

DISSERTAÇÃO

O IMPACTO DAS CAPACIDADES SOCIAIS DOS AGENTES
CONVERSACIONAIS NA EXPERIÊNCIA DO CONSUMIDOR

AUTOR(A): Marta Sofia Matos Narciso

ORIENTADOR(A): Professora Doutora Simoni Rohden

INSTITUTO PORTUGUÊS DE ADMINISTRAÇÃO E MARKETING DE LISBOA, JUNHO DE 2024

O IMPACTO DAS CAPACIDADES SOCIAIS DOS AGENTES CONVERSACIONAIS NA EXPERIÊNCIA DO CONSUMIDOR

AUTOR(A): Marta Sofia Matos Narciso

Dissertação apresentado(a) ao IPAM, para cumprimento dos requisitos necessários à obtenção do grau de Mestre em Gestão de Marketing realizada sob a orientação científica da Professora Doutora Simoni Rohden.

Agradecimentos

Não podia deixar de agradecer a todos aqueles que caminharam junto a mim durante estes meses desafiantes.

Primeiramente, gostaria de agradecer a todos os docentes do IPAM Lisboa que me acompanharam ao longo destes dois anos, por toda a dedicação que colocaram em proporcionar-nos um ensino prático e focado em casos reais. Um agradecimento especial à minha orientadora, Professora Doutora Simoni Rohden, por toda a disponibilidade e o apoio que me deu durante os meses de investigação.

À equipa de Conteúdos e Competências Digitais dos CTT, obrigada por me terem acolhido no verão de 2023 e me darem a oportunidade de participar no projeto que deu vida à Helena. A Helena que serviu de inspiração para esta investigação e que é imagem da transformação e inovação de uma empresa com mais de 500 anos.

À Zumub, por me dar espaço para crescer, aprender e abraçar novos desafios. Um obrigada especial à equipa de Marketing, por se terem tornado casa e não se limitarem a ser colegas de trabalho.

Aos meus amigos, que sempre foram e sempre serão a minha maior claque, presentes em todas as vitórias e derrotas.

A toda a minha família, que lidou com todas as minhas dúvidas e hesitações, que me transmitiram uma força gigante e uma vontade de continuar a melhorar todos os dias.

A todos vós, o maior bem-haja do mundo!

Resumo

Vários são os estudos recentes relativos às aplicações da inteligência artificial e, muitos deles, abordam como estas podem ter um impacto positivo na otimização de processos no contexto empresarial. Para além disso, também são apresentadas várias investigações sobre como a inteligência artificial generativa tem alterado a forma como os agentes conversacionais se liberalizaram junto dos utilizadores. Contudo, o estudo do efeito das capacidades sociais nos *chatbots* enquanto estímulo da experiência do consumidor continua a ser um objeto pouco explorado. Assim, a presente investigação procurou analisar a empatia enquanto uma capacidade social implementada nos agentes conversacionais dotados de inteligência artificial generativa e como esta pode afetar a experiência do consumidor. Para tal, foram criados dois cenários distintos, um em que o *chatbot* demonstrava altos níveis de empatia e outro com baixos níveis de empatia, que foram aplicados a uma amostra. Cada participante dessa amostra teve acesso a apenas um dos cenários criados, sendo avaliadas a satisfação, lealdade e *electronic word of mouth*, como variáveis dependentes, e a confiança, *self-disclosure* e apego afetivo, como variáveis mediadoras. O estudo foi concluído com a confirmação de duas das seis hipóteses, afirmando que a satisfação e o eWOM são impactados positivamente quando a empatia é integrada no *chatbot*. Algumas das limitações passaram pelo tipo de amostra escolhido, porém foi demonstrado que empresas que querem seguir os desenvolvimentos tecnológicos devem apostar na potencialização do uso da inteligência artificial nas suas ferramentas, de modo a acompanharem as necessidades dos consumidores.

Palavras-chave: inteligência artificial, capacidades sociais, agentes conversacionais, experiência do consumidor

Abstract

Several recent studies have focused on the applications of artificial intelligence, and many of them discuss how these can positively impact process optimization in a business context. Additionally, there are various investigations into how generative artificial intelligence has changed the way conversational agents have become widespread among users. However, the study of the effect of social capabilities in chatbots as a stimulus for consumer experience remains an underexplored topic. Therefore, the present research aimed to analyze empathy as a social capability implemented in generative AI-powered conversational agents and how it can affect consumer experience. To achieve this, two distinct scenarios were created: one where the chatbot demonstrated high levels of empathy and another with low levels of empathy. These scenarios were applied to a sample, with each participant having access to only one of the created scenarios. Satisfaction, loyalty, and electronic word of mouth (eWOM) were evaluated as dependent variables, while trust, self-disclosure, and emotional attachment were evaluated as mediating variables. The study concluded by confirming two of the six hypotheses, asserting that satisfaction and eWOM are positively impacted when empathy is integrated into the chatbot. Some limitations included the type of sample chosen, but it was demonstrated that companies aiming to keep up with technological advancements should invest in enhancing the use of artificial intelligence in their tools to meet consumer needs.

Abreviaturas

IA – Inteligência Artificial

GPT – Generative Pretrained Transformer

NLP – Natural Language Processing

ANI – Artificial Narrow Intelligence

AGI – Artificial General Intelligence

ASI – Artificial Super Intelligence

ML – Machine Learning

CASA – Computers Are Social Actors

Índice

Agradecimentos	3
Resumo	4
Abstract	5
Abreviaturas	6
IA – Inteligência Artificial	6
GPT – Generative Pretrained Transformer	6
NLP – Natural Language Processing	6
ANI – Artificial Narrow Intelligence	6
AGI – Artificial General Intelligence	6
Índice de Figuras	9
Índice de Tabelas	10
1. Introdução	11
2. Revisão da Literatura	13
2.1. Inteligência Artificial	13
2.1.1. Inteligência Artificial em Contexto de Marketing	15
2.1.2. Agentes Conversacionais	17
2.1.3. Capacidades Sociais em Agentes Conversacionais	19
2.1.3.1. Empatia e Inteligência Artificial	20
2.2. Experiência do Consumidor	23
2.2.1. Satisfação em Contexto <i>Online</i>	23
2.2.2. Lealdade nas Marcas	24
2.2.3. <i>Electronic Word of Mouth (eWOM)</i>	24
2.3. Criação de Relações Humano – <i>Chatbot</i>	26
2.3.1. Confiança nas Ferramentas de IA	26
2.3.2. <i>Self-disclosure</i> com Agentes de IA	27
2.3.3. Apego afetivo em Contexto Humano – <i>Chatbot</i>	29

3. Metodologia	31
3.1. Procedimentos da investigação	31
3.2. Escalas de mensuração das variáveis	32
3.3. Recolha e análise de dados.....	36
4. Análise de dados.....	38
4.1. Pré-teste	38
4.2. Amostra	39
4.3. Análise da confiabilidade das escalas	41
4.4. Análise do teste de manipulação.....	43
4.5. Análise das variáveis de controlo.....	43
4.6. Estudo das variáveis dependentes	45
4.7. Estudo das variáveis mediadoras	46
5. Conclusão	49
5.1. Implicações e contributos teóricos	49
5.2. Implicações práticas e empresariais	51
5.3. Limitações e estudos futuros.....	52
Referências Bibliográficas	54

Índice de Figuras

Figura 1- Modelo conceptual do estudo.....	30
Figura 2- Quadro sinóptico de variáveis dependentes	32
Figura 3- Quadro sinóptico de variáveis mediadoras	33
Figura 4- Quadro sinóptico do teste de manipulação	34
Figura 5- Quadro sinóptico de variáveis de controlo.....	34
Figura 6- Quadro sinóptico da questão de frequência.....	34
Figura 7- Quadro sinóptico de variáveis sociodemográficas	35
Figura 8- Cenário B: Chatbot com baixa empatia.....	36
Figura 9- Cenário A: Chatbot com alta empatia	36
Figura 10- Modelo de mediação em análise.....	47
Figura 11- Sintetização dos resultados das análises de hipóteses	49

Índice de Tabelas

Tabela 1- Estatísticas descritivas do pré-teste	38
Tabela 2- Teste de significância do pré-teste	39
Tabela 3- Frequências de gêneros	40
Tabela 4- Frequências de idades	40
Tabela 5- Frequências de educação	41
Tabela 6- Frequências de ocupação	41
Tabela 7- Valores do Alpha de Cronbach das variáveis de controlo	42
Tabela 8- Valores do Alpha de Cronbach das variáveis dependentes	42
Tabela 9- Valores do Alpha de Cronbach das variáveis mediadoras	42
Tabela 10- Estatísticas descritivas do teste de manipulação	43
Tabela 11- Teste de significância do teste de manipulação	43
Tabela 12- Estatísticas descritivas das variáveis de controlo	44
Tabela 13- Teste de significância das variáveis de controlo	44
Tabela 14- Estatísticas descritivas das variáveis dependentes	45
Tabela 15- Teste de significância das variáveis dependentes	46
Tabela 16- Estatísticas descritivas das variáveis mediadoras	46
Tabela 17- Teste de significância das variáveis mediadoras	47

1. Introdução

O desenvolvimento tecnológico a que assistimos nos últimos anos fez com que a integração de ferramentas alimentadas pela inteligência artificial (IA) em atividades do âmbito cotidiano das empresas deixasse de ser considerada ficção científica e passasse a ser uma necessidade para todas aquelas que pretendem sobreviver no mercado atual (Shahid & Li, 2019). Porém, apesar de já recorrerem a alguma forma de IA, são poucas as empresas que se encontram, atualmente, a explorar a imensidade de funcionalidades proporcionadas por esta tecnologia (Shaik, 2023).

As empresas recorrem à IA para dar respostas a diversas operações (Shaik, 2023), porém o marketing tem demonstrado ser uma das formas mais pertinentes da sua utilização (Bughin et al., 2017). Vários autores têm considerado relevantes os potenciais benefícios que a integração de ferramentas alimentadas pela inteligência artificial pode ter na vida dos consumidores (Pitardi & Marriott, 2021). Se por um lado temos autores que defendem que podemos dividir em dois grandes pilares a relação da IA com o marketing, sendo estes a análise de consumo e a análise estratégica (Mustak et al., 2021), por outro encontramos autores que apontam quatro temas principais: canais, estratégia, performance e posicionamento, segmentação e targeting (Vlačić et al., 2021). No presente estudo, abordar os efeitos que a IA pode ter na experiência do consumidor.

O crescimento das tecnologias de *deep learning* e *natural language processing* (NLP) fez com que o interesse pelas ferramentas de IA que auxiliam com a gestão da relação com o cliente aumentasse (Huang & Rust, 2021). Com isto, foi adotada uma classificação que divide as ferramentas de IA utilizadas no marketing em quatro categorias (Huang & Rust, 2018): mecânicas (e.g., tecnologias de self-service), analíticas (e.g., sistemas de recomendação), intuitivas (e.g., personalização de serviços adaptáveis) e IA empática (e.g., companheiros sociais e bots conscientes da emoção).

A liberalização de modelos *generative pretrained transformer* (GPT) aumenta a necessidade de investigar a aproximação destes agentes conversacionais. Para alguns autores, esta tecnologia tem vindo a ganhar mais notoriedade por se tratar de uma ferramenta automatizada e que representa

algum tipo de companheirismo para os utilizadores (Rapp et al., 2023). Investigações mais recentes sobre o tema sugerem que alguns destes modelos GPT têm a capacidade de aprendizagem sobre um determinado ambiente, ao exercerem funções com base na predictabilidade e, consequentemente, demonstram traços de empatia e autonomia (Zierau et al., 2020). Estas características sociais podem tornar possível a criação de relações entre humanos e a IA (Pentina et al., 2023). Contudo, as considerações sobre o tema parecem divergir relativamente à natureza destas relações (Pentina, Hancock, et al., 2023).

No seu estudo, Pentina, Xie, et al. (2023), algumas capacidades sociais, nomeadamente a empatia, apresentadas pelas ferramentas de IA devem ser objeto de estudo, na medida em que podem ser cruciais para a compreensão das relações entre humanos e IA. Posto isto, a presente investigação tem como principal objetivo compreender como é que os consumidores percecionam as capacidades sociais dos agentes conversacionais, com uma maior atenção na empatia, com o objetivo de responder à questão “Quais os impactos das capacidades sociais dos agentes conversacionais, com maior foco na empatia, na experiência do consumidor?”. Deste modo, este estudo irá enfatizar as respostas dos consumidores em termos de satisfação, lealdade e *electronic word of mouth*.

Num momento inicial da revisão literária, serão apresentadas diversas abordagens da inteligência artificial, com um principal foco no contexto de marketing, seguindo-se de uma apresentação dos agentes conversacionais. Também serão abordadas as capacidades sociais destes mesmos agentes, com maior atenção ao paradigma CASA e na capacidade de empatia. De seguida, são apresentadas as variáveis mediadoras do estudo, que estão inerentes à criação de relações entre humanos e *chatbots*, sendo estas a confiança, o *self-disclosure* e a proximidade. Posteriormente, e para avaliar a experiência do consumidor, é feita uma sintetização de literatura sobre a satisfação, a lealdade e intenção de compra e o *electronic word-of-mouth*.

Para a investigação, serão realizados testes experimentais, recorrendo a uma amostra não probabilística de conveniência. Por fim, com a discussão dos dados, serão apresentadas as principais conclusões, os benefícios desta investigação e, ainda, possíveis desafios a averiguar em futuras pesquisas.

2. Revisão da Literatura

2.1. Inteligência Artificial

Para muitos a inteligência artificial (IA) é algo relativamente recente, uma vez que, apenas com os rápidos avanços tecnológicos a que assistimos nos últimos anos, se tornou uma realidade liberalizada para o utilizador comum (Puntoni et al., 2021). Contudo, o conceito surgiu pouco tempo depois dos primeiros computadores (Bornet et al., 2021). Em 1956, John McCarthy surge com uma primeira abordagem científica daquele que deverá ser o objetivo da IA, dizendo-nos que este deve passar pela construção de máquinas que conseguem simular a criação de aprendizagens ou cenários relacionados com o desenvolvimento de inteligência (McCarthy et al., 2006).

Ao tentarmos encontrar uma noção para IA, deparamo-nos com a falta de consenso na definição do conceito de "inteligência". São várias as áreas, como a psicologia, sociologia, filosofia e ainda algumas ciências exatas, que definem de forma distinta esta noção tão utilizada de forma diária (Legg & Hutter, 2007). Se por um lado temos definições que nos são dadas por dicionários e enciclopédias, como "A capacidade de adquirir e aplicar conhecimento" – The American Heritage Dictionary, 4th Edition (2000), também nos deparamos com noções mais rigorosas numa vertente científica, como a que nos é dada J. Peterson: "Um mecanismo biológico que reúne estímulos complexos que de forma unificada afetam o comportamento" (Sternberg, 2000, p. 11). Assim, para podermos atermar inteligência artificial ao longo deste estudo, teremos de considerar as diversas visões para o conceito, mas assumindo que existe uma ideia consensual para a definição do tema (De Bruyn et al., 2020).

De forma muito breve, podemos começar por definir IA como a inteligência demonstrada por máquinas (Shieber, 2004), sendo esta a noção mais aceite. Contudo, e principalmente devido ao ponto abordado anteriormente sobre as várias ideias que existem para definir inteligência, existe alguma dificuldade em atermar inteligência artificial, bem como a sua principal finalidade (Kaplan & Haenlein, 2019).

De um ponto de vista técnico, a IA tem o intuito de ser a representação de que os computadores podem pensar e desempenhar tarefas como os seres

humanos, recorrendo ao uso de *softwares* e algoritmos (Kumar et al., 2019). Segundo Wirth (2018), os principais tópicos que constituem a reprodução de inteligência humana são a aprendizagem, a representação de conhecimento, o raciocínio, a previsão e o planeamento. Assim, o autor defende que a IA se baseia na capacidade de máquinas executarem todos os aspetos apontados anteriormente, com uma maximização da probabilidade de sucesso no desempenho dessas funções. Kaplan & Haenlein (2019, p. 17) definem a IA como “a habilidade de um sistema interpretar corretamente dados externos, aprender com estes dados e utilizar esta aprendizagem para atingir objetivos específicos e realizar tarefas através de uma aprendizagem flexível”.

O recente interesse e popularidade da IA é justificado por três fatores chave, sendo estes, o crescimento do *Big Data*, a liberalização de poder computacional a baixos custos e o desenvolvimento de novas técnicas de IA. Também com a crescente disponibilidade de sistemas computacionais mais poderosos e a revolução do *Big Data* foi possível implementar tecnologias de IA, em várias áreas (Darwiche, 2018). Kumar et al. (2019) dizem-nos que a IA atua no domínio da automação e da aprendizagem contínua, conduzindo a análise de dados e a posterior tomada de decisão. Para tal, esta tecnologia recorre a processos de *deep learning*, *genetic algorithms* e *natural language processing*, o que torna possível o reconhecimento de padrões, em grandes bases de dados. Com estas metodologias de IA, os autores consideram que as máquinas ganham a capacidade de ser treinadas para executar as funções da forma mais adequada e eficiente.

Alguns autores defendem que a IA segue as mesmas diretrizes que todas as outras tecnologias relativamente a fases de evolução. Kaplan & Haenlein (2019) apresentam-nos três etapas explicativas:

- **Artificial Narrow Intelligence (ANI):** é a fase mais simples e fraca da IA, sendo considerada abaixo do nível humano. Neste estágio, a IA é aplicada apenas a áreas específicas, uma vez que não tem capacidade para responder a desafios de forma autónoma. Ainda assim, quando aplicada numa área em particular, pode igualar ou até mesmo superar as habilitações humanas.
- **Artificial General Intelligence (AGI):** é uma forma de IA mais forte, que é equiparada às capacidades humanas. Pode ser aplicada

em várias áreas, apresentando competências iguais ou superiores às humanas nas mesmas, sendo capaz de resolver problemas de forma autônoma.

- **Artificial Super Intelligence (ASI):** é a etapa de IA mais evoluída, sendo vista como consciente e que ultrapassa o nível humano em qualquer área. Tem a capacidade de apresentar respostas de forma instantânea em todos os tópicos.

Atualmente, as principais utilizações da IA são o reconhecimento de voz, texto e imagem, a automação de *robots* e veículos e, ainda, a tomada de decisão. Assim, os autores consideram que as formas de IA que se encontram mais liberalizadas são ferramentas de ANI, que contam com tecnologias de *machine learning* (ML), *deep learning* e NLP (Jarek & Mazurek, 2019). Numa revisão científica, encontramos que a ML se baseia no estudo dos algoritmos que são utilizados por sistemas computacionais com a finalidade de realizar tarefas específicas, sem terem de ser programados somente para as mesmas (Mahesh, 2020). Esta ciência pode ser utilizada para que as máquinas consigam detetar padrões e prever dados futuros, sendo uma grande contribuição para a tomada de decisão, principalmente em contextos e períodos de incerteza (Murphy, 2012). A *deep learning* é a tecnologia que permite o reconhecimento de voz, texto, imagem, objetos, entre outros (LeCun et al., 2015). Para além disso, é um instrumento mais avançado que a ML, uma vez que não exige qualquer programação manual e consegue oferecer resultados de forma imediata (Alpaydin, 2016). Por fim, a NLP garante que as máquinas tenham a capacidade para compreender linguagem em forma escrita ou discursada, tal como os humanos, de modo a realizar todas as tarefas desejadas (Chowdhary & Chowdhary, 2020).

2.1.1. Inteligência Artificial em Contexto de Marketing

Numa visão empresarial, a IA tem ganho mais reconhecimento, pois demonstrou ser uma solução para um dos obstáculos que as empresas enfrentam, atualmente, ao possibilitar o processamento e análise de grandes bases de dados (Wirth, 2018). A IA tem a capacidade de coleccionar, armazenar e gerir informação que, posteriormente, se torna conhecimento e que auxilia no

momento de tomada de decisão. Tal como referido anteriormente, considera-se que a IA tem a capacidade de treinar máquinas, com a finalidade de automatizar as diversas atividades das empresas, ao reconhecer padrões que são criados pela grande quantidade de dados corridos. Isto é possível graças ao NLP e à utilização de algoritmos genéricos e de tecnologias como a *deep learning* (Kumar et al., 2019).

As várias aplicações da IA estão, rapidamente, a transformar o mundo dos negócios (Ma & Sun, 2020). Com isto, cresce a noção de que o desenvolvimento da IA não depende apenas da tecnologia, como também das suas em aplicações numa vertente empresarial, como é o caso do marketing, ao serem utilizadas para a automatização de processos, recolha de *insights* e no (T. H. Davenport & Ronanki, 2018). Com isto, as organizações conseguem tornar os seus processos mais eficazes e automatizados, possibilitando uma redução dos seus custos e a satisfação dos clientes (Ping, 2019).

Nos anos mais recentes, as empresas têm-se deparado com uma crescente dificuldade em satisfazer as necessidades dos clientes, por diversos motivos. Estes têm cada vez mais oferta e informação a seu dispor, obrigando as empresas que querem manter uma posição forte no mercado a estar sempre disponíveis para os consumidores e a serem eficazes nos seus processos (Ping, 2019). Estas empresas podem recorrer a ferramentas de IA para tarefas específicas como armazenamento de dados dos clientes em bases internas que podem ser recolhidos em formato de texto ou de voz, extrair informações relevantes de grandes documentos para facilitar a sua leitura e o processo de tomada de decisão, fazer previsões de vendas através da interpretação de padrões, entre outras. Para o desempenho destes processos específicos, não seria necessária grande intervenção humana, o que permite às empresas uma redução de custos, principalmente no longo prazo, e ainda uma realocação dos seus esforços para outras atividades (T. Davenport et al., 2020).

A utilização de várias ferramentas de IA pode representar um custo, uma vez que requer investimento por parte das empresas, contudo, no longo prazo, será uma estratégia que permitirá aumentar receitas e diminuir custos (T. Davenport et al., 2020). A utilização de agentes de IA que interagem de forma automática tem tido uma tendência de crescimento positiva e as suas principais

formas são *chatbots*, agentes virtuais e assistentes inteligentes (Ashfaq et al., 2020). Podem ser um recurso valioso para os consumidores fazerem pesquisa de informação e para o desenvolvimento de relações sociais (Ashfaq et al., 2020; Chung et al., 2020). Para Chung et al. (2020), as principais vantagens destes agentes são a personalização de recomendações com base em previsões, a disponibilidade a qualquer momento e o entretenimento gerado, com grande impacto na experiência do consumidor.

2.1.2. Agentes Conversacionais

As empresas podem optar por várias formas de implementar esta tecnologia, sendo que uma das mais utilizadas são os agentes conversacionais, também conhecidos por *chatbots* (Pantano & Pizzi, 2020). Para responder de forma mais eficaz e eficiente às necessidades e desejos dos consumidores, as empresas procuram diferenciar-se das demais. Assim, ao introduzirem estas tecnologias, conseguem promover uma interação facilitada e melhorada entre as suas marcas e os consumidores (Puntoni et al., 2021).

Os *chatbots* surgiram na década de 50, com o principal objetivo de replicar conversas humanas. De forma breve, podemos descrever esta tecnologia como programas de computadores que interagem com os utilizadores com uma linguagem natural, tal como se de um humano se tratasse (Belda-Medina & Calvo-Ferrer, 2022).

Chaves & Gerosa (2021, p. 730) dizem que recorrem ao conceito de *chatbot* para se referirem a um “agente de conversação não corpóreo que mantém uma conversa em linguagem natural através de um ambiente baseado em texto para envolver o utilizador numa conversa com um propósito geral ou orientada para a realização de tarefas”.

É consensual que esta tecnologia tem vindo a alterar a forma como os humanos interagem com os computadores (Følstad & Brandtzaeg, 2020). Atualmente, podemos contar com a capacidade dos *chatbots* para responder a perguntas sobre os mais variados temas, como educação, saúde, produtividade, viagens, entre muitas outras (Adamopoulou & Moussiades, 2020). Para alguns autores, esta tecnologia tem vindo a ganhar mais notoriedade por se tratar de uma ferramenta automatizada e que representa algum tipo de

companheirismo para os utilizadores (Rapp et al., 2023). Num contexto empresarial, estes agentes conversacionais podem ser utilizados de modo a facilitar vendas, otimizando processos como a compra e a entrega (Feine et al., 2019). É sugerido, em alguns estudos, a utilização do termo *chatbot commerce* para descrever este tipo de ferramentas que recorrem a linguagem natural de forma a responder a necessidades e desafios de cariz comercial (Klein & Martinez, 2023). A principal ideia de *chatbot commerce* é que os clientes conseguem manter relações comerciais, comunicando e fazendo compras, recorrendo apenas a um agente conversacional (Hair, 2009).

Ainda assim, para muitos autores, os *chatbots* continuam a ter várias lacunas e não se alinham na totalidade com as expectativas dos utilizadores (Følstad & Brandtzaeg, 2020; Luger & Sellen, 2016; Zamora, 2017). Os autores justificam esta posição defendendo que o design desta tecnologia se deve focar não só na criação de uma boa performance e de respostas rigorosas, como também no desenvolvimento de capacidades sociais, de modo a aproximar-se de um humano (Jain et al., 2018). Para alguns autores, a construção de um agente conversacional deve ter, primeiramente, em atenção as capacidades sociais e, posteriormente, as suas capacidades técnicas (Neururer et al., 2018).

Com isto, alguns estudos dizem-nos que estes agentes conversacionais devem ser introduzidos enquanto complementos à atividade humana e não como substitutos (Wilson & Daugherty, 2018). A verdade é que os humanos, quando são especialistas numa determinada matéria, conseguem apresentar respostas com uma grande precisão e prestar serviços de alta qualidade. Contudo, esta perícia pode depender muitas vezes do estado emocional do humano (Zhao & Mattila, 2013) que, tão bem sabemos, é algo bastante complexo e instável e está em constante adaptação. Os *chatbots*, por sua vez, conseguem ser consistentes com as suas respostas (Tran et al., 2021) e mantêm sempre a imparcialidade (Huang & Rust, 2018). Para além disso, estamos numa era em que a conveniência é uma tendência de consumo e os consumidores valorizam a velocidade (Collier & Kimes, 2013) e os agentes conversacionais conseguem entregar respostas de forma imediata, independentemente da altura do dia a que a questão é colocada, contrariamente aos humanos (Tran et al., 2021) que acabam por ser limitados pelas suas capacidades fisiológicas.

Se aplicarmos o modelo de ciclo de vida de um produto (Rink & Swan, 1979) aos *chatbots*, podemos concluir que esta tecnologia ainda se encontra na sua fase de crescimento, na medida em que, o número de empresas que a está a aplicar, continua a evoluir positivamente (Klein & Martinez, 2023). Os agentes conversacionais são utilizados pelas empresas como um complemento e os consumidores já sentem que é algo comum no comércio *online* (Francis & Hoefel, 2018), que se está a tornar numa ferramenta indispensável para a construção e manutenção de relações entre os consumidores e as empresas no contexto *online* (Zarantonello & Pauwels-Delassus, 2015).

As empresas têm tendência a aumentar os seus pontos de contacto com os consumidores (Klein & Martinez, 2023) e os *chatbots* são, assim, mais uma forma de interação que as empresas têm vindo a implementar. Com isto, cresce a necessidade de as organizações implementarem sistemas mais eficientes, com capacidades de resposta a jornadas do consumidor mais complexas e a um maior número de ações realizadas pelo utilizador nos *sites* (Lim & Ting, 2012).

A experiência dos consumidores *online* é cada vez mais relevante e os profissionais têm dado grande importância a estas interações (Klein & Martinez, 2023). Para (Bleier et al., 2019) e Chung et al. (2020), uma das características mais apreciadas pelos consumidores é o entretenimento, combinado com a eficiência do processo de compra. Os agentes conversacionais podem ser ferramentas de comunicação importantes neste aspeto, visto que conseguem influenciar a experiência dos consumidores online, ao criarem estímulos e serem fontes de entretenimento (Klein & Martinez, 2023).

2.1.3. Capacidades Sociais em Agentes Conversacionais

Os estudos sobre *chatbots* podem ser agrupados em algumas categorias estratégicas que ajudam à sua compreensão, sendo estas a tecnologia, capacidades sociais e as fases do desenvolvimento de relações com humanos (Pentina, Hancock, et al., 2023). As capacidades dos agentes conversacionais podem ser de natureza social ou direcionadas para a realização de tarefas (Chattaraman et al., 2019; De Cicco et al., 2020). Assim, nesta investigação iremos focar-nos na análise das características sociais dos *chatbots*.

Quando estudamos as capacidades sociais dos agentes conversacionais, deparamo-nos com o paradigma CASA – *Computers Are Social Actors* que nos diz que, embora a tecnologia seja inanimada, os utilizadores das mesmas abordam-nas como agentes sociais (Nass & Moon, 2000; Reeves & Nass, 1996).

Torna-se relevante referir que alguns autores apoiam que esta conceção é algo que os utilizadores fazem de forma inconsciente, principalmente em tópicos sociais, como *feedback* de forma síncrona ou em saudações (Pentina, Xie, et al., 2023). Assim, durante as interações, consumidores percecionam uma presença social e atribuem uma entidade social às máquinas (Liu & Sundar, 2018). Posto isto, e apesar de se tratar de tecnologias, o agente humano acaba por considerar certas regras que são usuais em interações humano – humano quando estão a interagir com agentes tecnológicos inanimados (Isbister & Nass, 2000; K. M. Lee & Nass, 2003; Nass & Moon, 2000).

As ferramentas de IA mais recentes são dotadas de certas capacidades sociais, consideradas sofisticadas, aproximando-as dos estereótipos humanos (Pentina, Xie, et al., 2023). Traços sociais como personalidade, autonomia e empatia (Zhou et al., 2020) tornam possíveis a criação de interações com maior sentido emocional entre humanos e agentes de IA e tornam possível a consolidação de relações (Pentina, Hancock, et al., 2023).

Segundo o paradigma CASA, a empatia é uma das principais capacidades sociais humanas a ser estudada no caso dos computadores, uma vez que é fundamental nas interações humano – humano (Liu & Sundar, 2018). No presente estudo, iremos focar-nos em aplicar estas capacidades sociais aos *chatbots*.

2.1.3.1. Empatia e Inteligência Artificial

A empatia é-nos definida como “uma resposta emocional que decorre do estado ou condição emocional de outra pessoa” (Jiang et al., 2022, p.2), estando dependente, assim, de uma interação. Porém, pode ser considerada um traço de personalidade ou um “mecanismo de processamento” (Jiang et al., 2022, p.2). Para este estudo, iremos reiterar a ideia de empatia enquanto um mecanismo de processo, que se refere a este conceito enquanto um processo

interpessoal, essencial nas interações humanas e que contribui para a recolha de informação nas relações (Finn, 2009).

Sendo uma noção multifacetada, encontramos que pode ter uma perspetiva cognitiva e uma perspetiva afetiva. A empatia cognitiva está inerente à adoção de uma perspetiva que depende da leitura das emoções de outra pessoa, num sentido controlado e intencional, focando-se em compreender as perspetivas do outro, com vista a reduzir conflitos. Por outro lado, a empatia afetiva é algo intencional que resulta da partilha de emoções e sentimentos, sendo relevante a demonstração de compreensão pela posição do próximo e está diretamente relacionada com atitudes altruístas e de preocupação (Caravita et al., 2009; Pfattheicher et al., 2020; Sassenrath et al., 2016; Todd & Burgmer, 2013; Topcu & Erdur-Baker, 2012). Assim, estas duas conceções de empatia acabam por criar respostas distintas (Pfattheicher et al., 2020).

A empatia tem um papel essencial no desenvolvimento de interações de sucesso (Leiberg & Anders, 2006) e isso deve-se ao facto de ser um ideal que tem impacto positivo na rapidez com a qual a informação é processada pelos recetores, bem como na sua qualidade, e ainda pode ser relevante para uma maior adaptabilidade dos mesmos (Jiang et al., 2022). O nível de empatia de cada indivíduo terá impacto na forma como processam informação a um nível social (Rieki et al., 2018), sendo então uma variável que é bastante considerada quando é medida a capacidade de processamento de informação individual e quando também a qualidade das interações sociais (van der Stouwe et al., 2018).

De acordo com a teoria CASA, apresentada anteriormente, os utilizadores de agentes conversacionais valorizam as ferramentas que transmitem algum tipo de empatia, quer seja esta afetiva, quer seja cognitiva (Liu & Sundar, 2018). A forma como os utilizadores acreditam nas capacidades das ferramentas de IA pode ter influência na maneira como percecionam a expressão de emoções destas máquinas (MacDorman & Entezari, 2015). A empatia surge como um tópico bastante relevante para temas como o marketing relacional e a prestação de serviços, devido à sua relevância na criação de momentos de compreensão entre os consumidores e os prestadores de serviços (Iglesias et al., 2019).

De acordo com Wang (2017), a IA tem aptidões, como a análise de grandes bases de dados, que lhe permitem a construção de respostas personalizadas consoante as diferentes necessidades de cada indivíduo, o que, consequentemente, pode gerar uma demonstração de empatia para com os consumidores. No seu estudo, Liu & Sundar (2018), concluíram que os utilizadores têm preferência por *chatbots* que demonstram maior compaixão nas suas respostas, ao recorrerem à empatia e simpatia, em detrimento dos *chatbots* que se limitam a utilizar uma linguagem de conselheiro. Assim, tal como nas relações com colaboradores humanos, quando os agentes de IA transmitem empatia para com os consumidores, existe um aumento da satisfação, da qualidade da relação e ainda da confiança percebida pela parte humana da interação (Ashfaq et al., 2020).

2.2. Experiência do Consumidor

2.2.1. Satisfação em Contexto Online

O estudo da satisfação dos consumidores, até em contexto *online*, já vem sendo feito há várias décadas. Vários autores concordam que o consumidor entra num estado de satisfação quando a percepção da sua experiência de compra *online* confirma as suas expectativas (Opreana & Vinerean, 2014). Um alto nível de satisfação dos consumidores terá influência positiva nas suas “atitudes, intenções, decisões e compras” (Li & Zhang, 2002, p. 514) *online*. Para as empresas, a satisfação dos clientes pode representar uma fonte de sucesso e vantagens competitivas, tendo um grande impacto nos negócios (Molla & Licker, 2001). Ainda assim, é importante considerar que as expectativas criadas são um dos pontos mais relevantes para alcançar um nível de satisfação. Essas expectativas irão ser criadas ao longo de todo o processo de tomada de decisão de compra (Li & Zhang, 2002).

Relativamente aos agentes conversacionais, Klein & Martinez (2023) referem que o consumidor pode sentir satisfação em dois momentos distintos, sendo estes quando avalia o produto ou serviço após o consumo ou utilização do mesmo ou quando interagem com o *chatbot* nos *sites* das empresas. Estas ferramentas podem ser fundamentais para as empresas que procuram aumentar os níveis de satisfação dos seus clientes, uma vez que são mais interativas e de utilização mais conveniente para os consumidores. Para além disso, conseguem apresentar as opções que mais se adequam às suas necessidades, reduzindo sentimentos de incerteza e ansiedade, tornando-se, assim, fontes de satisfação (J.-S. Chen et al., 2021).

Os *chatbots* que operam com inteligência artificial generativa, isto é, os que demonstram capacidades mais próximas das humanas, têm um grande impacto em várias variáveis inerentes à experiência do consumidor, sendo uma delas a sua satisfação (Araujo, 2018). Porém, as grandes aptidões destas ferramentas podem ter um efeito contrário ao desejado, ao criarem grandes expectativas nos consumidores que, caso não sejam igualadas ou superadas, se sentirão insatisfeitos (Spears & Singh, 2004). Assim, neste estudo iremos analisar a seguinte hipótese:

H1: Chatbots com capacidades sociais de empatia têm um impacto positivo na satisfação do consumidor.

2.2.2. Lealdade nas Marcas

A lealdade surge como uma variável comportamental (Gunawan, 2022), bastante relevante na criação de relações com os consumidores, na medida em que é definida como o interesse, por parte do consumidor em construir uma relação com uma marca em específico, a longo prazo (Markovic et al., 2018). Vários autores defendem que a lealdade é uma variável com bastante impacto para as empresas e que gera lucros relevantes, uma vez que leva os consumidores a repetir compras na marca, gera recomendações e referências positivas, faz com que os clientes estejam dispostos a pagar preços mais elevados e, conseqüentemente, constitui uma redução de custos para as empresas (Iglesias et al., 2020).

Variáveis como a confiança e o compromisso dos consumidores para com as marcas estão diretamente ligadas à construção de um sentimento de lealdade (Markovic et al., 2018). A satisfação surge como uma variável relevante, uma vez que no seu estudo, Gunawan (2022, p.36) diz-nos que “a probabilidade de uma pessoa ser leal é de 65% quando está satisfeita e de 95% quando está muito satisfeita”.

Armstrong et al. (2014) referem que um consumidor leal é aquele que, para além de ter intenção de repetir a compra, se sente orgulhoso da mesma e que recomenda a experiência a outros consumidores. Posto isto, no presente estudo, iremos tentar perceber se as capacidades sociais dos agentes conversacionais terão um efeito positivo na lealdade para com as marcas:

H2: Chatbots com capacidades sociais de empatia têm um impacto positivo na lealdade do consumidor.

2.2.3. Electronic Word of Mouth (eWOM)

Vários autores concordam que *word of mouth* (WOM) é um tópico bastante relevante no comportamento do consumidor (Cheung & Thadani, 2012; Shankar et al., 2020), uma vez que é definido como um modo de

comunicação informal que tem impacto no processo de tomada de decisão do consumidor (Augusto & Torres, 2018; Yang, 2016). Com o desenvolvimento das tecnologias, surgiu o termo *electronic WOM* (eWOM), que Hennig-Thurau et al. (2004,) definem como qualquer afirmação, de conotação positiva ou negativa, que é feita por clientes relativamente a uma empresa, produto ou serviço que esteja disponível na internet, de forma acessível.

Para as equipas de marketing, eWOM é um conceito que é cada vez mais relevante para a experiência do consumidor (H. Li et al., 2022), uma vez que pode gerar confiança (Gvili & Levy, 2021) por parte dos potenciais consumidores. Isto é, antes de recorrerem a certas tecnologias, os utilizadores procuram comentários e *reviews* de outros clientes e fazem uma análise crítica aos mesmos (J. Chen et al., 2016), refletindo a confiança que depositam nas opiniões de outros consumidores, em detrimento das informações que são trabalhadas e publicadas pelas equipas de marketing das marcas (Kim et al., 2015).

As principais diferenças do WOM tradicional para o eWOM passam pelo facto de alcançar uma maior audiência e divulgação, permitir uma troca de informações multidirecional entre utilizadores e com grande acessibilidade e disponibilidade a qualquer momento (Augusto & Torres, 2018; Cheung & Thadani, 2012). Estas são também algumas das principais características dos agentes conversacionais em estudo, por isso tentaremos compreender se as suas características sociais terão um impacto num eWOM positivo:

H3: Chatbots com capacidades sociais de empatia têm um impacto positivo no eWOM.

2.3. Criação de Relações Humano – Chatbot

2.3.1. Confiança nas Ferramentas de IA

Várias abordagens relativas às relações entre humanos e tecnologias têm a confiança como um ponto fundamental de estudo, uma vez que é um sentimento que tem grande impacto na percepção de risco (Ba & Pavlou, 2002; McKnight et al., 1998). A confiança é algo essencial para qualquer interação (Chi et al., 2021) e é definida a “predisposição para atribuir boas intenções e ter confianças nas palavras de ações de outras pessoas” (Cook & Wall, 1980, p. 39). Por norma, é uma variável medida através de escalas multidimensionais (McKnight et al., 2002). Quando estudamos este termo, surge o conceito de *trust stance in technology* que se refere à confiança que os consumidores colocam na tecnologia quando acreditam que terão benefícios com através desta postura (Tussyadiah & Miller, 2019).

Estudos demonstram que a confiança depositada em ferramentas que operam com IA é diferente da sentida pelos utilizadores em relação a tecnologias tradicionais (Chi et al., 2021; Gursoy et al., 2019). Para compreender a confiança gerada nas interações com IA, os autores abordam tanto uma perspetiva teórica, como uma perspetiva operacional (Chi et al., 2021).

De um ponto de vista teórico, é relevante ter em consideração os fatores psicológicos que afetam os humanos e têm impacto na confiança (McKnight et al., 2002). Por outro lado, relativamente à tecnologia, são importantes condicionantes como as suas funcionalidades, utilidades e, ainda, o grau de confiabilidade (Lankton et al., 2014). No caso das tecnologias de IA, como os agentes conversacionais, os consumidores consideram-nos não só prestadores de serviços, como também lhes atribuem uma entidade social (Gursoy et al., 2019; Van Doorn et al., 2017). Numa abordagem operacional, vários autores defendem a necessidade de serem criadas escalas multidimensionais para medir esta variável quando aplicada a tecnologias de IA (W.-H. Lee et al., 2018; Van Pinxteren et al., 2019; Xu, 2019), visto que a confiança é fundamental para a criação de relações a longo prazo (Chi et al., 2021).

Chi et al. (2021) defendem que a confiança nas interações entre humanos e agentes sociais de IA são uma combinação entre a “confiança humana nas tecnologias e a confiança entre humanos”. Isto acontece quando

os consumidores têm estas ferramentas de IA como entidades sociais e não como simples máquinas (Rodriguez-Lizundia et al., 2015), avaliando-as também com base nos seus níveis sociais (Gursoy et al., 2019).

Posto isto, iremos utilizar a confiança como uma variável moderadora do presente estudo para responder à hipótese:

H4: A confiança medeia a relação entre capacidades sociais dos chatbots e satisfação (a), lealdade (b) e eWOM (c).

2.3.2. Self-disclosure com Agentes de IA

Podemos começar por definir *self-disclosure* como a partilha de informação de conotação privada com terceiros (Greene et al., 2006), quer seja informação pessoal sobre atitudes e valores, quer seja algum tipo de informação sobre vivências passadas, estados de vida presentes ou planos para o futuro (Al-Natour et al., 2021).

Vários autores relacionam este conceito à *social exchange theory*. Isto é, quando são criadas relações, existe uma partilha de informações, conhecimentos, entre outros, entre as partes envolvidas, que é desencadeada por necessidades de interdependência (Bigras et al., 2019). Al-Natour et al., 2011) dizem-nos que *self-disclosure* é um processo cognitivo em que existe uma distinção entre benefícios e custos. Com isto, os autores querem dizer que quando existem interações sociais, os indivíduos atribuem, subjetivamente, um benefício ou um custo à informação que estão a partilhar. Enquanto seres racionais, os humanos tentam obter o máximo de benefícios relativamente aos custos (Cropanzano & Mitchell, 2005), em qualquer tipo de troca. Assim, a predisposição para partilhar informações pessoais passa por uma relativização dos custos perante os benefícios potencialmente obtidos (Phelps et al., 2000).

Surgem alguns autores que criticam esta posição, defendendo que *self-disclosure* não é um processo cognitivo, mas sim como algo que ocorre durante interações sociais e que depende do contexto da interação e das possíveis consequências da mesma (Serrano Archimi et al., 2018). Posto isto, é sugerido que devem ser consideradas todas as características da interação, bem como a natureza da relação e, ainda, todo o contexto envolvente, na medida em

que vão influenciar a partilha de informação pessoal (Antaki et al., 2005). Isto torna-se relevante para perceber a razão pela qual em algumas situações ou relações há mais momentos de *self-disclosure* (Self-Disclose & Omarzu, 2000).

Outra variável importante referir é a confiança envolvida no *self-disclosure*, uma vez que pode ser visto como uma ação que envolve risco para quem partilha e que obriga a uma sensação de conforto perante a parte que recebe (W. Wang & Benbasat, 2016).

Neste estudo, iremos considerar que *self-disclosure* depende não só da perceção subjetiva dos benefícios e custos que cada parte atribui à partilha de informação, como também de todo o contexto em que ocorre. Como pretendemos estudar a ligação deste conceito aos agentes conversacionais que operam com base na inteligência artificial generativa, é fundamental compreender como os indivíduos estão dispostos a interagir com os mesmos. Al-Natour et al., (2020) e Hui et al., (2006) apresentam-nos a ideia de que os consumidores *online* estão dispostos a partilhar informações pessoais de modo a receber algum tipo de benefício. Um dos principais benefícios que os consumidores encontram é a troca de informações por serviços mais personalizados. Contudo com esta partilha de dados pessoais, aumentam as preocupações com a privacidade (Adjerid et al., 2018; Al-Natour et al., 2020; Buckman et al., 2019). Estas questões acabaram por criar o *personalization privacy paradox* (Sutanto et al., 2013). Este cenário acaba por ser enquadrado na *social exchange theory*, pois os consumidores acabam por assumir que a personalização é o benefício que terá como custo a perda de privacidade (Al-Natour et al., 2021). Para além disso, os consumidores demonstram-se mais dispostos a partilhar informações pessoais quando os *sites* se apresentam de forma transparente (Awad & Krishnan, 2006).

Os estudos existentes sobre *self-disclosure* mostram que existem vários fatores que podem ter influência na partilha de informação, alterando a perceção que os indivíduos têm relativamente aos benefícios e custos e sobre outras variáveis que podem impactar o processo (Al-Natour et al., 2021). Quanto à partilha online, os consumidores estão dispostos a partilhar mais informação quando são apresentadas razões pelas quais são necessários certos dados pessoais (Zimmer et al., 2010) e quando os benefícios parecem maiores que a possível perda de privacidade (Al-Natour et al., 2021).

H5: O *self-disclosure* medeia a relação entre capacidades sociais dos chatbots e satisfação (a), lealdade (b) e eWOM (c).

2.3.3. Apego afetivo em Contexto Humano – Chatbot

O apego afetivo surge em alguns estudos com uma postura moderadora no estudo de relações, sendo também aplicada a relações entre a inteligência artificial com os humanos (Bilal et al., 2024). Esta variável é apresentada como essencial para construção, manutenção e fortalecimento de relações (Rioux et al., 2017). O apego afetivo é definido como uma ligação do espectro emocional humano para com objetos (Jamieson et al., 2000), locais (Yuksel et al., 2010), ou até mesmo marcas (Rioux et al., 2017).

No seu estudo de 1998, Fournier defende que os consumidores conseguem criar relações interpessoais com objetos, às semelhanças que têm entre si em sociedade. Assim, surge a curiosidade para percebermos se o apego afetivo terá impacto na construção de relações entre humanos e *chatbots*, bem como na sua experiência enquanto consumidores. A verdade é que, segundo os vários estudos relativos ao tema, o apego afetivo reitera a existência de laços emocionais (Bilal et al., 2024), o que pode resultar na manutenção de relações de longo prazo (Hsiao & Chen, 2016).

Bilal et al. (2024) apresentam uma relação de proporcionalidade entre o apego afetivo e a satisfação, reforçando que se os consumidores têm uma experiência positiva com as ferramentas de IA, ou seja, fiquem satisfeitos com a interação, então irá existir um aumento do apego afetivo percebido, e vice-versa. Assim, surge a hipótese em teste, de modo a podermos avaliar o impacto deste conceito como mediadora, não só na satisfação, como também nas restantes noções a estudo para a experiência do consumidor:

H6: O apego afetivo medeia a relação entre capacidades sociais dos chatbots e satisfação (a), lealdade (b) e eWOM (c).

Assim, com a combinação de todas as variáveis e hipóteses apresentadas anteriormente, surge o modelo conceptual que irá servir como base da presente investigação.




Figura 1- Modelo conceptual do estudo

3. Metodologia

3.1. Procedimentos da investigação

O presente estudo foi realizado através de uma investigação experimental, para o qual foram desenvolvidos dois cenários distintos. Cada participante teve acesso a apenas um dos cenários e em nenhum momento foi exposta a existência de um cenário mais empático que o outro. Os inquiridos tiveram apenas o poder de decisão entre “Questionário A” ou “Questionário B”, não sendo feita qualquer referência ao alto ou baixo nível de capacidades sociais do *chatbot* em cada cenário.

Os cenários apresentados foram criados de modo a simular uma interação entre um utilizador e um *chatbot*, em que o utilizador pede ajuda a esta tecnologia com o *tracking* de uma encomenda. Este contexto foi inspirado pela “Helena”, a ferramenta de inteligência artificial generativa lançada em 2023 pelos CTT – Correios de Portugal, SA, com o objetivo otimizar o serviço de apoio ao cliente.

A diferença entre os cenários foi apenas aplicada nas respostas dadas pela tecnologia, sendo as respostas do utilizador as mesmas ao longo de toda a interação. Deste modo, durante a análise de dados, sabemos que as diferenças entre as respostas se baseiam apenas na forma como o *chatbot* interage com ou sem empatia. Foi escolhida uma interação curta, com o intuito de não sobrecarregar o participante com informação.

Posto isto, esta investigação tem como finalidade perceber como a presença de empatia nas interações entre o ser humano e os agentes conversacionais derivados da inteligência artificial, isto é, a variável independente, pode ter um impacto positivo na satisfação, lealdade e *electronic word of mouth*, ou seja, as variáveis dependentes. Para além disso, foram nomeadas variáveis como a confiança, o *self-disclosure* e o apego afetivo, para percebermos como medeiam a nossa variável independente e as variáveis dependentes.

3.2. Escalas de mensuração das variáveis

O inquérito começou por apresentar aos participantes um dos cenários criados, ou seja, foi num momento inicial que os inquiridos se depararam com um cenário com alta ou baixa empatia. De seguida, os participantes responderam à questão de manipulação, seguindo-se as questões que envolviam as variáveis de controlo e a questão de frequência. Posteriormente, foram apresentadas as questões referentes às variáveis dependentes e mediadoras. Por fim, os participantes concluíram ao preencherem o formulário com dados sociodemográficos.

Figura 2- Quadro sinóptico de variáveis dependentes

Variável Dependente	Questões	Escala	Fonte
Satisfação	Sinto-me satisfeito com este <i>chatbot</i> .	Escala de Likert (1-5) 1= Discordo totalmente 5= Concordo totalmente	Adaptado de: Chung et al., 2020
	Este <i>chatbot</i> deu uma boa resposta.		
	Este <i>chatbot</i> respondeu tal como eu esperava.		
	Sinto-me feliz ao interagir com este <i>chatbot</i> .		
Lealdade	O <i>chatbot</i> faz com que eu considere este serviço como a minha primeira opção quando necessito deste tipo de informações.	Escala de Likert (1-5) 1= Discordo totalmente 5= Concordo totalmente	Adaptado de: Dagger et al., 2011
	O <i>chatbot</i> faz com que eu esteja disposto a manter relações com a empresa em questão.		
	Se o <i>chatbot</i> não estivesse operacional, eu preferia esperar a resolução do seu problema.		Adaptado de: Peng & Li, 2019
	Considerando essa interação com o <i>chatbot</i> , eu teria intenção de voltar a utilizá-lo no futuro, se necessário.		
(Electronic) Word of Mouth	Eu diria coisas positivas sobre este <i>chatbot</i> a outras pessoas, na internet.	Escala de Likert (1-5)	Adaptado de: Babin et al., 2005

	Eu recomendaria este <i>chatbot</i> a outras pessoas, na internet.	1= Discordo totalmente 5= Concordo totalmente	
	Eu encorajaria amigos e familiares a utilizarem o serviço deste <i>chatbot</i> .		

Figura 3- Quadro sinóptico de variáveis mediadoras

Variável Mediadora	Questões	Escala	Fonte
Confiança	Eu confio neste <i>chatbot</i> .	Escala de Likert (1-5) 1= Discordo totalmente 5= Concordo totalmente	Adaptado de: Zarantonello & Pauwels-Delassus, 2015
	Eu sinto que posso confiar neste <i>chatbot</i> para desempenhar as suas funções, tal como é suposto.		Adaptado de: Fernandes & Oliveira, 2021; Mattison Thompson & Siamagka, 2022
	Eu acredito que este <i>chatbot</i> fornece informações precisas.		
	Este <i>chatbot</i> preocupa-se com as necessidades do consumidor.		Adaptado de: Zarantonello & Pauwels-Delassus, 2015
Self-disclosure	Eu estaria disposto a partilhar informações pessoais ao usar este <i>chatbot</i> , no futuro.	Escala de Likert (1-5) 1= Discordo totalmente 5= Concordo totalmente	Adaptado de: L. Wang et al., 2017
	Provavelmente, eu revelaria informações sobre mim ao <i>chatbot</i> .		
	Provavelmente, eu partilharia informações pessoais com o <i>chatbot</i> se fosse necessário.		
Apego Afetivo	Eu sentiria que este <i>chatbot</i> é parte de mim.	Escala de Likert (1-5) 1= Discordo totalmente 5= Concordo totalmente	Adaptado de: Ki et al., 2020
	Eu sentir-me-ia pessoalmente conectado ao <i>chatbot</i> .		
	Eu sentiria um apego emocional para com este <i>chatbot</i> .		

Figura 4- Quadro sinóptico do teste de manipulação

Teste de manipulação	Questão	Escala
Realizado de modo a compreender se os participantes percebem a presença ou falta de empatia	Como avalia o atendimento realizado pelo <i>chatbot</i> na situação descrita?	1= Nada empático 2= Muito pouco empático 3= Neutro 4= Parcialmente empático 5= Totalmente empático

Figura 5- Quadro sinóptico de variáveis de controle

Variável de Controle	Questões	Escala	Fonte
Warmth	Este <i>chatbot</i> é gentil.	Escala de Likert (1-5) 1= Discordo totalmente 5= Concordo totalmente	Adaptado de: (Y. Li et al., 2023)
	Este <i>chatbot</i> é amigável.		
	Este <i>chatbot</i> é cordial.		
Competência	Este <i>chatbot</i> é competente.	Escala de Likert (1-5) 1= Discordo totalmente 5= Concordo totalmente	Adaptado de: (Y. Li et al., 2023)
	Este <i>chatbot</i> é eficiente.		
	Este <i>chatbot</i> é eficaz.		
Percepção de risco	Partilhar informações com este <i>chatbot</i> poderia gerar problemas inesperados.	Escala de Likert (1-5) 1= Discordo totalmente 5= Concordo totalmente	Adaptado de: (Hayes et al., 2021)
	Poderia ser arriscado interagir com esse <i>chatbot</i> .		
	Há um grande risco envolvido com a partilha de dados pessoais com este <i>chatbot</i> .		

Figura 6- Quadro sinóptico da questão de frequência

Questão de frequência	Questão	Escala
Realizado de modo a compreender a frequência com a qual os participantes recorrem a agentes conversacionais	Tenho por hábito recorrer à utilização de <i>chatbots</i> no meu dia-a-dia.	Adaptado: Ordinal Escala de Likert (1-5) 1= Discordo totalmente 5= Concordo totalmente

Figura 7- Quadro sinóptico de variáveis sociodemográficas

Variável Sociodemográfica	Respostas possíveis	Escala
Género	Feminino Masculino Prefiro não responder Outro	F= Feminino M= Masculino 8= Prefiro não responder 9= Outro
Idade	(resposta aberta)	Categórica
Educação	Ensino básico Ensino secundário Ensino técnico-profissional Licenciatura Mestrado Doutoramento Prefiro não responder	1= Ensino básico 2= Ensino secundário 3= Ensino técnico-profissional 4= Licenciatura 5= Mestrado 6= Doutoramento 8= Prefiro não responder
Ocupação	Estudante Trabalhador-estudante por conta própria Trabalhador-estudante por conta de outrem Trabalhador por conta própria Trabalhador por conta de outrem Desempregado Reformado Prefiro não responder	1= Estudante 2= Trabalhador-estudante por conta própria 3= Trabalhador-estudante por conta de outrem 4= Trabalhador por conta própria 5= Trabalhador por conta de outrem 6= Desempregado 7= Reformado 8= Prefiro não responder

3.3. Recolha e análise de dados

Para a recolha de dados, foi criado um Google Forms inicial, no qual foi dado a conhecer o objetivo geral do estudo, isto é, o impacto das capacidades sociais dos *chatbots* na experiência do consumidor. Neste momento, não foi mencionado que o foco da investigação era compreender como a presença de empatia teria influência na interação. Deste modo, os participantes não teriam tendência a procurar uma capacidade social específica quando se deparassem com o cenário apresentado. No questionário inicial, tal como referido anteriormente, os inquiridos selecionaram, sem qualquer possibilidade de resposta tendenciosa, entre um “Questionário A” e um “Questionário B”.

Consoante a escolha, foram encaminhados para um novo Google Forms. Assim, foram criados dois formulários iguais, em que a única diferença era o cenário apresentado. O “Questionário A” apresentava a interação dotada de alta empatia e o “Questionário B” mostrava a situação com baixa empatia.

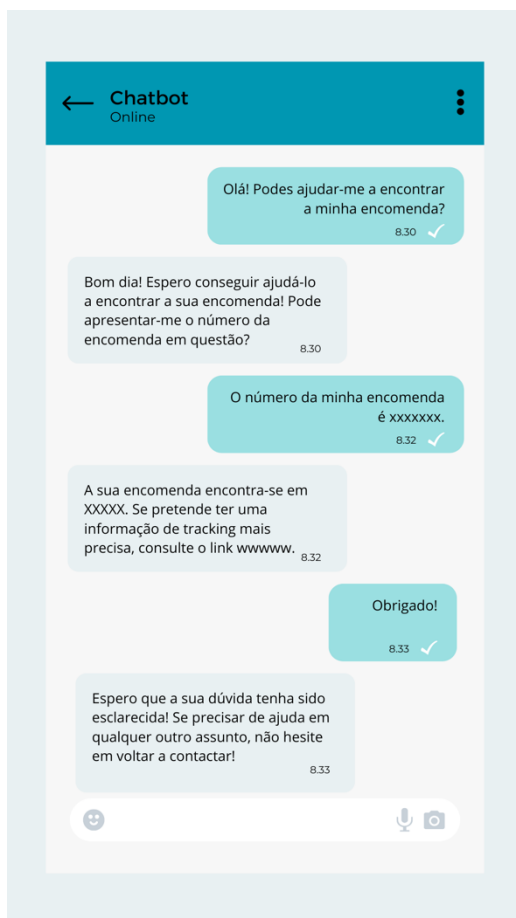


Figura 9- Cenário A: Chatbot com alta empatia

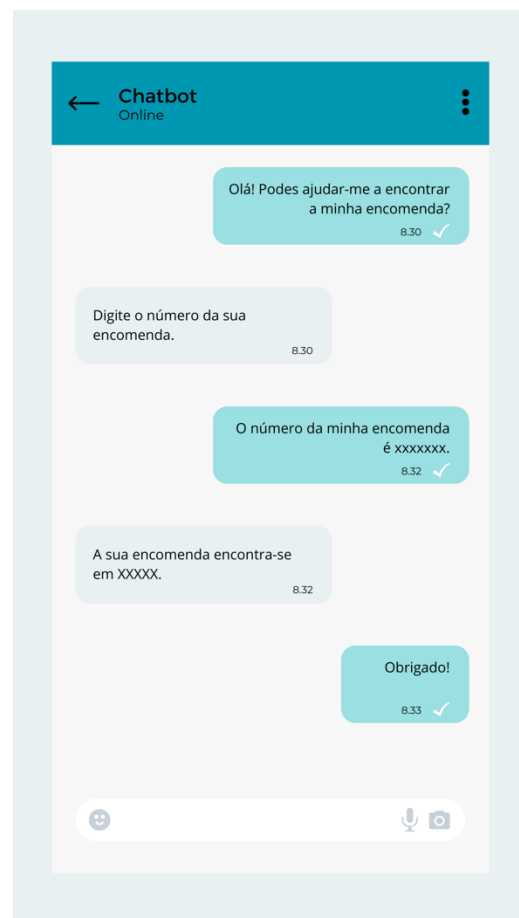


Figura 8- Cenário B: Chatbot com baixa empatia

Relativamente aos períodos de recolha de dados, o pré-teste foi realizado nos dias 18 e 19 de março do presente ano, enquanto a investigação recebeu participantes desde o dia 4 ao dia 22 de abril.

Para realizar as análises estatísticas dos dados, foi utilizado o SPSS (Statistical Package for the Social Science), onde foram realizadas análises de estatísticas descritivas, como médias e frequências, análises de correlações e análises multivariadas, ou seja, de variância e regressão.

4. Análise de dados

4.1. Pré-teste

Para percebermos a viabilidade do questionário, foi realizado um pré-teste, que reuniu 25 inquiridos. Desse grupo inicial, 12 responderam ao cenário com alta empatia e 13 responderam ao cenário com baixa empatia. Neste pré-teste, a média de idades foi de 26.64 anos, com 18 participantes do sexo feminino e 7 inquiridos que se identificam com o género masculino.

Nesta fase, também foi aplicado o teste de manipulação, no qual os inquiridos perceberam uma diferença significativa relativamente à empatia demonstrada pelo *chatbot* ($F= 38.28$, $p= 0.001$). Foi perceptível que existia um cenário com maiores níveis de empatia ($M= 4.50$, $SD= 1.00$) que o outro ($M= 2.23$, $SD= 0.83$).

Quanto às variáveis dependentes em estudo, os participantes apresentaram uma diferença significativa relativamente à satisfação que sentiram perante a resposta do *chatbot* ($F= 16.66$, $p= 0.001$), demonstrando-se mais satisfeitos com o cenário mais empático ($M= 4.44$, $SD= 0.51$), do que com o cenário menos empático ($M= 3.69$, $SD= 0.40$). O mesmo aconteceu com a lealdade ($F= 6.32$, $p= 0.019$), em que os inquiridos estavam mais dispostos a ser leais ao cenário mais empático ($M= 3.77$, $SD= 0.42$), comparativamente ao cenário com baixa empatia ($M= 3.29$, $SD= 0.53$). Quanto ao eWOM, os participantes não responderam de modo que fossem sentidas diferenças significativas entre ambos os cenários ($F= 2.93$, $p= 0.1$). Contudo, para a continuação do estudo, foi considerado relevante manter esta variável na investigação.

Tabela 1- Estatísticas descritivas do pré-teste

		N	Mean	Std. Deviation	Std. Error
Satisfação	Com empatia	12	3.6923	.39731	.11019
	Sem empatia	13	4.4375	.51262	.14798
	Total	25	4.0500	.58630	.11726
Lealdade	Com empatia	12	3.2885	.52882	.14667
	Sem empatia	13	3.7708	.41912	.12099

	Total	25	3.5200	.52994	.10599
Electronic Word of Mouth	Com empatia	12	2.6923	1.36396	.37830
	Sem empatia	13	1.9444	.67918	.19606
	Total	25	2.3333	1.13448	.22690

Tabela 2- Teste de significância do pré-teste

		Sum of Squares	df	Mean Square	F	Sig.
Satisfação	Entre grupos	3.465	1	3.465	16.656	<.001
	Dentro dos grupos	4.785	23	.208		
	Total	8.250	24			
Lealdade	Entre grupos	1.452	1	1.452	6.315	.019
	Dentro dos grupos	5.288	23	.230		
	Total	6.740	24			
Electronic Word of Mouth	Entre grupos	3.490	1	3.490	2.930	.100
	Dentro dos grupos	27.399	23	1.191		
	Total	30.889	24			

A aplicação deste pré-teste foi feita a uma amostra não probabilística de conveniência que, embora não represente toda a população, foi capaz de identificar diferenças entre os cenários. Deste modo, os resultados do pré-teste permitiram-nos avançar com a investigação, não tendo sido feitas quaisquer alterações aos cenários criados para simular a interação entre o *chatbot* e o utilizador, uma vez que a manipulação foi considerada notória.

4.2. Amostra

O processo de amostragem utilizado para esta investigação foi a amostra não probabilística de conveniência, uma vez que o questionário foi partilhado através de redes sociais pessoais, de modo a alcançar uma amostra acessível. É de reiterar que uma das principais características deste método de seleção é a não representação de toda a população.

Embora o estudo conte com uma questão relativa à frequência de utilização de agentes conversacionais, não foram excluídos quaisquer

participantes da investigação. Esta escolha justifica-se pelo facto de que estamos a medir uma capacidade social, isto é, a empatia, que não implica um conhecimento profundo do funcionamento deste tipo de tecnologias para ser reconhecida.

A amostra desta investigação contou com 108 participantes, em que 59 tiveram acesso ao cenário com alta empatia e os restantes 49 assistiram ao cenário menos empático. Da amostra, 75% responderam pertencer ao sexo feminino, enquanto 23,1% responderam ser do sexo masculino e 1.9% preferiram não responder à questão. Relativamente às idades, a média da mesma são 32.76 anos (SD= 13.12), sendo que 50 (46.3%) inquiridos tem até 24 anos, 24 (22.2%) têm entre os 25 e os 40 anos, 28 (25.9%) tem entre os 41 e os 55 anos e 6 (5.6%) têm mais de 55 anos. Relativamente à educação, 4 (3.7%) inquiridos concluíram o ensino básico, 24 (22.2%) têm o ensino secundário, 9 (8.3%) têm um grau técnico-profissional, 48 (44.4%) são licenciados, 22 (20.4%) concluíram o mestrado e 1 (0.9%) preferiu não responder à questão. Por fim, relativamente à ocupação, 32 (29.6%) são estudantes, 4 (3.7%) são trabalhadores-estudantes por conta própria, 18 (16.7%) são trabalhadores-estudantes por conta de outrem, 4 (3.7%) são trabalhadores por conta própria, 43 (39.8%) são trabalhadores por conta de outrem, 3 (2.8%) são desempregados, 2 (1.9%) são reformados e 2 (1.9%) preferiram não responder à questão.

Tabela 3- Frequências de géneros

Género	N	%
Feminino	81	75.0%
Masculino	25	23.1%
Prefiro não responder	2	1.9%

Tabela 4- Frequências de idades

Grupos de idade	N	%
Até 24 anos	50	46.3%
25 – 40 anos	24	22.2%
41 – 55 anos	28	25.9%
Mais de 55 anos	6	5.6%

Tabela 5- Frequências de educação

Educação	N	%
Ensino básico	4	3.7%
Ensino secundário	24	22.2%
Ensino técnico-profissional	9	8.3%
Licenciatura	48	44.4%
Mestrado	22	20.4%
Prefiro não responder	1	0.9%

Tabela 6- Frequências de ocupação

Ocupação	N	%
Estudante	32	29.6%
Trabalhador-estudante por conta própria	4	3.7%
Trabalhador-estudante por conta de outrem	18	16.7%
Trabalhador por conta própria	4	3.7%
Trabalhador por conta de outrem	43	39.8%
Desempregado	3	2.8%
Reformado	2	1.9%
Prefiro não responder	2	1.9%

4.3. Análise da confiabilidade das escalas

Para analisar a precisão do questionário aplicado, foi realizada uma análise ao Alpha de Cronbach, cujo coeficiente varia entre 0 e 1, e quanto mais próximo de 1, maior o nível de confiabilidade do questionário. Posteriormente, os valores podem ser qualitativamente agrupados, considerando-se que valores inferiores a 0,5 são inaceitáveis e que, por isso, o estudo não deve continuar, valores entre 0,5 e 0,7 são considerados valores médios, de 0,7 a 0,8 são valores bons, de 0,8 a 0,9 são valores ótimos e acima de 0,9 são considerados valores excelentes (Gliem & Gliem, 2003).

Relativamente às variáveis de controlo, isto é, *warmth*, competência e percepção de risco, as escalas utilizadas demonstraram valores ótimos e excelentes de confiabilidade.

Tabela 7- Valores do Alpha de Cronbach das variáveis de controlo

Variáveis de controlo	Alpha de Cronbach	Número de itens
<i>Warmth</i>	.885	3
Competência	.906	3
Percepção de risco	.861	3

Os valores apresentados demonstram a confiabilidade das escalas utilizadas e permitiram dar continuidade ao estudo, sendo de destacar os resultados excelentes do eWOM e da Satisfação.

Tabela 8- Valores do Alpha de Cronbach das variáveis dependentes

Variáveis dependentes	Alpha de Cronbach	Número de itens
Satisfação	.868	4
Lealdade	.638	4
<i>Electronic Word of Mouth</i>	.939	3

Por fim, as escalas utilizadas para medir as variáveis mediadoras, confiança, *self-disclosure* e apego afetivo, também apresentaram valores de confiabilidade que permitiram continuar o estudo.

Tabela 9- Valores do Alpha de Cronbach das variáveis mediadoras

Variáveis mediadoras	Alpha de Cronbach	Número de itens
Confiança	.765	4
<i>Self-disclosure</i>	.885	3
Apego afetivo	.956	3

4.4. Análise do teste de manipulação

A questão de manipulação foi aplicada de modo a analisar se os inquiridos percebiam que existia um cenário de alta empatia e um cenário de baixa empatia. Os participantes sentiram uma diferença significativa entre os cenários ($F = 35.07$, $p = 0.001$), sendo notória a empatia no cenário mais empático ($M = 4.00$, $SD = 1.03$) relativamente ao cenário menos empático ($M = 2.73$, $SD = 1.19$). Deste modo, confirmamos que a presença de empatia e a falta da mesma, respetivamente, foram sentidas pelos participantes, permitindo a continuação do estudo.

Tabela 10- Estatísticas descritivas do teste de manipulação

	N	Mean	Std. Deviation	Std. Error
Com empatia	59	4.00	1.034	.135
Sem empatia	49	2.73	1.186	.169
Total	108	3.43	1.269	.122

Tabela 11- Teste de significância do teste de manipulação

	Sum of Squares	df	Mean Square	F	Sig.
Entre grupos	42.856	1	42.856	35.066	<.001
Dentro dos grupos	129.551	106	1.222		
Total	172.407	107			

4.5. Análise das variáveis de controlo

Para a realização do estudo, foram utilizadas variáveis de controlo para percebermos se os participantes notavam diferenças entre os cenários utilizados. As variáveis utilizadas foram a perceção de risco (Hayes et al., 2021), *warmth* e competência (Y. Li et al., 2023).

No que diz respeito ao *warmth*, os inquiridos notaram diferenças entre os cenários ($F = 65.39$, $p = 0.001$), sendo que o cenário com alta empatia foi considerado mais caloroso e próximo do participante ($M = 3.98$, $SD = 0.71$), que o cenário com baixa empatia ($M = 2.69$, $SD = 0.94$). Esta abordagem era

espectável, uma vez que a empatia e o *warmth* são abordadas por muitos quando o tema são as capacidades sociais.

Contudo, não houve diferenças significativas na percepção de risco ($F= 0.005$, $p= 0.941$) nem na percepção de competência ($F= 0.068$, $p= 0.795$). Isto demonstra que os participantes na investigação não consideram relevante a integração de empatia nos *chatbots* para o desempenho das suas tarefas. É importante apontar que, no caso da competência, os utilizadores notam que ambos os cenários são competentes ($M= 4.22$, $SD= 0.69$), enquanto na percepção de risco os inquiridos se demonstram mais reticentes com a partilha de informação com o *chatbot* ($M= 2.66$, $SD= 0.87$).

Tabela 12- Estatísticas descritivas das variáveis de controlo

		N	Mean	Std. Deviation	Std. Error
Warmth	Com empatia	59	3.9774	.70809	.09219
	Sem empatia	49	2.6939	.93995	.13428
	Total	108	3.3951	1.03936	.10001
Competência	Com empatia	59	4.2147	.72915	.09493
	Sem empatia	49	4.2245	.63606	.09087
	Total	108	4.2191	.68535	.06595
Percepção de risco	Com empatia	59	2.6836	.91690	.11937
	Sem empatia	49	2.6395	.82730	.11819
	Total	108	2.6636	.87363	.08407

Tabela 13- Teste de significância das variáveis de controlo

		Sum of Squares	df	Mean Square	F	Sig.
Warmth	Entre grupos	44.099	1	44.099	65.388	<.001
	Dentro dos grupos	71.489	106	.674		
	Total	115.588	107			
Competência	Entre grupos	.003	1	.003	.005	.941
	Dentro dos grupos	50.256	106	.474		
	Total	50.258	107			
	Entre grupos	.052	1	.052	.068	.795

Percepção de risco	Dentro dos grupos	81.613	106	.770		
	Total	81.666	107			

É de notar que nenhuma das variáveis de controlo foi adicionada ao modelo conceptual da presente investigação. Esta escolha deve-se ao facto de, tal como verificado anteriormente, apenas termos conseguido mostrar a significância de uma das variáveis. Uma vez que *warmth* é também considerada uma das principais características inerentes à percepção de empatia, não foi considerado relevante incluí-la no modelo em estudo.

4.6. Estudo das variáveis dependentes

Relativamente à satisfação, foram notadas diferenças entre ambos os cenários ($F= 13.21$, $p= 0.001$), uma vez que os participantes que tiveram acesso ao cenário em que o chatbot tinha maior empatia apresentaram maiores níveis de satisfação ($M= 3.97$, $SD= 0.67$) que os inquiridos que experienciaram o cenário sem empatia ($M= 3.44$, $SD= 0.85$). Assim, confirmamos H1.

Quanto à lealdade, os inquiridos não notaram diferenças significativas entre ambos os cenários ($F= 3.42$, $p= 0.067$), refutando H2.

Por fim, quanto à intenção de fazer *electronic word of mouth*, os participantes notaram diferenças significativas entre os cenários ($F= 4.77$, $p= 0.031$), tendo uma maior intenção de fazer eWOM no cenário empático ($MD= 3.73$, $SD= 0.82$), do que no cenário não empático ($MD= 3.37$, $SD= 0.89$). Posto isto, aceitamos H3.

Tabela 14- Estatísticas descritivas das variáveis dependentes

		N	Mean	Std. Deviation	Std. Error
Satisfação	Com empatia	59	3.9703	.66644	.08676
	Sem empatia	49	3.4388	.85320	.12189
	Total	108	3.7292	.79875	.07686
Lealdade	Com empatia	59	3.4915	.67109	.08737
	Sem empatia	49	3.2551	.65050	.09293
	Total	108	3.3843	.66927	.06440

Electronic Word of Mouth	Com empatia	59	3.7345	.82066	.10684
	Sem empatia	49	3.3741	.89140	.12734
	Total	108	3.5710	.86833	.08356

Tabela 15- Teste de significância das variáveis dependentes

		Sum of Squares	df	Mean Square	F	Sig.
Satisfação	Entre grupos	7.564	1	7.564	13.208	<.001
	Dentro dos grupos	60.702	106	.573		
	Total	68.266	107			
Lealdade	Entre grupos	1.496	1	1.496	3.416	.067
	Dentro dos grupos	46.432	106	.438		
	Total	47.928	107			
Electronic Word of Mouth	Entre grupos	3.475	1	3.475	4.772	.031
	Dentro dos grupos	77.203	106	.728		
	Total	80.678	107			

4.7. Estudo das variáveis mediadoras

No que diz respeito às variáveis mediadoras, não foram verificadas diferenças significativas entre os cenários relativamente à confiança ($F = 3.74$, $p = 0.06$) nem ao *self-disclosure* ($F = 0.30$, $p = 0.58$). No entanto, os participantes demonstraram um maior apego afetivo para com um dos cenários ($F = 5.96$, $p = 0.016$), sendo este a interação em que o *chatbot* teve uma abordagem mais empática ($M = 2.19$, $SD = 1.02$) em detrimento do cenário contrário ($M = 1.71$, $SD = 0.98$).

Tabela 16- Estatísticas descritivas das variáveis mediadoras

		N	Mean	Std. Deviation	Std. Error
Confiança	Com empatia	59	3.7754	.62231	.08102
	Sem empatia	49	3.5510	.57278	.08183
	Total	108	3.6736	.60802	.05851
Self-disclosure	Com empatia	59	2.4859	.95557	.12440
	Sem empatia	49	2.5918	1.04364	.14909

	Total	108	2.5340	.99316	.09557
Sem empatia	Sem empatia	59	2.1864	1.01949	.13273
	Sem empatia	49	1.7143	.97658	.13951
	Total	108	1.9722	1.02322	.09846

Tabela 17- Teste de significância das variáveis mediadoras

		Sum of Squares	df	Mean Square	F	Sig.
Confiança	Entre grupos	1.348	1	1.348	3.740	.056
	Dentro dos grupos	38.209	106	.360		
	Total	39.557	107			
Self-disclosure	Entre grupos	.301	1	.301	.303	.583
	Dentro dos grupos	105.242	106	.993		
	Total	105.542	107			
Apego Afetivo	Entre grupos	5.968	1	5.968	5.964	.016
	Dentro dos grupos	106.060	106	1.001		
	Total	112.028	107			

Deste modo, apenas será analisado o efeito mediador do apego afetivo na investigação, sendo descartadas as variáveis *self-disclosure* e confiança. Para além disso, tal como verificamos anteriormente, apenas duas das variáveis dependentes demonstraram resultados significativos. Posto isto, iremos analisar se o apego afetivo tem efeito mediador entre a nossa variável independente, isto é, as capacidades sociais dos agentes conversacionais, e as nossas variáveis dependentes, a satisfação e o *electronic word of mouth*. Para verificar esta mediação, foi utilizado o modelo 4 da Macro Process no SPSS.




Figura 10- Modelo de mediação em análise

Relativamente à satisfação, percebemos que o efeito indireto do apego afetivo não é significativo ($\beta = -0.07$, CI de -0.20 a 0.03). O mesmo acontece ao analisarmos a mediação do apego afetivo quando temos o *electronic word of mouth* como variável dependente ($\beta = -0.09$, CI de -0.25 a 0.01). Concluímos, assim, que não foi verificado nenhum efeito de mediação.

5. Conclusão

Com base em toda a revisão literária e análises de dados, podemos concluir que foram confirmadas apenas duas das hipóteses iniciais, sendo rejeitadas as restantes quatro. Deste modo, provamos o efeito direto das capacidades sociais dos agentes conversacionais, com foco na empatia, na satisfação e no *electronic word of mouth*. Quanto à lealdade, não foi provada que seja impactada pela variável independente considerada. Relativamente às variáveis mediadoras, também não foi possível confirmar que tenham um efeito indireto e moderador no modelo em estudo.

H1	Chatbots com capacidades sociais de empatia têm um impacto positivo na satisfação do consumidor.	Confirmada
H2	Chatbots com capacidades sociais de empatia têm um impacto positivo na lealdade do consumidor.	Rejeitada
H3	Chatbots com capacidades sociais de empatia têm um impacto positivo no eWOM.	Confirmada
H4	A confiança medeia a relação entre capacidades sociais dos chatbots e satisfação (a), lealdade (b) e eWOM (c).	Rejeitada
H5	O <i>self-disclosure</i> medeia a relação entre capacidades sociais dos chatbots e satisfação (a), lealdade (b) e eWOM (c).	Rejeitada
H6	O apego afetivo medeia a relação entre capacidades sociais dos chatbots e satisfação (a), lealdade (b) e eWOM (c).	Rejeitada

Figura 11- Sintetização dos resultados das análises de hipóteses

5.1. Implicações e contributos teóricos

Embora a amostra utilizada no presente estudo não tenha confirmado algumas das hipóteses, podemos considerar que este se distingue dos demais por várias razões. A investigação foi focada apenas numa capacidade social, a empatia, que foi representada, de acordo com alguns estudos, com saudações e *feedbacks* (Pentina, Xie, et al., 2023). Foram utilizadas variáveis

que, ao longo de vários estudos, demonstraram ligações essenciais para a conceptualização das mesmas, como a confiança e o *self-disclosure*, a satisfação e a lealdade, o eWOM e a confiança.

Primeiramente, este estudo agrupou três variáveis consideradas relevantes para medir a experiência do consumidor, satisfação, lealdade e eWOM. Posteriormente, foram também consideradas três variáveis importantes para a criação de relações, principalmente no contexto humano – *chatbot*, sendo estas a confiança, o *self-disclosure* e o apego afetivo, que podiam ter um efeito indireto na experiência do consumidor.

Embora alguns estudos tenham revelado uma conexão entre os sentimentos de lealdade e satisfação (Gunawan, 2022), podem existir muitos outros fatores que acabam por afastar estas variáveis. Isto é, embora a interação apresentada tenha confirmado as expectativas dos participantes, ou seja, gerado satisfação, não foi suficiente para despertar o interesse em criar uma relação de longo prazo, que se converte em lealdade.

Relativamente ao *self-disclosure*, uma das variáveis que não comprovou os resultados esperados, podemos afirmar que a interação apresentada não foi considerada relevante para os participantes no que diz respeito à partilha de informações. Tal como foi apresentado ao longo da revisão literária desta investigação, o *self-disclosure* faz com que os indivíduos ponderem sobre os custos e benefícios que teriam em partilhar informações (Al-Natour et al., 2021), o que não foi necessário em nenhum dos cenários apresentados, uma vez que se baseavam na partilha de informações básicas e não em dados pessoais, que possam colocar em causa a privacidade de um utilizador (Adjerid et al., 2018; Al-Natour et al., 2020; Buckman et al., 2019). Assim, conseguimos perceber que tópicos como a privacidade e confiança sejam mais relevantes para que exista *self-disclosure*.

Quanto ao apego afetivo, tal como revisto por alguns autores como Bilal et al. (2024), verificamos que o mesmo pode existir em relações entre humanos e agentes conversacionais, contudo, no presente estudo, não como mediador, mas sim com efeito direto, quando estamos na presença de interações empáticas entre *chatbots* e seres humanos.

5.2. Implicações práticas e empresariais

Em termos numéricos, espera-se que a utilização de IA num contexto empresarial tenha um aumento de 10.1 mil milhões de dólares americanos, em 2018, para 126 mil milhões de dólares americanos, até 2025 (Vlačić et al., 2021). Contudo é importante reforçar que neste estudo, quando referimos a capacidade de agentes tecnológicos serem dotados de empatia, estamos a recorrer a inteligência artificial generativa, que pode não ser o principal foco das empresas quando pensam em implementar IA nas suas operações. Para além disso, o impacto estudado é focado na experiência do consumidor, isto é, nas aplicações que pode ter em áreas como o apoio ao cliente e áreas do marketing como o marketing relacional e experiencial.

Ainda assim, é necessário ter em atenção que este tipo de tecnologia apenas é possível com um esforço humano técnico de implementação, não só para a criação da mesma, como para a sua testagem e, se necessária, manutenção. No processo de criação, devem ser consideradas todas as áreas de negócio abrangidas pela empresa, com principal ênfase nas que estão diretamente ligadas ao consumidor, pois essas serão as que irão ter maior impacto na sua experiência.

Um plano de ação deve passar por reunir as principais questões respondidas pelo apoio ao cliente, passando por uma análise de sentimento do mesmo, e ainda uma recolha pormenorizada de todos os produtos e/ou serviços inerentes à organização. Após uma listagem de todos os aspetos operacionais, devem ser definidos temas como a forma de comunicação com os clientes, englobando conceitos como o tom de comunicação. É de reiterar que este deve ser considerado um dos pontos mais relevantes quando o objetivo é a representação de capacidades sociais, pois será através da forma como o *chatbot* comunica e interage com o utilizador que este terá a perceção de qualquer tipo de competência social, como a empatia.

Para a representação da empatia, e à semelhança do que foi apresentado na análise de literatura, devem ser utilizadas saudações que podem ser elevadas através da pontuação utilizada; um tom informal também poderá ser essencial para a criação de um cenário de proximidade; podem ser adicionadas informações que, embora não tenham sido inicialmente

requeridas pelo cliente, podem ser consideradas úteis e que enriquecerão a sua experiência; o agente conversacional deve questionar se o utilizador tem outro tipo de questões a ser respondidas, entre outros.

Com o desenvolvimento tecnológico a que temos assistido nos últimos anos, principalmente no contexto internacional, é necessário considerar que uma simples interação com inteligência artificial pode ser vista como obsoleta e pouco relevante para os consumidores. Se o objetivo é transformar a experiência do consumidor, é necessário fazer implementações que façam com que o *chatbot* deixe de ser visto como uma mera tecnologia e passe a ser recebido como um agente que colabora com as empresas e cuja finalidade é apoiar o utilizador. Vivemos numa era em que a difusão de informação é extremamente rápida e pouco controlada, por isso, se as empresas procuram criar e manter relações de longo prazo, é essencial que evoluam juntamente com a sociedade e que aloquem os seus esforços para um serviço ao cliente eficiente e otimizado.

5.3. Limitações e estudos futuros

Na recolha de informação para o estudo, deparamo-nos com uma falta de casos específicos no contexto português, embora a investigação não fosse limitada ao país em questão. A criação dos cenários passou pela testagem de alguns agentes conversacionais, como o Google Bard, Bing Chat, ChatGPT e Helena (CTT), de modo a percebermos como estes *chatbots* interagem em diferentes contextos e que tipo de comunicação utilizam, principalmente devido ao tipo de amostra escolhido. A maioria destas ferramentas responde em português do Brasil, o que dificulta a criação de cenários precisos e significantes para a amostra considerada.

O tipo de amostra selecionado também foi considerado uma limitação ao longo da realização da análise de dados. Sendo uma amostra não probabilística de conveniência, não é uma amostra considerada representativa da população.

Assim, em estudos futuros, deve ser utilizada uma amostra probabilística. Em jeito de sugestão, uma amostra probabilística aleatória simples irá trazer

resultados representativos da população. Para além disso, seria interessante fazer uma comparação entre os resultados de duas amostras probabilísticas aleatórias sistemáticas com base na frequência de utilização de *chatbots* que operam com base em inteligência artificial generativa. Deste modo, seria possível perceber se indivíduos que utilizam com grande frequência este tipo de tecnologias responderiam com maiores níveis de significância a certas variáveis, quando comparados com utilizadores que recorrem com menos frequência a estes agentes conversacionais.

Para além disso, poderia ser realizado um caso de estudo aplicado a uma empresa que já tem este tipo de tecnologia implementada. Os participantes seriam clientes que constam nas bases de dados da empresa em questão. A sugestão passa pela aplicação de cenários baseados naqueles criados para esta investigação, isto é, um com altos níveis de empatia e outro com baixos níveis da mesma capacidade, independentemente do tom de comunicação utilizado pela empresa. Assim, as equipas da mesma poderiam ter uma ideia relativamente ao impacto que estas capacidades poderiam ter no seu negócio e nas relações com os clientes.

A simulação criada, embora tenha tido resultados positivos no teste de manipulação, pode ter sido considerado curta para responder a certas variáveis em estudo. Algumas das sugestões para estudos futuros passam pela partilha de informações mais pessoais, para que se possa analisar de forma mais precisa o *self-disclosure* e confiança; uma interação mais longa e com mais detalhes também pode ajudar a obter outros resultados no que diz respeito à lealdade, tentando passar a ideia da existência de uma relação, prévia à interação, entre o cliente e a empresa.

Referências Bibliográficas

- Adamopoulou, E., & Moussiades, L. (2020). An overview of chatbot technology. *IFIP International Conference on Artificial Intelligence Applications and Innovations*, 373–383.
- Adjerid, I., Peer, E., & Acquisti, A. (2018). Beyond the privacy paradox: Objective versus relative risk in privacy decision making. *MIS Quarterly*, 42(2), 465–488.
- Al-Natour, S., Benbasat, I., & Cenfetelli, R. (2011). The adoption of online shopping assistants: Perceived similarity as an antecedent to evaluative beliefs. *Journal of the Association for Information Systems*, 12(5), 2.
- Al-Natour, S., Benbasat, I., & Cenfetelli, R. (2021). Designing online virtual advisors to encourage customer self-disclosure: a theoretical model and an empirical test. *Journal of Management Information Systems*, 38(3), 798–827.
- Al-Natour, S., Cavusoglu, H., Benbasat, I., & Aleem, U. (2020). An empirical investigation of the antecedents and consequences of privacy uncertainty in the context of mobile apps. *Information Systems Research*, 31(4), 1037–1063.
- Alpaydin, E. (2016). *Machine learning: the new AI*. MIT press.
- Antaki, C., Barnes, R., & Leudar, I. (2005). Self-disclosure as a situated interactional practice. *British Journal of Social Psychology*, 44(2), 181–199.
- Araujo, T. (2018). Living up to the chatbot hype: The influence of anthropomorphic design cues and communicative agency framing on conversational agent and company perceptions. *Computers in Human Behavior*, 85, 183–189.
- Armstrong, G., Adam, S., Denize, S., & Kotler, P. (2014). *Principles of marketing*. Pearson Australia.
- Ashfaq, M., Yun, J., Yu, S., & Loureiro, S. M. C. (2020). I, Chatbot: Modeling the determinants of users' satisfaction and continuance intention of AI-powered service agents. *Telematics and Informatics*, 54, 101473.
- Augusto, M., & Torres, P. (2018). Effects of brand attitude and eWOM on consumers' willingness to pay in the banking industry: Mediating role of

- consumer-brand identification and brand equity. *Journal of Retailing and Consumer Services*, 42, 1–10.
- Awad, N. F., & Krishnan, M. S. (2006). The personalization privacy paradox: an empirical evaluation of information transparency and the willingness to be profiled online for personalization. *MIS Quarterly*, 13–28.
- Ba, S., & Pavlou, P. A. (2002). Evidence of the effect of trust building technology in electronic markets: Price premiums and buyer behavior. *MIS Quarterly*, 243–268.
- Babin, B. J., Lee, Y., Kim, E., & Griffin, M. (2005). Modeling consumer satisfaction and word-of-mouth: restaurant patronage in Korea. *Journal of Services Marketing*, 19(3), 133–139.
- Belda-Medina, J., & Calvo-Ferrer, J. R. (2022). Using chatbots as AI conversational partners in language learning. *Applied Sciences*, 12(17), 8427.
- Bigras, É., Léger, P.-M., & Sénécal, S. (2019). Recommendation agent adoption: how recommendation presentation influences employees' perceptions, behaviors, and decision quality. *Applied Sciences*, 9(20), 4244.
- Bilal, M., Zhang, Y., Cai, S., Akram, U., & Halibas, A. (2024). Artificial intelligence is the magic wand making customer-centric a reality! An investigation into the relationship between consumer purchase intention and consumer engagement through affective attachment. *Journal of Retailing and Consumer Services*, 77, 103674.
- Bleier, A., Harmeling, C. M., & Palmatier, R. W. (2019). Creating effective online customer experiences. *Journal of Marketing*, 83(2), 98–119.
- Bornet, P., Barkin, I., & Wirtz, J. (2021). *Intelligent automation: Welcome to the world of hyperautomation: learn how to harness artificial intelligence to boost business & make our world more human*. World Scientific.
- Buckman, J. R., Bockstedt, J. C., & Hashim, M. J. (2019). Relative privacy valuations under varying disclosure characteristics. *Information Systems Research*, 30(2), 375–388.
- Bughin, J., Hazan, E., Sree Ramaswamy, P., DC, W., & Chu, M. (2017). *Artificial intelligence the next digital frontier*.

- Caravita, S. C. S., Di Blasio, P., & Salmivalli, C. (2009). Unique and interactive effects of empathy and social status on involvement in bullying. *Social Development, 18*(1), 140–163.
- Chattaraman, V., Kwon, W.-S., Gilbert, J. E., & Ross, K. (2019). Should AI-Based, conversational digital assistants employ social-or task-oriented interaction style? A task-competency and reciprocity perspective for older adults. *Computers in Human Behavior, 90*, 315–330.
- Chaves, A. P., & Gerosa, M. A. (2021). How should my chatbot interact? A survey on social characteristics in human–chatbot interaction design. *International Journal of Human–Computer Interaction, 37*(8), 729–758.
- Chen, J., Teng, L., Yu, Y., & Yu, X. (2016). The effect of online information sources on purchase intentions between consumers with high and low susceptibility to informational influence. *Journal of Business Research, 69*(2), 467–475.
- Chen, J.-S., Le, T.-T.-Y., & Florence, D. (2021). Usability and responsiveness of artificial intelligence chatbot on online customer experience in e-retailing. *International Journal of Retail & Distribution Management, 49*(11), 1512–1531.
- Cheung, C. M. K., & Thadani, D. R. (2012). The impact of electronic word-of-mouth communication: A literature analysis and integrative model. *Decision Support Systems, 54*(1), 461–470.
- Chi, O. H., Jia, S., Li, Y., & Gursoy, D. (2021). Developing a formative scale to measure consumers' trust toward interaction with artificially intelligent (AI) social robots in service delivery. *Computers in Human Behavior, 118*, 106700.
- Chowdhary, K., & Chowdhary, K. R. (2020). Natural language processing. *Fundamentals of Artificial Intelligence, 603–649*.
- Chung, M., Ko, E., Joung, H., & Kim, S. J. (2020). Chatbot e-service and customer satisfaction regarding luxury brands. *Journal of Business Research, 117*, 587–595.
- Collier, J. E., & Kimes, S. E. (2013). Only if it is convenient: Understanding how convenience influences self-service technology evaluation. *Journal of Service Research, 16*(1), 39–51.

- Cook, J., & Wall, T. (1980). New work attitude measures of trust, organizational commitment and personal need non-fulfilment. *Journal of Occupational Psychology*, 53(1), 39–52.
- Cropanzano, R., & Mitchell, M. S. (2005). Social exchange theory: An interdisciplinary review. *Journal of Management*, 31(6), 874–900.
- Dagger, T. S., David, M. E., & Ng, S. (2011). Do relationship benefits and maintenance drive commitment and loyalty? *Journal of Services Marketing*, 25(4), 273–281.
- Darwiche, A. (2018). Human-level intelligence or animal-like abilities? *Communications of the ACM*, 61(10), 56–67.
- Davenport, T., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, 48, 24–42.
- Davenport, T. H., & Ronanki, R. (2018). Artificial intelligence for the real world. *Harvard Business Review*, 96(1), 108–116.
- De Bruyn, A., Viswanathan, V., Beh, Y. S., Brock, J. K.-U., & Von Wangenheim, F. (2020). Artificial intelligence and marketing: Pitfalls and opportunities. *Journal of Interactive Marketing*, 51(1), 91–105.
- De Cicco, R., Silva, S. C., & Alparone, F. R. (2020). Millennials' attitude toward chatbots: an experimental study in a social relationship perspective. *International Journal of Retail & Distribution Management*, 48(11), 1213–1233.
- Feine, J., Gnewuch, U., Morana, S., & Maedche, A. (2019). A taxonomy of social cues for conversational agents. *International Journal of Human-Computer Studies*, 132, 138–161.
- Fernandes, T., & Oliveira, E. (2021). Understanding consumers' acceptance of automated technologies in service encounters: Drivers of digital voice assistants adoption. *Journal of Business Research*, 122, 180–191.
- Finn, S. E. (2009). The many faces of empathy in experiential, person-centered, collaborative assessment. *Journal of Personality Assessment*, 91(1), 20–23.
- Følstad, A., & Brandtzaeg, P. B. (2020). Users' experiences with chatbots: findings from a questionnaire study. *Quality and User Experience*, 5(1), 3.

- Fournier, S. (1998). Consumers and their brands: Developing relationship theory in consumer research. *Journal of Consumer Research*, 24(4), 343–373.
- Francis, T., & Hoefel, F. (2018). True Gen': Generation Z and its implications for companies. *McKinsey & Company*, 12, 1–10.
- Gliem, J. A., & Gliem, R. R. (2003). Calculating, interpreting, and reporting Cronbach's alpha reliability coefficient for Likert-type scales. *Midwest Research-to-Practice Conference in Adult, Continuing, and Community Education*, 1, 82–87.
- Greene, K., Derlega, V. J., & Mathews, A. (2006). Self-disclosure in personal relationships. *The Cambridge Handbook of Personal Relationships*, 409, 427.
- Gunawan, I. (2022). CUSTOMER LOYALTY: The Effect Customer Satisfaction, Experiential Marketing and Product Quality. *KINERJA: Jurnal Manajemen Organisasi Dan Industri*, 1(1), 35–50.
- Gursoy, D., Chi, O. H., Lu, L., & Nunkoo, R. (2019). Consumers acceptance of artificially intelligent (AI) device use in service delivery. *International Journal of Information Management*, 49, 157–169.
- Gvili, Y., & Levy, S. (2021). Consumer engagement in sharing brand-related information on social commerce: the roles of culture and experience. *Journal of Marketing Communications*, 27(1), 53–68.
- Hair, J. F. (2009). *Multivariate data analysis*.
- Hayes, J. L., Brinson, N. H., Bott, G. J., & Moeller, C. M. (2021). The influence of consumer–brand relationship on the personalized advertising privacy calculus in social media. *Journal of Interactive Marketing*, 55(1), 16–30.
- Hennig-Thurau, T., Gwinner, K. P., Walsh, G., & Gremler, D. D. (2004). Electronic word-of-mouth via consumer-opinion platforms: what motivates consumers to articulate themselves on the internet? *Journal of Interactive Marketing*, 18(1), 38–52.
- Hodges, S. D., & Wegner, D. M. (1997). *Automatic and controlled empathy*.
- Hsiao, K.-L., & Chen, C.-C. (2016). What drives in-app purchase intention for mobile games? An examination of perceived values and loyalty. *Electronic Commerce Research and Applications*, 16, 18–29.

- Huang, M.-H., & Rust, R. T. (2018). Artificial intelligence in service. *Journal of Service Research*, 21(2), 155–172.
- Huang, M.-H., & Rust, R. T. (2021). A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science*, 49, 30–50.
- Hui, K.-L., Tan, B. C. Y., & Goh, C.-Y. (2006). Online information disclosure: Motivators and measurements. *ACM Transactions on Internet Technology (TOIT)*, 6(4), 415–441.
- Iglesias, O., Markovic, S., Bagherzadeh, M., & Singh, J. J. (2020). Co-creation: A key link between corporate social responsibility, customer trust, and customer loyalty. *Journal of Business Ethics*, 163, 151–166. <https://link.springer.com/article/10.1007/s10551-018-4015-y>
- Iglesias, O., Markovic, S., & Rialp, J. (2019). How does sensory brand experience influence brand equity? Considering the roles of customer satisfaction, customer affective commitment, and employee empathy. *Journal of Business Research*, 96, 343–354.
- Isbister, K., & Nass, C. (2000). Consistency of personality in interactive characters: verbal cues, non-verbal cues, and user characteristics. *International Journal of Human-Computer Studies*, 53(2), 251–267.
- Jain, M., Kota, R., Kumar, P., & Patel, S. N. (2018). Convey: Exploring the use of a context view for chatbots. *Proceedings of the 2018 Chi Conference on Human Factors in Computing Systems*, 1–6.
- Jamieson, P., Fisher, K., Gilding, T., Taylor, P. G., & Trevitt, A. C. F. (2000). Place and space in the design of new learning environments. *Higher Education Research & Development*, 19(2), 221–236.
- Jarek, K., & Mazurek, G. (2019). Marketing and artificial intelligence. *Central European Business Review*, 8 (2), 46–55.
- Jiang, Q., Zhang, Y., & Pian, W. (2022). Chatbot as an emergency exist: Mediated empathy for resilience via human-AI interaction during the COVID-19 pandemic. *Information Processing & Management*, 59(6), 103074.

- Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, 62(1), 15–25.
- Ki, C.-W. C., Cuevas, L. M., Chong, S. M., & Lim, H. (2020). Influencer marketing: Social media influencers as human brands attaching to followers and yielding positive marketing results by fulfilling needs. *Journal of Retailing and Consumer Services*, 55, 102133.
- Kim, W. G., Lim, H., & Brymer, R. A. (2015). The effectiveness of managing social media on hotel performance. *International Journal of Hospitality Management*, 44, 165–171.
- Klein, K., & Martinez, L. F. (2023). The impact of anthropomorphism on customer satisfaction in chatbot commerce: an experimental study in the food sector. *Electronic Commerce Research*, 23(4), 2789–2825.
- Kumar, V., Rajan, B., Venkatesan, R., & Lecinski, J. (2019). Understanding the role of artificial intelligence in personalized engagement marketing. *California Management Review*, 61(4), 135–155.
- Lankton, N., McKnight, D. H., & Thatcher, J. B. (2014). Incorporating trust-in-technology into Expectation Disconfirmation Theory. *The Journal of Strategic Information Systems*, 23(2), 128–145.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Lee, K. M., & Nass, C. (2003). Designing social presence of social actors in human computer interaction. *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, 289–296.
- Lee, W.-H., Lin, C.-W., & Shih, K.-H. (2018). A technology acceptance model for the perception of restaurant service robots for trust, interactivity, and output quality. *International Journal of Mobile Communications*, 16(4), 361–376.
- Legg, S., & Hutter, M. (2007). A collection of definitions of intelligence. *Frontiers in Artificial Intelligence and Applications*, 157, 17.
- Leiberg, S., & Anders, S. (2006). The multiple facets of empathy: a survey of theory and evidence. *Progress in Brain Research*, 156, 419–440.

- Li, H., Chen, Q., Zhong, Z., Gong, R., & Han, G. (2022). E-word of mouth sentiment analysis for user behavior studies. *Information Processing & Management*, 59(1), 102784.
- Li, N., & Zhang, P. (2002). Consumer online shopping attitudes and behavior: An assessment of research. *AMCIS 2002 Proceedings*, 74.
- Li, Y., Song, X., & Zhou, M. (2023). Impacts of brand digitalization on brand market performance: the mediating role of brand competence and brand warmth. *Journal of Research in Interactive Marketing*, 17(3), 398–415.
- Lim, W. M., & Ting, D. H. (2012). E-shopping: An analysis of the uses and gratifications theory. *Modern Applied Science*, 6(5), 48.
- Liu, B., & Sundar, S. S. (2018). Should machines express sympathy and empathy? Experiments with a health advice chatbot. *Cyberpsychology, Behavior, and Social Networking*, 21(10), 625–636.
- Luger, E., & Sellen, A. (2016). " Like Having a Really Bad PA" The Gulf between User Expectation and Experience of Conversational Agents. *Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems*, 5286–5297.
- Ma, L., & Sun, B. (2020). Machine learning and AI in marketing–Connecting computing power to human insights. *International Journal of Research in Marketing*, 37(3), 481–504.
- MacDorman, K. F., & Entezari, S. O. (2015). Individual differences predict sensitivity to the uncanny valley. *Interaction Studies*, 16(2), 141–172.
- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. [Internet], 9(1), 381–386.
- Markovic, S., Iglesias, O., Singh, J. J., & Sierra, V. (2018). How does the perceived ethicality of corporate services brands influence loyalty and positive word-of-mouth? Analyzing the roles of empathy, affective commitment, and perceived quality. *Journal of Business Ethics*, 148, 721–740.
- Mattison Thompson, F., & Siamagka, N. (2022). Counteracting consumer subversion: Organizational privacy ethical care as driver of online information sharing. *Psychology & Marketing*, 39(3), 579–597.

- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI Magazine*, 27(4), 12.
- McKnight, D. H., Choudhury, V., & Kacmar, C. (2002). Developing and validating trust measures for e-commerce: An integrative typology. *Information Systems Research*, 13(3), 334–359.
- McKnight, D. H., Cummings, L. L., & Chervany, N. L. (1998). Initial trust formation in new organizational relationships. *Academy of Management Review*, 23(3), 473–490.
- Molla, A., & Licker, P. S. (2001). E-commerce systems success: An attempt to extend and respecify the Delone and MacLean model of IS success. *J. Electron. Commer. Res.*, 2(4), 131–141.
- Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*. MIT press.
- Mustak, M., Salminen, J., Plé, L., & Wirtz, J. (2021). Artificial intelligence in marketing: Topic modeling, scientometric analysis, and research agenda. *Journal of Business Research*, 124, 389–404.
- Nass, C., & Moon, Y. (2000). Machines and mindlessness: Social responses to computers. *Journal of Social Issues*, 56(1), 81–103.
- Neururer, M., Schlögl, S., Brinkschulte, L., & Groth, A. (2018). Perceptions on authenticity in chat bots. *Multimodal Technologies and Interaction*, 2(3), 60.
- Opreana, A., & Vinerean, S. (2014). Analyzing mediators of the customer satisfaction–loyalty relation in internet retailing. *Expert Journal of Marketing*, 2(1).
- Pantano, E., & Pizzi, G. (2020). Forecasting artificial intelligence on online customer assistance: Evidence from chatbot patents analysis. *Journal of Retailing and Consumer Services*, 55, 102096.
- Peng, M. Y.-P., & Li, Y. (2019). The impact of expressive brand relationship on brand loyalty: Drawing on relationship marketing theory. *2019 16th International Conference on Service Systems and Service Management (ICSSSM)*, 1–5.

- Pentina, I., Hancock, T., & Xie, T. (2023). Exploring relationship development with social chatbots: A mixed-method study of replika. *Computers in Human Behavior, 140*, 107600.
- Pentina, I., Xie, T., Hancock, T., & Bailey, A. (2023). Consumer-machine relationships in the age of artificial intelligence: Systematic literature review and research directions. *Psychology & Marketing, 40*(8), 1593–1614.
- Pfattheicher, S., Nockur, L., Böhm, R., Sassenrath, C., & Petersen, M. B. (2020). The emotional path to action: Empathy promotes physical distancing and wearing of face masks during the COVID-19 pandemic. *Psychological Science, 31*(11), 1363–1373.
- Phelps, J., Nowak, G., & Ferrell, E. (2000). Privacy concerns and consumer willingness to provide personal information. *Journal of Public Policy & Marketing, 19*(1), 27–41.
- Ping, N. L. (2019). Constructs for artificial intelligence customer service in E-commerce. *2019 6th International Conference on Research and Innovation in Information Systems (ICRIIS)*, 1–6.
- Pitardi, V., & Marriott, H. R. (2021). Alexa, she's not human but... Unveiling the drivers of consumers' trust in voice-based artificial intelligence. *Psychology & Marketing, 38*(4), 626–642.
- Puntoni, S., Reczek, R. W., Giesler, M., & Botti, S. (2021). Consumers and artificial intelligence: An experiential perspective. *Journal of Marketing, 85*(1), 131–151.
- Rapp, A., Boldi, A., Curti, L., Perrucci, A., & Simeoni, R. (2023). How Do People Ascribe Humanness to Chatbots? An Analysis of Real-World Human-Agent Interactions and a Theoretical Model of Humanness. *International Journal of Human-Computer Interaction, 1–24*.
- Reeves, B., & Nass, C. (1996). The media equation: How people treat computers, television, and new media like real people. *Cambridge, UK, 10*(10).
- Riekk, T., Svedholm-Häkkinen, A. M., & Lindeman, M. (2018). Empathizers and systemizers process social information differently. *Social Neuroscience, 13*(5), 616–627.

- Rink, D. R., & Swan, J. E. (1979). Product life cycle research: A literature review. *Journal of Business Research*, 7(3), 219–242.
- Rioux, L., Scrima, F., & Werner, C. M. (2017). Space appropriation and place attachment: University students create places. *Journal of Environmental Psychology*, 50, 60–68.
- Rodriguez-Lizundia, E., Marcos, S., Zalama, E., Gómez-García-Bermejo, J., & Gordaliza, A. (2015). A bellboy robot: Study of the effects of robot behaviour on user engagement and comfort. *International Journal of Human-Computer Studies*, 82, 83–95.
- Sassenrath, C., Hodges, S. D., & Pfattheicher, S. (2016). It's all about the self: When perspective taking backfires. *Current Directions in Psychological Science*, 25(6), 405–410.
- Self-Disclose, I. W., & Omarzu, J. (2000). A Disclosure Decision Model: Determining How and When. *Personality and Social Psychology Review*, 4(2), 174–185.
- Serrano Archimi, C., Reynaud, E., Yasin, H. M., & Bhatti, Z. A. (2018). How perceived corporate social responsibility affects employee cynicism: The mediating role of organizational trust. *Journal of Business Ethics*, 151, 907–921.
- Shahid, M. Z., & Li, G. (2019). Impact of artificial intelligence in marketing: a perspective of marketing professionals of Pakistan. *Global Journal of Management and Business Research*, 19(2), 27–33.
- Shaik, M. (2023). Impact of artificial intelligence on marketing. *East Asian Journal of Multidisciplinary Research*, 2(3), 993–1004. <https://journal.formosapublisher.org/index.php/eajmr/article/view/3112>
- Shankar, A., Jebarajakirthy, C., & Ashaduzzaman, M. (2020). How do electronic word of mouth practices contribute to mobile banking adoption? *Journal of Retailing and Consumer Services*, 52, 101920.
- Shieber, S. M. (2004). *The Turing test: verbal behavior as the hallmark of intelligence*. Mit Press.
- Spears, N., & Singh, S. N. (2004). Measuring attitude toward the brand and purchase intentions. *Journal of Current Issues & Research in Advertising*, 26(2), 53–66.

- Sternberg, R. J. (2000). *Handbook of Intelligence* Cambridge University Press. New York ISBN: 9780521596480.
- Sutanto, J., Palme, E., Tan, C.-H., & Phang, C. W. (2013). Addressing the personalization-privacy paradox: An empirical assessment from a field experiment on smartphone users. *MIS Quarterly*, 1141–1164.
- Todd, A. R., & Burgmer, P. (2013). Perspective taking and automatic intergroup evaluation change: testing an associative self-anchoring account. *Journal of Personality and Social Psychology*, 104(5), 786.
- Topcu, Ç., & Erdur-Baker, Ö. (2012). Affective and cognitive empathy as mediators of gender differences in cyber and traditional bullying. *School Psychology International*, 33(5), 550–561.
- Tran, A. D., Pallant, J. I., & Johnson, L. W. (2021). Exploring the impact of chatbots on consumer sentiment and expectations in retail. *Journal of Retailing and Consumer Services*, 63, 102718.
- Tussyadiah, I., & Miller, G. (2019). Nudged by a robot: Responses to agency and feedback. *Annals of Tourism Research*, 78, 102752.
- van der Stouwe, T., Asscher, J. J., Hoeve, M., van der Laan, P. H., & Stams, G. J. J. M. (2018). Social skills training (SST) effects on social information processing skills in justice-involved adolescents: Affective empathy as predictor or moderator. *Children and Youth Services Review*, 90, 1–7.
- Van Doorn, J., Mende, M., Noble, S. M., Hulland, J., Ostrom, A. L., Grewal, D., & Petersen, J. A. (2017). Domo arigato Mr. Roboto: Emergence of automated social presence in organizational frontlines and customers' service experiences. *Journal of Service Research*, 20(1), 43–58.
- Van Pinxteren, M. M. E., Wetzels, R. W. H., Rüger, J., Pluymaekers, M., & Wetzels, M. (2019). Trust in humanoid robots: implications for services marketing. *Journal of Services Marketing*, 33(4), 507–518.
- Vlačić, B., Corbo, L., e Silva, S. C., & Dabić, M. (2021). The evolving role of artificial intelligence in marketing: A review and research agenda. *Journal of Business Research*, 128, 187–203.

- Wang, L., Yan, J., Lin, J., & Cui, W. (2017). Let the users tell the truth: Self-disclosure intention and self-disclosure honesty in mobile social networking. *International Journal of Information Management*, 37(1), 1428–1440.
- Wang, W. (2017). Smartphones as social actors? Social dispositional factors in assessing anthropomorphism. *Computers in Human Behavior*, 68, 334–344.
- Wang, W., & Benbasat, I. (2016). Empirical assessment of alternative designs for enhancing different types of trusting beliefs in online recommendation agents. *Journal of Management Information Systems*, 33(3), 744–775.
- Wilson, H. J., & Daugherty, P. R. (2018). Collaborative intelligence: Humans and AI are joining forces. *Harvard Business Review*, 96(4), 114–123.
- Wirth, N. (2018). Hello marketing, what can artificial intelligence help you with? *International Journal of Market Research*, 60(5), 435–438.
- Xu, K. (2019). First encounter with robot Alpha: How individual differences interact with vocal and kinetic cues in users' social responses. *New Media & Society*, 21(11–12), 2522–2547.
- Yang, S. (2016). Role of transfer-based and performance-based cues on initial trust in mobile shopping services: a cross-environment perspective. *Information Systems and E-Business Management*, 14, 47–70.
- Yuksel, A., Yuksel, F., & Bilim, Y. (2010). Destination attachment: Effects on customer satisfaction and cognitive, affective and conative loyalty. *Tourism Management*, 31(2), 274–284.
- Zamora, J. (2017). I'm sorry, dave, i'm afraid i can't do that: Chatbot perception and expectations. *Proceedings of the 5th International Conference on Human Agent Interaction*, 253–260.
- Zarantonello, L., & Pauwels-Delassus, V. (2015). *The handbook of brand management scales*. Routledge.
- Zhao, X. R., & Mattila, A. S. (2013). Examining the spillover effect of frontline employees' work-family conflict on their affective work attitudes and customer satisfaction. *International Journal of Hospitality Management*, 33, 310–315.

- Zhou, L., Gao, J., Li, D., & Shum, H.-Y. (2020). The design and implementation of xiaoice, an empathetic social chatbot. *Computational Linguistics*, 46(1), 53–93.
- Zierau, N., Elshan, E., Visini, C., & Janson, A. (2020). A Review of the Empirical Literature on Conversational Agents and Future Research Directions. *ICIS*.
- Zimmer, J. C., Arsal, R., Al-Marzouq, M., Moore, D., & Grover, V. (2010). Knowing your customers: Using a reciprocal relationship to enhance voluntary information disclosure. *Decision Support Systems*, 48(2), 395–406.