

CICLO DE ESTUDOS
GESTÃO DE SERVIÇOS

NEGATIVE IMPACTS OF HUMAN-AI INTERACTION IN BRANDS


Ricardo Paulo Sousa Santos

M

2023



FACULDADE DE ECONOMIA



NEGATIVE IMPACTS OF HUMAN-AI INTERACTION IN BRANDS

Ricardo Paulo Sousa Santos

Dissertação

Mestrado em Gestão de Serviços

Orientado por

Amélia Maria Pinto da Cunha Brandão, PhD

José Vasconcelos, PhD

2022/2023

Agradecimentos

À Professora Doutora Amélia Brandão, gostaria de expressar a minha profunda gratidão pela sua orientação e apoio excecional ao longo de todo o processo de elaboração desta tese de mestrado.

Ao Professor Doutor Bruno Veloso pela sua valiosa contribuição com o conhecimento técnico para desenvolvimento do código aplicado na investigação.

Gostaria de expressar a minha sincera gratidão à Rita pelo seu apoio incondicional e paciência durante todo o período deste estudo. A sua dedicação e comprometimento são fonte constante de inspiração e motivação para mim, e sou profundamente grato por tê-la ao meu lado.

Além disso, gostaria de expressar o meu agradecimento aos meus colegas de trabalho, que me apoiaram e acumularam tarefas nos períodos mais intensos desta investigação.

Por fim, a todos que direta ou indiretamente contribuíram para a conclusão desta tese.

Obrigado.

Resumo

A Inteligência Artificial (IA) é um tema estratégico para o desenvolvimento económico global, devido ao seu potencial económico. No entanto, a falta de transparência nas aplicações de IA gera desconfiança devido à complexidade dos algoritmos. A indústria de serviços tem sido transformada pela IA a par do desenvolvimento e do desafio as interações homem-IA. Esta interação pode despertar sentimentos negativos nos consumidores, que estabelecem comunidades para expor o seu repúdio e ódio as marcas. A pesquisa nesta área é escassa, e esta investigação visa compreender os sentimentos negativos resultantes da interação homem-IA, utilizando análise de sentimentos em comunidades online (Reddit) e uma abordagem qualitativa, procura-se identificar os sentimentos negativos predominantes nessa interação. Pretende-se também contribuir para o entendimento dos efeitos emocionais dessa interação e preencher uma lacuna na literatura. Os insights obtidos podem auxiliar no desenvolvimento de estratégias mais eficazes de interação entre humanos e IA, com benefícios para as marcas e para sociedade.

Os resultados revelam a presença considerável de sentimentos negativos, como ódio, raiva e frustração, e sugerem uma nova dimensão nos sentimentos que ultrapassa o ódio as marcas: “kill”. Destaca-se por isso a importância de compreender as interações negativas entre consumidores, marcas e IA, e a necessidade de desenvolver estratégias para minimizar esses sentimentos. As contribuições no campo académico e corporativo, destacam-se pela importância de acompanhar os sentimentos e promover uma interação mais positiva entre marcas e consumidores.

Palavras-chave: Sentimentos negativos, Marcas, Inteligência Artificial, Interação homem/Inteligência Artificial, Gestão da Marca

Abstract

Artificial Intelligence (AI) is a strategic topic for global economic development due to its economic potential. However, the lack of transparency in AI applications generates mistrust due to the complexity of algorithms. The service industry has been transformed by AI alongside the development and challenge of human-AI interactions. This interaction can evoke negative sentiments in consumers, who establish communities to express their disdain and brand hatred. Research in this area is scarce, and this investigation aims to understand the negative sentiments resulting from human-AI interaction, using sentiment analysis in online communities. Using a qualitative approach and sentiment analysis techniques, the goal is to identify the predominant negative sentiments in this interaction. The objective is to contribute to understanding this interaction's emotional effects and fill a gap in the literature. The insights obtained can help develop more effective strategies for human-AI interaction, benefiting brands and society.

The findings reveal a significant presence of negative feelings, such as hate, anger, and frustration, and suggest a new dimension in emotions that goes beyond brand hatred: "kill." This highlights the importance of understanding negative interactions between consumers, brands, and AI, and the need to develop strategies to minimize these sentiments. The contributions in both academic and corporate fields emphasize the importance of monitoring emotions and promoting a more positive interaction between brands and consumers.

Keywords: Negative feelings, Brands, Artificial Intelligence, Human/Artificial Intelligence interaction, Brand Management

Índice

1.	Introdução	1
2.	Revisão da literatura	5
2.1.	Inteligência artificial	5
2.1.1.	Enquadramento concetual e histórico	5
2.1.2.	Tipos de Inteligência artificial.....	6
2.1.3.	Machine learning	7
2.1.4.	Inteligência artificial e o marketing.....	10
2.1.5.	Interação inteligência artificial-homem.	10
2.1.5.1.	Chat-bot e Personal assistance.....	13
2.1.5.2.	Avatares	14
2.2.	Negatividade na relação marca consumidor.....	15
2.2.1.	Tipos de emoções negativas	15
2.2.2.	As marcas na web3.0 e o metaverso	17
2.2.3.	Comunidades anti marca e EWOM.....	18
3.	Metodologia	21
3.1.	Objetivo e questão de Investigação	21
3.2.	Netnography	23
3.3.	Data set	25
3.4.	Tarefas de Pré-processamento	28
3.5.	Sentiment Analysis	29
3.6.	Apresentação dos dados e validade dos resultados obtidos	29
4.	Resultados e discussão	31
5.	Conclusão.....	38
5.1.	Implicações teóricas	38
5.2.	Implicações práticas:	40
5.3.	Limitações e pesquisas futuras.....	40
6.	Apêndice	42
6.1.	Código e verificações utilizadas ao longo da investigação.....	42
7.	Bibliografia.....	49

Índice de figuras

Figura 1:Tipos de inteligência artificial.	6
Figura 2: Mapa conceptual da investigação.	22
Figura 3: Sequência de passos para recolha e análise de dados.....	24
Figura 4: Visão geral da frequência de palavras e sentimentos negativos nos comentários.	35
Figura 5: Logging na App do reddit, web Scraping e text normalization	42
Figura 6: Text normalization, text representation e sentiment analysis	43
Figura 7: Analise de sentimentos, clusters e wordcloud	44
Figura 8: Frequências de palavras e representação gráfica.....	45

Índice de tabelas

Tabela 1: Tipos de inteligência artificial.....	7
Tabela 2: Ambientes de aprendizagem de ML.	9
Tabela 3: 10 Níveis de automação.	11
Tabela 4: Tipos de emoções negativas	17
Tabela 5: Principais características do reddit	26
Tabela 6: Palavras usadas na pesquisa comentários e publicações dentro das comunidades.	28
Tabela 7: Resultados da análise de sentimentos.....	32
Tabela 8: Wordcloud com sentimentos negativos e positivos.....	34
Tabela 10: Quadro resumo dos resultados obtidos	47

1. Introdução

As pesquisas realizadas no âmbito da interação Homem-IA têm dado ênfase à sua aplicabilidade e benefícios, gerando uma lacuna na literatura relativamente ao tipo de sentimentos negativos que esta interação desperta nos consumidores em relação à marca. Esta investigação procura perceber quais são os sentimentos negativos que podem resultar desta interação. (Alsheibani et al., 2019)

O sentimento de pertença a um grupo promove maior envolvimento e participação ativa dos indivíduos (Martínez-Torres, 2014), e por isso, estabelecer comunidades de marca pode desempenhar um papel importante na implementação destes novos tipos de interação com o consumidor, importantes para o processo de desenvolvimento de novas ideias, de forma a poder impulsionar a mudança e aumentar a lucratividade (Hofstetter et al., 2020).

O enorme potencial económico da Inteligência Artificial (IA) faz com que seja cada vez mais discutida como um tópico estratégico para o desenvolvimento das economias a nível mundial.

Associada ao desenvolvimento da inteligência artificial, existe uma tendência para se pensar que as aplicações não são transparentes. Um dos motivos para que tal aconteça relaciona-se com a falta de entendimento sobre a forma como os algoritmos se comportam, já que a complexidade destes sistemas cria desconfiança nos seus utilizadores, principalmente quando falamos em aplicações críticas em indústrias como a saúde ou o setor financeiro.

A indústria dos serviços tem experimentado uma rápida transformação devido às tecnologias inovadoras, alicerçadas na IA, que revolucionam a forma como vivemos e trazem consigo a promessa de conseguir extrair informação de uma grande quantidade de dados (Big data), que será útil às marcas e irá auxiliar a tomada de decisão. O “Big data” é um fenómeno crescente que permite que a IA seja uma opção cada vez mais viável para as empresas autonomizarem tarefas, como já é possível observar nos setores da saúde, negócios, design, (Lui & Lamb, 2018; McKinney et al., 2020; Nagar & Malone, 2011; Zhang & Lu, 2021), e nas smart Cities, onde a IA já apresenta benefícios ao oferecer serviços mais personalizados de educação e mobilidade. Para o consumidor as vantagens são múltiplas, como os serviços mais personalizados, atendimento ao cliente 24/7 através do auxílio dos robots Advisors,

assistentes virtuais e chat bots, entre outras. O consumidor pode ainda beneficiar dos sistemas IA, por exemplo em compras online, onde cada vez é mais fácil perder-se numa panóplia infindável de ofertas de bens e serviços sem o auxílio da IA.

A IA está presente na vida dos indivíduos através da Machine Learning (ML), do processamento de linguagem natural (NLP), dos Expert Systems, da visão computacional, da Robótica e do Planeamento. A seleção do tipo de inteligência artificial depende do propósito da utilização.

O desenvolvimento tecnológico tem transmitido capacidades humanas para a IA que colocam em causa pressupostos que os investigadores formularam sobre interação Homem-IA (Shen, 2022). Este progresso permite à IA desenvolver a capacidade, compreender, reagir e aprender, assumindo funções e características cada vez mais próximas dos humanos (McDuff & Czerwinski, 2018), enquanto rompe a fronteira entre os humanos e a tecnologia. Este estado contínuo de evolução torna a interação entre o homem e a IA um desafio constante, tanto na indústria como nas comunidades científicas.

A Europa, por exemplo, está a iniciar uma terceira onda de digitalização e, por esse motivo, criou em 2018 um conjunto de linhas orientadoras para o desenvolvimento da IA. Estas sugerem que os sistemas devem: estar em conformidade com as leis; respeitar os valores e princípios éticos da EU; ser robustos, tendo em conta os possíveis riscos associados ao seu desenvolvimento. Várias destas medidas têm como objetivo proteger e colocar os benefícios do cidadão no centro das preocupações. Trata-se de uma perspetiva centrada no homem, na qual os algoritmos de IA e ML devem ser desenvolvidos tendo em consideração o benefício para os utilizadores (Riedl, 2019).

Através da análise da literatura existente, é possível perceber que os indivíduos tendem a tratar os sistemas de IA como um humano durante as suas interações, sendo que alguns consumidores experimentam uma maior conexão com o sistema de IA do que com os indivíduos. Isto acontece porque as recomendações são baseadas em comportamentos anteriores, o que permite prever interesses e preferências no futuro, ou seja, a IA está configurada de modo a refletir sobre o consumidor e as suas necessidades (Huang & Philp, 2021). Tendo isto em consideração, a IA deve ser observada através de uma perspetiva de um sistema autónomo e inteligente, capaz de interagir com os humanos. Este rápido desenvolvimento e a interação entre os consumidores e a IA levanta questões para além dos seus benefícios.

A percepção de um consumidor em relação a uma experiência inclui emoções, crenças, preferências, percepções, comportamentos e conquistas que ocorrem durante ou depois de uma interação com um determinado produto ou serviço (Nicolescu & Tudorache, 2022). O desempenho ineficiente das tarefas e as experiências negativas são alguns dos diferentes tipos de falhas de serviço que afetam a percepção que o utilizador tem em relação aos sistemas de IA (Blöcher & Alt, 2021) e às marcas (Anaza et al., 2021).

Esta investigação visa alargar a nossa compreensão atual sobre os sentimentos resultantes da interação Homem-IA e o seu impacto nas marcas, através da alavancagem teórica e da análise de sentimentos em comunidades online. Como esta investigação pretende-se também colmatar um “Gap” existente na literatura relativamente ao entendimento, e concetualização da evolução e da interação entre seres humanos e (IA), bem como as consequências positivas e negativas decorrentes dessa forma de interação (Shen, 2022). Com os avanços tecnológicos torna-se imperativo compreender este relacionamento, assim os investigadores podem definir metodologias mais adequadas às suas investigações e os gestores podem aplicar estratégias mais adequadas às suas marcas. As preocupações supracitadas, motivam a procura pela contribuição com novos conhecimentos e novos temas de discussão sobre o futuro da interação entre seres humanos, a IA e as marcas, contribuindo assim, para o avanço da pesquisa atual e futura.

A pesquisa realizada em comunidades online, presentes no Reddit, permitirá também avaliar a existência de ódio às marcas e colmatar a carência de literatura em torno deste tema, nos mais variados campos das ciências sociais (Pantano, 2021; Patton et al., 2014; Yadav & Chakrabarti, 2022).

Para levar a cabo esta investigação, será aplicada uma perspetiva metodológica, netnografia, e um conjunto de ferramentas associadas a sentiment analysis (SA), que permitem extrair automaticamente opiniões dos consumidores (Shafie et al., 2018). A SA, perante uma coleção de dados, torna possível extrair informações, que podem ser usadas para perceber quais os sentimentos negativos que o consumidor experimenta, fruto desta relação Homem-IA. A metodologia usada divide-se em 3 fases: recolha de dados, (praw); Processamento de dados (Natural language toolkit NLTK), e análise de sentimentos (SIA/VADER). Desta forma, será possível perceber quais os sentimentos negativos mais predominantes.

A presente dissertação está estruturada em cinco capítulos. O primeiro capítulo consiste na introdução, seguido por um capítulo dedicado à revisão da literatura, dividido em dois blocos principais. O primeiro bloco aborda a temática da IA, englobando a discussão acerca dos diferentes tipos de inteligência artificial, machine learning (ML), implicações no âmbito do Marketing e a interação entre inteligência artificial e ser humano. O segundo bloco está relacionado com a negatividade em torno das marcas, incluindo a análise dos diversos tipos de emoções negativas, a web 3.0, o metaverso, as comunidades online e o passa a palavra eletrônico (EWOM).

No capítulo subsequente, apresenta-se a metodologia utilizada no estudo, expondo não somente o objetivo e a questão de pesquisa abordada, como também o modelo conceptual, componente técnica e o código desenvolvido para este estudo.

O quinto capítulo contempla a apresentação dos resultados e a sua discussão, confrontando-se os resultados obtidos com a literatura existente. Por fim, o sexto e último capítulo engloba as conclusões, os contributos para o campo da literatura e da gestão e as limitações e sugestões para futuras investigações.

2. Revisão da literatura

2.1. Inteligência artificial

2.1.1. Enquadramento concetual e histórico

A IA é uma das tecnologias mais disruptivas associadas ao pensamento humano, que permite as máquinas assumir funções cognitivas e efetuar tarefas intelectuais, tais como resolução de problemas, raciocínio e aprendizagem de forma autónoma (De Bruyn et al., 2020a). Faz parte da natureza humana a procura constante de novas formas de ser mais produtivo. Durante as três primeiras revoluções industriais, foi possível assistir a uma mudança radical nos empregos e na forma como as tarefas eram executadas. As tarefas de força física começaram a ser substituídas por máquinas, libertando os trabalhadores para tarefas cognitivas.

Os avanços tecnológicos, a digitalização e o “data analysis” procuram melhorar as capacidades cognitivas humanas, através da introdução da IA e de mecanismos de ML, culminando numa alteração profunda de algumas profissões e de alguns negócios que simplesmente deixaram de existir, especialmente os que podem ser executados por robôs, ou por novos modelos de negócios.

A IA pode ser encontrada em quase todos os aspetos do nosso dia a dia (D. Dwivedi et al., 2022). Como tecnologia, permite aos computadores perceber o mundo, avaliar cenários em tempo real através da recolha de dados, de fontes físicas ou virtuais, para posteriormente fornecer sugestões personalizadas e aprender por experiência (Kolbjørnsrud et al., 2017; Xu et al., 2020). A IA, através de algoritmos sofisticados e da sua capacidade de aprendizagem (machine learning), está rapidamente a transformar o mundo dos negócios e a gerar um grande interesse nos investigadores.

A sua capacidade de gerar emoções, torna a IA importante para a análise da interação das organizações com os consumidores (Kim et al., 2022). Esta capacidade de gerar emoções permitiu a sua rápida ascensão na indústria dos serviços e consequente extensão às mais variadas áreas de negócio, defesa, “design”, saúde (ao permitir diagnosticar doenças cancerígenas de forma mais eficiente do que um radiologista) e ao setor das finanças (usando-a para gerar alertas sobre investimentos, contas bancárias e transações financeiras) (Lui & Lamb, 2018; McKinney et al., 2020; Nagar & Malone, 2011).

2.1.2. Tipos de Inteligência artificial




Figura 1: Tipos de inteligência artificial.

Processamento linguagem natural

O processamento de linguagem natural (NLP) é um campo da inteligência artificial que se concentra em permitir analisar, compreender e gerir a linguagem humana. O NLP permite que os computadores interpretem a linguagem humana e executem tarefas e, por isso, é utilizado como tradução automática, resumo automático, resposta a perguntas através de chat, atendimento ao cliente, análise de texto e mecanismos de pesquisa, categorizar sentimentos ou opiniões em documentos ou vídeos para entender a atitude de determinada pessoa ou entidade em relação a um conjunto de tópicos, análise de notícias e redes sociais para entender a reputação de uma marca.

Expertsystem

Os expert systems são uma tecnologia de inteligência artificial baseada em regras definidas previamente, que permitem armazenar e gerir conhecimento e que são

usadas para aperfeiçoar as habilidades de tomada de decisão do utilizador humano. Ao contrário dos sistemas de ML que aprendem as regras de forma automática, estes sistemas utilizam as regras já definidas para gerar um output que replica o processo de tomada de decisão de um ser humano. São usados numa variedade de aplicações, desde diagnósticos médicos até aos conselhos financeiros.

**Visão
computacional**

A visão computacional permite que os sistemas entendam e extraiam informação útil de imagens, vídeos e de outras fontes visuais. A visão computacional usa algoritmos e técnicas para processar a informação recolhida e executar um conjunto de ações ou recomendações. Com esta tecnologia, é possível analisar, identificar e classificar objetos, reconhecer padrões e, até mesmo, calcular a profundidade e a distância entre os objetos.

Planeamento

O planeamento refere-se à capacidade de executar e desenvolver um conjunto de ações que requerem um planeamento bastante complexo. O planeamento com base na IA pode ser usado para ajudar a criar e manter planos de produção, gerir stocks, alocação de recursos, gerir as mudanças nos planos e avaliar os seus efeitos. O planeamento pode fornecer informações sobre o que é necessário para alcançar metas específicas, como por exemplo preços de venda, níveis de serviço, através de uma representação do ambiente envolvente e prevendo como as suas ações irão mudar, realizando escolhas e otimizando o seu desempenho. Esta tecnologia está presente em carros e robôs autónomos.

Robótica

Inclui o desenho, a conceção, construção, operação e aplicação de robôs. A robótica é usada numa grande variedade de aplicações, desde veículos autónomos, a robôs médicos e robôs domésticos, com o intuito de facilitar e dar suporte a tarefas normalmente executadas por humanos. Os robôs são dispositivos programáveis que executam tarefas automatizadas. Esses dispositivos usam sensores para receber informações do ambiente e realizar certas ações.

Tabela 1: Tipos de inteligência artificial

2.1.3. Machine learning

A IA pode ser encontrada em quase todos os aspetos do nosso dia a dia e é uma área que implica a utilização de algoritmos de ML e algoritmos de deep learning (DL). As tecnologias de IA mais inovadoras, relacionadas com o DL, permitem à academia e à indústria fazer

grandes progressos na melhoria da performance e automatização dos processos e técnicas industriais convencionais. Grande parte do potencial da IA é extraído através da ML.

Os ambientes de aprendizagem para a ML podem ser divididos em 3 grandes grupos:

	INTERAÇÃO COM UTILIZADOR	TIPO DE DADOS	ALGORITMOS	EXEMPLO DE APLICAÇÃO
Supervisionados	Requer a interação humana na categorização segundo a natureza dos dados.	Tirando partido do entendimento prévio do que já existia, são utilizados para treinar o modelo, selecionar os parâmetros e testar o desempenho.	Os algoritmos mais comuns são as redes neurais e árvores de decisão.	Avaliar a lealdade do consumidor.
Não Supervisionados	Não requer a interação humana na categorização segundo a natureza dos dados.	Constituída por algoritmos que não utilizam dados previamente categorizados.	Este tipo de algoritmo é capaz de analisar as relações entre os dados e propôr uma classificação. Tipicamente é utilizada quando existem grandes volumes de dados que precisam de ser classificados e o esforço de o fazer manualmente é bastante elevado.	Prever a insatisfação de um cliente.

Semi- supervisionado	Combina os dois tipos de aprendizagem.	Existem situações onde um grande volume de dados está disponível, mas poucos se encontram categorizados, sendo o custo de categorizar os resultados bastante elevado.	Aprendizagem semi-supervisionada pode ser particularmente útil para a criação de sinergias entre a abordagem supervisionada e não supervisionada.	É usado para prever o comportamento do consumidor.
Aprendizagem por reforço	Semelhante aos modelos supervisionados	Os dados não são treinados com base em informação categorizada.	O algoritmo aprende através de tentativa erro, sendo reforçado pelas decisões bem-sucedidas.	Recomendações em plataformas de e-commerce.
Deep learning	É um subconjunto bastante complexo de ML.	Constitui-se como uma rede neural com 3 ou mais camadas, onde são processadas grandes quantidades de dados.	Tentam simular o comportamento do cérebro humano. A sua complexidade faz com que sejam muito mais precisos do que os outros mecanismos de ML.	

Tabela 2: Ambientes de aprendizagem de ML.

Fonte: Ansari & Riasi, 2016; Bruyn et al., 2020; Ma & Sun, 2020; Sarkar & De Bruyn, 2021; Yau et al., 2021

O termo “meta-learning” (Salimitari et al., 2019) introduz aquele que será um novo paradigma de ML, o “Auto-machine learning”. Este permitirá aos sistemas aprender e substituir os próprios algoritmos através da análise dos dados recolhidos e combinando as previsões de outros algoritmos de M (Yang et al., 2022). É difícil definir categorias que sejam mutuamente exclusivas e exaustivas, existindo sempre alguma sobreposição entre os tipos de inteligência artificial. Estes são normalmente combinados, sendo os algoritmos muitas vezes modificados para permitir estender a sua aplicação.

2.1.4. Inteligência artificial e o marketing.

Uma das vantagens que a IA acrescenta ao marketing é a possibilidade de automatizar a análise de uma grande quantidade de dados e informações que acrescentam conhecimento ao Marketing mix (Verma et al., 2021). A sua implementação tem ganho adeptos entre as equipas de marketing. Na área do marketing digital, a IA pode ser bastante útil na divulgação dos produtos de uma forma mais eficiente, personalizando a oferta com base nos dados recolhidos dos utilizadores, permitindo assim, aumentar a satisfação e fidelização dos consumidores à marca (De Bruyn et al., 2020a). É possível analisar a implementação da IA através de uma perspetiva mais ampla onde as empresas antecipam a superação das capacidades cognitivas da IA em relação ao humanos e, ainda assim, apesar de todos os riscos associados a este nível de automação, como o caso do discurso de ódio promovido pela IA no Facebook ou o caso das afirmações controversas do chatbot do Twitter, pouco tempo depois de ter sido lançado (Neff & Nagy, 2016), as empresas procuram substituir os recursos humanos por IA (Narain et al., 2019). Isto acontece porque as vantagens suplantam os riscos, tornando os processos mais eficientes, reduzindo os custos de aquisição e despesas de marketing, traçando perfis de clientes, possibilitando a personalização de campanhas e, consequentemente, aumentar as margens (Huang & Rust, 2020; Roggeveen & Sethuraman, 2020; Stone et al., 2020).

Da mesma forma que os negócios e os trabalhos têm evoluído pela influência da introdução da IA e ML, todos os paradigmas da jornada de compra do cliente têm sido alterados. Uma jornada que começou por ser física e presencial, torna-se cada vez mais virtual e à distância. A partir do momento que um consumidor demonstra interesse em determinado produto, são despoletadas uma série de mecanismos que vão desde a criação automática de anúncios personalizados nas páginas web e cupões de email, à análise pós-compra da sua opinião, muitas vezes expressa através das redes sociais. (Bode & Vraga, 2018; Ma & Sun, 2020)

2.1.5. Interação inteligência artificial-homem.

A IA e o Marketing ligam os humanos e as máquinas de várias formas. A primeira, através da substituição completa dos humanos por IA, por exemplo, nas recomendações e publicidade em tempo real. A segunda é através da recolha e análise de dados usados posteriormente no auxílio de tomada de decisões, na contratação de colaboradores e na

melhoria da relação com o consumidor. A terceira depende também da recolha de dados, mas ao contrário da anterior, a decisão é tomada pelo sistema de IA e não pelo utilizador. A escolha de cada um dos modos de operação depende do tipo de negócio. (Yau et al., 2021).

A classificação em 10 níveis de automação (Sheridan et al., 1978), inicia-se no patamar onde todas as decisões são tomadas pelo utilizador, até ao último, onde todas as decisões são tomadas pelo computador.

NÍVEL	TIPO DE INTERAÇÃO
1	O computador não interfere em nada. Todas as decisões e ações são levadas a cabo pelo utilizador.
2	O computador ajuda a determinar as opções.
3	O computador ajuda a determinar as opções e sugere a que o utilizador deve optar.
4	O computador seleciona a opção e cabe ao utilizador aceitar ou não a opção.
5	O computador seleciona a opção e implementa-a se o utilizador a aceitar.
6	O computador seleciona a opção e implementa-a, informando o utilizador da sua opção, permitindo que este pare a execução.
7	O computador executa toda a tarefa e informa ao utilizador o que está a fazer.
8	O computador executa toda a tarefa e informa o utilizador apenas se for especificamente requerido.
9	O computador executa toda a tarefa, e decide também sobre o que o utilizador deve ser informado.
10	O computador decide e executa toda a tarefa de forma autónoma, ignorando o utilizador.

Tabela 3: 10 Níveis de automação.

Fonte: (Parasuraman et al., 2000)

À medida que a tecnologia de IA avança, as formas de interação humanos-IA continuam a evoluir. Isto torna-se particularmente importante, tendo em consideração a falta de confiança e reservas quanto ao uso da IA em determinadas circunstâncias (Alsheibani et al., 2019). Enquanto muitas pessoas acreditam que a automação é benéfica, a literatura em torno da IA identificou vários problemas e falhas (Munoko et al., 2020). O aumento da

complexidade dos sistemas é um destes problemas e trouxe o mito da “blackbox”. Este termo é geralmente utilizado para descrever a falta de transparência associada a algo. Esta tecnologia torna-se cada vez mais complexa e difícil de analisar, fazendo com que o utilizador não entenda quais os processos por detrás das tarefas executadas com recurso a IA. Isto provoca um aumento da desconfiança, complexidade percebida e resistência ao uso dos sistemas (D. Dwivedi et al., 2022; Johnson et al., 2008; Nanda & Banerjee, 2020; Skraaning & Jamieson, 2021). O “Technostress” é um termo sugerido por Craig Brood em 1894 (Gaudio et al., 2017) e é usado para descrever os sintomas físicos e psicológicos causados pelo uso excessivo de tecnologia (Tu et al., 2005), pela pressão da necessidade de acompanhar a tecnologia mais recente ou, ainda, pela sensação de estar sobrecarregado com a quantidade de tecnologia disponível (Tarafdar et al., 2007).

Existem 3 perspetivas que podem explicar a tensão existente entre a automação e os humanos. O paradoxo da automação, o “tradeoff, automação vs controlo” e a indulgência induzida pela automação. A primeira refere-se a um fenómeno que resulta da diminuição da interação e da importância que o utilizador tem na execução da tarefa, à medida que esta se vai tornando mais autónoma, tornando-o quase dispensável depois de automatizar o processo, apenas necessário verificar e controlar as operações ou assumir o controlo em caso de falhas (Bainbridge, 1983; De Bruyn et al., 2020b). Na perspetiva do “tradeoff, automação vs control”, à medida que o nível de automação aumenta, o nível de controlo e interferência por parte dos utilizadores é menor, até ao ponto em que o sistema autónomo pode ignorar completamente o utilizador, executando toda a tarefa sozinho (Jiang et al., 2022). Neste cenário os utilizadores veem a sua ação diminuída, o que pode ser indesejável, uma vez que desperta sentimentos de falta de controlo, confiança e relutância quanto ao uso destes sistemas (Berberian et al., 2012). A última perspetiva está relacionado com a falta de controlo e complacência gerada pela automação, onde o utilizador deposita confiança excessiva nos sistemas, ficando preso a um sentimento de autossatisfação, prestando pouca atenção ou vigilância às operações e resultados obtidos (Merritt et al., 2019), o que poderá conduzir à diminuição do conhecimento sobre os sistemas, culminando em respostas inesperadas ou inadequadas. Para evitar sentimentos de desconfiança, o especialista em IA deve conseguir explicá-la a utilizadores não especializados, principalmente nas indústrias baseadas em evidência. Por exemplo, na medicina, neste caso, o médico precisa de compreender como é que a inteligência artificial chegou a determinada recomendação para avaliar a sua aplicabilidade.

2.1.5.1. Chat-bot e Personal assistance.

Um chatbot é um sistema desenhado com base no uso da NLP (Brandtzaeg & Følstad, 2017) para simular conversas com utilizadores humanos, através da Internet. Os chatbots são frequentemente usados no atendimento e suporte ao cliente, pois permitem providenciar informações 24/7 e concluir tarefas, tendo em consideração palavras ou ideias chave. (Friedman et al., 2000; Xu et al., 2017)

Um dos motivos pelo qual muitos serviços estão a adotar esta ferramenta é a sua capacidade de responder a vários utilizadores ao mesmo tempo, mantendo o custo de utilização praticamente inalterado (Brandtzaeg & Følstad, 2017).

Os assistentes pessoais de inteligência virtual (AIPA- Artificial inteligente personal assitent) como a Siri, a Alexa, o Google Assistant e a Cortana, são cada vez mais comuns na relação direta com o consumidor, são programados para facilitar as tarefas dos utilizadores, minimizar o pensamento do consumidor, providenciando soluções personalizadas (Kim et al., 2022). Contudo, neste processo, podem acontecer vários aspetos negativos e causar insatisfação e stress (Ragu-Nathan et al., 2008). Tal como os Chatbots, os AIPA usam o NLP para entender os comandos e fornecer respostas úteis (Dale, 2016). Esta tecnologia está a mudar completamente, não só a forma de viver das pessoas (Zolfagharian & Yazdanparast, 2017), como a forma de interação com as marcas. Estes sistemas são usados em diversas áreas como a saúde, entretenimento, marketing, educação e cultura e ao mesmo tempo que são usados para auxiliar tarefas como definir lembretes, pesquisar na web, controlar dispositivos domésticos inteligentes, otimizar processos das empresas, automatizar tarefas e melhorar a experiência do cliente (Adamopoulou & Moussiades, 2020; Brill et al., 2019; Ramadan et al., 2021)

A proliferações desta tecnologia têm resultado em algumas falhas inesperadas nos serviços que rompem com as expetativas dos consumidores, impedindo-os de obter o nível de performance esperado do AIPA. No caso das empresas que recorrem a este tipo de serviços e o disponibilizam aos seus clientes, estas falhas causam danos na reputação da marca, redução das vendas e, em alguns casos, o consequente abandono do uso da marca (Huang & Philp, 2021). Uma das principais causas poderá ser a falta de maturidade do serviço. (Sun et al., 2021)

A utilização da ML permite aos AIPA adquirir traços humanos e imitar comportamentos. Estas características são importantes para as empresas, especialmente em serviços de apoio ao cliente, através de soluções obtidas automaticamente (Følstad & Brandtzaeg, 2020). A título de exemplo, cabe mencionar o desenvolvimento de uma tecnologia, por parte da a Startup koko, sucursal do MIT Media lab, que ajuda os assistentes de inteligência artificial a demonstrarem compaixão.

2.1.5.2. Avatares

Avatares são usados como forma de representação do utilizador num mundo virtual, que permite uma interação social mais autêntica. O “Brand Avatar” pode assumir uma representação personificada de uma marca num ambiente virtual e, por isso, a sua personalidade deve ser um reflexo da marca, já que este interage socialmente com os consumidores. Apesar de normalmente ser controlado por um representante humano, as organizações muitas vezes recorrem a chatbots e IA para gerir esta interação (Foster et al., 2022)

Os avatares interagem através de jogos on-line, simulações educacionais, assistência médica remota e estão presentes, principalmente, através da realidade virtual (RV) (Dewez et al., 2021). A interação humana com avatares através da RV cria um ambiente inovador e envolvente que leva a sensação de incorporação, (Kilteni et al., 2012) através da qual os utilizadores sentem que os avatares são o seu próprio corpo.

2.2. Negatividade na relação marca consumidor

O consumo não é apenas uma resposta a um fenómeno externo, é também influenciado pelas emoções e sentimentos (Hackley, 2003). As emoções agem como um catalisador para todos os humanos (Fonberg, 1986) e, tendo isto em consideração, ao longo dos anos, a análise de emoções tem sido amplamente utilizada para melhorar a relação entre os consumidores e as organizações.

A análise das emoções negativas (EN) experimentadas por um consumidor representam uma preocupação significativa para as marcas, uma vez que a interação dos consumidores com produtos e serviços permite à marca identificar tendências nos comportamentos e determinar o tipo de abordagem que deve escolher, de forma a diminuir o efeito da oposição, já que este tem uma força maior do que o efeito de apoio (Banister & Hogg, 2004). Por exemplo, as organizações têm recorrido à análise de sentimentos na web, para compreender a perceção dos consumidores sobre os seus produtos e serviços. Além disso, a análise de emoções também pode ser usada para criar campanhas de marketing mais eficazes, perceber a motivação e sustentar o comportamento e mudanças do consumidor.

As emoções em torno de uma marca podem ser positivas ou negativas. As primeiras resultam de uma avaliação positiva da situação (Iopez & Snyder, 2009) e incluem sentimentos de lealdade, confiança, proximidade e satisfação. As emoções negativas surgem quando a experiência com a marca ficou aquém das expectativas e os objetivos não foram atingidos, (Silva, 2019), suscitando emoções como raiva, desconfiança, insatisfação e frustração (Christodoulides et al., 2021; Fetscherin, 2019). As emoções têm diferentes intensidades partindo do “brand dislike” (sentimento de apatia em relação às marcas) até o “brand hate” (ódio às marcas). O brand Hate é a posição mais negativa que um consumidor pode ter em relação a uma marca (Bryson et al., 2013; Zarantonello et al., 2016)

2.2.1. Tipos de emoções negativas

EMOÇÃO	CONCEPTUALIZAÇÃO
Ódio (Hate)	O ódio às marcas é um misto de sentimentos de raiva, medo, aversão e repulsa (Sternberg, 2003). De acordo com (Khatoon & Rehman, 2021) o ódio às marcas é uma das emoções negativas mais estudadas, por três motivos principais: pela

capacidade que os “brand haters” têm em prejudicar as marcas; pelo fato de o brand hate ser o sentimento mais intenso que o consumidor pode sentir em relação a uma marca; e porque surge devido à má performance ou à insatisfação do cliente com um produto ou serviço (Hegner et al., 2017)

Medo (Fear)	Compreender o medo que o consumidor sente em relação a uma marca permite estabelecer uma estratégia de comunicação clara e eficaz, permitindo melhorar o relacionamento com o seu consumidor, de forma a reduzir o medo. Um consumidor na presença do medo tem tendência a rejeitar uma marca, (Dunn & Hoegg, 2014) pois o medo é uma resposta emocional à presença de um perigo ou ameaça. (Latour & Rotfeld, 1997)
Anciedade (Anxiety)	Os consumidores sentem ansiedade em relação às marcas, aos produtos, ao marketing, por exemplo, quando as marcas não se adequam à sua personalidade e ao que desejam transparecer para a sociedade. Isto acontece porque os indivíduos, por vezes, associam-se a uma marca como forma de demonstrar a sua personalidade à sociedade (Kull & Heath, 2016; Swaminathan et al., 2009).
Culpa (Guilt)	O sentimento de culpa surge normalmente quando os consumidores adquirem um produto ou consomem um serviço que vai contra os seus próprios valores. Isto leva, também, a que muitos consumidores se associem às marcas por questões éticas, de forma a aliviar os seus sentimentos de culpa (Newman & Trump, 2017). O sentimento de culpa pode culminar numa redução de autoestima do consumidor, causando desconforto. (Burnett & Lunsford, 1994)
Angústia (Distress)	É um termo usado para descrever os efeitos negativos das tomadas de decisão de uma marca, que pode colocar em causa a sua reputação e causar desconforto no consumidor. Isto pode acontecer devido a vários fatores como comportamentos pouco éticos, publicidade negativa, quebra de uma espécie de compromisso quando uma marca deixa de produzir determinado produto (Hung & Lu, 2018).
Deseção (Disappointment)	O consumidor experimenta este sentimento quando um produto ou serviço não vai de encontro às suas expectativas (Zeelenberg & Pieters, 2004), ou não cumpre com as suas promessas. Isto pode acontecer quando um produto tem fraca qualidade, quando o serviço de apoio ao cliente não procura encontrar a melhor solução para o cliente ou quando o preço está desajustado. É resultado

de um “gap” entre o que aconteceu e o que podia ter acontecido (Das & Kerr, 2010).

Arrependimento (Regret)	O sentimento de arrependimento surge após uma compra de um produto ou serviço que não vai de encontro às suas expectativas ou à promessa feita pela marca. Isto pode ocorrer, por exemplo, quando o produto tem um defeito, má qualidade ou o valor não está alinhado com a expectativa do consumidor. Este difere do anterior (distress/arrependimento) na medida em que o consumidor sente que efetuou a escolha errada na presença de outras alternativas (Zeelenberg, 1999).
Rejeição Rejection)	O sentimento de rejeição/recusa normalmente resulta de uma experiência negativa com a marca, ou das relações que os consumidores têm com outros consumidores. Este sentimento pode levar à perda de lealdade ou confiança por parte do cliente ou, até, o abandono da marca, podendo ser considerada uma rejeição permanente quando o consumidor não demonstra intenção de comprar novamente produtos ou serviços da marca (Fajer & Schouten, 1995).
Raiva (Anger)	Este sentimento surge quando as falhas nos serviços das empresas ocorrem por negligência das mesmas (Weiner, 2000). Este sentimento está também associado a outro conceito (brand complaining), em que os consumidores reclamam sobre a marca.
Aversão (Dislike)	Refere-se a um sentimento ou opinião negativa que um consumidor tem em relação a uma marca e que pode ter um impacto negativo significativo, ao fazer com que este opte por um produto de outra marca (Dalli et al., 2006). O brand dislike afeta também a reputação, pois os consumidores tendem a recomendar outras opções.

Tabela 4: Tipos de emoções negativas

Fonte: Casado-Díaz & Mas-Ruiz, 2002; Khatoon & Rehman, 2021

2.2.2. As marcas na web3.0 e o metaverso

Uma marca forte depende, não só da perceção que os consumidores têm relativamente aos seus atributos e qualidades, como também dos sentimentos que o consumidor nutre pela marca. As criptomoedas, nft's, avatares e experiências imersivas de vídeo jogos, estão a

tornar-se cada vez mais preponderantes na capacidade de influenciar os consumidores a desenvolver relações mais intimistas e fortes com as organizações e os seus produtos (Kshetri, 2022).

A web 2.0 foi responsável pelo “homo connectus”, que através das redes sociais, fez proliferar as comunidades de marca e as brand consumer relationship’s, onde os consumidores interagem, conversam e falam sobre as marcas, o que torna cada vez mais relevante o EWoW (Heding et al., 2020).

A web 3.0 está construída sobre três elementos-chave: análise semântica, inteligência artificial e interações sociais (Kwanya et al., 2013). Estes três elementos permitem analisar a sequência de dados fornecida pelos consumidores durante a sua interação com os web sites e traduzi-las em informações úteis para as marcas e para a gestão. A web 3.0 irá permitir uma aproximação da forma como os sistemas interpretam os dados à dos humanos (Rudman & Bruwer, 2016)

Com a web 3.0 e o metaverso, surge uma nova oportunidade de expor os consumidores a campanhas e publicidade que antes não existia e, quando consolidados, torna possível entregar campanhas e anúncios cada vez mais personalizados. A web 3.0 considera as necessidades individuais de cada indivíduo ao mesmo tempo que reúne informação (Erragcha & Romdhane, 2014). Para além das pessoas que interagem no metaverso, também os objetos do mundo real se ligam aos produtos do metaverso, tendo exatamente o mesmo significado, representando num ativo físico (Kapteyn et al., 2021). Este facto explica a razão pela qual existe uma tendência na indústria para criar um produto digital igual ao físico (Yang et al., 2022).

2.2.3. Comunidades anti marca e EWOM

As emoções negativas em torno da marca podem ser expressas individualmente ou em comunidades. Os consumidores que agem sozinhos demonstram o seu desagrado através de reclamações, abandono da marca e, em alguns casos, o cliente procura até formas de se vingar da marca. (Zarantonello et al., 2016; Zhang et al., 2020).

Os consumidores que expressam as suas emoções negativas em comunidades de marca, conseguem uma maior expressão através do “passa a palavra”, (WOM- word of mouth)

especialmente quando este acontece através das redes sociais e em fóruns online (Chu, 2011; Erkan & Evans, 2016)

Em 1983, a Harley-Davidson enfrentou uma situação de quase falência. A forma de dar a volta a esta situação foi através do seu compromisso em criar uma forte comunidade de marca, uma comunidade que se unia a um estilo de vida (Fournier & Lee, 2009). Através do apoio, envolvimento e WOM positivo, as comunidades podem fortalecer as marcas. Contudo, no sentido oposto, as comunidades anti marcas possuem um potencial bastante negativo, ampliado pela proliferação da digitalização (Kucuk, 2008).

As comunidades anti marcas juntam pessoas que nutrem sentimentos negativos em relação a uma marca para partilhar, criticar e expor as razões do seu desagrado e repugnância em torno das ações da marca. (Fournier & Avery, 2011; Holt, 2002). Nestas comunidades, a marca serve de pilar para a conceção, interação e sentimento de pertença ao grupo, assumindo uma dimensão social ao serem transmitidos entre indivíduos com sentimentos semelhantes, afetando a forma como estes se relacionam com as marcas (Johnson et al., 2012; Kaur et al., 2018; Romani et al., 2015).

A evolução da internet providencia um espaço excelente para que os consumidores e as comunidades falem sobre as marcas. Associado ao desenvolvimento está a proliferação das redes sociais, que fortaleceu a capacidade de alcance das críticas negativas em relação às marcas (Awasthi et al., 2012).

Os sentimentos negativos das comunidades anti marcas online estão geralmente ligados às questões culturais, tecnológicas, políticas e legais (Awasthi et al., 2012). São demonstradas em relação às falhas da qualidade dos produtos/serviços fornecidos e às condições de trabalho, (Krishnamurthy & Kucuk, 2009; Tomás, 2018). Estão também ligadas ao desejo de promover e fazer crescer a comunidade, à falta de compatibilidade emocional (Dessart et al., 2020), e a insatisfação com práticas comerciais, ideologias e sistema económico (Krishnamurthy & Kucuk, 2009).

O negative WOM, que resulta em atitudes negativas (Bambauer-Sachse & Mangold, 2011), envolve a partilha de experiências “reviews”, que procuram alertar para as falhas nos serviços e, por isso, não implicam que exista um ódio à marca para que sejam publicados comentários relativamente prejudiciais, como comprovam as pesquisas realizadas por (Frank et al., 2023; Powell et al., 2021; Saura et al., 2022). Nesta pesquisa, os investigadores tiveram em consideração não só o “brand Hate”, como o consumidor. Este pode ser motivado a

realizar comentários negativos por motivos sociais, principalmente quando pode ser usado para se auto promover enquanto “reviewer”, trazendo benefício para o próprio.

O EWOM preocupa as organizações, já que os comentários negativos costumam ter mais ênfase e efeitos negativos do que os comentários positivos, e influenciam o processo de tomada de decisão (East et al., 2008; Sparks & Browning, 2011).

3. Metodologia

A próxima secção aborda o tema de estudo, o objetivo principal da pesquisa e a questão de investigação. Além disso, é apresentado o modelo conceitual desenvolvido, que serve de estrutura teórica para a análise dos dados e a formulação das hipóteses.

A metodologia adotada neste estudo é de grande importância. Tendo em consideração a impossibilidade de obter dados já estruturados sobre este tema específico. Foi necessário recorrer a ferramentas “webmining and web scraping”, a métodos de validação de resultados, para que estes sejam significativos e confiáveis, e a procedimentos e técnicas de SA.

Nesta secção será também justificada a escolha do Reddit para obtenção de dados e apresentadas sugestões para investigações futuras. Ao desenhar uma metodologia sólida e consistente, espera-se obter resultados com validade e que possam contribuir, tanto para a academia, como para o âmbito empresarial. Por fim, são apresentados e discutidos os resultados, de forma a poderem ser retiradas conclusões.

3.1. Objetivo e questão de Investigação

Durante a revisão da literatura, demonstraram-se de várias formas como a IA, o marketing e os consumidores interagem, apesar de este não ser um fenómeno novo, como podemos observar através do estudo de Sheriand and Verplank em 1978, sobre 10 níveis de automação da IA. A constante evolução e avanços tecnológicos tem levado as marcas a adotarem cada vez mais este tipo de tecnologia que vai desde a utilização de chat-bot, aos personal assistance, avatares e a realidade aumentada. (Brandtzaeg & Følstad, 2017; Friedman et al., 2000)

Tal como evidenciado na revisão da literatura, as pesquisas existentes sobre a interação homem-IA, têm se debruçado sobre a investigação dos benefícios e da aplicabilidade dessa relação (Zhang & Lu, 2021), deixando uma lacuna considerável em relação aos sentimentos negativos que essa interação pode suscitar nos consumidores, em relação às marcas envolvidas.

Ainda que as pesquisas se tenham concentrado, principalmente, nos aspetos positivos e na interação, é igualmente importante compreender e explorar os sentimentos negativos

que podem surgir nesse contexto. Esses sentimentos podem variar desde a desconfiança e a frustração até à ansiedade e a aversão em relação à marca. (Banister & Hogg, 2004; Huang & Philp, 2021)

A pesquisa realizada neste trabalho, propõe preencher essa lacuna de conhecimento, realizando uma análise aprofundada dos sentimentos negativos que surgem na interação entre o homem e a IA, especificamente no contexto das relações com a marca. O objetivo é obter uma compreensão mais abrangente da dinâmica emocional envolvida nessa interação, a fim de possibilitar as empresas a adotarem uma postura mais sensível em relação às reações negativas dos consumidores e desenvolverem estratégias adequadas para lidar com as mesmas. Ao responder à questão: “Quais os tipos de sentimentos negativos que podem os consumidores experimentar em relação às marcas, tendo em consideração a sua interação com a Inteligência Artificial?”, irão ser acrescentadas informações valiosas que permitem uma melhor compreensão da aplicação da IA e os efeitos da interação homem-IA nas percepções e atitudes em relação às marcas. Essas descobertas podem ter implicações significativas no desenvolvimento de estratégias de marketing mais eficazes e centradas no consumidor, promovendo relações mais saudáveis e satisfatórias entre as marcas e os seus clientes.




Figura 2: Mapa conceitual da investigação.

3.2. Netnography

A introdução de novas tecnologias de realidade aumentada, realidade virtual e IA afetam as experiências dos consumidores e podem ter tanto impactos positivos (eficiência, satisfação e fidelização), como negativos (isolamento, frustração e outros tipos de doenças) nos consumidores e na sociedade. (Y. Dwivedi et al., 2022; Gaudio et al., 2017; Nanda & Banerjee, 2020; Skraaning & Jamieson, 2021)

Decidiu-se optar pela realização de um estudo exploratório utilizando a netnografia, tendo em conta as seguintes considerações: 1) o objetivo desta investigação, 2) a publicação de um Call for paper a solicitar a investigação da interação AI com os humanos (Shen, 2022), 3) o facto das interações tradicionais *face-to-face* estarem a ser substituídas por interações com assistentes virtuais, 4) os efeitos negativos da tecnologia na interface com o cliente que ainda são escassamente investigados e compreendidos.

Adaptada da etnografia, a netnografia é uma técnica qualitativa que permite obter uma compreensão profunda das atitudes e comportamentos dos consumidores em comunidades online (Kozinets, 2002). Considerando as transformações que o desenvolvimento da internet tem propulsionado na procura de novos métodos de pesquisa, que permitem determinar quem, o quê, o quando, o onde e como em diversos ambientes online e comunidades virtuais distintas (Gebera, 2008), adotar a netnografia permite-nos obter dados autênticos e não adulterados sobre os sentimentos adversos da implementação da IA diretamente a partir das opiniões dos consumidores. Em comparação com outras técnicas de pesquisa qualitativa, como entrevistas ou grupos focais, a netnografia é mais objetiva e envolve menos viés de memória (Kozinets, 2002; Divakaran, 2017). As pesquisas recentes sugerem também que a netnografia é eficaz para enriquecer o conhecimento teórico sobre os fatores influenciadores da resistência dos consumidores em contextos específicos (Huang et al., 2021).

Neste estudo, foram realizadas observações não participativas nas comunidades do Reddit e extraídos dados, uma vez que estas comunidades representam fontes de dados abertos com informação rica sobre vários tópicos discutidos em público. Os dados recolhidos remontam de período junho de 2022 a junho de 2023 e foram escolhidas comunidade que respeitam os requisitos sugeridos por (Kozinets & Gretzel, 2022): relevância, interatividade, conteúdo, participantes heterógenos, dados ricos, detalhados e alto tráfego de publicações e interações.

Cada vez mais os consumidores partilham as suas emoções online, através das redes sociais, gerando uma grande quantidade de dados, que podem ser usados para analisar os sentimentos expressos pelos consumidores em várias publicações. Sentimentos de raiva, tristeza, felicidade e excitação podem ser extraídos dos comentários e analisados para auxiliar a tomada de decisão.

O método aplicado segue numa sequência utilizada por (Ağrali & Aydın, 2021):




Figura 3: Sequência de passos para recolha e análise de dados

Fonte: Ağrali & Aydın, 2021

Os desafios relacionados com a extração de dados, exigem a utilização de técnicas mais avançadas para organizar, pesquisar, indexar e rever extensas coleções de dados, de forma eficiente em termos de tempo (Alghamdi & Alfalqi, 2015). O scrapping de dados no reddit, permite analisar sentimentos e opiniões dos utilizadores em relação às marcas.

Sentiment analysis (SA) é um método que permite extrair automaticamente opiniões de “reviews”, ao combinar o processamento de linguagem e algoritmos de ML, para atribuir sentimentos a frases ou expressões, e com isto fornecer uma ideia sobre a opinião, reputação, preocupações, experiência do cliente, a sua perceção e um índice geral de satisfação do público em geral (D. Dwivedi et al., 2022; Shafie et al., 2018).

A SA, perante uma coleção de “reviews”, permite obter informações que podem ser usadas para melhorar as estratégias de marketing (Giatsoglou et al., 2017). Existem vários métodos possíveis para realizar a análise de sentimentos, tais como o Bert, IBM Watson, Textlobm, VADDER. (Ağrali & Aydın, 2021). Estes modelos consistem num conjunto de

bibliotecas de léxicos que permite rotular os sentimentos como positivos ou negativos e classificá-los em classes binárias (positivas ou negativas). (Tanna et al., 2020).

3.3.Data set

A escolha do REDDIT para obter os dados desta investigação tem na sua base um conjunto de características que lhe são únicas e outras que são transversais às redes sociais.

O Reddit é uma rede social que oferece aos seus utilizadores a possibilidade de publicar conteúdo de forma pseudoanónima, o que permite discutir tópicos sensíveis sem receio de repercussões sociais (Moore & Chuang, 2017).

Os fóruns online como o reddit, devido à sua abertura, permitem aos utilizadores partilhar opiniões e emoções verdadeiras sobre questões controversas e dão a liberdade para que estes publiquem tópicos provocativos que, de outra forma, não se sentiriam confortáveis em discutir na vida real (Schouten et al., 2007; Wu et al., 2021). Além disso, o Reddit é um espaço onde regras formais e normas sociais implícitas são desenvolvidas dentro de diferentes subcomunidades (subreddits), nas quais os utilizadores criam subculturas adequadas às suas necessidades específicas.

Pretende-se, ainda que, os dados recolhidos para a análise de sentimentos tenham com base a experiência dos consumidores que utilizam a IA e a sua opinião em relação às marcas.

Os dados recolhidos do Reddit apresentam diversificação, autenticidade, representatividade dos consumidores, em geral, e os dados são facilmente acedidos e atuais. Para além destas características, é uma fonte de dados abertos, que contém informações ricas sobre o conjunto amplo de tópicos discutidos pelo público.

Diversidade de informações:	O Reddit permite ter acesso a discussões online entre utilizadores e consumidores sobre de vários tópicos, incluindo a inteligência artificial e as marcas. Permite ainda analisar diferentes perspetivas, e opiniões que conferem uma grande diversidade de informações e uma melhor compreensão do tópico em estudo.
-----------------------------	--

Acesso a opiniões e experiências autênticas:	O facto de ser um espaço onde os utilizadores tendem a partilhar as suas experiências autênticas, faz deste espaço um local onde não existe a influência de intermediários e influenciadores, às vezes presentes noutras plataformas. As plataformas aqui partilhadas são, por isso, aparentemente mais genuínas e espontâneas.
Amostra representativa:	No Reddit podemos encontrar uma grande diversidade nas características dos utilizadores e, assim, abranger várias regiões, culturas e setores de indústria. Esta diversidade permite tirar conclusões, tendo como ponto de partida um panorama geral dos consumidores.
Atualidade e relevância dos dados:	Apesar de ser um tópico muito estudado, nos últimos anos a inteligência artificial tem ganho preponderância e presença na vida dos consumidores e das marcas, através do seu rápido desenvolvimento. O Reddit é uma plataforma que reflete essa dinâmica, permitindo que as discussões acompanhem as tendências atuais e os desenvolvimentos mais recentes.
Acessibilidade e disponibilidade de dados:	O acesso à plataforma Reddit é livre, assim como a maioria do seu conteúdo, o que nos permite ter uma grande quantidade de informação, de forma relativamente fácil e sem a necessidade de subscrições e licenciamentos. Além disso, o Reddit oferece APIs (Application Programming Interfaces) e ferramentas que facilitam o scrapping de dados, permitindo extrair grande quantidade de dados de forma mais eficiente.

Tabela 5: Principais características do reddit

Para descobrir quais os sentimentos negativos que resultam da interação do homem com a inteligência artificial e relacioná-los com as marcas, foi necessário classificar os dados do dataset como positivos, negativos ou neutros, recorrendo a etapas de pré processamento e análise de sentimentos. Neste estudo, foram analisadas as publicações e respetivos comentários dos grupos de discussão (subreddits), metaverso, Anticonsumption, artificial inteligente e branding. O grupo de discussão “anticonsumption” é um grupo de discussão que se opõem ao consumismo excessivo e promovem estilos de vida mais simples, e conscientes, é um grupo onde os utilizadores se reúnem para discutir ideias, expor más experiências. O grupo “ArtificialIntelligence” têm por objetivo fornecer uma porta de entrada para as diversas facetas da comunidade de Inteligência Artificial e promover a discussão relacionada às ideias e conceitos que conhecemos como IA. Isso pode incluir questões filosóficas e sociais, arte e design, artigos técnicos, ML, onde encontrar recursos e ferramentas, como desenvolver projetos de IA/ML, IA nos negócios, como a IA está a afetar

as nossas vidas, o que o futuro reserva e muitos outros temas. Mais relacionado com as marcas o grupo de discussão “branding” dedica-se à análise de aplicações envolventes, estudos de caso, técnicas de gestão e crescimento da marca. Por fim, o grupo “metaverse” é um grupo onde são discutidos tópicos relacionados com o metaverso baseado em realidade virtual, realidade aumentada e inteligência artificial.

A escolha destes subreddits teve por base o fato de serem comunidades com grande número de utilizadores (Anticonsumption- 617 534; ArtificialIntelligence - 202 161; branding - 14 958; Metaverso -40 542) no total 875 195 utilizadores que se dedicam à discussão de temas relevantes para a investigação.

Os dados depois de recolhidos são armazenados num ficheiro CSV, e organizados de forma a serem aplicados processos de pré-processamento de texto antes de ser aplicada a análise de sentimentos.

Para realizar a análise de sentimentos, foi utilizado o *Valence Aware Dictionary and Sentiment Reasoner* (VADER) e o *sentiment intensity analyzer* (SIA), incorporados na biblioteca NLTK (*Natural Language Toolkit*), utilizada para processamento de linguagem natural em Python. O método SIA, baseado em regras, prevê não apenas a polaridade do texto, mas também a intensidade de cada opinião no texto. Neste método, a pontuação está compreendida no intervalo [-1.1], onde os sentimentos com pontuações inferiores a 0 são classificados como negativos e superiores a 0, positivos. O código utilizado neste estudo foi escrito em linguagem Python e compilado no googlecolab Notebook, seguindo os seguintes passos:

Para obter os dados foi usado o método de “*web scrapping*” que consiste numa técnica de extração de dados, recorrendo à análise de código HTML e à extração de dados de forma automatizada. Para isso, foi necessário criar uma conta “developer” e criar uma aplicação de autenticação na API, através da qual nos é atribuído um ID de cliente e um código secreto. Para a extração dos dados pretendidos foi utilizada uma biblioteca *Python* que fornece uma interação adequada a API do reddit chamada PRAW (*Python Reddit API Wrapper*).

Todos os métodos usados quer recolha de dados, quer na análise de sentimentos, são gratuitos.

Subreddit	Query	Data
Metaverse	['brand', 'branding', 'branded', 'brands']	

Anticonsumption	'Artificial intelligence', 'chat bot', 'virtual reality', 'augmented reality', 'brand', 'branding', 'branded', 'brands', AI]	A pesquisa percorreu as últimas 1000 publicações
ArtificialIntelligence	['brand', 'branding', 'branded', 'brands']	
Brandind	['AI', 'artificial intelligence', 'chat bot', 'virtual reality', 'augmented reality', 'brand']	

Tabela 6: Palavras usadas na pesquisa comentários e publicações dentro das comunidades.

3.4. Tarefas de Pré-processamento

Os dados recolhidos nas redes Reddit, na sua maioria, apresentam uma linguagem menos formal, e os utilizadores recorrem por exemplo a emojis, abreviações e urls para expressar as suas opiniões. Estes podem gerar algum ruído durante a análise de texto e devem, por isso, ser extensivamente “limpos” antes dos cálculos de polaridade, para obter resultados com mais sucesso. É uma etapa necessária para transformar a linguagem humana num formato legível pelo algoritmo e, por isso, tem um papel tão fundamental para uma análise mais consistente, de maior qualidade, mais confiável, aumentando a eficácia dos modelos de ML e a sua consequente interpretação.

Durante este processo foram executadas as seguintes etapas:

- Remoção de caracteres não alfanuméricos e numéricos;
- Remoção de Emojis;
- Remoção de Urls;
- Remoção de Stopwprds;
- Remoção de comentários e publicações repetidas;
- Remoção das colunas não necessárias, ficando apenas o título das publicações e os comentários.

Os mecanismos de Natural Language Processing (NLP) permitem, por exemplo, que os computadores analisem e interpretem os textos de linguagem humana. Assim, antes de iniciar a análise, é necessário realizar processos de normalização, que consistem num conjunto de técnicas usadas para transformar os dados de na forma de poderem ser comparados e processados. Os dados foram assim processados segundo as seguintes técnicas:

- Tokenização- A tokenização é uma das primeiras etapas a serem realizadas e o processo consiste em dividir um texto em unidades/parágrafos menores chamadas de "tokens", que permitem transações e análises mais eficazes.
- Stemming - O stemming é um processo linguístico aplicado para remover flexões verbais, isto é, refere-se à remoção de sufixos, como "ing", "ly", "s", etc., reduzindo as palavras à sua forma básica ou radical. Ao remover os prefixos e sufixos, as palavras são avaliadas de forma diferente.
- Stopwords – As frases recolhidas no dataset contém palavras que não expressam emoções e significados. Durante este processo, são eliminadas palavras como por exemplo “the”, “is”, “and”, “a” e outras preposições e artigos, que geralmente não possuem significado relevante na análise de texto. Foi usada a lista de Stopwords em inglês já que todos o data set está em inglês.

(Ağrali & Aydın, 2021)

3.5. Sentiment Analysis

A análise de sentimentos foi executada com recurso ao Sentiment Intensity Analyzer (SIA) e à biblioteca VADDER. Contudo, existem várias alternativas como o Bert, IBM Watson, Textblob, Vadder, Lexalytics, MonkeyLearn, Semantria, entre outros (Ağrali & Aydın, 2021). A escolha deste método foi baseada em 3 premissas principais. A primeira assenta na simplicidade e rapidez de implementação destes métodos, o que permite aos utilizadores realizarem a análise de sentimentos de uma forma rápida e intuitiva, sem conhecimentos avançados de programação e processamento de linguagem natural. São úteis quando há restrições de tempo ou recursos, para desenvolver e implementar soluções mais complexas. A segunda premissa é facto do SIA medir a intensidade do sentimento para além da classificação binária (positiva ou negativo), permitindo atribuir o grau de positividade ou negatividade. A terceira premissa assenta na gratuidade e na fácil integração no código python.

3.6. Apresentação dos dados e validade dos resultados obtidos

Para a apresentação dos dados acedeu-se à biblioteca WordCloud, que é usada em Python para criar nuvens de palavras que são apresentadas em diferentes cores e tamanhos de acordo com a sua relevância e a biblioteca Matplotlib, que fornece uma interface semelhante ao MATLAB para a criação de gráficos e visualizações em Python.

O método de Vetores de Suporte (SVM) é um conjunto de métodos de aprendizagem supervisionada amplamente utilizadas para realizar tarefas de classificação e prever valores numéricos com base em modelos de ML, com o objetivo de obter elevada precisão preditiva, sem comprometer o ajuste excessivo aos dados. A precisão indica a proporção de amostras corretamente classificadas pelo modelo em relação ao total de amostras de teste.

4. Resultados e discussão

Nos últimos anos, tem-se observado um aumento significativo da adoção de tecnologias de IA por parte de várias marcas, tecnologias essas muitas vezes interagem diretamente com o consumidor. No entanto, é importante reconhecer que existem desafios e limitações a serem superadas na implementação destes sistemas e de que forma podemos minimizar os sentimentos negativos. Os sentimentos negativos podem prejudicar as marcas, com o crescente desenvolvimento das comunidades online, como o Reddit, as informações disseminam-se mais rapidamente, tornando-se uma ameaça para o relacionamento entre as marcas e os consumidores.

As redes sociais desempenham um papel importante como fonte de dados que fornecem insights sobre as percepções dos consumidores. No entanto o recurso a uma única plataforma fornece apenas uma visão parcial e pode tornar a amostra menos rica em termos de diversidade de utilizadores. de uma única plataforma fornece apenas uma visão parcial das suas opiniões (Bode & Vraga, 2018).

A presente investigação diferencia-se de estudos anteriores ao explorar as comunidades online e ao tratar os dados exportados diretamente dos comentários dos consumidores, através de mecanismos de ML e NLP. A escolha do Reddit torna a investigação ainda mais inovadora, pois trata-se de um ambiente digital e a possibilidade de atuar sobre o pseudónimo, permite aos utilizadores expressarem-se de uma forma anónima, mais aberta e sincera do que em outros contextos, tornando os dados mais ricos em conteúdo (Wu et al., 2021) e propícios para o estudo de fenómenos sociais e comportamentais.

Após aplicar o código, criado especificamente para esta investigação, verificou-se que a relação entre sentimentos negativos, positivos e neutros é relativamente semelhante entre as comunidades. O que fortalece a consistência do modelo e das opiniões entre comunidades.

Os resultados obtidos mostram que predominam os sentimentos positivos em relação à interação entre a IA e o consumidor, contudo existe uma percentagem que varia entre os 23% e 35% de sentimentos negativos. Uma percentagem considerável que pode ter impactos nas estratégia das marcas, mas que contraria os resultados obtidos em outras investigações que relacionam a adoção de novas tecnologia, como o estudo de (Saura et al., 2022) onde os resultados revelaram que a cultura corporativa atual, é percebida de forma negativa em relação introdução de novas tecnologias, o mesmo acontece no artigo realizado por (Frank et al., 2023). Nesta investigação os resultados demonstram que os consumidores

respondem de forma mais negativa às propriedades negativas da tecnologia inovadora do que positivamente às propriedades positivas. As diferenças entre as investigações realizadas e a que é aqui apresentada pode porventura ser justificada pelo facto de estarmos perante uma comunidade online, onde os consumidores interagem tendo em consideração sobretudo os seus tópicos de interesse e conhecimento da área. (Frank et al., 2021; Munoko et al., 2020). O interesse e conhecimento dos utilizadores pode reduzir a desconfiança, o nível de complexidade percebida e a resistência ao uso dos sistemas (Skraaning & Jamieson, 2021) e assim minorar a percentagem de sentimentos negativos durante a interação dos consumidores com estes sistemas.




Tabela 7: Resultados da análise de sentimentos.

O desenvolvimento da capacidade da IA em avaliar e exprimir sentimentos tem dois objetivos: aperfeiçoar as interações entre o homem e a IA, analisar os sentimentos e emoções humanas. Por este motivo, tem sido desenvolvidas as técnicas de NLP, Redes neurais

recorrentes, chat bots e avatares para replicar as características humanas (McDuff & Czerwinski, 2018). A análise de sentimentos através de IA proporciona benefícios, devido à sua capacidade de reconhecer e responder a emoções, principalmente nas atividades de marketing, que executam funções que envolvem emoções, como satisfação do cliente, reclamações de clientes, estados de espírito dos clientes e emoções em publicidade, entre outros, e poder-se fazer uso da IA sensível. (Huang & Rust, 2021). Os resultados obtidos demonstram a importância de continuar a desenvolver estes sistemas, de forma a aprimorar a recolha dos sentimentos e a sua análise, com o objetivo de conseguir diminuir os sentimentos negativos.

Ao mesmo tempo que a inteligência artificial, através da automatização, evita erros humanos elevados, os níveis de automação levam a resultados adversos nas respostas efetivas do consumidor, quando acontecem incidentes críticos (Frank et al., 2021; Munoko et al., 2020). Este paradoxo, apresenta a perspectiva de que o aumento dos benefícios funcionais proporcionados pela tecnologia pode simultaneamente aumentar o risco e o receio dos consumidores em relação às experiências negativas (Johnson et al., 2008). Justificando algumas dos sentimentos encontrados nesta investigação “Threat, Fear, Frustration, Anxiety, Worried”.

Depois da análise de sentimentos, organizaram-se os dados numa nuvem de palavras, onde é possível observar as palavras mais utilizadas para expressar cada um dos sentimentos, negativos ou positivos.

[illegible]

	Frequência de palavras				
SubReddit->	Anticonsumption	Metaverse	Artificial intelligence	Branding	Total
hate	8		2	3	13
Disgust	6				6
kill	3		6	3	12
bad	3		2	4	9
wrong	3	3			6
Anger	2	1	2		5
danger	2	1			3
Overpriced	1				1
Misleading	1				1
Frustration	1				1
Fraud	1				1
Guilt	1				1
Regret	1				1
Shame	1				1
Scam	1	2			3
struggling	1				1
Outdated	1				1
Anxiety	1				1
threat		1	5		6
Pathetic		1			1
mistake		1		2	3
warned				4	4
Fear			2		2
Worried			1		1
struggling				4	4
Failure				1	1




Figura 4: Visão geral da frequência de palavras e sentimentos negativos nos comentários.

Esta ação implica uma hostilidade intensa e pode ter implicações significativas para as marcas, uma vez que envolve a rejeição e a vontade de eliminar completamente a presença e influência da marca na vida dos consumidores. Esse resultado indica que as marcas precisam de estar cientes da possibilidade de despertar um sentimento tão extremo nos consumidores e tomar medidas para evitar ou reverter essa hostilidade.

O ódio pela marca é um sentimento muito presente na insatisfação dos consumidores. A mudança do comportamento do consumidor é evidente em todas as áreas. Tal hostilidade reforça estas alterações no comportamento do consumidor e a crescente importância das investigações em redor do ódio pelas marcas, que estão cada vez mais suscetíveis à insatisfação, especialmente quando não conseguem atender às expectativas da comunidade ou não levam em consideração o que os consumidores e a sociedade valorizam. (Silva, 2019).

A percentagem e frequência de sentimentos negativos obtidos comprovam também a necessidade de compreender as interações negativas entre marcas, consumidores e a inteligência artificial. Tal como ficou provado através da recolha de dados no Reddit, as marcas que tomam decisões incompreensíveis aos olhos dos consumidores tendem a experimentar ódio, e consequentemente, os consumidores tornam-se mais propensos a descrever uma experiência ou avaliação negativa (Christodoulides et al., 2021; Fetscherin, 2019).

O EWOM ocorre quando os consumidores partilham as suas experiências relacionadas com marcas em plataformas de online (Chu, 2011). A literatura tem amplamente reconhecido o papel significativo do EWOM na influência do comportamento do consumidor, nas suas avaliações, intenções de compra e alterando significativamente o seu relacionamento com as marcas (Erkan & Evans, 2016; Romani et al., 2015; Zhang et al., 2020).

As emoções negativas do “brand hate”, é mediado por uma terceira variável “brand avoidance” (Jain & Sharma, 2019). Os consumidores que experimentam emoções negativas em relação a uma marca repetidamente tendem a demonstrar uma propensão para se dissociarem da marca e a manifestar o ódio da marca através de comentários negativos, tal como comprovada através desta investigação.

Apesar da diferença para os estudos anteriores, os resultados aqui demonstrados vem confirmar que, tanto no âmbito corporativo, como no âmbito académico, é importante

acompanhar os sentimentos dos consumidores e a sua relação com as marcas e instituições, Yadav e Chakrabarti (2022) uma vez que este tipo de análise torna possível obter detalhes sobre o que o utilizador pensa em relação às marcas e de que forma esta se pode envolver mais com o consumidor.

O ódio às marcas é composto por diversas emoções como raiva, desprezo, repugnância, tristeza e medo (Fetscherin, 2019). Tais evidências foram comprovadas neste investigação ao surgirem emoções como “Disgust, Anger, Frustration, Guilt, Regret, Shame, Hatred, Scam, Anxiety, Warned, Fear, Worried”. Ao percorrer não só uma lista de sentimentos negativos, como uma lista de palavras negativas, foi possível verificar a natureza comportamental que poderá estar implícita nesta investigação, através de palavras como “kill, warned”, sendo que estas representam mais do que um sentimento, representam um comportamento e uma ação prejudicial à marca.

Por fim, resta apresentar os dados obtidos através do método SVM. Este método é reconhecido no campo do ML, pela sua capacidade de classificação de dados complexos. Com base nos resultados obtidos, verificou-se que o SVM alcançou uma acurácia de 92.8% na comunidade Branding, 92.1% na comunidade metaverso, 92,5% na comunidade artificial intelligence, na comunidade Anticonsumption 84.7%. Estes valores permitem determinar a capacidade do modelo em acertar a classificação dos sentimentos presentes nos textos com alta precisão e confiabilidade.

5. Conclusão

No presente estudo, utilizamos uma metodologia de três fases para extrair informações relacionadas com a interação homem e a IA e quais os sentimentos que esta faz resultar nas marcas. Com base nos resultados obtidos, identificamos a presença de sentimentos negativos como Hate, Anger, Fear, Worri, Threat, Warned, Danger, Regret, e algumas palavras também preponderantes, para entendermos a percentagem de sentimentos negativos, como bad, mistake wrong, kill. No geral, podemos observar que a maioria dos sentimentos são positivos, mas cerca de 30% dos sentimentos encontrados são negativos. Ao analisarmos o tipo de sentimentos e palavras negativas associadas aos comentários e publicações percebe-se que a maioria dos sentimentos está relacionado com a desconfiança e incerteza provocadas pela dificuldade em acompanhar a rápida evolução da IA e pela impossibilidade da sua própria evolução no futuro. (Friedman et al., 2000)

5.1. Implicações teóricas

O presente estudo amplia o conhecimento nas áreas da inteligência artificial e da gestão das marcas, desenvolvendo e testando um quadro abrangente de relacionamentos e sentimentos em relação às marcas. Permitiu ainda, simultaneamente, preencher algumas das lacunas na investigação (Pantano, 20(Shen, 2022)21). Em ambos os tópicos ao analisar conjuntamente a interação entre a IA/consumidores e os sentimentos negativos gerados em torno da marca.

Os resultados demonstram a relevância de continuar a desenvolver investigações neste campo para contrariarem algumas pesquisas realizadas em contextos diferentes do aplicado. Trata-se por isso, de uma contribuição importante, uma vez que se distancia de investigações anteriores ao dar ênfase à análise de sentimentos negativos em relação à marca e ao introduzir o relacionamento entre o consumidor e a IA recorrendo a comunidades online. Permite também uma melhor compreensão do papel das experiências negativas com a marca no desenvolvimento de uma reação emocional negativa por parte dos consumidores.

O principal contributo do nosso estudo diz respeito ao tipo de sentimentos negativos que os consumidores experimentam em relação às marcas ao interagirem com a inteligência

artificial. Na nossa investigação para além do ódio a marca sugere um novo elemento antropomórfico “kill”. Isto torna-se ainda mais relevante quando confrontamos esta informação com a restante literatura que tem apontado o ódio às marcas como um sentimento mais intenso que o consumidor pode sentir em relação a uma marca (Hegner et al., 2017) (Khatoon & Rehman, 2021). Isto abre caminho para a necessidade de aprofundar este sentimento na relação com as marcas, “assassinar” uma marca é ainda mais extremo que odiar a marca, isto é, ultrapassa o sentimento individual para uma necessidade coletiva.

A realização de um estudo experimental sobre o tema fornece a oportunidade de testar sentimentos e relações, que ajudam a validar hipóteses e a fundamentar as conclusões retiradas neste âmbito. Além disso, este estudo estende toda a linha de pesquisa ao contexto das comunidades online, investigando o papel EWOM.

O WOM negativo surge como resultado de experiências negativas (Bambauer-Sachse & Mangold, 2011), prolifera-se através das redes sociais e exerce uma influência significativa nas avaliações, intenções de compra e no relacionamento do consumidor com as marcas, provocando alterações significativas nas perceções e atitudes dos consumidores, (Erkan & Evans, 2016; Romani et al., 2015; Zhang et al., 2020) principalmente na presença de sentimentos tão extremos.

Os dados desta investigação abrem também novos horizontes de pesquisa, ao adicionar sentimento/comportamento mais extremo que o ódio das marcas, “kill”. Este sentimento, pouco explorado na literatura, pode estar relacionado com o tipo de utilizadores da plataforma, o anonimato ou ainda com uma crescente escalada de violência nas redes sociais. (Patton et al., 2014). Os efeitos negativos desta relação e a introdução de um sentimento ainda mais extremo que o ódio são uma evidência da contribuição desta investigação.

O nosso estudo acrescenta uma forte contribuição concetual para a literatura da inteligência artificial e para a gestão das marcas, confirmando a presença de sentimentos negativos fortes como resultado da interação entre os consumidores da marca e a inteligência artificial (Saura et al., 2022)

5.2. Implicações práticas:

Em relação às implicações práticas, as marcas e respectivos responsáveis podem usar os resultados do presente estudo para estabelecer novas estratégias e abordagens na adoção de tecnologia de IA, nomeadamente níveis e formas de implementação, e em última estância avaliar se existe ou não interesse na própria implementação destes sistemas.

Caso as marcas optem pela introdução de sistemas de IA, tendo em consideração as descobertas, sugere-se que esta seja realizada de forma faseada e recorrendo a análise de sentimentos através de plataformas que permitem avaliar ao segundo a reação dos consumidores nas diferentes redes sociais e comunidades online. Assim poderão avaliar as suas estratégias evitando a proliferação e escalada de sentimentos negativos. Durante cada fase de implementação e após a implementação destes sistemas as marcas devem procurar acompanhar os seus consumidores explicando quais as vantagens, os motivos e o seu funcionamento. Os sistemas de IA devem também ser projetados de acordo com o público-alvo e de forma transparente, informada e segura permitindo que os consumidores tenham confiança durante a interação com a marca (Skraaning & Jamieson, 2021).

A monitorização constante dos sentimentos subjacentes a esta implementação, permitirá também evitar experiências negativas e minimizar acontecimentos que possam levar ao desenvolvimento do ódio e garantir que tomam decisões tendo em consideração as expectativas dos seus consumidores.

5.3. Limitações e pesquisas futuras

As principais limitações do presente estudo estão relacionadas com o tamanho da amostra. Apesar de terem sido analisados os comentários e publicações de um grande número de utilizadores da plataforma foram poucas as divulgações em torno da marca (15 130). Outra limitação poderá estar relacionada com o tipo de utilizadores da plataforma, os dados foram obtidos através dos comentários e publicações de utilizadores ativos em plataformas online e que se interessam pelo uso da IA, o que poderá aumentar o seu nível de expertise e, conseqüentemente, diminuir os erros e sentimentos negativos.

No futuro, as pesquisas podem usar os tópicos identificados para estabelecer novos construtos, variáveis ou indicadores que estudem especificamente questões de risco para as marcas, em determinados cenários específicos ou setores. Apesar da metodologia utilizada ser inovadora para este tipo de investigação, do algoritmo ter sido construído especificamente para esta investigação e com base no desenvolvimento metodológico focado extração de dados no uso do UGC- User-generated content como fonte de dados, seria interessante comparar os dados obtidos com outros dados obtidos de uma forma mais tradicional inquéritos ou entrevistas, onde pode ser alcançado um público-alvo diferente, mais alheio do meio tecnológico.

6. Apêndice

6.1. Código e verificações utilizadas ao longo da investigação

```
!pip install praw

import praw
from IPython import display
from nltk.sentiment.vader import SentimentIntensityAnalyzer as SIA
import nltk
import matplotlib.pyplot as plt
import seaborn as sns
from nltk.tokenize import word_tokenize
import re

# login in to reddit API auth
client_id = "REkvMhUPQ4JnuOMooIkbCA"
client_secret = "zHmskZYtUTtI_sSKILxu_v78JDDPxkA"
user_agent = "teste 2"
reddit = praw.Reddit(
    client_id=client_id,
    client_secret=client_secret,
    user_agent=user_agent)

import pandas as pd

# Consulta específica que deseja pesquisar
query = ['artificial intelligence', 'chat bot', 'virtual reality', 'augmented reality', 'brand']

posts = []
post_topic = reddit.subreddit('branding')
for post in post_topic.search(query, limit=10000):
    posts.append([post.title,
                  post.score,
                  post.id,
                  post.subreddit,
                  post.url,
                  post.num_comments,
                  post.selftext,
                  post.created])

# Criar o DataFrame com os posts filtrados
posts = pd.DataFrame(posts, columns=['title', 'score', 'id', 'subreddit', 'url', 'num_comments', 'body', 'created'])
posts.head()

total_comments = posts['num_comments'].sum()
print(f"Total de comentários: {total_comments}")

from wordcloud import WordCloud
import matplotlib.pyplot as plt

# Juntar todos os títulos dos posts em uma única string
titles = ' '.join(posts['title'])

# Criar a word cloud
wordcloud = WordCloud(width=800, height=400).generate(titles)

# Plotar a word cloud
plt.figure(figsize=(10, 5))
plt.imshow(wordcloud, interpolation='bilinear')
plt.axis('off')
plt.title('Word Cloud - Títulos dos Posts')
plt.show()
```

▼ New Post Clustering

```
top_post_reddit = posts.iloc[:, [1, 6]]
top_post_reddit.head()

top_post_reddit = top_post_reddit.rename(columns={'body': 'title'})
top_post_reddit.head()

import re

# Remover caracteres não alfanuméricos
top_post_reddit['title'] = top_post_reddit['title'].apply(lambda x: re.sub(r'\W', ' ', x))

# Remover números
top_post_reddit['title'] = top_post_reddit['title'].apply(lambda x: re.sub(r'\d+', '', x))

import nltk
nltk.download('punkt')

top_post_reddit['title'] = top_post_reddit['title'].apply(lambda x: nltk.word_tokenize(x))
```

Figura 5: Logging na App do reddit, web Scraping e text normalization

```

from nltk.corpus import stopwords
nltk.download('stopwords')

stop_words = set(stopwords.words('english'))

top_post_reddit['title'] = top_post_reddit['title'].apply(lambda x: [word for word in x if word.lower() not in stop_words])

top_post_reddit['title'] = top_post_reddit['title'].apply(lambda x: [word.lower() for word in x])

top_post_reddit['titles'] = top_post_reddit.title.apply(lambda x: ' '.join(x))

# iniciar da biblioteca de análise de sentimentos do NLTK
import nltk

nltk.download('vader_lexicon')
sia = SIA()

# membuat kolom sentimen kemudian menerapkan polarity score
top_post_reddit['sentiment'] = top_post_reddit.titles.apply(lambda x: sia.polarity_scores(x)['compound'])
top_post_reddit

# importação da biblioteca de análise de sentimento do NLTK
import nltk
from nltk.sentiment.vader import SentimentIntensityAnalyzer as SIA
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.decomposition import LatentDirichletAllocation
from sklearn.model_selection import train_test_split
from sklearn.svm import SVC

nltk.download('vader_lexicon')
sia = SIA()

# criação da coluna de sentimento e aplicação do polarity score
top_post_reddit['sentiment'] = top_post_reddit['titles'].apply(lambda x: sia.polarity_scores(x)['compound'])

# Definição dos limites para as classes
positive_threshold = 0.2
negative_threshold = -0.2

# Função para converter o sentimento contínuo em classes discretas
def convert_sentiment_to_class(sentiment):
    if sentiment > positive_threshold:
        return 'positive'
    elif sentiment < negative_threshold:
        return 'negative'
    else:
        return 'neutral'

# Conversão dos rótulos contínuos em classes discretas
top_post_reddit['sentiment_class'] = top_post_reddit['sentiment'].apply(convert_sentiment_to_class)

# TF-IDF vectorizer com stop words em inglês
vectorizer = TfidfVectorizer(stop_words='english')
X = vectorizer.fit_transform(top_post_reddit['titles'])

# Aplicação do modelo LDA
lda_model = LatentDirichletAllocation(n_components=5, random_state=42)
X_lda = lda_model.fit_transform(X)

# Concatenar as features do LDA com as features existentes
X_combined = np.concatenate((X.toarray(), X_lda), axis=1)

# Divisão dos dados em treinamento e teste
X_train, X_test, y_train, y_test = train_test_split(X_combined, top_post_reddit['sentiment_class'], test_size=0.2, random_state=42)

# Treinamento do modelo SVM com as novas features
svm_model = SVC()
svm_model.fit(X_train, y_train)

# Avaliação do modelo SVM
accuracy = svm_model.score(X_test, y_test)
print("Accuracy:", accuracy)

top_post_reddit.head()

# coluna titulo
top_post_reddit = top_post_reddit['titles']
top_post_reddit

from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.cluster import KMeans
from sklearn.metrics import adjusted_rand_score

# TFIDF vectorizer com stopwords em inglês
vectorizer = TfidfVectorizer(stop_words='english')
# aplique o vetorizador ao conjunto de dados top_post_reddit
X = vectorizer.fit_transform(top_post_reddit)

# treine o modelo com 5 clusters e 100 iterações
model = KMeans(n_clusters=5, init='k-means++', max_iter=5, n_init=1)
model.fit(X)

```

Figura 6: Text normalization, text representation e sentiment analysis

```

for cluster_label in set(model.labels_):
    cluster_phrases = copy_data[copy_data['kluster'] == cluster_label]['titles']
    print(f"Cluster {cluster_label}:")
    for phrase in cluster_phrases:
        print(phrase)
    print()

from sklearn.decomposition import LatentDirichletAllocation
from sklearn.feature_extraction.text import CountVectorizer

# Definir o número de clusters
num_clusters = len(set(copy_data['kluster']))

# Aplicar LDA nos textos de cada cluster
for cluster in range(num_clusters):
    cluster_text = copy_data[copy_data['kluster'] == cluster]['titles']

    # Criar matriz de frequência de termos
    vectorizer = CountVectorizer()
    term_matrix = vectorizer.fit_transform(cluster_text)

    # Aplicar LDA
    lda = LatentDirichletAllocation(n_components=1, random_state=42)
    lda.fit(term_matrix)

    # Obter os tópicos principais
    feature_names = vectorizer.get_feature_names_out()
    top_words_indices = lda.components_.argsort()[0, :-1][0:10] # Obter os 10 principais termos
    top_words = [feature_names[i] for i in top_words_indices.flatten()]

    print(f"Cluster {cluster}:")
    print(top_words)
    print()

print(model.cluster_centers_)

# análise de sentimento
headlines = set()
for submission in post_topic.new(limit=10000):
    headlines.add(submission.title)
    display.clear_output()
    print(headlines)

sia = SIA()
results = []

for line in headlines:
    pol_score = sia.polarity_scores(line)
    pol_score['headline'] = line
    results.append(pol_score)
result_df = pd.DataFrame.from_records(results)
result_df

print("0: neutral\n1: positive\n-1: negative\n")

top_post_reddit.head()

result_df['label'] = 0
result_df.loc[result_df['compound'] > 0.2, 'label'] = 1
result_df.loc[result_df['compound'] < -0.2, 'label'] = -1

# Result data
result_df

result_df.info()

print("Positive headlines:\n")
print(list(result_df[result_df['label'] == 1].headline[:5]))

print("\nNegative headlines:\n")
print(list(result_df[result_df['label'] == -1].headline[:5]))

from wordcloud import WordCloud
import matplotlib.pyplot as plt

# Filtrar os títulos dos posts com classificação positiva e negativa
positive_headlines = list(result_df[result_df['label'] == 1].headline)
negative_headlines = list(result_df[result_df['label'] == -1].headline)

# Juntar todos os títulos positivos em uma única string
positive_text = ' '.join(positive_headlines)

# Criar a word cloud para os sentimentos positivos
positive_wordcloud = WordCloud(width=800, height=400).generate(positive_text)

# Juntar todos os títulos negativos em uma única string
negative_text = ' '.join(negative_headlines)

# Criar a word cloud para os sentimentos negativos
negative_wordcloud = WordCloud(width=800, height=400).generate(negative_text)

```

Figura 7: Análise de sentimentos, clusters e wordcloud

```

# Plotar as word clouds
plt.figure(figsize=(10, 5))

plt.subplot(1, 2, 1)
plt.imshow(positive_wordcloud, interpolation='bilinear')
plt.axis('off')
plt.title('Word Cloud - Sentimentos Positivos')

plt.subplot(1, 2, 2)
plt.imshow(negative_wordcloud, interpolation='bilinear')
plt.axis('off')
plt.title('Word Cloud - Sentimentos Negativos')

plt.tight_layout()
plt.show()

import pandas as pd

# Palavras a serem verificadas
target_words = ['Failure', 'Complaints', 'Defective', 'kill', 'Controversial', 'Unsafe', 'Unresponsive', 'hate',
'Distrust', 'Outdated', 'Incompetent', 'Scandalous', 'Unpopular', 'Unethical', 'Poor reputation',
'Unprofessional', 'Untrustworthy', 'Ineffective', 'Sheepish', 'Negligent', 'Scam', 'Fraud', 'Deceptive',
'Poor quality', 'Unreliable', 'Disappointing', 'Unethical', 'Overpriced', 'Bad customer service',
'Misleading', 'Anger', 'Sadness', 'Frustration', 'Disappointment', 'Resentment', 'Envy', 'Jealousy',
'Fear', 'Anxiety', 'Guilt', 'Regret', 'Embarrassment', 'Shame', 'Threatened', 'Bitterness', 'Hatred',
'Disgust', 'threat', 'warned', 'danger', 'Abysmal', 'Atrocious', 'Catastrophic', 'Damaging', 'Dreadful',
'Insecure', 'Discontented', 'Miserable', 'Pathetic', 'Terrible', 'Wretched', 'Flawed', 'Deficient', 'Inadequate',
'Rotten', 'Worthless', 'Distressed', 'Horrendous', 'Lousy', 'Shoddy', 'Discontentment', 'Despair', 'Resentment',
'Displeasure', 'Disheartenment', 'Disillusionment', 'Pessimism', 'Disgust', 'revulsion', 'Anguish', 'Irritation',
'Agony', 'Embitterment', 'Disapproval', 'Desolation', 'Desperation', 'Indignation', 'Hostility', 'Vengefulness', 'Worried', 'struggling', 'mistake', 'bad',
'wrong', 'dislike']

# Filtrar os sentimentos negativos
negative_headlines = result_df[result_df['label'] == -1]['headline']

# Criar um dicionário para armazenar a contagem de frequência das palavras alvo
target_word_freq = {word: 0 for word in target_words}

# Verificar a frequência das palavras alvo
for headline in negative_headlines:
    for word in target_words:
        if word.lower() in headline.lower():
            target_word_freq[word] += 1

# Criar um DataFrame a partir do dicionário de frequência
df = pd.DataFrame.from_dict(target_word_freq, orient='index', columns=['Frequência'])

# Filtrar palavras com frequência diferente de zero
df = df[df['Frequência'] != 0]

# Ordenar a tabela pela coluna de frequência em ordem decrescente
df = df.sort_values(by='Frequência', ascending=False)

# Exibir a tabela
print(df)

# Exportar a tabela para um arquivo CSV
df.to_csv('frequencia_palavras.csv', index=True)

import matplotlib.pyplot as plt

# Obter as palavras e as contagens a partir do dicionário target_word_freq
words = [word for word, count in target_word_freq.items() if count != 0]
counts = [count for word, count in target_word_freq.items() if count != 0]

# Criar o gráfico de barras
plt.figure(figsize=(12, 6))
plt.bar(words, counts)
plt.xlabel('Palavras')
plt.ylabel('Frequência')
plt.title('Frequência das Palavras Negativas')

# rodar os rótulos do eixo x para melhor visualização
plt.xticks(rotation=90)

# Exibir o gráfico
plt.show()


# value total positives and negatives
print(result_df.label.value_counts(), "\n")
print(result_df.label.value_counts(normalize=True) * 1000)

# plotting pie chart
labels = 'Positive', 'Negative', 'Neutral'
sizes = result_df.label.value_counts()
colors = ['green', 'red', 'lightblue']
explode = (0.1, 0, 0) # explode 1st slice
plt.pie(sizes, explode=explode, labels=labels, colors=colors, autopct='%1.1f%%', startangle=140)
plt.axis('equal')
plt.show()

```

Figura 8: Frequências de palavras e representação gráfica

Tabela 9: Quadro resumo dos resultados obtidos



7. Bibliografia

- 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>
- Ağrali, Ö., & Aydın, Ö. (2021). Tweet Classification and Sentiment Analysis on Metaverse Related Messages. *Journal of Metaverse*, 1, 25-30. <https://doi.org/10.2139/ssrn.4171318>
- Alghamdi, R., & Alfalqi, K. (2015). A Survey of Topic Modeling in Text Mining. *International Journal of Advanced Computer Science and Applications*, 6. <https://doi.org/10.14569/IJACSA.2015.060121>
- Alsheibani, S. A., Cheung, Y. P., & Messom, C. H. (2019). Factors Inhibiting the Adoption of Artificial Intelligence at organizational-level: A Preliminary Investigation. Americas Conference on Information Systems,
- Anaza, N. A., Luis Saavedra, J., Hair, J. F., Bagherzadeh, R., Rawal, M., & Nedu Osakwe, C. (2021). Customer-brand disidentification: Conceptualization, scale development and validation. *Journal of Business Research*, 133, 116-131. <https://doi.org/https://doi.org/10.1016/j.jbusres.2021.03.064>
- Bainbridge, L. (1983). Ironies of automation. In *Analysis, design and evaluation of man-machine systems* (pp. 129-135). Elsevier.
- Bambauer-Sachse, S., & Mangold, S. (2011). Brand equity dilution through negative online word-of-mouth communication. *Journal of Retailing and Consumer Services*, 18, 38-45. <https://doi.org/10.1016/j.jretconser.2010.09.003>
- Banister, E., & Hogg, M. (2004). Negative symbolic consumption and consumers' drive for self-esteem: The case of the fashion industry. *European Journal of Marketing*, 38, 850-868. <https://doi.org/10.1108/03090560410539285>
- Berberian, B., Sarrazin, J.-C., Le Blaye, P., & Haggard, P. (2012). Automation Technology and Sense of Control: A Window on Human Agency. *PloS one*, 7, e34075. <https://doi.org/10.1371/journal.pone.0034075>
- Blöcher, K., & Alt, R. (2021). AI and robotics in the European restaurant sector: Assessing potentials for process innovation in a high-contact service industry. *Electronic Markets*, 31, 529-551. <https://doi.org/10.1007/s12525-020-00443-2>
- Bode, L., & Vraga, E. K. (2018). Studying politics across media. *Political Communication*, 35(1), 1-7.
- Brandtzaeg, P. B., & Følstad, A. (2017, 2017//). Why People Use Chatbots. Internet Science, Cham.
- Brill, T., Munoz, L., & Miller, R. (2019). Siri, Alexa, and other digital assistants: a study of customer satisfaction with artificial intelligence applications. *Journal of Marketing Management*, 35. <https://doi.org/10.1080/0267257X.2019.1687571>
- Bryson, D., Atwal, G., & Hultén, P. (2013). Towards the conceptualisation of the antecedents of extreme negative affect towards luxury brands. *Qualitative Market Research: An International Journal*, 16. <https://doi.org/10.1108/QMR-06-2013-0043>
- Burnett, M. S., & Lunsford, D. A. (1994). Conceptualizing Guilt in the Consumer Decision-making Process. *Journal of Consumer Marketing*, 11(3), 33-43. <https://doi.org/10.1108/07363769410065454>
- Casado-Díaz, A., & Mas-Ruiz, F. (2002). The Consumer's Reaction to Delays in Service. *International Journal of Service Industry Management*, 13, 118-140. <https://doi.org/10.1108/09564230210425331>

- Christodoulides, G., Gerrath, M. H., & Siamagka, N. T. (2021). Don't be rude! The effect of content moderation on consumer-brand forgiveness. *Psychology & Marketing*, 38(10), 1686-1699.
- Chu, S.-C. (2011). Determinants of consumer engagement in electronic word-of-mouth (eWOM) in social networking sites. *International Journal of Advertising*, 30. <https://doi.org/10.2501/IJA-30-1-047-075>
- Dale, R. (2016). The return of the chatbots. *Natural Language Engineering*, 22(5), 811-817. <https://doi.org/10.1017/S1351324916000243>
- Dalli, D., Romani, S., & Gistri, G. (2006). Brand Dislike: Representing the Negative Side of Consumer Preferences. *Advances in Consumer Research*, 33.
- Das, N., & Kerr, A. (2010). "Woulda, Coulda, Shoulda": A Conceptual Examination of the Sources of Postpurchase Regret. *The Journal of Marketing Theory and Practice*, 18, 171-180. <https://doi.org/10.2753/MTP1069-6679180205>
- De Bruyn, A., Viswanathan, V., Beh, Y. S., Brock, J. K.-U., & Von Wangenheim, F. (2020a). Artificial Intelligence and Marketing: Pitfalls and Opportunities. *Journal of Interactive Marketing*, 51(1), 91-105. <https://doi.org/10.1016/j.intmar.2020.04.007>
- De Bruyn, A., Viswanathan, V., Beh, Y. S., Brock, J. K.-U., & von Wangenheim, F. (2020b). Artificial Intelligence and Marketing: Pitfalls and Opportunities. *Journal of Interactive Marketing*, 51, 91-105. <https://doi.org/https://doi.org/10.1016/j.intmar.2020.04.007>
- Dewez, D., Hoyet, L., Lécuyer, A., & Argelaguet, F. (2021). Towards "Avatar-Friendly" 3D Manipulation Techniques: Bridging the Gap Between Sense of Embodiment and Interaction in Virtual Reality. <https://doi.org/10.1145/3411764.3445379>
- Dunn, L., & Hoegg, J. (2014). The Impact of Fear on Emotional Brand Attachment. *Journal of Consumer Research*, 41(1), 152-168. <https://doi.org/10.1086/675377>
- Dwivedi, D., Mahanty, G., & Vemareddy, A. (2022). How Responsible Is AI?: Identification of Key Public Concerns Using Sentiment Analysis and Topic Modeling. *International Journal of Information Retrieval Research*, 12, 1-14. <https://doi.org/10.4018/IJIRR.298646>
- Dwivedi, Y., Hughes, L., Kar, A., Baabdullah, A., Grover, P., Abbas, R., Andreini, D., Abumoghli, I., Barlette, Y., Bunker, D., Chandra Kruse, L., Constantiou, I., Davison, R., P, R., Dubey, R., Fenby-Taylor, H., Gupta, B., He, W., Kodama, M., & Baabdullah. (2022). Climate change and COP26: Are digital technologies and information management part of the problem or the solution? An editorial reflection and call to action ☆ International Journal of Information Management. *International Journal of Information Management*, 63, 102456. <https://doi.org/10.1016/j.ijinfomgt.2021.102456>
- East, R., Hammond, K., & Lomax, W. (2008). Measuring the impact of positive and negative word of mouth on brand purchase probability. *International Journal of Research in Marketing*, 25. <https://doi.org/10.1016/j.ijresmar.2008.04.001>
- Erkan, I., & Evans, C. (2016). The influence of eWOM in social media on consumers' purchase intentions: An extended approach to information adoption. *Computers in Human Behavior*, 61, 47-55.
- Erragcha, N., & Romdhane, R. (2014). New Faces of Marketing In The Era of The Web: From Marketing 1.0 To Marketing 3.0. *Journal of Research in Marketing*, 2, 137. <https://doi.org/10.17722/jorm.v2i2.46>
- Fajer, M. T., & Schouten, J. W. (1995). Breakdown and dissolution of person-brand relationships. *Advances in Consumer Research*, 22, 663-667.
- Fetscherin, M. (2019). The five types of brand hate: How they affect consumer behavior. *Journal of Business Research*, 101, 116-127.

- Følstad, A., & Brandtzaeg, P. B. (2020). Users' experiences with chatbots: findings from a questionnaire study. *Quality and User Experience*, 5(1), 3. <https://doi.org/10.1007/s41233-020-00033-2>
- Fonberg, E. (1986). AMYGDALA, EMOTIONS, MOTIVATION, AND DEPRESSIVE STATES. In (pp. 301-331). <https://doi.org/10.1016/B978-0-12-558703-7.50019-X>
- Foster, J. K., McLelland, M. A., & Wallace, L. K. (2022). Brand avatars: impact of social interaction on consumer–brand relationships. *Journal of Research in Interactive Marketing*, 16(2), 237-258. <https://doi.org/10.1108/JRIM-01-2020-0007>
- Fournier, S., & Lee, L. (2009). Getting Brand Communities Right. *Harvard Business Review*, 87, 105–111.
- Frank, D.-A., Chrysochou, P., & Mitkidis, P. (2023). The paradox of technology: Negativity bias in consumer adoption of innovative technologies. *Psychology & Marketing*, 40(3), 554-566. <https://doi.org/https://doi.org/10.1002/mar.21740>
- Frank, D.-A., Elbæk, C. T., Børsting, C. K., Mitkidis, P., Otterbring, T., & Borau, S. (2021). Drivers and social implications of Artificial Intelligence adoption in healthcare during the COVID-19 pandemic. *PloS one*, 16(11), e0259928.
- Friedman, B., Jr, P., & Howe, D. (2000). Trust Online. *Commun. ACM*, 43, 34-40. <https://doi.org/10.1145/355112.355120>
- Gaudioso, F., Turel, O., & Galimberti, C. (2017). The mediating roles of strain facets and coping strategies in translating techno-stressors into adverse job outcomes. *Computers in Human Behavior*, 69, 189-196. <https://doi.org/https://doi.org/10.1016/j.chb.2016.12.041>
- Gebera, O. W. T. (2008). La netnografía: un método de investigación en Internet. *Educar*, 42, 81-93.
- Giatsoglou, M., Vozalis, M. G., Diamantaras, K., Vakali, A., Sarigiannidis, G., & Chatzisavvas, K. C. (2017). Sentiment analysis leveraging emotions and word embeddings. *Expert Systems with Applications*, 69, 214-224. <https://doi.org/https://doi.org/10.1016/j.eswa.2016.10.043>
- Hackley, C. (2003). *Doing Research Projects in Marketing Management and Consumer Research*. <https://doi.org/10.4324/9780203402597>
- Hegner, S., Fetscherin, M., & Delzen, M. (2017). Determinants and outcomes of brand hate. *Journal of Product & Brand Management*, 26, 13-25. <https://doi.org/10.1108/JPBM-01-2016-1070>
- Hofstetter, R., Dahl, D. W., Aryobsei, S., & Herrmann, A. (2020). Constraining Ideas: How Seeing Ideas of Others Harms Creativity in Open Innovation. *Journal of Marketing Research*, 58(1), 95-114. <https://doi.org/10.1177/0022243720964429>
- Huang, B., & Philp, M. (2021). When AI-based services fail: examining the effect of the self-AI connection on willingness to share negative word-of-mouth after service failures. *The Service Industries Journal*, 41(13-14), 877-899. <https://doi.org/10.1080/02642069.2020.1748014>
- Huang, D., Jin, X., & Coghlan, A. (2021). Advances in consumer innovation resistance research: A review and research agenda. *Technological Forecasting and Social Change*, 166, 120594.
- Huang, M.-H., & Rust, R. (2020). A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science*, 49. <https://doi.org/10.1007/s11747-020-00749-9>
- Huang, M.-H., & Rust, R. T. (2021). A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science*, 49(1), 30-50. <https://doi.org/10.1007/s11747-020-00749-9>

- Hung, H.-Y., & Lu, H.-T. (2018). The rosy side and the blue side of emotional brand attachment. *Journal of Consumer Behaviour*, 17. <https://doi.org/10.1002/cb.1712>
- Jain, K., & Sharma, I. (2019). Negative outcomes of positive brand relationships. *Journal of Consumer Marketing*.
- Jiang, J., Karran, A. J., Coursaris, C. K., Léger, P.-M., & Beringer, J. (2022). A Situation Awareness Perspective on Human-AI Interaction: Tensions and Opportunities. *International Journal of Human-Computer Interaction*, 1-18. <https://doi.org/10.1080/10447318.2022.2093863>
- Johnson, D. S., Bardhi, F., & Dunn, D. T. (2008). Understanding how technology paradoxes affect customer satisfaction with self-service technology: The role of performance ambiguity and trust in technology. *Psychology & Marketing*, 25(5), 416-443.
- Kapteyn, M., Pretorius, J., & Willcox, K. (2021). A probabilistic graphical model foundation for enabling predictive digital twins at scale. *Nature Computational Science*, 1, 1-11. <https://doi.org/10.1038/s43588-021-00069-0>
- Khatoon, S., & Rehman, V. (2021). Negative emotions in consumer brand relationship: A review and future research agenda. *International Journal of Consumer Studies*, 45. <https://doi.org/10.1111/ijcs.12665>
- Kiltner, K., Groten, R., & Slater, M. (2012). The Sense of Embodiment in Virtual Reality. *Presence Teleoperators & Virtual Environments*, 21. https://doi.org/10.1162/PRES_a_00124
- Kim, T., Jiang, L., Duhachek, A., Lee, H., & Garvey, A. (2022). Do You Mind if I Ask You a Personal Question? How AI Service Agents Alter Consumer Self-Disclosure. *Journal of Service Research*, 25, 109467052211202. <https://doi.org/10.1177/10946705221120232>
- Kolbjørnsrud, V., Amico, R., & Thomas, R. (2017). Partnering with AI: how organizations can win over skeptical managers. *Strategy & Leadership*, 45, 37-43. <https://doi.org/10.1108/SL-12-2016-0085>
- Kozinets, R. V. (2002). The field behind the screen: Using netnography for marketing research in online communities. *Journal of Marketing Research*, 39(1), 61-72.
- Kozinets, R. V., & Gretzel, U. (2022). Netnography. In *Encyclopedia of Tourism Management and Marketing* (pp. 316-319). Edward Elgar Publishing.
- Kshetri, N. (2022). Web 3.0 and the Metaverse Shaping Organizations' Brand and Product Strategies. *IT Professional*, 24, 11-15. <https://doi.org/10.1109/MITP.2022.3157206>
- Kucuk, S. (2008). Negative Double Jeopardy: The role of anti-brand sites on the internet. *Journal of Brand Management*, 15, 209-222. <https://doi.org/10.1057/palgrave.bm.2550100>
- Kull, A. J., & Heath, T. B. (2016). You decide, we donate: Strengthening consumer-brand relationships through digitally co-created social responsibility. *International Journal of Research in Marketing*, 33(1), 78-92. <https://doi.org/https://doi.org/10.1016/j.ijresmar.2015.04.005>
- Latour, M. S., & Rotfeld, H. J. (1997). There are Threats and (Maybe) Fear-Caused Arousal: Theory and Confusions of Appeals to Fear and Fear Arousal Itself. *Journal of Advertising*, 26(3), 45-59. <https://doi.org/10.1080/00913367.1997.10673528>
- Lui, A., & Lamb, G. (2018). Artificial intelligence and augmented intelligence collaboration: Regaining trust and confidence in the financial sector. *Information & Communications Technology Law*, 27, 1-17. <https://doi.org/10.1080/13600834.2018.1488659>
- Ma, L., & Sun, B. (2020). Machine learning and AI in marketing – Connecting computing power to human insights. *International Journal of Research in Marketing*, 37. <https://doi.org/10.1016/j.ijresmar.2020.04.005>
- Martínez-Torres, M. R. (2014). Analysis of open innovation communities from the perspective of social network analysis. *Technology Analysis & Strategic Management*, 26(4), 435-451. <https://doi.org/10.1080/09537325.2013.851378>

- McDuff, D., & Czerwinski, M. (2018). Designing emotionally sentient agents. *Communications of the ACM*, 61(12), 74-83.
- McKinney, S., Sieniek, M., Godbole, V., Godwin, J., Antropova, N., Ashrafian, H., Back, T., Chesus, M., Corrado, G., Darzi, A., Etemadi, M., Garcia-Vicente, F., Gilbert, F., Halling-Brown, M., Hassabis, D., Jansen, S., Karthikesalingam, A., Kelly, C., King, D., & Shetty, S. (2020). International evaluation of an AI system for breast cancer screening. *Nature*, 577, 89-94. <https://doi.org/10.1038/s41586-019-1799-6>
- Merritt, S. M., Ako-Brew, A., Bryant, W. J., Staley, A., McKenna, M., Leone, A., & Shirase, L. (2019). Automation-Induced Complacency Potential: Development and Validation of a New Scale [Original Research]. *Frontiers in Psychology*, 10. <https://doi.org/10.3389/fpsyg.2019.00225>
- Moore, C., & Chuang, L. (2017). *Redditors Revealed: Motivational Factors of the Reddit Community*. <https://doi.org/10.24251/HICSS.2017.279>
- Munoko, I., Brown-Liburd, H. L., & Vasarhelyi, M. (2020). The ethical implications of using artificial intelligence in auditing. *Journal of Business Ethics*, 167, 209-234.
- Nagar, Y., & Malone, T. (2011). *Making Business Predictions by Combining Human and Machine Intelligence in Prediction Markets* (Vol. 4).
- Nanda, A. P., & Banerjee, R. (2020). Binge watching: An exploration of the role of technology. *Psychology & Marketing*, 37. <https://doi.org/10.1002/mar.21353>
- Narain, K., Swami, A., Srivastava, A., & Swami, S. (2019). Evolution and control of artificial superintelligence (ASI): a management perspective. *Journal of Advances in Management Research*, Ahead of print. <https://doi.org/10.1108/JAMR-01-2019-0006>
- Neff, G., & Nagy, P. (2016). Talking to Bots: Symbiotic Agency and the Case of Tay. *International Journal of Communication*, 10, 4915-4931.
- Newman, K., & Trump, R. (2017). When are Consumers Motivated to Connect with Ethical Brands? The Roles of Guilt and Moral Identity Importance. *Psychology & Marketing*, 34, 597-609. <https://doi.org/10.1002/mar.21008>
- Nicolescu, L., & Tudorache, M. T. (2022). Human-Computer Interaction in Customer Service: The Experience with AI Chatbots—A Systematic Literature Review. *Electronics*, 11(10), 1579. <https://www.mdpi.com/2079-9292/11/10/1579>
- Pantano, E. (2021). When a luxury brand bursts: Modelling the social media viral effects of negative stereotypes adoption leading to brand hate. *Journal of Business Research*, 123, 117-125. <https://doi.org/https://doi.org/10.1016/j.jbusres.2020.09.049>
- Parasuraman, R., Sheridan, T., & Wickens, C. (2000). A model for types and levels of human interaction with automation. *IEEE Trans. Syst. Man Cybern. Part A Syst. Hum.* 30(3), 286-297. *IEEE transactions on systems, man, and cybernetics. Part A, Systems and humans : a publication of the IEEE Systems, Man, and Cybernetics Society*, 30, 286-297. <https://doi.org/10.1109/3468.844354>
- Patton, D. U., Hong, J. S., Ranney, M., Patel, S., Kelley, C., Eschmann, R., & Washington, T. (2014). Social media as a vector for youth violence: A review of the literature. *Computers in Human Behavior*, 35, 548-553. <https://doi.org/https://doi.org/10.1016/j.chb.2014.02.043>
- Powell, A., Stavros, C., & Dobeles, A. (2021). Transmission of negative brand-relevant content on social media. *Journal of Product & Brand Management*, ahead-of-print. <https://doi.org/10.1108/JPBM-12-2020-3258>
- Ragu-Nathan, T. S., Tarafdar, M., Ragu-Nathan, B. S., & Tu, Q. (2008). The Consequences of Technostress for End Users in Organizations: Conceptual Development and Empirical Validation. *Information Systems Research*, 19(4), 417-433. <https://doi.org/10.1287/isre.1070.0165>

- Ramadan, Z., Farah, M., & Essrawi, L. (2021). From Amazon.com to Amazon.love: How Alexa is redefining companionship and interdependence for people with special needs. *Psychology & Marketing*, 38. <https://doi.org/10.1002/mar.21441>
- Riedl, M. O. (2019). Human-centered artificial intelligence and machine learning. *Human Behavior and Emerging Technologies*, 1(1), 33-36. <https://doi.org/https://doi.org/10.1002/hbe2.117>
- Roggeveen, A., & Sethuraman, R. (2020). Customer-Interfacing Retail Technologies in 2020 & Beyond: An Integrative Framework and Research Directions. *Journal of Retailing*, 96. <https://doi.org/10.1016/j.jretai.2020.08.001>
- Romani, S., Grappi, S., Zarantonello, L., & Bagozzi, R. (2015). The revenge of the consumer! How brand moral violations lead to consumer anti-brand activism. *Journal of Brand Management*, advance online publication. <https://doi.org/10.1057/bm.2015.38>
- Salimitari, M., Joneidi, M., & Chatterjee, M. (2019). *AI-enabled Blockchain: An Outlier-aware Consensus Protocol for Blockchain-based IoT Networks*.
- Saura, J., Palacios-Marqués, D., & Ribeiro-Soriano, D. (2022). Exploring the boundaries of open innovation: Evidence from social media mining. *Technovation*, 119, 102447. <https://doi.org/10.1016/j.technovation.2021.102447>
- Schouten, A. P., Valkenburg, P. M., & Peter, J. (2007). Precursors and underlying processes of adolescents' online self-disclosure: Developing and testing an "Internet-attribute-perception" model. *Media Psychology*, 10(2), 292-315.
- Shafie, A. S., Sharef, N. M., Murad, M. A. A., & Azman, A. (2018, 26-28 March 2018). Aspect Extraction Performance with POS Tag Pattern of Dependency Relation in Aspect-based Sentiment Analysis. 2018 Fourth International Conference on Information Retrieval and Knowledge Management (CAMP),
- Shen, X.-L. (2022). Human-AI interaction. *Data and Information Management*(2543-9251).
- Sheridan, T. B., Verplank, W. L., & Brooks, T. (1978). Human/computer control of undersea teleoperators. NASA. Ames Res. Center The 14th Ann. Conf. on Manual Control,
- Silva, K. C. d. (2019). Why Do People Hate Your Brand? <https://www.forbes.com/sites/karencorreiaasilva/2019/08/21/why-do-people-hate-your-brand/?sh=2bd1535935c0>
- Skraaning, G., & Jamieson, G. A. (2021). Human Performance Benefits of The Automation Transparency Design Principle:Validation and Variation. *Human Factors*, 63(3), 379-401. <https://doi.org/10.1177/0018720819887252>
- Sparks, B., & Browning, V. (2011). The impact of online reviews on hotel booking intentions and perception of trust. *Tourism Management - TOURISM MANAGE*, 32, 1310-1323. <https://doi.org/10.1016/j.tourman.2010.12.011>
- Sternberg, R. J. (2003). A Duplex Theory of Hate: Development and Application to Terrorism, Massacres, and Genocide. *Review of General Psychology*, 7(3), 299-328. <https://doi.org/10.1037/1089-2680.7.3.299>
- Stone, M., Aravopoulou, E., Ekinci, Y., Evans, G., Hobbs, M., Labib, A., Laughlin, P., Machtynger, J., & Machtynger, L. (2020). Artificial intelligence (AI) in strategic marketing decision-making: a research agenda. *The Bottom Line, ahead-of-print*. <https://doi.org/10.1108/BL-03-2020-0022>
- Swaminathan, V., Stilley, K., & Ahluwalia, R. (2009). When Brand Personality Matters: The Moderating Role of Attachment Styles. *Journal of Consumer Research*, 35, 985-1002. <https://doi.org/10.1086/593948>
- Tanna, D., Dudhane, M., Sardar, A., Deshpande, K., & Deshmukh, N. (2020, 13-15 May 2020). Sentiment Analysis on Social Media for Emotion Classification. 2020 4th International Conference on Intelligent Computing and Control Systems (ICICCS),

- Tarafdar, M., Tu, Q., Ragu-Nathan, B. S., & Ragu-Nathan, T. S. (2007). The Impact of Technostress on Role Stress and Productivity. *Journal of Management Information Systems*, 24(1), 301-328. <https://doi.org/10.2753/MIS0742-1222240109>
- Tu, Q., Wang, K., & Shu, Q. (2005). Computer-related technostress in China. *Commun. ACM*, 48, 77-81. <https://doi.org/10.1145/1053291.1053323>
- Verma, S., Sharma, R., Deb, S., & Maitra, D. (2021). Artificial intelligence in marketing: Systematic review and future research direction. *International Journal of Information Management Data Insights*, 1(1), 100002. <https://doi.org/https://doi.org/10.1016/j.jiime.2020.100002>
- Weiner, B. (2000). Attributional Thoughts About Consumer Behavior. *Journal of Consumer Research*, 27, 382-387. <https://doi.org/10.1086/317592>
- Wu, W., Lyu, H., & Luo, J. (2021). Characterizing discourse about covid-19 vaccines: A reddit version of the pandemic story. *Health Data Science*, 2021.
- Xu, A., Liu, Z., Guo, Y., Sinha, V., & Akkiraju, R. (2017). A New Chatbot for Customer Service on Social Media. <https://doi.org/10.1145/3025453.3025496>
- Xu, Y., Shieh, C.-H., van Esch, P., & Ling, I. L. (2020). AI Customer Service: Task Complexity, Problem-Solving Ability, and Usage Intention. *Australasian Marketing Journal (AMJ)*, 28. <https://doi.org/10.1016/j.ausmj.2020.03.005>
- Yadav, A., & Chakrabarti, S. (2022). Brand hate: A systematic literature review and future research agenda. *International Journal of Consumer Studies*, 46(5), 1992-2019. <https://doi.org/https://doi.org/10.1111/ijcs.12772>
- Yang, Q., Yetong, Z., Huang, H., Xiong, Z., Kang, J., & Zheng, Z. (2022). Fusing Blockchain and AI with Metaverse: A Survey. <https://doi.org/10.48550/arXiv.2201.03201>
- Yau, K.-L., Saad, N., & Chong, Y.-W. (2021). Artificial Intelligence Marketing (AIM) for Enhancing Customer Relationships. *Applied Sciences*, 11, 8562. <https://doi.org/10.3390/app11188562>
- Zarantonello, L., Romani, S., Grappi, S., & Bagozzi, R. (2016). Brand hate. *Journal of Product & Brand Management*, 25. <https://doi.org/10.1108/JPBM-01-2015-0799>
- Zeelenberg, M. (1999). The Use of Crying over Spilled Milk: A Note on the Rationality and Functionality of Regret. *Philosophical Psychology - PHILOS PSYCHOL*, 12, 325-340. <https://doi.org/10.1080/095150899105800>
- Zeelenberg, M., & Pieters, R. (2004). Beyond valence in customer dissatisfaction: A review and new findings on behavioral responses to regret and disappointment in failed services. *Journal of Business Research*, 445-455.
- Zhang, C. M., & Lu, Y. (2021). Study on artificial intelligence: The state of the art and future prospects. *Journal of Industrial Information Integration*, 23, Article 100224. <https://doi.org/10.1016/j.jii.2021.100224>
- Zhang, Y., Zhang, J., & Sakulsinlapakorn, K. (2020). Love becomes hate? or love is blind? Moderating effects of brand love upon consumers' retaliation towards brand failure. *Journal of Product & Brand Management*.
- Zolfagharian, M., & Yazdanparast, A. (2017). The dark side of consumer life in the age of virtual and mobile technology. *Journal of Marketing Management*, 33(15-16), 1304-1335. <https://doi.org/10.1080/0267257X.2017.1369143>