



INSTITUTO
UNIVERSITÁRIO
DE LISBOA

A possibilidade de implementação de sistemas inteligentes e o respetivo impacto da Inteligência Artificial na segmentação de clientes

Bruno Miguel da Silva Fachada

Mestrado em Gestão

Orientadores:

Professor Doutor Renato Jorge Lopes da Costa, Professor Auxiliar,
ISCTE-IUL

Professor Doutor Rui Alexandre Henriques Gonçalves, Professor
Auxiliar Convidado,
ISCTE-IUL

Julho, 2021

Departamento de Marketing, Operações e Gestão Geral

A possibilidade de implementação de sistemas inteligentes e o respetivo impacto da Inteligência Artificial na segmentação de clientes

Bruno Miguel da Silva Fachada

Mestrado em Gestão

Orientadores:

Professor Doutor Renato Jorge Lopes da Costa, Professor Auxiliar,
ISCTE-IUL

Professor Doutor Rui Alexandre Henriques Gonçalves, Professor
Auxiliar Convidado,
ISCTE-IUL

Julho, 2021

Agradecimentos

Quero começar por agradecer aos meus orientadores, Professor Doutor Renato Lopes da Costa e Professor Doutor Rui Gonçalves, principalmente por me terem inspirado a fazer uma dissertação da qual me orgulho, mas também por todo o apoio e disponibilidade que sempre tiveram comigo.

À minha mãe, uma pessoa incrível, quero deixar aqui o meu enorme obrigado por me demonstrar o seu apoio incondicional, principalmente quando tomei uma decisão que mudou bastante a minha vida. Sem ela isto seria impossível.

Por fim, não posso deixar de agradecer a todas as pessoas que participaram neste estudo e que me ajudaram a ter respostas no questionário e nas entrevistas. Entre essas pessoas não posso deixar de ter um agradecimento especial ao Filipe Feio, uma pessoa com muito conhecimento para partilhar e que foi, sem dúvida nenhuma, um privilégio de o ter tido como colega ao longo da minha primeira experiência profissional.

A todos estes intervenientes, um grande obrigado.

Resumo

É inegável a presença que a Inteligência Artificial tem nos nossos dias, sendo uma realidade atual e não apenas do futuro. Nos dias que correm, é possível observar várias empresas, de diversos sectores de atividade, a utilizar a Inteligência Artificial no seu dia a dia e o Marketing, um sector que procura constantemente a inovação, é um deles. Posto isto, é essencial que as organizações percebam todas as dinâmicas subjacentes à Inteligência Artificial e compreendam como poderão tirar proveito destas tecnologias para as suas tarefas.

Este estudo pretende perceber como funciona a Inteligência Artificial, as suas características, impactos e limitações, compreendendo assim a sua aplicabilidade na segmentação de clientes.

Após analisar todas estas variáveis, durante a realização da revisão de literatura, as mesmas foram aprofundadas através de duas metodologias. Inicialmente através de um questionário *online* e através da realização de entrevistas. Após a análise dos *outputs* do questionário *online*, concluiu-se que a Inteligência Artificial tem características e impactos que influenciam positivamente a sua implementação na segmentação de clientes, ainda que este tipo de tecnologia tenha limitações, que poderão ser uma barreira na sua implementação.

Relativamente às entrevistas, estas revelam que a Inteligência Artificial ainda é vista como uma tecnologia de apoio na tomada de decisão e, por isso mesmo, ainda precisa de suporte humano. No entanto, apesar desta conclusão, muitos dos colaboradores ainda olham para estas tecnologias como uma ameaça ao seu posto de trabalho, podendo originar resistência na sua implementação e incorrer em custos desnecessários para as organizações.

Palavras-chave: Inteligência Artificial, segmentação de clientes, apoio na tomada de decisão.

Classificação JEL:

M31 – Marketing

O32 – Management of Technological Innovation and R&D

Abstract

There is no doubt that Artificial Intelligence is a current technology, already being put into practice, rather than being something far ahead, as some might think. There are several companies, from different industries and sectors, using Artificial Intelligence on a daily basis, including Marketing, an activity that constantly seeks innovation. That being said, it is crucial that organizations understand all the dynamics underlying Artificial Intelligence and comprehend how they can take advantage of it for their day-to-day tasks.

This study aims to investigate how Artificial Intelligence works; its characteristics; impacts; and limitations; and, consequently, assess the possibility of its application in customer segmentation. Firstly, all these aspects were thoroughly analyzed through literature review. Then, these were further developed by conducting two methodologies: an online questionnaire and interviews. The online questionnaire concluded that, while Artificial Intelligence's characteristics and impacts positively influence its implementation in customer segmentation, this type of technology still has limitations that could constitute an obstacle. Regarding the interviews, the main insight was that Artificial Intelligence is still only perceived as a support in decision making, thus, dependent on humans. However, despite this conclusion, many employees still look at these technologies as a threat to their workplace, which can lead to resistance in their implementation and incur on unnecessary costs for organizations.

Keywords: artificial intelligence, customer segmentation, decision making support.

JEL Classification:

M31 – Marketing

O32 – Management of Technological Innovation and R&D

Índice Geral

Agradecimentos	i
Resumo	iii
Abstract.....	v
Índice Geral	vii
Índice de tabelas	xi
Índice de ilustrações	xiii
Índice de anexos	xv
Lista de abreviaturas	xvii
Capítulo I – Introdução.....	1
1.1 Enquadramento	1
1.2 Problemática de Investigação.....	1
1.3 Objetivos da investigação	2
1.4 Estrutura da tese.....	2
Capítulo II – Sistemas Inteligentes	5
2.1 Inteligência Artificial	5
2.1.1 Componentes da IA	6
2.1.1.1 Machine Learning.....	6
2.1.1.2 Deep Learning	7
2.1.2 Potencializar IA através de <i>big data</i>	9
2.2 Desafios da IA	10
2.3 IA no Marketing	12
Capítulo III – Segmentação de clientes	15
3.1 Conceito de segmentação de clientes	15
3.1.1 Tipos de Segmentação de clientes	16
3.2 Segmentação de clientes com sistemas de IA e os seus impactos.....	20

Capítulo IV – Abordagem teórica.....	25
Capítulo V – Metodologia	29
5.1 Motivações, características e limitações na possibilidade da implementação de sistemas inteligentes na segmentação de clientes.....	32
5.1.1 Modelo de investigação	32
5.1.2 Descrição da amostra	36
5.2 Impacto da IA nos colaboradores	37
5.2.1 Modelo de investigação	37
5.2.2 Descrição da amostra	39
Capítulo VI – Apresentação e discussão de resultados.....	41
6.1 Principais motivações, características e limitações na possibilidade da implementação de sistemas inteligentes na segmentação de clientes.....	41
6.2 Perceber o impacto da IA na segmentação de clientes numa abordagem refletida nos seus recursos humanos.....	45
6.2.1 Situações em que os humanos devem substituir e controlar sistemas de IA....	45
6.2.2 Possível resistência na implementação de sistemas inteligentes e impactos na performance da organização.....	47
Capítulo VII – Conclusão	51
7.1 Considerações Finais.....	51
7.2 Contribuição para a gestão empresarial.....	53
7.3 Limitações do estudo.....	54
7.4 Sugestões para futuras investigações.....	54
Bibliografia	55
Anexos.....	59
Anexo A - Níveis de Inteligência Artificial	59
Anexo B - Componentes da Inteligência Artificial	59
Anexo C - Rede Neural Simples e Rede Neural Profunda	59
Anexo D - Principais variáveis de segmentação.	63
Anexo E - Principais métodos quantitativos no Marketing	65

Anexo F - Método de segmentação de clientes com base em redes neurais artificiais..	67
Anexo G – Estrutura do questionário online	67
Anexo H– Guião da entrevista	69

Índice de tabelas

Tabela 1 - Quadro de resumo das definições do conceito de Inteligência Artificial.....	6
Tabela 2 - Relação entre revisão de literatura, os objetivos, questões de pesquisa e metodologia	31
Tabela 3 - Relação entre variáveis do modelo conceptual e as perguntas do questionário	35
Tabela 4 - Caracterização sociodemográfica da amostra	37
Tabela 5 - Caracterização sociodemográfica da amostra	39
Tabela 6 - Verificações de CR, AVE, correlações e validade discriminante.....	41
Tabela 7 - Relações diretas entre construtos.....	42
Tabela 8 - Situações em que os humanos devem substituir e controlar sistemas IA.....	46
Tabela 9 – Possibilidade de resistência na implementação de IA nas organizações	48
Tabela 10 – Impactos da resistência da IA na performance da organização	49

Índice de ilustrações

Figura 1 - Modelo de investigação	30
Figura 2 - Modelo conceptual e hipóteses a testar com SmartPLS.....	34
Figura 3 - Categorização e codificação do corpus da entrevista para análise qualitativa ...	38
Figura 4 – Modelo conceptual testado com SmartPLS3 com valores associados	43

Índice de anexos

Anexo A - Níveis de Inteligência Artificial	59
Anexo B - Componentes da Inteligência Artificial.....	59
Anexo C - Rede Neural Simples e Rede Neural Profunda	59
Anexo D - Principais variáveis de segmentação.....	63
Anexo E - Principais métodos quantitativos no Marketing.....	65
Anexo F - Método de segmentação de clientes com base em redes neurais artificiais	67
Anexo G – Estrutura do questionário online.....	67
Anexo H– Guião da entrevista	69

Lista de abreviaturas

IA – Inteligência Artificial

AI – artificial intelligence

ML – machine learning

DL – deep learning

CNN - convolutional neural network

BP - back propagation

RNN - recurrent neural network

LSTM - long short-term memory

STP - segmentation, targeting and positioning

CR - composite Reliability

AVE - average variance extracted

HTMT - Heterotrait-Monotrait ratio

VIF - *variance inflation factor*

Capítulo I – Introdução

1.1 Enquadramento

É inegável que a Inteligência Artificial (IA) já se encontra bastante presente na sociedade e também no dia a dia das organizações. As empresas estão cada vez mais cientes das mais valias que a implementação da IA pode trazer às mesmas, no entanto a grande maioria das empresas que possuem este tipo de tecnologia, ainda não está a implementar no seu *core business*, mas sim em tarefas mais simples (Fountaine et al. 2019).

A verdade é que esta alavancagem, no uso da IA, é ajudada por dois tipos de estudos, estudos como os de Angwin et al. (2016), Dornelles et al. (2018), Harvard Law Review (2017), Liu et al. (2014), Lobo (2017), McGrath et al. (2019) e Mesquita (2017), que nos mostram que empresas dos mais variados sectores de atividade já utilizam IA no seu dia a dia, e estudos como o que foi levado a cabo por Purdy & Daugherty (2017), que nos indica o enorme potencial que estes sistemas inteligentes têm para impulsionar a economia mundial.

Estudos como os referidos, ajudam a desmistificar a IA aos olhos das organizações e faz com que estas estejam cada vez mais atentas aos benefícios que podem ter com estes sistemas. Sendo o Marketing um sector que está em constante evolução e sempre a procurar inovar, não poderia ser um sector que ficasse indiferente à IA. Em 2016, segundo Naimat (2016), já era a quarta maior área que mais recursos gastava com a utilização da IA e a sexta maior indústria que mais investia na IA. Tais dados mostram-nos que o sector já reconheceu o enorme potencial que a IA tem para resolver questões relacionadas com o Marketing (Tjepkema, 2017).

Posto isto, o grande objetivo deste estudo é investigar os impactos que a IA pode trazer a uma tarefa essencial para a gestão das organizações, a segmentação de clientes. Assim sendo, é espetável que o presente estudo contribua para o desenvolvimento da comunidade científica, acrescentando mais conhecimento sobre a temática e contribuindo com um estudo que relacione IA com Marketing, visto serem duas áreas com poucos estudos em comum.

1.2 Problemática de Investigação

Sendo o tema da investigação “A possibilidade de implementação de sistemas inteligentes e o respetivo impacto da Inteligência Artificial na segmentação de clientes”, o presente estudo pretende relacionar a temática de IA com o Marketing, sendo que estará focado na problemática de gestão que é a segmentação de clientes. Este estudo desmistifica a IA e expõe a sua aplicabilidade para a segmentação de clientes sendo, por isso mesmo, um estudo pertinente, por se tratar de uma tarefa essencial para sucesso de uma organização.

Deste modo, pretende-se expor as motivações para a implementação da IA para a segmentação de clientes, as características desta tecnologia que serão benéficas para a segmentação de clientes, bem como as principais limitações destes algoritmos e que poderão gerar barreiras na implementação de IA. Expostas as variáveis identificadas, pretende-se perceber como é que cada uma poderá influenciar a implementação de sistemas inteligentes na segmentação de clientes.

Como referido anteriormente, o Marketing é claramente um sector que está atento à evolução da IA e que aposta nesta tecnologia no seu dia a dia. Porém, contrariamente ao esperado, não existem muitos estudos que relacionem a IA com o Marketing, sendo que este estudo ambiciona complementar e atualizar os estudos já existentes sobre estas áreas.

1.3 Objetivos da investigação

O propósito do presente estudo é contribuir com novos conhecimentos para a comunidade científica, cujo objetivo será relacionar uma tarefa essencial na gestão das organizações - segmentação de clientes - com a Inteligência Artificial.

De forma a cumprir com o propósito já referido, foram definidos dois objetivos, sendo estes: perceber os fatores que influenciam a possibilidade de aplicar sistemas inteligentes na segmentação de clientes, e perceber o impacto dos sistemas inteligentes numa abordagem refletida nos recursos humanos das organizações.

1.4 Estrutura da tese

O presente estudo é composto por 7 capítulos, sendo que cada um dos capítulos tem um propósito específico e que será prontamente explicado.

No capítulo I, podemos encontrar a introdução que se encontra dividida em: enquadramento, problemática de investigação e objetivos da investigação.

O capítulo II é o início da revisão da literatura e encontra-se dividido em duas partes. A primeira parte é mais teórica e tem como objetivo global explicar o conceito de Inteligência Artificial. Posteriormente, foram abordados temas como os componentes que constituem a Inteligência Artificial, *machine learning* e *deep learning*, como funcionam, *big data* e como é que estes dados podem potencializar a IA.

A segunda parte do capítulo é composta por dois subcapítulos com uma abordagem mais prática. Estes subcapítulos têm dois objetivos principais, nomeadamente mostrar os desafios, identificados por alguns autores, trazidos pela IA e evidenciar alguns impactos que estes sistemas inteligentes têm no Marketing.

O capítulo III, a revisão de literatura termina, focando-se na segmentação de clientes. Numa fase inicial, foi abordado o conceito de segmentação de clientes, as características para uma segmentação

adequada e as diferentes formas para realizar uma segmentação, utilizando métodos qualitativos e quantitativos. Ainda no capítulo III, é abordado um método de segmentação de clientes recorrendo a sistemas de IA, assim como uma explicação dos possíveis impactos que esses mesmos sistemas poderão ter na segmentação de clientes.

O capítulo IV é composto pela abordagem teórica, onde são destacadas as questões de pesquisa resultantes da revisão da literatura e que vão servir de base para a investigação.

O capítulo V é dedicado às diferentes metodologias, aplicadas para responder às questões de pesquisa identificadas no capítulo anterior, assim como à descrição das amostras que cada questão de pesquisa teve.

O capítulo VI apresenta os resultados obtidos das diferentes metodologias que cada questão de pesquisa teve, e respetiva discussão dos mesmos, sendo que, sempre que possível, a discussão contempla as opiniões dos autores referidos na revisão de literatura, com o objetivo de comparar ambos os pontos de vista e, assim, aprofundar os conhecimentos retirados da investigação.

Por fim, o capítulo VII é constituído pela conclusão, onde são feitas as considerações finais do estudo, a contribuição que o estudo teve para a gestão empresarial, as limitações do mesmo e algumas sugestões para futuras investigações.

Capítulo II – Sistemas Inteligentes

2.1 Inteligência Artificial

Costa (2009) defende que a IA envolve métodos, ferramentas e sistemas para resolver um problema onde a inteligência humana é necessária, acrescentando ainda, que a IA utiliza a observação de sistemas complexos existentes na natureza, numa tentativa de metodizar a solução de problemas. O mesmo autor explica que, quando confrontados com um problema, os sistemas vivos reagem de uma forma adaptativa que consiste em três procedimentos: reconhecer padrões em imagens e sons, processar linguagem e, por fim, planejar e prever ações. Costa (2009) afirma ainda que a IA deve ter em conta estes processos e desenvolver métodos e modelos de forma a simular os mesmos num sistema computacional.

Explorando outra definição de IA, Kuberski (2020), no *webinar “Bringing real value to enterprises with AI”* realizado pelo ISCTE AI Business Hub, começa por explicar que existem três níveis de IA (*Anexo A*), *artificial narrow intelligence*, *artificial general intelligence* e *artificial super intelligence*.

No primeiro nível, *artificial narrow intelligence*, estão os programas de IA que podemos encontrar atualmente tal como a Siri. Estes programas aplicam a IA na execução de apenas uma atividade específica. No entanto, e apesar de serem bons executadores, não conseguem realizar previsões ou múltiplas tarefas distintas. É estimado que a IA fique neste nível nas próximas décadas ou até mesmo séculos. No campo da *artificial general intelligence*, os programas de IA irão conseguir igualar a inteligência humana, neste nível já será possível fazer qualquer tipo de tarefa com estes programas. Por fim o último nível, *artificial super intelligence*, terá programas onde a IA irá ultrapassar a inteligência humana (Kuberski, 2020).

O mesmo palestrante define o conceito de IA como uma engenharia capaz de criar máquinas e programas inteligentes de forma a resolver tarefas mais complexas. Por outras palavras, compreende todos os sistemas e algoritmos que lidam com a solução de problemas complexos, geralmente, feitos por humanos. Para que tal seja possível, a IA processa de forma rápida e interativa enormes quantidades de dados e algoritmos, o que leva a uma aprendizagem constante e automática (Kuberski, 2020).

Na Tabela 1 é possível ver as definições de IA defendidas pelos autores estudados ao longo da presente revisão de literatura. Ao analisar estes conceitos é visível que existem alguns pontos em comum, sendo por isso possível afirmar que IA consiste em tentar replicar o pensamento humano em sistemas computadorizados de forma a executar tarefas de elevada complexidade.

Tabela 1 - Quadro de resumo das definições do conceito de Inteligência Artificial

Autor	Definição do conceito de IA
(Costa, 2009)	Simulação computacional de um conjunto de métodos, ferramentas e sistemas para resolver um problema onde a inteligência humana é necessária.
(Kuberski, 2020)	Engenharia capaz de criar máquinas e programas inteligentes de forma a resolver tarefas mais complexas.

Fonte: Elaboração do Autor

2.1.1 Componentes da IA

Agora que, de modo geral, foi identificado o conceito de IA, o presente ponto irá abordar a estrutura da IA e como funciona cada componente. Voltando ao *webinar “Bringing real value to enterprises with AI”*, Kuberski (2020) diz que a IA possui uma subcategoria, a *Machine Learning* (ML), que por sua vez também tem uma subcategoria, *Deep Learning* (DL), ambos os componentes estão representados no *Anexo B*.

2.1.1.1 Machine Learning

Segundo Dunjko & Briegel (2017), a *machine learning* (ML) explora a construção de algoritmos capazes de aprender e fazer previsões através de dados. Estes algoritmos se encontram divididos em três grupos, aprendizagem supervisionada, aprendizagem não supervisionada e aprendizagem por reforço.

A aprendizagem supervisionada consiste em aprender com o exemplo, isto é, o algoritmo necessita de dados com resposta para aprender, ou seja, dados rotulados. Através dos dados rotulados, o algoritmo tenta perceber qual é a regra/padrão para fazer a classificação/rotulagem dos dados. Uma vez identificado o padrão é possível classificar os novos dados com base nos exemplos que lhe foram dados anteriormente (Dunjko & Briegel, 2017).

Dunjko & Briegel (2017) dão-nos um exemplo prático deste tipo de aprendizagem, onde o objetivo passa por perceber se o ADN de um certo indivíduo tem tendência a desenvolver diabetes. Neste caso, o algoritmo irá perceber os padrões que levam uma sequência ADN a desenvolver diabetes. Para tal, o algoritmo irá analisar os dados (previamente registados) de outros pacientes, juntamente com as informações sobre se efetivamente desenvolveram, ou não, diabetes. Descoberto o padrão, o algoritmo irá desenvolver uma função com os dados rotulados, sendo possível perceber se novos pacientes têm probabilidade, ou não, de desenvolver diabetes.

A aprendizagem não supervisionada, segundo De Bruyn et al. (2020), ajuda a descobrir padrões em dados sem rótulos pré-existentes. O sistema de ML analisa os dados de treino e procura por tendências, estruturas e relações entre eles, de forma a criar uma função que será usada para prever

os resultados (*outputs*) com base nos *inputs* (Cannella, 2018). Os clusters são um exemplo muito comum para a aprendizagem não supervisionada, onde os dados são agrupados em grupos de forma a minimizar a distância das variáveis dentro dos grupos, e maximizar a distância entre outros grupos (Dunjko & Briegel, 2017).

A aprendizagem por reforço está presente, principalmente, em domínios onde a robótica e a IA se juntam. Neste grupo, a aprendizagem é feita com base numa política de recompensas e penalizações, onde o agente (por exemplo um robô) é recompensado sempre que toma uma decisão correta. A aprendizagem por reforço consiste em aprender a executar a correta sequência de ações, depois de recebidas as percepções, num ambiente totalmente *online*, onde a única forma de aprender é interagindo com ele (Dunjko & Briegel, 2017), sendo que o agente não terá qualquer orientação ou professor (Bertsekas, 2012). Em suma, este tipo de aprendizagem implica que uma função objetiva especifique um conjunto de recompensas que o algoritmo de IA irá tentar maximizar ao longo do tempo (Sutton & Barto, 2018).

De uma forma resumida, é nos sistemas de ML que estão concentrados algoritmos que permitem a aprendizagem ou descoberta de padrões nos dados, sem serem claramente programados (Kuberski, 2020). Apesar de os sistemas de ML estarem claramente identificados como subcategorias da IA, estes conceitos são muitas vezes confundidos de forma errada, pelo que é importante ter em conta que os sistemas de ML estão relacionados com o aprender, enquanto que Inteligência Artificial trata de vários outros aspetos da inteligência humana (Monteiro, 2019).

2.1.1.2 Deep Learning

A necessidade de processar grandes quantidades de dados, gerados diariamente, fez com que a *deep learning* (DL) fosse criada em meados do século 1900. No entanto devido à falta de poder de computação da altura, a DL não tinha grande aplicação. Só com o aumento do poder de computação, especialmente com a melhoria das GPU's¹, é que a DL passou a ser um dos componentes mais populares da IA (Cannella, 2018).

Aquilo que a DL permite é, segundo Cannella (2018), uma aprendizagem não supervisionada através de redes neurais, também chamadas de redes neurais artificiais, que são modelos inspirados no cérebro humano. As redes neurais são sistemas hierárquicos compostos por várias camadas de neurónios artificiais, criando uma rede de neurónios interligados, que analisam uma grande quantidade de dados de forma não linear (Anexo C). A forma como estas redes têm de analisar os dados é fazê-los passar pelas várias camadas de neurónios artificiais, onde cada neurónio aprende e armazena memória. Esta por sua vez pode ser fixa (o peso da importância de um determinado

¹ Graphics Processing Unit

neurónio não muda) ou adaptativa (o peso da importância de um neurónio pode mudar) (Cannella, 2018).

As redes neurais aprendem à medida que são alimentadas por uma grande quantidade de dados de treino. Posteriormente, é facultada uma pequena quantidade de dados de validação para evitar o sobreajuste, mais conhecido por *overfitting*. Este problema acontece quando o algoritmo se adapta demasiado bem aos dados de treino e apenas produz resultados muito precisos (Cannella, 2018). O problema é que o algoritmo vai perceber variações aleatórias como sendo um conceito do modelo, quando esses mesmos conceitos não se podem aplicar a novos dados o que, conseqüentemente, irá ter um impacto negativo naquele que é um objetivo da IA, o de universalizar modelos para a execução de tarefas (Brownlee, 2019). Por fim, é usado um conjunto de dados de teste para garantir que a rede neural artificial é treinada com precisão (Cannella, 2018).

A rede neural pode ter duas formas distintas sobre as quais os dados viajam, *feedforward* ou *feedback*. Na rede neural *feedforward* os *inputs* viajam apenas numa direção e é tipicamente usada para reconhecimento de padrões. Um tipo comum deste género de redes é a *convolutional neural network* (CNN), muito usada para o reconhecimento de imagens (Cannella, 2018). Outro exemplo de uma rede neural *feedforward* é a *back propagation* (BP) *neural network*, que tem a particularidade de os dados terem uma propagação direta, enquanto que os erros têm uma propagação regressiva. Neste topo de rede, os dados são processados na *input layer* e fazem o seu caminho natural até chegarem à *output layer*, mas quando os valores chegam à *output layer* muito diferentes do esperado, dá-se então uma propagação regressiva otimizando o peso da rede neural através uma aprendizagem e ajuste autónomos (Yan et al. 2019).

No caso das redes neurais *feedback*, os dados tanto podem viajar para a frente como para trás e a rede está em constante mudança. Este tipo de rede, também conhecida por *recurrent neural network* (RNN), permite uma maior complexidade quando comparadas com as CNN. Um bom exemplo de RNN são as *long short-term memory* (LSTM), capazes de reter dados por longos períodos de tempo, o que lhes permite ultrapassar problemas enfrentados pelas redes neurais tradicionais, levando a uma maior eficiência em algumas tarefas (Cannella, 2018).

Em suma, segundo Kuberski (2020), os sistemas de DL usam tipos de algoritmos muito específicos, chamados de *Deep Neural Network*, que imitam o cérebro humano e permitem trabalhar com dados não estruturados², ao contrário da ML. Este tipo de redes permite tecnologias como o reconhecimento facial, tradução automática de textos, reconhecimento de voz, entre outras.

² Dados sem uma organização estruturada (ex.: e-mails, imagens ou sons)

2.1.2 Potencializar IA através de *big data*

Com os avanços tecnológicos e a diversidade de dispositivos que encontramos nos dias de hoje, a produção de dados é cada vez maior e são muitos os estudos, e artigos que afirmam que o conteúdo digital, a nível mundial, duplica a cada dois anos. Um exemplo dessa mesma produção massiva de dados é o facto de o Instagram ter mais de 100 milhões de *uploads* de fotos e vídeos diários (Aslam, 2020).

É com base nesta produção massiva de dados estruturados³ e não estruturados, de diversas fontes que entra o conceito de *big data*. O termo *big data* refere-se a um conjunto de dados cujo tamanho está para além da capacidade das ferramentas típicas de software em capturar, armazenar, gerir e analisar (Manyika, et al., 2011). Segundo os mesmos autores, esta definição é intencionalmente subjetiva e dá mais flexibilidade relativamente ao tamanho dos dados necessários para serem considerados *big data*. O número mínimo de dados não é estabelecido pois à medida que a tecnologia evolui, o tamanho dos dados necessários para serem considerados *big data* também aumentará.

A *big data* tem sido falada como uma revolução que irá modificar a forma como vivemos, trabalhamos e pensamos e, como consequência, também vai exigir novas formas de processamento para possibilitar a descoberta de novos conhecimentos, a melhoria na tomada de decisão e a otimização de processos (Monteiro, 2019).

Segundo o estudo “*Big Data: The Next Frontier for Innovation, Competition and Productivity*” realizado pela consultora McKinsey, existem várias formas de criar valor usando *big data*. Uma das formas de criar valor passa pela possibilidade de ajudar a descobrir um valor significativo nas bases de dados, tornando a informação mais transparente e utilizável numa maior frequência. À medida que as organizações criam e armazenam mais dados transacionais em formato digital, podem recolher informações de desempenho mais precisas, detalhadas e holísticas, aumentando o desempenho no trabalho.

A *big data* também irá possibilitar um aperfeiçoamento da segmentação de clientes, sendo possível oferecer produtos e/ou serviços muito mais precisos e adequados aos clientes. Adicionalmente, também irá permitir melhorar a tomada de decisões através de análises mais sofisticadas, e por fim, outra forma de criar valor passa por melhorar o desenvolvimento da próxima geração de produtos e serviços.

Este estudo mostra a importância do processamento de dados, sendo a IA um dos componentes essenciais na análise dos mesmos, por outras palavras, a IA irá permitir a criação de novas formas de processamento de dados tornando-se, como referido pela *McKinsey*, num dos principais

³ Dados organizados com uma estrutura rígida, previamente planeada para armazenamento (ex.: base de dados)

impulsionadores da revolução do *big data*, por outro lado, é essa mesma revolução que irá favorecer o cenário da IA.

2.2 Desafios da IA

Agora que a forma de funcionamento da IA foi explicada, serão abordados os desafios identificados por alguns autores. Para De Bruyn et al. (2020) a principal força dos algoritmos de Inteligência Artificial encontra-se na capacidade de descobrir padrões escondidos nos dados e, de forma autônoma, criar modelos complexos com intervenção humana limitada ou inexistente. No entanto é essa força que pode originar vários desafios identificados pelos mesmos autores.

O primeiro desafio está ligado à falta de senso comum nos sistemas de IA. A falta de senso comum faz com que os sistemas de IA não obedeçam a regras básicas que qualquer ser humano entende. No entanto como são tão básicas e óbvias, não são especificadas, originando sistemas que não compreendem o mundo onde atuam. Por exemplo, quando uma empresa contrata uma agência de comunicação para realizar uma campanha de publicidade, ambas partem do princípio de que a campanha não poderá colocar vidas humanas em perigo ou violar a lei e, como tal, isso não é especificado no contrato. Em sistemas de IA não existem essas regras implícitas, ou seja, o senso comum, e é essa ausência que irá levar a outro desafio, a especificação de funções objetivas (De Bruyn et al. 2020).

Como um algoritmo IA não é munido de senso comum ou balizado por um conjunto predefinido de especificações para operar, torna-se essencial a definição de uma função objetiva holística (De Bruyn et al. 2020), algo que pode ser um verdadeiro desafio e é exemplificado no artigo de Natter et al. (2007). O artigo fala de um sistema inteligente desenvolvido com um propósito, maximização do lucro tendo em conta os parâmetros preço e promoção. Os autores concluíram que o modelo conseguia atingir lucros elevados, mas à custa do volume de vendas, no entanto este problema foi resolvido com uma modificação na função inicial para uma função ponderada onde incluíram os parâmetros lucro, vendas e procura.

Os sistemas de IA têm um grande potencial no Marketing, mas é necessário perceber que os objetivos do Marketing são complexos, multifacetados, difíceis de quantificar e, muitas vezes, mal conceptualizados. Quando se fala em aumentar lucros, as ideias de legalidade, ética, moral e justiça já estão implícitas, mas também devem ser passadas para os sistemas de IA de forma a atingir resultados esperados e não resultados a todo o custo (De Bruyn et al. 2020).

Outro desafio que a aprendizagem por reforço nos traz é a construção de um ambiente seguro e realista para a aprendizagem, sendo que De Bruyn et al. (2020) levantam uma questão: “em que tipo de ambiente é que esta aprendizagem pode acontecer?”. No caso de sistemas de IA desenvolvidos para vencerem humanos em jogos de xadrez, é muito simples simular um ambiente de aprendizagem

seguro e realista, mas existem situações que requerem um grau de complexidade maior, como é o caso do Marketing.

De Bruyn et al. (2020) dizem que para criar um ambiente de aprendizagem realista num sector tão complexo como é o Marketing, é necessário ter em conta um grande número de fatores. Alguns deles passam por conseguir modelar a fadiga dos clientes em relação ao número de solicitações e a taxa de abandono, ou a probabilidade de os clientes cancelarem a assinatura se forem solicitados em excesso. A ideia que os autores passam é a de que é essencial compreender e mensurar todos os fatores e aplicá-los em ambientes de aprendizagem, caso contrário, todas as campanhas pensadas por sistemas de IA estão condenadas ao fracasso.

Alguns algoritmos de IA podem ser bastante poderosos e conseguem reproduzir, com bastante precisão e facilidade, conceitos tendenciosos e preconceitos existentes nos dados de treino, o que nos leva a outra falha identificada por De Bruyn et al. (2020) - a possibilidade de sistemas de IA serem tendenciosos. Segundo Bolukbasi et al. (2016), o risco de sistemas de IA fazerem previsões tendenciosas é mais presente na aprendizagem não supervisionada e exemplificou essa afirmação. Num contexto onde o sistema de IA se depara com as frases “ele conduz um carro” e “ele conduz um camião”, o algoritmo percebe que as palavras “carro” e “camião” são palavras que representam objetos semelhantes. No entanto, se a palavra “camião” for mais associada a homens e a palavra “carro” a mulheres, o algoritmo irá replicar esses mesmos preconceitos nas previsões.

O conceito de IA explicável leva-nos à identificação de outro desafio da IA. Este desafio é explicado por De Bruyn et al. (2020), recorrendo ao artigo escrito Ribeiro et al. (2016). Os autores falam de um sistema inteligente criado para diferenciar imagens de cães e lobos. A precisão do modelo era muito boa, mas falhou em atingir o objetivo, isto porque o modelo percebeu que os lobos apareciam mais em imagens com neve, enquanto que os cães em imagens com relva, ou seja, o algoritmo aprendeu a distinguir lobos de cães através do ambiente que rodeava os animais e não pelas suas características.

Torna-se, então, imprescindível perceber a importância de perceber as razões das previsões, principalmente quando os sistemas de IA são muito usados como apoio à decisão. Além do mais, a compreensão das razões que levam às previsões providenciam conhecimentos sobre o modelo que, eventualmente, podem transformar um modelo que não é de confiança, num modelo confiável (Ribeiro et al. 2016). Segundo De Bruyn et al. (2020), mesmo que um algoritmo de IA seja preciso e não tendencioso, não compreender os fundamentos teóricos e causais dos *outputs* pode levar a graves problemas no futuro, pois os modelos de IA interagem com outros modelos e geram cada vez mais dados de uma forma autónoma, podendo causar problemas internos indetetáveis.

Outro desafio dos sistemas inteligentes é chamado de IA controlável. Um sistema de IA controlável é um bom sistema de IA (De Bruyn et al. 2020) e, durante o processo de desenvolvimento de sistemas de IA, as organizações devem criar mecanismos para controlar, parar e substituir os algoritmos de IA

em tempo real (Armstrong et al. 2012) e (Russell, 2019). De Bruyn et al. (2020) afirmam que “nos negócios em geral e no Marketing em particular, existem muitos “*unknown unknowns*” para deixar que algoritmos de IA, por mais eficazes e eficientes que possam ser nas operações do dia-a-dia, funcionem sem controlo humano ou capacidade de substituição”.

De Bruyn et al. (2020) voltam a identificar um novo desafio, o paradoxo da automatização. Os autores definem o paradoxo da automação recorrendo a Bainbridge (1983). Este concluiu que a automatização visa substituir o homem em ações de controlo, planeamento e na solução de problemas através de dispositivos automatizados. Depois desta substituição, os especialistas ficam com dois tipos de responsabilidades, verificar e controlar as operações de IA e assumir as operações quando a situação assim exigir, como por exemplo, em situações com circunstâncias incomuns ou de dificuldades extremas com as quais a IA não consegue lidar.

De acordo com o paradoxo da automatização definido pelo autor, as tarefas rotineiras são as mais fáceis de automatizar, mas são essas tarefas que permitem o aperfeiçoamento das capacidades dos humanos, preparando-os para situações mais complexas. Assim a automatização impede que os humanos aperfeiçoem o conhecimento e as capacidades necessárias para lidar com as tarefas que a IA não consegue. Apesar de não conseguir identificar com exatidão as consequências da automatização nos humanos, De Bruyn et al. (2020) mostram-se preocupados com o tipo de profissionais de Marketing que poderão ser criados se as tarefas rotineiras e repetitivas, que permitem ter um melhor conhecimento sobre os clientes e as suas necessidades, forem automatizadas, ficando estes apenas com tarefas de casos extremos.

O último desafio a ser retratado foi identificado por McGrath et. al (2019). Os autores afirmam que os *media* apresentam os sistemas de IA como “destruidores de trabalhos”, originando medo e resistência por parte dos colaboradores aquando da implementação de sistemas de IA. No entanto, os mesmos autores afirmam que a combinação de sistemas de IA com a experiência dos colaboradores faz com que estes melhorem as suas capacidades, prevenindo-se de serem substituídos por sistemas de IA.

2.3 IA no Marketing

Atualmente já existem diversos artigos que falam sobre a utilização de sistemas inteligentes nos mais diversos sectores como por exemplo na agricultura (Dornelles, et al., 2018), na medicina (Liu, et al., 2014; Lobo, 2017; Mesquita, 2017), no direito (Angwin et al, 2016; Harvard Law Review, 2017) e até mesmo no ramo imobiliário (McGrath et al. 2019). Os artigos referenciados chegam a várias conclusões acerca do sucesso destes sistemas na resolução de problemáticas específicas dos vários sectores, no entanto, de modo geral, os autores afirmam que atualmente estes programas acabam por ser, principalmente, facilitadores na tomada de decisão.

Os autores McGrath et al. (2019) também acabam por estudar alguns impactos que estes sistemas podem ter na performance organizacional, nomeadamente a redução de tempo despendido em certas tarefas e, conseqüentemente, o aumento de produtividade dos funcionários. Em última análise, os autores concluíram que estes sistemas podem transformar-se em vantagens competitivas das empresas, permitindo aumentar a quota de mercado e as receitas geradas, contudo, os mesmos autores também concluíram que pode existir resistência por parte dos colaboradores no momento de implementação destes sistemas, mas que pode ser ultrapassada através das chefias de topo. Estes devem transmitir que os sistemas são cruciais para o *core business* e que contribuem para o aumento de produtividade, substituindo uma possível política de redução de custos.

Os artigos anteriormente referenciados são prova de que, mesmo vivendo numa fase muito inicial da IA, já é possível observar o uso de várias ferramentas de IA para resolver os mais variados problemas nas mais variadas áreas, o que faz com que exista uma grande expectativa e entusiasmo em perceber o impacto que a IA poderá ter na nossa vida. Segundo um estudo realizado por Purdy & Daugherty (2017), a IA tem um potencial de impulsionar taxas de rentabilidade de, em média, 38% até ao ano 2035 e levar a um aumento da economia em US \$14 mil biliões em 16 indústrias e 12 economias no mesmo ano.

Também no Marketing se vive com bastante entusiasmo o desenvolvimento deste tipo de tecnologias. Em 2016, segundo Naimat (2016), o Marketing representava o quarto maior caso a nível de recursos gastos com uso da IA e era a sexta indústria que mais investia em IA, com um investimento de cerca de 2,55% do total investido pela indústria. Segundo um estudo realizado por Fountaine et al. (2019) as empresas já estão cientes da possibilidade de implementação de sistemas inteligentes, ainda que a grande maioria das empresas que possuem este tipo de tecnologia, não esteja a implementá-los no seu *core business* mas, segundo os autores do estudo, “em questões de negócio mais simples como a segmentação de clientes”.

Tjepkema (2017) partilha da mesma ideia e afirma que o potencial que a IA tem para resolver questões de Marketing é enorme, assim como os seus impactos. Devido à *social media* e aos rápidos motores de busca, como o Google, as pessoas encontram o que procuram de uma forma muito mais rápida. Com as sinergias criadas entre *big data* e IA, é possível analisar os padrões de pesquisa e ajudar os *marketers* a identificar áreas chave onde devem focar os seus esforços.

A publicidade será mais inteligente, uma vez que, atualmente, os *marketers* já estão a entrar no mundo de anúncios inteligentes com outras ferramentas que não a IA, mas a IA veio dar a possibilidade de criar anúncios inteligentes de uma forma mais rápida e eficaz. Com *big data*, os anúncios *online* são agora mais inteligentes e eficazes e, com soluções de IA, é possível aprofundar anúncios em pesquisas por palavras chaves, perfis sociais e outros dados *online* de forma a obter resultados do público (Tjepkema, 2017).

Também será possível entregar conteúdo mais refinado, com a ajuda da IA é possível levar a segmentação de clientes a outro patamar. A análise do público pode passar do tradicional entendimento por regiões demográficas para um entendimento a nível do indivíduo. Atualmente, os *marketers* podem usar a IA na identificação de potenciais clientes e entregar o conteúdo mais relevante para eles. Tudo isto é possível através da combinação entre *big data*, ML e IA (Tjepkema, 2017).

Segundo Tjepkema (2017), os *bots* serão mais eficientes, fazendo com que a retenção e atendimento ao cliente sejam outras das áreas onde a IA poderá ter um papel bastante importante. Em breve, os *chats* e outras formas de envolvimento direto com o consumidor serão feitos por *bots* usando a IA. Muitas empresas podem, assim, economizar o tempo dos colaboradores e os gastos dessas mesmas funções. Os *bots* de IA também acabam por ter acesso a todos os dados disponíveis na internet, informação e históricos de pesquisa, tornando-os mais eficientes do que os colaboradores.

Uma das últimas conclusões de Tjepkema (2017) é que a IA permitirá uma aprendizagem contínua. A IA pode ser usada, não apenas para descobrir conhecimentos ocultos, mas também pode ser ensinada e aprender como incorporar os conhecimentos descobertos nas novas campanhas e na otimização da segmentação de clientes. Com o tempo, estas soluções de IA vão tornar-se mais inteligentes, eficientes, com melhores taxas de conversão e também irão promover a tomada de decisões em tempo real.

Indo de encontro com as ideias acima referidas, os autores Vishnoi & Bagga (2019) afirmam que, os sistemas de IA vão permitir às organizações adquirir conhecimento sobre os hábitos de consumo dos clientes.

Os valores gastos em IA e os estudos feitos para perceber os possíveis impactos no Marketing, são a prova de que o sector está atento à evolução e ao potencial associado a estes sistemas, fazendo com que a execução de diversas tarefas do Marketing, sejam mais eficazes e eficientes. Entre elas está o tema desta dissertação, a segmentação de clientes.

Capítulo III – Segmentação de clientes

3.1 Conceito de segmentação de clientes

Antes de ser abordada a temática de segmentação de clientes, é importante esclarecer o conceito de segmentação e, posteriormente, será detalhado o conceito de segmentação de clientes.

Kotler (2002) e Kotler et al. (2017) explicam que um dos processos fundamentais do Marketing é o estabelecimento de clientes alvo. Para tal é necessário ter em conta o processo STP⁴ composto por três passos. Em primeiro lugar é necessário identificar grupos distintos de clientes que possam exigir produtos ou estratégias de Marketing diferentes (segmentação de mercado), posteriormente é necessário selecionar um ou mais segmentos de mercado para entrar (mercado alvo) e, por fim, o último passo consiste em estabelecer e comunicar os benefícios chave dos produtos nos mercados alvo (posicionamento de mercado).

Para Kotler & Armstrong (1999) e Kotler et al. (2017), a segmentação de mercado passa pela divisão do mercado em grupos distintos, em que cada grupo tem as suas necessidades, características ou comportamentos face aos produtos ou aos esforços do Marketing. Estes segmentos devem ser o maior possível sem sacrificar a uniformidade da resposta. A segmentação de mercado é algo crucial para uma organização pois esta detém recursos limitados e, como tal, deve focar-se em identificar os clientes da melhor forma possível, para que possa aplicar as estratégias de Marketing de uma forma mais eficiente para cada segmento (Cooil et al. 2007).

Explicado o conceito de segmentação, irá ser detalhado o conceito de segmentação de clientes. Segundo Song et al. (2001), a segmentação de clientes é um processo que consiste em dividir clientes em grupos com características e recursos semelhantes. Evans (2003) tem uma definição muito semelhante, mas acrescenta o conceito de necessidades dos clientes. O autor afirma que a segmentação de clientes passa por identificar um grupo de pessoas com necessidades semelhantes e que possam ser satisfeitas por um único produto.

Para Yan & Li, (2006), a necessidade de segmentar clientes aumentou com o limitado alcance para clientes que representam elevados níveis de lucro e, com a competição feroz que se vive no mercado. Tal acabou por originar uma grande preocupação em perceber realmente os clientes que, de acordo com os autores, têm diferentes características, como valores, preferências, entre outros. De forma a ir ao encontro às necessidades e, conseqüentemente, aumentar os níveis de satisfação dos clientes, as organizações devem ter capacidades para realizar a segmentação de clientes.

A teoria por detrás da segmentação de clientes propõe que os grupos de clientes com necessidades e comportamentos de compras idênticos, tenham respostas semelhantes às iniciativas

⁴ *Segmentation, targeting e positioning.*

de Marketing e, com uma correta segmentação, as organizações conseguem produzir produtos, serviços e recursos corretos para cada segmento, construindo uma relação mais próxima com os mesmos. Por estes motivos, a segmentação tem sido falada como um dos pontos mais críticos para que a organização consiga obter sucesso nas campanhas de Marketing e na gestão do relacionamento com os seus clientes (Yan & Li, 2006).

Atualmente existem várias formas para se realizar uma segmentação de clientes, estas serão abordadas posteriormente. Não obstante, segundo Kotler (2002) e Kotler et al. (2017), os *marketers* devem perceber que nem todas as formas de segmentação são úteis e adequadas para as organizações. O autor dá-nos um exemplo de uma, hipotética, má aplicação da segmentação de clientes numa empresa que vende sal. Neste caso não faz sentido segmentar os clientes com base na cor dos cabelos, esta variável não terá qualquer tipo de relevância para a venda de sal e como tal resultará numa segmentação incorreta, para impedir que isso aconteça, Kotler (2002) e Kotler et al. (2017) identificam uma série de características que uma segmentação de clientes deve possuir.

A segmentação de clientes deve ser mensurável, ou seja, é necessário medir o tamanho, poder de compra e outras características dos segmentos, ser substancial, isto é, um segmento deve ser o maior grupo homogêneo possível para que se consiga implementar estratégias de Marketing “*tailor made*” e mesmo assim ser lucrativo, deve ser acessível para que seja efetivamente alcançável e para que seja possível satisfazer as suas necessidades, diferenciável. Os autores explicam que por definição os segmentos respondem de formas diferentes às estratégias de Marketing, isto é, se dois segmentos respondem de uma forma idêntica a uma estratégia de Marketing então, não faz sentido serem considerados dois segmentos distintos.

Por fim, deve ser acionável, oferecendo a possibilidade de criar programas eficazes para atrair e servir os segmentos (Kotler 2002; Kotler et al. 2017).

3.1.1 Tipos de Segmentação de clientes

A exatidão da segmentação depende muito da escolha dos recursos e dos métodos de segmentação (Yan & Li, 2006). Nos dias de hoje, existem diversas formas para realizar uma segmentação de clientes, entre as quais os métodos qualitativos⁵ e quantitativos⁶, que serão abordados de imediato.

Relativamente aos métodos qualitativos e, segundo Kotler (2002), existem várias variáveis que podem ser tidas em conta no processo de segmentação, nomeadamente geográficas, demográficas e

⁵ Método de pesquisa que tem o foco na compreensão do comportamento do consumidor

⁶ Método de pesquisa conclusivo onde o foco é quantificar e perceber a dimensão de um problema

psicográficas, relacionadas com as características do cliente, e variáveis comportamentais, ligadas com a resposta do cliente. O

Anexo D apresenta alguns exemplos de variáveis que podem ser tidas em conta.

A segmentação geográfica consiste na divisão dos clientes em diferentes zonas geográficas, que podem ser países, cidades, bairros ou outro tipo de divisão geográfica. A empresa pode operar numa ou em várias áreas geográficas, ou até mesmo em todas, sendo que neste caso deve ter em conta as variações locais (Kotler, 2002). Segundo Martin (2011), este tipo de segmentação é feito acreditando que todos os clientes, que vivem numa determinada região, partilham algumas necessidades e desejos, e que essas mesmas necessidades e desejos podem ser muito diferentes de outros clientes que moram numa outra região.

A segmentação demográfica consiste em dividir os clientes em grupos tendo em conta a idade, sexo, rendimento, educação, agregado familiar, entre outras (Kotler, 2002). O mesmo autor defende que este tipo de segmentação é um dos mais populares e identifica duas razões para tal afirmação, a primeira é que as variáveis demográficas são relativamente fáceis de medir, a outra razão é que as necessidades, preferências e taxas de uso dos clientes, por norma, estão associadas com variáveis demográficas.

A segmentação psicográfica passa por ter em conta variáveis como o estilo de vida, personalidade ou valores para fazer a divisão de clientes. Este tipo de segmentação é importante porque dentro de um grupo demográfico podemos encontrar vários perfis psicográficos (Kotler, 2002). Segundo Martin (2011), a segmentação psicográfica foi desenvolvida para correlacionar personalidades com marcas, e como tal é chamada de “estudo da personalidade, valores, atitudes, interesses, e estilos de vida”. A ideia deste tipo de segmentação é que a empresa possa identificar os hábitos dos seus clientes para se conectar com eles, e assim os clientes passam a conhecer os produtos e/ou serviços da empresa.

Na segmentação comportamental os clientes são divididos tendo em conta: conhecimento de, atitudes sobre, uso de, ou resposta a um produto, assim como o benefício e lealdade com a marca. A variável benefício passa por classificar os clientes com base nos benefícios que procuram nos produtos, enquanto que a lealdade pode classificar os clientes tendo em conta o nível de lealdade perante a marca. Muitos *marketers* acreditam que as variáveis comportamentais são o melhor ponto de partida para a segmentação de clientes (Kotler, 2002).

Segundo Kotler (2002), os *marketers* estão a combinar diferentes variáveis para identificar segmentos mais pequenos e melhores. Um exemplo disso é a segmentação multi atributos, chamada de *geocustering*, que a empresa norte americana Claritas desenvolveu. Uma das razões para a criação deste tipo de segmentação foi a necessidade de uma resposta para a pergunta “Quais os grupos que contêm os clientes mais valiosos?”. Para tal desenvolveram uma

segmentação que junta variáveis geográficas com o estilo de vida dos clientes. Estes tipos de novas segmentações permitem ajudar as empresas na identificação de micro segmentos que são economicamente viáveis, isto é possível devido aos reduzidos custos das bases de dados, softwares mais avançados ou até mesmo do uso mais amplo da internet.

Segundo Moutinho & Meidan (2003), existem outros métodos que podemos aplicar na segmentação de clientes, os chamados métodos quantitativos. A quantidade deste tipo de métodos é enorme, alguns deles no

Anexo E, no entanto apenas será abordado com maior detalhe a análise de *cluster* que, segundo Tan et al. (2006), é um dos métodos de segmentação mais conhecido e que tem aplicações em áreas ligadas com a IA, como o reconhecimento de padrões e os sistemas de ML.

A análise de *cluster* é um conjunto de técnicas usadas para identificar entidades semelhantes, com base nas características possuídas pelas mesmas, e agrupá-las em *clusters*. Esses *clusters*, ou agrupamentos, são constituídos por indivíduos de características ou comportamentos semelhantes, sendo que os grupos devem ter uma alta homogeneidade dentro deles e uma alta heterogeneidade entre outros *clusters*. Esta é técnica muito usada no apoio de tomada de decisão de estratégias de Marketing nos vários segmentos (Moutinho & Meidan, 2003).

É evidente que existem várias formas de segmentar clientes, no entanto cabe à organização identificar qual é a melhor segmentação de acordo com a sua estratégia, produtos e/ou serviços. Muitas vezes as organizações optam por usar várias formas de segmentação, como foi o caso da Claritas. A percepção das várias culturas no mercado global de hoje pode ser um fator essencial para o sucesso de uma empresa e, como tal, é essencial que as empresas moldem as suas estratégias de Marketing de acordo com os hábitos de compra dos seus clientes (Martin, 2011).

3.2 Segmentação de clientes com sistemas de IA e os seus impactos

Segundo Natter (1999), as redes neurais BP são muito usadas na segmentação de clientes pela sua simplicidade e pelo bom desempenho na classificação, contudo, Yan & Li (2006) dizem que a maioria das segmentações de clientes baseadas em redes neurais são feitas tendo em conta características estáticas do cliente, não incluindo dados sobre o comportamento do consumidor no processo de segmentação que acabam por ser importantes. A razão dada pelos autores para tal, é o facto de tonar-se difícil para as redes neurais incorporarem este tipo de dados na segmentação de clientes.

Foi com base nessa falha identificada que Yan & Li (2006) decidiram propor uma técnica de segmentação de clientes baseada em redes neurais e *clusters*. Antes de explicar o método proposto, os autores fazem uma clara distinção entre dados estáticos e dinâmicos. De acordo com os autores, os dados estáticos são dados que raramente mudam e refletem informações básicas do cliente, como nome, morada, idade, entre outros, sendo mais fáceis de se analisar. Os dados dinâmicos são dados sobre os clientes que com o passar do tempo são alterados, como por exemplo dados de transação⁷ do cliente, e que acabam por refletir diversas características dos clientes, como os hábitos de consumo, alguma mudança de comportamento ou até mesmo o valor gasto pelos clientes.

⁷ Os dados transacionais referem-se às transações da organização e incluem dados que são capturados, por exemplo, quando um produto é vendido ou comprado (Borek, Parlikad, Webb, & Woodall, 2014).

No método de segmentação de clientes sugerido por Yan & Li (2006), os clientes são agrupados pelo comportamento de compras (atributos dinâmicos) e depois é usado um atributo para rotular os resultados do agrupamento, que será usado no processo de classificação de variáveis. Entretanto são selecionados atributos estáticos que irão ser combinados com o resultado do agrupamento, e essa combinação irá ser tratada como *input* na rede neural para construir o modelo de segmentação (

Anexo F). Segundo os autores, este é um método flexível e é possível fazer diferentes tipos de segmentação de clientes, entre elas uma segmentação de clientes tendo em conta o valor dos mesmos.

Os autores Yan & Li (2006), explicam que a seleção de atributos estáticos deve excluir dados redundantes e tentar extrair o máximo de informação possível de um grupo pequeno de atributos. Assim é possível reduzir no tempo de computação, generalizar melhor a segmentação de clientes e reduzir o problema de *overfitting* do modelo, fazendo com que os decisores percebam melhor o modelo.

Este modelo é considerado híbrido, pois combina a metodologia de *clusters* com redes neurais artificiais, onde o método de *cluster* identifica o comportamento de compra dos clientes com uma descrição, enquanto que as redes neurais, neste caso redes neurais BP, são usadas para fazer a segmentação de clientes tendo em conta o objetivo proposto. No final do estudo, os autores fizeram um teste e compararam o método criado com um método de segmentação considerando as redes neurais sem o método de clusters, e comprovaram que o seu modelo melhorou bastante a precisão da segmentação de clientes (Yan & Li, 2006).

Segundo Kietzmann et al. (2018), a combinação de algumas características da IA, irá permitir aos *marketers* aprofundarem o conhecimento sobre os seus clientes. Uma das características chave da IA é o reconhecimento de imagens, que permite aos *marketers* aprofundar o conhecimento que têm do comportamento dos seus clientes através das imagens e vídeos que os mesmos partilham nas redes sociais. É nestas partilhas que os clientes identificam detalhes das ofertas e os vendedores beneficiam disso (Forsyth & Ponce, 2011). A título de exemplo, as *selfies* que podem revelar dados sobre as marcas usadas e detalhes pessoais (Kietzmann et al. 2018).

Como vem sendo referido ao longo da dissertação, segundo Kietzmann et al. (2018), a capacidade de resolução de problemas e de raciocínio dos sistemas de IA permite a descoberta de padrões e, com isso, a conquista de novos conhecimentos. É tendo em conta esses novos conhecimentos que as organizações podem segmentar os clientes, com base nas variáveis psicográficas ou através do valor de clientes, de forma a identificar quais são os melhores clientes. Tal é possível através da forma como os sistemas de IA interagem com os clientes que, eventualmente, acaba por revelar traços de personalidade, valores e necessidades.

O reconhecimento de voz, por sua vez, permite que os sistemas de IA analisem o significado das palavras. A Sayint, empresa fornecedora de serviços de *call-center*, usa esta capacidade da IA para monitorizar as chamadas com os clientes e perceber as suas necessidades (Kietzmann et al. 2018).

Concluindo, é através das capacidades de IA anteriormente faladas, que se consegue adquirir novos conhecimentos que se revelam bastante importantes no apoio à tomada de decisão do Marketing, onde a definição de segmentos de clientes é um bom exemplo de uma tarefa que os sistemas de IA podem realizar com grande eficiência e eficácia. Atualmente é possível perceber desejos

e necessidades emergentes em tempo real e criar, de uma forma mais rápida, perfis de clientes mais completos (Kietzmann et al. 2018).

Capítulo IV – Abordagem teórica

No decorrer da revisão da literatura realizada nos capítulos II e III da dissertação, foram apresentados vários pontos de vista, de diversos autores, onde é possível apurar algumas ideias relativamente aos impactos que sistemas inteligentes poderão vir a ter nas organizações e as limitações que os mesmos, eventualmente, apresentam. Como consequência, surgiram algumas questões de pesquisa que serão discutidas ao pormenor no decorrer do presente capítulo.

A primeira questão de pesquisa foi pensada tendo em conta quatro variáveis, nomeadamente as motivações, características, limitações e possibilidade de implementar os sistemas inteligentes na segmentação de clientes.

Relativamente às motivações, segundo Vishnoi & Bagga (2019), os sistemas inteligentes permitem descobrir os padrões de consumo dos clientes e, como consequência, adquirir novos conhecimentos sobre os mesmos. Essa opinião é partilhada por Kietzmann et al. (2018) que afirmam que é com base nesses novos conhecimentos que as organizações poderão otimizar a segmentação de clientes, dado que agora é possível perceber desejos e necessidades emergentes em tempo real e criar, de uma forma mais rápida, perfis de clientes mais completos.

Tjepkema (2017) defende que estes sistemas inteligentes têm um potencial imenso e que os seus impactos no Marketing são bastante positivos e variados, fazendo com que esses mesmos impactos sejam as principais motivações para que as empresas implementem estes sistemas inteligentes no seu dia a dia. Um dos impactos que a autora refere é sobre a segmentação de clientes, na qual os sistemas de IA permitem uma aprendizagem contínua que, como referido anteriormente, leva à descoberta de novos conhecimentos, fundamentais para tornar a segmentação de clientes mais eficaz, sendo possível entregar conteúdo mais refinado e assim levar esta tarefa a outros patamares.

Sobre as características da IA, os autores Kietzmann et al. (2018) têm um ponto de vista muito interessante. Os autores defendem que a IA tem características que oferecem a possibilidade aos *marketers* de aprofundar o conhecimento sobre os clientes, tal como o reconhecimento de imagens e de voz, e a capacidade de resolução de problemas e de raciocínio. Para o autor, estas características permitem uma conceptualização de perfis de clientes mais completos.

Outra abordagem muito interessante chega-nos dos autores De Bruyn, et al. (2020) que estudaram as limitações encontradas em sistemas inteligentes. Os autores explicam que as principais falhas deste tipo de sistemas passam pela falta de senso comum, que irá levar a outra falha, a dificuldade na especificação de uma função objetiva holística, a complexidade em criar ambientes seguros e realistas para que um sistema inteligente possa aprender de forma correta, a possibilidade destes sistemas fazerem juízos de valor tendenciosos e preconceituosos, a necessidade constante de perceber a razão pela qual o sistema de IA tomou alguma decisão, a necessidade de controlar os sistemas inteligentes, principalmente em situações inesperadas, e o paradoxo da automatização.

Para concluir a questão de pesquisa, será abordado um estudo levado a cabo por Fountaine et al. (2019). O estudo questionou diversas empresas que têm sistemas inteligentes implementados nos seus negócios e concluiu que, embora a grande maioria das empresas não utilize estes sistemas no seu *core business*, estas implementam este tipo de tecnologias “em questões de negócio mais simples como a segmentação de clientes”.

Tjepkema (2017) partilha da mesma opinião e afirma que a Inteligência Artificial traz muitos benefícios que podem ser implementados na segmentação de clientes, nomeadamente a capacidade de adquirir conhecimentos ocultos sobre os clientes e com isso entregar conteúdo mais relevante aos mesmos.

Foi com base nos vários autores abordados que surgiu a primeira questão de pesquisa:

Q1 – Quais as principais motivações, características e limitações da IA que influenciam a possibilidade de implementar sistemas inteligentes na segmentação de clientes?

A próxima questão de pesquisa começou a ganhar formato tendo em conta as conclusões dos autores Angwin et al. (2016), Dornelles et al. (2018), Harvard Law Review (2017), Liu et al. (2014), Lobo (2017), McGrath et al. (2019) e Mesquita (2017), que afirmam que os sistemas inteligentes aplicados nos mais diversos sectores de atividade têm um papel de apoio na tomada de decisão, juntamente com uma das falhas identificadas anteriormente, a necessidade de controlar os sistemas inteligentes.

Segundo Armstrong, et al. (2012) e Russell (2019), um sistema inteligente deve possuir mecanismos para controlar, parar e substituir os algoritmos de IA em tempo real, indo de encontro com o pensamento de De Bruyn, et al. (2020) que afirmam que um bom sistema inteligente é um sistema controlável.

Como explicado por De Bruyn, et al. (2020), “nos negócios em geral e no Marketing em particular, existem muitos “*unknow unknowns*” para deixar que algoritmos de IA, por mais eficazes e eficientes que possam ser nas operações do dia-a-dia, funcionem sem controlo humano ou capacidade de substituição”. Foi com o objetivo de perceber em que situações é que os humanos devem controlar os sistemas inteligentes que surgiu a sexta questão de pesquisa:

Q2 – Quais as situações onde os humanos devem substituir e controlar sistemas IA?

A terceira, e última, questão de pesquisa foi pensada tendo em conta as ideias de McGrath, et al. (2019) que afirmam que a implementação destes sistemas poderá encontrar algum tipo de resistência por parte dos colaboradores. Apesar de os sistemas de IA poderem facilitar as tarefas diárias dos colaboradores, os *media* passam a imagem de que os sistemas inteligentes são “destruidores de postos de trabalho”, o que acaba por originar uma resistência à implementação destes sistemas nos colaboradores.

Deste modo, surge a terceira questão de pesquisa que, numa fase inicial, pretende perceber se efetivamente existe algum tipo de resistência dos colaboradores no momento de implementação de

sistemas inteligentes, como observado por McGrath, et al. (2019) e, numa segunda fase, pretende perceber os impactos que essa resistência poderá vir a ter na performance da organização. De referir que não foi encontrado qualquer estudo que suportasse a segunda parte desta questão de pesquisa:

Q3 – Pode existir resistência dos colaboradores na implementação de sistemas inteligentes? Que impactos poderá essa resistência vir a ter na performance da organização?

Capítulo V – Metodologia

Segundo Tarski (1977), a metodologia de investigação é uma disciplina oriunda da lógica e que pretende estudar o método científico. Assim sendo, é possível concluir que método ou processo científico é uma junção de práticas utilizadas e comprovadas pela comunidade científica como sendo válidas para a exposição e confirmação de uma dada teoria.

Tendo em conta essa perspetiva, e considerando o critério de classificação de pesquisa proposto por Vergara (2006) e Vilelas (2020), podemos classificar a metodologia utilizada na criação de documentos de investigação de duas formas, quanto aos fins e quanto aos meios. Os fins referem-se à pesquisa aplicada e exploratória, enquanto que os meios estão ligados ao estudo de campo e pesquisa bibliográfica. Relativamente aos meios do presente estudo, como fontes primárias o estudo contou com a aplicação de inquéritos e entrevistas semiestruturadas, e como fontes secundárias o estudo contou com a pesquisa bibliográfica que resultou de uma análise a vários livros, revistas, estudos e artigos científicos.

Visto que o presente estudo possui dois objetivos (Tabela 2), optou-se por se realizar duas metodologias para cada um dos objetivos. No seguimento do primeiro objetivo (perceber as principais motivações, características e limitações na possibilidade da implementação de sistemas inteligentes na segmentação de clientes), e consequentemente na primeira questão de pesquisa, abordada no capítulo anterior, optou-se por uma abordagem quantitativa através da criação de um questionário. Por outro lado, para responder às questões de pesquisa 2 e 3, estas dentro do segundo objetivo (perceber o impacto da IA na segmentação de clientes numa abordagem refletida nos seus recursos humanos), optou-se por uma abordagem qualitativa e, consequentemente, pela realização de entrevistas.

É importante referir que ambas as abordagens tiveram um carácter pragmático ou indutivo⁸, sendo que foram conduzidas a partir de amostras não probabilísticas por conveniência⁹ (Carmo & Ferreira, 2008), dado que o pretendido era ter uma amostra com membros das áreas de Marketing e/ou Inteligência Artificial de forma a conseguir atingir os objetivos do presente estudo. No entanto, o facto de as amostras terem uma natureza por conveniência faz com que estejam mais sujeitas a serem

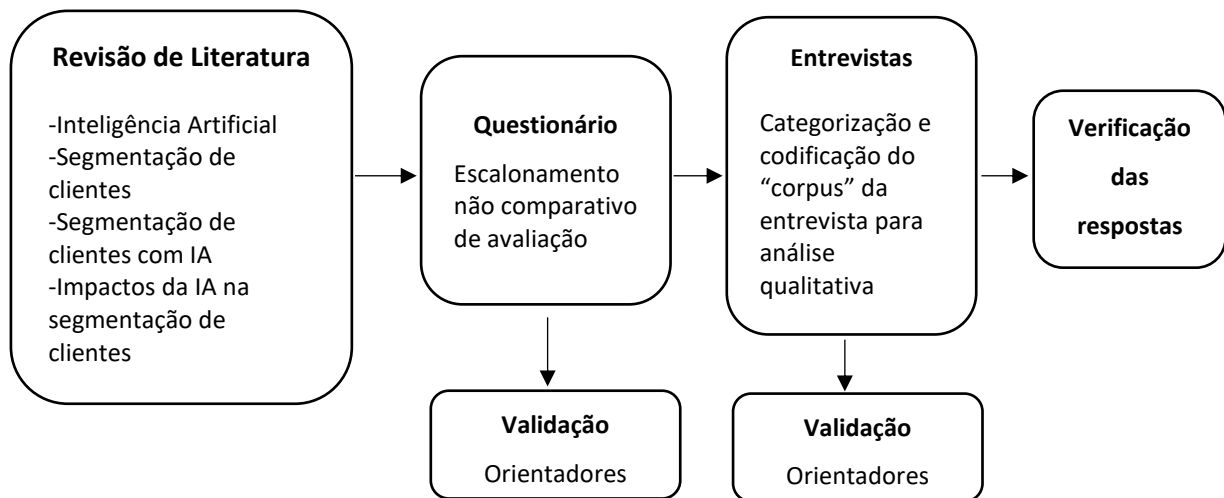
⁸ Não se pretende chegar a conclusões verdadeiras a partir de premissas igualmente verdadeiras (método dedutivo), mas pelo meio da indução, medir um conjunto de fenómenos sociais em estudo a fim de se chegar a um conjunto de probabilidades que permitam fazer comparações e descobrir relações existentes entre eles.

⁹ Este tipo de amostragem não é representativa da população. Acontece quando a participação é voluntária ou os elementos da amostra são escolhidos por uma questão de conveniência. Neste caso, o processo amostral foi constituído por um conjunto de indivíduos aos quais lhes foi pedido que respondessem a um conjunto de questões de um questionário e/ou de uma entrevista. Ou seja, a amostra foi constituída pelos elementos que colaboraram, não podendo por isso ser representativa, pelo que os resultados desta investigação terão de ser lidos com muitas cautelas a fim de se poderem generalizar à população em geral.

influenciadas por variáveis que não estão sob o controlo do investigador, não permitindo, assim, que sejam feitas afirmações gerais e rigorosas sobre a população (Saunders et al. 2016).

A Figura 1 ilustra como foi conduzido o presente estudo. Em suma, inicialmente foi escrita a revisão de literatura, posteriormente foi realizado o trabalho de campo com a elaboração do questionário e das entrevistas, tendo em conta as questões de pesquisa desenvolvidas através da revisão de literatura e, por fim, procedeu-se a uma análise quantitativa, no caso do questionário, e uma análise qualitativa no caso das entrevistas realizadas.

Figura 1 - Modelo de investigação



Fonte: Elaboração do Autor

Relativamente à validade externa, ou seja, a eventualidade de generalizar os resultados encontrados a outros contextos ou amostras, este estudo veio reforçar alguma da teoria já existente, bem como descobrir novas informações sobre o impacto da Inteligência Artificial na segmentação de clientes. Na Tabela 2 é possível verificar os objetivos do estudo e as respetivas questões de pesquisa, revisão de literatura, técnica de análise e, no caso da abordagem quantitativa, as seções do questionário relativas às respetivas questões de pesquisa do primeiro objetivo do estudo.

Tabela 2 - Relação entre revisão de literatura, os objetivos, questões de pesquisa e metodologia

Objetivo de Estudo	Questões de Pesquisa	Revisão de Literatura	Metodologia	Questões nos Inquéritos
OBJ 1 – Perceber os fatores que influenciam a possibilidade de aplicar sistemas inteligentes na segmentação de clientes	(Q1). Quais as principais motivações, características e limitações da IA que influenciam a possibilidade de implementar sistemas inteligentes na segmentação de clientes.	(Tjepkema, 2017) (Vishnoi & Bagga, 2019) (Kietzmann et al. 2018) (De Bruyn et al. 2020) (Fountaine et al. 2019)	Abordagem quantitativa - SmartPLS	Secção 2, secção 3, secção 4 e secção 5 do questionário
OBJ 2 - Perceber o impacto da IA na segmentação de clientes numa abordagem refletida nos seus recursos humanos.	(Q2). Quais as situações onde os humanos devem substituir e controlar sistemas IA?	(Dornelles, et al., 2018) (Lobo, 2017) (Mesquita, 2017) (Liu, et al., 2014) (Harvard Law Review, 2017) (Angwin et al. 2016) (McGrath et al. 2019) (De Bruyn et al. 2020) (Russell, 2019) (Armstrong et al. 2012)	Abordagem qualitativa – Entrevistas com software MAXQDA 2020.1	Guião de entrevista
	(Q3). Pode existir resistência dos colaboradores na implementação de sistemas inteligentes? Que impactos poderá essa resistência vir a ter na performance da organização?	(McGrath et al. 2019)	Abordagem qualitativa – Entrevistas com software MAXQDA 2020.1	Guião de entrevista

Fonte: Elaboração do Autor

5.1 Motivações, características e limitações na possibilidade da implementação de sistemas inteligentes na segmentação de clientes

5.1.1 Modelo de investigação

Como referido anteriormente, para o primeiro objetivo do estudo foi realizada uma abordagem quantitativa com a criação de um questionário, segundo Bhattacharjee (2012), esta abordagem é um instrumento de pesquisa que abrange várias questões, onde a finalidade se concentra na apreensão de respostas de forma padronizada. Vilelas (2020) afirma que este é o método mais adequado quando a unidade de análise do estudo são pessoas, o mais utilizado na área de gestão e o que apresenta maiores vantagens ao nível de custos, tratamento de dados e redução de erro.

Nos questionários o investigador não está presente no ato de recolha de informação e as perguntas têm um grau mais elevado de diretividade, dado que é um questionário estruturado com perguntas fechadas, compreendidas pelos inquiridos e não dúbias. Ao longo do questionário foram colocadas perguntas de identificação, com o objetivo de identificar o inquirido através de grupos sociais (como o género, idade, habilitações académicas, área de trabalho e experiência profissional), perguntas de informação, com o objetivo de recolher dados sobre factos e opiniões do inquirido, e perguntas de controlo para verificar a veracidade de outras perguntas introduzidas noutra parte do questionário (Carmo & Ferreira, 2008).

Os autores Cohen et al. (2007) afirmam que este método permite obter informação complexa e subjetiva como as opiniões dos inquiridos, atitudes e perceções, no entanto este método não tem apenas vantagens. Carmo & Ferreira (2008), afirmam que as elevadas taxas de não respostas, as dificuldades de conceção e o facto de não serem aplicáveis a toda a população são as grandes desvantagens. Porém também apontam várias vantagens, como sendo uma solução barata, rápida na recolha e análise de dados e também simples na análise dos resultados.

Relativamente ao questionário (Anexo G), foi pensado tendo em conta a revisão de literatura e desenhado através do recurso Google Forms, que, após validação dos orientadores do presente estudo, foi partilhado através de um *link*. O questionário era composto por seis secções, a primeira secção era formada por uma pergunta de resposta múltipla com o objetivo de realizar uma triagem inicial e garantir que apenas pessoas ligadas a Marketing e/ou IA pudessem avançar no questionário. As secções dois, três, quatro e cinco pretendiam responder às questões de pesquisa do primeiro objetivo (Tabela 2), através de escalas tipo *Likert* com cinco níveis, em que cada extremo teria uma posição oposta. A última secção possuía quatro questões com resposta múltipla para se proceder à caracterização do inquirido através de grupos sociais.

As respostas foram recolhidas entre 15 de fevereiro de 2021 e 8 de abril de 2021, tendo sido obtidas 110 respostas. De seguida os dados foram extraídos em formato de *Excel* e introduzidos no

software SmartPLS 3, de maneira a realizar uma modelagem de equações estruturais (Structural Equations Modeling ou SEM). Este tipo de modelo, criado por Sewall Wright, apresenta um mapa de caminhos com coeficientes estruturais estimados tendo em conta a correlação entre as variáveis. Segundo Raykov & Marcoulides (2006), o recurso a modelos SEM nos estudos comportamentais e relativos a ciências sociais aumentou bastante nos últimos anos e, na opinião de Tarka (2018), ajudam a suprir a necessidade de explicar e prever comportamentos de indivíduos, grupos e organizações.

O mesmo autor explica que este tipo de modelo para além de conseguir identificar tendências de desenvolvimento, também consegue perceber relações causa-efeito entre as variáveis em estudo. El-Sheikh et al. (2017) explicam que o modelo SEM é composto por uma série de equações onde os parâmetros têm origem numa observação estatística, fazendo com que este modelo, segundo Anderson & Gerbing (1988), seja uma abordagem estatística viável na exploração de relações multivariadas entre as variáveis.

Para uma análise recorrendo a SEM, Anderson & Gerbing (1988), aconselham duas fases. Inicialmente deverá ser testada a credibilidade, a carga fatorial e a qualidade do ajuste para cada escala do estudo, posteriormente o modelo deverá focar-se na relação entre variáveis e descrição dos detalhes de cada uma delas. Segundo Haque, et al. (2019), o modelo SEM é uma excelente forma de medir o efeito das variáveis independentes na dependente, e Raykov & Marcoulides (2000), reforça essa ideia ao afirmar que este modelo consegue ter em conta o erro de medição das variáveis observadas.

De acordo com Ringle, et al. (2015), para testar o modelo conceptual, como referido anteriormente, foi utilizada uma SEM através dos mínimos quadrados parciais (LPS) que é uma técnica de modelagem de equações estruturais baseada na variância. A análise e interpretação dos resultados teve duas fases. Inicialmente foi avaliada a confiabilidade e validade do modelo de medição e, posteriormente, foi analisado o modelo estrutural. Para avaliar a qualidade do modelo de medição, procedeu-se à examinação dos indicadores individuais de confiabilidade, validade convergente, confiabilidade de consistência interna e validade discriminante, tudo procedimentos de acordo com as afirmações de Hair et al. (2017) para este tipo de estudo.

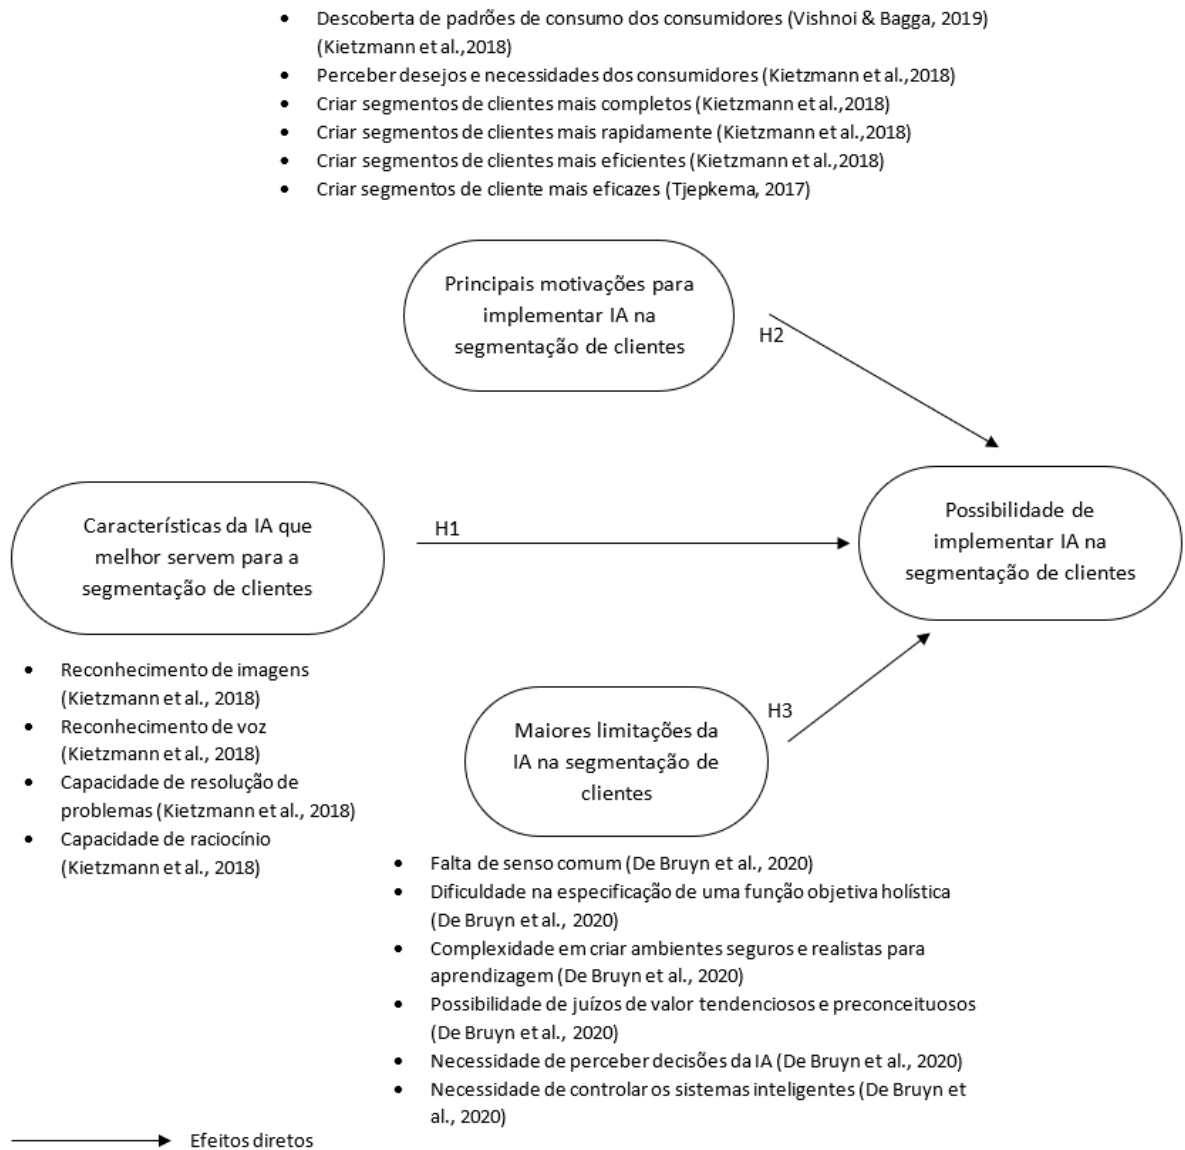
De modo a construir o modelo conceptual para responder ao primeiro objetivo do estudo foi desenvolvida a Figura 2 e Tabela 3, tendo em conta as hipóteses representadas.

H1 – As características da IA impactam positivamente a possibilidade de implementação de IA na segmentação de clientes

H2 – As motivações para implementar IA na segmentação de clientes impactam positivamente a possibilidade de implementação destes sistemas na segmentação de clientes

H3 – As limitações da IA na segmentação de clientes impactam negativamente a possibilidade de implementar esses sistemas na segmentação de clientes

Figura 2 - Modelo conceptual e hipóteses a testar com SmartPLS



Fonte: Elaboração do Autor

Tabela 3 - Relação entre variáveis do modelo conceptual e as perguntas do questionário

Variável independente	Indicador	Pergunta do questionário (respostas 1 a 5)
Características da IA que melhor servem para a segmentação de clientes	Reconhecimento de imagens	Quão importante é o reconhecimento de imagens para melhorar a segmentação de clientes?
	Reconhecimento de voz	Quão importante é o reconhecimento de voz para melhorar a segmentação de clientes?
	Capacidade de resolução de problemas	Quão importante é a capacidade de resolução de problemas para melhorar a segmentação de clientes?
	Capacidade de raciocínio	Quão importante é a capacidade de raciocínio para melhorar a segmentação de clientes?
Principais motivações para implementar IA na segmentação de clientes	Descoberta de padrões de consumo dos consumidores	É a descoberta de padrões de consumo dos consumidores uma motivação forte para a implementação de IA na segmentação de clientes?
	Perceber desejos e necessidades dos consumidores	É a perceção de desejos e necessidades dos consumidores uma motivação forte para a implementação de IA na segmentação de clientes?
	Criar segmentos de clientes mais completos	É a criação de segmentos de clientes mais completos uma motivação forte para a implementação de IA na segmentação de clientes?
	Criar segmentos de clientes mais rapidamente	É a criação de segmentos mais rápidos uma motivação forte para a implementação de IA na segmentação de clientes?
	Criar segmentos de clientes mais eficientes	É a criação de segmentos de uma forma mais eficiente uma motivação forte para a implementação de IA na segmentação de clientes?
	Criar segmentos de clientes mais eficazes	É a criação de segmentos de uma forma mais eficaz uma motivação forte para a implementação de IA na segmentação de clientes?
Maiores limitações da IA na segmentação de clientes	Falta de senso comum	É a falta de senso comum uma grande limitação da IA na segmentação de clientes?
	Dificuldade na especificação de uma função objetiva holística	É a dificuldade na especificação de uma função objetiva holística, uma grande limitação da IA na segmentação de clientes?
	Complexidade em criar ambientes seguros e realistas para aprendizagem	É a complexidade em criar ambientes seguros e realistas para aprendizagem uma grande limitação da IA na segmentação de clientes?
	Possibilidade de juízos de valor tendenciosos e preconceituosos	É a possibilidade de fazer juízos de valor tendenciosos e preconceituosos uma grande limitação da IA na segmentação de clientes?
	Necessidade de perceber decisões dos sistemas inteligentes	É a necessidade de perceber as decisões tomadas pelos sistemas inteligentes uma grande limitação da IA na segmentação de clientes?
	Necessidade de controlar os sistemas inteligentes	É a necessidade de controlar os sistemas inteligentes uma grande limitação da IA na segmentação de clientes?

Fonte: Elaboração do Autor

5.1.2 Descrição da amostra

A presente amostra inclui 110 inquiridos. Inicialmente procedeu-se a uma análise a variáveis que pudessem caracterizar a amostra quanto à sua área de trabalho, género, faixa etária, nível de educação e anos de experiência profissional, com o objetivo de perceber a amostra no que diz respeito à origem e dimensão do conhecimento profissional e experiência (Prodanov & Freitas, 2013). No final, realizou-se uma análise quantitativa das respostas de modo a obter os dados necessários para se tirarem conclusões teóricas e empíricas.

Do total de 110 inquiridos, de acordo como está representado na Tabela 4, 56 inquiridos (51%) trabalham diretamente com IA, 43 inquiridos (39%) trabalham em Marketing e 11 inquiridos (10%) trabalham em ambas as áreas. Relativamente ao género, 63 (57%) dos inquiridos são do género feminino e 47 (43%) do género masculino.

No que respeita à faixa etária, 18 inquiridos (16%) estão entre os 18 e 25 anos, 68 (62%) entre os 26 e 35 anos, 17 (15%) entre os 36 e 45 anos, 6 (5%) entre os 46 e 55 anos e 1 inquirido (1%) entre os 56 e 65 anos. No presente estudo não foi obtida nenhuma resposta de inquiridos com mais de 65 anos.

No que toca ao nível de formação, 1 dos inquiridos (1%) concluiu o ensino secundário, 9 (8%) possuem uma licenciatura, 21 (19%) uma pós-graduação, 72 (65%) um mestrado e 7 (6%) um doutoramento.

Por fim, relativamente aos anos de experiência profissional, 53 inquiridos (48%) possuem menos de 5 anos de experiência, 25 (23%) possuem entre 5 a 10 anos de experiência profissional, 16 (15%) entre 11 a 15 anos e 16 inquiridos (15%) mais de 15 anos de experiência profissional.

Tabela 4 - Caracterização sociodemográfica da amostra

		N	%
Área de trabalho	IA	56	51
	Marketing	43	39
	Ambas	11	10
Género	Feminino	63	57
	Masculino	47	43
Faixa etária	Entre 18 e 25 anos	18	16
	Entre 26 e 35 anos	68	62
	Entre 36 e 45 anos	17	15
	Entre 46 e 55 anos	6	5
	Entre 56 e 65 anos	1	1
	Mais de 65 anos	0	0
Nível de formação	Ensino secundário	1	1
	Licenciatura	9	8
	Pós-graduação	21	19
	Mestrado	72	65
	Doutoramento	7	6
Anos de experiência profissional	Menos de 5 anos	53	48
	Entre 5 e 10 anos	25	23
	Entre 11 e 15 anos	16	15
	Mais de 15 anos	16	15

Fonte: Elaboração do Autor

5.2 Impacto da IA nos colaboradores

5.2.1 Modelo de investigação

Relativamente ao segundo objetivo, “perceber o impacto da IA na segmentação de clientes numa abordagem refletida nos seus recursos humanos”, a abordagem utilizada foi qualitativa. A abordagem teve como princípio a realização de entrevistas semiestruturadas como fonte de informação qualitativa primária (Anexo H), e com o objetivo de compreender a posição dos entrevistados relativamente aos impactos que os sistemas inteligentes podem vir a ter nos colaboradores.

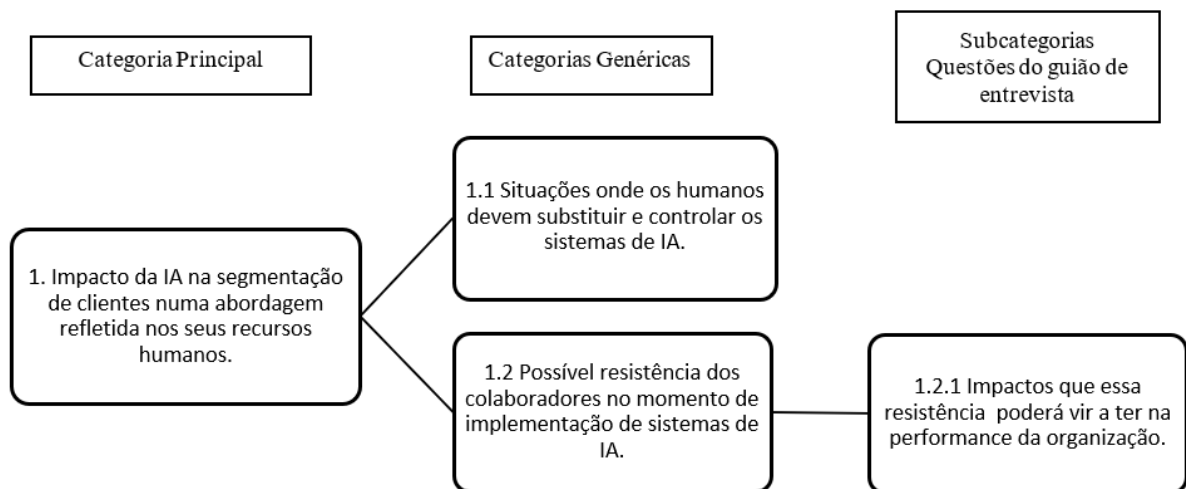
Segundo Carmo & Ferreira (2008), este método permite que os entrevistados sejam os principais atores sociais a fornecer dados sobre o fenómeno em estudo. Os mesmos autores afirmam que a

entrevista semiestruturada deve ser uma entrevista adaptável e não rígida, permitindo que a conversa decorra a um ritmo fluido. Por outras palavras, as perguntas devem surgir conforme a conversa se desenvolve, permitindo que ambas as partes da entrevista consigam desenvolver e/ou confirmar certos dados, tal como aconteceu no presente estudo.

Como principal vantagem, afirma que este método tem como vantagem o facto de não ser necessário uma recolha uniforme de dados quantificados e comparáveis entre os diversos entrevistados. No entanto, essa recolha não uniforme de dados dificulta o agrupamento e comparação das respostas, tornando mais complexa a sintetização dos *outputs* recolhidos nas entrevistas (Vilelas, 2020).

Segundo Vilelas (2020), o número de entrevistas a serem realizadas para que o estudo tenha um grau de fiabilidade aceitável deve ser entre as 15 a 20 entrevistas. No final de 16 entrevistas foi possível notar um certo grau de repetição de ideias por parte dos entrevistados sendo que, acrescentando esse fator ao critério definido por Vilelas (2020), não se realizaram mais entrevistas. Não obstante, apesar do número de entrevistas realizadas ir ao encontro com o pedido pelos autores, é preciso ter em conta que as conclusões deste estudo devem ser lidas com as devidas cautelas de uma amostra reduzida. Na *Figura 3* é possível analisar a categorização e codificação do *corpus* da entrevista.

Figura 3 - Categorização e codificação do corpus da entrevista para análise qualitativa



Fonte: Elaboração do Autor

De forma a serem analisadas as informações decorrentes das entrevistas, procedeu-se a uma análise de conteúdo recorrendo ao software MAXQDA 2020.1 para a análise dos dados qualitativos. Segundo Bardin (1977), a análise de conteúdo deve possuir três fases, começando pela realização de uma pré-análise, isto é, organização e sistematização das ideias que resultaram das entrevistas. De

seguida deverá ser feita a exploração de material onde se procede à codificação e categorização do material e, por fim, deverá ser realizado o tratamento dos resultados obtidos e respetiva interpretação dos mesmos.

De notar que, devido à situação pandémica que se viveu durante o estudo, todas as entrevistas foram feitas via *online*.

5.2.2 Descrição da amostra

Relativamente às pessoas entrevistadas, todas elas tinham contacto com IA ou com Marketing de forma a que os seus *inputs* fossem realmente relevantes para o objetivo do estudo em questão. Todos os contactos de possíveis entrevistados foram conseguidos via questionário onde, no fim do mesmo, existia uma pergunta em que as pessoas podiam colocar o seu contacto caso estivessem disponíveis e interessados em serem entrevistados. Após a realização das entrevistas foi realizada uma análise de conteúdo das respostas, onde foi possível obter dados analíticos que permitiram tirar conclusões teóricas e empíricas.

Das 16 entrevistas realizadas, de acordo como está representado na Tabela 5, 7 (44%) foram realizadas a pessoas ligadas a IA, 8 (50%) a pessoas ligadas a Marketing e 1 (6%) entrevistado estava ligado às duas áreas de trabalho. Relativamente ao género, 9 (56%) das entrevistas foram a pessoas do sexo feminino e 7 (44%) a pessoas do sexo masculino. Por fim, relativamente ao nível de formação académica, 5 dos entrevistados (31%) concluíram uma licenciatura, 9 (56%) o mestrado e 2 (13%) o doutoramento.

Tabela 5 - Caracterização sociodemográfica da amostra

		N	%
Área de trabalho	IA	7	44
	Marketing	8	50
	Ambas	1	6
Género	Feminino	9	56
	Masculino	7	44
Nível de formação	Licenciatura	5	31
	Mestrado	9	56
	Doutoramento	2	13

Fonte: Elaboração do Autor

Ainda que o número de respostas seja considerado satisfatório, as conclusões deste estudo devem ser lidas com os devidos cuidados de uma amostra considerada pequena.

Capítulo VI – Apresentação e discussão de resultados

6.1 Principais motivações, características e limitações na possibilidade da implementação de sistemas inteligentes na segmentação de clientes

Para a análise e interpretação dos resultados do primeiro objetivo do estudo foi tida em conta uma abordagem de duas fases, explicada por Hair et al. (2017). Segundo os autores, em primeiro lugar deve ser avaliada o grau de confiabilidade e validade do modelo de medição e depois a avaliação do modelo estrutural. Os indicadores individuais a serem examinados para avaliar a qualidade do modelo de medição são confiabilidade (CR), validade convergente, confiabilidade de consistência interna e validade discriminante.

Os resultados mostraram que as cargas fatoriais padronizadas da maioria dos itens são superiores a 0.6 (*Figura 4*), e foram significativas quando $p < 0,001$, o que mostrou a confiabilidade do indicador individual (Hair et al. 2017). A confiabilidade interna foi confirmada porque todos os valores da confiabilidade composta (*Composite Reliability*) dos constructos são superiores a 0.7 (Hair et al. 2017), conforme representado na Tabela 6.

Tabela 6 - Verificações de CR, AVE, correlações e validade discriminante

	CR	AVE	1	2	3	4
(1) Características	0,800	0,503	0,253	0,258	0,478	0,251
(2) Limitações	0,756	0,442	0,031	0,195	0,220	0,352
(3) Motivações	0,790	0,488	0,224	-0,016	0,238	0,278
(4) Possibilidade de Implementar IA	1,000	1,000	0,224	-0,292	0,247	1,000

Nota: CR - fiabilidade composta; AVE - variância média extraída. Os números em negrito são as raízes quadradas da AVE. Abaixo dos elementos diagonais estão as correlações entre os constructos. Acima dos elementos diagonais estão valores de HTMT.

Fonte: Elaboração do Autor

Conforme representado na tabela acima, é possível concluir que a validade convergente foi confirmada por cumprir três critérios. O primeiro critério passa por ter todos os itens positivos e significativos nos respetivos construtos, como observado anteriormente. O seguinte critério diz que todos os constructos devem ter valores de CR superiores a 0.70, o que também acontece. Por fim, a AVE (variância média extraída) excedeu o valor mínimo de 0.50 (Bagozzi & Yi, 1998). Relativamente à validade discriminante, esta foi avaliada por duas abordagens. Inicialmente foi usado o critério de Fornell & Larcker (1981) que, segundo os autores, requer a raiz quadrada da AVE (valores representados na diagonal da tabela em negrito) maior do que a sua maior correlação com qualquer construto, critério esse que é cumprido como se pode verificar na Tabela 6. Posteriormente foi utilizado o critério do rácio HTMT (*heterotrait-monotrait ratio*) (Hair et al. 2017; Henseler et al. 2015),

segundo o qual os autores dizem que estes valores devem ser menores que 0.85 para que o modelo ofereça mais provas de validade discriminante, algo que os valores acima da diagonal cumprem.

Relativamente à avaliação do modelo estrutural, segundo Hair, et al. (2017), esta deve ser feita em três etapas. Inicialmente deve feita através do sinal, magnitude e significância dos coeficientes do caminho estrutural, de seguida através da magnitude do valor de R^2 para cada variável endógena como uma medida da precisão preditiva do modelo e, por fim, através dos valores de Q^2 de Stone-Geisser como uma dimensão da relevância preditiva do modelo. No entanto foi verificada uma colinearidade antes de se avaliar o modelo estrutural (Hair et al. 2017). Os mesmos autores pedem que os valores *variance inflation factor* (VIF) sejam todos inferiores a 5, o que realmente acontece neste modelo pois os valores encontram-se num intervalo de valores entre 1.00 e 2.322, cumprindo com o requisito defendido pelos autores. Os valores não indicam colinearidade.

O coeficiente de determinação R^2 para a variável endógena de possibilidade de implementação de IA na segmentação de clientes é de 17,8% que também cumpre com o que os autores Falk & Miller (1992) pedem, que é ser superior a 10%. Por fim, os valores de Q^2 para a variável endógena é de 0.123, o que, segundo Hair et al. (2017), indica uma relevância preditiva do modelo.

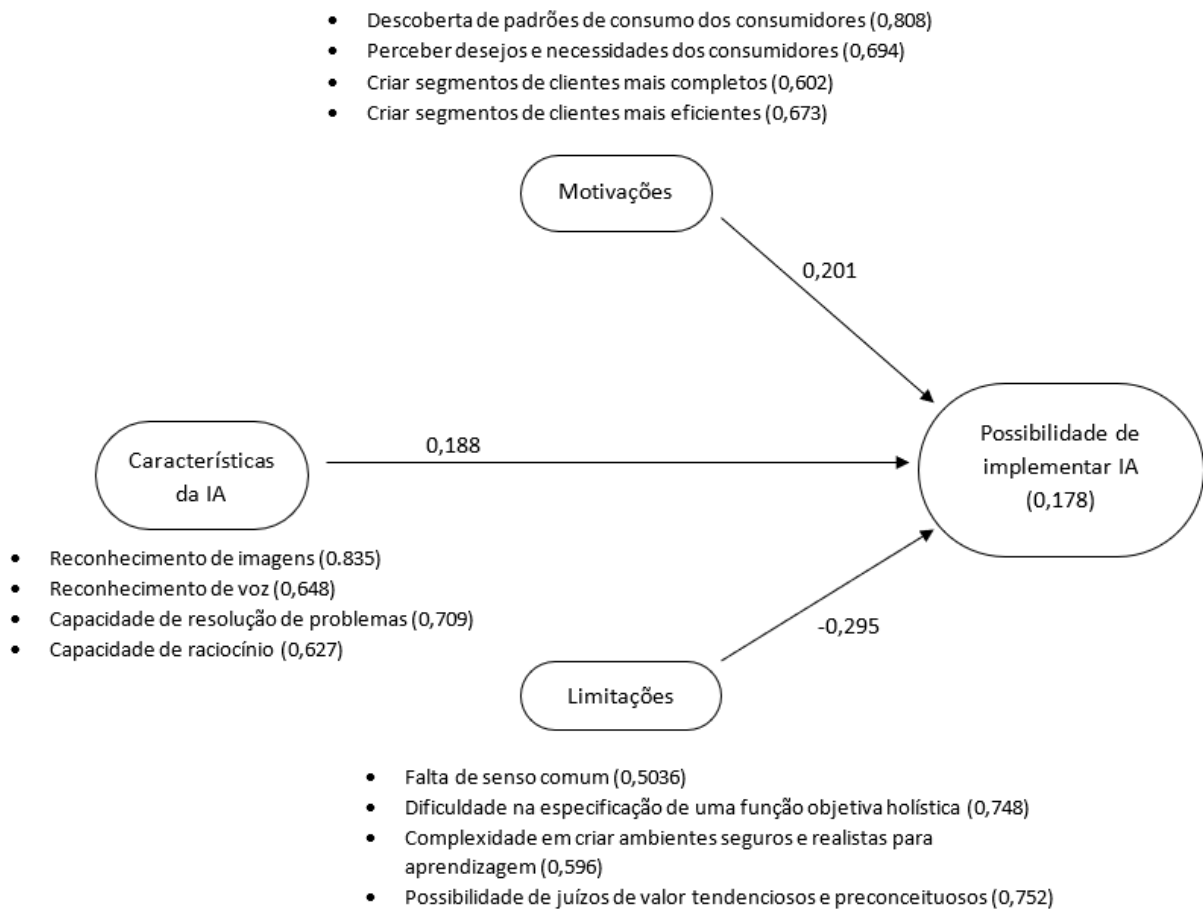
Tabela 7 - Relações diretas entre construtos

	Original Sample	Standard Deviation	T Statistics	P Values
Características-> Possibilidade de Implementar IA	0.188	0.073	2.577	0.010
Limitações -> Possibilidade de Implementar IA	-0.295	0.079	3.747	0.000
Motivações -> Possibilidade de Implementar IA	0.201	0.080	2.496	0.013

Fonte: Elaboração do Autor

Os resultados da Tabela 7 mostram que as características da IA têm um impacto positivo na possibilidade de implementação de IA na segmentação de clientes ($\beta = 0.188$, $p < 0.001$), o que nos diz que a IA realmente tem características intrínsecas que podem ser úteis na segmentação de clientes, confirmando a hipótese H1. Um efeito semelhante também acontece com as motivações para se utilizar a IA. Estas também têm um impacto positivo na possibilidade de implementar sistemas inteligentes na segmentação de clientes ($\beta = 0.201$, $p < 0.001$), o que nos diz que, de facto os benefícios da IA são motivações reais para se utilizar IA na segmentação de clientes, comprovando a hipótese H2. Por fim podemos ver que as limitações da IA têm um efeito oposto e afetam negativamente a possibilidade de implementação de IA na segmentação de clientes ($\beta = -0.295$, $p < 0.001$), o que comprova a hipótese H3 e diz-nos que quanto maior forem as limitações, então maior serão as barreiras na implementação deste tipo de tecnologia para a segmentação de clientes.

Figura 4 – Modelo conceptual testado com SmartPLS3 com valores associados



Fonte: Elaboração do Autor

Como já foi referido, o modelo conceitual em estudo foi submetido a vários testes utilizando o *software* SmartPLS 3 de forma a responder ao primeiro objetivo do presente estudo - “Quais as principais motivações, características e limitações na possibilidade da implementação de sistemas inteligentes na segmentação de clientes”. Como é visível na Figura 4, foram identificados três fatores para explicar a possibilidade de implementar IA na segmentação de clientes, sendo estes as características da IA que melhor servem para a segmentação, identificadas por Kietzmann, et al. (2018), as motivações para a implementação da IA na segmentação de clientes, identificadas por Vishnoi & Bagga (2019), Kietzmann et al. (2018) e Tjepkema (2017), e por fim, as limitações que este tipo de tecnologia pode ter na segmentação de clientes, identificados por De Bruyn, et al. (2020). De forma a chegar aos três fatores identificados anteriormente, os indicadores de cada fator foram avaliados individualmente através do questionário, sendo que, a maioria atinge pontuações acima de 0.6, o que nos diz que são indicadores confiáveis quando $p < 0.001$ Hair et al. (2017).

Relativamente às características da IA que melhor servem a segmentação de clientes, os resultados mostram-se em linha com as ideias dos autores estudados e comprovam que estas são o reconhecimento de imagens e de voz, a capacidade de resolução de problemas e a capacidade de raciocínio (Kietzmann et al. 2018).

Sobre as principais motivações para implementar IA na segmentação de clientes, os resultados não estão totalmente em linha com a teoria dos autores estudados. Os resultados do modelo mostram que são a descoberta de padrões de consumo dos consumidores (Vishnoi & Bagga, 2019), a perceção dos desejos e necessidades dos consumidores, a criação de segmentos mais completos e mais eficientes (Kietzmann et al. 2018) as principais motivações para se utilizarem sistemas inteligentes na segmentação de clientes. O ponto de discórdia é relativamente às variáveis: criar segmentos de clientes mais rapidamente (Kietzmann et al. 2018) e mais eficazes (Tjepkema, 2017). Segundo o modelo, estas são pouco significativas no momento de influenciar a implementação de IA na segmentação de clientes, tendo sido retiradas do modelo.

Por fim, o resultado das maiores limitações da IA na segmentação de clientes voltam a não estar em total concordância com os autores estudados. As principais limitações são então a falta de senso comum, dificuldade na especificação de uma função objetiva, complexidade em criar ambientes seguros e realistas para a aprendizagem e a possibilidade de criar juízos de valor tendenciosos e preconceituosos (De Bruyn et al. 2020). De acordo com o modelo conceptual, a necessidade de perceber as decisões da IA e de a controlar (De Bruyn et al. 2020), são pouco significativas no momento de influenciar a implementação de IA na segmentação de clientes, tendo sido excluídas do modelo.

Após estarem identificadas as três categorias genéricas com impacto na possibilidade de implementação de sistemas inteligentes na segmentação de clientes, avançou-se para a testagem das hipóteses formuladas no capítulo da metodologia. O modelo conceptual é composto apenas por efeitos diretos e os resultados mostram que as características dos sistemas inteligentes impactam positivamente a possibilidade de implementação da IA na segmentação de clientes, confirmando a hipótese H1 do estudo. Assim, conclui-se que, de facto, a IA tem características, tais como reconhecimento de imagens e de voz e capacidade de resolução de problemas e de raciocínio, que podem realmente ser aproveitadas pelas empresas e assim aumentar a possibilidade de usar IA na problemática de gestão que é a segmentação de clientes (Kietzmann et al. 2018).

Relativamente às motivações, os resultados mostram que as motivações para se usar sistemas inteligentes também impactam positivamente a possibilidade de implementar este tipo de tecnologia, confirmando a hipótese H2 do estudo. Resumindo, tal como dito pelos autores, quanto maior for a perceção das motivações para se usar a IA, tais como descoberta de padrões de consumo dos consumidores (Vishnoi & Bagga, 2019; Kietzmann et al. 2018), a perceção dos desejos e necessidades

dos consumidores, a criação de segmentos mais completos e mais eficientes, maior será a possibilidade de implementação destes sistemas na segmentação de clientes (Kietzmann et al. 2018).

Por fim, os resultados relativos às limitações da IA mostram que estes impactam negativamente a possibilidade de as empresas implementarem IA na segmentação de clientes, comprovando a hipótese H3, ou seja, quanto maior forem as limitações identificadas pelas empresas, menor será a possibilidade de implementação de IA para segmentar clientes. Apesar de todas as mais valias que a IA pode trazer às empresas, ainda existem algumas limitações associadas. Estas passam maioritariamente pela falta de senso comum, dificuldade na especificação de uma função objetiva, complexidade em criar ambientes seguros e realistas para a aprendizagem e a possibilidade de criar juízos de valor tendenciosos e preconceituosos (De Bruyn, et al. 2020), que originam barreiras quando se pensa em utilizar este tipo de tecnologia para a segmentação de clientes.

De modo geral, o modelo mostra que, tendo em conta as principais motivações, características da IA e as suas limitações, é realmente possível implementar sistemas inteligentes na segmentação de clientes, conclusão que está em linha ao estudo realizado por Fountaine et al. (2019).

6.2 Perceber o impacto da IA na segmentação de clientes numa abordagem refletida nos seus recursos humanos

6.2.1 Situações em que os humanos devem substituir e controlar sistemas de IA

A categoria genérica 1.1 teve como objetivo questionar os entrevistados de forma a perceber em que situações é que os humanos devem substituir e controlar sistemas inteligentes. Como representado na Tabela 8, existem claramente duas situações que têm mais consenso entre os entrevistados.

Tabela 8 - Situações em que os humanos devem substituir e controlar sistemas IA

Texto	Categoria Genérica	Nº de vezes	Entrevistados
Nas tomadas de decisões.	1.1	8	2, 3, 5, 6, 7, 9, 10, 13
Situações em que o comportamento do consumidor muda numa direção oposta ao espectável.	1.1	7	1, 7, 8, 10, 12, 13, 14
Situações em que algoritmos tenham informações sensíveis sobre pessoas.	1.1	3	4, 11, 14
Situações em que existe um desvio superior ao desvio padrão definido.	1.1	3	1, 7, 15
Problemas mais complexos.	1.1	2	5, 16

Fonte: Elaboração do Autor

Na visão de 8 dos entrevistados, os sistemas inteligentes têm a função importante de apoiar as tomadas de decisão, sendo por isso uma tarefa mais operacional e de recolha de dados, a leitura e análise dos dados recolhidos pela IA deve ser feita pelas pessoas. Uma das entrevistadas afirma que *“nos dias de hoje a IA serve muito de apoio na tomada de decisão, principalmente para apoiar decisões estratégicas. O papel de recolha de dados é feito pelos algoritmos e é de responsabilidade dos seres humanos a leitura, interpretação, organização e direcionamento dos dados. São os sistemas inteligentes que nos devem mostrar como é que uma campanha de Marketing está a ser recebida por parte dos clientes-alvo, mas a análise dos dados e decisão estratégica é uma tarefa dos humanos”*.

Esta visão vai ao encontro das ideias dos autores Dornelles et al. (2018), Lobo (2017), Mesquita (2017), Liu et al. (2014), Harvard Law Review (2017), Angwin, et al. (2016), e McGrath, et al. (2019) apresentadas ao longo do capítulo de revisão de literatura.

A segunda situação mais referida pelos entrevistados (um total de 7) em que os humanos devem substituir e controlar os sistemas inteligentes, é quando um comportamento do cliente caminha numa direção totalmente oposta ao espectável. Nesta situação os humanos devem então substituir e controlar os sistemas inteligentes de modo a perceberem as razões para o que está a acontecer e assim saberem como atuar.

Uma das entrevistadas deu um exemplo de uma experiência que teve numa empresa onde trabalhou. A empresa em questão fazia uma *“segmentação de clientes baseada no comportamento de compra e consumo do cliente”*. A entrevistada explicou que esta situação específica aconteceu com uma consumidora que estava grávida. Através do seu comportamento de compra, nomeadamente através da aquisição de produtos para bebés, o algoritmo apercebeu-se da sua condição e, de

imediatamente, começou a impactar a consumidora com campanhas relacionadas com bebês. No entanto a consumidora sofreu um aborto espontâneo e começou a comprar produtos que não são normais para grávidas, como pensos higiênicos.

A entrevistada referiu que *“o algoritmo não entendeu a mudança de comportamento e continuou a impactar a consumidora com mais campanhas de bebês, o que originou uma situação complicada para a empresa. Toda a situação poderia ter sido evitada com a criação de um mecanismo de segurança que informasse o algoritmo para parar de impactar a consumidora, com o mesmo tipo de campanhas, numa situação em que a mesma comprasse um produto que não estivesse relacionado com a gravidez, mas sim com outro comportamento fisiológico feminino contrário ao inicial. Com a intervenção humana numa fase inicial todo este problema era perfeitamente evitável.”*

Esta última conclusão da entrevistada sobre a criação de mecanismos de segurança nos sistemas inteligentes está exatamente na mesma linha de pensamento dos autores Armstrong et al. (2012), Russell (2019) e De Bruyn, et al. (2020), mostrando-nos que é realmente uma preocupação atual no momento de criação deste tipo de algoritmos.

Em suma, é possível concluir que, através da análise de conteúdo, a principal visão dos entrevistados se encontra em linha com as conclusões de alguns dos autores estudados na revisão de literatura e referenciados neste capítulo. Sobre a segunda visão não foi encontrada qualquer literatura que a suportasse, no entanto, a grande repetição nas entrevistas é indicador de que pode ser realmente uma situação a ter em conta para substituir e controlar os sistemas inteligentes.

6.2.2 Possível resistência na implementação de sistemas inteligentes e impactos na performance da organização

A categoria genérica 1.2 teve como objetivo questionar os entrevistados de forma a entender se atualmente existe resistência, por parte dos colaboradores, no momento de implementação de sistemas inteligentes. Caso a resposta seja positiva a categoria leva uma subcategoria (1.2.1) onde se pretende perceber que impactos é que essa resistência poderá causar na performance da organização. A tabela 9 mostra os resultados das entrevistas que pretendem explorar a questão de pesquisa 3.

Tabela 9 – Possibilidade de resistência na implementação de IA nas organizações

Texto	Categoria Genérica	Nº de vezes	Entrevistados
Pode existir resistência em pessoas menos instruídas ou com mais idade.	1.2	6	3, 4, 6, 12, 14, 16
Existe resistência.	1.2	5	2, 7, 9, 13, 15
Depende do sector de atividade.	1.2	3	1, 8, 10
Não existe resistência.	1.2	2	5, 11

Fonte: Elaboração do Autor

De um modo geral, a grande maioria dos entrevistados considera existir algum tipo de resistência, sendo que apenas dois entrevistados acreditam não existir qualquer tipo de resistência. Uma entrevistada refere que *“não existe resistência dos colaboradores quando se implementam este tipo de sistemas, muito pelo contrário. Os colaboradores olham para a IA como uma mais valia, é uma forma de rentabilizar as tarefas e que permite estarem mais focados em tarefas mais essenciais do negócio e não tão operacionais, principalmente no sector de IT.”*. Esta visão vai ao encontro ao estudo realizado por McGrath, et al. (2019), em que os autores concluíram que um dos impactos da implementação de sistemas inteligentes é precisamente a redução do tempo despendido para realizar tarefas mais operacionais.

Contudo, esta visão não é partilhada pela grande maioria dos entrevistados. Dentro das pessoas que considera ainda existir alguma resistência, 6 entrevistados consideram que pode existir alguma resistência, mas que essa resistência terá origem em grupos de pessoas com menos consciência dos benefícios que estas tecnologia podem trazer, e que por norma são pessoas com mais idade. Outra visão partilhada durante as entrevistas é de que realmente existe resistência por parte dos colaboradores no momento de implementação de IA, segundo um entrevistado *“existe resistência à mudança e as pessoas podem sentir que o posto de trabalho está em risco, mas essas pessoas deveriam perceber que a IA traz muitos benefícios e que com estes sistemas podem focar-se em tarefas realmente importantes para o negócio”*. Também esta visão vai de encontro do estudado por McGrath et al. (2019), onde se afirma que ainda existe a ideia de que os sistemas inteligentes podem colocar os postos de trabalho em risco o que pode originar resistência aos mesmos.

Por fim, 3 entrevistados admitem que pode existir resistência, mas que essa depende muito do setor de atividade em que as organizações estão inseridas e que *“nas áreas de IT não existe qualquer tipo de resistência”*.

Como referido, dependendo da resposta dada pelos entrevistados à categoria genérica 1.2, existe a possibilidade de as visões levarem à subcategoria 1.2.1 e com isto, serem percebidos os impactos

que a resistência à implementação de IA tem nas organizações, sendo que esses mesmos impactos estão resumidos na Tabela 10.

Tabela 10 – Impactos da resistência da IA na performance da organização

Texto	Categoria Genérica	Subcategoria	Nº de vezes	Entrevistados
Sem impactos significantes.	1.2	1.2.1	6	1, 3, 4, 10, 12, 14
Custos evitáveis.	1.2	1.2.1	6	6, 7, 8, 9, 15, 16
Pode impactar positiva ou negativamente.	1.2	1.2.1	2	2, 13

Fonte: Elaboração do Autor

Conforme apresentado na Tabela 10, uma boa parte das pessoas (6) desvaloriza a resistência que se vive em relação à IA e que os possíveis impactos são insignificantes para as organizações. Uma das entrevistadas argumenta que *“a mudança para a IA é inevitável e tanto as empresas como as pessoas vão ser obrigadas a aceitar a IA pelo que a resistência atual não é significativa”*. Outro entrevistado complementa afirmando que *“a revolução que estamos a viver com a IA está ao nível da primeira revolução industrial e que os colaboradores vão ser obrigados a acompanhar o progresso, quando surgiram os computadores todos diziam que seriam inúteis para o trabalho, hoje é impensável trabalhar sem um computador”*.

Por outro lado, a mesma quantidade de entrevistados (6) considera que este tipo de resistência pode causar custos evitáveis para a organização e que isso obviamente poderá contribuir negativamente para a sua *performance*. Uma entrevistada afirma que *“a desconfiança e consequente resistência pode trazer prejuízos desnecessários para uma organização”*, já outra entrevistada afirma ainda que *“a resistência traz passividade ao erro humano que é duplamente prejudicial para a empresa pois pode causar custos perfeitamente evitáveis e ainda é perdido tempo para corrigir um problema que poderia não ter existido.”*

Por fim, dois dos entrevistados consideram que é complicado perceber os impactos que a resistência pode causar pois, *“os colaboradores podem ter a necessidade de mostrar que trazem mais valor que a IA e então vão esforçar-se para provar isso mesmo, sendo que neste caso a organização irá beneficiar desta resistência. Por outro lado, as organizações podem ter pessoas que tomem como garantido que vão perder o posto de trabalho e então fazem o mínimo dos possíveis para o manter,*

neste caso os impactos serão negativos". Importa lembrar que para esta subcategoria não foi encontrada qualquer literatura que suportasse os resultados do estudo.

Capítulo VII – Conclusão

7.1 Considerações Finais

Como concluído por Fountaine et al. (2019), atualmente as empresas estão cada vez mais cientes das mais valias que a implementação da IA pode trazer às mesmas e, para isso, muito contribuem os vários estudos sobre esta temática. O estudo realizado pela consultora Accenture, levado a cabo por Purdy & Daugherty (2017), fala do potencial enorme que os sistemas inteligentes têm para impulsionar a economia mundial, o que leva a que os olhos estejam postos nesta tecnologia.

Um dos “olhos mais atentos” pertence ao Marketing visto que, em 2016 e segundo Naimat (2016), já era a quarta maior área que mais recursos gastava com a utilização da IA e a sexta maior indústria que mais investia na IA. Após uma extensa pesquisa sobre IA e segmentação de clientes, e a análise de um questionário com 110 respostas e 16 entrevistas, foi possível chegar a várias conclusões.

Após concluída a revisão de literatura foi possível definir uma série de questões de pesquisa e as variáveis que dariam respostas às mesmas, por sua vez estariam nas várias conclusões dos diversos autores referenciados ao longo da revisão da literatura. A primeira questão de pesquisa pretendia perceber quais as variáveis que influenciavam a implementação da IA na segmentação de clientes. Após a conclusão da revisão de literatura, e posterior criação do modelo conceptual, percebeu-se que as variáveis estariam divididas em três grupos, nomeadamente motivações, características da IA e limitações da mesma.

Relativamente às motivações, conforme abordado ao longo da revisão da literatura, foi possível identificar que as principais motivações para implementação de IA na segmentação de clientes passam por: descoberta de padrões de consumo dos consumidores (Vishnoi & Bagga, 2019; Kietzmann et al., 2018), perceber os desejos e necessidades dos consumidores, criar segmentos de clientes mais completos, criar segmentos de clientes mais rapidamente, criar segmentos de clientes mais eficientes (Kietzmann et al. 2018) e, por fim, criar segmentos mais eficazes (Tjepkema, 2017). No entanto, após analisados os outputs dos questionários, concluiu-se que as a criação de segmentos mais eficazes (Tjepkema, 2017) e de uma forma mais rápida (Kietzmann et al. 2018), segundo o modelo conceptual, não influenciam de forma significativa a possibilidade de implementação de IA na segmentação de clientes, sendo confirmadas quatro das seis principais motivações para implementar IA identificadas pelos autores.

Sobre as características da IA, os autores dizem-nos que as características que melhor servem para a segmentação de clientes são: o reconhecimento de imagens e de voz, e a capacidade de resolução de problemas e de raciocínio (Kietzmann et al. 2018). Neste caso, os outputs dos questionários estão na mesma linha de pensamento dos autores referenciados, ou seja, o modelo conceptual diz-nos que todas as variáveis identificadas são relevantes e que influenciam a possibilidade de implementar IA.

O último grupo de variáveis que influenciam a possibilidade de implementar IA, como referido anteriormente, são as limitações destas tecnologias. Os autores dizem que estas passam pela falta de senso comum, dificuldade na criação de uma função objetiva holística, complexidade na criação de ambientes seguros e realistas para a aprendizagem destes sistemas, a possibilidade de juízos de valor tendenciosos e preconceituosos, a necessidade de perceber as decisões da IA e, a necessidade de controlar esta tecnologia (De Bruyn et al. 2020). De acordo com o modelo conceptual, a necessidade de perceber as decisões e controlar a IA, são duas variáveis pouco significativas no momento de influenciar a implementação deste tipo de tecnologias. Ou seja, das seis variáveis inicialmente identificadas pelos autores, quatro foram confirmadas como reais limitações da IA na sua implementação na segmentação de clientes.

Após análise dos dados retirados dos questionários, concluiu-se que, tanto as principais motivações, como as características da IA que melhor servem a segmentação de clientes, afetam positivamente a possibilidade de implementar sistemas inteligentes na problemática de gestão que é a segmentação de clientes. Tal como defendido pelos autores, quanto maior for a perceção das motivações para se usar a IA, tais como descoberta de padrões de consumo dos consumidores (Vishnoi & Bagga, 2019) e (Kietzmann et al. 2018), a perceção dos desejos e necessidades dos consumidores, a criação de segmentos mais completos e mais eficientes, maior será a possibilidade de implementação destes sistemas na segmentação de clientes (Kietzmann et al. 2018). Relativamente às características da IA, tais como reconhecimento de imagens e de voz, capacidade de resolução de problemas e de raciocínio (Kietzmann et al. 2018), podem realmente ser aproveitadas pelas organizações, aumentando a possibilidade de usar IA para a segmentação de clientes.

Em contrapartida, segundo o modelo, as limitações da IA impactam negativamente a possibilidade de implementação da IA na segmentação de clientes. De facto os autores estudados alertam para algumas limitações destes sistemas como a falta de senso comum, dificuldade na especificação de uma função objetiva, complexidade em criar ambientes seguros e realistas para a aprendizagem e a possibilidade de criar juízos de valor tendenciosos e preconceituosos (De Bruyn, et al., 2020), acabam por criar barreiras quando se pensa em utilizar este tipo de tecnologia para a segmentação de clientes, ou seja, quanto maiores forem estas limitações, menor será a probabilidade de implementar IA na segmentação de clientes.

A segunda questão de pesquisa pretendia perceber em que situações os humanos deveriam substituir e controlar os sistemas inteligentes. Para responder a esta questão de pesquisa, foram realizadas 16 entrevistas e a análise de conteúdos mostrou-nos que existe claramente duas respostas, para esta questão de pesquisa, que geram consenso.

A primeira resposta prende-se com o facto de os humanos deverem substituir a IA em momentos de tomada de decisão, tal como os Angwin et al. (2016), Dornelles et al. (2018), Harvard Law Review

(2017), Liu et al. (2014), Lobo (2017), McGrath et al. (2019), Mesquita (2017) e Tjepkema (2017) defendem. Os autores dizem que atualmente a IA é uma ferramenta de apoio na tomada de decisão e que essa decisão deve ser tomada pelos humanos, opinião claramente partilhada pelos entrevistados.

A segunda resposta que gerou consenso indica-nos que os sistemas de IA devem ser substituídos por humanos em situações em que o comportamento do consumidor muda numa direção oposta ao espectável. Segundo os entrevistados, neste tipo de situações os humanos devem parar e substituir os algoritmos de forma a perceber o que motivou tal mudança de comportamento. Esta visão, partilhada por uma grande parte dos entrevistados, não foi encontrada na literatura, no entanto, a repetição desta visão nas entrevistas, diz-nos que é realmente uma situação recorrente no mundo atual.

Por fim, a terceira e última questão de pesquisa tinha como objetivo perceber se existe resistência, por parte dos colabores, à implementação de sistemas inteligentes e se essa possível resistência provoca algum tipo de impactos na performance organizacional.

De modo geral, a grande maioria dos entrevistados afirmou que realmente existe resistência no momento de implementação de IA nas organizações. Esta visão, vai de encontro da opinião dos autores McGrath et al. (2019), que afirmam que ainda existe a ideia de que os sistemas inteligentes podem colocar os postos de trabalho em risco e isso pode originar resistência aos mesmos. Percebido que realmente existe resistência por parte dos colaboradores, a terceira questão de pesquisa pretendia perceber que impactos é que isso poderia ter nas organizações.

Relativamente aos impactos resultantes da resistência à IA, os entrevistados mostram dois pontos de vista distintos. Por um lado, muitos dos entrevistados desvalorizam a resistência à IA e afirmam que os resultados são insignificantes, por outro lado, outro grupo de entrevistados refere que a resistência à IA pode causar custos desnecessários às organizações e que isso poderá contribuir de uma forma negativa para a performance da organização.

7.2 Contribuição para a gestão empresarial

Atualmente a discussão em torno à IA é cada vez maior e mais abrangente, sendo cada vez mais os sectores e indústrias atentas ao que pode surgir com os sistemas inteligente. Este estudo pretende contribuir para a evolução da gestão empresarial trazendo para a discussão em torno da IA conhecimentos sobre a possibilidade de aplicar estas tecnologias na segmentação de clientes. Para tal foram abordados os principais fatores que influenciam a possibilidade de implementação da IA na segmentação de clientes, como as principais motivações, as características da IA que melhor servem a segmentação de clientes e as limitações que estes sistemas têm e que podem afetar a sua implementação, bem como os impactos que a IA poderá ter nos colaboradores e na performance das organizações.

Sendo todas as temáticas em torno da IA recentes, pouco exploradas e estudadas, este estudo também pretende contribuir para a literatura científica ao estudar com detalhe os impactos que a IA tem na segmentação de clientes, a sua possibilidade de implementação nessa temática e possíveis impactos nos colaboradores e na performance das organizações. Especificamente, este estudo aborda as características da IA que melhor servem a segmentação de clientes, as principais motivações para a sua implementação e as limitações. Explora ainda em que situações é que os humanos devem controlar e substituir estes algoritmos, bem como a existência de resistência contra a IA e os impactos na performance da organização que podem resultar.

No entanto é importante referir que é essencial que se continue a fazer estudos sobre esta temática, de forma a ser possível aprofundar o conhecimento sobre estas áreas e assim compreender com mais detalhe todas as implicações que a IA poderá trazer à segmentação de clientes.

7.3 Limitações do estudo

Para a realização do presente estudo, o tamanho da amostra (inquiridos e entrevistados) foi reduzido, tendo sido a principal limitação do mesmo. Apesar de o presente estudo ter comprovado a literatura existente sobre o tema, é preciso ter prudência na generalização dos resultados concluídos com o questionário e entrevistas. É também importante referir que é um estudo exploratório e que não pode ser generalizado ou representativo, muito devido à reduzida amostra do estudo.

7.4 Sugestões para futuras investigações

A primeira sugestão a ser dada vai de encontro da principal limitação do estudo, considerando que seria proveitoso levar esta temática a uma amostra consideravelmente maior. Outra sugestão seria a de transportar este tema para mercados e sectores de atividade mais específicos, uma vez que seria bastante interessante perceber se existem variações entre diferentes mercados e sectores de atividade.

Por fim, a última sugestão prende-se com uma das limitações da IA identificadas na literatura. Já se fala na possibilidade da IA produzir conceitos preconceituosos e tendenciosos nas áreas como o direito, no entanto seria extremamente interessante perceber com detalhe quais as implicações que este tipo de *outputs* podem ter numa campanha de Marketing.

Bibliografia

- Anderson, J., & Gerbing, D. (1988). Structural equation modeling in practice: A review and recommended two-step approach. *Psychological Bulletin*, 103(3), 411–423. doi:<https://doi.org/10.1037/0033-2909.103.3.411>
- Angwin, J., Larson, J., Mattu, S., & Kirchner, L. (23 de Maio de 2016). *Machine Bias: There's software used across the country to predict future criminals. And it's biased against blacks*. Obtido de ProPublica: <https://www.propublica.org/article/machine-bias-risk-assessments-in-criminal-sentencing>
- Armstrong, S., Sandberg, A., & Bostrom, N. (2012). Thinking Inside the Box: Controlling and Using an Oracle AI. *Minds and Machines*(22), 299–324. doi:10.1007/s11023-012-9282-2
- Aslam, S. (2020). *Instagram by the Numbers: Stats, Demographics & Fun Facts*. Obtido em 12 de Julho de 2020, de Omnicore: <https://www.omnicoreagency.com/instagram-statistics/>
- Bagozzi, R., & Yi, Y. (1998). On the evaluation of structural equation models. *Journal of the Academy of Marketing Science*(16), 74–94. doi:<https://doi.org/10.1007/BF02723327>
- Bainbridge, L. (1983). Ironies of Automation. *19*(6), pp. 775-779.
- Bardin, L. (1977). *Análise de Conteúdo*. Lisboa: Edições 70.
- Bertsekas, D. P. (2012). *Dynamic Programming and Optimal Control*. Athena Scientific.
- Bhattacharjee, A. (2012). *Social Science Research: Principles, Methods, and Practices*. Obtido de https://scholarcommons.usf.edu/cgi/viewcontent.cgi?article=1002&context=oa_textbooks
- Bolukbasi, T., Chang, K.-W., Zou, J., Saligrama, V., & Kalai, A. (2016). Man is to Computer Programmer as Woman is to Homemaker? Debiasing Word Embeddings. *30th Conference on Neural Information Processing Systems*.
- Borek, A., Parlikad, A., Webb, J., & Woodall, P. (2014). Software Tools. Em *Total Information Risk Management* (pp. 237-269). Morgan Kaufmann. doi:<https://doi.org/10.1016/C2012-0-00446-2>
- Brownlee, J. (2019). *Master Machine Learning Algorithms: Discover How They Work and Implement Them From Scratch* (Vol. 1). Machine Learning Mastery.
- Cannella, J. (2018). *Dissertação sobre: Artificial Intelligence in Marketing*. Arizona State University.
- Capelo, A. M. (2019). *Dissertação sobre: O Impacto da Inteligência Artificial na Gestão Comercial*.
- Carmo, H., & Ferreira, M. (2008). *Metodologia da Investigação: Guia para Autoaprendizagem*. Obtido de https://www.academia.edu/17585183/Metodologia_da_Investiga%C3%A7%C3%A3o
- Cohen, L., Manion, L., & Morrison, K. (2007). *Research Methods in Education*.
- Cool, B., Aksov, L., & Keiningham, T. (2007). Approaches to Customer Segmentation. *Journal of Relationship Marketing*.
- Costa, E. J. (2009). Inteligência artificial aplicada à Zootecnia. *38*, pp. 390-396.
- Data Science Academy*. (2019). Obtido em 21 de Julho de 2020, de Deep Learning Book: <http://deeplearningbook.com.br/o-que-sao-redes-neurais-artificiais-profundas/>
- 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*. Obtido de <https://doi.org/10.1016/j.intmar.2020.04.007>
- Dimitrieska, S., Stankovska, A., & Efremova, T. (2018). ARTIFICIAL INTELLIGENCE AND MARKETING. *7*(2), pp. 298-304.
- Dornelles, E., Kraisig, A., Silva, J., Sawicki, S., Roos-Frantz, F., & Carbonera, R. (2018). Artificial intelligence in seeding density optimization and yield simulation for oat. *22*(3), pp. 183-188.
- Dunjko, V., & Briegel, H. (2017). Machine learning & artificial intelligence in the quantum domain. *81*(7).
- El-Sheikh, A., Abonazel, M., & Gamil, N. (2017). A Review of Software Packages for Structural Equation Modeling: A Comparative Study. *Applied Mathematics and Physics*, 5(3), 85-94. doi:10.12691/amp-5-3-2
- Evans, M. (2003). Market Segmentation. Em *The Marketing Book*. Butterworth-Heinemann.

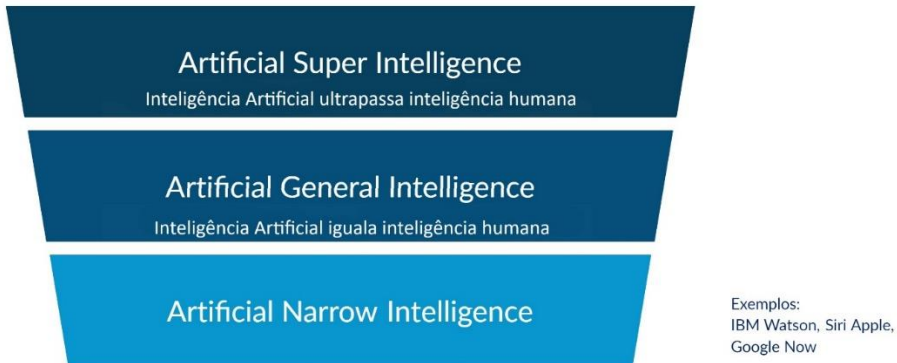
- Falk, F., & Miller, N. (1992). *A primer for soft modeling*. University of Akron Press.
- Fornell, C., & Larcker, D. (1981). Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research*, 18(1), 39-50. doi:<https://doi.org/10.1177/002224378101800104>
- Forsyth, D., & Ponce, J. (2011). *Computer Vision: A Modern Approach*. Prentice Hall.
- Fontaine, T., McCarthy, B., & Saleh, T. (2019). Building the AI-Powered Organization. *Harvard Business Review*.
- Ge, M., Bangui, H., & Buhnova, B. (2018). Big data for internet of things: A survey. doi:<https://doi.org/10.1016/j.future.2018.04.053>
- Gönül, F., & Ter Hofstede, F. (2006). How to Compute Optimal Catalog Mailing Decisions. *Marketing Science*, 65-74. doi:10.1287/mksc.1050.0136
- Gross, S., Possley, M., & Stephens, K. (2017). *RACE AND WRONGFUL CONVICTIONS IN THE UNITED STATES*. National Registry of Exonerations, Newkirk Center for Science and Society. California: University of California Irvine.
- Gunkel, D. J. (2017). Comunicação e Inteligência Artificial: novos desafios e oportunidades para a pesquisa em comunicação. (33), pp. 5-19.
- Hair, J., Hult, G., Ringle, C., & Sarstedt, M. (2017). *A primer on partial least squares structural equation modeling*. Sage Publication.
- Haque, A., Fernando, M., & Caputi, P. (2019). The Relationship Between Responsible Leadership and Organisational Commitment and the Mediating Effect of Employee Turnover Intentions: An Empirical Study with Australian Employees. *Journal of Business Ethics*, 156(3), 759–774. doi:10.1007/S10551-017-3575-6
- Harvard Law Review*. (Março de 2017). Obtido de Wisconsin Supreme Court Requires Warning Before Use of Algorithmic Risk Assessments in Sentencing: <https://harvardlawreview.org/2017/03/state-v-loomis/>
- Henseler, J., Ringle, C., & Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*(43), 115–135. doi:<https://doi.org/10.1007/s11747-014-0403-8>
- Hosseini, M., & Shabani, M. (Setembro de 2015). New approach to customer segmentation based on changes in customer value. *Journal of Marketing Analytics*. doi:10.1057
- Hughes, A. (1994). *Strategic Database Marketing*. Chicago: Probus Publishing.
- Hwang, H., Jung, T., & Suh, E. (2004). An LTV model and customer segmentation based on customer value: a case study on the wireless telecommunication industry. *Expert Systems with Applications*, 181-188.
- Kaufman, L., & Rousseeuw, P. (1990). *Finding Groups in Data: An Introduction to Cluster Analysis*. New York: John Wiley & Sons.
- Kietzmann, J., Paschen, J., & Treen, E. R. (Setembro de 2018). Artificial Intelligence in Advertising: How marketers can leverage Artificial Intelligence along the consumer journey. *Journal of Advertising Research*. doi:10.2501/JAR-2018-035
- Kotler, P., & Armstrong, G. (1999). *Principles of Marketing*. Prentice Hall.
- Kotler, P. (2001). *Marketing Management* (10 ed.). Pearson Education.
- Kotler, P. (2002). *Marketing Management Millenium Edition*. Pearson Custom Publishing.
- Kotler, P., Kartajaya, H., & Setiawan, I. (2017). *Marketing 4.0: Mudança do tradicional para o digital*. Actual editora.
- Kuberski, W. (2020). Bringing real value to enterprises with AI. ISCTE AI Business hub.
- Liu, N., Lee, M. A., Ho, A. F., Haaland, B., Fook-Chong, S., Koh, Z. X., . . . Ong, M. E. (2014). Risk stratification for prediction of adverse coronary events in emergency department chest pain patients with a machine learning score compared with the TIMI score. *International journal of cardiology*, 177(3), 1095-1097. doi:<https://doi.org/10.1016/j.ijcard.2014.09.199>
- Lobo, L. C. (2017). Inteligência Artificial e Medicina. *Revista Brasileira de Educação Médica*, 41(2), 185-193.

- Manogaran, G., Thota, C., Lopez, D., Vijayakumar, V., Abbas, K., & Sundarsekar, R. (2017). Big Data Knowledge System in Healthcare.
- Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C., & Byers, A. H. (2011). *Big data: The next frontier for innovation, competition and productivity*. McKinsey Global Institute.
- Marcus, C. (1998). A practical yet meaningful approach to customer segmentation. *JOURNAL OF CONSUMER MARKETING*, 15(5), 494 - 504.
- Martin, G. (Junho de 2011). The Importance Of Marketing Segmentation. *American Journal of Business Education*, 4(6).
- McGrath, P., Desai, K., & Junquera, P. (Setembro de 2019). Resistance is futile: How corporate real estate companies can deploy artificial intelligence as a competitive advantage. *Corporate Real Estate Journal*, 9(2).
- Mesquita, C. T. (2017). Inteligência Artificial e Machine Learning em Cardiologia – Uma Mudança de Paradigma. *International Journal of Cardiovascular Sciences*, 30(3), 187-188.
- Mitchell, T. M. (2006). *The Discipline of Machine Learning*. Carnegie Mellon University.
- Monteiro, A. L. (2019). Dissertação sobre: Machine learning no processo de risco de crédito das instituições bancárias. (ISCTE-IUL, Ed.)
- Moutinho, L., & Meidan, A. (2003). Quantitative methods in Marketing. Em *The Marketing Book*. Butterworth-Heinemann.
- Naimat, A. (2016). *New Artificial Intelligence Market*. O'Reilly.
- Natter, M. (1999). Conditional market segmentation by neural networks: a Monte-Carlo study. *Journal of Retailing and Consumer Services*, 6, 237-248.
- Natter, M., Reutterer, T., Mild, A., & Taudes, A. (2007). Practice Prize Report—An Assortmentwide Decision Support System for Dynamic Pricing and Promotion Planning in DIY Retailing. *Marketing Science*, 576-583. Obtido de <https://doi.org/10.1287/mksc.1060.0217>
- Prodanov, C. C., & Freitas, E. C. (2013). *Metodologia do Trabalho Científico: Métodos e Técnicas da Pesquisa e do Trabalho Acadêmico* (2ª ed.). Editora Feevale.
- Purdy, M., & Daugherty, P. (2017). *HOW AI BOOSTS INDUSTRY PROFITS AND INNOVATION*. Accenture.
- Raykov, T., & Marcoulides, G. (2000). A first course in structural equation modeling.
- Raykov, T., & Marcoulides, G. (2006). On Multilevel Model Reliability Estimation From the Perspective of Structural Equation Modeling. *A Multidisciplinary Journal*, 13(1), 130-141.
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). "Why Should I Trust You?" Explaining the Predictions of Any Classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 1135–1144.
- Ringle, C., Wende, S., & Will, A. (2015). SmartPLS3.0.
- Roddick, J., & Spiliopoulou, M. (2002). A Survey of Temporal Knowledge Discovery Paradigms and Methods. *IEEE TRANSACTIONS ON KNOWLEDGE AND DATA ENGINEERING*, 14(4).
- Russell, S. (2019). *Human Compatible: Artificial Intelligence and the Problem of Control*. Viking Press.
- Santos, J. A. (2011). Segmentação de Clientes com Características Específicas Adequadas às Necessidades do Mercado.
- Saunders, M., Lewis, P., & Thornhill, A. (2016). *Research Methods for Business Students*.
- Schultz, E. (19 de Janeiro de 2017). *HOW TOYOTA USED ARTIFICIAL INTELLIGENCE FOR RAV4 CAMPAIGN*. Obtido em 10 de Agosto de 2020, de Adage: <https://adage.com/article/digital/toyota-artificial-intelligence-rav4-campaign/307544>
- Sibata, K. T. (2017). Segmentação de clientes de uma empresa de modelo de assinatura através da análise de clusters.
- Simon, H. A., & Newell, A. (1972). Human problem solving. p. 321.
- Smolensky, P. (1990). Tensor product variable binding and the representation of symbolic structures in connectionist systems. 46, pp. 159-215.
- Song, H. S., Kim, J. K., & Kim, S. H. (2001). Expert Systems with Applications. *Mining the change of customer behavior in an internet shopping mall*.
- Sutton, R., & Barto, A. (2018). *Reinforcement Learning: An Introduction*. (M. p. Ltd, Ed.)

- Tajik, A. J. (2016). Machine Learning for Echocardiographic Imaging: Embarking on Another Incredible Journey. *JOURNAL OF THE AMERICAN COLLEGE OF CARDIOLOGY*, 68(21).
- Tan, P.-N., Steinbach, M., & Kumar, V. (2006). *Introduction to Data Mining*. Pearson Addison-Wesley.
- Tarka, P. (2018). An overview of structural equation modeling: its beginnings, historical development, usefulness and controversies in the social sciences. 52(1), 313–354. doi:<https://doi.org/10.1007/s11135-017-0469-8>
- Tarski, A. (1977). *Introducción a la Lógica y a la Metodología de las Ciencias*.
- Tjepkema, L. (Outubro de 2017). *What Is Artificial Intelligence Marketing & Why Is It So Powerful?* Obtido de Emarsys: <https://emarsys.com/learn/blog/artificial-intelligence-Marketing-solutions/>
- Vergara, S. (2006). *Projetos e Relatórios de Pesquisa em Administração*.
- Verhoef, P., Spring, P., Hoekstra, J., & Leeflang, P. (2002). The commercial use of segmentation and predictive modeling techniques for database Marketing in the Netherlands. *Decision Support Systems*, 471-481.
- Vicente, P., & Cardoso, M. (2019). *Texto policriado da Unidade Curricular, Análise de Dados*. Lisboa: ISCTE-IUL.
- Vilelas, J. (2020). *Investigação: O Processo de Construção do Conhecimento*.
- Vishnoi, S. K., & Bagga, T. (2019). Artificial Intelligence enabled Marketing solutions. *Indian Journal of Economics and Business*. Obtido de <https://www.researchgate.net/publication/334626027>
- Wei, J.-T., Lin, S.-Y., & Wu, H.-H. (2010). A review of the application of RFM model. *African Journal of Business Management*, 4199–4206.
- Yan, R., LV, Y., Kong, Q., & Song, G. (2019). Percussion-based bolt looseness monitoring using intrinsic multiscale entropy analysis and BP neural network. *Smart Materials and Structures*.
- Yan, X.-B., & Li, Y.-J. (2006). Customer Segmentation based on Neural Network with Clustering Technique. *Proceedings of the 5th Int. Conf. on Artificial Intelligence* (pp. 265-268). Madrid: Knowledge Engineering and Data Bases.


Anexos

Anexo A - Níveis de Inteligência Artificial




Fonte: Elaboração própria

Anexo B - Componentes da Inteligência Artificial



Fonte: Elaboração própria

Anexo C - Rede Neural Simples e Rede Neural Profunda



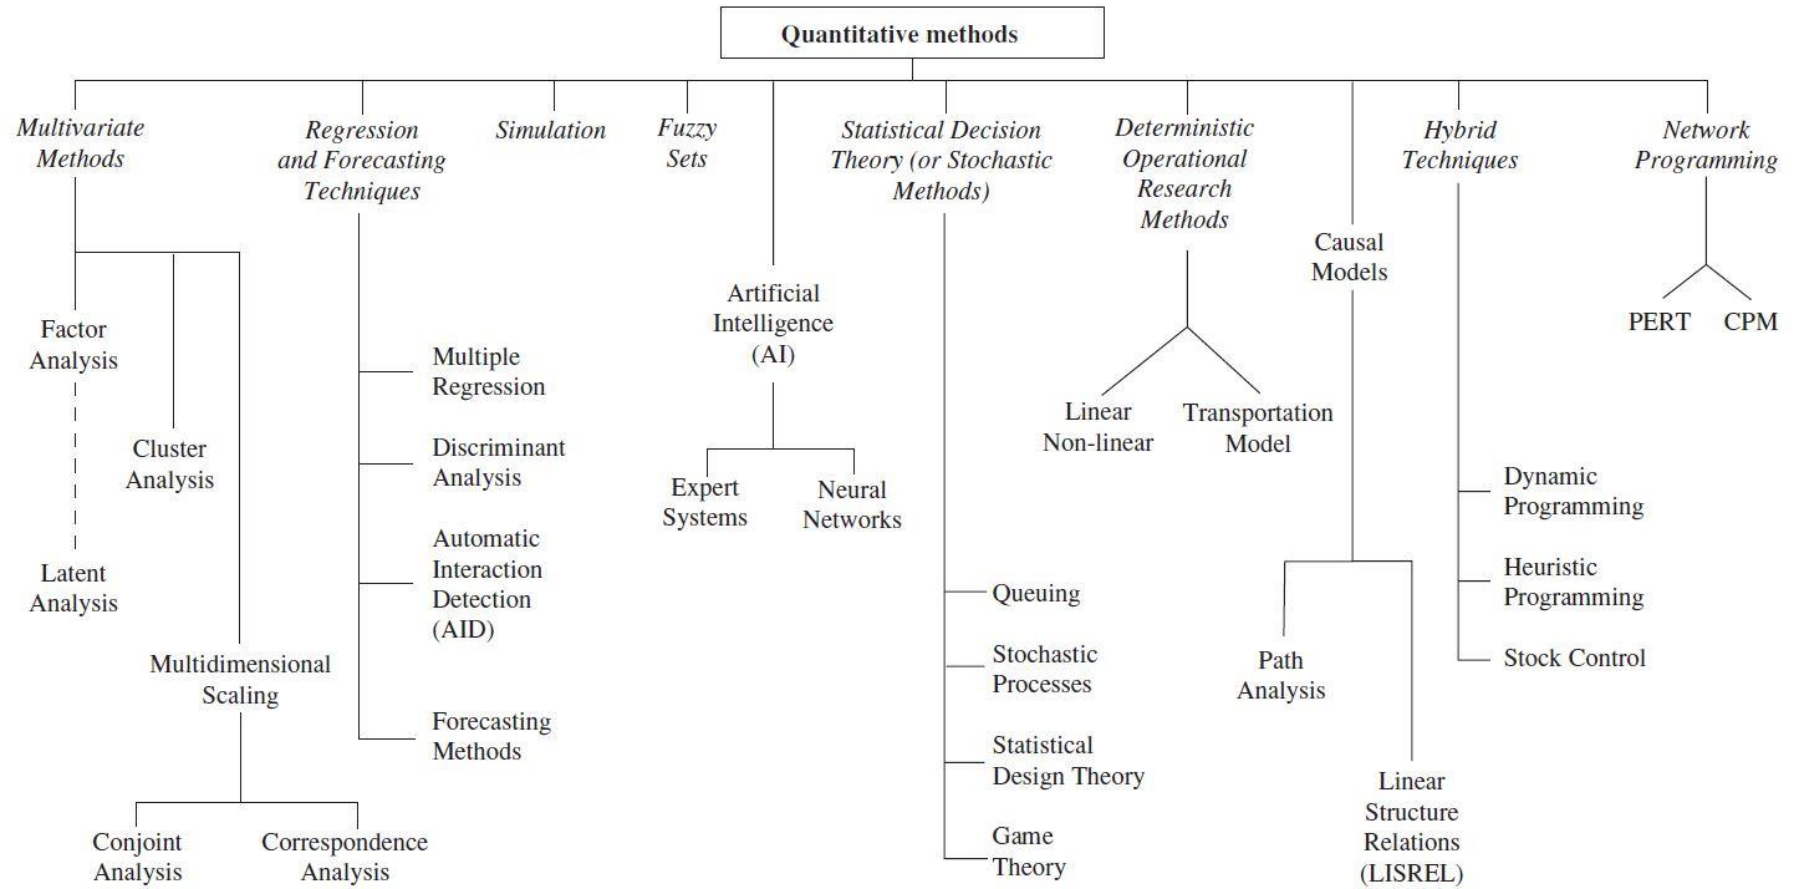
Fonte: (Data Science Academy, 2019)

Anexo D - Principais variáveis de segmentação.

Geographic	
Region	Pacific, Mountain, West North Central, West South Central, East North Central, East South Central, South Atlantic, Middle Atlantic, New England
City or metro size	Under 4,999; 5,000–19,999; 20,000–49,999; 50,000–99,999; 100,000–249,999; 250,000–499,999; 500,000–999,999; 1,000,000–3,999,999; 4,000,000 or over
Density	Urban, suburban, rural
Climate	Northern, southern
Demographic	
Age	Under 6, 6–11, 12–19, 20–34, 35–49, 50–64, 65+
Family Size	1–2, 3–4, 5+
Family life cycle	Young, single; young, married, no children; young, married, youngest child under 6; young, married, youngest child 6 or over; older, married, with children; older, married, no children under 18; older, single; other
Gender	Male, female
Income	Under \$9,999; \$10,000–\$14,999; \$15,000–\$19,999; \$20,000–\$29,999; \$30,000–\$49,999; \$50,000–\$99,999; \$100,000 and over
Occupation	Professional and technical; managers, officials, and proprietors; clerical, sales; craftspeople; forepersons; operatives; farmers; retired; students; homemakers; unemployed
Education	Grade school or less; some high school; high school graduate; some college; college graduate
Religion	Catholic, Protestant, Jewish, Muslim, Hindu, other
Race	White, Black, Asian, Hispanic
Generation	Baby boomers, Generation Xers
Nationality	North American, South American, British, French, German, Italian, Japanese
Social class	Lower lowers, upper lowers, working class, middle class, upper middles, lower uppers, upper uppers
Psychographic	
Lifestyle	Straights, swingers, longhairs
Personality	Compulsive, gregarious, authoritarian, ambitious
Behavioral	
Occasions	Regular occasion, special occasion
Benefits	Quality, service, economy, speed
User status	Nonuser, ex-user, potential user, first-time user, regular user
Usage rate	Light user, medium user, heavy user
Loyalty status	None, medium, strong, absolute
Readiness stage	Unaware, aware, informed, interested, desirous, intending to buy
Attitude toward product	Enthusiastic, positive, indifferent, negative, hostile

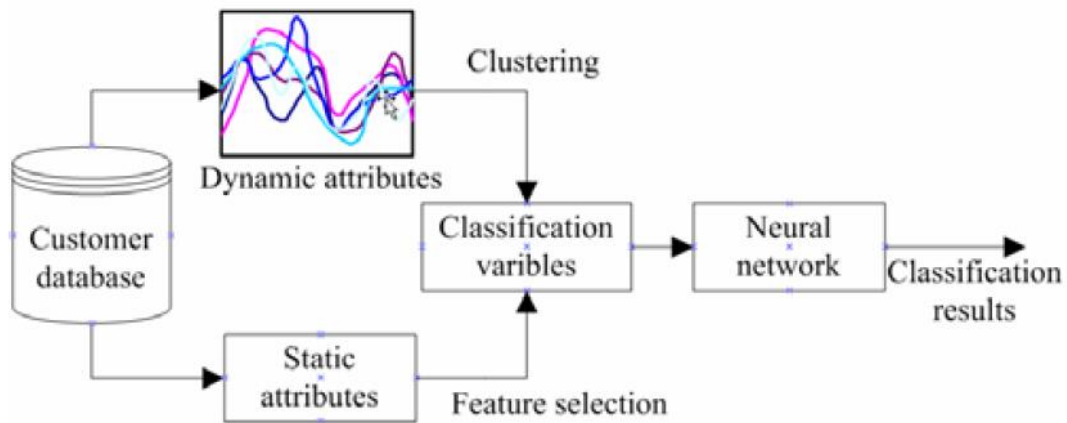
Fonte: (Kotler, *Marketing Management Millenium Edition*, 2002)

Anexo E - Principais métodos quantitativos no Marketing



Fonte: (Moutinho & Meidan, 2003)

Anexo F - Método de segmentação de clientes com base em redes neurais artificiais



Fonte: (Yan & Li, 2006)

Anexo G – Estrutura do questionário online

1 - In which area of work are you in?

- Marketing
- Artificial Intelligence
- Both
- None

2 - Please rate the following motivations on a scale of 1 to 5, where 1 means being a weaker motivation and 5 being a stronger motivation for a company to implement intelligent systems in customer segmentation.

- Analyze and discover patterns of behavior
- Improve the perception of customers' needs and desires
- Create customer segments with more variables, therefore more complete
- Create customer segments faster
- Create customer segments more efficiently
- Create customer segments in a successful way

3 - According to Kietzmann, Paschen, & Treen (2018), image and voice recognition, problem-solving and reasoning skills are essential to optimize customer segmentation using AI. Using a scale of 1 to 5, where 1 means not important and 5 very important, how would you rate the importance of the characteristics identified to improve customer segmentation?

- Image recognition
- Voice recognition

- Problem-solving skills
- Reasoning skills

4 - Please rate the following AI challenges, that can be limitations in customer segmentation, on a scale of 1 to 5, knowing that 1 means not being a limitation and 5 being a big limitation.

- Lack of common sense
- Difficulty in specifying an holistic objective function
- Complexity to create a safe and realistic environment for AI learning
- Possibility of making biased and prejudiced judgments
- A constant need to understand the AI decision
- The need to control intelligent systems

5 - Taking into account all your previous answers and the next 1 to 5 scale, where 1 means unlikely and 5 means very likely, what is the probability for a company to implement AI for customer segmentation?

6 – Gender

- Male
- Female

7 – Age

- Under 18 years old
- Between 18 and 25 years old
- Between 26 and 35 years old
- Between 36 and 45 years old
- Between 46 and 55 years old
- Between 56 and 65 years old
- More than 65 years old

8 - Education level

- Primary school
- High school
- Undergraduate degree
- Bachelor degree

- Master degree
- Phd

9- Years of professional experience

- Less than 5 years
- Between 5 and 10 years
- Between 11 and 15 years
- More than 15 years

Anexo H– Guião da entrevista

1 - Em que situações, relacionadas com o Marketing, é que os sistemas inteligentes devem ser controlados e substituídos por humanos?

2 - Pode existir resistência dos colaboradores na implementação de sistemas inteligentes? Que impactos poderá essa resistência vir a ter na performance da organização?