

UNIVERSIDADE EUROPEIA
MESTRADO DE MARKETING DIGITAL

RÚBEN PAULO DIAS MARTINS MOREIRA

INTELIGÊNCIA ARTIFICIAL NO MARKETING DIGITAL

Aceitação da Utilização de Inteligência Artificial nas Plataformas de Comércio

Eletrónico

Portugal, Lisboa

2021

RÚBEN PAULO DIAS MARTINS MOREIRA

INTELIGÊNCIA ARTIFICIAL NO MARKETING DIGITAL

Aceitação da Utilização de Inteligência Artificial nas Plataformas de Comércio

Eletrónico

Trabalho de Mestrado apresentado à Universidade Europeia como requisito parcial para a obtenção do grau de mestre em Marketing Digital.

Orientadora: Professora Doutora Joana Motta

Portugal, Lisboa

2021

Agradecimentos

E assim termina. Termina mais uma etapa, mais um desafio, mais uma corrida e sempre com o mesmo resultado: a vitória. No entanto, ninguém vence sozinho e a história encarrega-se de nos demonstrar isso, vezes e vezes sem conta. Este projeto é o culminar de anos de trabalho, persistência e resiliência que não seria possível sem aqueles que me são próximos, que me ajudaram a levantar quando estive em baixo e me guiaram da melhor forma para que visse a meta cada vez mais perto. A sensação de mérito e orgulho próprio é boa, sim, mas este feito é tanto meu como vosso e não consigo deixar de vos agradecer todo este tempo que estiveram comigo. O que me tornei e o que virei a ser é fruto da vossa presença.

À minha mãe, ao meu pai e ao meu irmão. Dedico esta importante etapa da minha vida àqueles que sempre estiveram cá, desde sempre e para sempre. Sem vocês, eu não era ninguém. Obrigado por me terem visto crescer, por todas as vezes em que cá e lá estiveram para me limpar as feridas. Obrigado por toda a vossa paciência e amor. Obrigado por acreditarem em mim, por me educarem e por todas as vezes em que achei que algo fosse correr mal e vocês estiveram lá para me dizerem o contrário. Tinham razão, correu bem. Amo-vos desde sempre e para sempre.

À Iara. Melhor amiga, gostava de ter palavras suficientes para te agradecer todos estes anos de amizade, de cumplicidade e entreajuda. É a ti que recorro quando estou triste, mas também quando estou feliz. Posso um orgulho imenso em ter-te comigo. Este projeto também é teu e obrigado por todas as contribuições que fizeste. São já 9 anos de muitos sorrisos e amor, desde as viagens de autocarro aos passeios pela costa cascalense, mas ainda é só o início. Muito mais nos espera.

À Madalena. Uma verdadeira amiga do coração que merece toda a gratidão do mundo. A pessoa que me levanta quando me sinto embaixo e uma autêntica fonte de inspiração na qual me abasteço quando a motivação é escassa. Obrigado por me teres acompanhado ao longo deste percurso, por todo o teu conhecimento e amizade que foram cruciais para chegasse à meta com sucesso.

Ao Pedro e ao Alexandre. Dizem que as amizades da faculdade são para a vida e tenho a certeza de que a nossa assim será. Obrigado pelos últimos 2 anos, por todos os projetos que desenvolvemos dentro e fora da universidade e pela vossa presença ao longo desta jornada.

Fizeram com que eu crescesse a nível pessoal e académico. Será algo que levarei comigo para sempre.

Também não posso deixar de agradecer à minha orientadora e professora doutora Joana Motta pela transmissão de toda a sua sabedoria, conselhos e constante paciência durante o desenvolvimento deste projeto. Mais que uma professora, foi alguém que me acompanhou desde a licenciatura até ao término deste percurso.

Por fim, mas não menos importante, gostaria de agradecer à minha restante família e amigos. Não é por falta de vontade que não vos menciono um a um. Apenas quero que saibam que sem vocês nada disto seria possível.

Do fundo do coração, obrigado a todos vós.

Rúben Moreira

Resumo

Plataformas digitais como os *websites* de comércio permitiram às organizações desenvolver um potencial de estimulação de consumo através de análises algorítmicas aos hábitos comportamentais na Internet recorrendo à utilização de tecnologias pertencentes à Inteligência Artificial. Assim sendo, surgiu a intriga de procurar avaliar o nível de aceitação dos consumidores relativamente à utilização desta tecnologia nas suas compras em plataformas de comércio eletrónico. De forma a realizar esta investigação, foi adotada uma metodologia de natureza quantitativa, recorrendo à elaboração de um inquérito por questionário moldado através de uma adaptação do clássico Modelo da Aceitação de Tecnologia juntamente com variáveis do Messy Middle, modelo de comportamento *online* desenvolvido pela Google. Descobriu-se que variáveis como a Confiança, a Experiência de Utilização e a Relevância impactam a Facilidade de Utilização e Utilidade Percebida e, consequentemente, estas têm um impacto na Atitude relativamente à tecnologia que, por sua vez, influencia a Intenção Comportamental. Posto isto, concluiu-se então que a utilização de Inteligência Artificial nas plataformas de comércio eletrónico é largamente aceite pelos consumidores e que as ferramentas inerentes ajudam as organizações a potenciarem as suas vendas.

Palavras-chave: Marketing Digital, Comércio Eletrónico, Inteligência Artificial, Messy Middle, Modelo da Aceitação de Tecnologia

Abstract

Digital platforms such as commerce websites allowed organizations to develop their potential for stimulating consumption through algorithmic analyzes of behavioral habits on the Internet by using technologies belonging to Artificial Intelligence. Therefore, the intrigue of trying to assess the level of consumer acceptance regarding the use of this technology in their purchases on e-commerce platforms arose. In order to carry out this investigation, a quantitative methodology was adopted, resorting to the elaboration of a questionnaire based on an adaptation of the classic Technology Acceptance Model along with variables from the Messy Middle, an online behavior model developed by Google. It was found that variables such as Trust, Usage Experience and Relevance impact Ease of Use and Perceived Usefulness and, consequently, these have an impact on Attitude towards technology which, in turn, influences Behavioral Intent. That said, it was then concluded that the use of Artificial Intelligence in e-commerce platforms is widely accepted by consumers and that the inherent tools help organizations to boost their sales.

Keywords: Digital Marketing, E-Commerce, Artificial Intelligence, Messy Middle, Technology Acceptance Model

Índice

Agradecimentos.....	II
Resumo	IV
Abstract	V
Lista de Tabelas.....	IX
Lista de Figuras	X
Lista de Abreviaturas	XI
1. Introdução.....	12
1.1.Motivação	14
2. Revisão da Literatura.....	16
2.1.Marketing	16
2.2.Marketing digital	17
2.3.Inteligência artificial.....	18
2.3.1.Definição abrangente	18
2.3.2.Interpretação mais restrita	19
2.3.3.Inteligência artificial no comércio eletrônico	20
2.3.4.Internet of things.....	24
2.3.5.Chatbots	25
2.3.6.Marketing automation.....	27
2.3.7.Motores de busca	27
2.3.8.Curadoria e personalização de ofertas	29
2.4.Comportamento de compra do consumidor online	31
2.4.1.Messy middle e o consumidor digital.....	32

2.4.1.1.Exposição	33
2.4.1.2.Exploração e avaliação	34
2.4.1.3.Experiência	35
2.4.1.4.Gatilhos e compra	36
2.4.2.Influenciar o messy middle.....	37
2.4.2.1.Heurística de categoria.....	37
2.4.2.2.Viés autoritária.....	37
2.4.2.3.Prova social.....	38
2.4.2.4.Poder do Agora	38
2.4.2.5.Viés da escassez.....	38
2.4.2.6.Poder do gratuito.....	39
2.4.3.Saída do messy middle	39
2.4.4.IA e a experiência do consumidor	39
2.5.Teorias de aceitação da tecnologia	42
2.5.1.Modelo de aceitação da tecnologia.....	42
3. Metodologia de Investigação.....	44
3.1.Inquérito por questionário	44
4. Apresentação dos resultados	50
4.1.Caracterização da amostra.....	50
4.2.Consistência interna	51
4.3.Estatísticas descritivas.....	52
4.4.Teste de hipóteses.....	54
5. Discussão dos Resultados.....	57

6. Conclusão	60
6.1.Limitações	61
6.2.Sugestões de investigação futura.....	62
7. Bibliografia.....	64
8. Apêndices	70

Lista de Tabelas

Tabela 1. Variadas definições do conceito de marketing, consoante a perspectiva do autor	16
Tabela 2. Tipos de análise da IA, áreas de retalho e decisões	22
Tabela 3. Constructos, definições e instrumentos de medição.....	46
Tabela 4. Sexo, faixa etária e região dos inquiridos que contribuíram para o estudo	50
Tabela 5. Resumo de processamento do caso	51
Tabela 6. Estatísticas de confiabilidade	52
Tabela 7. Estatísticas descritivas das variáveis sociodemográficas	52
Tabela 8. Estatísticas descritivas das questões de concordância.....	53
Tabela 9. Resultados da testagem das hipóteses	54

Lista de Figuras

Figura 1. Os estágios da inteligência artificial	20
Figura 2. O modelo Messy Middle	32
Figura 3. Exposição no Messy Middle.....	33
Figura 4. Ciclo de Exploração e Avaliação no Messy Middle	34
Figura 5. Experiência no Messy Middle	35
Figura 6. Gatilhos e Compra no Messy Middle	36
Figura 7. Modelo de Aceitação da Tecnologia.....	42
Figura 8. Modelo de investigação utilizado	48

Lista de Abreviaturas

AGI	Artificial General Intelligence
ANI	Artificial Narrow Intelligence
ASI	Artificial Super Intelligence
CRM	Customer Relationship Management
IA	Inteligência Artificial
INP	Incrementally New Products
IoT	Internet of Things
PPC	Pay-Per-Click
RNP	Really New Products
SEM	Search Engine Marketing
SEO	Search Engine Optimization
SERP	Search Engine Results Page

1. Introdução

Figueiredo (2019) defende que o aumento da procura por produtos e avanços tecnológicos está a empurrar a Inteligência Artificial (IA) para novos níveis. Assiste-se neste momento a uma rápida transformação para a qual temos de estar preparados para melhor compreender como retirar vantagens competitivas desta tecnologia. Ao aliar a IA ao Marketing Digital, torna-se então mais importante do que nunca as organizações aprenderem a utilizar esta combinação para suprimir as necessidades e desejos de compra dos consumidores.

De acordo com Kumar et al. (2019), o papel da IA no marketing personalizado levará a que os consumidores estejam preparados para uma nova jornada em que esta tecnologia seja uma ferramenta de infinitas opções e informação que se afunila e cura de uma forma personalizada. Davenport et al. (2020), por outro lado, defendem que no futuro seja provável que a IA mude substancialmente as estratégias de marketing, bem como o comportamento dos consumidores.

Segundo dados do Instituto Nacional de Estatística (INE, 2020), o comércio eletrónico (*e-commerce*) registou em 2020 o maior aumento percentual desde o início do seu registo em 2002. Em 2020, 44,5% dos indivíduos dos 16 aos 74 anos realizaram encomendas através da Internet nos últimos 12 meses. Para além destes valores, o INE (2020) afirma que não só aumentaram significativamente a quantidade de encomendas realizadas *online*, mas também a importância despendida pelos consumidores. Na quantidade de encomendas, o grupo de consumidores que fez entre 3 a 5 encomendas registou um aumento de 4%, os de 6 a 10 encomendas assinalaram um aumento de 9,5% e, mais de 10 encomendas, 6,9%. Relativamente aos gastos, houve um aumento de 15,7% no caso de encomendas com valores compreendidos entre os 100 e os 499 euros e mais 8% para encomendas de valores superiores a 500 euros.

Tendo em conta a argumentação apresentada anteriormente, podemos afirmar que a utilização da tecnologia do digital para os consumidores realizarem as suas compras é cada vez mais não só o presente, mas também o futuro. Assim, é crucial perceber como os consumidores aceitam e utilizam esta tecnologia para melhorar a eficácia das suas compras, bem como a forma que as organizações podem utilizar a IA para potenciar as suas plataformas de comércio eletrónico.

Posto isto, propôs-se a seguinte pergunta de partida para iniciar o estudo: **Qual o nível de aceitação por parte dos consumidores relativamente ao uso de Inteligência Artificial nas suas compras através da Internet?**

Para responder a esta questão, estabeleceu-se um objetivo geral e três específicos. Relativamente à delimitação do objetivo geral, este passa por: analisar o impacto da IA nas compras *online*. Adicionalmente, os objetivos específicos assentam em:

- Verificar o nível de aceitação da IA no processo de compra *online* por parte do consumidor;
- Verificar se o modelo TAM é aplicável ao contexto do estudo;
- Averiguar se a aceitação da IA tem um impacto significativo na intenção comportamental nas compras através da Internet;

A dissertação é dividida em 6 partes distintas. Numa primeira, a atual, consta a introdução ao projeto onde se aborda quais as temáticas a serem investigadas, a questão de partida bem como quais os objetivos que se pretende concretizar com a dissertação.

Na segunda parte, encontra-se a revisão da literatura que consiste num conjunto de conhecimentos científicos, perspetivas e confrontos de ideias entre autores acerca das diversas temáticas como o Marketing e a sua vertente Digital, a Inteligência Artificial e a Intenção de Compra através de um novo modelo desenvolvido pela Google: o Meio Confuso (*Messy Middle*).

Relativamente ao Marketing e à sua vertente digital, procurou-se explorar os conceitos básicos destas áreas. Noções como a evolução da definição de “marketing” ao longo do último século, o propósito do marketing nas empresas e as diferentes partes que o constituem.

Na IA, abordou-se uma série de definições, a evolução da tecnologia num futuro a longo prazo, a utilização que esta tem ao nível do *e-commerce* e alguns tópicos que a abrangem como a Internet das Coisas (*Internet of Things*), os Motores de Busca (*Search Engines*), os *Chatbots*, a Automatização de Marketing (*Marketing Automation*) e a Curadoria de Conteúdos/Produtos.

Sobre a Intenção de Compra, procurou-se abordar o modelo mais recente até à data da escrita desta investigação: o *Messy Middle*. Criado em meados de 2020 pela gigante tecnológica Google, este modelo ainda não possui grande aplicação científica por parte de outros investigadores para além da própria organização que o desenvolveu. No entanto, de

forma a manter o estudo o mais atual possível, aliou-se os princípios teóricos do *Messy Middle* ao Modelo da Aceitação da Tecnologia (TAM), o mais utilizado para investigações desta natureza, de acordo com Groß (2015).

Após a revisão da literatura, na terceira parte, aborda-se a metodologia a ser utilizada para a vertente prática da investigação. Esta consistiu na realização de um estudo quantitativo por via de um inquérito por questionário.

Ao longo da quarta parte, apresentou-se os resultados do estudo, passando pela caracterização da amostra, a consistência interna, estatísticas descritivas e validação das hipóteses.

Na quinta parte elaborou-se uma discussão acerca dos resultados obtidos. Aqui, comparou-se as ilações presentes na investigação com dados de outros autores, permitindo a observação dos resultados através de diversos pontos de vistas e abrindo portas ao debate.

E, na parte final do documento, temos a conclusão do estudo e as referências bibliográficas que foram utilizadas para a realização da dissertação, bem como os apêndices complementares à investigação.

Para terminar, espera-se que esta dissertação possa contribuir para este campo de estudo ao conseguir aliar, com sucesso, através de um contributo teórico e prático, as três temáticas abordadas.

1.1. Motivação

Após uma breve análise à documentação bibliográfica utilizada para o desenvolvimento da dissertação, deparei-me com algumas lacunas apresentadas pelos artigos científicos em questão. Estas lacunas apresentam-se como uma das grandes motivações que me levaram a abordar este assunto numa fase tão crucial do meu percurso académico.

Assumindo que a presente investigação assume três temáticas distintas que acabam por se entrelaçar - Marketing Digital, Inteligência Artificial e Intenção de Compra - pude observar ao longo da minha literatura que grande parte dos autores não abordam os três tópicos de uma forma conjunta.

A nível pessoal e sendo estudante de marketing desde o ensino secundário, observei durante o meu crescimento escolar e académico à expansão da tecnologia, bem como a sua

aplicação prática nos diferentes campos do marketing, apercebendo-me de que gostaria de contribuir pessoalmente para o desenvolvimento de uma área ainda pouco explorada.

2. Revisão da Literatura

2.1. Marketing

Ao longo dos últimos 100 anos, a definição de marketing tem-se alterado constantemente, pois a sua conceptualização não é consensual entre todos os autores. Segundo Brunswick (2014), isto deve-se ao facto do marketing ter continuado a evoluir com o passar do tempo, refletindo uma variedade de influências que o envolvem. Similarmente, a definição da disciplina e prática de marketing evoluiu com o tempo como uma reflexão destas mudanças evolutivas. Com isto em mente, geraram-se diversas perspetivas e opiniões acerca do tópico, que uns autores podem considerar mais corretas que outros. Na Tabela 1 constam algumas destas definições.

Tabela 1

Variadas definições do conceito de marketing, consoante a perspetiva do autor

Autores	Definições
Alderson (1957, p.42)	“Marketing é a troca entre grupos consumidores, por um lado, e grupos fornecedores, por outro.”
McCarthy (1960, p.33)	“Marketing é o ato de realizar atividades negociais que direcionam o destino de bens e serviços de produtor para consumidor ou utilizador de forma a melhor satisfazer os consumidores e alcançar os objetivos da empresa.”
Stanton (1984, p.7)	“Marketing é um sistema total de atividades negociais desenhado para planear, atribuir um preço, promover, e distribuir quaisquer bens e serviços a atuais e potenciais consumidores.”
Kotler e Keller (2006, p.4)	“O marketing envolve a identificação e satisfação das necessidades humanas e sociais.”
American Marketing Association (2017)	“Marketing é a atividade, conjunto de instituições e processos para criar, comunicar, entregar e trocar ofertar que tenham valor para os consumidores, clientes, parceiros e sociedade em geral.”

Através da leitura da Tabela 1, podemos perceber que existem diversas perspetivas quando nos referimos à abordagem ao marketing, no entanto, o princípio base das definições dadas assenta sempre no mesmo. Ou seja, existe um grupo - as organizações (com ou sem fins lucrativos) - que identificam determinadas necessidades num outro grupo (os consumidores) e que, através de trocas, faz com que o bem ou serviço criado para suprimir essas necessidades chegue até estes. No caso de uma empresa, estas trocas pretendem trazer lucros pecuniários. Por outro lado, uma associação sem fins lucrativos, não obtém necessariamente um valor pecuniário, podendo apenas querer obter um valor social.

2.2. Marketing digital

Ramesh e Vidhya (2019), sustentam que na era moderna em que vivemos, os *marketeers* utilizam estratégias inovadoras para magnetizar e reter uma série de consumidores que comprem os seus produtos ou serviços. Assim sendo, acrescentam que o Marketing Digital se trata de um processo que consiste em aliar as atividades promocionais feitas por *marketeers* à Internet, utilizando *media* eletrónica para vender as suas ofertas. Para além disto, o Marketing Digital oferece novas oportunidades para os *marketeers* manterem um contacto constante com os clientes. Com a digitalização do marketing, todo o tipo de negócios (pequenos, médios e grandes) beneficiam de novos caminhos para poderem comercializar os seus produtos ou serviços através de um contacto direto com os consumidores (Ramesh e Vidhya, 2019). No entanto, tal como o Marketing Tradicional, também o Digital possui interpretações diferentes, consoante o autor e a sua perspetiva.

Para Behera et al. (2020), o Marketing Digital define-se em “comunicar o valor de itens como bens, produtos ou serviços aos consumidores, alavancando os canais *online* e *offline* digitalmente, principalmente na Internet.” (p.1)

Patel (n.d.-a), reconhecido especialista de Marketing Digital, argumenta que este é “qualquer forma de marketing de produtos ou serviços que envolva aparelhos eletrónicos (...) não tendo necessariamente nada a ver com marketing de conteúdo, Google Ads, Social Media ou *retargeting*. Marketing digital pode ser feito tanto por via *online* como *offline*.” Ainda de acordo com o autor, o Marketing Digital assenta em 2 grandes pilares: o Marketing *Online* e o Marketing *Offline*, sendo que o *online* engloba 7 grandes categorias, sendo elas: a Otimização de Motor de Busca (*Search Engine Optimization*, SEO), o Marketing de Motor de Busca

(*Search Engine Marketing*, SEM), o Marketing de Conteúdo (*Content Marketing*), o Marketing de Redes Sociais (*Social Media Marketing*, SMM), a Publicidade Custo-por-clique (*Pay-per-click Advertising*, PPC), o Marketing de Afiliados (*Affiliate Marketing*) e o *E-mail Marketing*.

2.3. Inteligência artificial

De acordo com Kumar et al. (2019), a IA está a abrir novos caminhos para a entrega de valor para os utilizadores. Segundo estes mesmos autores, o conceito de IA refere-se à ideia de que as máquinas, através da utilização de *software* e algoritmos, conseguem pensar e realizar tarefas como se de um ser humano se tratassem.

De Bruyn et al. (2020) alegam que a IA terá um profundo impacto num largo leque de negócios e funções empresariais.

2.3.1. Definição abrangente

Definir concretamente a IA não é tarefa fácil, pois para Legg e Hutter (2007), só para o termo “inteligência”, existem mais de 70 definições dadas por psicólogos, sociólogos, biólogos, neurocientistas e filósofos. Posto isto, não é surpreendente que o termo “inteligência artificial”, embora tão commumente utilizado, permaneça tão mal definido e um conceito tão difuso (Kaplan e Haenlein, 2019).

Shieber (2004) diz-nos que a definição mais simples, e maioritariamente aceite, assenta em conceptualizar a IA como “inteligência demonstrada por máquinas”. Brooks (1991), por outro lado, argumenta que a IA pode ser definida como uma intenção para que os computadores realizem tarefas, que quando feitas por pessoas, são descritas como tendo sido realizadas com recurso a inteligência. Estas definições, embora válidas, partem do pressuposto de que existe um consenso geral acerca do conceito de “inteligência” (De Bruyn et al., 2020). Enquanto que para alguns autores, como é o caso de Norvig e Russel (2016), a inteligência está mais associada à aprendizagem, ao planeamento e à resolução de problemas, para outros, esta pode também abranger o conhecimento, a autoconsciência, o conhecimento emocional, a razão, a criatividade, a lógica e o pensamento crítico (Legg e Hutter, 2007).

Com base na definição maioritariamente aceite dada por Shieber (2004) e dependendo de como percebemos o termo “inteligência”, De Bruyn et al. (2020) argumentam que ainda

estamos a décadas de distância de atingir a verdadeira IA. No entanto, ainda assim, alegam que outros autores defendem que uma simples análise estatística realizada por uma máquina já pode ser considerada, com sucesso, uma utilização de IA.

Para De Bruyn et al. (2020), podemos de facto afirmar que IA é “inteligência demonstrada por máquinas”. No entanto, para os autores, esta definição não nos ajuda a clarificar os perímetros que realmente constituem a IA por si e temos de reconhecer que este conceito, embora abrangente, pode gerar confusão ou abusos do seu significado.

2.3.2. Interpretação mais restrita

De acordo com Kumar et al. (2019), a IA opera no domínio da automatização e da aprendizagem contínua, agindo como sendo a inteligência que guia as análises e as tomadas de decisão tomando por base um conjunto de dados. Na mesma linha de raciocínio, ela automatiza muitas das atividades relacionadas com a coleta, armazenamento e gestão de informação, o que permite às organizações criarem as suas ofertas para os consumidores. Através da utilização de tecnologias como a aprendizagem profunda (*deep learning*), algoritmos genéticos e o processamento de linguagem natural, a IA pode treinar máquinas para que estas aprendam a reconhecer padrões em grandes quantidades de informação (Kumar et al., 2019).

Kaplan e Haenlein (2019) acreditam que a IA, tal como qualquer outra tecnologia, passa por fases evolutivas e defendem a existência de 3 estágios para descrever esta evolução: Inteligência Artificial Limitada (*Artificial Narrow Intelligence, ANI*), Inteligência Artificial Geral (*Artificial General Intelligence, AGI*) e Super Inteligência Artificial (*Artificial Super Intelligence, ASI*).

ANI, o primeiro estágio, assenta em utilizar a IA para tarefas bastante específicas. Tarefas estas que, de acordo com Kaplan e Haenlein (2019), permitem, por exemplo, ao Facebook conseguir reconhecer as faces dos seus utilizadores e identificá-los com sucesso nas fotografias; à Siri, assistente virtual da Apple, conseguir identificar a voz de quem a chama e a Tesla produzir carros com pilotagem automática.

O segundo estágio, o AGI, permitirá que a IA “consiga raciocinar, planear e resolver problemas de forma autónoma em tarefas para as quais nem sequer foi desenhada” (Kaplan e Haenlein, 2019, p.16).

E, por último, o terceiro estágio (ASI), que ainda de acordo com os mesmos autores, a IA tornar-se-á completamente autoconsciente que a própria existência do ser humano será redundante. Estes sistemas inteligentes, conseguirão aplicar as suas capacidades em qualquer área e serão também capazes de produzir conhecimento científico, social e cultural.

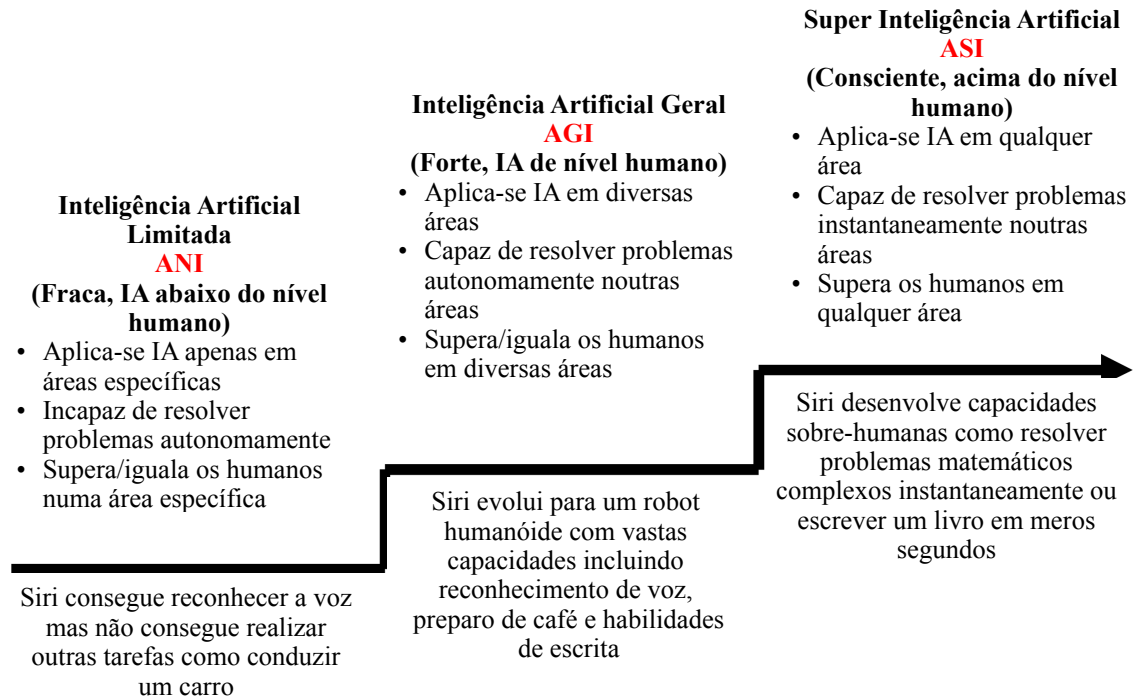


Figura 1. Os estágios da inteligência artificial.

Fonte: De “Siri, Siri, in my hand: Who’s the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence” de Kaplan, A. e Haenlein, M., 2019, *Business Horizons*, p.16. <https://doi.org/10.1016/j.bushor.2018.08.004>

Em suma, a IA pode ser definida como “a habilidade de um sistema em interpretar corretamente dados externos, aprender com estes dados e utilizar esta aprendizagem para atingir objetivos específicos e realizar tarefas através de uma aprendizagem flexível” (Kaplan e Haenlein, 2019, p.15).

2.3.3. Inteligência artificial no comércio eletrónico

Os agentes da IA conduzidos por algoritmos estão a transformar rapidamente o mundo empresarial, elevando exponencialmente o interesse científico acerca deste tópico (Ma e Sun, 2020). Davenport e Ronanki (2018) corroboram esta afirmação ao defenderem que a IA não só depende da tecnologia que se encontra por detrás desta, mas também das suas aplicações no marketing e nos negócios. Aplicações estas que assentam na automatização de processos

empresariais, recolha de *insights* através de dados ou no envolvimento de consumidores e colaboradores.

De acordo com Ping et al. (2019), o comércio eletrónico é adotado como uma estratégia para alavancar a competitividade de um negócio. No entanto, cada consumidor digital está ciente de que pode partilhar avaliações positivas ou negativas nas diferentes plataformas sociais. Como resultado, a informação torna-se cada vez mais transparente, o que pode afetar a imagem e a rentabilidade de uma determinada empresa (Nisar e Prabhakar, 2017).

Com o aumento da dificuldade em satisfazer os clientes, a utilização de IA é a resposta mais eficiente para combater esta tendência (Ping et al., 2019). Os autores adiantam que as tecnologias inerentes à IA como o processamento de linguagem natural e o *machine learning* permitem às organizações serem mais eficazes e estarem disponíveis 24 horas por dia, automatizando muitas das tarefas, reduzindo custos e aumentando a satisfação dos clientes.

Davenport et al. (2020) defendem que, de forma a automatizar os processos empresariais, os algoritmos de IA realizam tarefas especificamente definidas com pouca ou nenhuma intervenção humana como, por exemplo, transferir dados de um *e-mail* ou *call center* para sistemas de armazenamento de registos internos (atualizando os dados do cliente), implementar simples transações de mercado ou ler documentos de forma a extrair informações chave utilizando processamento de linguagem natural. De seguida, ainda na mesma linha de pensamento dos autores, a IA consegue ganhar *insights* através de vastos volumes de informação sobre o consumidor e as suas transações, incluindo não só informação numérica, mas também textual, vocal, imagética ou expressões faciais.

A Tabela 2 mostra-nos alguns exemplos em como as empresas podem utilizar diversos tipos de análise de IA para recolherem *insights* e, conseqüentemente, gerirem o seu negócio de acordo com os dados recolhidos.

Tabela 2

Tipos de análise da IA, áreas de retalho e decisões

Tipos de análise da IA	Algumas áreas de retalho relacionadas	Decisões tipicamente influenciadas por IA
Análise numérica	Finanças, contabilidade, vendas e marketing, logística, operações de loja	Localização da loja, encomendas, variedade, preço, promoções, investimento
Análise textual	Satisfação do cliente, análise de avaliação do produto	Modificação do produto, introdução de novo produto, melhoria de serviço
Análise vocal	Apoio ao cliente, gestão de encomendas	Previsão de compra, recuperação de serviço, atendimento de pedidos
Análise de imagem/vídeo	Análise comportamental do comprador, marketing de consumidor (<i>shopper marketing</i>), variedade de produto	<i>Layout</i> da loja, espaço nas prateleiras, colocação dos itens, conteúdo digital, recomendação de produto

Fonte: Acedido de “How Artificial Intelligence (AI) is Reshaping Retailing”, de V. Shankar, 2018, *Journal of Retailing*, 94(4), p.7

Para Shankar (2018), as empresas podem utilizar e beneficiar da IA de diversas formas. Do lado do consumidor, podem perceber e antecipar o seu comportamento, recomendar produtos, gerir vendas e a relação com o cliente (*Customer Relationship Management*, CRM), gerir a experiência nas suas lojas, fornecer apoio ao cliente e gerir pagamentos, bem como otimizar os meios de comunicação. No lado da logística, podem utilizar a IA para otimizar o inventário, o transporte e as entregas de encomendas.

Para que tenham sucesso nestas atividades, Davenport et al. (2020) argumenta que as *analytics* alimentadas por IA conseguem prever o que um determinado consumidor estará mais disposto a comprar e, como consequência disso, as empresas podem direcionar, em tempo real, publicidade digital especificamente para esse consumidor de forma a encorajar a compra. A tecnologia de IA subjacente a este processo integra dados fornecidos pelos próprios consumidores, como por exemplo, preferências de outros consumidores que tenham gostos similares ou tendências gerais de mercado (Davenport et al., 2020).

A IA tem o potencial de aumentar receitas e diminuir custos. As receitas podem aumentar através da melhoria das tomadas de decisão do marketing (preço, produto, recomendação e *engagement* com o consumidor), enquanto que os custos podem diminuir devido à automatização de tarefas simples de marketing, apoio ao cliente e transações estruturadas (Davenport et al., 2020).

“A IA consegue ajudar as empresas a prever o que os consumidores irão comprar e deverá levá-las a melhorias substanciais na capacidade preditiva.” (T. Davenport et al., 2020, p.35) Dependendo do nível de precisão destas previsões, as empresas podem até mudar completamente os seus modelos de negócio, providenciando bens e serviços aos seus clientes de forma contínua com base nos seus dados e previsões acerca das suas necessidades. Esta lógica, segundo os autores, permite que surjam novas oportunidades de pesquisa de mercado relacionadas com o processo de compra dos consumidores, os seus comportamentos e consequentes definições estratégicas de marketing.

Zhao et al. (2012) aborda a precisão das previsões algorítmicas da IA no lançamento de *Really New Products* (Verdadeiros Novos Produtos, RNP). Os RNPs são descritos pelos autores como produtos em que os consumidores têm pouca ou nenhuma experiência na sua utilização e que são avaliados através da sua própria imaginação.

Estes algoritmos de previsão possuem uma boa capacidade para os *Incrementally New Products* (Incremento de Novos Produtos, INP), descritos pelos autores como sendo produtos em que o consumidor já possui um conhecimento passado, não sendo necessária a sua avaliação através da imaginação. A questão que se põe é se esta mesma capacidade se mantém para os RNP, afirmam.

Davenport et al. (2020) argumenta que, para a IA ter esta mesma capacidade preditiva tanto para INPs como para RNPs, é necessária uma quantidade abundante de dados para que se possam treinar os modelos de *machine learning*. No entanto, estes dados não estão imediatamente disponíveis para produtos completamente novos no mercado (RNPs) e que a melhor opção é combinar *insights* recolhidos pela IA com o discernimento humano.

Para Shankar (2018), no futuro, a IA cumprirá um papel fulcral não só ao prever o que os consumidores quererão comprar, mas também a que preço e se as empresas deverão fazer promoções ou não. Guha et al. (2018) argumenta que tanto o preço como as promoções são

grandes impulsionadores de vendas e, sendo assim, fazem parte de um importante campo de estudo do marketing.

2.3.4. Internet of things

De acordo com Sestino et al. (2020), a utilização da Internet das Coisas (*Internet of Things*, IoT) mudou radicalmente as nossas vidas, trazendo imenso valor para atividades tanto a nível individual, como a nível empresarial.

Tendo em conta a definição de IA dada por Kaplan e Haenlein (2019) em que afirmam que a IA consiste na capacidade de um sistema interpretar dados externos e aprender com estes, os mesmos autores argumentam que existe uma distinção clara, mas relacionada, entre IA e IoT. Para Krotov (2017), a IoT assenta na ideia de que os equipamentos eletrónicos que nos rodeiam estão equipados com sensores e *software* que coletam e trocam dados, podendo esta tecnologia ser vista como uma forma específica de obter dados externos que servirão de *input* para a IA. No entanto, para Lee (2017), a IoT é apenas um dos muitos canais incluídos na *Big Data*.

A *Big Data* é caracterizada como uma grande quantidade de informação (volume) frequentemente atualizada (velocidade) em diversos formatos, como numéricos, textuais ou imagens/vídeos (variedade) (Kaplan e Haenlein, 2019). A *Big Data* é, por outro lado, mais abrangente que a IoT visto que também inclui dados recolhidos por outras fontes, como aplicações móveis (*mobile*) e redes sociais.

Para Sestino et al., (2020), a utilização destas tecnologias permite que as empresas aumentem a sua competitividade ao transformarem os seus produtos e serviços em oportunidades de negócio digitais. Os autores dizem-nos ainda que a IoT possui ferramentas para estudar o comportamento dos consumidores, as suas atitudes, o consumo e as escolhas que estes fazem, tendo uma grande relevância para estudos de marketing.

É graças a estas ferramentas que Sestino et al. (2020) defendem que os *marketeers* conseguem recolher dados em grande escala de forma a identificar novas lacunas ou tendências emergentes no comportamento do consumidor. Argumentam Hofacker et al. (2016) que a principal vantagem da utilização da IoT no marketing é a possibilidade de publicar campanhas publicitárias com dados recolhidos em tempo real.

Uma das aplicações da IoT no marketing, mais concretamente no comércio eletrónico, de acordo com Joghee (2021), assenta no momento em que um utilizador partilha a sua localização através do telemóvel e recebe dados relacionados com promoções, negócios e descontos oriundos da IoT.

Bijmolt et al. (2021) assinalam que as empresas podem também fazer uso das ferramentas do marketing digital para refinar e enfatizar a jornada dos seus consumidores (*Customer Journey*). Seguindo esta lógica, os autores exemplificam o facto de agora os consumidores possuírem uma linha de contacto direta com as empresas e, inversamente, as empresas podem recolher dados sobre estes em tempo real para que consigam melhorar os seus produtos e campanhas de marketing.

Novak e Hoffman (2019) afirmam que os *smart objects* (objetos imbuídos com IoT) estão-se a tornar cada vez mais proeminentes no ambiente de compra, contribuindo assim para estratégias *omnichannel* que combinam a experiência *online* com *offline*. Para Erevelles et al. (2016), os consumidores utilizam os seus *smarthphones* durante as fases pré e pós compra, comparando preços, verificando a disponibilidade dos produtos, informarem-se sobre as funcionalidades ou para lerem avaliações *online*. Este volume de informação obtida aumenta drasticamente quando consideramos todos os *touchpoints* que uma loja pode ter (assistentes virtuais, ecrãs, sistemas interativos, etc.). As empresas podem, adicionalmente, recolher dados acerca das transações dos clientes e providenciar ofertas baseadas em estratégias de marketing altamente personalizadas (Sestino et al., 2020).

Para concluir, os autores defendem que a IoT aliada à IA, permite que as empresas utilizem soluções *smart* de forma a guiarem os consumidores pela sua jornada e sugerirem as ações mais apropriadas. Tecnologias IoT como *beacons*, NFC, aplicações e *touchpoints* interativos, podem encorajar o uso de estratégias de geolocalização. Por outro lado, os comportamentos de compra e as interações podem ser analisadas para que se consiga comunicar de uma forma mais eficiente e eficaz, seja através de promoções, *e-mail* marketing ou anúncios.

2.3.5. Chatbots

Os *chatbots* já ultrapassaram os limites daquilo que considerávamos serem características intrínsecas ao ser humano, defende Kaczorowska-Spychalska (2019). Para a

autora, estas tecnologias digitais apresentam uma vasta gama de competências como o reconhecimento de imagens, padrões, a capacidade de tomarem decisões, comunicarem ou ajustarem as suas afirmações mediante o contexto. Acrescenta ainda que o interesse em utilizar *chatbots*, que é um dos sintomas da transformação digital, sobressai-se cada vez mais nas atividades de marketing das organizações.

De acordo com Holtgraves et al. (2007), um *chatbot* consiste num programa de *software* que utiliza linguagem natural para manter conversas em tempo real com os consumidores.

Para Kull et al. (2021), as estratégias de marketing podem incorporar os *chatbots* para melhorarem a experiência do consumidor e enaltecerem as relações com as marcas. No entanto, para Holtgraves et al. (2007), um dos pontos negativos da utilização desta tecnologia prende-se na avaliação da personalidade do *bot* por parte dos consumidores.

Para Kaczorowska-Spychalska (2019), os *bots* têm especial utilidade quando implementados no universo *social media*. A sua personalidade, de acordo com a autora, é geralmente percebida pela forma com que os *bots* conduzem conversas, pelo estilo comportamental que apresentam, pela multiplicidade de frases que proferem, etc. e intensificam a experiência e as emoções desejadas no consumidor pela empresa/marca, ao mesmo tempo que influenciam as suas tomadas de decisão e comportamento.

Ainda segundo a autora, um *chatbot* que tenha uma personalidade bem definida e carismática e que possua a capacidade de conduzir o comprador através das diversas fases do processo de compra enquanto economiza o seu esforço cognitivo e tempo, pode tornar-se num valor chave que distingue uma determinada marca da sua concorrência. No entanto, o tipo de *chatbot* que predomina o mercado atualmente é o chamado “*rule-based chatbot*” (*chatbot* baseado em regras) em que o seu papel se encontra limitado a determinadas bases de dados privadas.

Por fim, Daugherty e Wilson (2018) afirmam que os *bots* são desenhados para serem dinâmicos, capazes de aprender e mudar. As organizações têm de determinar também que limites podem impor à medida que estes evoluem. Como resultado, os *bots* serão capazes de responder a perguntas que lhes são feitas e resolver problemas à medida que percebem as intenções dos utilizadores.

2.3.6. Marketing automation

Bagshaw (2015) descreve a automatização de marketing (*marketing automation*) como sendo a utilização de *software* para tornar automáticos os processos de marketing, como segmentação de públicos, integração de dados dos consumidores e gestão de campanhas. O autor acrescenta ainda que, quando corretamente implementado, o *marketing automation* permite às empresas focarem-se nos consumidores e acelerar o processo de compra através do funil de vendas, utilizando muito menos recursos, sejam humanos ou financeiros. A utilização de *software* de automatização, ajuda a centralizar dados, entregar uma estratégia de contacto muito mais relevante e complexa, bem como converter *leads* em clientes, tornando as campanhas de marketing muito mais eficazes (Bagshaw, 2015).

Rahman et al. (2020) argumentam que a integração da IA com o *marketing automation* através de publicidade programada e marketing de redes sociais permite obter uma melhor compreensão acerca do comportamento do consumidor, *analytics* de previsão mais precisos e *insights* mais profundos. Para Bagshaw (2015), uma empresa necessita de um plano estratégico e de conseguir adaptar a sua atividade e campanhas com base nos resultados.

Um dos maiores impactos do *marketing automation* no quotidiano das empresas assenta no setor das vendas (Rahman et al., 2020). Os autores defendem que os esforços das atividades de marketing terão de passar por compreender o comportamento do consumidor e fornecer ofertas altamente personalizadas para cada um deles, percebendo as suas preferências e identificando gatilhos de comunicação que sejam relevantes, convertendo isto em mensagens de grande interesse, direcionadas e temporizadas para que adotem um comportamento mais lucrativo.

Por último, a adoção destas tecnologias, para Mero et al. (2020), é considerada uma grande fonte de oportunidades de negócio, se corretamente estruturadas e planeadas.

2.3.7. Motores de busca

Dumitriu e Popescu (2020) acreditam que o marketing chegou a um ponto na sua evolução em que é imperativo adaptar-se às tendências tecnológicas. De acordo com os autores, as aplicações e sistemas automatizados baseados em IA diminuem a complexidade dos clássicos processos de *targeting* e personalização. Prosseguem, defendido que em muitas situações, as plataformas utilizadas para vendas através da Internet contêm algoritmos para

identificar os melhores produtos com base no que os consumidores pesquisam. Estas plataformas/sistemas que os autores referem, tratam-se dos motores de busca (*search engines*).

Berman e Katona (2013) descrevem um motor de busca como um intermediário entre os consumidores e os *websites*. Segundo os autores, os consumidores que utilizam *search engines*, geralmente, deparam-se com duas opções: hiperligações (*links*) orgânicas e pagas (PPC). As hiperligações orgânicas são classificadas de acordo com a sua relevância para a pesquisa do consumidor enquanto que as pagas são alocadas aos anunciantes através de uma licitação competitiva (Berman e Katona, 2013). Afirmam ainda que, como os consumidores têm tendência para confiar mais em *links* orgânicos, os anunciantes tentam, por vezes, aumentar a sua visibilidade na listagem orgânica através da manipulação do algoritmo utilizando técnicas conhecidas como “otimização do motor de busca” (*Search Engine Optimization*, SEO).

Na listagem orgânica, de acordo com Berman e Katona (2013), o objetivo dos *search engines* é fornecer aos consumidores hiperligações para os *websites* com maior índice de qualidade. De forma a classificar qualitativamente os *websites*, os motores de busca utilizam informação recolhida na Internet através de algoritmos de rastreio (*crawlers*) e métodos de prospeção de dados (*data mining*) (Mattaet al., 2020). Estes algoritmos, segundo Dumitriu e Popescu (2020), utilizam palavras-chave (*keywords*) para conduzirem as suas buscas.

Argumentam ainda os autores que as *keywords* são, juntamente com outros componentes, um dos elementos mais importantes na definição de uma estratégia de SEO. As *keywords* podem ser frases ou palavras usadas pelo utilizador para encontrar um determinado *website* nos motores de busca (Dumitriu e Popescu, 2020). No fundo, um *website* otimizado necessita de “estar no idioma” dos utilizadores que o pesquisam, utilizando as mesmas *keywords* que estes no seu conteúdo, *meta descriptions*, textos alternativos das imagens, etc.

Relativamente aos resultados pagos, Kritzinger e Weideman (2013) afirmam que quando um motor de busca adiciona PPC aos resultados orgânicos, estes fornecem uma segunda lista de resultados classificados na mesma página dos resultados orgânicos. Isto gera mais competição entre os *websites*, principalmente se possuírem um teor comercial.

Para Kritzinger e Weideman (2013), tanto o SEO como o PPC possuem as suas vantagens e desvantagens. O PPC consegue assegurar uma apresentação imediata na página

de resultados (*Search Engine Results Page*, SERP) e, conseqüentemente, uma posição mais elevada, assumindo que tenha um bom índice de qualidade e licitações altas. Por outro lado, o seu custo pode ser elevado, especialmente quando se tratam de *keywords* populares entre a concorrência.

Zuze (2011), argumenta que a implementação de SEO num *website* leva algum tempo a demonstrar resultados. Kritzinger e Weideman (2013) defendem que cada motor de busca possui os seus próprios requisitos, significa isto que um *website* pode estar otimizado para um motor de busca, mas não para outro. Uma dificuldade acrescida é o facto do algoritmo dos motores de busca estarem em constante mudança como forma de prevenir o *spamdexing*¹ (Kritzinger e Weideman, 2013). Devido a isto, a constante alteração da estratégia de SEO pode tornar-se dispendiosa. Por outro lado, acrescentam os autores, uma das vantagens que o SEO possui relativamente ao PPC, é que o primeiro ocupa uma grande parte da SERP, sendo os resultados dificilmente ignorados por parte dos utilizadores.

Por último, para Kritzinger e Weideman (2013), é essencial que os marketeers implementem estratégias conjuntas tanto de SEO como de PPC na construção das suas campanhas para que consigam maximizar o tráfego dos seus *websites*.

2.3.8. Curadoria e personalização de ofertas

Kumar et al. (2019) expressam que os consumidores estão prontos para uma jornada em que a IA é uma ferramenta de infinitas opções e informações que são afuniladas e selecionadas de uma forma personalizada para cada um. Acrescentam que os avanços tecnológicos, como os *smartphones*, os computadores e a Internet, produzem mudanças estruturais nas estratégias das organizações e têm a capacidade de mudar negócios por completo. Tais avanços permitem que as organizações melhorem o seu potencial de conhecimento acerca das necessidades dos clientes e na forma como disponibilizam as suas ofertas.

Para estes mesmos autores, existem duas formas de entregar conteúdo personalizado: personalização e curadoria. A nível do marketing, a personalização é apresentada e estudada

¹ “Técnicas maliciosas utilizadas em páginas web com o objetivo de contornar os algoritmos dos motores de busca de forma a obter boa visibilidade nas páginas de resultados.” (Almeida et al., 2013, p.86)

ao lado da curadoria porque a sua conceptualização é semelhante, mas, no entanto, as suas aplicações diferem.

Arora et al. (2008) argumentam que a curadoria ocorre quando as organizações decidem, com base nos dados recolhidos dos clientes, que marketing mix é adequado para cada um deles, enquanto que a personalização ocorre quando o cliente especifica, proativamente, um ou mais elementos do seu marketing mix. Ou seja, a curadoria é, em grande parte, um processo controlado pelas organizações utilizando dados obtidos dos clientes e a personalização trata-se de um processo amplamente conduzido pelo cliente que se foca no *design* e na entrega da oferta. Um exemplo clássico dado pelos autores para melhor definir a curadoria são as secções “Recomendado para si” em plataformas como a Netflix, Amazon ou Spotify.

“A curadoria, como um processo, interliga clientes e marketeers e solidifica a sua relação.” (Kumar et al., 2019, p.136) Relações com clientes que possuam um traço emocional progridem para um estado de envolvimento (*engagement*²) e, as que são consideradas relações positivas, desempenham um papel que influencia o comportamento. (Pansari e Kumar, 2017)

O elevado grau de curadoria possível na IA, é considerado um fator importante por detrás da sua popularidade e mudou o paradigma de ação de um sistema que se baseava em regras para uma abordagem assente numa aprendizagem profunda e orientada por dados (Kumar et al., 2019). No entanto, contrapõem Arora et al. (2008), o sucesso da curadoria é constringido pelo volume e qualidade de informação acerca do cliente e pela capacidade das organizações em recolherem e implementarem *insights* dos ditos dados recolhidos.

No contexto do marketing personalizado, Kumar et al. (2019) definem a curadoria como uma seleção feita automaticamente por máquinas de produtos, preços, conteúdos e mensagens publicitárias que se alinham com as preferências individuais dos clientes. Neste caso, a IA utiliza dados - transacionais, padrões de consumo e de comunicação das ofertas da organização - para prever automaticamente o tipo, o *timing* e a compra das ofertas preferidas dos clientes. Mais ainda, a IA pode também curar o conteúdo do *website* de forma a alinhar-se com as preferências do cliente, oferecer preços com base no que o cliente está disposto a

² “Definido como a atitude, comportamento, nível de ligação entre clientes; entre clientes e colaboradores; e clientes e colaboradores numa organização. Quanto maior for a positividade da atitude, do comportamento, do nível de ligação, maior é o nível de *engagement*.” (Kumar et al., 2019, p.136-137)

pagar por determinado produto/serviço e interligar as suas interações com a organização de forma personalizada através de todos os canais em que esta está presente.

Dentro da IA, segundo Jordan e Mitchell (2015), os algoritmos de *machine learning* emergiram como o principal método para desenvolver aplicações que percebam as preferências dos consumidores (com base nas suas avaliações dos produtos, utilização dos mesmos e compras anteriores) em encontrar novos produtos ou serviços. Os motores de recomendação são uma destas populares ferramentas, onde os utilizadores são associados a ofertas que gostaram no passado ou que poderão estar interessados no futuro.

2.4. Comportamento de compra do consumidor *online*

De acordo com Pomirleanu et al. (2013), o aumento da utilização da Internet por parte do consumidor impôs diversos desafios no campo do marketing, mais concretamente no estudo do comportamento do consumidor.

Perceber a psicologia por detrás do comportamento *online* é um fator essencial para competir no mercado moderno, caracterizado cada vez mais pelo incremento da concorrência e da globalização (Martinez-Ruiz e Moser, 2019). Para os autores, no contexto *online*, a resposta do consumidor já não depende somente do ambiente físico, mas também de uma variedade de novos fatores como o equipamento com que este interage e a forma como os produtos e serviços são vendidos e apresentados na Internet, que muitas vezes difere das tradicionais estratégias de marketing offline.

Cummins et al. (2014) defendem que o comportamento de compra *online* está conectado a aspetos relacionados com as relações que os consumidores desenvolvem com as marcas através da Internet e, ligado a isso, a análise das atitudes, as crenças e os sentimentos que desenvolvem como parte da sua experiência de compra movem-se do mundo físico para o virtual.

De acordo com Protheroe et al. (2020), o que acontece entre um gatilho e a decisão de compra não é linear. Existe uma rede complicada de *touchpoints* que difere de pessoa para pessoa. Com isto, a Google desenvolveu um novo modelo que procura descrever a forma como os consumidores processam toda a informação e escolhas com que se deparam ao longo da sua jornada e como é que este processo influencia o que decidem comprar. A este modelo, deram o nome de Messy Middle.

2.4.1. *Messy middle e o consumidor digital*

Antes do surgimento da Internet, os consumidores compravam em lojas físicas, onde existia menos escolha e menos informação (Protheroe et al., 2020). O que comprávamos, de acordo com os autores, estava restringido pela disponibilidade, pela proximidade e a confiança pela marca era algo que assegurava se estaríamos a tomar a decisão correta ou não.

Para Protheroe et al. (2020), o comportamento dos consumidores mudou fundamentalmente, mas, na maior parte do tempo, os instintos formados ao longo de milhares de anos, de repente, sentiram-se realizados devido à súbita riqueza de opções e oportunidades que surgiram. Esta tamanha diversidade e complexidade de opções, permitiu criar mecanismos - atalhos mentais e outras técnicas - que possibilitam encurtar caminhos quando o assunto se trata de compras.

Os autores argumentam ainda que o marketing também evoluiu e desenvolveu técnicas semelhantes. Os *marketeers* abraçaram novas plataformas, tecnologias, dados e formatos. Inovações como a *machine learning* e a Inteligência Artificial estão a transportar os consumidores para cada vez mais longe e rápido no futuro.

Posto isto, Protheroe et al. (2020), arquitetos comportamentais da Google, desenvolveram um novo modelo que permite identificar o território específico dentro do labirinto de pesquisas, anúncios, hiperligações e cliques envolvidos numa compra. Este novo



Figura 2. O modelo *Messy Middle*.

Fonte: De “How people decide what to buy lies in the “messy middle” of the purchase journey” de Rennie, A. e Protheroe, J., 2020, *Think With Google*, <https://www.thinkwithgoogle.com/intl/en-ccc/consumer-insights/consumer-journey/navigating-purchase-behavior-and-decision-making/>

modelo denomina-se de “Meio Confuso” (*Messy Middle*) e trata-se de um espaço abundante de informação e escolhas ilimitadas que os consumidores aprenderam a gerir utilizando um conjunto de atalhos cognitivos. O modelo, representado na Figura 2, mostra-nos uma bolha envolvente (Exposição e Experiência), com dois polos (Gatilhos e Compra), sendo que, no meio, se encontram dois estados mentais diferentes: a Exploração (uma atividade expansiva) e a Avaliação (uma atividade redutora).

De acordo com os autores, entre os polos de Gatilhos e Compra, assenta o “meio confuso” onde os consumidores percorrem, ciclicamente, os dois estados de Exploração e Avaliação de diversas opções até que estejam prontos para fazer a compra. Este processo ocorre num constante cenário de Exposição (um substrato que representa todos os pensamentos, sentimentos e perceções que o consumidor tem sobre as categorias, marcas, produtos e retalhistas). Após a compra, surge a Experiência tanto com a marca como com o produto em que, no fim, tudo se soma ao total da Exposição (sendo esta o conjunto de todos os fatores envolventes).

2.4.1.1. Exposição

As marcas podem inspirar fortes reações emocionais e o seu impacto pode ser sentido ao longo do processo de tomada de decisão (Protheroe et al., 2020). Acrescentam que o poder

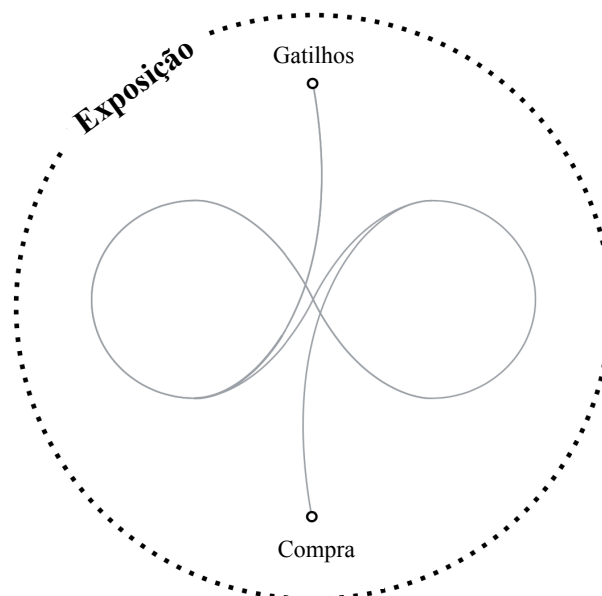


Figura 3. Exposição no *Messy Middle*.

Fonte: De “Decoding Decisions: Making Sense of the Messy Middle. In *Think With Google*.” de Protheroe, J., Rennie, A., Charron, C., & Breatnach, G., 2020, *Think With Google*, p.20. <https://www.thinkwithgoogle.com/intl/en-ccc/consumer-insights/consumer-journey/navigating-purchase-behavior-and-decision-making/>

das marcas não deriva apenas da publicidade e que estas têm uma presença que vai para além do marketing. As nossas associações com as marcas tendem a ser vitalícias nalguns casos e tudo o que conhecemos acerca delas, desde um artigo de jornal a uma conversa com amigos, pode influenciar a nossa perceção.

Argumentam os autores que a Exposição é a conscientização dos consumidores acerca das marcas e produtos numa categoria. A Exposição é a soma total de todos os esforços publicitários oriundos de uma categoria que o consumidor já tenha visto ou ouvido falar, podendo ser passivamente assimilada antes de um gatilho de compra, ser parte do gatilho em si, procurada ativamente ou experienciada pós-gatilho, podendo ser um fator decisivo na compra final. No entanto, concluem, a Exposição não se trata de um estágio, de uma fase ou de uma etapa, mas sim de um cenário de fundo omnipresente que está em constante alteração durante todo o processo de tomada de decisão.

2.4.1.2. Exploração e avaliação

Protheroe et al. (2020) afirmam que este constructo aparentemente infinito é a característica definidora do *Messy Middle*.

De acordo com estes autores, é aqui que os consumidores exploram as suas opções, expandem o seu conhecimento e o seu repertório de alternativas, seja de forma sequencial ou



Figura 4. Ciclo de Exploração e Avaliação no *Messy Middle*.

Fonte: De “Decoding Decisions: Making Sense of the Messy Middle. In *Think With Google*.” de Protheroe, J., Rennie, A., Charron, C., & Breatnach, G., 2020, *Think With Google*, p.21. <https://www.thinkwithgoogle.com/intl/en-ccc/consumer-insights/consumer-journey/navigating-purchase-behavior-and-decision-making/>

simultânea e, posteriormente, avaliam e afinam as suas escolhas. No entanto, prosseguem, compras habituais ou impulsivas podem contornar este ciclo por completo, mas outras que sejam tipicamente mais complexas, encorajam ou obrigam os consumidores a entrarem numa longa exploração, gerando assim um elevado número de opções para avaliar.

Para estes cientistas comportamentais da Google, este ciclo é a melhor forma de descrever a natureza não-linear do *Messy Middle*, com o seu progresso e retrocesso entre *websites* e nós mentais até que uma marca possa emergir vitoriosa.

Os autores concluem afirmando que este ciclo infinito de exploração/avaliação pode frustrar os anunciantes, mas que é importante lembrar que os consumidores, geralmente, sentem-se agradaos nesta fase. O objetivo do *Messy Middle* não é forçar o consumidor a sair da atividade que escolheu realizar, mas sim fornecer-lhe tudo o que precisa para que se sinta confortável a tomar uma decisão.

2.4.1.3. Experiência

A Experiência ocorre fora do *Messy Middle* e, tal como o nome indica, trata-se da experiência que um consumidor tem com um produto ou serviço que adquiriu e que alimenta diretamente a exposição subjacente (Protheroe et al., 2020). Uma marca que forneça uma excelente experiência ao consumidor, pode ela própria tornar-se num gatilho, aumentando o

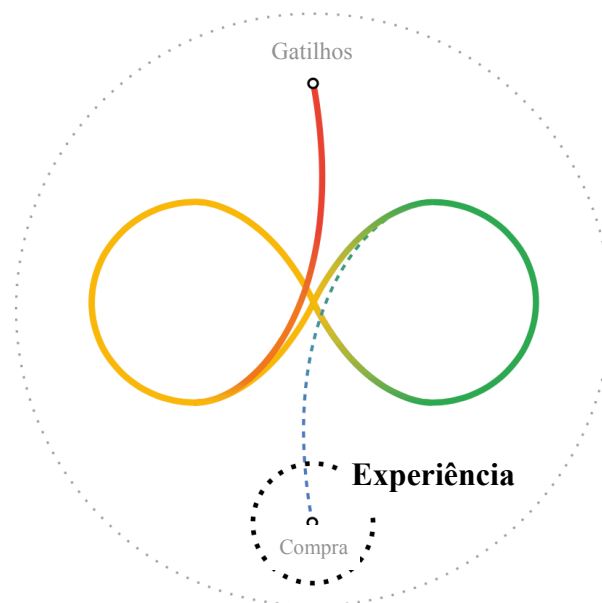


Figura 5. Experiência no *Messy Middle*.

Fonte: De “Decoding Decisions: Making Sense of the Messy Middle. In *Think With Google*.” de Protheroe, J., Rennie, A., Charron, C., & Breatnach, G., 2020, *Think With Google*, p.23. <https://www.thinkwithgoogle.com/intl/en-ccc/consumer-insights/consumer-journey/navigating-purchase-behavior-and-decision-making/>

seu potencial de compras mais frequentes. Por outro lado, uma marca que entregue uma má experiência, provavelmente terá dificuldade em voltar a adquirir o mesmo consumidor. No pior dos casos, uma péssima experiência poderá empurrar o consumidor completamente para fora da categoria e arriscar que a sua insatisfação seja descoberta por outros potenciais clientes através de avaliações *online* ou comentários nas redes sociais.

2.4.1.4. Gatilhos e compra

Os Gatilhos e a Compra - os polos deste modelo - ocorrem estritamente fora dos limites do *Messy Middle*. Os Gatilhos são responsáveis por desencadear uma reação nos consumidores, fazendo-os passar de um estado de compra passivo para ativo (Protheroe et al., 2020). Os autores afirmam que um conjunto interligado de fatores internos e externos (como sentimentos, memórias, anúncios ou lembretes) são responsáveis por desencadear esta mudança de estado.



Figura 6. Gatilhos e Compra no *Messy Middle*.

Fonte: De “Decoding Decisions: Making Sense of the Messy Middle. In *Think With Google*.” de Protheroe, J., Rennie, A., Charron, C., & Breatnach, G., 2020, *Think With Google*, p.24. <https://www.thinkwithgoogle.com/intl/en-ccc/consumer-insights/consumer-journey/navigating-purchase-behavior-and-decision-making/>

2.4.2. Influenciar o messy middle

Segundo Protheroe et al. (2020), o processo de decisão de compra dos consumidores baseia-se tanto em ações racionais como emocionais. Uma simples compra funcional que não requeira um elevado esforço financeiro pode ser acionada por considerações emocionais ou racionais.

Para os autores, a publicidade é o que turva a separação entre a emoção e a razão, particularmente o *branding*. As marcas, geralmente, cultivam ligações emocionais com os consumidores. Estas associações, muitas vezes ligadas ao nosso sentido de identidade e aspirações acerca de quem queremos ser, são uma poderosa fonte de mudança comportamental. De forma a que seja possível justificar a forma como o comportamento é influenciado durante as fases de exploração e avaliação do modelo, os autores criaram uma lista de seis vieses que estão fortemente associadas a estes estágios.

2.4.2.1. Heurística de categoria

A primeira viés descrita por Protheroe et al. (2020) denomina-se de “Heurística de Categoria”. Esta viés consiste em permitir ao consumidor realizar uma compra de forma rápida e satisfatória ao apresentar descrições curtas das especificações chave de um produto.

De acordo com Shah e Oppenheimer (2008), a heurística reduz o esforço cognitivo através de diversos impactos na tomada de decisão. Impactos estes que assentam em fornecer menos peças de informação para o consumidor analisar, bem como manipular a dependência que este tem por informação de fácil acesso, simplificar informação outrora complexa, integrar menos informação no processo de decisão e, por fim, um menor número de alternativas a considerar.

2.4.2.2. Viés autoritária

Descreve a tendência para o consumidor alterar a sua opinião ou comportamento para que se assemelhe àquele que considera ser uma autoridade num determinado assunto (Protheroe et al., 2020). Quando o consumidor se encontra na incerteza, tende a seguir um líder que acredita ser credível e um especialista reconhecido, utilizando assim a autoridade como um atalho mental.

2.4.2.3. Prova social

Os autores defendem que a Prova Social descreve a tendência em copiar o comportamento ou ações de outras pessoas em situações de ambiguidade ou incerteza. A Internet contém *reviews word-of-mouth* digitais e recomendações, facilitando a confiança do consumidor em utilizar a prova social como um atalho mental na tomada de decisão. Por vezes, prosseguem, têm consciência deste processo (como por exemplo, quando gastam tempo a ler *reviews* por iniciativa própria), mas, geralmente, são influenciados inconscientemente.

2.4.2.4. Poder do Agora

De acordo com Protheroe et al. (2020), esta viés descreve a tendência de o consumidor querer receber o que compra o mais rapidamente possível, ou seja, quanto mais tempo o consumidor tiver de esperar pelo produto, mais fraca se torna a proposta. Prosseguem, afirmando que o ser humano está programado para viver no presente e que a nossa sobrevivência evolutiva depende de nossa capacidade de lidar com os problemas do “agora”, ao invés da nossa capacidade de planear o futuro.

2.4.2.5. Viés da escassez

Para os autores da Google, esta viés baseia-se no princípio económico de que um recurso raro ou limitado é mais desejado e propõem 3 razões que se aplicam a esta tese.

- Tempo limitado: quando a disponibilidade de um produto está dependente de um determinado limite de tempo, cria um prazo que incentiva o consumidor a agir antes que este último se esgote;
- Quantidade limitada: recursos limitados ou raros são percebidos pelos consumidores como uma ameaça à sua liberdade de escolha, desencadeando uma reação para a combater e manterem o seu acesso a tal recurso;
- Acesso limitado: a limitação do acesso a determinadas funcionalidades como informação, grupos ou espaços. A censura incentiva os consumidores a colocarem um valor mais elevado a funcionalidades restritas porque a exclusividade fá-los sentir especiais.

2.4.2.6. Poder do gratuito

Protheroe et al. (2020) defendem que o “Poder do Gratuito” descreve o facto de que existe algo de especial no que é gratuito. A procura por um produto ou serviço é muito maior quando estes têm um preço igual a 0, comparativamente a um preço ligeiramente acima de 0. Continuam, argumentando que o Poder do Gratuito pode ser encarado como um gatilho emocional, uma fonte de excitação irracional que pode ser decisiva na persuasão de um consumidor para que este tome uma decisão de compra.

2.4.3. Saída do messy middle

Tal como descrito por Protheroe et al. (2020), no *Messy Middle*, a soma total da experiência e impressões dos consumidores cria um fundo de exposição que abrange marcas, produtos, entre outras coisas. Contrastando com este fundo subjacente, os Gatilhos de compra levam os consumidores a entrarem num ciclo de Exploração e Avaliação, reunindo informações e, posteriormente, afunilando-as. Se a primeira passagem pelo ciclo não produzir uma escolha definitiva, os consumidores retornam e repetem-no as vezes que forem necessárias até que tal aconteça. Por último, depois de todas as opções avaliadas, efetuam a compra ou não. De qualquer das formas, toda a experiência pela qual atravessaram, alimenta diretamente o fundo de Exposição por detrás de todo o processo.

Protheroe et al. (2020) argumenta que o *Messy Middle* é um espaço complexo para os *marketeers* onde é possível ganhar clientes, mas também perdê-los. No entanto, na perspetiva do consumidor, este apenas está a fazer aquilo que sempre fez: identificar uma necessidade e preenchê-la através de uma compra. Para os autores, quanto mais cedo as marcas conseguirem antecipar a necessidade dos consumidores por informações e orientações, melhor será a sua experiência geral. A Exploração torna-se mais eficiente e a avaliação mais simples, encurtando a jornada e resultando em melhores resultados e experiências para ambas as partes.

2.4.4. IA e a experiência do consumidor

A IA está a revolucionar a forma como os consumidores interagem com as marcas (Ameen et al., 2021). Adiantam que as tecnologias de *data analytics* que utilizam IA estão a ser rapidamente adotadas pelas empresas como resposta às constantes pressões de apresentar

margens de lucro, ciclos estratégicos mais curtos e expectativas mais altas por parte dos consumidores. Isto, de acordo com Evans (2019), altera a forma como as organizações interagem com os seus clientes. Especificamente, estes avanços na IA têm o potencial de melhorar a experiência do consumidor ao aumentar o conhecimento que a organização possui sobre este e os seus padrões de consumo (Ameen et al., 2021). Para estes autores, a implementação destas tecnologias de forma estratégica em diferentes *touch points*, pode significar um incremento na satisfação do cliente.

De acordo com Ameen et al. (2021), as empresas utilizam atualmente a IA de diversas formas como por exemplo em *chatbots*, geradores de conteúdo automático e *insights* do consumidor.

Tal como sugerido por Kumar et al. (2019), a IA pode personalizar serviços e recomendações de produtos ao analisar as compras passadas e as preferências do consumidor. As organizações esperam diversos benefícios com o uso destas tecnologias como é o caso do aumento dos níveis de automatização, redução de custos, mais flexibilidade e interações simplificadas com os clientes. No entanto, para estes benefícios terem efeitos concretos, Ameen et al. (2021) defendem que existe uma grande dependência por parte da IA em obter grandes volumes de informação dos consumidores, o que para Dwivedi et al. (2019) pode causar alguma desconfiança por parte destes relativamente ao tratamento dos seus dados. Ameen et al. (2021) acrescenta ainda que a ausência de interação humana ou esforços adicionais requeridos pelo consumidor podem constituir sacrifícios na qualidade da experiência.

De acordo com um estudo realizado pela Gartner (<https://www.gartner.com/en>), citado por Ameen et al. (2021), “a utilização de tecnologias como *machine learning* e processamento e compreensão de linguagem natural pode ajudar a analisar a intenção e o *feedback* dos consumidores em escala, de forma precisa e em velocidades não atingíveis pelos humanos” (p.2). Esta afirmação, para Newman (2019), sugere que a IA tem o potencial de se tornar uma das principais ferramentas para as organizações melhorarem constantemente a experiência dos seus clientes e, como consequência, permanecerem competitivas no mercado.

Por outro lado, Ameen et al. (2021) argumenta que os consumidores se encontram motivados pelo hedonismo e de uma necessidade de autonomia. Isto tem grandes implicações para o marketing e para a IA, uma vez que pressupõe que os consumidores estão dispostos a

abdicar de uma utilidade hedónica em favor de valores pessoais mais fortes. Os autores justificam esta afirmação dando como exemplo o momento em que um consumidor é confrontado com recomendações algorítmicas baseadas nas suas preferências, este pode seleccionar alternativas menos favoráveis como uma contra-medida às recomendações.

T. Davenport et al. (2020) referem três tópicos importantes quando se fala de IA conjuntamente com comportamento do consumidor: adoção, utilização e problemas pós-utilização.

Relativamente à adoção da tecnologia, os autores defendem que devido a uma variedade de fatores, os consumidores vêem a IA como algo negativo, constituindo assim uma barreira para a sua adoção. Esta perspetiva nociva, para Castelo et al. (2019), parte do pressuposto que os consumidores assumem que a IA não consegue sentir ou que é incapaz de identificar o que é único em cada um deles. Luo et al. (2019) sugerem que os consumidores vêem os *bots* alimentados por IA como sendo menos empáticos. Longoni et al. (2020) propõe que, ao dar a oportunidade aos consumidores de modificarem ligeiramente a IA, pode fazer com que estes negligenciam as questões levantadas anteriormente e se foquem mais nos benefícios da personalização.

Na utilização da IA, Kim e Duhachek (2020) afirmam que quando um consumidor interage com uma aplicação que faz uso desta tecnologia, isto pode desencadear um constructo mental de baixo nível. T. Davenport et al. (2020) defendem que futuros estudos deverão passar por determinar que outros níveis mentais poderão ser desencadeados pela IA, dando como exemplo a utilização desta tecnologia como uma forma de prevenção para consumidores que nunca a utilizaram. Perceções retiradas destes futuros estudos teriam implicações na forma como a IA deveria comunicar com os consumidores, uma vez que a comunicação exerce um impacto mais forte quando se enquadra numa mentalidade já preparada para o ato.

Posto isto, se as preferências atuais dos consumidores diferirem das escolhas que fizeram no passado (como por exemplo, uma mudança para um estilo de vida mais saudável), a IA pode dificultar a busca por alternativas alinhadas com as preferências atuais ao apresentar opções que reflitam comportamentos já ultrapassados (T. Davenport et al., 2020).

Por fim, na fase pós-adoção da IA, Luo et al. (2019) crêem que o facto da IA conseguir prever as necessidades dos consumidores pode causar um sentimento de perda de autonomia.

Teoricamente, prosseguem, como a IA facilita a obtenção de dados e permite criar estratégias micro-segmentadas de marketing, os consumidores deveriam ver estas ofertas mais favoravelmente uma vez que reduzem o seu esforço de pesquisa. No entanto, podem também diminuir a autonomia percebida pelos consumidores com impacto nas suas avaliações e escolhas (André et al., 2018). Defendem ainda que se os consumidores obtiverem conhecimento de que a IA pode prever as suas escolhas com relativa facilidade, estes podem deliberadamente escolher uma alternativa diferente de forma a reafirmar a sua autonomia.

2.5. Teorias de aceitação da tecnologia

De acordo com Groß (2015), a maioria dos estudos que abordam tecnologias inovadoras são baseados no Modelo de Aceitação da Tecnologia (TAM, *Technology Acceptance Model*), na Teoria do Comportamento Planeado (TPB, *Theory of Planned Behaviour*) ou na Teoria Unificada de Aceitação e Uso da Tecnologia (UTAUT, *Unified Theory of Acceptance and Use of Technology*), sendo esta última uma redefinição de perspectiva integrada das anteriores.

2.5.1. Modelo de aceitação da tecnologia

Para Nagy e Hajdú (2021), o TAM é um dos modelos teóricos mais utilizados para explicar o porquê de um indivíduo aceitar ou rejeitar determinada tecnologia e prever o seu

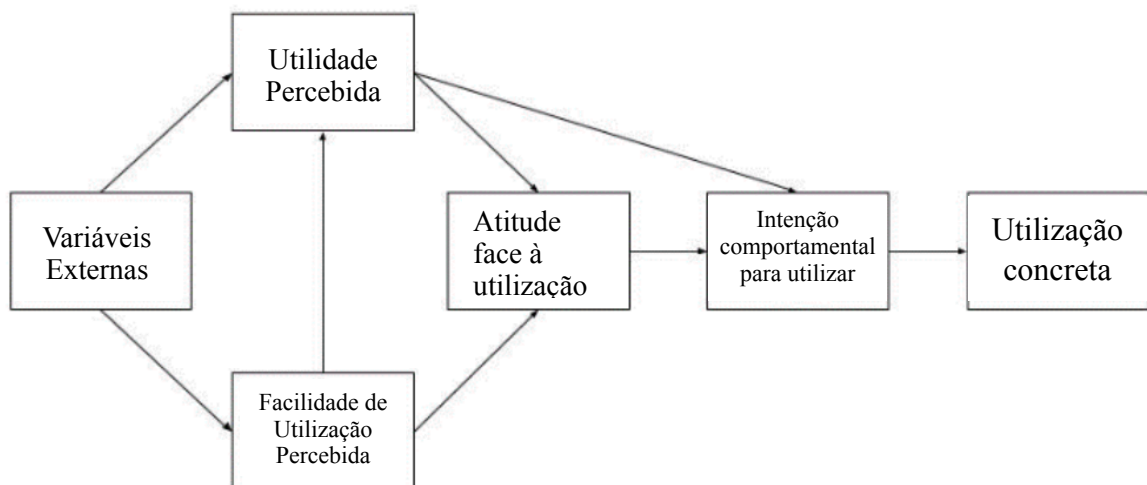


Figura 7. Modelo de Aceitação da Tecnologia (TAM).

Fonte: De “Consumer Acceptance of the Use of Artificial Intelligence in Online Shopping: Evidence From Hungary.” de Nagy, S., & Hajdú, N., 2021, *Amfiteatru Economic*, p.158. <https://doi.org/10.24818/EA/2021/56/155>

comportamento. Similarmente, Marangunic e Granic (2015), defendem que o modelo TAM é extremamente popular no campo da tecnologia e que evoluiu para se tornar um modelo-chave no estudo do comportamento humano relativamente à aceitação ou rejeição de tecnologia.

Davis (1985), o autor do modelo, afirma que o TAM tradicional (Figura 7) é composto por seis elementos: Variáveis Externas, Utilidade Percebida, Facilidade de Utilização Percebida, Atitude, Intenção Comportamental para Utilizar e Utilização Concreta. Nagy e Hajdú (2021), explica que cada seta presente no modelo representa uma relação de causa-efeito. Isto é, as Variáveis Externas possuem uma influência direta na Utilidade Percebida (UP) e na Facilidade de Utilização Percebida (FUP), duas componentes de crença cognitiva. A Facilidade de Utilização Percebida influencia diretamente a Utilidade Percebida e a Atitude (AT), enquanto que a Utilidade Percebida tem um impacto direto tanto na Atitude como na Intenção Comportamental para Utilizar (IC) que, por sua vez, afeta a Utilização Concreta (UC).

3. Metodologia de Investigação

3.1. Inquérito por questionário

Esta dissertação apresenta uma investigação de carácter estatístico com o propósito de averiguar o nível de aceitação da IA por parte dos consumidores nas suas compras *online*. O presente estudo utiliza um método quantitativo.

Relativamente à sua tipologia, a investigação apresenta 3 distintas que servem o propósito de tornar o estudo mais coeso e robusto, sendo elas: a exploratória, a descritiva e a correlacional.

Exploratória, visto que, de acordo com Révillion (2003), esta tipologia visa dotar o investigador de um maior conhecimento sobre o tema em perspetiva e é ideal para os primeiros estágios da investigação quando a familiaridade, o conhecimento e a compreensão de determinado fenómeno são geralmente insuficientes. Precisamente o que foi elaborado aquando a revisão da literatura.

Descritiva, uma vez que esta tipologia objetiva conhecer e interpretar a realidade sem nela interferir para a modificar (Vieira, 2002). Ainda de acordo com o mesmo autor, uma pesquisa descritiva está interessada em descobrir e observar fenómenos, procurando descrevê-los, classificá-los e interpretá-los, podendo ainda relacionar variáveis. Acrescenta que os instrumentos de medição mais utilizados para esta tipologia são as entrevistas, questionários e observação.

Correlacional, pois segundo Coutinho (2008), esta tipologia tem como objetivo encontrar e avaliar a intensidade de relações entre variáveis, sem manipulações e sem pretensões de causalidade. Na mesma linha, esta busca de associações ou relações entre as variáveis processa-se através de procedimentos estatísticos que nos fornecem uma medida quantificada do grau de relação entre variáveis, a que se pode chamar de “coeficiente de correlação” e “análise de causa-efeito”.

Em relação à população, esta consiste em indivíduos portugueses que sejam compradores de produtos *online*. A seleção da amostra em concreto passou por meio de uma pergunta filtro com o objetivo de aceitar ou rejeitar participantes no estudo consoante a sua atividade relacionada com compras através da Internet. Se o indivíduo indicou que já comprou *online*, teve então condições para participar no estudo. Já se o oposto tiver ocorrido, não pôde continuar.

A técnica de amostragem que se colocou em prática foi não-probabilística por conveniência, uma vez que não se possui uma lista completa dos indivíduos que formam a população, garantindo a aleatoriedade da escolha.

Como instrumento de medição, elaborou-se um inquérito por questionário. O estudo realizado por Nagy e Hajdú (2021) foi fulcral para o desenvolvimento da investigação, uma vez que possui um objetivo semelhante. As questões utilizadas no questionário foram largamente baseadas no estudo destes autores, mas com o acrescento de variáveis relacionadas com o *Messy Middle* - Exposição, Gatilhos, Exploração, Avaliação, Experiência e Compra - de forma a que se pudesse colocar em prática este novo modelo e, ao mesmo tempo, associando-o à utilização da IA nas plataformas de comércio eletrónico.

O questionário foi elaborado na plataforma *Google Forms* e publicado nas diversas redes sociais do autor desta dissertação (*Facebook, Instagram e LinkedIn*) entre os dias 14 de julho de 2021 e 17 de julho do mesmo ano. O questionário foi composto por 30 questões, entre as quais 3 de carácter sociodemográfico (sexo, região e faixa etária), 1 pergunta filtro e as restantes 26 pertencentes aos diferentes constructos do TAM e do *Messy Middle*. Após a indicação dos dados sociodemográficos e resposta positiva à pergunta filtro, os participantes foram confrontados com uma breve explicação, acompanhada de exemplos, das diversas aplicações que a IA pode ter no marketing digital.

A Tabela 3 representa os constructos, as respetivas definições para cada um destes e o instrumento de medição utilizado. É de salientar que todas as variáveis foram medidas através de uma Escala de Likert a cinco pontos onde (1) representa “discordo totalmente” e (5) “concordo totalmente”, em conformidade com os procedimentos do TAM descritos por Nagy e Hajdú (2021).

Tabela 3

Constructos, definições e instrumentos de medição

Constructo	Definição	Instrumento de medição
Variáveis externas		
Confiança (C)	Probabilidade subjetiva em que as pessoas acreditam que a IA trabalha com os seus interesses em mente.	C1. Acredito que a utilização da IA no retalho <i>online</i> é usada para me dar as melhores ofertas. C2. Confio em lojas que utilizam IA. C3. A quantidade de dados que a IA recolhe sobre mim não me preocupa. C4. A segurança das minhas compras é essencial para que eu confie na IA. C5. Confio que a minha privacidade <i>online</i> (histórico de navegação, de compras, etc.) está segura com os sistemas de IA.
Experiência (EXP)	O conhecimento do consumidor e a sua experiência em utilizar uma loja alimentada por IA.	EXP1. Tenho experiência em comprar <i>online</i> . EXP2. Já utilizei <i>websites</i> que fazem uso da IA (<i>chatbots</i> , recomendações, sugestões de alternativas, conteúdo personalizado, etc). (Variável “Experiência” do Messy Middle) EXP3. Uma boa experiência numa loja <i>online</i> que contenha IA é essencial para que eu volte a comprar na loja em questão no futuro. (Variável “Experiência” do Messy Middle) EXP4. Consumo regularmente <i>websites</i> / plataformas que fazem uso da IA.
Relevância da Tarefa (RT)	Grau em que o consumidor acredita que lojas que fazem uso da IA são aplicáveis ao seu percurso de compra.	RT1. Acredito que a IA pode ser utilizada eficazmente no meio digital. RT2. Acredito que a IA pode ser útil durante a minha pesquisa por alternativas. (Variável “Exploração” do Messy Middle) RT3. Acredito que a publicidade que vejo na Internet encoraja-me a comprar <i>online</i> . (Variável “Gatilhos” e “Exposição” do Messy Middle)
Variáveis internas		

Utilidade Percebida (UP)	Grau em que o consumidor acredita que a utilização da IA nas compras <i>online</i> tornaria as suas compras mais eficazes.	UP1. A utilização de IA no retalho <i>online</i> permite-me encontrar melhores oportunidades de negócio. (Variável “Exploração” do Messy Middle) UP2. A utilização de IA no retalho <i>online</i> melhora a eficácia das minhas compras. UP3. A utilização de IA no retalho <i>online</i> é útil para mim. UP4. A utilização de IA no retalho <i>online</i> permite-me poupar tempo.
Facilidade de Utilização Percebida (FUP)	Grau em que o consumidor acredita que a utilização de IA em plataformas de comércio eletrónico será livre de esforço.	FUP1. Lojas online alimentadas por IA são fáceis de usar. FUP2. Comprar <i>online</i> não requer esforço mental da minha parte se a IA me apresentar diversas alternativas. (Variável “Exploração e Avaliação” do Messy Middle) FUP3. Comprar não é complicado se a IA me recomendar produtos. FUP4. Aprender a usar lojas alimentadas por IA é fácil para mim.
Atitude (AT)	A atitude do consumidor face a comprar em lojas com IA.	AT1. Comprar numa loja <i>online</i> que é alimentada por IA é uma boa ideia. AT2. Comprar numa loja <i>online</i> ou aplicação é uma decisão sábia. AT3. Tenho uma atitude positiva em relação a lojas alimentadas por IA.
Intenção Comportamental (IC)	A intenção comportamental do consumidor em fazer compras em lojas alimentadas por IA.	IB1. Tenciono visitar e usufruir de lojas alimentadas por IA mais frequentemente. IB2. Estou disposto a gastar mais dinheiro em produtos que se encontram em lojas ou aplicações alimentadas por IA. IB3. Estou mais disposto(a) a comprar numa loja que adicione ofertas gratuitas às minhas compras comparativamente com as que não o fazem. (Variável “Compra” do Messy Middle)

Fonte: Acedido e adaptado de “Consumer Acceptance of the Use of Artificial Intelligence in Online Shopping: Evidence From Hungary”, de Nagy, S. and Hadjú, N., 2021, *Amfiteatru Economic*, 23(56), p.160-161

De acordo com o TAM, cada seta indicadora dentro do modelo representa uma relação causa-efeito, formulando assim uma hipótese. A Figura 8 representa esta lógica adaptada ao questionário realizado. Posto isto, foram colocadas as seguintes hipóteses a serem testadas:

H₁: A confiança influencia positivamente a utilidade percebida;

H₂: A experiência influencia positivamente a utilidade percebida;

H₃: A relevância da tarefa influencia positivamente a utilidade percebida;

H₄: A facilidade de utilização percebida influencia positivamente a utilidade percebida;

H₅: A facilidade de utilização percebida influencia positivamente a atitude;

H₆: A utilidade percebida influencia positivamente a atitude;

H₇: A utilidade percebida influencia positivamente a intenção comportamental;

H₈: A atitude influencia positivamente a intenção comportamental;

H₉: A confiança influencia positivamente a facilidade de utilização percebida;

H₁₀: A experiência influencia positivamente a facilidade de utilização percebida;

H₁₁: A relevância da tarefa influencia positivamente a facilidade de utilização percebida.




Figura 8. Modelo de investigação utilizado.

Foram obtidas um total de 176 respostas, das quais 154 se demonstraram válidas. Os dados recolhidos foram posteriormente migrados do *Google Forms* para o *SPSS Statistics* e elaborou-se uma análise estatística para que fosse possível testar as hipóteses formuladas anteriormente.

4. Apresentação dos Resultados

4.1. Caracterização da amostra

Após a divulgação do questionário nos devidos meios já esclarecidos, obteve-se um total de 176 respostas. No entanto, uma vez que 22 inquiridos (12,5% da amostra total) indicaram que nunca compraram *online*, foram imediatamente impedidos de responder às questões seguintes e, conseqüentemente, eliminados da análise estatística. Posto isto, o estudo é então composto por 154 participantes válidos. Num total de 154 inquiridos, 72,1% são do sexo feminino enquanto que 27,9% são do masculino (Tabela 4).

Tabela 4

Sexo, faixa etária e região dos inquiridos que contribuíram para o estudo

	Frequência	%
Sexo		
Feminino	111	72,1
Masculino	43	27,9
Faixa etária		
< 18 anos	1	0,6
Entre 18 e 24 anos	43	27,9
Entre 25 e 34 anos	34	22,1
Entre 35 e 44 anos	35	22,7
Entre 45 e 54 anos	27	17,5
Entre 55 e 64 anos	11	7,1
> 65 anos	2	1,9
Região		
Área Metropolitana de Lisboa	113	73,4
Centro	28	18,2
Norte	5	3,2
Alentejo	3	1,9
Algarve	5	3,2
Total válido	154	100

Relativamente à idade dos elementos da amostra, observou-se que o maior aglomerado (43 indivíduos) encontra-se com uma idade compreendida entre os 18 e os 24 anos (27,9%), sendo seguido pela faixa dos 35 a 44 anos, com 34 indivíduos (22,7%). As idades menos representadas no estudo foram indivíduos com menos de 18 anos e com mais de 65 anos (0,6% e 1,9%, respetivamente).

Quanto à região, a esmagadora maioria dos inquiridos (113) pertence à Área Metropolitana de Lisboa (73,4%), seguida pela região Centro (18,2%). A região com menor expressão na amostra é o Alentejo, com apenas 3 indivíduos (1,9%).

4.2. Consistência interna

A confiabilidade das respostas foi calculada através do Alfa de *Cronbach* (α). “O α pode ser interpretado como o coeficiente médio de todas as estimativas de consistência interna que se obteriam se todas as divisões possíveis da escala fossem feitas” (Maroco e Garcia-Marques, 2006, p.73).

De acordo com Murphy e Davidsholder (1988), citados por Maroco e Garcia-Marques (2006), um coeficiente α varia entre 0 e 1, onde um valor <0.6 é considerado como tendo uma “fiabilidade inaceitável”, 0.7 uma “baixa fiabilidade”, entre 0.8 e 0.9 uma “fiabilidade moderada a elevada” e >0.9 uma “fiabilidade elevada”.

Relativamente à consistência interna do questionário elaborado, anteriormente à sua divulgação pública, foi realizado um pré-teste. Aqui, foram obtidas 30 respostas nas quais todos os indivíduos indicaram que já compraram *online*, estando portanto aptos para responderem a todas as questões do estudo. Após a recolha das respostas, os dados foram migrados para o SPSS e foi efetuado o teste de fiabilidade. As Tabelas 5 e 6 demonstram os resultados.

Tabela 5
Resumo de processamento do caso

		N	%
Casos	Válidos	30	100.0
	Excluídos	0	.0
	Total	30	100.0

Tabela 6
Estatísticas de confiabilidade

Alfa de Cronbach (α)	Alfa de Cronbach com base em itens padronizados	Nº de itens
.944	.949	26

Após a observação da Tabela 6, conclui-se que o questionário realizado possui um índice de fiabilidade elevado, já que $\alpha > 0.9$.

4.3. Estatísticas descritivas

Foi elaborado o cálculo das estatísticas descritivas tanto das questões colocadas sob a forma de Escala de Likert, bem como das variáveis sociodemográficas.

Tabela 7
Estatísticas descritivas das variáveis sociodemográficas

	Sexo	Região	Faixa etária	Já comprou <i>online</i>?
N	154	154	154	154
Média	-	-	2.62	-
Moda	Feminino	Área Metropolitana de Lisboa	Entre 18 e 24 anos	Sim
Desvio Padrão	0.450	1.318	1.366	0
Mínimo	-	-	Menos de 18 anos	-
Máximo	-	-	Mais de 65 anos	-

Tabela 8
Estatísticas descritivas das questões de concordância

Variável	N	Média	Mediana	Moda	Desvio Padrão
C1	154	3.695	4	3	1.056
C2		3.734	4	4	0.977
C3		2.786	3	3	1.339
C4		4.234	5	5	1.015
C5		3.104	3	3	1.253
EXP1		4.169	4	5	1.009
EXP2		3.864	4	5	1.085
EXP3		3.909	4	5	1.099
EXP4		3.669	4	3	1.120
RT1		3.993	4	4	0.889
RT2		4.084	4	4	0.928
RT3		3.649	4	5	1.270
UP1		3.727	4	4	1.024
UP2		3.721	4	4	1.019
UP3		3.617	4	4	1.049
UP4		3.825	4	4	1.103
FUP1		3.934	4	4	0.905
FUP2		3.650	4	4	1.186
FUP3		3.650	4	4	1.158
FUP4		4.040	4	5	0.935
AT1		3.851	4	4	0.955
AT2		3.734	4	4	0.950
AT3		3.656	4	4	1.069
IC1		3.656	4	4	1.056
IC2		3.090	3	3	1.310
IC3		4	4	5	1.029

Analisando a Tabela 8, observando especificamente a Moda, é possível concluir que, de um modo geral, os participantes concordam com as afirmações que lhes foram apresentadas.

4.4. Teste de hipóteses

Na testagem das hipóteses, devido aos dados estarem agrupados por constructos multidimensionais - Confiança, Experiência, Relevância da Tarefa, Utilidade Percebida, Facilidade de Utilização Percebida, Atitude e Intenção Comportamental - foi calculada uma média para cada um destes de forma a que fosse possível correlacioná-los.

Na Tabela 9 estão representadas as 11 hipóteses formuladas anteriormente com o total de variáveis calculadas (N) e as relações testadas. As setas indicam a direção da relação presente no TAM.

Tabela 9
Resultados da testagem das hipóteses

Hipótese	N	Relação	Correlação de Pearson (r)	Sig. 2-tailed (p)	Variância (r ²)	Resultado
H ₁	154	C → UP	0.705	0	0.497	Rejeitada
H ₂		EXP → UP	0.487	0	0.237	Rejeitada
H ₃		RT → UP	0.768	0	0.590	Aceite
H ₄		FUP → UP	0.784	0	0.614	Aceite
H ₅		FUP → AT	0.747	0	0.559	Aceite
H ₆		UP → AT	0.774	0	0.599	Aceite
H ₇		UP → IC	0.737	0	0.544	Aceite
H ₈		AT → IC	0.818	0	0.670	Aceite
H ₉		C → FUP	0.642	0	0.412	Rejeitada
H ₁₀		EXP → FUP	0.571	0	0.327	Rejeitada
H ₁₁		RT → FUP	0.688	0	0.473	Rejeitada

Ao nível da Correlação de Pearson (r), considera-se que existe uma relação estatisticamente significativa quando $\rho < 0.05$ na direção prevista pelo Modelo da Aceitação da Tecnologia. Para Nettleton (2014), a Correlação de Pearson é o método mais comum para variáveis numéricas. Este cálculo atribui um valor entre -1 e 1 à ligação entre duas variáveis distintas. 0 significa que não existe qualquer correlação entre as variáveis, enquanto que 1 indica uma totalmente positiva e -1 uma totalmente negativa. O autor adianta que a interpretação realiza-se da seguinte forma: uma correlação de 0.7 entre a variável A e a variável B indicaria uma relação significativa e positiva entre as duas. Uma relação positiva significa que se a variável A sobe, a B terá também este comportamento. No caso de uma correlação negativa, ocorre o oposto (se A sobe, B desce).

Calculou-se também a Variância (r^2) através de regressão linear. De acordo com Jr Hair et al. (2011), a interpretação sobre o que constitui um valor de r^2 “alto” depende da natureza do campo de estudo da investigação. Adianta o autor que os estudos relacionados com marketing encontram-se ligados às ciências sociais e, por isso, quando se analisam relações de causa-efeito entre constructos (como no caso do modelo TAM), r^2 interpreta-se da seguinte forma: 0.75 considera-se que existe uma variância “substancial”, 0.50 indica-nos que se encontra em níveis “moderados/aceitáveis” e 0.25 significa que é “fraca”.

Observando a Tabela 9, verifica-se que todas as correlações entre as variáveis são positivas, uma vez que $\rho < 0.05$. No entanto, não se pode aceitar todas as hipóteses porque existem valores de r^2 abaixo do que se pode considerar “aceitável”. Sendo assim, a H_1 , H_2 , H_9 , H_{10} e H_{11} foram rejeitadas por se encontrarem nestes patamares.

Relativamente à correlação mais forte, esta refere-se à relação entre a Atitude e a Intenção Comportamental (H_8), encontrando-se muito próxima de uma correlação perfeita. Significa isto que quanto mais positiva for a atitude do consumidor relativamente a comprar em lojas *online* que utilizem IA, maior será também a sua intenção para as utilizar. Sobre a variância, acrescenta-se que a H_8 apresenta um valor de 0.67, próximo do que se pode considerar “substancial”, mas ainda dentro dos níveis “moderados”. Isto indica que parte da variável dependente (67% da Intenção Comportamental) é explicada através da variância ocorrida na variável independente (Atitude).

Em segundo lugar, surge a correlação constituída pela Facilidade de Utilização Percebida e a Utilidade Percebida (H_4) que demonstra que quanto maior for a perceção de

facilidade do consumidor em utilizar a IA, maior será a sua utilidade para este. Ou seja, o consumidor afirma que quanto menor for o esforço mental que tiver de fazer para utilizar lojas que contenham IA, mais útil será a IA na eficácia das suas compras. Tal como a hipótese referida anteriormente, a H₄ também se encontra em níveis “moderados”, apresentando um r² de 0.614, ou seja, 61,4% da Utilidade Percebida é influenciada pela variância da Facilidade de Utilização Percebida.

Relativamente à correlação linear mais fraca, esta é constituída pela Experiência e pela Utilidade Percebida. Apesar de ser uma correlação positiva, é consideravelmente mais baixa que todas as outras apresentadas, o que causa também um decréscimo acentuado na variância quando comparada com outras hipóteses (r²=0.237), encontrando-se no nível considerado “fraco”. Significa isto que apenas 23,7% da Utilidade Percebida pelos consumidores relativamente à IA nas plataformas de comércio eletrónico é explicada pela variância da Experiência.

5. Discussão dos Resultados

Como indicado no capítulo anterior, rejeitaram-se 5 das 11 hipóteses colocadas. Isto é, a investigação realizada não se encontra em perfeita sintonia com o Modelo da Aceitação da Tecnologia proposto por Davis (1985). O autor do modelo defende que as Variáveis Externas (Confiança, Experiência e Relevância da Tarefa) influenciam os constructos da resposta cognitiva (Facilidade de Utilização Percebida e Utilidade Percebida) que, por sua vez, influenciam a resposta afetiva (Atitude) e, conseqüentemente, a resposta comportamental (Intenção Comportamental). Tal não se verificou. No estudo, averiguou-se que nem todas as Variáveis Externas influenciam, de facto, os constructos da resposta cognitiva. Das Variáveis Externas, apenas a Relevância da Tarefa possui uma relação causa-efeito com a Utilidade Percebida (H₃).

No estudo realizado por Nagy e Hajdú (2021), os autores também não obtiveram resultados alinhados com o modelo original, tendo, inclusive, rejeitado uma das suas hipóteses (H₄: a Facilidade de Utilização influencia positivamente a Atitude). Os autores justificam esta discrepância entre os seus resultados e o modelo de Davis (1985) ao facto de que comprar numa loja que utilize IA não é complicado, logo, não requer muito esforço mental. Comparativamente aos resultados obtidos nesta dissertação, a hipótese equivalente à de Nagy e Hajdú (2021), a H₅, obteve conclusões distintas. Enquanto que os autores averiguaram que a Facilidade de Utilização não influencia positivamente a Atitude, aqui verificou-se o contrário. Existe, de facto, uma influência moderada da variável independente sobre a dependente.

De acordo com Ha e Stoel (2009), a principal razão pela qual muitos consumidores não utilizam a Internet para efetuar compras é devido às suas crenças acerca da segurança de efetuar negócios *online*. Adiantam que a confiança dos consumidores nas lojas *online* e a tecnologia da Internet são fatores chave que influenciam as suas crenças acerca da segurança. Corroborado por Pavlou (2003) quando este afirma que as características únicas do ambiente de compra virtual (incapacidade de ver e tocar no produto e a ausência de contacto direto com colaboradores) fazem com que os consumidores sintam uma maior incerteza e risco elevado nas suas decisões de compra *online*. Segundo este autor, a confiança é uma das ferramentas mais eficazes para reduzir a incerteza e os riscos e gerar uma sensação de segurança.

Observando os resultados obtidos na investigação, apesar da Confiança apresentar correlações positivas com as devidas variáveis, esta também apresenta variâncias abaixo do esperado. Relativamente à relação entre a Confiança e a Utilidade Percebida (H_1), esta possui uma variância bastante próxima do nível considerado “aceitável” ($r^2=0.497$). No que toca à relação entre a Confiança e a Facilidade de Utilização Percebida, esta apresenta uma variância de 0.412, fazendo também ela parte do lote de hipóteses rejeitadas.

No que toca à relação entre a Confiança e a Facilidade de Utilização Percebida (H_9), na investigação realizada por Nagy e Hajdú (2021), os autores verificaram que o nível de confiança dos consumidores relativamente a uma loja que utilize IA é proporcional à facilidade percebida que estes esperam dela. Isto é, quanto maior o índice de confiança, maior será a facilidade de utilização. Os resultados da presente dissertação apresentam conclusões diferentes. A variância registada é de apenas 0.412, encontrando-se abaixo do nível “aceitável”. Ou seja, menos de metade da Facilidade de Utilização Percebida é explicada pela variância da Confiança.

Relativamente à Experiência, na perspetiva do consumidor, Ha e Stoel (2009) definem-na nas compras *online* como “o número de experiências que inclui a busca por informação, navegação no *website*, colocar uma encomenda, pagamento, interações com o apoio ao cliente, entrega, resolução de problemas pós-compra e satisfação com a compra” (p. 567). No estudo conduzido, verificou-se que a Experiência não impacta qualquer na componente cognitiva do TAM (H_2 e H_{10}). No que toca à relação com a Utilidade Percebida (H_2), registou a pior correlação de todas as hipóteses formuladas e, conseqüentemente, a pior variância (0.237), encontrando-se no patamar considerado “fraco”. Similarmente, a relação da Experiência com a Facilidade de Utilização Percebida (H_{10}) foi rejeitada. A correlação demonstrou ser a segunda pior dentro das 11 testadas, bem como a variância (0.327).

Por último, existem seis hipóteses que se encontram em sintonia com o modelo de Davis (1985), sendo elas: H_3 , H_4 , H_5 , H_6 , H_7 e H_8 . Destas, a H_8 (Atitude → Intenção Comportamental) é a que apresenta tanto a correlação mais forte, como a variância. Em conformidade com o que defendem Nagy e Hajdú (2021), estas conclusões sugerem que consumidores que tenham uma atitude positiva em relação a lojas que utilizam IA, estão mais dispostos a comprar nessas mesmas lojas. Olhando também para a segunda correlação mais forte, a H_4 indica-nos que a 61,4% da Utilidade Percebida provém da variância da Facilidade

de Utilização. Isto é, quanto mais fácil for utilizar lojas que contenham IA para o consumidor, mais utilidade este vê nestas.

6. Conclusão

Ao longo da dissertação foi possível aprofundar o conhecimento acerca das tecnologias inerentes à Inteligência Artificial, quais as suas aplicabilidades no Marketing Digital e o seu nível de aceitação por parte dos consumidores aquando as suas compras através da Internet. Para além disso, verificou-se que o TAM não é um modelo totalmente adequado para a realização deste estudo.

É notório que ao longo dos últimos 100 anos, o Marketing, para Brunswick (2014) tem evoluído constantemente devido à variedade de influências que o envolvem. O Marketing Digital, sendo a vertente mais moderna deste campo, utiliza estratégias inovadoras que magnetizam e retêm uma série de consumidores que adquirem um determinado produto ou serviço (Ramesh e Vidhya, 2019). Parte destas estratégias assentam em utilizar tecnologias como a IA, onde ferramentas como os motores de busca, a *Internet of Things*, os *chatbots*, o *marketing automation* e a curadoria de ofertas utilizam algoritmos que lhes permite entregar um maior valor aos consumidores.

Relativamente à intenção de compra, explorou-se um modelo criado recentemente pela Google (2020): o Messy Middle. Este modelo, construído com influências de outros anteriormente desenvolvidos (como o AIDA e o ZMOT), procura explicar a totalidade da jornada da compra *online* desde o primeiro estímulo, passando pelo processo de procura de alternativas, até à compra final. Assim, é possível utilizar diversas tecnologias da IA para influenciar a intenção de compra dos consumidores. Tecnologias como a publicidade digital em tempo real podem influenciar o momento da Exposição e da Exploração e Avaliação, gerando assim um elevado número de alternativas que o consumidor pode considerar antes de efetuar a sua compra. A Google (2020) indica-nos também que, numa lista de centenas, existem 6 vieses chave que influenciam a intenção de compra dos consumidores dentro do Messy Middle: a Heurística de Categoria, a Viés Autoritária, a Prova Social, o Poder do Agora, a Viés da Escassez e o Poder do Gratuito.

Por fim, no estudo quantitativo, utilizou-se o já aprofundado Modelo da Aceitação de Tecnologia desenvolvido por Davis (1985). A utilização deste modelo não se demonstrou totalmente adequada, tendo-se rejeitado 5 hipóteses. Para averiguar a utilidade do modelo, baseou-se a investigação num estudo realizado por Nagy e Hajdú (2021) onde os autores procuraram explorar o nível de aceitação dos consumidores acerca da utilização de IA nas

compras *online* na Hungria. No entanto, para esta dissertação, realça-se o acrescento de variáveis baseadas no *Messy Middle* para que fosse possível obter informação que complementasse a aceitação da IA e a intenção de compra dos consumidores. O *Messy Middle*, por se tratar de um modelo desenvolvido recentemente, à data da realização deste projeto, não possui estudos que o tenham colocado em prática desta forma.

Os resultados, como já referidos, foram maioritariamente, mas não totalmente positivos. 6 hipóteses foram aceites e 5 foram rejeitadas. O que influencia a intenção comportamental dos consumidores face à utilização de IA nas suas compras *online* é a atitude, através da influência da relevância que esta tecnologia tem para a tarefa que os consumidores estão a realizar. Por sua vez, este fator influencia diretamente a utilidade, que causa um efeito direto significativo na atitude. Esta, conseqüentemente, impacta a intenção comportamental.

Assim sendo, em linha com os resultados obtidos, as lojas *online* precisam de criar ferramentas que sejam relevantes para melhorar a eficácia das compras dos consumidores para que este tenha uma maior tendência para as utilizar. Esta relevância pode ser atingida através da personalização de ofertas para que os consumidores consigam realizar os melhores negócios, diminuindo assim o tempo que estes permanecem no ciclo de Exploração-Avaliação do *Messy Middle*. A soma de todos estes fatores contribui para uma atitude mais positiva em torno de lojas que utilizem IA, contribuindo para um aumento de tráfego nas suas plataformas.

Por fim, torna-se mais importante do que nunca criar uma jornada personalizada para cada consumidor de forma a satisfazer as suas necessidades de uma forma mais eficaz e, ao mesmo tempo, melhorar cada vez mais a experiência *online*. Posto isto, com a realização de toda esta investigação, confirma-se que a IA é uma tecnologia altamente eficiente que os marketeers podem utilizar para perceber a adaptação/aceitação dos consumidores a determinadas práticas digitais.

6.1. Limitações

Ao longo do desenvolvimento da investigação, encontraram-se algumas limitações que não permitiram que o estudo fosse tão profundo como poderia ter sido.

Primeiramente, e a mais óbvia das que serão mencionadas, a propagação do novo coronavírus SARS-CoV-2, mais conhecido por COVID-19, foi a mais impactante. O facto

desta dissertação ter sido realizada ao longo de um período pandémico não permitiu a realização de “trabalho de campo”. O plano inicial para este projeto consistia em efetuar entrevistas presenciais a especialistas em IA e *marketeers* que utilizassem estas tecnologias no desempenho das suas tarefas profissionais de forma a averiguar a taxa de utilização e procurar saber se consideravam esta tecnologia de facto útil e eficiente. Posteriormente, comparar-se-iam os resultados das entrevistas com a perceção e o nível de aceitação dos consumidores acerca da utilização da IA nas lojas *online*, obtendo assim uma investigação mais detalhada acerca da temática.

De forma a tentar contornar o efeito pandémico na investigação, mas mantendo o mesmo nível de detalhe, procurou-se também elaborar um inquérito por questionário a profissionais de *marketing*. Tal não foi possível devido a limitações de tempo e demora na obtenção de respostas. Posto isto, manteve-se então apenas a investigação relacionada com a perspetiva do consumidor.

Outra razão pela qual o estudo se encontra limitado é o facto do modelo *Messy Middle* ter sido criado recentemente, à data da escrita deste projeto. A utilização de um modelo com tão pouco tempo de existência, não permitiu ainda à comunidade científica aprofundar o seu conhecimento acerca da sua praticidade em investigações, dificultando assim a obtenção de literatura relacionada com o assunto, de como o utilizar corretamente e a sua consequente operacionalização.

Por fim, a temática da Inteligência Artificial é extremamente ampla, tal como a do Comportamento do Consumidor. Cada um destes tópicos abrange uma multiplicidade de variáveis, o que torna complicado o seu afunilamento sem sentir que se está a deixar algo de importante fora da investigação.

6.2. Sugestões de investigação futura

Para que investigações futuras consigam ser mais detalhadas, propõe-se a utilização de modelos comportamentais que estejam mais extensamente estudados como a Jornada do Consumidor de McKinsey (2009) ou o ZMOT (2011).

A presente dissertação abordou exclusivamente a perspetiva dos consumidores relativamente ao uso de IA no Marketing Digital. Posto isto, sugere-se investigar a perspetiva das empresas para que fosse possível perceber qual o verdadeiro nível de adoção desta

tecnologia nas organizações e quão eficiente e eficaz é na obtenção de resultados relacionados com o *e-commerce*, uma vez que existe uma plenitude de literatura acerca do assunto.

Por último, sugere-se o afinilamento do tema. A utilização de uma temática demasiado abrangente dificulta bastante a consecução de resultados específicos. Assim, propõe-se que no futuro se escolha um pequeno grupo de tópicos sobre cada assunto de forma a que a investigação se torne mais focada.

7. Bibliografia

- Alderson, W. (1957). *Marketing behavior and executive action*. Richard D. Irwin.
- Almeida, T., Silva, R., & Yamakami, A. (2013). Machine Learning Methods for Spamdexing Detection. *International Journal of Information*, 2(3), 86–108. <http://ijiss.org/ijiss/index.php/ijiss/article/view/35>
- Ameen, N., Tarhini, A., Reppel, A., & Anand, A. (2021). Computers in Human Behavior Customer experiences in the age of artificial intelligence. *Computers in Human Behavior*, 114(August 2020), 106548. <https://doi.org/10.1016/j.chb.2020.106548>
- American Marketing Association. (2017). *Definitions of Marketing*. <https://www.ama.org/the-definition-of-marketing-what-is-marketing/>
- André, Q., Carmon, Z., Wertenbroch, K., Crum, A., Frank, D., Goldstein, W., Huber, J., van Boven, L., Weber, B., & Yang, H. (2018). Consumer Choice and Autonomy in the Age of Artificial Intelligence and Big Data. *Customer Needs and Solutions*, 5(1–2), 28–37. <https://doi.org/10.1007/s40547-017-0085-8>
- Arora, N., Dreze, X., Ghose, A., Hess, J. D., Iyengar, R., Jing, B., Joshi, Y., Kumar, V., Lurie, N., Neslin, S., Sajeesh, S., Su, M., Syam, N., Thomas, J., & Zhang, Z. J. (2008). Putting one-to-one marketing to work: Personalization, customization, and choice. *Marketing Letters*, 19(3–4), 305–321. <https://doi.org/10.1007/s11002-008-9056-z>
- Bagshaw, A. (2015). What is marketing automation? *Journal of Direct, Data and Digital Marketing Practice*, 17(2), 84–85. <https://doi.org/10.1057/dddmp.2015.46>
- Behera, R. K., Gunasekaran, A., Gupta, S., Kamboj, S., & Bala, P. K. (2020). Personalized digital marketing recommender engine. *Journal of Retailing and Consumer Services*, 53(March 2019), 101799. <https://doi.org/10.1016/j.jretconser.2019.03.026>
- Berman, R., & Katona, Z. (2013). The role of search engine optimization in search marketing. *Marketing Science*, 32(4), 644–651. <https://doi.org/10.1287/mksc.2013.0783>
- Bijmolt, T. H. A., Broekhuis, M., de Leeuw, S., Hirche, C., Rooderkerk, R. P., Sousa, R., & Zhu, S. X. (2021). Challenges at the marketing–operations interface in omni-channel retail environments. *Journal of Business Research*, 122(July 2018), 864–874. <https://doi.org/10.1016/j.jbusres.2019.11.034>
- Brunswick, G. J. (2014). A Chronology Of The Definition Of Marketing. *Journal of Business & Economics Research (JBER)*, 12(2), 105. <https://doi.org/10.19030/jber.v12i2.8523>
- Castelo, N. (2019). *Blurring the Line Between Human and Machine: Marketing Artificial Intelligence* [Tese de Doutorado, Columbia University]. Academic Commons. <https://doi.org/https://doi.org/10.7916/d8-k7vk-0s40>
- Coutinho, C. (2008). Estudos correlacionais em educação: potencialidades e limitações. *Psicologia, Educação e Cultura*, XII, 143–169. <http://hdl.handle.net/1822/8549>

Cummins, S., Peltier, J. W., Nill, A., & Schibrowsky, J. A. (2014). Consumer behavior in the online context. *Journal of Research in Interactive Marketing*, 8(3), 169–202. <https://doi.org/10.1108/JRIM-04-2013-0019>

Davenport, T., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, 48(1), 24–42. <https://doi.org/10.1007/s11747-019-00696-0>

Davenport, T. H., & Ronanki, R. (2018). Artificial intelligence for the real world. *Harvard Business Review*, January-February, 108–117.

Davis, F. D. (1985). *A technology acceptance model for empirically testing new end-user information systems: Theory and results* [Tese de Doutorado, Massachusetts Institute of Technology]. DSpace@MIT. <http://hdl.handle.net/1721.1/15192>

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, 91–105. <https://doi.org/10.1016/j.intmar.2020.04.007>

Dumitriu, D., & Popescu, M. A.-M. (2020). Artificial Intelligence Solutions for Digital Marketing. *Procedia Manufacturing*, 46(2019), 630–636. <https://doi.org/10.1016/j.promfg.2020.03.090>

Dwivedi, Y. K., Hughes, L., Ismagilova, E., Aarts, G., Coombs, C., Crick, T., Duan, Y., Dwivedi, R., Edwards, J., Eirug, A., Galanos, V., Ilavarasan, P. V., Janssen, M., Jones, P., Kar, A. K., Kizgin, H., Kronemann, B., Lal, B., Lucini, B., ... Williams, M. D. (2019). Artificial Intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. *International Journal of Information Management*, 57(August 2019), 101994. <https://doi.org/10.1016/j.ijinfomgt.2019.08.002>

Erevelles, S., Fukawa, N., & Swayne, L. (2016). Big Data consumer analytics and the transformation of marketing. *Journal of Business Research*, 69(2), 897–904. <https://doi.org/10.1016/j.jbusres.2015.07.001>

Evans, M. (2019, February 17). *Build A 5-Star Customer Experience With Artificial Intelligence*. Forbes. <https://www.forbes.com/sites/allbusiness/2019/02/17/customer-experience-artificial-intelligence/?sh=5b05c3e515bd>

Figueiredo, M. M. (2019). *Artificial Intelligence Acceptance: Morphological elements of the acceptance of Artificial Intelligence* (Issue May) [Universidade Católica Portuguesa]. <http://hdl.handle.net/10400.14/28555>

Groß, M. (2015). Mobile shopping: A classification framework and literature review. *International Journal of Retail and Distribution Management*, 43(3), 221–241. <https://doi.org/10.1108/IJRDM-06-2013-0119>

Guha, A., Biswas, A., Grewal, D., Verma, S., Banerjee, S., & Nordfält, J. (2018). Reframing the discount as a comparison against the sale price: Does it make the discount

more attractive? *Journal of Marketing Research*, 55(3), 339–351. <https://doi.org/10.1509/jmr.16.0599>

Hofacker, C., Malthouse, E. C., & Sultan, F. (2016). Big Data and consumer behavior: imminent opportunities. *Journal of Consumer Marketing*, 33(2), 89–97. <https://doi.org/10.1108/JCM-04-2015-1399>

Holtgraves, T. M., Ross, S. J., Weywadt, C. R., & Han, T. L. (2007). Perceiving artificial social agents. *Computers in Human Behavior*, 23(5), 2163–2174. <https://doi.org/10.1016/j.chb.2006.02.017>

Instituto Nacional de Estatística. (2020). Sociedade da Informação e do Conhecimento - Inquérito à Utilização de Tecnologias da Informação e da Comunicação nas Famílias. https://www.ine.pt/xportal/xmain?xpid=INE&xpgid=ine_destaques&DESTAQUESdest_boui=415621509&DESTAQUEStema=55483&DESTAQUESmodo=2

Joghee, S. (2021). Internet of Things-assisted E-marketing and distribution framework. *Soft Computing*, 25(18), 12291–12303. <https://doi.org/10.1007/s00500-021-05920-0>

Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255–260. <https://doi.org/10.1126/science.aac4520>

Jr Hair, Ringle, C., & Sarstedt, M. (2011). PLS-sem: Indeed a silver bullet. *The Journal of Marketing Theory and Practice*, 19, 139–151. <https://doi.org/10.2753/MTP1069-6679190202>

Kaczorowska-Spychalska, D. (2019). How chatbots influence marketing. *Management*, 23(1), 251–270. <https://doi.org/10.2478/manment-2019-0015>

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. <https://doi.org/10.1016/j.bushor.2018.08.004>

Kim, T. W., & Duhachek, A. (2020). Artificial Intelligence and Persuasion: A Construal-Level Account. *Psychological Science*, 31(4), 363–380. <https://doi.org/10.1177/0956797620904985>

Kritzing, W. T., & Weideman, M. (2013). Search Engine Optimization and Pay-per-Click Marketing Strategies. *Journal of Organizational Computing and Electronic Commerce*, 23(3), 273–286. <https://doi.org/10.1080/10919392.2013.808124>

Krotov, V. (2017). The Internet of Things and new business opportunities. *Business Horizons*, 60(6), 831–841. <https://doi.org/10.1016/j.bushor.2017.07.009>

Kull, A. J., Romero, M., & Monahan, L. (2021). How may I help you? Driving brand engagement through the warmth of an initial chatbot message. *Journal of Business Research*, 135(July 2020), 840–850. <https://doi.org/10.1016/j.jbusres.2021.03.005>

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. <https://doi.org/10.1177/0008125619859317>

Lee, I. (2017). Big data: Dimensions, evolution, impacts, and challenges. *Business Horizons*, 60(3), 293–303. <https://doi.org/10.1016/j.bushor.2017.01.004>

Legg, S., & Hutter, M. (2007). *A Collection of Definitions of Intelligence*. 1–12. <http://arxiv.org/abs/0706.3639>

Longoni, C., Bonezzi, A., & Morewedge, C. K. (2019). Resistance to Medical Artificial Intelligence. *Journal of Consumer Research*, 46(4), 629–650. <https://doi.org/10.1093/jcr/ucz013>

Luo, X., Tong, S., Fang, Z., & Qu, Z. (2019). Frontiers: Machines vs. humans: The impact of artificial intelligence chatbot disclosure on customer purchases. *Marketing Science*, 38(6), 937–947. <https://doi.org/10.1287/mksc.2019.1192>

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. <https://doi.org/10.1016/j.ijresmar.2020.04.005>

Maroco, J., & Garcia-Marques, T. (2006). Qual a fiabilidade do alfa de Cronbach? Questões antigas e soluções modernas? *Laboratório de Psicologia*, 4(1), 65–90.

Marangunić, N., & Granić, A. (2015). Technology acceptance model: a literature review from 1986 to 2013. *Universal Access in the Information Society*, 14(1), 81–95. <https://doi.org/10.1007/s10209-014-0348-1>

Martinez-Ruiz, M. P., & Moser, K. S. (2019). Studying Consumer Behavior in an Online Context: The Impact of the Evolution of the World Wide Web for New Avenues in Research. *Frontiers in Psychology*, 10(December), 3–6. <https://doi.org/10.3389/fpsyg.2019.02731>

Matta, H., Gupta, R., & Agarwal, S. (2020). Search Engine optimization in Digital Marketing: Present Scenario and Future Scope. *Proceedings of International Conference on Intelligent Engineering and Management, ICIEM 2020*, 530–534. <https://doi.org/10.1109/ICIEM48762.2020.9160016>

Mero, J., Tarkiainen, A., & Tobon, J. (2020). Effectual and causal reasoning in the adoption of marketing automation. *Industrial Marketing Management*, 86(March 2019), 212–222. <https://doi.org/10.1016/j.indmarman.2019.12.008>

Nagy, S., & Hajdú, N. (2021). Consumer Acceptance of the Use of Artificial Intelligence in Online Shopping: Evidence From Hungary. *Amfiteatru Economic*, 23(56), 155–173. <https://doi.org/10.24818/EA/2021/56/155>

Nettleton, D. (2014). *Commercial Data Mining: Processing, Analysis and Modeling for Predictive Analytics Projects*. Elsevier. <https://doi.org/10.1016/C2013-0-00263-0>

Newman, D. (2019). *5 ways AI is transforming the customer experience*. Forbes. <https://www.forbes.com/sites/danielnewman/2019/04/16/5-ways-ai-is-transforming-the-customer-experience/?sh=4e09f384465a>

Nisar, T. M., & Prabhakar, G. (2017). What factors determine e-satisfaction and consumer spending in e-commerce retailing? *Journal of Retailing and Consumer Services*, 39(July), 135–144. <https://doi.org/10.1016/j.jretconser.2017.07.010>

Norvig, P., & Russel, S. (2016). *Artificial Intelligence: A Modern Approach* (2nd ed.). Pearson Education Limited.

Novak, T. P., & Hoffman, D. L. (2019). Relationship journeys in the internet of things: a new framework for understanding interactions between consumers and smart objects. *Journal of the Academy of Marketing Science*, 47(2), 216–237. <https://doi.org/10.1007/s11747-018-0608-3>

Pansari, A., & Kumar, V. (2017). Customer engagement: the construct, antecedents, and consequences. *Journal of the Academy of Marketing Science*, 45(3), 294–311. <https://doi.org/10.1007/s11747-016-0485-6>

Patel, N. (n.d.-a). *Digital Marketing Made Simple: A Step-by-Step Guide*. Retrieved December 14, 2020, from <https://neilpatel.com/what-is-digital-marketing/>

Pavlou, P. A. (2003). Consumer acceptance of electronic commerce: Integrating trust and risk with the technology acceptance model. *International Journal of Electronic Commerce*, 7(3), 101–134. <https://doi.org/10.1080/10864415.2003.11044275>

Ping, N. L., Hussin, A. R. B. C., & Ali, N. B. M. (2019). Constructs for artificial intelligence customer service in E-commerce. *International Conference on Research and Innovation in Information Systems, ICRIIS, December-2*, 19–24. <https://doi.org/10.1109/ICRIIS48246.2019.9073486>

Pomirleanu, N., Schibrowsky, J. A., Peltier, J., & Nill, A. (2013). A review of internet marketing research over the past 20 years and future research direction. *Journal of Research in Interactive Marketing*, 7(3), 166–181. <https://doi.org/10.1108/JRIM-01-2013-0006>

Protheroe, J., Rennie, A., Charron, C., & Breatnach, G. (2020). Decoding Decisions: Making Sense of the Messy Middle. In *Think With Google*. <https://www.thinkwithgoogle.com/intl/en-ccc/consumer-insights/consumer-journey/navigating-purchase-behavior-and-decision-making/>

Rahman, W. F. W. A., Fauzi, A. A. C., Husain, W. S. W., Hassan, S. H. C., Kamaruzaman, N. N. N., & Aziz, W. A. H. W. (2020). The Usage of Artificial Intelligence in Marketing Automation: Potentials and Pitfalls. *Journal of Mathematics & Computing Science*, 6(2), 1–8. <http://www.jmcs.com.my/index.php/jmcs/article/view/54/48>

Ramesh, M., & Vidhya, B. (2019). Digital marketing and its effect on online consumer buying behavior. *Journal of Services Research*, 19(2), 61–77. <http://proxy.lib.sfu.ca/login?>

[url=https://search.ebscohost.com/login.aspx?direct=true&db=bth&AN=145293180&site=ehost-live](https://search.ebscohost.com/login.aspx?direct=true&db=bth&AN=145293180&site=ehost-live)

Rennie, A., & Protheroe, J. (2020, July). *How people decide what to buy lies in the “messy middle” of the purchase journey*. <https://www.thinkwithgoogle.com/intl/en-ccc/consumer-insights/consumer-journey/navigating-purchase-behavior-and-decision-making/>

Révillion, A. S. P. (2003). A Utilização de Pesquisas Exploratórias na Área de Marketing. *RIMAR - Revista Interdisciplinar de Marketing*, 2(2), 21–37. <https://pdfs.semanticscholar.org/f75f/7ba7b5b210c213ea273311d04cbfae5392dd.pdf>

Sestino, A., Prete, M. I., Piper, L., & Guido, G. (2020). Internet of Things and Big Data as enablers for business digitalization strategies. *Technovation*, 98(July), 102173. <https://doi.org/10.1016/j.technovation.2020.102173>

Shah, A. K., & Oppenheimer, D. M. (2008). Heuristics Made Easy: An Effort-Reduction Framework. *Psychological Bulletin*, 134(2), 207–222. <https://doi.org/10.1037/0033-2909.134.2.207>

Shankar, V. (2018). How Artificial Intelligence (AI) is Reshaping Retailing. *Journal of Retailing*, 94(4), vi–xi. [https://doi.org/10.1016/s0022-4359\(18\)30076-9](https://doi.org/10.1016/s0022-4359(18)30076-9)

Zhao, M., Hoeffler, S., & Dahl, D. W. (2012). Imagination difficulty and new product evaluation. *Journal of Product Innovation Management*, 29, 76–90. <https://doi.org/10.1111/j.1540-5885.2012.00951.x>

8. Apêndices

Apêndice A - Questionário

Questão	Opções de resposta
Caracterização Sociodemográfica	
Indique o seu sexo.	Feminino Masculino
Indique a sua região.	Norte Centro Área Metropolitana de Lisboa Alentejo Algarve Região Autónoma dos Açores Região Autónoma da Madeira
Qual a faixa etária a que pertence?	Menos de 18 anos Entre os 18 e 24 anos Entre 25 e 34 anos Entre 45 e 54 anos Entre 55 e 64 anos Mais de 65 anos
Confiança na tecnologia	
1. Acredito que a utilização da IA no retalho online é usada para me dar as melhores ofertas.	Discordo totalmente (1) a Concordo totalmente (5)
2. Confio em lojas online que utilizam IA.	
3. A quantidade de dados que a IA recolhe sobre mim não me preocupa.	
4. A segurança das minhas compras é essencial para que eu confie na IA.	
5. Confio que a minha privacidade online (histórico de navegação, de compras, etc.) está segura com os sistemas de IA.	
Experiência	
1. Tenho experiência em comprar online.	
2. Já utilizei <i>websites</i> que fazem uso da IA (<i>chatbots</i> , recomendações, sugestões de alternativas, conteúdo personalizado, etc).	

3. Uma boa experiência numa loja online que contenha IA é essencial para que eu volte a comprar na loja em questão no futuro.	Discordo totalmente (1) a Concordo totalmente (5)
4. Consumo regularmente <i>websites/</i> plataformas que fazem uso da IA.	
Relevância da Tarefa	
1. Acredito que a IA pode ser utilizada eficazmente no meio digital.	Discordo totalmente (1) a Concordo totalmente (5)
2. Acredito que a IA pode ser útil durante a minha pesquisa por alternativas (produtos semelhantes).	
3. Acredito que a publicidade que vejo na Internet encoraja-me a comprar online.	
Utilidade Percebida	
1. A utilização de IA no retalho online permite-me encontrar melhores oportunidades de negócio.	Discordo totalmente (1) a Concordo totalmente (5)
2. A utilização de IA no retalho online melhora a eficácia das minhas compras.	
3. A utilização de IA no retalho online é útil para mim.	
4. A utilização de IA no retalho online permite-me poupar tempo.	
Facilidade de Utilização	
1. Lojas online alimentadas por IA são fáceis de usar.	Discordo totalmente (1) a Concordo totalmente (5)
2. Comprar online não requer esforço mental da minha parte se a IA me apresentar diversas alternativas.	
3. Comprar não é complicado se a IA me recomendar produtos.	
4. Aprender a usar lojas alimentadas por IA é fácil para mim.	
Atitude	
1. Comprar numa loja online que é alimentada por IA é uma boa ideia.	

2. Comprar numa loja online que contenha IA é uma decisão sábia.	Discordo totalmente (1) a Concordo totalmente (5)
3. Tenho uma atitude positiva em relação a lojas alimentadas por IA.	
Intenção Comportamental	
1. Tenciono visitar e usufruir de lojas alimentadas por IA mais frequentemente.	Discordo totalmente (1) a Concordo totalmente (5)
2. Estou disposto(a) a gastar mais dinheiro em produtos que se encontram em lojas alimentadas por IA.	
3. Estou mais disposto(a) a comprar numa loja que adicione ofertas gratuitas às minhas compras comparativamente com as que não o fazem.	

Apêndice B - Tabelas de resultados SPSS

Indique o seu sexo.

		Frequência	Porcentagem	Porcentagem válida	Porcentagem acumulativa
Válido	Masculino	49	27.8	27.8	27.8
	Feminino	127	72.2	72.2	100.0
	Total	176	100.0	100.0	

Indique a sua região.

		Frequência	Porcentagem	Porcentagem válida	Porcentagem acumulativa
Válido	Area Metropolitana de Lisboa	130	73.9	73.9	73.9
	Alentejo	4	2.3	2.3	76.1
	Algarve	5	2.8	2.8	79.0
	Centro	32	18.2	18.2	97.2
	Norte	5	2.8	2.8	100.0
	Total	176	100.0	100.0	

Qual a faixa etária a que pertence?

		Frequência	Porcentagem	Porcentagem válida	Porcentagem acumulativa
Válido	18-24	45	25.6	25.6	25.6
	25-34	34	19.3	19.3	44.9
	35-44	36	20.5	20.5	65.3
	45-54	36	20.5	20.5	85.8
	55-64	19	10.8	10.8	96.6
	+65	4	2.3	2.3	98.9
	-18	2	1.1	1.1	100.0
	Total	176	100.0	100.0	

Alguma vez efetuou compras através da Internet (online)?

		Frequência	Porcentagem	Porcentagem válida	Porcentagem acumulativa
Válido	Sim	154	87.5	87.5	87.5
	Não	22	12.5	12.5	100.0
	Total	176	100.0	100.0	

Tabela de Frequências

Indique o seu sexo.

		Frequência	Porcentagem	Porcentagem válida	Porcentagem acumulativa
Válido	Masculino	43	27.9	27.9	27.9
	Feminino	111	72.1	72.1	100.0
	Total	154	100.0	100.0	

Indique a sua região.

		Frequência	Porcentagem	Porcentagem válida	Porcentagem acumulativa
Válido	Area Metropolitana de Lisboa	113	73.4	73.4	73.4
	Alentejo	3	1.9	1.9	75.3
	Algarve	5	3.2	3.2	78.6
	Centro	28	18.2	18.2	96.8
	Norte	5	3.2	3.2	100.0
	Total	154	100.0	100.0	

Qual a faixa etária a que pertence?

		Frequência	Porcentagem	Porcentagem válida	Porcentagem acumulativa
Válido	18-24	43	27.9	27.9	27.9
	25-34	34	22.1	22.1	50.0
	35-44	35	22.7	22.7	72.7
	45-54	27	17.5	17.5	90.3
	55-64	11	7.1	7.1	97.4
	+65	3	1.9	1.9	99.4
	-18	1	.6	.6	100.0
	Total	154	100.0	100.0	

Alguma vez efetuou compras através da Internet (online)?

		Frequência	Porcentagem	Porcentagem válida	Porcentagem acumulativa
Válido	Sim	154	100.0	100.0	100.0

Resumo de processamento do caso

Casos	N		%	
	Válido	30	100.0	
	Excluídos ^a	0	.0	
	Total	30	100.0	

a. Exclusão de lista com base em todas as variáveis do procedimento.

Estatísticas de confiabilidade

Alfa de Cronbach	Alfa de Cronbach com base em itens padronizados	N de itens
.944	.949	26

Estatísticas

N	Indique o seu sexo.		Indique a sua região.		Qual a faixa etária a que pertence?	Alguma vez efetuou compras através da Internet (online)?
	Válido	Omisso	Válido	Omisso		
	154	0	154	0	154	154
	Média	1.7208	1.7597	3.5779	1.0000	
	Mediana	2.0000	1.0000	3.0000	1.0000	
	Modo	2.00	1.00	2.00	1.00	
	Erro Desvio	.45008	1.31882	1.36618	.00000	
	Mínimo	1.00	1.00	1.00	1.00	
	Máximo	2.00	5.00	7.00	1.00	

Estatísticas

N	Válido	154	154	154	154	154	154	154	154	154	154	154	154	154
	Omisso	0	0	0	0	0	0	0	0	0	0	0	0	0
	Média	3.6948	3.7338	2.7857	4.2338	3.1039	4.1688	3.8636	3.9091	3.6688	3.9935	4.0844	3.6494	3.7273
	Mediana	4.0000	4.0000	3.0000	5.0000	3.0000	4.0000	4.0000	4.0000	4.0000	4.0000	4.0000	4.0000	4.0000
	Modo	3.00	4.00	3.00	5.00	3.00	5.00	5.00	5.00	3.00	4.00	4.00	5.00	4.00
	Erro Desvio	1.05612	.97714	1.33805	1.01487	1.25333	1.00849	1.08506	1.09880	1.12055	.88927	.92850	1.27075	1.02436

A utilização de IA no retalho online melhora a eficácia das minhas compras.	A utilização de IA no retalho online é útil para mim.	A utilização de IA no retalho online permite-me poupar tempo.	Lojas online alimentadas por IA são fáceis de usar.	Comprar online não requer esforço mental da minha parte se a IA me apresentar diversas alternativas.	Comprar não é complicado se a IA me recomendar produtos.	Aprender a usar lojas alimentadas por IA é fácil para mim.	Comprar numa loja online que é alimentada por IA é uma boa ideia.	Comprar numa loja online que contenha IA é uma decisão sábia.	Tenho uma atitude positiva em relação a lojas alimentadas por IA.	Tenciono visitar e usufruir de lojas alimentadas por IA mais frequentemente.	Estou disposto(a) a gastar mais dinheiro em produtos que se encontram em lojas alimentadas por IA.	Estou mais disposto(a) a comprar numa loja que adicione ofertas gratuitas às minhas compras comparativamente com as que não o fazem.
154	154	154	154	154	154	154	154	154	154	154	154	154
0	0	0	0	0	0	0	0	0	0	0	0	0
3.7208	3.6169	3.8247	3.9351	3.6494	3.6494	4.0390	3.8506	3.7338	3.6558	3.6558	3.0909	4.0000
4.0000	4.0000	4.0000	4.0000	4.0000	4.0000	4.0000	4.0000	4.0000	4.0000	4.0000	3.0000	4.0000
4.00	4.00	4.00	4.00	4.00	4.00	5.00	4.00	4.00	4.00	4.00	3.00	5.00
1.01940	1.04911	1.10337	.90514	1.18560	1.15771	.93503	.95509	.95001	1.06875	1.05645	1.31041	1.02899

Correlações

		Media_Exper iência	Media_Utilida dePercebida
Media_Experiencia	Correlação de Pearson	1	.487**
	Sig. (2 extremidades)		.000
	N	154	154
Media_UtilidadePercebi da	Correlação de Pearson	.487**	1
	Sig. (2 extremidades)	.000	
	N	154	154

** A correlação é significativa no nível 0,01 (2 extremidades).

Correlações

		Media_Confi ança	Media_Utilida dePercebida
Media_Confiança	Correlação de Pearson	1	.705**
	Sig. (2 extremidades)		.000
	N	154	154
Media_UtilidadePercebi da	Correlação de Pearson	.705**	1
	Sig. (2 extremidades)	.000	
	N	154	154

** A correlação é significativa no nível 0,01 (2 extremidades).

Correlações

		Media_Facilid adeUtilizacão Percebida	Media_Utilida dePercebida
Media_FacilidadeUtilizac ãoPercebida	Correlação de Pearson	1	.784**
	Sig. (2 extremidades)		.000
	N	154	154
Media_UtilidadePercebi da	Correlação de Pearson	.784**	1
	Sig. (2 extremidades)	.000	
	N	154	154

** A correlação é significativa no nível 0,01 (2 extremidades).

Correlações

		Media_Utilida dePercebida	Media_Atitud e
Media_UtilidadePercebi da	Correlação de Pearson	1	.774**
	Sig. (2 extremidades)		.001
	N	154	154
Media_Atitude	Correlação de Pearson	.774**	1
	Sig. (2 extremidades)	.000	
	N	154	154

** A correlação é significativa no nível 0,01 (2 extremidades).

Correlações

		Media_Confi ança	Media_Facilid adeUtilizacão Percebida
Media_Confiança	Correlação de Pearson	1	.642**
	Sig. (2 extremidades)		.000
	N	154	154
Media_FacilidadeUtilizac ãoPercebida	Correlação de Pearson	.642**	1
	Sig. (2 extremidades)	.000	
	N	154	154

** A correlação é significativa no nível 0,01 (2 extremidades).

Correlações

		Media_Exper iência	Media_Facilid adeUtilizacão Percebida
Media_Experiencia	Correlação de Pearson	1	.571**
	Sig. (2 extremidades)		.000
	N	154	154
Media_FacilidadeUtilizac ãoPercebida	Correlação de Pearson	.571**	1
	Sig. (2 extremidades)	.000	
	N	154	154

** A correlação é significativa no nível 0,01 (2 extremidades).

Correlações

		Media_Relev ânciaTarefa	Media_Facilid adeUtilizacão Percebida
Media_RelevanciaTarefa	Correlação de Pearson	1	.688**
	Sig. (2 extremidades)		.000
	N	154	154
Media_FacilidadeUtilizac ãoPercebida	Correlação de Pearson	.688**	1
	Sig. (2 extremidades)	.000	
	N	154	154

** A correlação é significativa no nível 0,01 (2 extremidades).

Correlações

		Media_Relev ânciaTarefa	Media_Utilida dePercebida
Media_RelevanciaTarefa	Correlação de Pearson	1	.768**
	Sig. (2 extremidades)		.000
	N	154	154
Media_UtilidadePercebi da	Correlação de Pearson	.768**	1
	Sig. (2 extremidades)	.000	
	N	154	154

** A correlação é significativa no nível 0,01 (2 extremidades).

Correlações

		Media_Facilid adeUtilizacão Percebida	Media_Atitud e
Media_FacilidadeUtilizac ãoPercebida	Correlação de Pearson	1	.747**
	Sig. (2 extremidades)		.000
	N	154	154
Media_Atitude	Correlação de Pearson	.747**	1
	Sig. (2 extremidades)	.000	
	N	154	154

** A correlação é significativa no nível 0,01 (2 extremidades).

Correlações

		Media_Utilida dePercebida	Media_Intenc ãoComporta mental
Media_UtilidadePercebi da	Correlação de Pearson	1	.737**
	Sig. (2 extremidades)		.000
	N	154	154
Media_IntencãoComport amental	Correlação de Pearson	.737**	1
	Sig. (2 extremidades)	.000	
	N	154	154

** A correlação é significativa no nível 0,01 (2 extremidades).

Correlações

		Media_Atitud e	Media_Intenc ãoComporta mental
Media_Atitude	Correlação de Pearson	1	.818**
	Sig. (2 extremidades)		.000
	N	154	154
Media_IntencãoComport amental	Correlação de Pearson	.818**	1
	Sig. (2 extremidades)	.000	
	N	154	154

** A correlação é significativa no nível 0,01 (2 extremidades).

Variáveis Inseridas/Removidas^a

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Media_Intenc aoComport amental ^b	.	Inserir

- a. Variável Dependente: Media_Atitude
b. Todas as variáveis solicitadas inseridas.

Resumo do modelo

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Mudança de R quadrado	Estatísticas de mudança			Sig. Mudança F
						Mudança F	df1	df2	
1	.818 ^a	.670	.668	.51713	.670	308.414	1	152	.000

- a. Preditores: (Constante), Media_IntencaoComportamental

ANOVA^a

Modelo		Soma dos Quadrados	df	Quadrado Médio	Z	Sig.
1	Regressão	82.476	1	82.476	308.414	.000 ^b
	Resíduo	40.648	152	.267		
	Total	123.123	153			

- a. Variável Dependente: Media_Atitude
b. Preditores: (Constante), Media_IntencaoComportamental

Coefficientes^a

Modelo		Coefficients não padronizados		Coefficients padronizados		Sig.
		B	Erro Erro	Beta	t	
1	(Constante)	.940	.165		5.691	.000
	Media_IntencaoComportamental	.784	.045	.818	17.562	.000

- a. Variável Dependente: Media_Atitude

Variáveis Inseridas/Removidas^a

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Media_FacilidadeUtilizac aoPercebida ^b	.	Inserir

- a. Variável Dependente: Media_Confiança
b. Todas as variáveis solicitadas inseridas.

Resumo do modelo

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Mudança de R quadrado	Estatísticas de mudança			Sig. Mudança F
						Mudança F	df1	df2	
1	.642 ^a	.412	.408	.64041	.412	106.466	1	152	.000

- a. Preditores: (Constante), Media_FacilidadeUtilizacaoPercebida

ANOVA^a

Modelo		Soma dos Quadrados	df	Quadrado Médio	Z	Sig.
1	Regressão	43.664	1	43.664	106.466	.000 ^b
	Resíduo	62.339	152	.410		
	Total	106.003	153			

- a. Variável Dependente: Media_Confiança
b. Preditores: (Constante), Media_FacilidadeUtilizacaoPercebida

Coefficientes^a

Modelo		Coefficients não padronizados		Coefficients padronizados		Sig.
		B	Erro Erro	Beta	t	
1	(Constante)	1.150	.234		4.906	.000
	Media_FacilidadeUtilizac aoPercebida	.618	.060	.642	10.318	.000

- a. Variável Dependente: Media_Confiança

Variáveis Inseridas/Removidas^a

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Media_Atitude ^b	.	Inserir

a. Variável Dependente: Media_UtilidadePercebida

b. Todas as variáveis solicitadas inseridas.

Resumo do modelo

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Mudança de R quadrado	Estatísticas de mudança			Sig. Mudança F
						Mudança F	df1	df2	
1	.774 ^a	.599	.596	.57130	.599	226.988	1	152	.000

a. Preditores: (Constante), Media_Atitude

ANOVA^a

Modelo		Soma dos Quadrados	df	Quadrado Médio	Z	Sig.
1	Regressão	74.085	1	74.085	226.988	.000 ^b
	Resíduo	49.610	152	.326		
	Total	123.695	153			

a. Variável Dependente: Media_UtilidadePercebida

b. Preditores: (Constante), Media_Atitude

Coefficientes^a

Modelo		Coefficients não padronizados		Coefficients padronizados		Sig.
		B	Erro Erro	Beta	t	
1	(Constante)	.816	.198		4.115	.000
	Media_Atitude	.776	.051	.774	15.066	.000

a. Variável Dependente: Media_UtilidadePercebida

a. Variável Dependente: Media_Confiança

Variáveis Inseridas/Removidas^a

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Media_UtilidadePercebida ^b	.	Inserir

a. Variável Dependente: Media_Experiencia

b. Todas as variáveis solicitadas inseridas.

Resumo do modelo

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Mudança de R quadrado	Estatísticas de mudança			Sig. Mudança F
						Mudança F	df1	df2	
1	.487 ^a	.237	.232	.70195	.237	47.223	1	152	.000

a. Preditores: (Constante), Media_UtilidadePercebida

ANOVA^a

Modelo		Soma dos Quadrados	df	Quadrado Médio	Z	Sig.
1	Regressão	23.268	1	23.268	47.223	.000 ^b
	Resíduo	74.896	152	.493		
	Total	98.164	153			

a. Variável Dependente: Media_Experiencia

b. Preditores: (Constante), Media_UtilidadePercebida

Coefficientes^a

Modelo		Coefficients não padronizados		Coefficients padronizados		Sig.
		B	Erro Erro	Beta	t	
1	(Constante)	2.288	.242		9.469	.000
	Media_UtilidadePercebida	.434	.063	.487	6.872	.000

a. Variável Dependente: Media_Experiencia

Variáveis Inseridas/Removidas^a

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Media_FacilidadeUtilizacaoPercebida ^b	.	Inserir

a. Variável Dependente: Media_Experiencia

b. Todas as variáveis solicitadas inseridas.

Resumo do modelo

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Mudança de R quadrado	Estatísticas de mudança			Sig. Mudança F
						Mudança F	df1	df2	
1	.571 ^a	.327	.322	.65951	.327	73.691	1	152	.000

a. Preditores: (Constante), Media_FacilidadeUtilizacaoPercebida

ANOVA^a

Modelo		Soma dos Quadrados	df	Quadrado Médio	Z	Sig.
1	Regressão	32.052	1	32.052	73.691	.000 ^b
	Resíduo	66.112	152	.435		
	Total	98.164	153			

a. Variável Dependente: Media_Experiencia

b. Preditores: (Constante), Media_FacilidadeUtilizacaoPercebida

Coefficientes^a

Modelo		Coefficients não padronizados		Coefficients padronizados	t	Sig.
		B	Erro Erro			
1	(Constante)	1.881	.241		7.788	.000
	Media_FacilidadeUtilizacaoPercebida	.530	.062	.571	8.584	.000

a. Variável Dependente: Media_Experiencia

Variáveis Inseridas/Removidas^a

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Media_Atitude ^b	.	Inserir

a. Variável Dependente: Media_FacilidadeUtilizacaoPercebida

b. Todas as variáveis solicitadas inseridas.

Resumo do modelo

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Mudança de R quadrado	Estatísticas de mudança			Sig. Mudança F
						Mudança F	df1	df2	
1	.747 ^a	.559	.556	.57607	.559	192.378	1	152	.000

a. Preditores: (Constante), Media_Atitude

ANOVA^a

Modelo		Soma dos Quadrados	df	Quadrado Médio	Z	Sig.
1	Regressão	63.842	1	63.842	192.378	.000 ^b
	Resíduo	50.442	152	.332		
	Total	114.284	153			

a. Variável Dependente: Media_FacilidadeUtilizacaoPercebida

b. Preditores: (Constante), Media_Atitude

Coefficientes^a

Modelo		Coefficients não padronizados		Coefficients padronizados	t	Sig.
		B	Erro Erro			
1	(Constante)	1.120	.200		5.602	.000
	Media_Atitude	.720	.052	.747	13.870	.000

a. Variável Dependente: Media_FacilidadeUtilizacaoPercebida

Variáveis Inseridas/Removidas^a

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Media_UtilidadePercebida ^b	.	Inserir

a. Variável Dependente:
Media_FacilidadeUtilizacaoPercebida

b. Todas as variáveis solicitadas inseridas.

Resumo do modelo

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Mudança de R quadrado	Estatísticas de mudança			Sig. Mudança F
						Mudança F	df1	df2	
1	.784 ^a	.614	.611	.53873	.614	241.777	1	152	.000

a. Preditores: (Constante), Media_UtilidadePercebida

ANOVA^a

Modelo		Soma dos Quadrados	df	Quadrado Médio	Z	Sig.
1	Regressão	70.170	1	70.170	241.777	.000 ^b
	Resíduo	44.114	152	.290		
	Total	114.284	153			

a. Variável Dependente: Media_FacilidadeUtilizacaoPercebida

b. Preditores: (Constante), Media_UtilidadePercebida

Coefficientes^a

Modelo		Coefficients não padronizados		Coefficients padronizados		Sig.
		B	Erro Erro	Beta	t	
1	(Constante)	1.015	.185		5.470	.000
	Media_UtilidadePercebida	.753	.048	.784	15.549	.000

a. Variável Dependente: Media_FacilidadeUtilizacaoPercebida

Variáveis Inseridas/Removidas^a

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Media_FacilidadeUtilizacaoPercebida ^b	.	Inserir

a. Variável Dependente:
Media_RelevanciaTarefa

b. Todas as variáveis solicitadas inseridas.

Resumo do modelo

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Mudança de R quadrado	Estatísticas de mudança			Sig. Mudança F
						Mudança F	df1	df2	
1	.688 ^a	.473	.470	.59977	.473	136.658	1	152	.000

a. Preditores: (Constante), Media_FacilidadeUtilizacaoPercebida

ANOVA^a

Modelo		Soma dos Quadrados	df	Quadrado Médio	Z	Sig.
1	Regressão	49.160	1	49.160	136.658	.000 ^b
	Resíduo	54.679	152	.360		
	Total	103.838	153			

a. Variável Dependente: Media_RelevanciaTarefa

b. Preditores: (Constante), Media_FacilidadeUtilizacaoPercebida

Coefficientes^a

Modelo		Coefficients não padronizados		Coefficients padronizados		Sig.
		B	Erro Erro	Beta	t	
1	(Constante)	1.405	.220		6.398	.000
	Media_FacilidadeUtilizacaoPercebida	.656	.056	.688	11.690	.000

a. Variável Dependente: Media_RelevanciaTarefa

Variáveis Inseridas/Removidas^a

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Media_UtilidadePercebida ^a	.	Inserir

a. Variável Dependente:
Media_RelevanciaTarefa

b. Todas as variáveis solicitadas inseridas.

Resumo do modelo

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Mudança de R quadrado	Estatísticas de mudança			Sig. Mudança F
						Mudança F	df1	df2	
1	.768 ^a	.590	.587	.52943	.590	218.459	1	152	.000

a. Preditores: (Constante), Media_UtilidadePercebida

ANOVA^a

Modelo		Soma dos Quadrados	df	Quadrado Médio	Z	Sig.
1	Regressão	61.233	1	61.233	218.459	.000 ^b
	Resíduo	42.605	152	.280		
	Total	103.838	153			

a. Variável Dependente: Media_RelevanciaTarefa

b. Preditores: (Constante), Media_UtilidadePercebida

Coefficientes^a

Modelo		Coefficients não padronizados		Coefficients padronizados		Sig.
		B	Erro Erro	Beta	t	
1	(Constante)	1.290	.182		7.078	.000
	Media_UtilidadePercebida	.704	.048	.768	14.780	.000

a. Variável Dependente: Media_RelevanciaTarefa

Variáveis Inseridas/Removidas^a

Modelo	Variáveis inseridas	Variáveis removidas	Método
1	Media_IntencaoComportamental ^a	.	Inserir

a. Variável Dependente:
Media_UtilidadePercebida

b. Todas as variáveis solicitadas inseridas.

Resumo do modelo

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Mudança de R quadrado	Estatísticas de mudança			Sig. Mudança F
						Mudança F	df1	df2	
1	.737 ^a	.544	.541	.60934	.544	181.147	1	152	.000

a. Preditores: (Constante), Media_IntencaoComportamental

ANOVA^a

Modelo		Soma dos Quadrados	df	Quadrado Médio	Z	Sig.
1	Regressão	67.259	1	67.259	181.147	.000 ^b
	Resíduo	56.437	152	.371		
	Total	123.695	153			

a. Variável Dependente: Media_UtilidadePercebida

b. Preditores: (Constante), Media_IntencaoComportamental

Coefficientes^a

Modelo		Coefficients não padronizados		Coefficients padronizados		Sig.
		B	Erro Erro	Beta	t	
1	(Constante)	1.188	.195		6.103	.000
	Media_IntencaoComportamental	.708	.053	.737	13.459	.000

a. Variável Dependente: Media_UtilidadePercebida