo foi a não consideração de fatores externos que podem impactar a experiência e a intenção de compra, tais como mudanças económicas, tendências de mercado e reputação da marca. A ausência desses elementos pode ter comprometido a interpretação dos resultados e das variáveis analisadas. Pesquisas futuras devem explorar como é que os fatores externos influenciam a eficácia da personalização baseada em IA na experiência de compra dos consumidores. Por exemplo, seria relevante investigar como é que a reputação da marca e a confiança pré-existente dos consumidores afetam a eficácia das tecnologias de personalização baseadas em IA.

Além disso, o foco exclusivo na Amazon, como plataforma de e-commerce, limita a aplicabilidade dos resultados a outras plataformas que utilizam diferentes técnicas de personalização e IA. Assim, estudos comparativos envolvendo várias plataformas de e-commerce seriam benéficos para identificar quais são as práticas e tecnologias que têm maior impacto na experiência e na intenção de compra dos clientes.

Finalmente, destaca-se que a pesquisa não se concentrou num segmento específico de produtos, mas abordou a plataforma de e-commerce de forma geral. Estudos futuros poderiam analisar setores específicos, como moda, tecnologia e alimentação, para determinar se a eficácia da personalização baseada em IA varia de acordo com o tipo de produto ou categoria de mercado. Tal abordagem permitiria uma compreensão mais detalhada sobre as nuances da personalização e as suas implicações no comportamento do consumidor em diferentes contextos de mercado.

REFERÊNCIAS BIBLIOGRÁFICAS

- Adamopoulou, E., & Moussiades, L. (2020). Chatbots: History, technology, and applications. *Machine Learning with Applications*, 2, 100006. <https://doi.org/https://doi.org/10.1016/j.mlwa.2020.100006>
- Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, 17(6), 734–749. <https://doi.org/10.1109/TKDE.2005.99>
- Adomavicius, G., & Tuzhilin, A. (2006). Personalization Technologies: A Process-Oriented Perspective. *Wirtschaftsinformatik*, 48, 449–450. <https://doi.org/10.1007/s11576-006-0098-7>
- Aggarwal, C. C. (2016). An Introduction to Recommender Systems. In *Recommender Systems: The Textbook* (pp. 1–28). Springer International Publishing. https://doi.org/10.1007/978-3-319-29659-3_1
- Alves, G. (2023). *A INFLUÊNCIA DA INTELIGÊNCIA ARTIFICIAL NO PROCESSO DE DECISÃO DE COMPRA ONLINE DO CONSUMIDOR* Dissertação para a obtenção do grau de Mestre em Direção Comercial e Marketing.
- Añaña, E., Vieira, L., Petroll, M., Petersen-Wagner, R., & Costa, R. (2008). *As Comunidades Virtuais e a Segmentação de Mercado: uma Abordagem Exploratória, Utilizando Redes Neurais e Dados da Comunidade Virtual Orkut*.
- Andre, M. (2014). O QUE É UM ESTUDO DE CASO QUALITATIVO EM EDUCAÇÃO? *Revista Da FAEBA- Educação e Contemporaneidade*, 22. <https://doi.org/10.21879/faeaba2358-0194.v22.n40.753>
- Araujo, T. (2018). Living up to the chatbot hype: The influence of anthropomorphic design cues and communicative agency framing on conversational agent and company perceptions. *Computers in Human Behavior*, 85, 183–189. <https://doi.org/https://doi.org/10.1016/j.chb.2018.03.051>
- Armstrong, G., & Kotler, P. (2023). *Princípios de Marketing* (Bookman, Ed.; 18th ed.).
- Bai, B., Law, R., & Wen, I. (2008). The impact of website quality on customer satisfaction and purchase intentions: Evidence from Chinese online visitors. *International*

- Journal of Hospitality Management*, 27, 391–402.
<https://doi.org/10.1016/j.ijhm.2007.10.008>
- Ballantine, P. (2005). Effects of interactivity and product information on consumer satisfaction in an online retail setting. *International Journal of Retail & Distribution Management*, 33, 461–471. <https://doi.org/10.1108/09590550510600870>
- Bavaresco, R., Silveira, D., Reis, E., Barbosa, J., Righi, R., Costa, C., Antunes, R., Gomes, M., Gatti, C., Vanzin, M., Junior, S. C., Silva, E., & Moreira, C. (2020). Conversational agents in business: A systematic literature review and future research directions. *Computer Science Review*, 36, 100239. <https://doi.org/https://doi.org/10.1016/j.cosrev.2020.100239>
- Bhatnagar, A., Misra, S., & Rao, R. (2000). On Risk, Convenience, and Internet Shopping Behavior. *Commun. ACM*, 43, 98–105. <https://doi.org/10.1145/353360.353371>
- Blackell, D., Miniard, W., & Engel, F. (2005). *Comportamento do Consumidor* (9th ed.).
- Bobadilla, J., Ortega, F., Hernando, A., & Gutiérrez, A. (2013). Recommender systems survey. *Knowledge-Based Systems*, 46, 109–132. <https://doi.org/https://doi.org/10.1016/j.knosys.2013.03.012>
- Bohle, S. (2018). “Plutchik”: Artificial intelligence chatbot for searching NCBI databases. *Journal of the Medical Library Association*, 106(4), 501–503. <https://doi.org/10.5195/jmla.2018.500>
- Bohr, A., & Memarzadeh, K. (2020). Chapter 2 - The rise of artificial intelligence in healthcare applications. In A. Bohr & K. Memarzadeh (Eds.), *Artificial Intelligence in Healthcare* (pp. 25–60). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-12-818438-7.00002-2>
- Bosri, R., Rahman, M. S., Bhuiyan, M. Z. A., & Al Omar, A. (2021). Integrating Blockchain With Artificial Intelligence for Privacy-Preserving Recommender Systems. *IEEE Transactions on Network Science and Engineering*, 8(2), 1009–1018. <https://doi.org/10.1109/TNSE.2020.3031179>
- Brambilla, F., & Gusatti, C. (2017). A INFLUÊNCIA DA SINALIZAÇÃO DE WEBSITES NA QUALIDADE PERCEBIDA E INTENÇÃO DE COMPRA EM SERVIÇOS NA INTERNET. In *Revista Capital Científico-Eletrônica* (Vol. 15).

- Camlot, S. (2014). *A Intenção de Compra do Consumidor Online, do Rio de Janeiro, na Aquisição de Viagens Turísticas*. 1–96.
- Cannella, J. (2018). *Artificial Intelligence In Marketing*.
- Carvalho, S. A. de. (2023). O Advento da Inteligência Artificial e o Futuro do Ser Humano e da Tecnologia. *Revista FSA*, 20(11), 142–155. <https://doi.org/10.12819/2023.20.11.7>
- Chandra, K. V., Sudha Rani, K., Singh, P., Rambabu, C. V, Vidya Sagar, K., & Billa, P. (2023). Artificial Intelligence Techniques to Revolutionize the Marketing Strategies for Enormous Business Expansion. *2023 First International Conference on Advances in Electrical, Electronics and Computational Intelligence (ICAEECI)*, 1–5. <https://doi.org/10.1109/ICAEECI58247.2023.10370805>
- Chaudhry, R. S., & Chandhok, A. (2023). Evaluation of E-Commerce Sites using Novel Similarity Measure of Neutrosophic Hypersoft Sets. In *Neutrosophic Sets and Systems* (Vol. 61).
- Chung, M., Ko, E., Joung, H., & Kim, S. J. (2020). Chatbot e-service and customer satisfaction regarding luxury brands. *Journal of Business Research*, 117, 587–595. <https://doi.org/https://doi.org/10.1016/j.jbusres.2018.10.004>
- City, C., Anli Suresh, I., & Jannifer Rani, N. (2020). Consumer Perception towards Artificial Intelligence in E-Commerce With Reference to. In *Journal of IT and Economic Development* (Vol. 11, Issue 1).
- Creswell, J. (2007). *Projeto de Pesquisa*.
- Cucato, J., Bizarrias, F., Strehlau, V., & Oliveira, M. (2021). *NECESSIDADE DE TOQUE NA INTENÇÃO DE COMPRAS ONLINE*.
- Davenport, T., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, 48(1), 24–42. <https://doi.org/10.1007/s11747-019-00696-0>
- De Araújo, S. R. F., Da Rocha, T. S., & Pakes, P. R. (2023). Estudo sobre a influência do comportamento do consumidor na hora da escolha do produto no e-commerce: estudo de caso. *Revista de Gestão e Secretariado (Management and Administrative Professional Review)*, 14(4), 6465–6478. <https://doi.org/10.7769/gesec.v14i4.2060>

- DeGroot, M. H. (1974). Reaching a Consensus. *Journal of the American Statistical Association*, 69(345), 118–121. <https://doi.org/10.2307/2285509>
- Delone, W. H., & Mclean, E. R. (2004). Measuring e-Commerce Success: Applying the DeLone & McLean Information Systems Success Model. In *International Journal of Electronic Commerce / Fall* (Vol. 9, Issue 1).
- Duffy, G., & Dale, B. (2002). E-commerce processes: A study of criticality. *Industrial Management and Data Systems*, 102, 432–441. <https://doi.org/10.1108/02635570210445862>
- Elkahky, A., Song, Y., & He, X. (2015). A multi-view deep learning approach for cross domain user modeling in recommendation systems. *WWW 2015 - Proceedings of the 24th International Conference on World Wide Web*, 278–288. <https://doi.org/10.1145/2736277.2741667>
- Faustino, P. (2019). *Marketing Digital na Prática: Como criar uma estratégia de marketing digital para promover negócios ou produtos*.
- Fortin, M.-F. (1996). *O processo de investigacao_FORTIN*. 1–373.
- Freris, N. M., & Patrinos, P. (2016). Distributed computing over encrypted data. *2016 54th Annual Allerton Conference on Communication, Control, and Computing (Allerton)*, 1116–1122. <https://doi.org/10.1109/ALLERTON.2016.7852360>
- Gabriel, M. (2010). *MARKETING DIGITAL NA ERA CONCEITOS, PLATAFORMAS E ESTRATÉGIAS*. www.novatec.com.br
- Gantz, J. F., Murray, G., Schubmehl, D., Vesset, D., & Wardley, M. (2017). *A Trillion-Dollar Boost: The Economic Impact of AI on Customer Relationship Management*.
- Garbarino, E., & Lee, O. (2003). Dynamic Pricing in Internet Retail: Effects on Consumer Trust. *Psychology and Marketing*, 20, 495–513. <https://doi.org/10.1002/mar.10084>
- Giri, C., Jain, S., Zeng, X., & Bruniaux, P. (2019). A Detailed Review of Artificial Intelligence Applied in the Fashion and Apparel Industry. *IEEE Access*, 7, 95376–95396. <https://doi.org/10.1109/ACCESS.2019.2928979>
- Goldberg, D., Nichols, D., & Oki, B. M. (1992). *Using Collaborative Filtering to Weave an Information Tapestry*. 35.

- Gomes, M. A., Tercan, H., Bodnar, T., Meisen, P., & Meisen, T. (2021). A Filter is Better Than None: Improving Deep Learning-Based Product Recommendation Models by Using a User Preference Filter. *2021 IEEE 23rd Int Conf on High Performance Computing & Communications; 7th Int Conf on Data Science & Systems; 19th Int Conf on Smart City; 7th Int Conf on Dependability in Sensor, Cloud & Big Data Systems & Application (HPCC/DSS/SmartCity/DependSys)*, 1278–1285. <https://doi.org/10.1109/HPCC-DSS-SmartCity-DependSys53884.2021.00195>
- Groh, C. (2009). *A Confiança e a Satisfação como Mediadoras no Varejo Multicanal*.
- Gupta, B. B., Gaurav, A., & Arya, V. (2024). Secure and Privacy-Preserving Decentralized Federated Learning for Personalized Recommendations in Consumer Electronics Using Blockchain and Homomorphic Encryption. *IEEE Transactions on Consumer Electronics*, 70(1), 2546–2556. <https://doi.org/10.1109/TCE.2023.3329480>
- Gupta, S., & Joshi, S. (2022). Predictive Analytic Techniques for enhancing marketing performance and Personalized Customer Experience. *2022 International Interdisciplinary Humanitarian Conference for Sustainability (IIHC)*, 16–22. <https://doi.org/10.1109/IIHC55949.2022.10060286>
- Haenlein, M., & Kaplan, A. (2019). A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. *California Management Review*, 61, 000812561986492. <https://doi.org/10.1177/0008125619864925>
- Hassani, H., Silva, E. S., Unger, S., TajMazinani, M., & Mac Feely, S. (2020). Artificial Intelligence (AI) or Intelligence Augmentation (IA): What Is the Future? *AI*, 1(2), 143–155. <https://doi.org/10.3390/ai1020008>
- He, X., Du, X., Wang, X., Tian, F., Tang, J., & Chua, T.-S. (2018). *Outer Product-based Neural Collaborative Filtering*. <http://arxiv.org/abs/1808.03912>
- He, X., Liao, L., Zhang, H., Nie, L., Hu, X., & Chua, T. S. (2017). Neural collaborative filtering. *26th International World Wide Web Conference, WWW 2017*, 173–182. <https://doi.org/10.1145/3038912.3052569>
- Huang, G. (2022). E-Commerce Intelligent Recommendation System Based on Deep Learning. *2022 IEEE Asia-Pacific Conference on Image Processing, Electronics*

and Computers (IPEC), 1154–1157.
<https://doi.org/10.1109/IPEC54454.2022.9777500>

Jhaveri, M., Chirputkar, A., & Ashok, P. (2023). The Efficacy of Artificial Intelligence in making Best Marketing Decisions. *2023 International Conference on Innovative Data Communication Technologies and Application (ICIDCA)*, 225–229.
<https://doi.org/10.1109/ICIDCA56705.2023.10100132>

Jonathan, K., & Yehuda, L. (n.d.). *Introduction To Modern Cryptography*.

Joshi, S., Majumdar, A., & Malhotra, A. (2014). Enhancing Customer Experience Using Business Intelligence Tools with Specific Emphasis on the Indian DTH Industry. *Procedia Economics and Finance*, 11, 289–305. [https://doi.org/10.1016/S2212-5671\(14\)00197-X](https://doi.org/10.1016/S2212-5671(14)00197-X)

Jr, A., Amorim, B., Tabata, P., & Felicissimo, V. (2022). Os impactos da Inteligência Artificial nas estratégias de marketing. *Revista Fatec Zona Sul*, 9, 1–24.
https://doi.org/10.26853/Refas_ISSN-2359-182X_v09n01_02

Kamineni, R. (2005). The next stage of psychographic segmentation: Usage of enneagram. *Journal of American Academy of Business, Cambridge*, 6, 315–320.

Kanakamma, T., Kancherla, D., Jain, A., & Singh, N. (2023). Precision Marketing Strategy for E-Commerce by Using Artificial Intelligence Technology. *Journal of Informatics Education and Research*, 3. <https://doi.org/10.52783/jier.v3i2.310>

Kartajaya, H., Kotker, P., & Setiawan, I. (2021). *Marketing 5.0: Technology for Humanity*.

Koren, Y. (2013). *Factorization Meets the Neighborhood: a Multifaceted Collaborative Filtering Model*. ACM Digital Library.

Kotler, P., Kartajaya, H., & Setiawan, I. (2017). *Marketing 4.0 _ Moving from Traditional to Digital*.

Kotler, P., & Keller, K. (2012). *Administração de Marketing*.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90.
<https://doi.org/10.1145/3065386>

- Lee, B. C. Y. (2007). Consumer attitude toward virtual stores and its correlates. *Journal of Retailing and Consumer Services*, 14(3), 182–191. <https://doi.org/https://doi.org/10.1016/j.jretconser.2006.07.001>
- Lee, D., & Seung, H. (1999). Learning the Parts of Objects by Non-Negative Matrix Factorization. *Nature*, 401, 788–791. <https://doi.org/10.1038/44565>
- Lee, J., Sun, M., & Lebanon, G. (2012). *A Comparative Study of Collaborative Filtering Algorithms*. <http://arxiv.org/abs/1205.3193>
- Lee, S. (2021). A Study on User Empathy Composition Factors of Digital Media. In *Volatiles & Essent. Oils* (Vol. 8, Issue 4).
- Legg, S., & Hutter, M. (2007). A Collection of Definitions of Intelligence. *Advances in Artificial General Intelligence: Concepts, Architectures and Algorithms*, 157.
- Lin, K., Yang, S., & Na, S. G. (2022). Collaborative Filtering Algorithm-Based Destination Recommendation and Marketing Model for Tourism Scenic Spots. *Computational Intelligence and Neuroscience*, 2022. <https://doi.org/10.1155/2022/7115627>
- Linden, G., Smith, B., & York, J. (2003). Amazon.com recommendations: item-to-item collaborative filtering. *IEEE Internet Computing*, 7(1), 76–80. <https://doi.org/10.1109/MIC.2003.1167344>
- Liu, K., Kargupta, H., & Ryan, J. (2006). Random projection-based multiplicative data perturbation for privacy preserving distributed data mining. *IEEE Transactions on Knowledge and Data Engineering*, 18(1), 92–106. <https://doi.org/10.1109/TKDE.2006.14>
- Lopes, I., rabelo neto, A., Nascimento, J., & Campelo Filho, E. (2022). Os Antecedentes da Intenção de Compra em E-Commerce: Uma Análise da Qualidade Percebida, da Atitude de Compra e da Satisfação. *Revista Ciências Administrativas*, 28, e10735. <https://doi.org/10.5020/2318-0722.2022.28.e10735>
- Madeira, A., Neves, B., & Branco, D. (2020). O Uso da Inteligência Artificial Aplicada ao Marketing Digital: exploração das vulnerabilidades do usuário-consumidor. *Journal of Digital Media & Interaction*, 3(8), 95–111. <https://doi.org/10.34624/jdmi.v3i8.14434>

- Martins, D. (2022). *Qual o Impacto da Usabilidade e Capacidade de Resposta dos Chatbots na Experiência do Cliente em E-commerce?* 1–64.
- Matias, C. (2020). *A INFLUÊNCIA DA INTELIGÊNCIA ARTIFICIAL NO E-COMMERCE: O USO DOS CHATBOTS*. Lisbon School Of Economics & Management.
- Md, Z., Goh, J., & Ling, H. (2012). FACTORS INFLUENCING CONSUMERS' ATTITUDE TOWARDS E-COMMERCE PURCHASES THROUGH ONLINE SHOPPING. In *International Journal of Humanities and Social Science* (Vol. 2, Issue 4).
- Mehta, R., & Rana, K. (2017). A review on matrix factorization techniques in recommender systems. *2017 2nd International Conference on Communication Systems, Computing and IT Applications (CSCITA)*, 269–274. <https://doi.org/10.1109/CSCITA.2017.8066567>
- Miklosik, A., & Evans, N. (2020). Impact of Big Data and Machine Learning on Digital Transformation in Marketing: A Literature Review. *IEEE Access*, 8, 101284–101292. <https://doi.org/10.1109/ACCESS.2020.2998754>
- Moriset, B. (2018). *e-Business and e-Commerce*. <https://shs.hal.science/halshs-01764594>
- Mu, R., Zeng, X., & Han, L. (2018). A Survey of Recommender Systems Based on Deep Learning. *IEEE Access, PP*, 1. <https://doi.org/10.1109/ACCESS.2018.2880197>
- Nanehkaran, Y. A. (2013). An Introduction To Electronic Commerce. *INTERNATIONAL JOURNAL OF SCIENTIFIC & TECHNOLOGY RESEARCH*, 2. www.ijstr.org
- Oliveira, M. (2013). *Efeitos Da Recomendação Online No Comportamento Do Consumidor: Um Estudo Envolvendo Confiança, Satisfação, Recomendação e Intenção de Compra*.
- Oliver, R. (1989). *Processing of the Satisfaction Response in Consumption: A Suggested Framework and Research Propositions*.
- Ouyang, W., & Feng, H. (2022). Critical Thinking on the Turing Test as a Standard for Testing Artificial Intelligence. *2022 International Conference on Artificial Intelligence in Everything (AIE)*, 297–300. <https://doi.org/10.1109/AIE57029.2022.00064>

- Pahadi, T. C., Verma, A., & Ranjan, R. (2022). Artificial Intelligence and its Influence on E-Commerce. *Proceedings - International Conference on Applied Artificial Intelligence and Computing, ICAAIC 2022*, 1–6. <https://doi.org/10.1109/ICAAIC53929.2022.9792783>
- Pandey, D., & Agarwal, V. (2014). E-commerce Transactions: An Empirical Study. *International Journal of Advanced Research in Computer Science and Software Engineering*, 4.
- Pantano, E., & Pizzi, G. (2020). Forecasting artificial intelligence on online customer assistance: Evidence from chatbot patents analysis. *Journal of Retailing and Consumer Services*, 55, 102096. <https://doi.org/https://doi.org/10.1016/j.jretconser.2020.102096>
- Parnas, D. L. (2017). Inside risks: The real risks of artificial intelligence. In *Communications of the ACM* (Vol. 60, Issue 10, pp. 27–31). Association for Computing Machinery. <https://doi.org/10.1145/3132724>
- Parra, D., & Sahebi, S. (2013). Recommender Systems: Sources of Knowledge and Evaluation Metrics. In *Studies in Computational Intelligence* (Vol. 452, pp. 149–175). https://doi.org/10.1007/978-3-642-33326-2_7
- Paula, M., Viali, L., & Guimarães, G. (2016). A PESQUISA QUALITATIVA E O USO DE CAQDAS NA ANÁLISE TEXTUAL: LEVANTAMENTO DE UMA DÉCADA. In *INTERNET LATENT CORPUS JOURNAL* (Vol. 6). <http://revistas.ua.pt//index.php/ilcj/index--INTERNETLATENTCORPUSJOURNAL>
- Paulichi, J., & Cardin, V. (2020). DAS FORMAS DE INTELIGÊNCIA ARTIFICIAL E OS IMPACTOS NOS PADRÕES DE CONSUMO E A PROTEÇÃO DOS DIREITOS DA PERSONALIDADE. *Revista Meritum*, vol 15 ed 4. <https://doi.org/10.46560/meritum.v15i4.7954>
- Pequito, S., Kar, S., Sundaram, S., & Aguiar, A. P. (2014). Design of communication networks for distributed computation with privacy guarantees. *53rd IEEE Conference on Decision and Control*, 1370–1376. <https://doi.org/10.1109/CDC.2014.7039593>
- Pimentel, M. F. (2021). *O PODER DO MARKETING DIGITAL*.

- Ping, N. L., Hussin, A. R. bin C., & Ali, N. binti M. (2019). Constructs for Artificial Intelligence Customer Service in E-commerce. *2019 6th International Conference on Research and Innovation in Information Systems (ICRIIS)*, 1–6. <https://doi.org/10.1109/ICRIIS48246.2019.9073486>
- Raasch, M. (2022). *COMO O MÉTODO QUANTITATIVO FOI UTILIZADO EM ESTUDOS SOBRE A TEORIA DAS CAPACIDADES DINÂMICAS NO CENÁRIO NACIONAL ENTRE 2014-2019?*
- Ramesh, R., & Vijayalakshmi, S. (2022). Improvement to Recommendation system using Hybrid techniques. *2022 2nd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)*, 778–782. <https://doi.org/10.1109/ICACITE53722.2022.9823879>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779–788. <https://doi.org/10.1109/CVPR.2016.91>
- Rosa, R., Casagrande, Y., & Spinelli, F. (2017). *A Importância do Marketing Digital utilizando a influência do comportamento do consumidor*. 28–39. <https://doi.org/10.21714/2237-3713rta2017v6n1p28>
- Sarwar, B. M., Karypis, G., Konstan, J. A., & Riedl, J. T. (n.d.). *Application of Dimensionality Reduction in Recommender System-A Case Study*. www.cdnw.com
- Schiffman, L., & Kanuk, L. (2000). *COMPORTAMENTO DO CONSUMIDOR*.
- Serrà, J., & Karatzoglou, A. (2017). Getting deep recommenders fit: Bloom embeddings for sparse binary input/output networks. *RecSys 2017 - Proceedings of the 11th ACM Conference on Recommender Systems*, 279–287. <https://doi.org/10.1145/3109859.3109876>
- Shah, L., Gaudani, H., & Balani, P. (2016). Survey on Recommendation System. *International Journal of Computer Applications*, 137(7), 43–49. <https://doi.org/10.5120/ijca2016908821>
- Shaiju, M. (2023). *THE SUBSTANTIAL IMPACT OF ARTIFICIAL INTELLIGENCE OVER E-COMMERCE PROGRESS WITH REFERENCE TO AMAZON ONLINE SHOPPING*.

- Sharda, R., Delen, D., & Turban, E. (2019). *Business Intelligence e Análise de Dados*.
- Shrirame, V., Sabade, J., Soneta, H., & Vijayalakshmi, M. (2020). Consumer Behavior Analytics using Machine Learning Algorithms. *2020 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT)*, 1–6. <https://doi.org/10.1109/CONECCT50063.2020.9198562>
- Silva, E., Domingues, D., & Biazon, V. (2021). Comportamento do consumidor: fatores que influenciam o poder de compra. *Scientific Electronic Archives*, *14*(4), 52–59. <https://doi.org/10.36560/14420211252>
- Silva, J. (2020). *Mouse Tracking No Estudo do Comportamento Do Consumidor - Uma Experiência Em Website De E-Commerce*.
- Singh, N., & Chouhan, S. S. (2021). Role of Artificial Intelligence for Development of Intelligent Business Systems. *2021 IEEE International Symposium on Smart Electronic Systems (ISES)*, 373–377. <https://doi.org/10.1109/iSES52644.2021.00092>
- Singh, R. (2021). *A Study of Artificial Intelligence and E-commerce Ecosystem - A Customer's Perspective*.
- Soares, D. V., & Leal, P. (2020). *CONSUMIDOR E REDES SOCIAIS: A NOVA DIMENSÃO DO CONSUMISMO NO ESPAÇO VIRTUAL* (Vol. 14).
- Soares, M., & Sousa, C. (2018). COMÉRCIO ELETRÔNICO: MOTIVAÇÕES E HÁBITOS DE CONSUMO. *REUNIR Revista de Administração Contabilidade e Sustentabilidade*, *8*, 19–35. <https://doi.org/10.18696/reunir.v8i1.460>
- Solomon, M. R. (2002). *O Comportamento do Consumidor: Comprando, Possuindo e Sendo* (11th ed.).
- Soni, V. D. (2020). Challenges and Solution for Artificial Intelligence in Cybersecurity of the USA. *SSRN Electronic Journal*, *17*. <https://doi.org/10.2139/ssrn.3624487>
- Stone, P., Brooks, R., Brynjolfsson, E., Calo, R., Etzioni, O., & Kamar, E. (2016). *Artificial Intelligence and Life In 2030*. 1–52.

- Sumathi, A., Akila, M., Prado, R., Wozniak, M., & Divakarachari, P. (2021). Dynamic Bargain Game Theory in the Internet of Things for Data Trustworthiness. *Sensors*, *21*, 7611. <https://doi.org/10.3390/s21227611>
- Szymanski, D. M., & Henard, D. (2001). Customer Satisfaction: A Meta-Analysis of the Empirical Evidence. *Journal of the Academy of Marketing Science*, *29*, 16–35. <https://doi.org/10.1177/0092070301291002>
- Tran, A. (2019). *Artificial Intelligence In E-Commerce*. 1–38.
- Turing, A. M. (1950). Computing Machinery and Intelligence. In *Source: Mind, New Series* (Vol. 59, Issue 236). Oxford University Press on. <http://www.jstor.orgStableURL:http://www.jstor.org/stable/2251299> Accessed:25/08/200818:56
- Tussyadiah, I. (2020). A review of research into automation in tourism: Launching the Annals of Tourism Research Curated Collection on Artificial Intelligence and Robotics in Tourism. *Annals of Tourism Research*, *81*. <https://doi.org/10.1016/j.annals.2020.102883>
- Viana, P. T. P. (2017). A percepção de qualidade dos hóspedes de um resort localizado na Ilha de Santa Catarina a partir da reputação on-line no site TripAdvisor.com. *Navus - Revista de Gestão e Tecnologia*, 26–36. <https://doi.org/10.22279/navus.2017.v7n2.p26-36.450>
- Vinuesa, R., Azizpour, H., Leite, I., Balaam, M., Dignum, V., Domisch, S., Felländer, A., Langhans, S. D., Tegmark, M., & Fuso Nerini, F. (2020). The role of artificial intelligence in achieving the Sustainable Development Goals. *Nature Communications*, *11*(1), 233. <https://doi.org/10.1038/s41467-019-14108-y>
- Wang, L., Liu, W., Guo, F., Qiao, Z., & Wu, Z. (2024). Differentially private average consensus with improved accuracy-privacy trade-off. *Automatica*, *167*, 111769. <https://doi.org/https://doi.org/10.1016/j.automatica.2024.111769>
- Webb, M., Autor, D., Bloom, N., Bresnahan, T., Brynjolfsson, E., Chetty, R., Coyle, D., Gentzkow, M., Hoxby, C., Jaravel, X., Jones, C., Klenow, P., Pistaferri, L., Rafey, W., Sorkin, I., Reenen, J. Van, Agrawal, A., Connelly, T., Han, A., ... Thornton, G. (2020). *The Impact of Artificial Intelligence on the Labor Market*. <https://web.stanford.edu/>

- Wu, C. Y., Ahmed, A., Beutel, A., Smola, A. J., & Jing, H. (2017). Recurrent recommender networks. *WSDM 2017 - Proceedings of the 10th ACM International Conference on Web Search and Data Mining*, 495–503. <https://doi.org/10.1145/3018661.3018689>
- Wu, S., Ren, W., Yu, C., Chen, G., Zhang, D., & Zhu, J. (2016). Personal recommendation using deep recurrent neural networks in NetEase. *2016 IEEE 32nd International Conference on Data Engineering (ICDE)*, 1218–1229. <https://doi.org/10.1109/ICDE.2016.7498326>
- Yang, C., & Liu, Z. (2021). Application of Computer Vision In Electronic Commerce. *Journal of Physics: Conference Series, 1992*, 22134. <https://doi.org/10.1088/1742-6596/1992/2/022134>
- Yang, H., Zhou, H., & Li, Y. (2022). A Review of Academic Recommendation Systems Based on Intelligent Recommendation Algorithms. *2022 7th International Conference on Image, Vision and Computing (ICIVC)*, 958–962. <https://doi.org/10.1109/ICIVC55077.2022.9886104>
- Yang, L., & Qiuxiang, Z. (2022). Research on E-Commerce User Interest Recommendation Method Based on TF-IDF Algorithm. *2022 2nd Asia-Pacific Conference on Communications Technology and Computer Science (ACCTCS)*, 291–295. <https://doi.org/10.1109/ACCTCS53867.2022.00066>
- Yang, Z., Wu, B., Zheng, K., Wang, X., & Lei, L. (2016). A Survey of Collaborative Filtering Based Recommender Systems for Mobile Internet Applications. *IEEE Access*, 4, 1. <https://doi.org/10.1109/ACCESS.2016.2573314>
- Yin, S., & Luo, X. (2021). A Review of Learning-Based E-commerce. *2021 16th International Conference on Intelligent Systems and Knowledge Engineering (ISKE)*, 483–490. <https://doi.org/10.1109/ISKE54062.2021.9755410>
- Zakriya, B., Asma Saleem, B., Ghafar, A., Ibrahim, M., Yousuf, M., Ahmed, N., Fayaz Ahmad, S., Saleem, A., Saleem α , A., Ghafar σ , A., Ibrahim ρ , M., & Yousuf ω , M. (2015). Product Perceived Quality and Purchase Intention with Consumer Satisfaction. *Type: Double Blind Peer Reviewed International Research Journal Publisher: Global Journals Inc. (USA) Global Journal of Management and Business Research*, 15.

- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? In *International Journal of Educational Technology in Higher Education* (Vol. 16, Issue 1). Springer Netherlands. <https://doi.org/10.1186/s41239-019-0171-0>
- Zhang, D., & Huang, M. (2022). A Precision Marketing Strategy of e-Commerce Platform Based on Consumer Behavior Analysis in the Era of Big Data. *Mathematical Problems in Engineering*, 2022. <https://doi.org/10.1155/2022/8580561>
- Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). Deep learning based recommender system: A survey and new perspectives. In *ACM Computing Surveys* (Vol. 52, Issue 1). Association for Computing Machinery. <https://doi.org/10.1145/3285029>
- Zhang, Y., & Li, C. (2023). Personalized Recommendation Algorithm for Electronic Commerce Based on Artificial Intelligence Technology. *2023 International Conference on Integrated Intelligence and Communication Systems (ICIICS)*, 1–5. <https://doi.org/10.1109/ICIICS59993.2023.10420971>
- Zhang, Z. (2023). Exploration of Hybrid Recommendation Algorithms for Learning Nature Software. *2023 2nd International Conference on Data Analytics, Computing and Artificial Intelligence (ICDACAI)*, 530–534. <https://doi.org/10.1109/ICDACAI59742.2023.00106>
- Zhao, S., Huang, Z., Guo, H., Xiao, X., & Ye, R. (2023). Deep Learning-Based Retrieval Algorithms for Recommendation Systems. *2023 IEEE 3rd International Conference on Power, Electronics and Computer Applications (ICPECA)*, 1155–1160. <https://doi.org/10.1109/ICPECA56706.2023.10076102>
- Zhu, J. (2023). Data Analysis of E-Commerce Precision Marketing System Based on Artificial Intelligence Algorithm. *2023 International Conference on Distributed Computing and Electrical Circuits and Electronics (ICDCECE)*, 1–5. <https://doi.org/10.1109/ICDCECE57866.2023.10150655>
- Zoroja, J., Klopotan, I., & Stjepic, A.-M. (2020). Quality of e-Commerce Practices in European Enterprises: Cluster Analysis Approach. *Interdisciplinary Description of Complex Systems*, 18, 312–326. <https://doi.org/10.7906/indec.18.2.17>

Apêndice I – Questionário

O presente questionário insere-se no âmbito de uma dissertação de mestrado em Marketing Digital no Instituto Superior de Contabilidade e Administração do Porto. Este questionário consiste num instrumento de pesquisa imprescindível com vista ao teste de um modelo previamente alcançado. O propósito assenta em compreender melhor as suas experiências e preferências relacionadas à personalização das recomendações de produtos, à utilização de tecnologias como a inteligência artificial e ao seu comportamento como consumidor *online*.

Para que este estudo seja levado a cabo com sucesso a sua colaboração é absolutamente fundamental. O preenchimento é muito simples, sendo que a duração média do questionário está compreendida entre os 5 e os 10 minutos. Por favor, lembre-se que os dados recolhidos são mantidos no anonimato e apenas utilizados para o fim exposto.

Se necessitar de algum esclarecimento adicional, não hesite em contactar: Bruna Gonçalves | 2220421@iscap.ipp.pt

Agradeço imensamente a sua participação e contribuição.

Bruna Gonçalves

Antes de iniciar o questionário, concorda em participar neste estudo?

- Sim
- Não (Se não, o questionário será encerrado)

Secção 2: Experiência de Compra na Amazon

Nesta secção, o propósito é conhecer um pouco mais sobre a sua experiência de compra na Amazon.

2.1: Já realizou compras *online* no *website* da Amazon?

2.1.1. Sim (Prossegue para a secção 4)

2.1.2. Não (Se não, o questionário será redirecionado para a secção seguinte: “Razão para não comprar na Amazon”)

Secção 3: Razão Para Não Comprar na Amazon

Esta secção, procura entender as suas razões para nunca ter realizado compras *online* no *website* da Amazon.

3.1: Qual a razão pela qual nunca realizou compras *online* no *website* da Amazon?

3.1.1. Resposta aberta (após responder, o questionário será redirecionado para a secção 10)

Secção 4: Conhecimento sobre Inteligência Artificial e E-commerce

Esta secção, explora o seu conhecimento sobre inteligência artificial e como ela é aplicada no e-commerce, especialmente na Amazon.

Os autores Stone et al. (2022) afirmam que a inteligência artificial procura entender a inteligência em seres humanos e, dessa maneira, elaborar sistemas com a finalidade de auxiliar o desenvolvimento de computadores, máquina, robôs e softwares. Para uma compreensão mais clara, ver o pequeno vídeo elucidativo sobre o tema em baixo. [Vídeo explicativo sobre inteligência artificial]

4.1. Após visualizar o vídeo, reconhece no *website* da Amazon a utilização da inteligência artificial?

4.1.1. Sim

4.1.2. Não

Um exemplo de inteligência artificial é o Amazon Lex. Este é um serviço da Amazon Web Services que permite aos desenvolvedores construir de uma forma fácil chatbots e interfaces de conversação com reconhecimento de fala e compreensão de linguagem natural. Para uma compreensão mais clara, ver o pequeno vídeo elucidativo sobre o seu funcionamento. [Vídeo explicativo sobre o Amazon Lex]

4.2. Após visualizar o vídeo, considera que a inteligência artificial já o auxiliou nas compras *online*?

4.2.1. Sim

4.2.2. Não

Secção 5: Recomendação de Produtos na Amazon

Nesta secção, o objetivo assenta em entender a sua experiência com a personalização das recomendações na Amazon.

5.1. Com que frequência compra produtos recomendados pela Amazon?

5.1.1. Sempre

5.1.2. Quase Sempre

5.1.3. Raramente

5.1.4. Nunca (se nunca, questionário é redirecionado para a secção 10)

5.2. A personalização das recomendações da Amazon influencia positivamente a sua experiência de compra?

5.2.1. Sim

5.2.2. Não

5.2.3. Talvez

Secção 6: Satisfação do Consumidor na Amazon

Nesta seção, o intuito é perceber a sua satisfação como consumidor na plataforma da Amazon.

6.1: Indique o seu grau de satisfação com base nas suas experiências de compra na Amazon, numa escala entre 'Discordo Totalmente' e 'Concordo Totalmente'.

6.1.1. Comprar um produto após uma recomendação personalizada na Amazon foi uma boa decisão

6.1.2. Estou satisfeito por ter realizado uma compra na Amazon por via das recomendações personalizadas

6.1.3. Sinto-me feliz por ter escolhido a Amazon para fazer uma compra baseada em recomendações personalizadas

6.1.4. A minha decisão de comprar determinado item através das recomendações personalizadas foi sábia

6.1.5. Estou satisfeito com as recomendações personalizadas oferecidas pela Amazon

6.1.6. A Amazon tem os meus melhores interesses como prioridade nas recomendações personalizadas

6.1.7. A performance das recomendações personalizadas da Amazon correspondem às minhas expectativas

6.1.8. Gosto de utilizar as recomendações personalizadas da Amazon

Secção 7: Confiança do Consumidor na Amazon

Nesta secção, o intuito é perceber a sua confiança como consumidor na plataforma da Amazon.

7.2. Indique o seu grau de confiança com base nas suas experiências de compra na Amazon, numa escala entre 'Discordo Totalmente' e 'Concordo Totalmente'.

7.2.1. A Amazon é honesta e bem intencionada ao nível das recomendações personalizadas

7.2.2. A Amazon, além de pensar em si mesma, pensa nos clientes à medida que faz recomendações personalizadas

7.2.3. A Amazon é competente no que diz respeito às recomendações personalizadas

7.2.4. A Amazon é previsível quanto às recomendações personalizadas

7.2.5. A Amazon tem a competência necessária para realizar as recomendações personalizadas alinhadas aos clientes

7.2.6. A Amazon tem acesso às informações necessárias para realizar as recomendações personalizadas de forma apropriada

7.2.7. A Amazon mantém em mente os melhores interesses dos clientes durante as recomendações personalizadas

7.2.8. A Amazon é justa com as recomendações personalizadas que mostra aos clientes

Secção 8: Atitude de Compra do Consumidor na Amazon

Nesta seção, o intuito é perceber a sua atitude de compra como consumidor na plataforma da Amazon.

Indique o seu grau de atitude de compra com base nas suas experiências de compra na Amazon, numa escala de diferencial semântico onde 1 é definido como a atitude mais negativa e 5 como a atitude mais positiva.

8.1: Escala de Diferencial Semântico Nº1

8.1.1. A Amazon fornece um mau negócio ao nível das recomendações personalizadas – A Amazon fornece um bom negócio ao nível das recomendações personalizadas

8.2: Escala de Diferencial Semântico Nº2

8.2.1. A Amazon proporciona uma experiência desagradável ao nível das recomendações personalizadas – A Amazon proporciona uma experiência agradável ao nível das recomendações personalizada

8.3: Escala de Diferencial Semântico Nº3

8.3.1. Na Amazon é difícil de entender as recomendações personalizadas – Na Amazon é fácil de entender as recomendações personalizadas

8.4: Escala de Diferencial Semântico N°4

8.4.1. A Amazon é cansativa ao nível das recomendações personalizadas – A Amazon é estimulante ao nível das recomendações personalizadas

Secção 9: Futuras Intenções de Compra do Consumidor na Amazon

Nesta secção, o intuito é perceber a suas futuras intenções de compra como consumidor na plataforma da Amazon.

9.1: Indique o seu grau de futuras intenções de compra com base nas suas experiências de compra na Amazon, numa escala entre 'Discordo Totalmente' e 'Concordo Totalmente'.

9.1.1. Voltaria a realizar uma compra das recomendações personalizadas da Amazon

9.1.2. Pretendo consultar a Amazon para fazer uma compra quando quiser comprar um produto recomendado

9.1.3. Pretendo recomendar a Amazon para compras de recomendações personalizadas para amigos e familiares

Secção 10: Identificação do Inquirido

Esta secção tem o objetivo de entender melhor quem são os participantes deste estudo.

10.1 - Género:

10.1.1. Feminino

10.1.2. Masculino

10.1.3. Prefiro não dizer

10.2 - Faixa Etária:

10.2.1. Menos de 18 anos

10.2.2. 18-24 anos

10.2.3. 25-34 anos

10.2.4. 35-44 anos

10.2.5. 45-54 anos

10.2.6. 55 anos ou mais

10.3 - Habilitações Literárias:

10.3.1. Ensino Básico

10.3.2. Ensino Secundário

10.3.3. Licenciatura

10.3.4. Mestrado

10.3.5. Doutoramento

10.4 - Situação Profissional:

10.4.1. Estudante

10.4.2. Desempregado

10.4.3. Trabalhador por conta de outrem

10.4.4. Trabalhador por conta própria

10.4.5. Reformado

Secção 11: Fim!

Agradeço sinceramente o tempo e esforço dedicados para completar este questionário.

Apêndice II – Configuração do nome das variáveis no software JASP

Categorização	Afirmação/Questão
Reconhecimento_IA	Após visualizar o vídeo, reconhece no <i>website</i> da Amazon a utilização da inteligência artificial?
Personalização_Influência	A personalização das recomendações da Amazon influencia positivamente a sua experiência de compra?
Satisfação_Compra1	Comprar um produto após uma recomendação personalizada na Amazon foi uma boa decisão
Satisfação_Compra2	Estou satisfeito por ter realizado uma compra na Amazon por via das recomendações personalizadas
Satisfação_Compra3	Sinto-me feliz por ter escolhido a Amazon para fazer uma compra baseada em recomendações personalizadas
Satisfação_Compra4	A minha decisão de comprar determinado item através das recomendações personalizadas foi sábia
Satisfação_Compra5	Estou satisfeito com as recomendações personalizadas oferecidas pela Amazon
Satisfação_Compra6	A Amazon tem os meus melhores interesses como prioridade nas recomendações personalizadas
Satisfação_Compra7	A performance das recomendações personalizadas da Amazon correspondem às minhas expectativas
Satisfação_Compra8	Gosto de utilizar as recomendações personalizadas da Amazon

Confiança_Amazon1	A Amazon é honesta e bem intencionada ao nível das recomendações personalizadas
Confiança_Amazon2	A Amazon, além de pensar em si mesma, pensa nos clientes à medida que faz recomendações personalizadas
Confiança_Amazon3	A Amazon é competente no que diz respeito às recomendações personalizadas
Confiança_Amazon4	A Amazon é previsível quanto às recomendações personalizadas
Confiança_Amazon5	A Amazon tem a competência necessária para realizar as recomendações personalizadas alinhadas aos clientes
Confiança_Amazon6	A Amazon tem acesso às informações necessárias para realizar as recomendações personalizadas de forma apropriada
Confiança_Amazon7	A Amazon mantém em mente os melhores interesses dos clientes durante as recomendações personalizadas
Confiança_Amazon8	A Amazon é justa com as recomendações personalizadas que mostra aos clientes
Atitude_Compra1	A Amazon fornece um mau negócio ao nível das recomendações personalizadas vs. A Amazon fornece um bom negócio ao nível das recomendações personalizadas
Atitude_Compra2	A Amazon proporciona uma experiência desagradável ao nível das recomendações personalizadas vs. A Amazon proporciona uma experiência agradável ao nível das recomendações personalizadas
Atitude_Compra3	Na Amazon é difícil de entender as recomendações personalizadas vs. Na

	Amazon é fácil de entender as recomendações personalizadas
Atitude_Compra4	A Amazon é cansativa ao nível das recomendações personalizadas vs. A Amazon é estimulante ao nível das recomendações personalizadas
Intenção_Compra_Futuro1	Voltaria a realizar uma compra das recomendações personalizadas da Amazon
Intenção_Compra_Futuro2	Pretendo consultar a Amazon para fazer uma compra quando quiser comprar um produto recomendado
Intenção_Compra_Futuro3	Pretendo recomendar a Amazon para compras de recomendações personalizadas a amigos e familiares