

iscte

INSTITUTO
UNIVERSITÁRIO
DE LISBOA

O impacto da inteligência artificial na área da saúde

Mário Jorge Estêvão Pereira

Mestrado em Gestão de Empresas

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

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

Março, 2022



BUSINESS
SCHOOL

O impacto da inteligência artificial na área da saúde

Mário Jorge Estêvão Pereira

Mestrado em Gestão de Empresas

Orientadores:

Doutor Renato Jorge Lopes da Costa, Professor

Auxiliar,

ISCTE-IUL

Doutor Rui Alexandre Henriques Gonçalves,

Professor Auxiliar Convidado,

ISCTE-IUL

Março, 2022

Agradecimentos

Aos meus professores, por toda a ajuda;

À minha família e, em especial aos meus pais, por todo o apoio;

Aos meus amigos e, em especial à minha namorada, por toda a paciência:

Obrigado.

Resumo

Nos últimos anos, os projetos de Inteligência Artificial na área da saúde têm atraído mais investimento do que qualquer outro setor da economia. Esse investimento tem impulsionado o desenvolvimento de ferramentas com capacidade de auxiliar profissionais de saúde e gestores na tomada de decisão em várias vertentes de atuação, nomeadamente, na vertente que envolve a prática clínica e na vertente que envolve o processo de gestão.

A investigação desenvolvida pretende perceber quais são os fatores que impulsionam e condicionam o processo de implementação desses sistemas por parte de profissionais e gestores de saúde.

Para obter conclusões relevantes foi realizada uma extensa revisão de literatura, assim como uma análise estatística dos questionários *online*, com recurso à ferramenta *SmartPLS 3*. Os resultados obtidos demonstraram que o grau de conhecimento e os benefícios gerados pelos sistemas inteligentes favorecem a intenção de implementar essas ferramentas, suportando a maioria das hipóteses formuladas. Adicionalmente e contrariamente ao expectável, foi possível verificar que os desafios não representam uma ameaça para esses mesmos profissionais durante o processo de adoção de ferramentas de Inteligência Artificial.

Com a investigação foi possível concluir que seria importante melhorar a integração da Inteligência Artificial na carreira dos profissionais ligados à área da saúde. Segundos os autores encontrados quanto maior for o nível de conhecimento sobre sistemas inteligentes, maior é a intenção de aplicar esses sistemas. Nesse sentido, devem ser tomadas algumas medidas para que esses profissionais entendam melhor o modo de funcionamento dos algoritmos que sustentam as ferramentas de Inteligência Artificial.

Palavras-chaves:

Gestão; Saúde; Inteligência Artificial

Classificação JEL:

I10 Saúde Geral; O32 Gestão de Inovação Tecnológica e P&D

Abstract

In recent years, Artificial Intelligence health projects have attracted more investment than any other sector of the economy. This investment has driven the development of tools with the capacity to assist health professionals and managers in decision-making in various aspects of action, namely, in the aspect that involves clinical practice and in the aspect that involves the management process.

The research developed aims to understand what are the main factors that condition the process of implementation of these systems by health professionals and managers. To obtain relevant conclusions, an extensive literature review was carried out, as well as a statistical analysis of online questionnaires, using the SmartPLS 3 tool.

The results showed that the degree of knowledge and the benefits generated by intelligent systems favor the intention to implement these tools, supporting most of the hypotheses formulated. Additionally, and contrary to what is expected, it was possible to verify that the challenges do not pose a threat to these same professionals during the process of adoption of Artificial Intelligence tools.

With the investigation it was possible to conclude that it would be important to improve the integration of Artificial Intelligence in the career of professionals related to health. According to the authors found the higher the level of knowledge about intelligent systems, the greater the intention to apply these systems. In this sense, some measures should be taken to better understand the way the algorithms that support Artificial Intelligence tools work.

Keywords:

Management; Health; Artificial Intelligence

JEL Classifications:

I10 Health: General; O32 Management of Technological Innovation and R&D:

Índice Geral

Capítulo 1 - Introdução	1
1.1 Enquadramento	1
1.2 Problemática de Investigação	2
1.3 Objetivos de investigação	2
1.4 Estrutura da dissertação	3
Capítulo 2 - Inteligência Artificial aplicada à área da Saúde	4
2.1 Aplicações Práticas de IA na área da Saúde	4
2.1.1 Aplicações práticas de sistemas de IA na área clínica	12
2.1.2 Aplicações práticas de sistemas de IA na área da Gestão de Saúde.....	15
2.2 Desafios à implementação de sistemas de IA na área da Saúde	20
Capítulo 3 - Metodologia	24
3.1 Modelo de Investigação	26
3.2 Caracterização da amostra	33
Capítulo 4 - Apresentação e discussão dos resultados	35
4.1 Apresentação dos resultados	35
4.2 Discussão dos resultados	39
Capítulo 5 - Conclusão	44
5.1 Considerações finais	44
5.2 Contribuição para a área da Saúde	45
5.2 Limitações do estudo	46
5.4 Contribuições para futuras investigações	46
Bibliografia	47
Anexo	53

Índice de Figuras

Figura 2.1.1: Principais Conceitos Inteligência Artificial	5
Figura 2.1.2: Diferentes tipos de <i>Machine Learning</i>	7
Figura 2.1.3: Manipulação e Preparação dos Dados	9
Figura 2.1.4: Diferentes Tipos de Redes Neurais	10
Figura 3.1: Modelo de investigação	24
Figura 3.1.1: Modelo conceptual e hipóteses a testar com o <i>SmartPLS 3</i>	29
Figura 3.2.1: Caracterização da Amostra	33
Figura 3.2.2: Distribuição dos Profissionais de Saúde	34
Figura 3.2.3: Distribuição dos Gestores de Saúde	34
Figura 4.2.1: Modelo conceptual testado com o <i>SmartPLS 3</i> com valores associados	40

Índice de Tabelas

Tabela 3.1: Relação entre revisão da literatura, questão de pesquisa e metodologia	25
Tabela 3.1.1: Relação entre as variáveis do modelo conceptual e as perguntas do questionário	30
Tabela 4.1.1: Verificações de CR, AVE, correlações e validade discriminante	35
Tabela 4.1.2: Relações diretas	37
Tabela 4.1.3: Relações indiretas	38
Tabela 4.1.4: Teste de Hipóteses	39

Lista de Abreviaturas

IA - Inteligência Artificial

ML - *machine learning*

DL - *deep learning*

SNS - Serviço Nacional de Saúde

NLP - *natural language processing*

ANN - *artificial neural networks*

DNN - *deep neural networks*

FDA - *US Food and Drug Administration*

SEM - *Structural Equations Modeling*

PA - *Path Analysis*

CFA - *Confirmatory Factor Analysis*

PLS-SEM - *Partial Least Squares*

PL - *Path Model*

CA - Alfa de *Cronbach*

CR - Confiabilidade composta

AVE - Variância média extraída

HTMT - Rácio *heterotrait-monotrait*

Capítulo 1 – Introdução

1.1 Enquadramento

A IA e o *machine learning* têm provocado um grande impacto na maioria das áreas da sociedade moderna, desde o entretenimento, ao comércio, até à área da saúde. Todos estes dados podem ser utilizados para prever determinados comportamentos da sociedade (Reis *et al.*, 2020). Na área da saúde existe um grande potencial por parte deste tipo de ferramentas em que é possível prever tendências e comportamentos com o propósito de melhorar a capacidade de resposta dada pelos profissionais e gestores de unidades de saúde (Jiang *et al.*, 2017).

São vários os estudos que comprovam que os algoritmos de Inteligência Artificial (IA) podem traduzir-se num acréscimo de valor para as várias unidades de saúde (Nelson *et al.*, 2020). A AI pretende contribuir de forma ativa para a melhoria da prestação de cuidados, como por exemplo, através da análise de imagens médicas, através da correlação de sintomas que permitam caracterizar e realizar um prognóstico em relação a uma determinada patologia, através da previsão do nível de procura de um determinado serviço ou através da melhoria dos processos de gestão inerente a uma unidade de saúde (Bohr & Memarzadeh, 2020).

A procura por cuidados de saúde têm vindo a aumentar e foi particularmente agravada pela crise pandémica, COVID-19. Nesse sentido, são vários os países que se têm deparado com a falta de profissionais de saúde e que lutam diariamente contra a escassez de recursos e contra a falta de medidas adaptativas face a esta nova realidade (Liu *et al.*, 2021). O ecossistema *healthcare* está cada vez mais consciente da importância que as ferramentas de IA podem vir a ter nas gerações futuras. Para além da melhoria em termos de desempenho, estima-se que a IA poderá ter um enorme impacto na redução de custos com menos hospitalizações, menos visitas médicas e menos tratamentos (Eigner *et al.*, 2019).

Durante o período de investigação foram considerados três fatores principais: A perceção e conhecimento, os benefícios e os desafios associados à implementação de sistemas inteligentes.

A principal motivação para o desenvolvimento da investigação deveu-se à necessidade de entender de que forma os profissionais e gestores de saúde portugueses perspetivam a implementação de ferramentas de IA (Asan *et al.*, 2020). Entender quais as principais motivações e preocupações dos profissionais e gestores de saúde é fulcral para perceber de que forma se deve atuar para potenciar a implementação desses sistemas ao longo dos próximos anos.

1.2 Problemática da investigação

O número crescente de desafios com que se deparam as instituições de saúde têm vindo a aumentar. A crise pandémica veio colocar enormes desafios em termos de capacidade de resposta do SNS. Torna-se por isso necessário reformular a estratégia de ação e encontrar formas inovadoras de fazer frente às diferentes fragilidades (Conselho das Finanças Públicas, 2020).

Apesar de serem reconhecidos os vários benefícios associados à implementação de ferramentas de IA, são várias as razões que levam ao insucesso da implementação das mesmas (Gerke, Minssen & Cohen, 2020). De acordo com Panch, Mattie e Celi (2019), as principais causa de insucesso devem-se a vários fatores como, a complexidade dos algoritmos de IA, a integridade e qualidade dos dados armazenados, o nível de confiança dos profissionais de saúde, o nível de perceção e aceitação dos utentes, a confiabilidade dos utentes, a violação de questões éticas e de privacidade, a responsabilidade legal, o propósito da adoção dessas ferramentas e a atitude de estudantes de medicina face a estas novas tecnologias. Para que seja possível contribuir para o processo de implementação destes sistemas é necessário perceber quais os fatores que contribuem maioritariamente para o insucesso da adoção da IA na área da saúde. Nesse sentido, o estudo pretende entender de que forma os profissionais e gestores de saúde encaram o desafio de integrar ferramentas de IA (Benke, K., & Benke, G., 2018).

A investigação apresenta na sua revisão de literatura vários artigos que exemplificam de que forma as instituições recorrem a sistemas de IA. O principal problema identificado está associado à falta de conhecimentos sobre IA por parte dos profissionais e gestores de saúde (Chan & Zary, 2019).

1.3 Objetivos de investigação

O estudo realizado pretende contribuir para o desenvolvimento científico da IA na área da saúde. Dessa forma, o intuito será dar a conhecer algumas dessas ferramentas a profissionais de saúde e gestores portugueses para que os mesmos se possam interessar cada vez mais pela temática.

Com o intuito de cumprir o propósito referido, foi definido o seguinte objetivo: Perceber quais os fatores que influenciam a possibilidade de aplicar sistemas inteligentes na área da saúde. Nesse sentido, será possível identificar quais os fatores que favorecem ou não, a

intencionalidade de implementar este tipo de sistemas em contexto.

1.4 Estrutura da dissertação

A presente investigação encontra-se dividida em 5 capítulos. Cada um desses capítulos tem um propósito específico que será devidamente explicado. Na introdução que consta no capítulo 1, é descrito o enquadramento, a problemática de investigação e os objetivos da mesma.

O capítulo 2 inicia com a revisão da literatura e encontra-se dividido em duas partes. A primeira parte tem como objetivo global explicar alguns conceitos relacionados com Inteligência Artificial, nomeadamente, *machine learning*, *deep learning* e *artificial neural networks*. A segunda parte do capítulo é composta por dois subcapítulos com uma abordagem mais prática. Um subcapítulo que procura demonstrar de que forma é possível recorrer a ferramentas de IA e com isso causar um impacto positivo nas tarefas desempenhadas por profissionais e gestores de saúde, e um subcapítulo que evidencia quais os desafios que são necessários ultrapassar para facilitar o processo de implementação de sistemas inteligentes.

O capítulo 3 é dedicado à metodologia, onde se destaca a questão de pesquisa que resultou da revisão da literatura e que vai servir de base para a investigação, bem como a descrição da amostra. Através de uma metodologia quantitativa e com o recurso à ferramenta *SmartPLS 3* o modelo em causa procura testar várias hipóteses com efeitos diretos e indiretos, cujo objetivo final passa por dar resposta à questão de pesquisa formulada.

No capítulo 4 são apresentados os resultados obtidos e é realizada a respetiva discussão dos mesmos. Neste capítulo, os autores são evidenciados com o intuito de sustentar os resultados obtidos. O objetivo passa por comparar opiniões e, dessa forma, aprofundar conhecimentos sobre a temática de investigação.

Por fim, o capítulo 5 é constituído pela conclusão, onde são feitas as considerações finais do estudo, a contribuição que o estudo teve para área da saúde, as limitações do mesmo e algumas sugestões para futuras investigações.

Capítulo 2 – Inteligência Artificial aplicada à área da Saúde

2.1 Aplicações Práticas de IA na área da Saúde

O Serviço Nacional de Saúde (SNS) é considerado uma das mais importantes conquistas da democracia portuguesa, promovendo ganhos significativos para a saúde dos portugueses, equidade no acesso a cuidados de saúde e coesão social. Dessa forma, é essencial continuar a zelar pelo funcionamento do mesmo, garantindo que o seu desempenho possa ser potenciado de acordo com as suas capacidades e valências (Ministério da Saúde e Serviço Nacional de Saúde, 2019).

Ao longo dos últimos 6 anos, a atividade assistencial do SNS gerou um aumento nos níveis de cuidados e com esse crescimento verificou-se também um crescimento da despesa do SNS de 0,5% em 2013 para 4,8% no ano de 2019 (Conselho das Finanças Públicas, 2020). Esta evidência sugere as dificuldades inerentes ao planeamento dos recursos financeiros necessários para o SNS e à implementação de políticas que visam a contenção da despesa nos limites orçamentais aprovados pela Assembleia da República (Conselho das Finanças Públicas, 2020). Apesar do crescimento da receita, que se deve em grande parte ao aumento de transferências do Orçamento de Estado para o SNS, o ritmo de crescimento da despesa coloca desafios de sustentabilidade financeira que importa ponderar no quadro da política orçamental e das políticas de saúde (Ministério da Saúde e Serviço Nacional de Saúde, 2019).

A manter-se este perfil de execução orçamental, o SNS necessitará de reformular a sua estratégia de ação e encontrar estratégias inovadoras que possam fazer frente às diferentes fragilidades financeiras e aos constrangimentos na capacidade de resposta do SNS face às solicitações com que se defronta. A crise pandémica veio expor de forma ainda mais premente essas debilidades e veio colocar a questão de saber se a pressão financeira será acompanhada de estabilidade e previsibilidade de recursos financeiros, de mecanismos de controlo da despesa e de concretização num quadro financeiro de racionalidade e rigor com medidas que visem acautelar a sua solidez financeira futura (Conselho das Finanças Públicas, 2020).

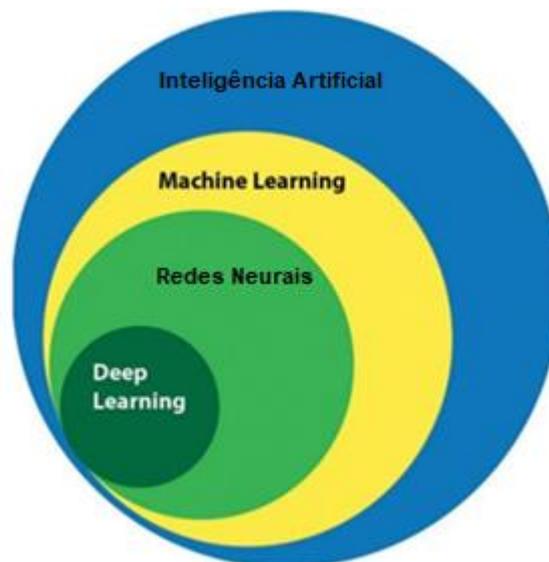
De acordo com Santos & Araújo, (2018) a sustentabilidade financeira na área da saúde está intrinsecamente ligada ao conceito de eficiência e neste sentido, tem havido um maior interesse em avaliar o desempenho das organizações de saúde de maneira a medir a eficiência no setor da saúde. De acordo com estes autores, a decisão prende-se, de uma forma geral, com a utilização de recursos para fazer face a um determinado problema de saúde em detrimento de utilizar esses mesmos recursos para solucionar outro tipo de problema. Atingir a eficiência

é, portanto, uma questão de comparar os custos com os benefícios e assegurar que os recursos são disponibilizados de forma a maximizar os ganhos em saúde para a sociedade.

Segundo Reis *et al.* (2020), são vários os projetos que procuram extrair o potencial de sistemas inteligentes em contexto nacional e com o objetivo de combater as dificuldades sentidas por parte de gestores e profissionais de saúde no desempenho das suas funções.

De acordo com Bohr e Memarzadeh (2020), as ferramentas de IA visam dar resposta a um conjunto de problemas, como a otimização de recursos, o auxílio na tomada de decisão clínica, a redução de tempos de serviço e a redução de custos. Segundo Bryant (2020), a IA irá aperfeiçoar o desempenho de determinadas tarefas, que vão desde o fluxo de trabalho administrativo, a gestão de documentos clínicos, o contato direto com o utente e a gestão da rede de cuidados especializados através da análise de imagens médicas, da automação de dispositivos médicos e da monitorização de utentes. Os avanços mais recentes ao nível de *hardware*, *software* e a crescente exigência de cuidados personalizados associados às necessidades urgentes da criação de valor para os utentes e instituições de saúde contribuíram para que a IA promovesse uma mudança de paradigma nas mais diversas áreas do conhecimento médico (Filho *et al.*, 2019). A crescente necessidade de apoiar a tomada de decisões e melhorar o desempenho de diagnósticos e prognósticos têm contribuído para o crescimento e desenvolvimento da IA na área da saúde (Gerke, Minssen & Cohen, 2020). O termo de IA surge, na maioria das vezes, associado a outros conceitos, nomeadamente, o conceito de *machine learning*, redes neurais e *deep learning*. Esses conceitos são suportados por diferentes tipos de algoritmos e têm áreas de atuação muito específicas.

Figura 2.1.1: Principais conceitos Inteligência Artificial



Fonte: Adaptado de Nelson *et al.* (2020)

Segundo Du-Harpur *et al.* (2020), o termo Inteligência Artificial foi utilizado pela primeira vez na Conferência de Dartmouth em 1956. No entanto, a possibilidade de que as máquinas fossem capazes de simular o comportamento humano foi levantada anteriormente por Alan Turing que desenvolveu um teste que procurou diferenciar o comportamento entre humanos e máquinas. No entanto, de acordo com os vários autores, este é um conceito que tem sofrido alterações ao longo do tempo, pelo que a sua definição difere em função das várias áreas de atuação.

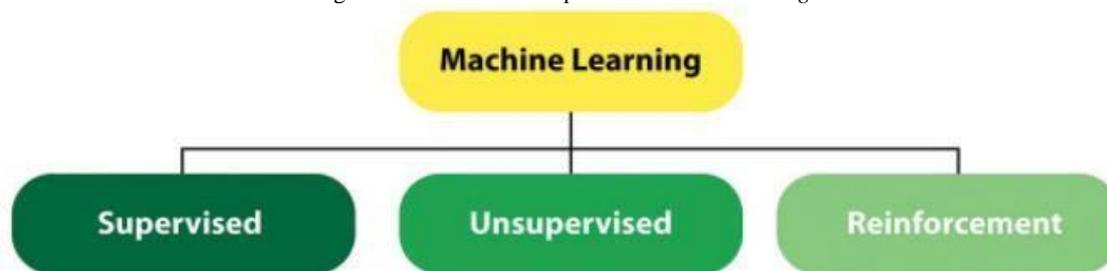
A medicina foi identificada desde cedo como uma das áreas mais promissoras para a aplicação de sistemas de IA (Bohr & Memarzadeh, 2020). Desde meados do século vinte os investigadores têm vindo a desenvolver sistemas de suporte para facilitar a decisão clínica através de ferramentas que auxiliam no diagnóstico de doenças e na escolha do tratamento adequado (Zhou, 2020). Com recurso à informação proveniente dos dados é possível ter acesso à informação detalhada sobre os utentes, incluindo notas clínicas e análises laboratoriais, possibilitando a aplicação de métodos de *natural language processing* (Yu, Beam & Kohane, 2018). Ao contrário da primeira geração de sistemas de IA que se baseava no conhecimento prático e teórico de médicos e especialistas que se regiam segundo regras previamente estabelecidas, os sistemas mais recentes de IA fomentaram o desenvolvimento de modelos de *machine learning*. Estes modelos têm a particularidade de conseguir analisar um vasto conjunto de dados e identificar diferentes tipos de padrões (Turner, 2020). A crescente implementação de sistemas de registos eletrónicos na área da saúde não só permitiu acelerar o processo de recolha de dados clínicos em grande escala como também contribuiu para uma integração mais simplificada deste tipo de sistemas (Char *et al.* 2018).

Segundo Chan & Zary (2019), a IA é um termo usado para descrever a teoria e o desenvolvimento de sistemas de computadores no desempenho de tarefas que normalmente requerem cognição humana, como a perceção, conhecimento da linguagem, aprendizagem, planeamento e a resolução de problemas. De acordo com Nelson *et al.* (2020), a maioria das aplicações de IA na área da saúde são denominadas por *narrow AI*. Este conceito está associado ao desempenho de uma tarefa simples e bem definida que requer inteligência humana e que não desempenha mais nenhuma função para além daquela que foi previamente programada. De uma forma prática, este tipo de sistemas conseguem aprender a reconhecer imagens de padrões que apresentam diversas patologias como a retinopatia diabética, mas não conseguem perceber qual é a condição de saúde específica para cada utente. Para estes autores, faria mais sentido adotar o termo *augmented intelligence* aproveitando os pontos fortes dos sistemas computacionais e os pontos fortes dos profissionais de saúde. O termo *augmented*

intelligence tem como base fundamental a ideia de que a tecnologia não procura substituir os profissionais de saúde mas sim auxiliá-los a desempenhar tarefas de uma forma mais rápida e eficiente e a fim de liberar os mesmos profissionais para o desempenho de tarefas mais complexas (Bryant, 2020).

Por sua vez, o *machine learning* é uma das principais disciplinas de IA que fornece aos computadores a capacidade de *self-improvement*, baseado no fator experiência, e sem que haja uma programação explícita (Bohr & Memarzadeh, 2020). De uma forma mais simples o termo *machine learning* refere-se à habilidade que os computadores têm para analisar os dados e identificar padrões sem que haja programação humana adicional. Esta metodologia pretende classificar e agrupar os dados em diferentes categorias de acordo com as regularidades que os mesmos possam apresentar, permitindo analisar bases de dados enormes e desenvolver modelos de classificação e previsão altamente precisos. Esta capacidade computacional pode melhorar a *performance* dos algoritmos e melhorar os processos de inovação, qualidade e eficiência de várias instituições de saúde (Turner, 2020).

Figura 2.1.2: Diferentes tipos de *Machine Learning*



Fonte: Adaptado de Nelson *et al.* (2020)

De acordo com Rashidi *et al.* (2019), ao aliar a ciência da computação e a área da estatística, as aplicações de *machine learning* estão a ter um impacto cada vez mais notório na área da saúde. As abordagens de *machine learning* têm demonstrado um avanço particular no diagnóstico de imagens, no prognóstico de doenças e na avaliação do risco (Zhou, 2020). De uma forma mais específica, existem três abordagens de *machine learning*.

Nos modelos de *supervised learning* o computador recebe como entrada ou *input*, características ou *features*, relacionados com o objetivo para o qual o algoritmo é treinado. O rótulo ou *label*, neste caso considerado como a saída ou *output*, do objetivo pretendido também é fornecido (Jiang *et al.*, 2017). Em termos práticos, para se proceder à identificação de uma imagem de um fígado, um conjunto de imagens de fígados em condições normais com características representativas, como os lóbulos hepáticos, os canais, as veias e artérias hepáticas são fornecidos ao sistema e é também apresentado ao computador o rótulo que

atribuí o nome de fígado para as características fornecidas. De seguida, o algoritmo é treinado para identificar as características representativas de um fígado e a *performance* do algoritmo é testada. De acordo com o exemplo, a coleção de amostras de fígado é usada para ajustar e escolher o melhor algoritmo. Na fase final, o algoritmo é testado com um conjunto de dados independentes em que os dados de teste são dados não rotulados de fígados. Através da identificação de características previamente aprendidas no conjunto de teste, o algoritmo deve ser capaz de prever e associar essas características ao rótulo “fígado” (Turner, 2020).

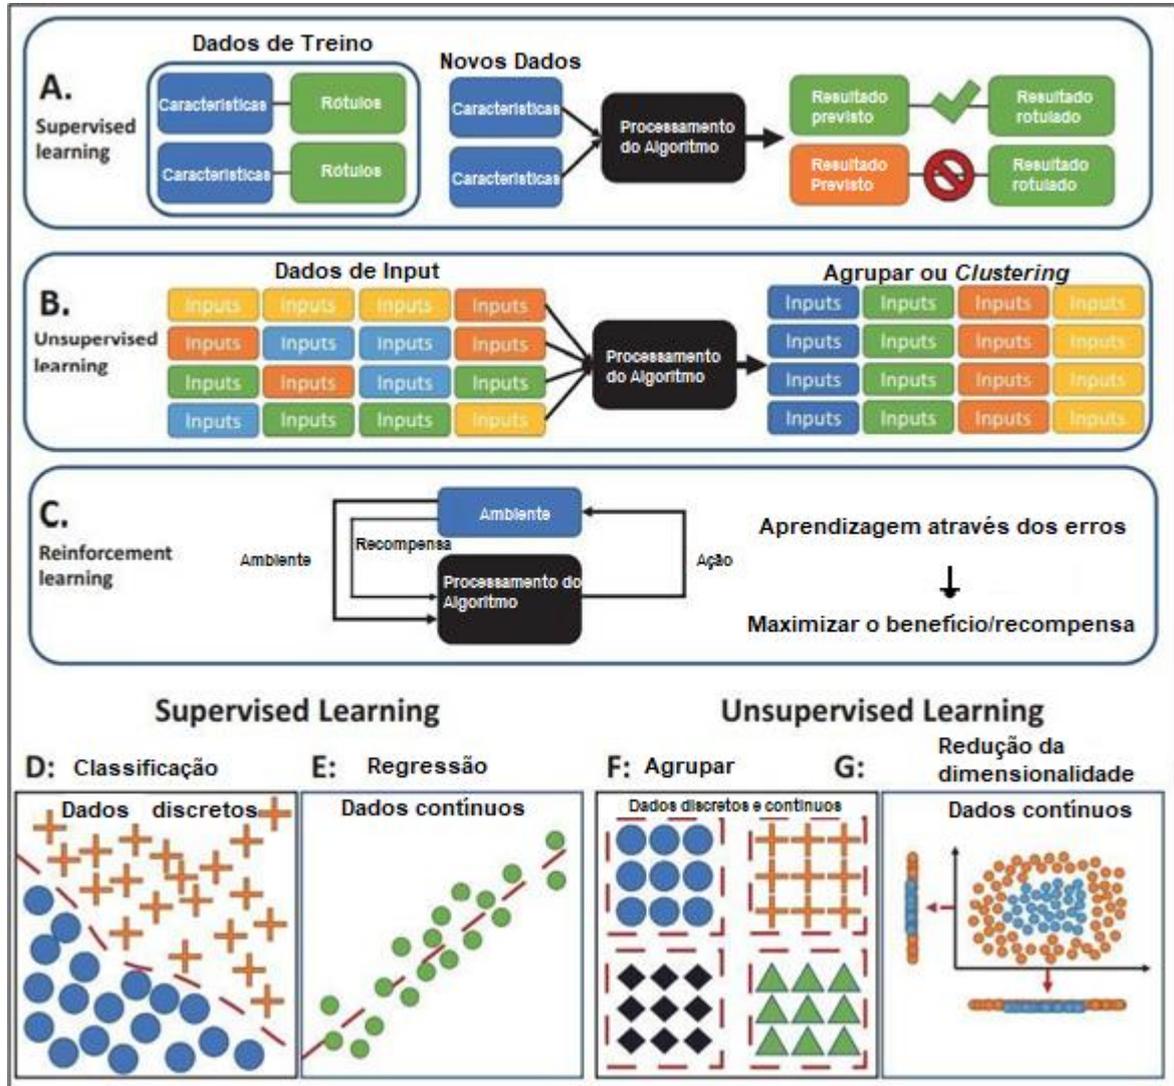
Dentro dos algoritmos de *supervised learning*, há duas abordagens distintas (Yu, Beam & Kohane, 2018). Na abordagem através da classificação, os dados ou as variáveis rotuladas, que podem ser números, texto ou dados não estruturados como imagens, produzem *outputs* qualitativos de classe discreta. Um exemplo dessa classificação ocorre quando um algoritmo de *supervised machine learning* é utilizado para produzir uma resposta/identificação qualitativa baseada num conjunto de dados de treino de imagens rotuladas que são posteriormente usadas para prever imagens futuras. Na abordagem feita através da regressão, a aquisição cumulativa das variáveis de dados tem como intuito produzir um *output* quantitativo de classe numérica (Rashidi et al., 2019). Com o desenvolvimento do processo inerente à técnica decorre um aperfeiçoamento contínuo que procura determinar as melhores associações entre os *outputs* e *inputs* cujo intuito passa por realizar uma aproximação da média dos resultados (Jiang et al., 2017).

Por outro lado, os modelos de *unsupervised learning* são usados em situações onde é difícil ou impossível definir características de tecido biológico que permitam identificar um fígado (Zhou, 2020). Nesta abordagem, um conjunto de diferentes tipos de tecido de vários órgãos são apresentados ao computador e o computador tem a capacidade de identificar padrões de tecidos e agrupar esses tecidos em grupos ou *clusters* com padrões idênticos (Turner, 2020).

Dentro do mesmo modelo de *unsupervised learning* é possível identificar representações nos dados projetados a partir de uma dimensão maior de dados. Esta transformação pretende representar esse mesmo conjunto de dados numa dimensão menor, mecanismo que é por norma associado ao termo *dimensionality reduction* e que ocorre especialmente quando uma determinada característica envolve um número elevado de dimensões (Nelson, 2020). Na prática esta metodologia projeta os dados nas principais dimensões sem perder informação relevante sobre o conteúdo. Em alguns casos, os investigadores recorrem primeiramente a esta metodologia para reduzir as dimensões dos dados e posteriormente usam a técnica de *clustering* para agrupar esses mesmos dados (Yu, Beam & Kohane, 2018). Assim, o objetivo

geral dos modelos de *unsupervised learning* é identificar estruturas nos dados de entrada sem uma definição prévia do *output* pretendido (Du-Harpur *et al.*, 2020).

Figura 2.1.3: Manipulação e Preparação dos Dados

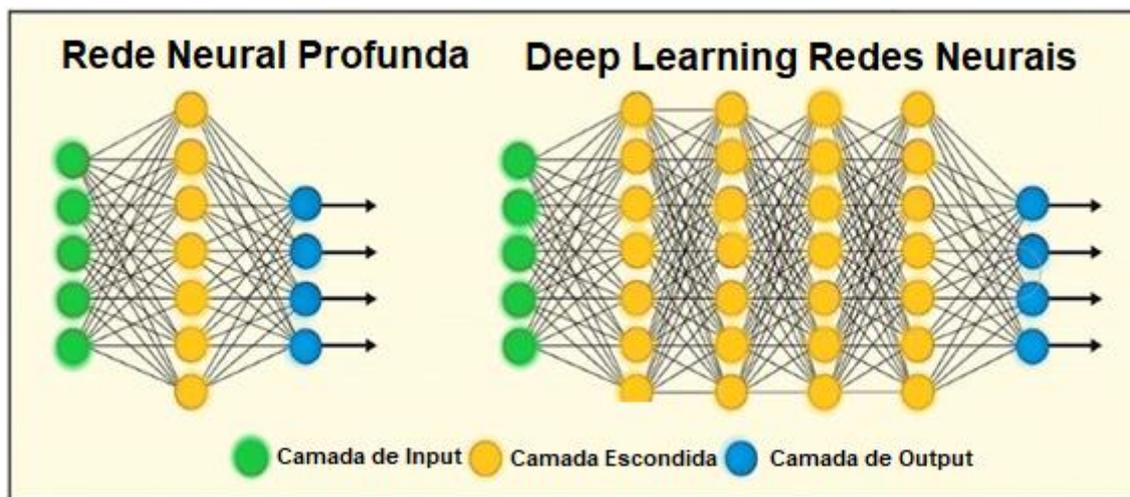


Fonte: Nelson *et al.* (2020)

A terceira categoria de *machine learning*, *reinforcement learning*, consiste na aprendizagem através dos erros realizados. Os modelos de *reinforcement learning* diferem dos modelos de *supervised learning* na medida em que os *inputs* são *unlabeled inputs*, ou seja, não se encontram rotulados, mas são levados a prever o *output* pretendido (Miotto *et al.*, 2017). A aprendizagem ocorre através do *feedback* gerado por um sistema de recompensas e punições. A aprendizagem por reforço permite que o algoritmo tenha a capacidade de maximizar a sua recompensa e melhorar a sua prestação com base nos eventos passados (Nelson *et al.*, 2020).

Relativamente às redes neurais artificiais ou *artificial neural networks* (ANN), as mesmas resultam de sistemas de computadores que são desenvolvidos para modelar redes neurais e desenvolver a capacidade de aprendizagem (Ahmed *et al.*, 2020). Estas redes contém um número de elementos processados denominados de neurónios que se interligam num padrão unidirecional. Estes neurónios conseguem executar tarefas simples de uma forma autónoma mas quando se interligam podem desempenhar tarefas complexas. A informação recebida através de um *input* organizado numa camada ou *layer* propaga - se de neurónio em neurónio através das várias camadas (Jiang *et al.*, 2017). O *input* da primeira camada da rede ativa a segunda camada de neurónios até que o *output* final é alcançado na última camada. Esta estrutura permite que o computador desenvolva a capacidade de *self-improvement* através da revisão de um grande conjunto de dados e de um ajuste de parâmetros que determinam o nível de correspondência entre neurónios, condicionando o modo como a informação é transmitida (Turner, 2020).

Figura 2.1.4: Diferentes Tipos de Redes Neurais



Fonte: Adaptado de Nelson *et al.* (2020)

Dentro da mesma área de aprendizagem, o *Deep learning* (DL) é uma subdisciplina de *machine learning* que desenvolve a capacidade de aprendizagem através de redes neurais com padrões de dados estruturados ou não estruturados e com múltiplas representações que correspondem a níveis de diferentes camadas abstratas (Yang *et al.*, 2021). *Deep learning* é considerada como o conjunto de aplicações de multicamadas de redes neurais artificiais também denominadas por *deep neural networks* (DNN) (Miotto *et al.*, 2017). De uma forma geral, na área da saúde as DNN são utilizadas para realizar o reconhecimento de imagens e a identificação de possíveis patologias que levam a formalização de diagnósticos médicos. De

uma forma prática, é feita a análise detalhada sobre o pixel da imagem para perceber se este respeita os parâmetros da imagem de interesse (Du-Harpur *et al.*, 2020). Nestes casos, o *output* gerado é comparado com o *output* desejado e o erro associado a essa análise é calculado de modo que não haja suposições sobre uma tarefa em particular (Noorbaksh-Sabet *et al.*, 2019).

São vários os exemplos que demonstram a aplicabilidade dessas ferramentas na área da saúde. Arbabshirani *et al.* (2018), desenvolveram um modelo de DNN com o objetivo de priorizar as tarefas de trabalho e reduzir o tempo de diagnóstico para utentes com hemorragias intracranianas. O modelo foi treinado através de 37000 tomografias computadorizadas e foi posteriormente avaliado em 9500 casos sem um diagnóstico associado. O tempo de atribuição de diagnóstico para o mesmo tipo de hemorragia foi reduzido em 96%. Este estudo demonstra o impacto positivo do modelo na otimização do fluxo de trabalho na área da radiologia e demonstra a influência que estes sistemas inteligentes têm sobre o aproveitamento dos recursos em função das necessidades de cada serviço (Liu *et al.*, 2021).

De uma forma mais específica, a IA demonstra-se particularmente útil em áreas onde a informação que permite diagnosticar uma patologia já se encontra digitalizada, como a classificação de lesões ou a obtenção de um diagnóstico através de imagens fornecidas pelos meios complementares de diagnóstico (Yang *et al.*, 2021).

No entanto, existe um conceito igualmente importante que permite analisar uma larga proporção da informação clínica disponível que se encontra disposta em forma de texto narrativo, como as notas clínicas de um teste de laboratório ou as notas de alta. Segundo Jiang *et al.* (2017), esta informação não estruturada não consegue ser interpretada e analisada por programas de computação e dessa forma, o conceito de *Natural Language Processing* (NLP) foca-se no processo de extração de informação útil presente em textos ou notas clínicas.

De acordo com Bohr e Memarzadeh (2020), existem várias áreas da medicina onde o NLP pode criar um impacto significativo. A extração de informação de notas médicas e a consequente atribuição de códigos médicos, o uso da informação de notas médicas para prevenir erros administrativos, a facilitação no processo de tomada de decisão clínica e a compilação de orientações e diretrizes clínicas necessárias para uma prestação de cuidados rigorosa e criteriosa são alguns dos contributos que o NLP pode promover na área da saúde (Jiang *et al.*, 2017). Segundo Viani *et al.* (2021), um dos principais exemplos práticos de NLP é o modo como se classifica as doenças descritas em notas médicas. A identificação precoce de palavras-chave pré-estabelecidas pela *Internacional Classification of Diseases* permite aos clínicos identificar e atuar atempadamente no tratamento de várias patologias.

2.1.1 Aplicações práticas de sistemas de IA na Área Clínica

Segundo Zhou (2020), o desenvolvimento da Inteligência Artificial médica está relacionado com o desenvolvimento de programas de IA cujo objetivo é ajudar o profissional de saúde na formulação de um diagnóstico, na tomada de decisões terapêuticas e na previsão de um resultado clínico. As imagens de diagnóstico e os registos eletrónicos de dados de saúde são maioritariamente avaliados através de modelos de *machine learning*. Estas ferramentas são projetadas para apoiar os profissionais de saúde no desempenho das suas tarefas diárias, auxiliando nas tarefas que dependem da manipulação de dados e da extração de informação relevante (Goh *et al.*, 2021).

Segundo Muehlematter *et al.* (2021), ao longo dos últimos cinco anos, mais de metade dos dispositivos médicos de IA aprovados pela *US Food and Drug Administration* (FDA) foram desenvolvidos para a área da radiologia. De acordo com Letourneau-Guillon *et al.* (2020), no campo da radiologia, os avanços de *machine learning* e mais especificamente de *deep learning* vieram potenciar o aumento de capacidade de processamento computacional e revolucionar a análise de imagens médicas, promovendo a aplicação de ferramentas que facilitam a atribuição de um diagnóstico e o desenvolvimento da prática da medicina de precisão.

De acordo com a Administração Portuguesa de Administradores Hospitalares (2019), a medicina de precisão, é um conceito de análise e compreensão da saúde de cada indivíduo para o tratamento e prevenção da doença e que tem em consideração vários fatores como a variabilidade genética, ambiente e estilo de vida de cada pessoa, conjugando a evolução tecnológica na implementação de novos mecanismos de diagnóstico e de tratamento de doenças.

Com o desenvolvimento das tecnologias de informação é possível direcionar o tipo de tratamento em função das características de cada utente. Dessa forma, a visão da medicina de precisão passa por melhorar a rapidez e eficácia dos diagnósticos, evitando a prescrição de terapêuticas desnecessárias, ineficazes e dispendiosas (Filipp, 2019). A nível económico, isso significará uma utilização racional e eficiente dos recursos disponíveis, diminuindo o desperdício e custos associados com tratamentos ineficazes e respetivos efeitos secundários (Bohr & Memarzadeh, 2020). Nesse sentido, é necessário passar pelo processo de digitalização dos registos médicos de cada cidadão utilizando os dados mais relevantes para que através da aplicação posterior das mais diversas ferramentas de inteligência artificial, como *machine learning* e mais recentemente *deep learning*, seja possível identificar e

reconhecer padrões que possam ser utilizados pelos clínicos, de modo a promover cuidados de saúde de uma forma mais adequada (Administração Portuguesa de Administradores Hospitalares, 2019).

O diagnóstico precoce pode ser alcançado com a melhoria no processo de extração de *insights* clínicos e com um sistema que seja capaz de retirar e analisar a informação proveniente desses *insights* (Zhou, 2020).

A FDA permitiu recentemente a aplicação de um *software* desenvolvido para detetar fraturas de pulso (FDA, 2018). O sistema *OsteoDetect* é um *software* que recorre a um modelo de *machine learning* para identificar sinais de fraturas radiais durante a revisão posterior- anterior e medial-lateral de imagens raio-x. O *software* marca a localização de uma fratura na imagem para ajudar os profissionais médicos a obter um diagnóstico. Estes profissionais podem usar o *software* em vários contextos, incluindo, cuidados de saúde primários, departamentos de emergência e em especialidades como a ortopedia. Os fabricantes deste *software* enviaram para a FDA, um conjunto com cerca de mil imagens de radiografias com o intuito de avaliar o nível de *performance* na deteção de fraturas de pulso. Adicionalmente, foram realizados dois estudos para sustentar o impacto que este sistema pode gerar na prática clínica. Numa fase inicial, procurou-se avaliar o nível de *performance* desta ferramenta comparativamente com a *performance* de três cirurgiões ortopédicos. De seguida, a companhia responsável submeteu um estudo com a análise de vinte e quatro clínicos não especializados na área da ortopedia cujo intuito foi comparar o nível de precisão para a deteção de fraturas de pulso em duzentos utentes. O nível de desempenho do modelo foi ligeiramente superior quando os profissionais de saúde recorreram ao uso do *software*. No entanto, a ferramenta permitiu também diminuir consideravelmente os tempos de atribuição de diagnóstico, o que sugere que o uso combinado entre este tipo de ferramentas e profissionais de saúde pode traduzir-se numa melhoria significativa para as instituições de saúde (FDA, 2018).

De acordo com Du-Harpur *et al.* (2020), na área da dermatologia o reconhecimento de padrões visuais também é visto como uma competência fundamental na obtenção de um diagnóstico mais preciso. Dessa forma, os sistemas de *neural networks* têm sido usados para diagnosticar várias doenças de pele.

Esteva *et al.* (2017), recorreram ao algoritmo *GoogLeNet Inception*, um algoritmo pré-treinado com mais de um milhão de imagens que foi novamente treinado num conjunto de dados universitários de alta qualidade com mais de cem mil imagens de dermatologia. Os *pixels* que constituíam os padrões das imagens foram devidamente avaliados com o intuito de

atribuir um possível diagnóstico. O teste foi feito através da comparação de desempenho de vinte dermatologistas que recorreram a imagens clínicas, comprovadas por biópsia e com duas classificações binárias. A primeira que procurava diferenciar carcinomas queratinócitos de queratoses e a segunda que pretendia distinguir tumores malignos ou melanomas de tumores benignos. Os dermatologistas foram iguados ou excedidos pelo algoritmo de *deep learning* no que há eficácia de atribuição de um diagnóstico diz respeito, tendo em conta que o algoritmo apresentou uma elevada taxa de acerto nos utentes que foram diagnosticados com o recurso a imagens que correspondiam a carcinomas e melanomas.

Nesse sentido, e segundo Esteva *et al.* (2017), estima-se que nos próximos anos os dermatologistas possam ter acesso a esta metodologia recorrendo a dispositivos móveis devidamente equipados com estas ferramentas e com a finalidade de fornecer um acesso universal de cuidados de diagnósticos essenciais com um custo significativamente menor.

De acordo com Gomes & Nunes (2020), ao longo da última década o cancro da mama tem apresentado a maior taxa de incidência de cancro nas mulheres portuguesas. Estima-se que por ano são diagnosticados seis mil novos casos, ou seja, dezassete novos casos por dia e em média, morrem anualmente mais de mil e quinhentas mulheres, sendo a segunda causa de morte por cancro na mulher. Se for identificado num estágio inicial, com recurso a mamografias e imagens de raio-x, a probabilidade de sucesso face ao tratamento é alta (Geras, Mann & Moy, 2019).

Na generalidade dos casos, as mamografias são examinadas por radiologistas que determinam se é necessário a realização de uma biópsia para determinar as características das células ou tecidos. Embora os métodos de rastreio demonstrem ser eficazes, os avanços recentes na visão computacional e nas tecnologias podem melhorar a precisão, velocidade, custo e acessibilidade dos rastreios (Geras, Mann & Moy, 2019).

Schaffter *et al.* (2020), desenvolveram um estudo recentemente aprovado pela FDA que procurou aumentar o nível de precisão do rastreio da mamografia através da redução do número de casos de cancro não diagnosticado e do número de casos de falsos positivos. O uso combinado de um algoritmo de *machine learning* com a avaliação de um único radiologista apresentou uma melhoria geral em termos de desempenho quando comparado com o método de classificação tradicional. O estudo realizado em vários países apresentou uma redução na taxa de falsos positivos de 1,5%. Em termos práticos, esta diminuição traduzir-se-ia numa redução de meio milhão de mulheres que não necessitaria de realizar outro exame complementar.

Os investigadores sugerem que a colaboração entre radiologistas e IA pode reduzir a taxa

de falsos positivos e permitir também entender de que forma é possível otimizar os recursos humanos na prática diária de radiologistas e evitar determinados procedimentos a fim de aferir se os utentes são portadores de uma determinada patologia (Du-Harpur *et al.*, 2020).

Dentro da mesma área de atuação, a ferramenta *CureMetric*, aprovada pela FDA, foi desenvolvida com o intuito de facilitar o processo de triagem na interpretação e análise de imagens correspondentes a mamografias. De acordo com Yala *et al.* (2019), esta ferramenta representa um papel importante no auxílio prestado aos radiologistas pelo modo como permite classificar os diferentes casos quanto à sua complexidade, necessidade e urgência de tratamento, permitindo de uma forma direta priorizar os utentes com casos que foram sinalizados pelo algoritmo como sendo os casos mais graves ou suspeitos. De acordo com os médicos envolvidos no desenvolvimento desta ferramenta, é possível separar os casos mais suspeitos para cancro da mama com um nível de precisão superior em relação aos métodos que se usam tradicionalmente.

De uma forma prática, os radiologistas são capazes de interpretar e analisar as imagens raio-x em quase metade do tempo, cerca de 40% mais rápido, quando têm acesso a uma lista com a priorização dos utentes, contrariando o modelo tradicional “*first in, first out*” (Bryant, 2020). Dessa forma, os casos que não apresentam qualquer tipo de suspeita para cancro da mama podem ser colocados no final da lista de utentes com imagens por observar, priorizando os casos que carecem de mais tempo de interpretação (Bryant, 2020).

De acordo com Hosny *et al.* (2018), a IA pode ter um impacto bastante significativo no desempenho de funções de radiologistas pela capacidade de categorizar exames quanto ao tipo de lesão, mas também pela identificação rápida de exames negativos em locais onde o volume de trabalho é acrescido e onde a escassez de recursos humanos é uma realidade.

2.1.2 Aplicações práticas de sistemas de IA na área da Gestão da Saúde

O reforço do financiamento do SNS tem de continuar a ser acompanhado pela consolidação das medidas de aumento da eficiência, com destaque para a otimização da capacidade instalada no SNS, para o aumento da produtividade dos recursos humanos, para a definição dos tetos máximos das despesas em medicamentos e meios complementares de diagnóstico e terapêutica, que têm sido acordados com os fornecedores, para a aquisição centralizada de produtos e dispositivos médicos e para o combate ao desperdício e à fraude (Ministério da Saúde, 2018).

São vários os estudos de investigação que visam aumentar a eficiência das unidades de

saúde através de sistemas de IA. Lopes *et al.* (2018), desenvolveram uma plataforma denominada *Knowlogis*, numa parceria estabelecida entre várias faculdades e uma empresa de consultoria e serviços tecnológicos, que visa facilitar a tomada de decisão na logística hospitalar através de um *dashboard* inteligente. A plataforma pretende prestar auxílio na previsão de necessidades, bem como, na monitorização e coordenação de encargos com medicamentos, dispositivos médicos e materiais. O sistema desenvolvido calcula automaticamente a evolução dos *stocks* de material clínico e de medicamentos, com o recurso a dados históricos e ao agendamento de intervenções cirúrgicas, sugerindo políticas de aprovisionamento, como o ciclo de reposição de *stock*. Além de produzir este tipo de informações, o *KnowLogis* oferece ainda vantagens no campo financeiro, através da monitorização e ajuste do orçamento, bem como da coordenação de compras. A plataforma *Knowlogis* tem uma política de autogestão de inventário de revisão periódica e contínua.

Os investigadores optaram por recorrer a métodos de análise preditiva, neste caso, de *machine learning*, com o intuito de otimizar os resultados pretendidos. A plataforma foi testada ao longo dos últimos 3 anos e os resultados obtidos até ao momento demonstram que os ganhos obtidos são potenciados pela melhoria na gestão de inventário (Lopes *et al.*, 2018). A mesma plataforma tem conseguido melhorias no que ao número de cancelamentos de procedimentos diz respeito pela forma como consegue controlar e gerir todo o ciclo de *stocks*.

Os sistemas de informática mais modernos, capazes de manipular e processar grandes quantidades de dados em conjunto com métodos de pesquisa de última geração, podem alavancar parte do trabalho realizado por gestores de saúde, melhorando, em última instância, os resultados de saúde. O *Knowlogis* foi desenvolvido com o objetivo de promover, de uma forma ativa, mudanças para melhorar a logística hospitalar. Se atualmente, em contexto nacional, não existe qualquer coordenação automática entre ajustes orçamentais e decisões operacionais, com esta solução será possível monitorizar e corrigir desvios no orçamento e simular o impacto financeiro de alterações operacionais (Dossou *et al.*, 2021).

Para Graham *et al.* (2018), a previsão do volume de pacientes, bem como a previsão da taxa de admissão de utentes, é um problema que surge principalmente em serviços de urgência. Nesse sentido, os investigadores procuraram prever a taxa de chegada de utentes que recorreram ao serviço de urgência. Compararam três modelos de *machine learning* e concluíram que a implementação destes modelos pode ser utilizada para o desenvolvimento de uma ferramenta de suporte à decisão de gestores hospitalares no planeamento e gestão de recursos. No entanto, segundo os mesmos autores, embora o modelo possa ser usado para apoiar o planeamento e a tomada de decisão, as decisões de admissão irão continuar a exigir

racionalidade, sentido crítico, experiência e bom senso por parte das pessoas que gerem instituições de saúde.

Segundo Austin *et al.* (2020), um dos maiores desafios para os gestores hospitalares prende-se com as elevadas taxas de chegada de utentes e com todos os cuidados que esses mesmos utentes necessitam. O tempo de permanência é um dos principais indicadores de *performance* de um serviço de urgência e com o intuito de solucionar esse problema, Cai *et al.* (2016), recorreram a um algoritmo de IA. O objetivo passou por desenvolver um modelo capaz de prever com maior precisão o tempo de internamento, a mortalidade e a taxa de readmissão de pacientes hospitalizados, com base nos dados armazenados de um serviço de urgência. O índice de mortalidade foi o índice que apresentou maior nível de precisão. Os investigadores classificaram os utentes em quatro categorias específicas, nomeadamente, utente com alta prevista, utente com expectativa de permanecer hospitalizado, utente com expectativa de morte e utente com possível readmissão, e forneceram diariamente essas probabilidades com o intuito de antecipar o desfecho mais provável para cada utente e tomar decisões em função dessas previsões. Dessa forma, Cai *et al.* (2016), concluíram que os algoritmos de *machine learning*, podem fornecer previsões com maior precisão face aos modelos mais tradicionais que se baseiam apenas num indicador.

Para uma unidade hospitalar, as readmissões de utentes representam um enorme desafio. Os modelos de *machine learning* podem ajudar a identificar pacientes que apresentam uma maior probabilidade de serem readmitidos. Futoma *et al.* (2016), procuraram avaliar o desempenho de vários algoritmos de IA para avaliar o risco de readmissão de utentes recorrendo apenas a códigos da *International Classification of Diseases* e a algumas variáveis, como a duração do último internamento, a idade e o número de admissões durante o último ano, e concluíram que comparativamente com os modelos que se usam tradicionalmente, os modelos de IA conseguem prever com maior precisão a taxa de readmissão de pacientes hospitalizados com base nos dados armazenados do sistema de saúde daquele país.

De acordo com Martins (2020), a disponibilidade de camas numa unidade de cuidados intensivos é na maioria das vezes escassa, pelo que se torna importante disponibilizar essas mesmas camas no menor período de tempo e encaminhar os utentes para serviços de enfermaria de diferentes serviços hospitalares.

McWilliams *et al.* (2019), testaram dois modelos de classificação de *machine learning* para classificar os utentes que podem ser transferidos ou dispensados da unidade de cuidados intensivos. Os investigadores concluíram que a abordagem testada é viável e pode ser implementada em conjunto com outros modelos de previsão de risco, nomeadamente,

modelos que procuram prever eventos adversos. Demonstraram ainda que quanto maior for a quantidade de variáveis e de dados disponíveis, maior é a capacidade de prever quais os utentes que podem ser dispensados da unidade de cuidados intensivos, no entanto, salientaram que a maior barreira para a inclusão de mais variáveis foi precisamente a harmonização dos dados e a forma como estes são registados.

Segundo Beltrame *et al* (2019), as taxas *no-show* representam um papel importante no planeamento hospitalar e contribuem diretamente para um maior desperdício em termos de recursos.

Kursawa *et al.* (2016), afirmam que 10% dos utentes seguidos na consulta de diabetes tendem a suspender o tratamento. Para prever e identificar esses utentes foi desenvolvido um modelo de *machine learning*. O objetivo passou por prever quais as consultas em que a probabilidade de os utentes não comparecerem fosse maior. Dessa forma, passou a ser possível alertar os profissionais de saúde para que estes pudessem ser capazes de adotar estratégias que reforçassem a importância do comparecimento nas consultas.

Devido aos elevados custos em vários sistemas de saúde é crucial para as instituições evitarem custos desnecessários. Eigner *et al.* (2019), propuseram usar um modelo de *machine learning* para identificar utentes que apresentavam um risco acrescido de necessitarem de cuidados de saúde com custos mais elevados. Nesse sentido, foram desenvolvidos quatro modelos de IA para avaliar e prever os custos com os utentes. Dos modelos desenvolvidos, o terceiro modelo foi o que apresentou melhores resultados de previsão para utentes de alto custo. Para além das variáveis sociodemográficas, o modelo englobou variáveis relacionadas com a utilização de recursos como, a pernoita do utente, o tempo de internamento, o número de médicos e enfermeiros disponíveis, bem como as medidas de reabilitação. Este estudo permitiu identificar quais os critérios que contribuíram mais significativamente para a identificação e previsão de utentes com custos mais elevados, permitindo a realização de cuidados preventivos com medidas que facilitaram o planeamento dos recursos disponíveis (Bohr & Memarzadeh, 2020).

Segundo Lin *et al.* (2019), a perceção dos utentes sobre os tempos de espera pode afetar a satisfação do utente e a qualidade do serviço. Os investigadores avaliaram a aplicabilidade de modelos de *machine learning* para prever o tempo de espera no serviço de oftalmologia pediátrica e concluíram que os modelos de *supervised machine learning* podem prever com precisão os tempos de espera de utentes e fornecer *insights* sobre os fatores que contribuem maioritariamente para esses tempos de espera. Os investigadores salientaram ainda que a satisfação do utente aumenta quando estes são informados sobre o tempo de espera previsto e

de quando esse tempo corresponde ao tempo que o utente esperou efetivamente até ser atendido. Dessa forma, é crucial melhorar as estimativas de tempo de espera com base nos dados que têm sido incorporados nos registos eletrónicos de saúde a fim de aumentar a eficiência em ambiente clínico (Buch, Ahmed & Maruthappu, 2018).

De acordo com o Ministério da Saúde (2015), os custos com o bloco operatório (BO) podem variar entre 7 a 11 euros por minuto, o equivalente a um valor mínimo de 420 euros por hora. No entanto, e de acordo com a mesma entidade, é feita a ressalva de que a atividade inerente ao funcionamento do BO gera também as maiores receitas dos hospitais. A mesma entidade refere que “*com uma avaliação rigorosa da situação nacional de blocos operatórios e dos respetivos sistemas de informação, será possível determinar a oferta pública existente de forma a poder formular propostas de como obter a melhor rentabilização da capacidade instalada existente e corrigir eventuais desajustamentos*”.

Segundo Demir *et al.* (2017), os tempos de espera cirúrgicos são maiores quando a procura excede a capacidade de resposta dos sistemas de saúde, que é limitada pelos recursos alocados e pela capacidade instalada, assim como da produtividade com que essa é utilizada. Para Birkhoff *et al.* (2021), uma melhor gestão e agendamento das cirurgias realizadas em BO podem traduzir-se em benefícios significativos para as unidades de saúde. De acordo com os mesmos autores, em muitos hospitais, a unidade de recobro, unidade onde os utentes recuperam depois dos procedimentos cirúrgicos, é vista como um *bottleneck*, ou seja, um ponto de estrangulamento que condiciona o fluxo de trabalho e que ocorre quando a unidade de recobro atinge o máximo da sua capacidade (Bellini *et al.*, 2020). Nesse contexto, os utentes têm de esperar no BO até que a unidade de recobro tenha uma vaga, levando a atrasos e cancelamentos de cirurgias programadas.

Para procurar solucionar esse problema, Fairley *et al.* (2019), desenvolveram uma metodologia de *machine learning* cujo foco passou por otimizar a programação dos tempos cirúrgicos para minimizar atrasos devido ao congestionamento da unidade de recobro. Dessa forma, procuraram estimar o tempo de permanência de um paciente na unidade de recobro para cada procedimento cirúrgico. Desenvolveram um algoritmo com o intuito de maximizar a ocupação na unidade de recobro e posteriormente utilizaram um modelo de evento discreto para comparar o modelo otimizado ao modelo pré-existente. Com o recurso aos dados do hospital *Lucile Packard Children 's* demonstraram que este sistema de agendamento poderia reduzir significativamente os atrasos no BO causados pelo congestionamento da unidade de recobro. Através de uma simulação feita verificaram que o modelo podia ter reduzido os tempos de espera em 76% sem diminuir a taxa de utilização do BO.

2.2 Desafios à implementação de sistemas de IA na área da Saúde

A aplicabilidade da IA na área da saúde tem um grande potencial para transformar os cuidados de Saúde e tornar as instituições de saúde mais eficientes, contudo, esta temática também levanta alguns desafios que são maioritariamente causados pela falta de regulamentação (Reddy *et al.*, 2020).

Segundo Gerke, Minssen e Cohen (2020), o princípio do consentimento informado deve estar assegurado e devidamente validado quando os utentes interagem diretamente ou indiretamente com sistemas de IA. É necessário perceber em que circunstâncias este consentimento deve ser aplicado e é igualmente importante perceber se são os profissionais de saúde que têm o dever e a responsabilidade de educar os utentes sobre a complexidade inerente a este tipo de sistemas. Para que o médico possa educar o utente sobre um determinado modelo de IA é necessário que haja uma explicação sobre como o algoritmo funciona, contudo, para modelos de *deep learning* nem sempre há uma explicação sobre como o algoritmo chegou a uma determinada resposta ou conclusão (Chan & Zary, 2019).

Um dos problemas que condiciona o desenvolvimento de sistemas de IA na área da saúde está precisamente associado à confiança que os profissionais de saúde e utentes depositam nesses sistemas. No desempenho de funções, o profissional de saúde deve assumir a responsabilidade dos seus atos, independentemente de serem ou não proveitosos para os seus utentes. Nesse sentido é importante definir como se deve proceder numa situação em que uma má decisão tem origem num sistema de IA.

Um estudo desenvolvido por Maassen *et al.* (2021), procurou avaliar a atitude de médicos alemães face à adoção de sistemas inteligentes. De acordo com os investigadores, os médicos que responderam ao questionário demonstraram estar particularmente divididos quando questionados sobre a responsabilidade legal das decisões que um algoritmo pode tomar. Quando lhes foi colocada a questão se a responsabilidade legal deve ser assumida na totalidade pelos investigadores que desenvolvem os algoritmos de IA, 43,9% respondeu que não, 44,2% respondeu que sim e 11,9% não respondeu. Este estudo sugere que a responsabilidade legal sobre os sistemas de IA é um tema que se encontra ainda em debate e que pode condicionar a implementação de ferramentas de IA.

Sit *et al.* (2020), procuraram explorar quais são as atitudes de estudantes de medicina do Reino Unido em relação à adoção de sistemas de IA. O estudo teve como intuito perceber o nível de perceção e conhecimento que os mesmos possuem sobre estes sistemas e entender qual é a intenção dos alunos sobre a inclusão desses sistemas na área da radiologia. De 1084

alunos distribuídos por 19 escolas do Reino Unido, 80% dos estudantes acreditam que os sistemas de IA vão desempenhar um papel importante na área da saúde e 49% afirma que é menos provável optarem por seguir uma carreira na área da radiologia devido ao impacto que os sistemas inteligentes podem ter no desempenho de tarefas de profissionais dessa área. De salientar que 79% dos inquiridos acreditam também que o ensino sobre sistemas inteligentes deveria fazer parte do plano curricular dos estudantes de medicina, no entanto apenas 45 alunos do número total dos alunos que participaram neste estudo receberam formação relacionada com IA e foram esses mesmos alunos que demonstraram um interesse acrescido no desenvolvimento de uma carreira na área da radiologia. O estudo dá especial ênfase à necessidade de envolver as escolas de medicina na área de IA para que os alunos não se sintam desencorajados na fase de implementação deste tipo de sistemas (McCoy *et al.*,2020).

De acordo com Gerke, Minssen e Cohen (2020), são vários os problemas associados à implementação de sistemas de IA. Para que o problema aliado à privacidade dos dados seja ultrapassado, é necessário que os utentes e profissionais de saúde confiem neste tipo de sistemas. Só dessa forma será possível dialogar com os utentes e estabelecer uma relação de confiança.

Zhang *et al.* (2021), desenvolveram um estudo na área da radiologia que procurou perceber o nível de perceção e aceitação face ao uso de sistemas inteligentes por parte de utentes que tinham sido recentemente diagnosticados. De uma forma geral, os utentes demonstraram estar pouco familiarizados com os conceitos de IA e afirmaram nunca terem beneficiado do uso desses sistemas. Contudo, depois de interagirem com um sistema de IA apresentado pelos investigadores, a maioria dos participantes considerou que as ferramentas de IA podem ser úteis na interpretação de um relatório de radiologia. Apesar dos utentes terem demonstrado uma atitude positiva face à adoção destes sistemas, os participantes afirmaram que as ferramentas desenvolvidas devem apenas fornecer serviço suplementar para coadjuvar a prática clínica. Uma das preocupações manifestada deveu-se à segurança do armazenamento dos dados e a questões relacionadas com a privacidade.

No mesmo estudo realizado por Zhang *et al.* (2021), os utentes expressaram que nunca aceitariam ser diagnosticados exclusivamente por sistemas inteligentes uma vez que a ausência de cuidados humanísticos lhes provocaria ansiedade, medo e insegurança. Contudo, a principal preocupação manifestada com a adoção destes sistemas deveu-se à qualidade, confiabilidade e precisão da informação médica providenciada pelos sistemas de IA.

A complexidade inerente ao modo de funcionamento dos algoritmos é outro dos fatores que gera preocupação nos profissionais que procuram implementar este tipo de sistemas

(Chan & Zary, 2019). Dessa forma, os algoritmos de IA/*machine learning* desenvolvidos por humanos devem evitar que os algoritmos assumam uma determinada tendência. Para Challen *et al.* (2020), é extremamente importante que os investigadores de IA estejam conscientes dos riscos do desenvolvimento de algoritmos de IA a fim de minimizar a probabilidade de que estes se possam tornar tendenciosos com o simples objetivo de alcançarem um determinado resultado pretendido. Este conceito é vulgarmente conhecido por *bias* e representa um enorme risco quando se pretende desenvolver um algoritmo (Kelly *et al.*, 2019).

De acordo com Rashidi *et al.* (2019), é necessário avaliar qual o tipo de algoritmo que se deve utilizar em função do problema que se pretende resolver e selecionar uma base de dados que tenha uma boa capacidade de generalizar. De acordo com os mesmos autores, uma base de dados deve considerar o fator qualidade e diversidade, tendo em conta que uma base de dados com dados demasiado perfeitos iria contribuir para que o algoritmo obtivesse um desempenho excelente para o conjunto de dados de treino, mas iria acabar por não apresentar o mesmo nível de desempenho para a fase de teste do modelo.

De acordo com Panch, Mattie e Celi (2019), a qualidade e a generalização dos dados são fatores que se devem ter em conta quando se pretende desenvolver e treinar um algoritmo de IA/*machine learning*. No entanto, a maioria dos profissionais de saúde não está satisfeito com a integridade e qualidade de *input* dos dados pela forma como a interoperabilidade entre utilizadores condiciona o processo de desenvolvimento e implementação de algoritmos de IA/*machine learning*. Segundo Stanfill *et al.* (2019), o modo como várias unidades de saúde compilam os dados dos seus pacientes, o erro humano associado a essa compilação, a forma como os profissionais de saúde e gestores hospitalares registam dados/ocorrências de maneiras diferentes e a incapacidade para avaliar o progresso da adoção desses processos são alguns dos fatores que dificultam a implementação dos sistemas de IA/*machine learning* (Lee & Yoon, 2017).

Segundo Benke e Benke (2018), a transparência dos dados, o propósito e o modo de funcionamento dos algoritmos de IA são também uma preocupação na medida em que deve ser possível avaliar o processo de treino de um algoritmo e interpretar como o sistema chegou a uma determinada decisão ou previsão. Dessa forma, é possível entender qual é a intenção de implementar uma determinada ferramenta de IA. É por isso necessário ter em conta que alguns dispositivos podem ser programados para atuarem contra os valores que salvaguardam a saúde dos utentes (Pesapane *et al.*, 2018).

A criação de algoritmos para uso clínico pode ser sujeita a programações que geram lucros acrescidos para os *stakeholders* envolvidos através da recomendação de medicamentos

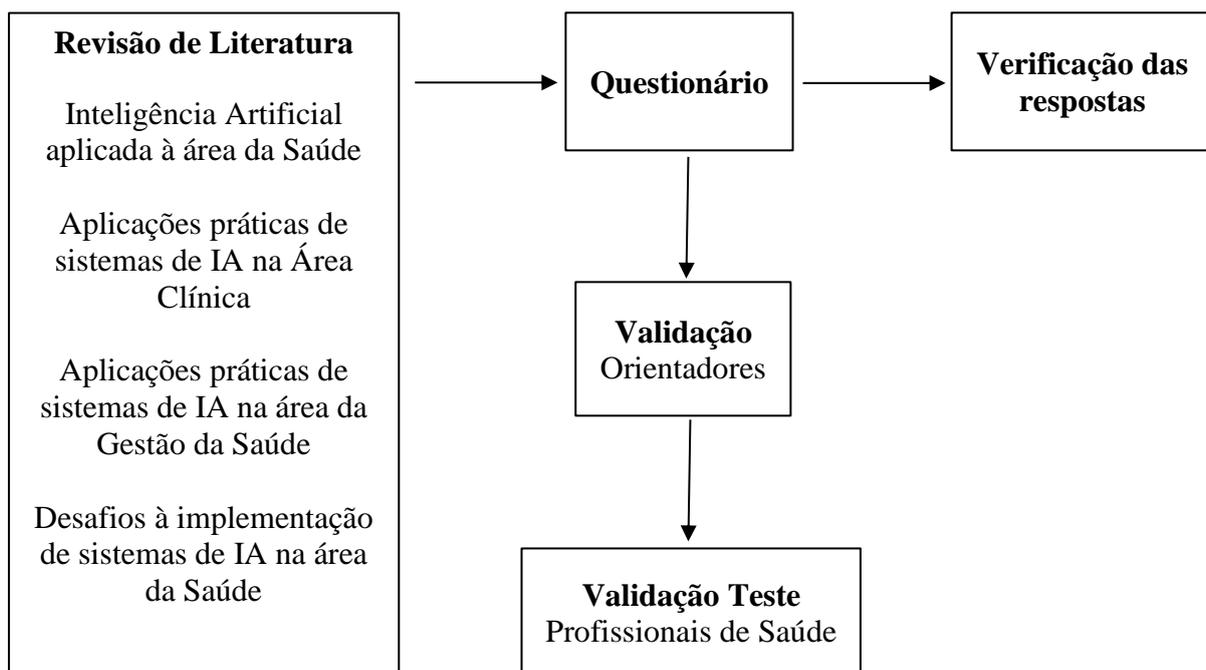
específicos ou dispositivos médicos nos quais as partes envolvidas detêm uma participação (Char *et al.*, 2018). Em determinadas situações e para diferentes *stakeholders* existem várias perspectivas sobre os problemas que se geram e por isso é necessário assegurar que os investigadores de IA agem de acordo com as normas necessárias à aplicação da mesma (Magrabi *et al.*, 2019). Os cientistas e investigadores de áreas como a *data science*, *data engineer*, ética, economia, direito e política devem estar envolvidos no desenvolvimento destas ferramentas para definir e perceber quais as medidas que promovem valores de justiça e igualdade, e com o objetivo de facilitar o processo de aceitação e integração de sistemas de IA na área da saúde (Chan & Zary, 2019).

Capítulo 3 – Metodologia

De acordo com Vilelas (2009), a metodologia de investigação tem como principal objetivo estudar o método científico que permite validar e confirmar uma dada teoria. De acordo com o autor, podemos classificar a metodologia de duas formas, quanto aos fins e quanto aos meios. Os fins dizem respeito à pesquisa aplicada de carácter exploratório, enquanto os meios estão relacionados com o estudo de campo e a pesquisa bibliográfica. Relativamente aos meios do presente estudo, como fonte primária o estudo contou com a aplicação de questionários, e como fonte secundária, a pesquisa bibliográfica que foi realizada através da análise de vários artigos científicos presentes em livros, jornais e revistas.

A partir dos objetivos do presente estudo, optou-se por realizar uma metodologia quantitativa através da criação de um questionário. Importa salientar que esta abordagem teve um carácter indutivo, uma vez que a mesma foi conduzida através de uma amostra não probabilística por conveniência, tendo em conta que o pretendido era obter uma amostra com membros da área da saúde e da área da gestão da saúde com interesse em IA. É igualmente importante referir que a amostra de natureza por conveniência faz com que a mesma esteja mais sujeita a ser influenciada por variáveis que não estão sob o controlo do investigador, não permitindo, dessa forma, que sejam feitas afirmações gerais e rigorosas sobre a população.

Figura 3.1: Modelo de investigação



Fonte: Elaboração do autor

Quanto à validade externa, este estudo veio reforçar alguma teoria já existente e aprofundar conhecimentos sobre o impacto que a Inteligência Artificial pode gerar na área da saúde. Na tabela 3.1 encontram-se descritos os objetivos de estudo e a respetiva questão de pesquisa, bem como, a metodologia escolhida e as secções do questionário relativas à questão de pesquisa.

Tabela 3.1: Relação entre revisão da literatura, questão de pesquisa e metodologia

Objetivo de Estudo	Questão de Pesquisa	Revisão de Literatura	Metodologia	Questões nos Inquéritos
Perceber os fatores que influenciam a possibilidade de aplicar sistemas inteligentes na área da saúde	Quais são os fatores que influenciam a intencionalidade de profissionais e gestores de saúde na implementação de sistemas de inteligência artificial de modo a promover uma maior eficiência e ganhos em saúde mais significativos?	(Nelson <i>et al.</i> , 2020) (Magrabi <i>et al.</i> , 2019) (Char <i>et al.</i> , 2018) (Letourneau <i>et al.</i> , 2020) (Dossou <i>et al.</i> , 2021) (Gerke, Minssen & Cohen, 2020) (Panch, Mattie & Celi, 2019) (Schwendicke <i>et al.</i> , 2020) (Asan <i>et al.</i> , 2020) (Fan <i>et al.</i> , 2018)	Abordagem quantitativa <i>SmartPLS</i>	Secção 2, Secção 3 e Secção 4 do questionário

Fonte: Elaboração do autor

3.1 Modelo de investigação

Para dar resposta ao objetivo do estudo, foi realizada uma abordagem quantitativa através da criação de um questionário. De acordo com Vilelas (2009), este é um método cuja finalidade pretende obter respostas padronizadas com perguntas fechadas e de fácil interpretação e é maioritariamente utilizada quando a unidade de análise são pessoas. Segundo Vilelas (2009), a aplicação de um questionário apresenta algumas vantagens ao nível de custos, tratamento de dados e redução da margem de erro.

O questionário apresentava uma secção com perguntas de identificação e perguntas de informação. O documento desenvolvido abordou os temas previamente descritos na revisão de literatura e foi estruturado com recurso à ferramenta *Google Forms*. Após validação do orientador foi avaliado e testado por três profissionais de saúde que sugeriram que uma das questões fosse reformulada. A validação por parte destes elementos procurou garantir que o questionário não detinha qualquer erro. Posteriormente, procedeu-se à partilha do documento através da rede *LinkedIn*.

O documento elaborado foi dividido em quatro secções, na primeira secção constava uma pergunta de resposta múltipla que tinha como objetivo realizar uma triagem inicial de forma a garantir que apenas pessoas ligadas à saúde ou gestão da saúde e com interesse na área da IA, pudessem avançar no questionário. A mesma secção possuía mais três questões para se proceder à caracterização do inquirido. As secções dois, três e quatro pretendiam responder à questão de pesquisa através de escalas tipo *Likert* com sete níveis, em que cada extremo teria uma posição contrária. As respostas foram recolhidas entre o dia 7 de Janeiro de 2021 e 7 de Fevereiro de 2022, onde foi possível obter 100 respostas. Seguidamente, os dados extraídos foram introduzidos em formato *Excel* na plataforma de *software SmartPLS 3*. Dessa forma, a questão de pesquisa - *Quais são os fatores que influenciam a intencionalidade de profissionais e gestores de saúde na implementação de sistemas de inteligência artificial de modo a promover uma maior eficiência e ganhos em saúde mais significativos?* - foi respondida através de uma metodologia quantitativa, nomeadamente, através da Modelagem de Equações Estruturais, *Structural Equations Modeling* (SEM).

No campo das ciências sociais tem-se verificado um crescimento exponencial da análise de dados no que ao desenvolvimento tecnológico e computacional diz respeito. O SEM é uma das técnicas de análise de dados mais estudadas ao longo dos últimos anos e a base do modelo é assente num método estatístico cada vez mais utilizado na área das ciências sociais pela

capacidade de conseguir explicar e prever comportamentos específicos de indivíduos, grupos ou organizações (Tarka, 2018). A técnica por de trás da metodologia SEM resulta da dicotomia entre um carácter exploratório e preditivo. Adicionalmente, o software *user-friendly*, *SmartPLS*, requer poucos conhecimentos técnicos para o desenvolvimento e teste do modelo (Hair *et al*, 2019). Esta metodologia permite estimar de que forma se estabelecem relações de causalidade, definidas a partir de um único modelo. O objetivo passa por poder analisar a complexidade de um sistema através de um conjunto de conceitos e indicadores obtidos com as Variáveis Latentes e as Variáveis Observadas/Manifestadas (Civelek, 2018). A metodologia desenvolvida permite realizar uma análise de dados multivariados e estudar em simultâneo o comportamento de múltiplas variáveis.

O SEM representa o elo de ligação entre o *Path Analysis* (PA) e o *Confirmatory Factor Analysis* (CFA). O CFA tem por base a ideia de que um conjunto de variáveis se pode expressar de maneira diferente para o mesmo conceito, por outro lado, o PA é constituído por um modelo que avalia a relação entre as variáveis medidas de uma forma direta ou indireta.

A abordagem por *Partial Least Squares* (PLS-SEM), também conhecida por *Path Modeling* procura maximizar a variância, abordagem *Variance-based*, explicada entre as variáveis dependentes do modelo e é utilizada num contexto de pesquisa exploratória. Com as relações lineares estabelecidas é possível estudar as ligações complexas entre as variáveis latentes e as variáveis observadas. Para simplificar esta análise, é possível realizar uma representação gráfica a partir de um diagrama denominado de *Path Model* (PL) (Civelek, 2018).

A medição dos constructos latentes é realizada indiretamente, principalmente com o uso de um conjunto de variáveis observáveis e através da observação dos efeitos causais na SEM entre as respetivas variáveis latentes (Tarka, 2018). De acordo com esta abordagem há duas etapas que importa destacar. A primeira testa a credibilidade, a carga fatorial e a qualidade do ajuste para cada escala do estudo. A segunda etapa foca-se no modelo estrutural e na relação entre constructos, descrevendo os detalhes de cada um no modelo (Tarka, 2018).

A SEM é uma ferramenta que permite medir o efeito direto ou indireto da variável explicativa na dependente, enquanto a análise fatorial não consegue estabelecer essas relações de causalidade (Civelek, 2018). De acordo com Hair *et al.* (2019), os motivos que explicam o crescimento na procura de modelos de PLS-SEM deve-se à capacidade que esta metodologia tem para entender a complexidade inerente aos modelos que incluem vários constructos, indicadores e possíveis relações entre esses indicadores, sem impor uma determinada distribuição aos dados, e ao facto de os modelos de equações estruturais terem em particular

consideração os erros de medição (Hair *et al.*, 2019).

A metodologia PLS-SEM não se limita a reconhecer fatores ou comportamentos individuais como também procura determinar os vínculos de causa-efeito entre as áreas científicas de interesse, bem como, compreender a complexidade inerente à realidade social (Tarka, 2018). A SEM é usada para testar os modelos dos mínimos quadrados parciais e é assente numa técnica de modelagem de equações estruturais baseada na variância. Para proceder a essa análise recorreu-se ao software *SmartPLS 3* (Tarka, 2018). Para chegar à fase de interpretação dos resultados avaliou-se, numa primeira instância, a confiabilidade e a validade do modelo de medição e posteriormente, procedeu-se à avaliação do modelo estrutural. Para avaliar a qualidade do modelo de medição, foram avaliados os seguintes critérios: indicadores individuais de confiabilidade, validade convergente, confiabilidade de consistência interna e validade discriminante (Hair *et al.*, 2019).

Nas seguintes figuras é possível analisar detalhadamente a informação que integrou o modelo conceptual criado para responder a esta questão de pesquisa. De acordo com o mesmo, foram formuladas as seguintes hipóteses:

H1a - Os benefícios gerados pelos sistemas inteligentes impactam positivamente a intenção de implementar este tipo de sistemas

H1b - Os benefícios gerados pelos sistemas inteligentes impactam positivamente a percepção e conhecimento sobre sistemas inteligentes

H2a - Os desafios associados à utilização de sistemas inteligentes impactam negativamente a intenção de implementar este tipo de sistemas

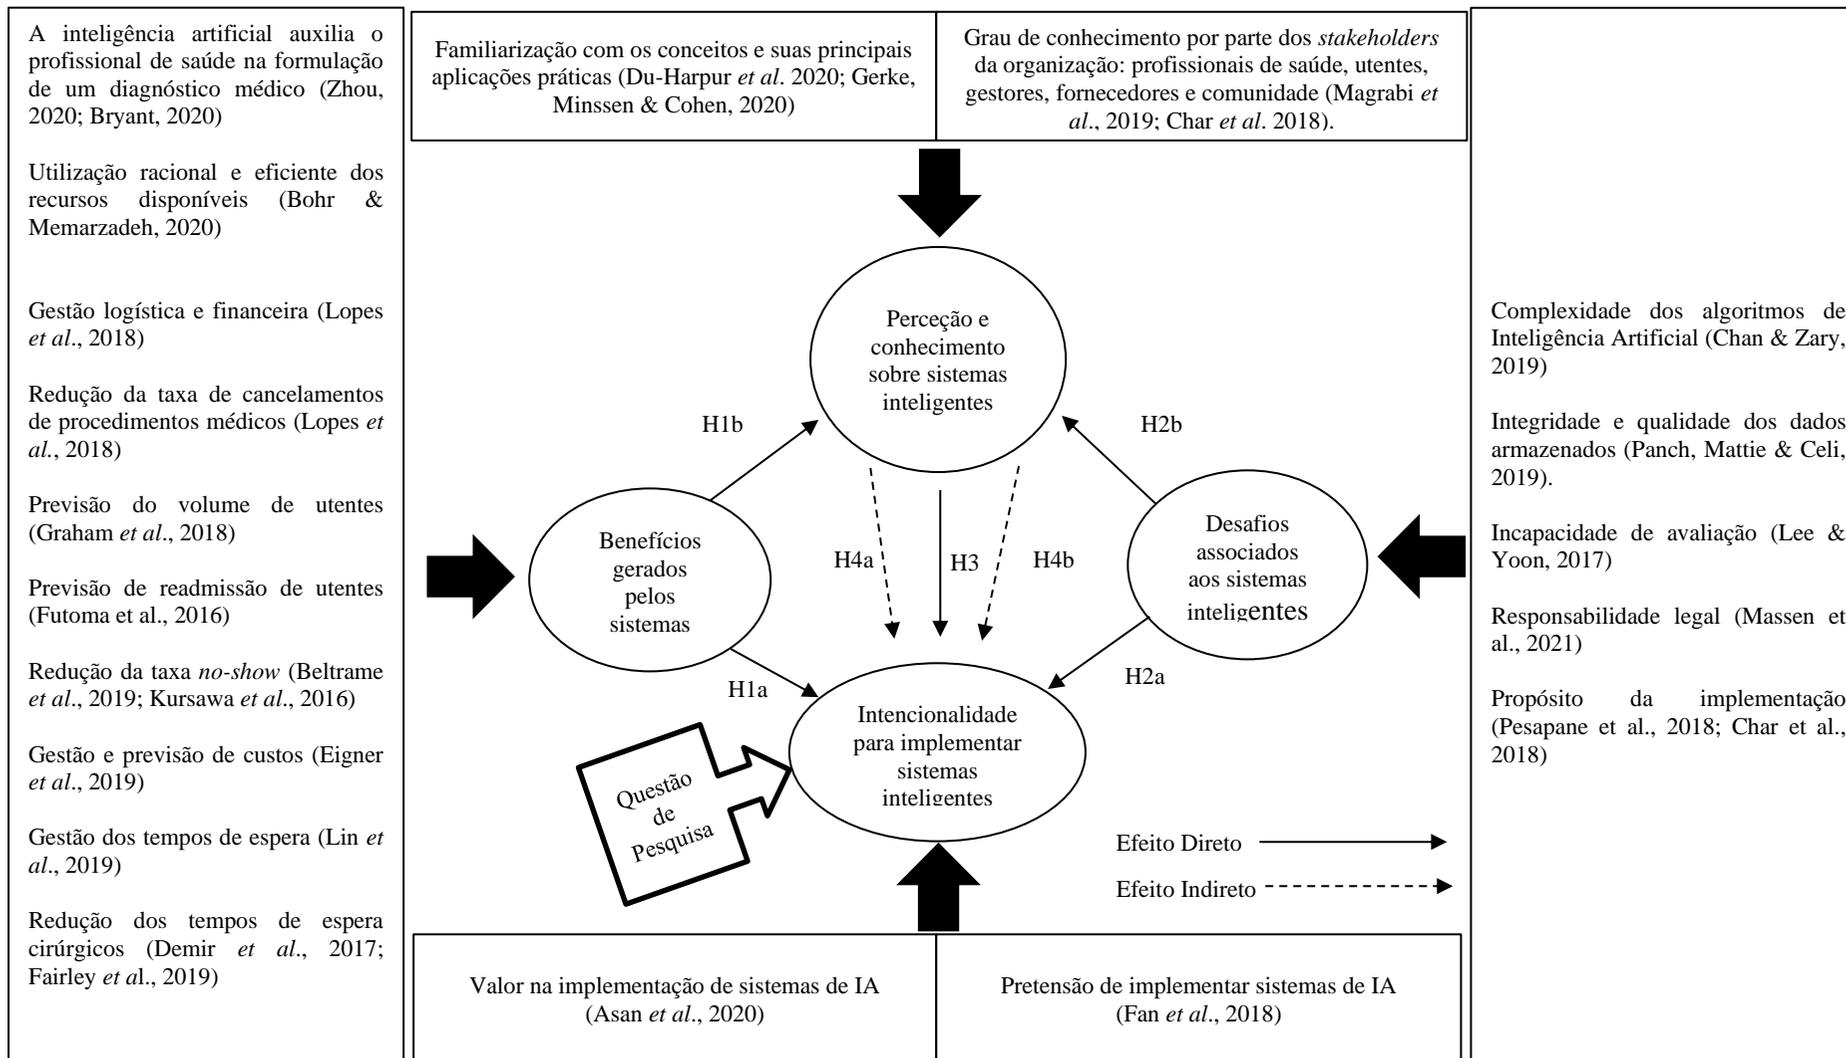
H2b - Os desafios associados à utilização de sistemas inteligentes impactam negativamente a percepção e conhecimento sobre sistemas inteligentes

H3 - A percepção e conhecimento sobre sistemas inteligentes impacta positivamente a intenção de implementar este tipo de sistemas

H4a - A percepção e conhecimento sobre sistemas inteligentes media o efeito entre os benefícios gerados pelos sistemas inteligentes e a intenção de implementar este tipo de sistemas

H4b - A percepção e conhecimento sobre sistemas inteligentes media o efeito entre os desafios associados à utilização de sistemas inteligentes e a intenção de implementar este tipo de sistemas

Figura 3.1.1: Modelo conceptual e hipóteses a testar com o *SmartPLS 3*



Fonte: Elaboração do autor

Tabela 3.1.1: Relação entre as variáveis do modelo conceptual e as perguntas do questionário

Variável independente	Indicador	Pergunta do questionário (respostas de 1 a 7)
Perceção e conhecimento sobre sistemas inteligentes	Familiarização com os conceitos e suas principais aplicações práticas (Du-Harpur <i>et al.</i> 2020; Gerke, Minssen & Cohen, 2020)	Está familiarizado com o conceito de Inteligência Artificial?
		Tem conhecimento de aplicações práticas de Inteligência Artificial na área da saúde?
		A sua entidade empregadora fomenta o desenvolvimento de ferramentas de Inteligência Artificial?
		Conhece o conceito e as aplicações práticas de <i>Machine Learning</i> ?
		Conhece o conceito e as aplicações práticas de <i>Deep Learning</i> ?
	Grau de conhecimento por parte dos <i>stakeholders</i> da organização: profissionais de saúde, utentes, gestores, fornecedores e comunidade (Magrabi <i>et al.</i> , 2019; Char <i>et al.</i> 2018).	Qual a sua perceção/avaliação sobre o grau de conhecimento de sistemas inteligentes por parte dos profissionais de saúde da sua organização?
		Qual a sua perceção/avaliação sobre o grau de conhecimento de sistemas inteligentes por parte dos utentes da sua organização?
		Qual a sua perceção/avaliação sobre o grau de conhecimento de sistemas inteligentes por parte dos gestores da sua organização?
		Qual a sua perceção/avaliação sobre o grau de conhecimento de sistemas inteligentes por parte dos fornecedores da sua organização?
		Qual a sua perceção/avaliação sobre o grau de conhecimento de sistemas inteligentes por parte da comunidade na qual a sua organização se insere?
Benefícios gerados pelos sistemas inteligentes	A inteligência artificial auxilia o profissional de saúde na formulação de um diagnóstico médico (Zhou, 2020; Bryant, 2020).	A inteligência artificial permite reduzir o tempo de realização de tarefas médicas através da interpretação de imagens médicas.
	Utilização racional e eficiente dos recursos disponíveis (Bohr & Memarzadeh, 2020).	Os sistemas inteligentes permitem diminuir o desperdício e custos associados com tratamentos ineficazes e respetivos efeitos secundários.

Melhorar a gestão logística e financeira (Lopes <i>et al.</i> , 2018).	Os sistemas inteligentes permitem realizar previsões sobre as necessidades hospitalares e coordenar os encargos com medicamentos, dispositivos médicos e materiais.
Redução da taxa de cancelamentos de determinados procedimentos médicos (Lopes <i>et al.</i> , 2018).	Os sistemas inteligentes previnem o cancelamento de determinados procedimentos através da monitorização e controlo de todo o ciclo de stocks.
Previsão do volume de utentes (Graham <i>et al.</i> , 2018).	Os sistemas inteligentes permitem prever a taxa de admissão de utentes para um determinado período.
Previsão de readmissões de utentes (Futoma <i>et al.</i> , 2016).	Os sistemas inteligentes permitem avaliar o risco de readmissão de utentes.
Redução da taxa <i>no-show</i> (Beltrame <i>et al.</i> , 2019; Kursawa <i>et al.</i> , 2016)	Os sistemas inteligentes permitem prever quais os utentes com maior probabilidade de não comparecerem às suas consultas sem aviso prévio.
Gestão de custos (Eigner <i>et al.</i> , 2019)	Os sistemas inteligentes permitem prever quais os utentes que apresentam um risco acrescido de apresentarem custos mais elevados associados a um maior nível de cuidados.
Gestão de tempos de espera (Lin <i>et al.</i> , 2019).	Os sistemas inteligentes permitem estimar com maior precisão os tempos de espera para determinados tipos de consulta

	Redução dos tempos de espera cirúrgicos (Demir et al., 2017; Fairley et al., 2019).	Os sistemas inteligentes permitem estimar o tempo de permanência dos utentes nas unidades cirúrgicas a fim de programar o agendamento cirúrgico com maior eficiência.
Desafios associados aos sistemas inteligentes	Complexidade dos algoritmos de Inteligência Artificial (Chan & Zary, 2019)	A inexistência de <i>know-how</i> interno faz com que a adoção de sistemas inteligentes seja condicionada.
	Integridade e qualidade dos dados armazenados (Panch, Mattie & Celi, 2019).	As diferentes formas como os profissionais de saúde registam os dados condiciona a integridade e qualidade dos dados armazenados.
	Incapacidade de avaliação (Lee & Yoon, 2017)	A incapacidade para avaliar o progresso de adoção de sistemas inteligentes dificulta o processo de adoção desses sistemas.
	Responsabilidade legal (Massen et al., 2021)	Existe uma grande preocupação por parte dos profissionais de saúde no que toca a potenciais violações de questões éticas e de privacidade dos seus dados.
	Propósito da implementação (Pesapane et al., 2018; Char et al., 2018)	A criação de algoritmos que geram lucros para os <i>stakeholders</i> envolvidos através da recomendação de medicamentos específicos ou dispositivos médicos nos quais as partes envolvidas detêm uma participação podem representar um problema grave para a implementação de sistemas inteligentes na área da saúde.
Variável dependente	Indicador	Pergunta do questionário (respostas de 1 a 7)
Intencionalidade para implementar sistemas inteligentes	Valor na implementação de sistemas de IA (Asan et al., 2020)	Na minha opinião, há valor na implementação de sistemas de IA na área da saúde.
	Pretensão de implementar sistemas de IA (Fan et al., 2018)	Pretendo implementar sistemas de IA na área da saúde.

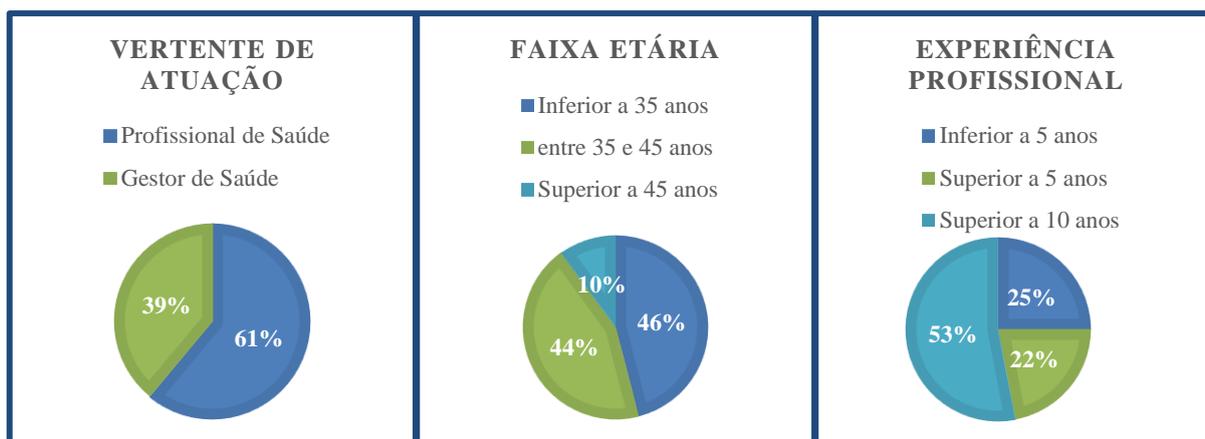
Fonte: Elaboração do autor

3.2 Caracterização da Amostra

A amostra recolhida conta com a resposta de 100 inquiridos. Numa fase inicial procedeu-se à análise das variáveis que pudessem caracterizar a amostra quanto à sua atividade profissional, faixa etária e experiência profissional. No final, realizou-se uma análise quantitativa das respostas de modo a obter os dados necessários para se retirarem conclusões teóricas e empíricas.

De um total de 100 inquiridos, 61% são profissionais de saúde e 39% desempenham cargos de gestão na área da saúde. Relativamente à faixa etária, 46% dos inquiridos têm uma idade inferior a 35 anos, 44% uma idade compreendida entre 35 e 45 anos e 10% uma idade superior a 45 anos. No que há experiência profissional diz respeito, 25% dos inquiridos possui uma experiência profissional inferior a 5 anos, 22% possui uma experiência profissional superior a 5 anos e 53% possui uma experiência profissional superior a 10 anos.

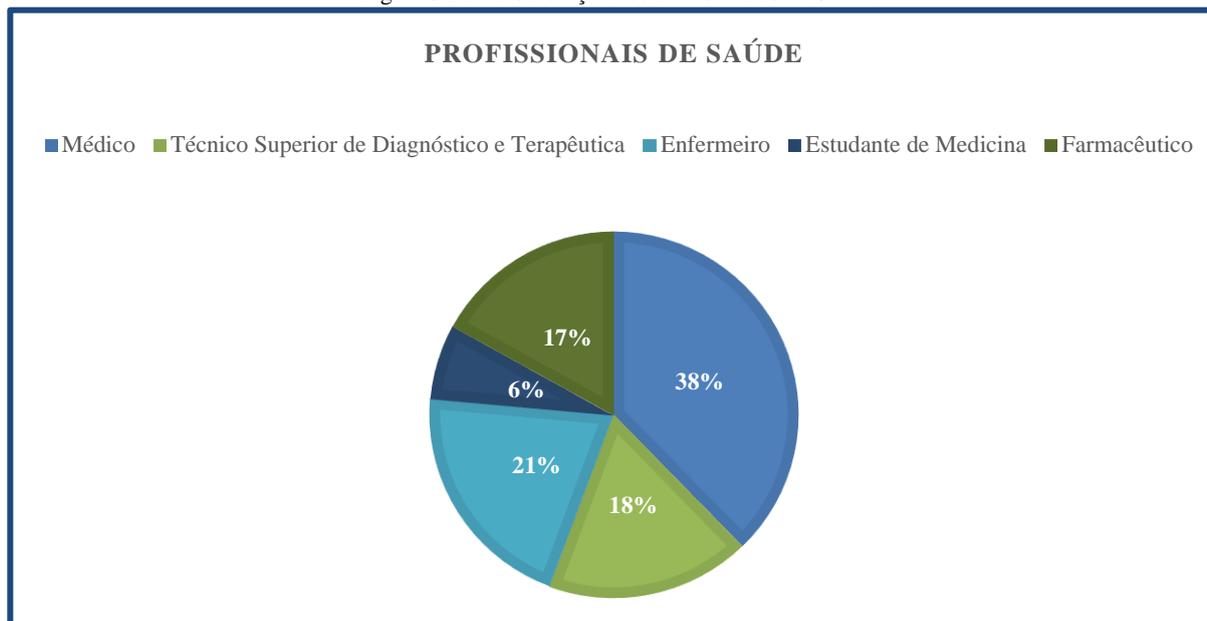
Figura 3.2.1: Caracterização da Amostra



Fonte: Elaboração do autor

Na vertente dos profissionais de saúde 38% destes profissionais de saúde são médicos, 18% são técnicos superiores de diagnóstico e terapêutica, 21% são enfermeiros, 6% são estudantes de medicina e 17% são farmacêuticos.

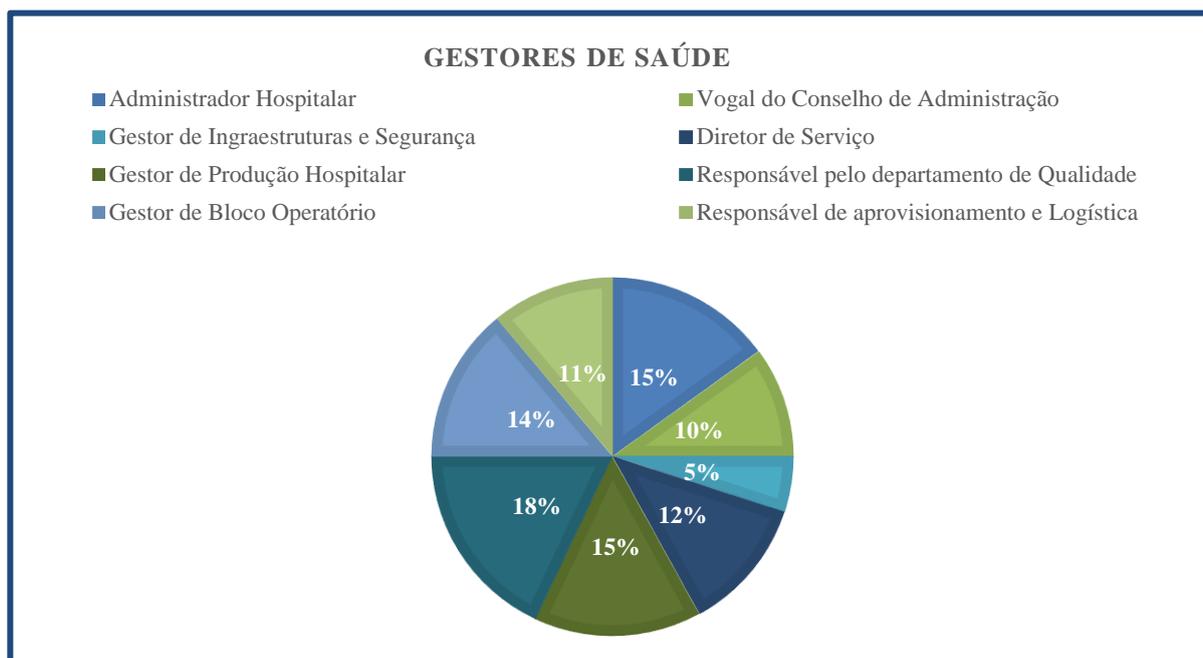
Figura 3.2.2: Distribuição dos Profissionais de Saúde



Fonte: Elaboração do autor

Relativamente à vertente de gestão, 15 % dos inquiridos são administradores hospitalares, 10% são vogais do conselho de administração hospitalar, 5% são gestores de infraestruturas e segurança, 12% diretores de serviços, 15% são gestores de produção hospitalar, 28% são responsáveis pelo departamento de qualidade, 14% são gestores de bloco operatório e 11% desempenham funções de aprovisionamento e logística.

Figura 3.2.3: Distribuição dos Gestores de Saúde



Fonte: Elaboração do autor

Capítulo 4 – Apresentação e discussão de resultados

4.1 Apresentação dos resultados

Os resultados obtidos neste capítulo pretendem dar resposta à questão de pesquisa previamente formulada - *Quais são os fatores que influenciam a intencionalidade de profissionais e gestores de saúde na implementação de sistemas de inteligência artificial de modo a promover uma maior eficiência e ganhos em saúde mais significativos?*

Através de uma abordagem com duas fases distintas foi possível realizar a análise e interpretação dos resultados obtidos. Para dar resposta à questão anteriormente referida recorreu-se à metodologia SEM-PLS através da qual terá sido testado o grau de confiabilidade e a validade do modelo de medição. Posteriormente foi realizada a avaliação do modelo estrutural (Tarka, 2018). Os indicadores individuais que permitem avaliar a qualidade do modelo de medição foram quatro, nomeadamente, confiabilidade composta, validade convergente, confiabilidade de consistência interna e validade discriminante (Hair *et al.*, 2019).

Os resultados obtidos demonstraram que as cargas fatoriais padronizadas apresentaram um valor aproximado ou superior a 0,6 e foram significativas quando $p < 0,05$, o que demonstra a confiabilidade dos indicadores individuais (Hair *et al.*, 2019). A confiabilidade interna foi confirmada uma vez que todos os valores da confiabilidade composta dos constructos apresentaram um valor superior a 0.7 (Hair *et al.*, 2019), conforme representado na Tabela 4.

Tabela 4.1.1: Verificações de CR, AVE, correlações e validade discriminante

	CA	CR	AVE	Benefícios	Desafios	Intencionalidade	Perceção
Benefícios	0,951	0,958	0,696	0,834	0,604	0,765	0,395
Desafios	0,688	0,798	0,452	0,516	0,672	0,608	0,259
Intencionalidade	0,723	0,880	0,785	0,639	0,445	0,886	0,526
Perceção	0,873	0,890	0,456	0,428	0,152	0,478	0,675

CA - Cronbach's Alpha CR - Composite Reliability AVE - Average Variance. Os números a negrito na diagonal representam a raiz quadrada de AVE. Abaixo dos elementos diagonais estão as correlações entre os constructos. Acima dos elementos diagonais estão valores de *HTMT*.

Fonte: Elaboração do autor

De acordo com a tabela é possível verificar que a validade convergente foi confirmada por respeitar os valores mínimos para os três critérios (Tarka, 2018). O primeiro critério necessita que todos os itens apresentem valores positivos e significativos, como é de facto observável (Hair *et al.*, 2019). Para que o segundo critério seja devidamente validado, todos os construtos devem ter valores de confiabilidade composta (CR) superiores a 0,70, o que também se verifica (Hair *et al.*, 2019). O último critério, variância média extraída (AVE), encontra-se representado na diagonal da tabela a negrito e deve ter um valor aproximado ou superior a 0,50 (Hair *et al.*, 2019).

Relativamente à validade discriminante esta foi avaliada através de duas abordagens. Numa fase inicial foi usado o critério de Fornel e Lacker (1981), que requer que o valor da raiz quadrada de AVE seja superior face ao valor da maior correlação estabelecida entre constructos, critério esse que é devidamente cumprido como se pode observar na tabela. Posteriormente recorreu-se ao critério do rácio HTMT, *heterotrait-monotrait ratio*. De acordo com Hair *et al.* (2019), esses valores devem ser menores que 0,85 para que o modelo seja mais robusto quanto à sua validade discriminante, valores esses que se refletem também no quadro acima.

Antes de efetuar a avaliação do modelo estrutural, foi verificada a colinearidade. Concluiu-se que todos os itens do modelo estrutural não apresentaram colinearidade entre si, pois os valores de VIF variaram entre 1,303 e 4,313, que está abaixo do valor crítico indicativo de 5 proposto por Hair *et al.* (2019). No que à avaliação do modelo estrutural diz respeito, foram considerados três pontos principais. Numa primeira instância, o sinal, magnitude, e a significância dos coeficientes de trajetória estrutural foram analisados. Posteriormente foi avaliada a magnitude do valor de R^2 para cada uma das variáveis endógenas como uma medida de precisão preditiva do modelo. Por fim, através dos valores de Q^2 de Stone-Geisser foi avaliada a dimensão da relevância preditiva do modelo (Hair *et al.*, 2019). Os valores para R^2 , coeficiente de determinação para as variáveis endógenas, “Perceção e conhecimento sobre sistemas inteligentes” e “Intencionalidade de implementar sistemas inteligentes” foram de 17,3%, e 46,8%, respetivamente, valor esse que é superior ao valor mínimo de 10% (Falk, 2014). Os valores de Q^2 de Stone-Geisser para cada variável endógena, 0,063 e 0,349 respetivamente, demonstraram estar acima de zero, indicando a relevância preditiva do modelo (Hair *et al.*, 2019).

Como foi referido anteriormente, através do SEM é possível medir o efeito direto ou indireto das variáveis. A tabela seguinte ilustra de que forma se estabelecem essas relações.

Tabela 4.1.2: Relações diretas

	<i>Path Coefficient</i>	<i>Standard Errors</i>	<i>T Statistics</i>	<i>p-value</i>
Benefícios -> Intencionalidade	0,431	0,102	4,221	0,000
Benefícios -> Percepção	0,476	0,102	4,687	0,000
Desafios -> Intencionalidade	0,182	0,093	1,958	0,037
Desafios-> Percepção	-0,094	0,129	0,728	0,467
Percepção-> Intencionalidade	0,266	0,087	3,070	0,002

Fonte: Elaboração do autor

Os resultados representados na Tabela 4.1 demonstram que os benefícios gerados pelos sistemas inteligentes têm um efeito significativamente positivo na intenção de implementar estes sistemas na área da saúde ($\beta=0,431$, $p<0,05$), bem como na percepção associada a este tipo de tecnologias ($\beta=0,476$, $p<0,05$) resultados estes que vêm comprovar as hipóteses H1a e H1b, respetivamente.

Através da Tabela 4.1 é também possível verificar que, ao contrário do que os autores defendem, os desafios na implementação deste tipo de sistemas têm uma relação significativamente positiva em relação à intenção de os aplicar, demonstrando que os desafios identificados não são vistos como uma barreira face à intenção de aplicar sistemas de IA na área da saúde ($\beta=0,182$, $p<0,05$) Dessa forma, a hipótese H2a é rejeitada.

Relativamente à hipótese H2b, não é possível determinar se os desafios associados à utilização de sistemas inteligentes impactam negativamente a percepção e conhecimento sobre sistemas inteligentes, uma vez que a hipótese testada não é estatisticamente significativa por apresentar um valor de *p-value* superior a 0,05 ($\beta=-0,025$, $p\ value=0,448$). Dessa forma, não é possível comprovar a hipótese H2b.

Por fim, pode-se comprovar pelos números da Tabela 4.1 que a percepção e conhecimento sobre sistemas inteligentes tem uma relação significativamente positiva com a intenção de implementar os mesmos sistemas ($\beta=0,266$, $p<0,05$), suportando assim a hipótese H3.

Com o intuito de testar as hipóteses de mediação (H4a e H4b) e com o recurso à ferramenta *SmartPLS 3*, procedeu-se ao método *bootstrapping* para testar o nível de significância dos efeitos indiretos através de um mediador (Tarka, 2018). Na Tabela 4.2 encontram-se representados os efeitos da mediação.

Tabela 4.1.3: Relações indiretas

	<i>Path Coefficient</i>	<i>Standard Errors</i>	<i>T Statistics</i>	<i>p-value</i>
Benefícios -> Percepção -> Intencionalidade	0,127	0,041	3,085	0,002
Desafios -> Percepção-> Intencionalidade	-0,025	0,034	0,743	0,458

Fonte: Elaboração do autor

Através da tabela é possível verificar que os efeitos indiretos dos benefícios gerados pelos sistemas inteligentes na intenção de implementar este tipo de sistemas através do mediador, percepção e conhecimento, têm uma relação significativamente positiva ($\beta=0,127$, $p<0,05$), dando suporte à hipótese H4a.

De acordo com a mesma tabela, não é possível determinar se a percepção e conhecimento sobre sistemas inteligentes media o efeito entre os desafios associados à implementação de sistemas inteligentes e a intenção de os implementar, uma vez que a hipótese testada não é estatisticamente significativa por apresentar um valor de *p-value* superior a 0,05 ($\beta=-0.025$, *P Value*=0,458). Dessa forma, não é possível comprovar a hipótese H4b.

Dando seguimento à análise de resultados, é possível verificar quais das hipóteses de modelo de pesquisa foram aceites. A Tabela 4.3 apresenta de forma sintetizada, o valor de β e a sua significância estatística para cada uma das hipóteses testadas, dando suporte à decisão de aceitar ou rejeitar cada uma das hipóteses.

Tabela 4.1.4: Teste de Hipóteses

Hipóteses	β	P Value	Aceite / Rejeitada
H1a - Os benefícios gerados pelos sistemas inteligentes impactam positivamente a intenção de implementar este tipo de sistemas	0,431	0,000	Aceite
H1b - Os benefícios gerados pelos sistemas inteligentes impactam positivamente a percepção e conhecimento sobre sistemas inteligentes	0,476	0,000	Aceite
H2a - Os desafios associados à utilização de sistemas inteligentes impactam negativamente a intenção de implementar este tipo de sistemas	0,182	0,037	Rejeitada
H2b - Os desafios associados à utilização de sistemas inteligentes impactam negativamente a percepção e conhecimento sobre sistemas inteligentes	-0,094	0,467	Não foi possível comprovar (para $\alpha < 0,05$)
H3 - A percepção e conhecimento sobre sistemas inteligentes impacta positivamente a intenção de implementar este tipo de sistemas	0,266	0,002	Aceite
H4a - A percepção e conhecimento sobre sistemas inteligentes media o efeito entre os benefícios gerados pelos sistemas inteligentes e a intenção de implementar este tipo de sistemas	0,127	0,002	Aceite
H4b - A percepção e conhecimento sobre sistemas inteligentes media o efeito entre os desafios associados à utilização de sistemas inteligentes e a intenção de implementar este tipo de sistemas	-0,025	0,458	Não foi possível comprovar (para $\alpha < 0,05$)

Fonte: Elaboração do autor

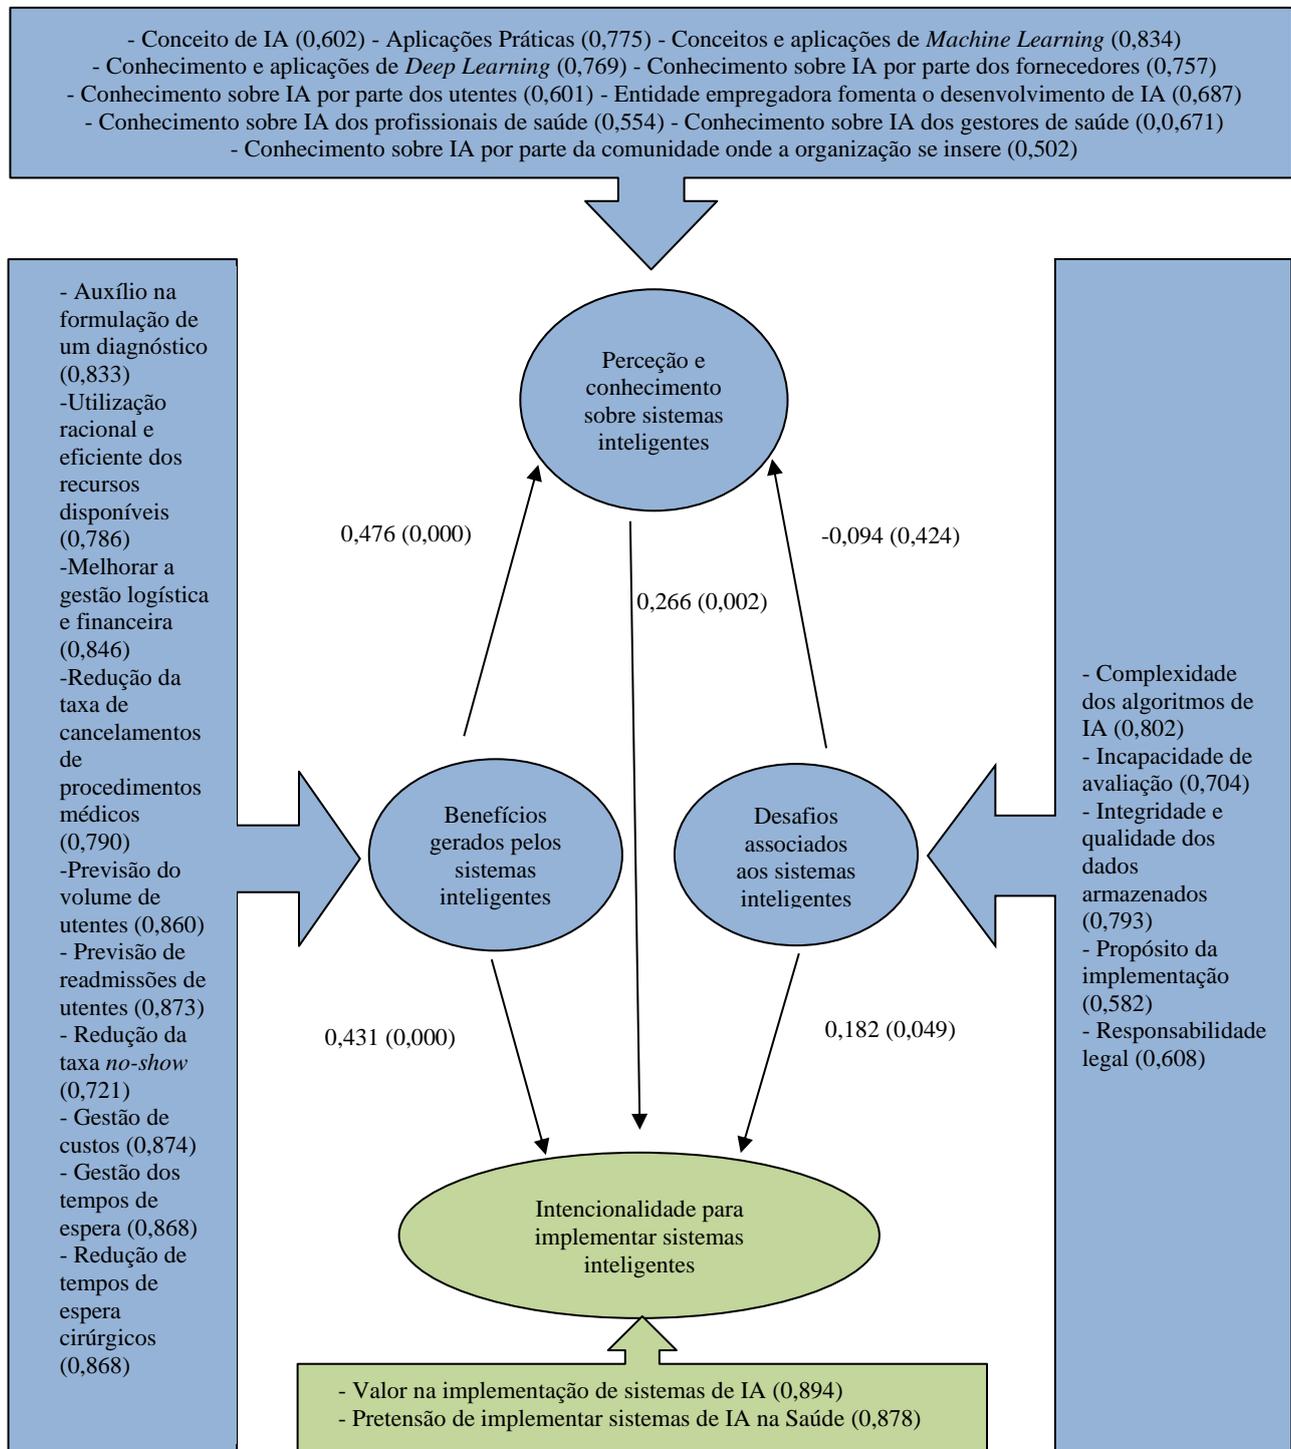
4.2 Discussão dos Resultados

Como é visível na figura 3.1.2, o modelo concetual foi submetido a vários testes com recurso à ferramenta *SmartPLS 3*. De acordo com a figura do modelo, foram identificados três fatores que fomentam a possibilidade de implementar sistemas de IA na área da saúde, nomeadamente, a percepção e conhecimento sobre sistemas inteligentes (Char *et al.*, 2018; Magrabi *et al.*, 2019; Nelson *et al.*, 2020), os benefícios gerados pelos sistemas inteligentes (Letourneau *et al.*, 2020; Dossou *et al.*, 2021) e os desafios associados à implementação de sistemas inteligentes (Gerke, Minssen & Cohen, 2020; Panch, Mattie & Celi, 2019).

De forma a chegar aos três fatores identificados, os indicadores de cada um dos fatores

foram avaliados individualmente através do questionário. Na grande maioria, os indicadores demonstraram ser relevantes para o estudo, ao obter pontuações acima de 0,6, o que nos diz que os indicadores escolhidos são indicadores confiáveis quando $p < 0,05$ (Hair *et al.*, 2019).

Figura 4.2.1: Modelo conceptual testado com o *SmartPLS 3* com valores associados



Fonte: Elaboração do autor

Relativamente à perceção e conhecimento sobre sistemas inteligentes, os resultados mostraram que estes são maioritariamente suportados pela familiarização com os conceitos que os inquiridos possuem (Nelson *et al.*, 2020; Du-Harpur *et al.*, 2020; Gerke, Minssen & Cohen, 2020) e o conhecimento que os vários *stakeholders* têm sobre os sistemas de IA (Magrabi *et al.*, 2019).

Os benefícios gerados pelos sistemas inteligentes também demonstraram estar alinhados com as teorias que os autores defendem, na medida em que os benefícios principais passam por aumentar a produtividade através da priorização de casos (Bryant, 2020), utilizar os recursos disponíveis de forma racional e eficiente (Bohr & Memarzadeh, 2020), melhorar a gestão logística e financeira (Lopes *et al.*, 2018), reduzir a taxa de cancelamentos de determinados procedimentos médicos (Lopes *et al.*, 2018); prever o volume de utentes (Graham *et al.*, 2018), prever o nível de readmissões de utentes (Futoma *et al.*, 2016); reduzir a taxa *no-show* (Beltrame *et al.*, 2019; Kursawa *et al.*, 2016), gerir custos (Eigner *et al.*, 2019), gerir tempos de espera (Lin *et al.*, 2019) e reduzir os tempos de espera cirúrgicos (Demir *et al.*, 2017; Fairley *et al.*, 2019).

Por fim, o resultado dos desafios gerados pela implementação de sistemas inteligentes não se encontra em total concordância com os autores estudados. De acordo com o modelo conceptual, o nível de confiança dos profissionais de saúde (Massen *et al.*, 2021), o nível de perceção e aceitação dos utentes, bem como, a confiabilidade dos mesmos (Zhang *et al.*, 2021), a violação de questões éticas e de privacidade (Gerke, Minssen & Cohen, 2020; Massen *et al.*, 2021) e a atitude dos estudantes de medicina face aos sistemas de IA (Sit *et al.*, 2020) demonstraram ser pouco significativos no momento de influenciar a intencionalidade de gestores e profissionais de saúde no processo de implementação de sistemas inteligentes pelo que foram excluídos do modelo.

Após se encontrarem identificadas as três categorias com impacto na intencionalidade de implementar sistemas de IA na área da saúde, procedeu-se à testagem das hipóteses comprovadas. Relativamente aos efeitos diretos, os resultados demonstram que os benefícios gerados pelos sistemas inteligentes impactam positivamente a intenção de gestores e profissionais de saúde implementarem estes sistemas, confirmando a hipótese H1a do presente estudo. De acordo com os autores estudados, os benefícios que os sistemas de IA aportam, quer seja em termos de prática clínica, através do auxílio na formulação de diagnósticos (Letourneau *et al.*, 2020), ou em termos de gestão de saúde (Dossou *et al.*, 2021), através do planeamento logístico e da otimização dos recursos disponíveis, aumentam a probabilidade destes profissionais virem a adotar sistemas inteligentes.

De modo adicional, é possível afirmar com base nos resultados, que os benefícios gerados pelos sistemas inteligentes impactam positivamente a percepção e conhecimento sobre este tipo de tecnologias, vindo assim confirmar igualmente a hipótese H1b. Esta hipótese reflete a importância de tornar público os avanços que os sistemas de IA têm vindo a causar na área da saúde, servindo de estímulo para que a comunidade científica, nos quais se inserem estes profissionais, possa aprofundar conhecimentos para promover a utilização destas tecnologias em instituições de saúde portuguesas (Nelson *et al.*, 2020).

Relativamente aos desafios associados à implementação de sistemas inteligentes, os resultados não suportam o que os autores defendem (Panch, Mattie & Celi, 2019; Gerke, Minssen & Cohen, 2020). Ou seja, seria de esperar que os desafios fossem um obstáculo face à intenção de implementar sistemas de IA, contudo, tal não se verifica. De acordo com os resultados obtidos, os desafios não constituem uma barreira para a intenção de adotar estes sistemas. A rejeição da hipótese H2a demonstra que os desafios identificados pelos utilizadores não diminuem os incentivos para a utilização de sistemas de IA. De acordo com Schwendicke *et al.* (2020), apesar de se reconhecerem vários desafios face à implementação destes sistemas, os autores acreditam que a IA tem potencial para revolucionar a área da saúde e ultrapassar as preocupações relativas à proteção e segurança dos dados, bem como, auxiliar gestores e profissionais de saúde a tomar decisões que promovam melhores cuidados de saúde.

Em relação ao impacto que a percepção e conhecimento gera sobre a intenção de implementar sistemas de IA, foi possível comprovar através dos resultados que quanto maior for o nível de conhecimentos por parte de todos os *stakeholders*, maior é a intenção de se implementarem sistemas inteligentes. De acordo com Magrabi *et al.* (2019), é necessário envolver os vários *stakeholders*, nomeadamente, enfermeiros, médicos, informáticos, matemáticos, gestores e investidores, no processo de implementação de uma ferramenta de IA. Torna-se por isso fulcral estabelecer pontes de comunicação de maneira que todos percebam o que está a ser realizado (Char *et al.*, 2018).

Por fim, tendo em conta os efeitos indiretos dos benefícios gerados pelos sistemas inteligentes na intenção de os implementar, por meio do mediador percepção e conhecimento, os resultados mostraram que o impacto gerado é positivo, vindo assim confirmar a hipótese de mediação H4b. Dessa forma, é possível afirmar que o aumento dos benefícios, têm a capacidade de suscitar interesse por parte das pessoas e impulsionar as mesmas a aprofundar conhecimentos sobre este tipo de tecnologias, e com isso, impactar positivamente a intenção de avançar para a sua implementação (Asan *et al.*, 2020). De acordo com Fan *et al.* (2018), a

expectativa face à *performance* dos sistemas inteligentes e a confiança inicial que é depositada nos sistemas inteligentes impactam a intenção de adotar essas tecnologias. O mesmos autores afirmam que as pessoas que têm maiores níveis de confiança face à IA, são precisamente as pessoas que têm uma maior percepção sobre estas matérias e que acabam por demonstrar maior intenção de implementar ferramentas de IA.

Capítulo 5 – Conclusão

5.1 Considerações Finais

Com a pesquisa realizada foi possível demonstrar de que forma a IA pode causar um impacto positivo na área da saúde. A questão desenvolvida a partir da revisão de literatura procurou entender quais são os fatores que contribuem para que profissionais e gestores de saúde possam implementar ferramentas de IA. As variáveis identificadas foram divididas em três grupos, nomeadamente, a percepção e conhecimento sobre sistemas inteligentes, os benefícios gerados pelos sistemas inteligentes e os desafios associados à implementação desses sistemas.

Por sua vez, as respostas ao questionário permitiram retirar algumas conclusões sobre a possibilidade de implementar sistemas inteligentes na área da saúde e discutir de acordo, com os autores encontrados, quais os principais benefícios e desafios encontrados, em função da percepção e do conhecimento de cada um dos inquiridos.

Relativamente aos benefícios, conforme foi abordado ao longo da revisão da literatura, foi possível verificar que as principais motivações para a implementação de sistemas de IA na área da saúde estão relacionadas com o auxílio desses sistemas na formulação de um diagnóstico médico (Zhou, 2020; Bryant, 2020), na utilização racional e eficiente dos recursos disponíveis (Bohr & Memarzadeh, 2020), na melhoria da gestão logística e financeira (Lopes *et al.*, 2018), na previsão do volume de utentes (Graham *et al.*, 2018), na previsão de readmissões de utentes (Futoma *et al.*, 2016), na redução da taxa *no-show* (Beltrame *et al.*, 2019; Kursawa *et al.*, 2016), na gestão de custos (Eigner *et al.*, 2019), na gestão de tempos de espera (Lin *et al.*, 2019) e na redução dos tempos de espera cirúrgicos (Demir *et al.*, 2017; Fairley *et al.*, 2019).

Apesar da introdução de IA na área da saúde estar numa fase embrionária, os inquiridos reconhecem que a implementação desses sistemas irá potenciar a capacidade de resposta dada pelos profissionais e gestores de saúde. Os inquiridos reconhecem que os dados disponíveis podem ser usados para prever determinados comportamentos e gerar valor para as instituições de saúde. De acordo com Dossou *et al.* (2021), há um otimismo generalizado por parte da comunidade científica, de que a aplicação de ferramentas de IA irá proporcionar melhorias substanciais em todas as áreas da saúde.

Segundo Bohr e Memarzadeh (2020), o ecossistema da saúde está cada vez mais consciencializado do impacto que a tecnologia pode gerar na área da saúde. Estima-se que as aplicações de IA possam reduzir os custos associados aos cuidados de saúde, apostando cada

vez mais no processo de prevenção e previsão da doença. Em termos práticos, espera-se que isso resulte em menos hospitalizações e num número reduzido de tratamentos. Os inquiridos acreditam também que esta tecnologia terá um papel importante na saúde dos utentes, na medida em que ajudará as pessoas a serem diagnosticadas mais precocemente e com acompanhamentos mais personalizados (Letourneau *et al.*, 2020).

Por outro lado, para o mesmo grupo de inquiridos foi possível identificar os principais desafios. Desafios esses que se encontram relacionados com a complexidade dos algoritmos de Inteligência Artificial (Chan & Zary, 2019), a integridade e qualidade dos dados armazenados (Panch, Mattie & Celi, 2019), a incapacidade de avaliação (Lee & Yoon, 2017), a responsabilidade legal (Massen *et al.*, 2021) e o propósito da implementação (Pesapane *et al.*, 2018; Char *et al.*, 2018). Nesse sentido, e de acordo com os autores estudados, há várias implicações por parte dos desafios associados à implementação desses sistemas, acabando por criar barreiras que não favorecem a intenção de utilizar este tipo de tecnologia para melhorar a prestação de cuidados, contudo, e segundo o modelo concetual desenvolvido, esses desafios não demonstraram ter um impacto negativo face a essa mesma intenção.

Numa primeira instância, pode retirar-se a conclusão de que os benefícios se sobrepõem aos desafios e que será difícil contrariar o impacto que as ferramentas de IA já demonstram ter na área da saúde, no entanto, a não valorização dos desafios por parte dos inquiridos pode estar também relacionada com um baixo nível de perceção e conhecimento dos mesmos (Wood, Ange & Miller, 2021).

De acordo com o grau de perceção de cada um dos inquiridos, importa salientar que os inquiridos que afirmaram ter mais conhecimentos têm uma maior intenção de implementar este tipo de sistemas (Du-Harpur *et al.* 2020; Gerke, Minssen & Cohen, 2020). No entanto, para que seja possível recorrer a ferramentas de IA é necessário envolver todos os dos *stakeholders*. De acordo com Manne e Kantheti (2021), será determinante, poder contar com apoio governamental. Importa por isso investir na formação, não só de profissionais de saúde e gestores, mas também de pessoas que detenham a capacidade necessária de regular este tipo de tecnologias e ultrapassar questões relacionadas com as violações éticas e legais (Magrabi *et al.*, 2019).

5.2 Contribuição para a área da Saúde

A investigação desenvolvida pretende contribuir para a introdução de sistemas inteligentes na área da saúde. Os exemplos práticos baseiam-se em duas principais vertentes de atuação,

nomeadamente, a vertente ligada à prática clínica e a vertente ligada à área de gestão na saúde. Dessa forma, é possível dar a conhecer quais são os principais benefícios e desafios da adoção de sistemas inteligentes.

A implementação desses sistemas na área da saúde é ainda um tema pouco explorado em contexto nacional, e nesse sentido, o estudo pretende também suscitar interesse por parte de pessoas que ainda não estão despertas para a temática abordada. Nesse sentido, é fulcral continuar a desenvolver estudos que correlacionem as duas áreas, com o intuito de aprofundar o conhecimento, e assim compreender que caminho é necessário trilhar para contornar os diferentes obstáculos.

5.3 Limitações do estudo

Tendo em conta que o público-alvo do questionário desenvolvido apenas se destinava a profissionais de saúde e gestores da mesma área com interesse na área de IA, o tamanho da amostra foi reduzido, tendo sido a principal limitação do mesmo. Apesar de se ter comprovado a literatura existente sobre o tema, é preciso ter consciência que um tema tão recente requer uma maior prudência na generalização dos resultados concluídos. É também importante referir que a presente investigação tem um carácter exploratório e que não pode ser generalizada ou representativa, muito devido à reduzida amostra do estudo.

5.4 Sugestões para futuras investigações

Uma das sugestões identificada, encontra-se relacionada com o nível que cada um dos inquiridos afirma ter em relação à perceção e conhecimento sobre sistemas inteligentes. O nível de conhecimentos beneficiaria de uma avaliação mais detalhada, e nesse sentido seria proveitoso alargar o conjunto de questões, a fim de aferir com mais precisão o nível de conhecimento sobre IA por parte de cada um dos inquiridos.

Outra das sugestões passaria por alargar a investigação e incluir profissionais de áreas como a *data engineer* e a *data science*, uma vez que são esses os profissionais que contactam com profissionais da área da saúde durante o processo de implementação de sistemas inteligentes.

Bibliografia

- Administração Portuguesa de Administradores Hospitalares (2019). Agenda Estratégica para o Futura da Medicina de Precisão em Portugal. Orientações para implementação 2020-2023. https://apah.pt/wp-content/uploads/2019/12/APAH_Medicina-de-precis%C3%A3o-Relat%C3%B3rio-Fase-2_VF.pdf
- Ahmed, Z., Mohamed, K., Zeeshan, S., & Dong, X. Q. (2020). Artificial intelligence with multi-functional machine learning platform development for better healthcare and precision medicine. In *Database* (Vol. 2020). Oxford University Press. <https://doi.org/10.1093/database/baaa010>
- Arbabshirani, M. R., Fornwalt, B. K., Mongelluzzo, G. J., Suever, J. D., Geise, B. D., Patel, A. A., & Moore, G. J. (2018). Advanced machine learning in action: identification of intracranial hemorrhage on computed tomography scans of the head with clinical workflow integration. *Npj Digital Medicine*, 1(1). <https://doi.org/10.1038/s41746-017-0015-z>
- Asan, O., Bayrak, A. E., & Choudhury, A. (2020). Artificial Intelligence and Human Trust in Healthcare: Focus on Clinicians. In *Journal of Medical Internet Research* (Vol. 22, Issue 6). JMIR Publications Inc. <https://doi.org/10.2196/15154>
- Austin, E. E., Blakely, B., Tufanaru, C., Selwood, A., Braithwaite, J., & Clay-Williams, R. (2020). Strategies to measure and improve emergency department performance: A scoping review. In *Scandinavian Journal of Trauma, Resuscitation and Emergency Medicine* (Vol. 28, Issue 1). BioMed Central Ltd. <https://doi.org/10.1186/s13049-020-00749-2>
- Bellini, V., Guzzon, M., Bigliardi, B., Mordonini, M., Filippelli, S., & Bignami, E. (2020). Artificial Intelligence: A New Tool in Operating Room Management. Role of Machine Learning Models in Operating Room Optimization. In *Journal of Medical Systems* (Vol. 44, Issue 1). Springer. <https://doi.org/10.1007/s10916-019-1512-1>
- Beltrame, S. M., Oliveira, A. E., Santos, M. A. B. dos, & Santos Neto, E. T. (2019). Absenteísmo de usuários como fator de desperdício: desafio para sustentabilidade no sistema universal de saúde. *Saúde Em Debate*, 43(123), 1015–1030. <https://doi.org/10.1590/0103-1104201912303>
- Benke, K., & Benke, G. (2018). Artificial intelligence and big data in public health. In *International Journal of Environmental Research and Public Health* (Vol. 15, Issue 12). MDPI AG. <https://doi.org/10.3390/ijerph15122796>
- Birkhoff, D. C., van Dalen, A. S. H. M., & Schijven, M. P. (2021). A Review on the Current Applications of Artificial Intelligence in the Operating Room. In *Surgical Innovation* (Vol. 28, Issue 5, pp. 611–619). SAGE Publications Inc. <https://doi.org/10.1177/1553350621996961>
- Bohr, A., & Memarzadeh, K. (2020). The rise of artificial intelligence in healthcare applications. In *Artificial Intelligence in Healthcare* (pp. 25–60). Elsevier. <https://doi.org/10.1016/b978-0-12-818438-7.00002-2>
- Bryant, M. (2020). EYE ON AI HOW ARTIFICIAL INTELLIGENCE IS CHANGING RADIOLOGY: The potential of emerging artificial intelligence (AI) technologies and their clinical applications to expand the capabilities of Radiology are the submeta of much excitement and anticipation within medical imaging. <https://www.appliedradiology.com/communities/Artificial-Intelligence/the-potential-and-reality-of-ai-in-clinical-application>
- Buch, V. H., Ahmed, I., & Maruthappu, M. (2018). Artificial intelligence in medicine: Current trends and future possibilities. In *British Journal of General Practice* (Vol. 68, Issue 668, pp. 143–144). Royal College of General Practitioners. <https://doi.org/10.3399/bjgp18X695213>
- Cai, X., Perez-Concha, O., Coiera, E., Martin-Sanchez, F., Day, R., Roffe, D., & Gallego, B. (2016). Real-time prediction of mortality, readmission, and length of stay using electronic health record data. *Journal of the American Medical Informatics Association*, 23(3), 553–561.

<https://doi.org/10.1093/jamia/ocv110>

- Civelek, M. E. (2018). Essentials of Structural Equation Modeling. *Zea Books*.
<https://doi.org/10.13014/k2sj1hr5>
- Challen, R., Denny, J., Pitt, M., Gompels, L., Edwards, T., & Tsaneva-Atanasova, K. (2019). Artificial intelligence, bias and clinical safety. In *BMJ Quality and Safety* (Vol. 28, Issue 3, pp. 231–237). BMJ Publishing Group. <https://doi.org/10.1136/bmjqs-2018-008370>
- Chan, K. S., & Zary, N. (2019). Applications and Challenges of Implementing Artificial Intelligence in Medical Education: Integrative Review. *JMIR Medical Education*, 5(1), e13930. <https://doi.org/10.2196/13930>
- Char, D. S., Shah, N. H., & Magnus, D. (2018). Implementing Machine Learning in Health Care — Addressing Ethical Challenges. *New England Journal of Medicine*, 378(11), 981–983. <https://doi.org/10.1056/nejmp1714229>
- Conselho das Finanças Públicas (2020). Evolução Orçamental Do Serviço Nacional de Saúde 2013-2019. Relatório N.º 10/2020.
https://www.cfp.pt/uploads/publicacoes_ficheiros/cfp-rel-10-2020.pdf
- Demir, E., Gunal, M. M., & Southern, D. (2017). Demand and capacity modelling for acute services using discrete event simulation. *Health Systems*, 6(1), 33–40. <https://doi.org/10.1057/hs.2016.1>
- Dossou, P.-E., Foreste, L., & Misumi, E. (2021). Intelligent Support System for Healthcare Logistics 4.0 Optimization in the Covid Pandemic Context. *Journal of Software Engineering and Applications*, 14(06), 233–256. <https://doi.org/10.4236/jsea.2021.146014>
- Du-Harpur, X., Watt, F. M., Luscombe, N. M., & Lynch, M. D. (2020). What is AI? Applications of artificial intelligence to dermatology. In *British Journal of Dermatology* (Vol. 183, Issue 3, pp. 423–430). Blackwell Publishing Ltd. <https://doi.org/10.1111/bjd.18880>
- Eigner, I., Bodendorf, F., & Wickramasinghe, N. (2019). Predicting high-cost patients by Machine Learning: A case study in an Australian private hospital group.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118. <https://doi.org/10.1038/nature21056>
- Fairley, M., Scheinker, D., & Brandeau, M. L. (2019). Improving the efficiency of the operating room environment with an optimization and machine learning model. *Health Care Management Science*, 22(4), 756–767. <https://doi.org/10.1007/s10729-018-9457-3>
- Fan, W., Liu, J., Zhu, S., & Pardalos, P. M. (2020). Investigating the impacting factors for the healthcare professionals to adopt artificial intelligence-based medical diagnosis support system (AIMDSS). *Annals of Operations Research*, 294(1–2), 567–592. <https://doi.org/10.1007/s10479-018-2818-y>
- Falk, R. F. (2014). *A Primer for Soft Modeling Partial Least Squares Path Modeling View project Dabrowski's Emotional Development View project*.
<https://www.researchgate.net/publication/232590534>
- Filho, E. M. de S., Fernandes, F. de A., Soares, C. L. de A., Seixas, F. L., dos Santos, A. A. S. M. D., Gismondi, R. A., Mesquita, E. T., & Mesquita, C. T. (2020). Artificial intelligence in cardiology: Concepts, tools and challenges-“the horse is the one who runs, you must be the jockey.” In *Arquivos Brasileiros de Cardiologia* (Vol. 114, Issue 4, pp. 718–725). *Arquivos Brasileiros de Cardiologia*. <https://doi.org/10.36660/abc.20180431>
- Filipp, F. v. (2019). Opportunities for Artificial Intelligence in Advancing Precision Medicine. *Current Genetic Medicine Reports*, 7(4), 208–213. <https://doi.org/10.1007/s40142-019-00177-4>
- Fornell, C., & Larcker, D. F. (1981). Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research*, 18(1), 39–50. <https://doi.org/10.2307/3151312>

- Futoma, J., Morris, J., & Lucas, J. (2015). A comparison of models for predicting early hospital readmissions. *Journal of Biomedical Informatics*, 56, 229–238. <https://doi.org/10.1016/j.jbi.2015.05.016>
- Gao, S., He, L., Chen, Y., Li, D., & Lai, K. (2020). Public perception of artificial intelligence in medical care: Content analysis of social media. *Journal of Medical Internet Research*, 22(7). <https://doi.org/10.2196/16649>
- Geras, K. J., Mann, R. M., & Moy, L. (2019). Artificial intelligence for mammography and digital breast tomosynthesis: Current concepts and future perspectives. In *Radiology* (Vol. 293, Issue 2, pp. 246–259). Radiological Society of North America Inc. <https://doi.org/10.1148/radiol.2019182627>
- Gerke, S., Minssen, T., & Cohen, G. (2020). Ethical and legal challenges of artificial intelligence-driven healthcare. In *Artificial Intelligence in Healthcare* (pp. 295–336). Elsevier. <https://doi.org/10.1016/b978-0-12-818438-7.00012-5>
- Goh, K. H., Wang, L., Yeow, A. Y. K., Poh, H., Li, K., Yeow, J. J. L., & Tan, G. Y. H. (2021). Artificial intelligence in sepsis early prediction and diagnosis using unstructured data in healthcare. *Nature Communications*, 12(1). <https://doi.org/10.1038/s41467-021-20910-4>
- Gomes, I. A., & Nunes, C. (2020). Analysis of the breast cancer mortality rate in Portugal over a decade: Spatiotemporal clustering analysis. *Acta Medica Portuguesa*, 33(5), 305–310. <https://doi.org/10.20344/AMP.11749>
- Graham, B., Bond, R., Quinn, M., & Mulvenna, M. (2018). Using Data Mining to Predict Hospital Admissions from the Emergency Department. *IEEE Access*, 6, 10458–10469. <https://doi.org/10.1109/ACCESS.2018.2808843>
- Hair, J. F., Risher, J. J., Sarstedt, M., & Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. In *European Business Review* (Vol. 31, Issue 1, pp. 2–24). Emerald Group Publishing Ltd. <https://doi.org/10.1108/EBR-11-2018-0203>
- Hosny, A., Parmar, C., Quackenbush, J., Schwartz, L. H., & Aerts, H. J. W. L. (2018). Artificial intelligence in radiology. In *Nature Reviews Cancer* (Vol. 18, Issue 8, pp. 500–510). Nature Publishing Group. <https://doi.org/10.1038/s41568-018-0016-5>
- Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., Wang, Y., Dong, Q., Shen, H., & Wang, Y. (2017). Artificial intelligence in healthcare: Past, present and future. In *Stroke and Vascular Neurology* (Vol. 2, Issue 4, pp. 230–243). BMJ Publishing Group. <https://doi.org/10.1136/svn-2017-000101>
- Kelly, C. J., Karthikesalingam, A., Suleyman, M., Corrado, G., & King, D. (2019). Key challenges for delivering clinical impact with artificial intelligence. In *BMC Medicine* (Vol. 17, Issue 1). BioMed Central Ltd. <https://doi.org/10.1186/s12916-019-1426-2>
- Kurasawa, H., Hayashi, K., Fujino, A., Takasugi, K., Haga, T., Waki, K., Noguchi, T., & Ohe, K. (2016). Machine-Learning-Based Prediction of a Missed Scheduled Clinical Appointment by Patients with Diabetes. *Journal of Diabetes Science and Technology*, 10(3), 730–736. <https://doi.org/10.1177/1932296815614866>
- Lee, C. H., & Yoon, H. J. (2017). Medical big data: Promise and challenges. *Kidney Research and Clinical Practice*, 36(1), 3–11. <https://doi.org/10.23876/j.krcp.2017.36.1.3>
- Letourneau-Guillon, L., Camirand, D., Guilbert, F., & Forghani, R. (2020). Artificial Intelligence Applications for Workflow, Process Optimization and Predictive Analytics. In *Neuroimaging Clinics of North America* (Vol. 30, Issue 4, pp. e1–e15). W.B. Saunders. <https://doi.org/10.1016/j.nic.2020.08.008>
- Lin, W.-C., Goldstein, I. H., Hribar, M. R., Sanders, D. S., & Chiang, M. F. (n.d.). Predicting Wait Times in Pediatric Ophthalmology Outpatient Clinic Using Machine Learning.
- Liu, X., Song, L., Liu, S., & Zhang, Y. (2021). A review of deep-learning-based medical image segmentation methods. *Sustainability (Switzerland)*, 13(3), 1–29. <https://doi.org/10.3390/su13031224>

- Lopes M. A., Girão L., Alves C., Gomes S. C., Figueira G., Guimarães C. M., Gil R., Amaral T., & Viana A. (2018). Paving the Way for Advanced Hospital Logistics Through an Intelligent Dashboard with Improved Predictive Models and Machine Learning. *Portuguese Journal of Public Health*, 36(1), 25. <https://apah.pt/wp-content/uploads/2018/09/492018.pdf>
- Maassen, O., Fritsch, S., Palm, J., Deffge, S., Kunze, J., Marx, G., Riedel, M., Schuppert, A., & Bickenbach, J. (2021). Future medical artificial intelligence application requirements and expectations of physicians in german university hospitals: Web-based survey. *Journal of Medical Internet Research*, 23(3). <https://doi.org/10.2196/26646>
- Magrabi, F., Ammenwerth, E., McNair, J. B., de Keizer, N. F., Hyppönen, H., Nykänen, P., Rigby, M., Scott, P. J., Vehko, T., Wong, Z. S. Y., & Georgiou, A. (2019). Artificial Intelligence in Clinical Decision Support: Challenges for Evaluating AI and Practical Implications. In *Yearbook of medical informatics* (Vol. 28, Issue 1, pp. 128–134). NLM (Medline). <https://doi.org/10.1055/s-0039-1677903>
- Manne, R., & Kantheti, S. C. (2021). Application of Artificial Intelligence in Healthcare: Chances and Challenges. *Current Journal of Applied Science and Technology*, 78–89. <https://doi.org/10.9734/cjast/2021/v40i631320>
- Martins, P. (2020). Recursos humanos de medicina intensiva em Portugal na era pós COVID. In *Acta Medica Portuguesa* (Vol. 33, Issue 13). CELOM. <https://doi.org/10.20344/AMP.14351>
- McCoy, L. G., Nagaraj, S., Morgado, F., Harish, V., Das, S., & Celi, L. A. (2020). What do medical students actually need to know about artificial intelligence? In *npj Digital Medicine* (Vol. 3, Issue 1). Nature Research. <https://doi.org/10.1038/s41746-020-0294-7>
- McWilliams, C. J., Lawson, D. J., Santos-Rodriguez, R., Gilchrist, I. D., Champneys, A., Gould, T. H., Thomas, M. J., & Bourdeaux, C. P. (2019). Towards a decision support tool for intensive care discharge: Machine learning algorithm development using electronic healthcare data from MIMIC-III and Bristol, UK. *BMJ Open*, 9(3). <https://doi.org/10.1136/bmjopen-2018-025925>
- Ministério da Saúde (2015). Avaliação da Situação Nacional dos Blocos Operatórios. Relatório final. https://www.apca.com.pt/documentos/2015/Avaliacao_situacao_nacional_blocos_operatorios_Outubro2015.pdf
- Ministério da Saúde (2018). Retrato da Saúde, Portugal. ISBN 978-989-99480-1-3 https://www.sns.gov.pt/wp-content/uploads/2018/04/RETRATO-DA-SAUDE_2018_compressed.pdf
- Ministério da Saúde & Serviço Nacional de Saúde (2019). Relatório e Contas 2018. http://www.acss.min-saude.pt/wp-content/uploads/2016/10/Relatorio_Contas_MS_SNS_2019.pdf
- Miotto, R., Wang, F., Wang, S., Jiang, X., & Dudley, J. T. (2017). Deep learning for healthcare: Review, opportunities and challenges. *Briefings in Bioinformatics*, 19(6), 1236–1246. <https://doi.org/10.1093/bib/bbx044>
- Muehlematter, U. J., Daniore, P., & Vokinger, K. N. (2021). Approval of artificial intelligence and machine learning-based medical devices in the USA and Europe (2015–20): a comparative analysis. In *The Lancet Digital Health* (Vol. 3, Issue 3, pp. e195–e203). Elsevier Ltd. [https://doi.org/10.1016/S2589-7500\(20\)30292-2](https://doi.org/10.1016/S2589-7500(20)30292-2)
- Nelson, S. D., Walsh, C. G., Olsen, C. A., McLaughlin, A. J., LeGrand, J. R., Schutz, N., & Lasko, T. A. (2020). Demystifying artificial intelligence in pharmacy. *American Journal of Health-System Pharmacy*, 77(19), 1556–1570. <https://doi.org/10.1093/ajhp/zxaa218>
- Noorbakhsh-Sabet, N., Zand, R., Zhang, Y., & Abedi, V. (2019). Artificial Intelligence Transforms the Future of Health Care. In *American Journal of Medicine* (Vol. 132, Issue 7, pp. 795–801). Elsevier Inc. <https://doi.org/10.1016/j.amjmed.2019.01.017>
- Nuno, S., & Araújo, M. F. (2018). Garantia de qualidade e eficiência em Saúde. *Revista*

- Portuguesa de Gestão e Saúde, 27–31. <http://www.jornalmedico.pt/wp-content/uploads/rpgs/rpgs024/files/downloads/rpgs024.pdf>
- Panch, T., Mattie, H., & Celi, L. A. (2019). The “inconvenient truth” about AI in healthcare. *Npj Digital Medicine*, 2(1). <https://doi.org/10.1038/s41746-019-0155-4>
- Pesapane, F., Codari, M., & Sardanelli, F. (2018). Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. In *European Radiology Experimental* (Vol. 2, Issue 1). Springer. <https://doi.org/10.1186/s41747-018-0061-6>
- Rashidi, H. H., Tran, N. K., Betts, E. V., Howell, L. P., & Green, R. (2019). Artificial Intelligence and Machine Learning in Pathology: The Present Landscape of Supervised Methods. In *Academic Pathology* (Vol. 6). SAGE Publications Ltd. <https://doi.org/10.1177/2374289519873088>
- Reddy, S., Allan, S., Coghlan, S., & Cooper, P. (2020). A governance model for the application of AI in health care. In *Journal of the American Medical Informatics Association* (Vol. 27, Issue 3, pp. 491–497). Oxford University Press. <https://doi.org/10.1093/jamia/ocz192>
- Reis, J., Santo, P., & Melão, N. (2020). Impact of artificial intelligence research on politics of the European Union member states: The case study of Portugal. *Sustainability* (Switzerland), 12(17). <https://doi.org/10.3390/SU12176708>
- Schaffter, T., Buíste, D. S. M., Lee, C. I., Nikulin, Y., Ribli, D., Guan, Y., Lotter, W., Jipe, Z., Du, H., Wang, S., Feng, J., Feng, M., Kim, H. E., Albiol, F., Albiol, A., Morrell, S., Wojna, Z., Ahsen, M. E., Asif, U., ... Jung, H. (2020). Evaluation of Combined Artificial Intelligence and Radiologist Assessment to Interpret Screening Mammograms. *JAMA Network Open*, 3(3), e200265. <https://doi.org/10.1001/jamanetworkopen.2020.0265>
- Schwendicke, F., Samek, W., & Krois, J. (2020). Artificial Intelligence in Dentistry: Chances and Challenges. *Journal of Dental Research*, 99(7), 769–774. <https://doi.org/10.1177/0022034520915714>
- Sit, C., Srinivasan, R., Amlani, A., Muthuswamy, K., Azam, A., Monzon, L., & Poon, D.S. (2020). Attitudes and perceptions of UK medical students towards artificial intelligence and radiology: a multicentre survey. *Insights into Imaging*, 11(1). <https://doi.org/10.1186/s13244-019-0830-7>
- Stanfill, M. H., & Marc, D. T. (2019). Health Information Management: Implications of Artificial Intelligence on Healthcare Data and Information Management. In *Yearbook of medical informatics* (Vol. 28, Issue 1, pp. 56–64). NLM (Medline). <https://doi.org/10.1055/s-0039-1677913>
- Tarka, P. (2018). An overview of structural equation modeling: its beginnings, historical development, usefulness and controversies in the social sciences. *Quality and Quantity*, 52(1), 313–354. <https://doi.org/10.1007/s11135-017-0469-8>
- Turner, O. C., Aeffner, F., Bangari, D. S., High, W., Knight, B., Forest, T., Cossic, B., Himmel, L. E., Rudmann, D. G., Bawa, B., Muthuswamy, A., Aina, O. H., Edmondson, E. F., Saravanan, C., Brown, D. L., Sing, T., & Sebastian, M. M. (2020). Society of Toxicologic Pathology Digital Pathology and Image Analysis Special Interest Group Article*: Opinion on the Application of Artificial Intelligence and Machine Learning to Digital Toxicologic Pathology. *Toxicologic Pathology*, 48(2), 277–294. <https://doi.org/10.1177/0192623319881401>
- U.S. Food and Drug Administration (2018). FDA permits marketing of artificial intelligence algorithm for aiding providers in detecting wrist fractures. <https://www.fda.gov/newsevents/newsroom/pressannouncements/ucm608833.htm>
- Vellido, A. (2019). Societal Issues Concerning the Application of Artificial Intelligence in Medicine. *Kidney Diseases*, 5(1), 11–17. <https://doi.org/10.1159/000492428>
- Viani, N., Botelle, R., Kerwin, J., Yin, L., Patel, R., Stewart, R., & Velupillai, S. (2021). A natural language processing approach for identifying temporal disease onset information from mental

- healthcare text. *Scientific Reports*, 11(1). <https://doi.org/10.1038/s41598-020-80457-0>
- Vilelas, J. (2009). *Investigação: o Processo de Construção do Conhecimento*. Lisboa: Edições Sílabo.
- Wood, E. A., Ange, B. L., & Miller, D. D. (2021). Are We Ready to Integrate Artificial Intelligence Literacy into Medical School Curriculum: Students and Faculty Survey. *Journal of Medical Education and Curricular Development*, 8, 238212052110240. <https://doi.org/10.1177/23821205211024078>
- Yala, A., Schuster, T., Miles, R., Barzilay, R., & Lehman, C. (2019). A deep learning model to triage screening mammograms: A simulation study. *Radiology*, 293(1), 38–46. <https://doi.org/10.1148/radiol.2019182908>
- Yang, Y. C., Islam, S. U., Noor, A., Khan, S., Afsar, W., & Nazir, S. (2021). Influential Usage of Big Data and Artificial Intelligence in Healthcare. In *Computational and Mathematical Methods in Medicine* (Vol. 2021). Hindawi Limited. <https://doi.org/10.1155/2021/5812499>
- Yu, K. H., Beam, A. L., & Kohane, I. S. (2018). Artificial intelligence in healthcare. In *Nature Biomedical Engineering* (Vol. 2, Issue 10, pp. 719–731). Nature Publishing Group. <https://doi.org/10.1038/s41551-018-0305-z>
- Zhang, Z., Citardi, D., Wang, D., Genc, Y., Shan, J., & Fan, X. (2021). Patients' perceptions of using artificial intelligence (AI)-based technology to comprehend radiology imaging data. *Health Informatics Journal*, 27(2). <https://doi.org/10.1177/14604582211011215>
- Zhou, L. Q., Wang, J. Y., Yu, S. Y., Wu, G. G., Wei, Q., Deng, Y. bin, Wu, X. L., Cui, X. W., & Dietrich, C. F. (2019). Artificial intelligence in medical imaging of the liver. *World Journal of Gastroenterology*, 25(6), 672–682. <https://doi.org/10.3748/wjg.v25.i6.672>

Anexo

Questionário - Perceber os fatores que influenciam a possibilidade de aplicar sistemas inteligentes na área da Saúde

O presente questionário, integra o projeto de investigação final no âmbito do mestrado de Gestão de Empresas realizado no ISCTE Business School. A investigação pretende abordar duas temáticas, a Inteligência Artificial e a prestação de cuidados de Saúde. O objetivo passa por entender quais são os fatores que favorecem ou dificultam a implementação de sistemas inteligentes na área da Saúde. Nesse sentido, o questionário é exclusivamente direcionado a profissionais e gestores da área da Saúde com interesse na área de Inteligência Artificial. O anonimato nas respostas está garantido.

Obrigado.

Selecione a qual das opções corresponde a sua atividade profissional:

Profissional de saúde Gestor de saúde

Caso seja Profissional de saúde, indique-nos a área/especialidade: _____

Caso seja Gestor de saúde, indique-nos o seu cargo: _____

Idade: Inferior a 35 anos Entre 35 e 55 anos Superior a 55 anos

Experiência profissional na área da saúde e/ou gestão da saúde:

Inferior a 5 anos Superior a 5 anos Superior a 10 anos

Responda às seguintes questões de acordo com a seguinte escala de Likert:

1 – Discordo totalmente 2 – Discordo 3 – Discordo Parcialmente 4 – Nem concordo nem discordo 5 – Concordo Parcialmente 6 – Concordo 7 – Concordo totalmente

Perceção e Conhecimento	Discordo Totalmente Concordo Totalmente						
							
Familiarização com os conceitos e principais aplicações práticas							
Está familiarizado com o							

conceito de Inteligência Artificial?	1	2	3	4	5	6	7
Tem conhecimento de aplicações práticas de Inteligência Artificial na área da saúde?	1	2	3	4	5	6	7
A sua entidade empregadora fomenta o desenvolvimento de ferramentas de Inteligência Artificial?	1	2	3	4	5	6	7
Conhece o conceito e as aplicações práticas de <i>Machine Learning</i> ?	1	2	3	4	5	6	7
Conhece o conceito e as aplicações práticas de <i>Deep Learning</i> ?	1	2	3	4	5	6	7
Perceção e Conhecimento	Discordo Totalmente Concordo Totalmente						
Grau de conhecimento por parte dos vários stakeholders da organização							
Há uma elevada perceção sobre o grau de conhecimento de sistemas inteligentes por parte dos profissionais de saúde da sua organização.	1	2	3	4	5	6	7
Há uma elevada perceção sobre o grau de conhecimento de sistemas inteligentes por parte dos utentes da sua organização.	1	2	3	4	5	6	7
Há uma elevada perceção sobre o grau de conhecimento de	1	2	3	4	5	6	7

sobre as necessidades hospitalares e coordenar os encargos com medicamentos, dispositivos médicos e materiais.							
Os sistemas inteligentes previnem o cancelamento de determinados procedimentos através da monitorização e controlo de todo o ciclo de stocks.	1	2	3	4	5	6	7
Os sistemas inteligentes permitem prever a taxa de admissão de utentes para um determinado período.	1	2	3	4	5	6	7
Os sistemas inteligentes permitem avaliar o risco de readmissão de utentes.	1	2	3	4	5	6	7
Os sistemas inteligentes permitem prever quais os utentes com maior probabilidade de não comparecerem às suas consultas sem aviso prévio.	1	2	3	4	5	6	7
Os sistemas inteligentes permitem prever quais os utentes que apresentam um risco acrescido de apresentarem custos mais elevados associados a um maior nível de cuidados.	1	2	3	4	5	6	7
Os sistemas inteligentes permitem estimar com maior							

desenvolvidas através de sistemas de inteligência artificial.							
O nível de percepção e aceitação por parte dos utentes face ao uso de sistemas inteligentes condiciona o processo de implementação desses sistemas.	1	2	3	4	5	6	7
A confiabilidade na qualidade dos dados e a precisão da informação médica condicionam o processo de implementação de sistemas inteligentes.	1	2	3	4	5	6	7
Há uma grande preocupação por parte das pessoas no que toca a potenciais violações de questões éticas e de privacidade dos dados.	1	2	3	4	5	6	7
Há uma grande preocupação por parte dos profissionais de saúde no que toca a potenciais violações de questões éticas e de privacidade dos seus dados.	1	2	3	4	5	6	7
A criação de algoritmos que geram lucros para os <i>stakeholders</i> envolvidos através da recomendação de medicamentos específicos ou dispositivos médicos, nos quais as partes envolvidas detêm uma participação, pode	1	2	3	4	5	6	7

representar um problema grave para a implementação de sistemas inteligentes na área da saúde.							
O nível de aceitação de estudantes de medicina face aos sistemas de IA condiciona o processo de adoção desses mesmos sistemas num futuro próximo.	1	2	3	4	5	6	7

Intencionalidade de implementar sistemas inteligentes na área da Saúde	Discordo Totalmente  Concordo Totalmente						
	1	2	3	4	5	6	7
Na minha opinião, há valor na implementação de sistemas de IA na área da saúde.	1	2	3	4	5	6	7
Pretendo implementar sistemas de IA na área da saúde	1	2	3	4	5	6	7