



INSTITUTO
UNIVERSITÁRIO
DE LISBOA

**Tendências emergentes da Inteligência Artificial na saúde:
análise bibliométrica de palavras-chave**

Maria Inês Duarte de Almeida

Mestrado em Gestão de Empresas

Orientador:

Professor Doutor Álvaro Augusto da Rosa, Professor Associado,
ISCTE Business School

Co-Orientadora:

Professora Helena Pestana, Professora Convidada,
INDEG Executive Education

Março, 2022



**BUSINESS
SCHOOL**

Departamento de Marketing, Operações e Gestão

**Tendências emergentes da Inteligência Artificial na saúde:
análise bibliométrica de palavras-chave**

Maria Inês Duarte de Almeida

Mestrado em Gestão de Empresas

Orientador:

Professor Doutor Álvaro Augusto da Rosa, Professor Associado,
ISCTE Business School

Co-Orientadora:

Professora Helena Pestana, Professora Convidada,
INDEG Executive Education

Março, 2022

Ao Filipe Soares Franco que sempre acreditou em mim e que já não está entre nós.

Agradecimento

Finalmente terminou. Esta dissertação foi um dos projetos acadêmicos mais desafiantes que já pude experienciar enquanto estudante. Considero que foi uma batalha que envolveu inicialmente grande entusiasmo, passando por momentos de ansiedade, preocupação e até de desespero culminando com um grande suspiro de alívio, sentimento de concretização e alegria.

O caminho faz-se caminhando é certo, mas não o fiz sozinha. Por esta razão tenho de expressar o meu profundo agradecimento a quem me acompanhou neste processo. Sem nenhuma ordem em particular:

Agradeço ao Professor Álvaro Augusto Rosa pela paciência, calma, disponibilidade e profundo conhecimento que me permitiu chegar até aqui, mostrando-me qual o melhor caminho.

À Professora Helena Pestana pela paciência, disponibilidade, conhecimento, pelas críticas construtivas que permitem que melhore todos os dias e por todo o apoio emocional que me forneceu.

À minha rica mãe, Anabela, a quem eu dedico igualmente esta dissertação e sei que esta dissertação é tanto minha quanto dela.

À minha irmã, Alexandra, que me apoiou e que me auxiliou na resolução de dilemas, expressando a sua opinião e direcionando-me para o melhor caminho. Ao meu cunhado Ricardo que igualmente me apoiou.

Ao meu namorado e *quasi*-marido João, por todo apoio, carinho, por nunca duvidar das minhas capacidades, pela paciência, enfim não tenho palavras.

Aos amigos que me apoiaram.

Gratidão.

Resumo

As novas tecnologias estão a transformar os cuidados de saúde e essa revolução tem por base a inteligência artificial. As despesas com a saúde irão crescer de forma significativa nos próximos anos devido a múltiplos fatores, entre eles o envelhecimento da população e o aumento do aparecimento de doenças crónicas. A pandemia causada pela doença Covid-19, apesar de sobrecarregar os sistemas de saúde, constituiu uma possibilidade de incrementar a inovação nesta área, tendo catalisado os desenvolvimentos tecnológicos e a consciencialização da utilização da inteligência artificial na saúde. A investigação em inteligência artificial na saúde está a expandir-se através da utilização dos modelos de *machine learning* e de *deep learning*, de forma a melhorar os cuidados de saúde e a permitir um atendimento mais personalizado (por exemplo: medicina de precisão) no diagnóstico, prognóstico e tratamento do doente.

O objetivo deste estudo é compreender, através da aplicação da inteligência artificial, quais são as tendências emergentes, de forma a auxiliar a implementação da medicina de precisão. Para tal, foi efetuada uma análise bibliométrica descritiva e uma análise da estrutura conceptual, como a análise de rede de coocorrência de palavras-chave, o mapa temático e a análise fatorial.

Os resultados obtidos indicam que é ao nível do diagnóstico e prognóstico de doenças que a aplicação destes modelos é mais evidenciada, com um maior foco nas áreas de cardiologia, pneumologia, oncologia e radiologia. O tópico tendência da investigação atual e futura diz respeito ao *big data*, com os seguintes temas subjacentes: imagiologia médica, segmentação, classificação de imagem, processamento de imagem e ciência de dados. A implementação da inteligência artificial na saúde tem assim, o potencial de alterar o denominado *Iron Triangle of Healthcare*, aumentando o acesso aos cuidados de saúde sem comprometer a qualidade e com um menor custo.

Palavras-chave: Inteligência Artificial, *Machine Learning*, *Deep Learning*, Saúde, Análise Bibliométrica

Códigos de Classificação JEL:

- **M10** - Business Administration: General
- **C88** - Other Computer Software

Abstract

New technologies are transforming healthcare and this revolution is based on artificial intelligence. Public health expenditure will increase significantly in the coming years due to several factors, including the aging of the population and the underlying increase in chronic diseases. The pandemic caused by the Covid-19 disease, despite overloading health systems, constituted an opportunity to increase innovation in health, having catalyzed technological developments, more specifically the use of artificial intelligence in health. Artificial intelligence research in health is expanding in various areas of medicine, using machine learning and deep learning models to improve health care and allow personalized care (for example: precision medicine) in the diagnosis, prognosis, and treatment of the patient.

The aim of this study is to understand the emerging trends through the application of artificial intelligence to aid the emergence and implementation of precision medicine. To this end, a descriptive bibliometric analysis and a conceptual structure analysis were carried out, such as co-occurrence network of keywords analysis, thematic map and factorial analysis.

The results obtained in this study indicate that the application of these models is more prevalent for the diagnosis and prognosis of diseases, with a greater focus on clinical areas such as cardiovascular, pulmonary, oncology and radiology. The trending topic of current and future research concerns primarily the analysis of big data, with the following underlying themes: medical imaging segmentation, image classification, image processing, and data science. The implementation of artificial intelligence in healthcare thus has the potential to change the so-called Iron Triangle of Healthcare, increasing access to healthcare without compromising quality at a lower cost.

Keywords: Artificial Intelligence, Machine Learning, Deep Learning, Health, Bibliometric Analysis

JEL Classification System:

- **M10** - Business Administration: General
- **C88** - Other Computer Software

Índice

Agradecimento	iii
Resumo.....	v
Abstract	vii
Índice de Figuras	xii
Índice de Tabelas.....	xiii
Lista de Acrónimos e Siglas.....	xv
Capítulo 1: Introdução.....	1
1.1. Enquadramento.....	1
1.2. Problema de Investigação.....	4
1.3. Justificação do Problema de Investigação.....	5
1.4. Objetivos da Dissertação e Questões de Investigação.....	6
1.5. Estrutura da Dissertação.....	6
Capítulo 2: Revisão da Literatura.....	9
2.1 Inteligência Artificial na Saúde	9
2.2. Modelos de <i>Machine Learning</i>	11
2.2.1. Aprendizagem Supervisionada	11
2.2.2. Aprendizagem Não Supervisionada.....	12
2.2.3. Aprendizagem Semi-supervisionada	13
2.2.4. Aprendizagem por Reforço.....	13
2.2.5. Aprendizagem Evolutiva	13
2.2.6. <i>Deep Learning</i>	14
2.3 Modelos de <i>Deep Learning</i>	14
2.4 Aplicação dos modelos de ML e DL na Medicina	17
Capítulo 3: Metodologia.....	20
3.1. Análise Bibliométrica.....	20
3.2. Método de investigação	21
3.2.1. Fase I - Desenho do estudo	21
3.2.2. Fase II - Recolha e processamento de dados	21
3.2.3. Fase III - Análise de dados	23
3.2.4. Fase IV – Mapeamento e análise de rede de palavras-chave.....	23
Capítulo 4: Resultados e Discussão	25
4.1 Análise Bibliométrica Descritiva.....	25
4.2 Análise da Estrutura Conceptual	42
4.3 Discussão dos Resultados	50

Capítulo 5: Conclusões e Recomendações.....	55
Referências Bibliográficas	60
ANEXOS.....	75
ANEXO A: Valores de <i>Betweenness</i> e <i>Closeness</i> - Análise de rede.....	75
ANEXO B: Valores de Centralidade e Densidade – Mapa Temático.....	76

Índice de Figuras

Figura 1 – Imagiologia Médica: Classificação de Tumores utilizando uma CNN.....	15
Figura 2 – Metodologia de investigação.	24
Figura 3 – As 10 principais áreas de investigação da WoS	26
Figura 4 – Lei de Bradford: <i>Core Sources</i> (Zona 1): núcleo dos principais periódicos.	28
Figura 5 – Fontes de publicação com maior número de publicações.	30
Figura 6 – Principais fontes de publicação e número de citações locais.	30
Figura 7 – Produtividade dos 20 principais autores de 2019 a 2022.	31
Figura 8 – Ocorrência das <i>Keywords Plus</i> com maior frequência.	36
Figura 9 – Nuvem de palavras-chave utilizadas com frequência no campo da IA em saúde utilizando o parâmetro - <i>Keywords Plus</i>	37
Figura 10 – Ocorrência das palavras-chave dos autores com maior frequência provenientes do conjunto de dados dos artigos relacionados com a IA na saúde.	38
Figura 11 – Mapa de árvore gerado com as palavras-chave dos autores.	39
Figura 12 – Visão dinâmica das 10 principais palavras-chave dos autores de 2019 a 2022: visualização do crescimento das palavras-chave.	39
Figura 13 – Rede de coocorrência de palavras-chave dos autores.....	43
Figura 14 – Mapa Temático.	45
Figura 15 – Mapa de evolução temática das palavras-chave dos autores de 2019 a 2022, relativamente à aplicação da IA na saúde.	46
Figura 16 – Mapa da Estrutura Conceptual correspondente à aplicação da IA na saúde através do método: Análise de Correspondências Múltiplas.....	48
Figura 17 – Dendrograma representativo dos <i>clusters</i> formados a partir das palavras-chave dos autores tendo em conta o seu nível de similaridade.	49

Índice de Tabelas

Tabela 1 - Número de documentos por anos de publicação.....	25
Tabela 2 - Estrutura da pesquisa por tipo de documentos.....	26
Tabela 3 - Número de documentos e respetivo número de autores.....	32
Tabela 4 - Os 10 principais autores com artigos mais citados	32
Tabela 5 - Os 20 principais países mais produtivos.	33
Tabela 6 - Total de citações e média de citações por artigo e por país.	34
Tabela 7 - Afiliações com maior produção científica e respetivo país de origem	35
Tabela 8 - Para cada área médica esta tabela lista os modelos de ML e DL e as respetivas funções identificadas pelos 20 artigos mais citados.....	41

Lista de Acrónimos e Siglas

A&HCI – Arts and Humanities Citation Index

AE – Autoencoder

ACM – Análise de Correspondências Múltiplas

ANN – Artificial Neural Network

CAGR – Compound Annual Growth Rate

CCR-EXPANDED – Current Chemical Reactions

CNN – Convolutional Neural Network

CPCI-S – Conference Proceedings Citation Index-Science

CPCI-SSH – Conference Proceedings Citation Index-Social Science & Humanities

DBN – Deep Belief Network

DL – Deep Learning

DNN – Deep Neural Network

EHR– Eletronic Health Records

ESCI – Emerging Sources Citation Index

EUA – Estados Unidos da América

FCNN – Fully Convolutional Neural Network

GAN – Generative Adversarial Network

GC – Global Citations

GRU – Gated Recurrent Unit

IA – Inteligência Artificial

IC – Index Chemicus

IoT – *Internet of Things*

ISI – *Institute of Scientific Information*

KNN – *K-Nearest Neighbors*

LSTM – *Long Short-Term Memory*

ML – *Machine Learning*

MeSH – *Medical Subject Headings*

NPL – *Natural Language Processing*

OCDE – *Organização para a Cooperação e Desenvolvimento Económico*

QI – *Questão de Investigação*

PIB – *Produto Interno Bruto*

RNN – *Recurrent Neural Network*

SCI-EXPANDED – *Science Citation Index Expanded*

SSCI – *Social Sciences Citation Index*

WoS – *Web of Science*

Capítulo 1: Introdução

1.1. Enquadramento

Os custos com os cuidados de saúde têm vindo a aumentar gradualmente e em todo o mundo nos últimos anos (Luz Tortorella et al., 2020; OECD.Stat, 2021; Proksch et al., 2019). De acordo com as projeções da OCDE (Organização para a Cooperação e Desenvolvimento Económico), as despesas com a saúde ultrapassarão o crescimento do PIB (Produto Interno Bruto) nos próximos anos e até 2030 em praticamente todos os estados-membros. O gasto per capita com a saúde crescerá a uma taxa média anual de 2,7% e atingirá 10,2% do PIB em 2030, sendo que em 2015 correspondia a 8,8% (OECD, 2019). As projeções da OCDE para o aumento dos gastos na saúde tiveram como base 4 fatores-chave: aumento dos salários, crescimento demográfico, restrições de produtividade (*Baumol's cost disease*) e progresso tecnológico, sendo que este último está intimamente interligado com os outros 3 fatores-chave (Lorenzoni et al., 2019). Neste sentido, as organizações de saúde têm vindo a reconfigurar e a inovar os seus processos, de forma a alcançarem e a manterem um equilíbrio contínuo entre a melhoria da qualidade do serviço e o custo-benefício (Gastaldi et al., 2018).

Nas últimas décadas, a inovação em saúde tem assumido um papel cada vez mais preponderante (Proksch et al., 2019), quer no que diz respeito à tecnologia aplicada aos produtos e processos, quer na tecnologia aplicada na prestação de serviços. Neste sentido, se por um lado as inovações em saúde têm vindo a permitir um aumento da esperança de vida dos doentes e uma melhoria da qualidade de vida dos mesmos, além de proporcionarem uma melhoria no acesso à assistência, ao diagnóstico e ao tratamento, por outro, geram eficiência, diminuição de custos e diminuição do erro humano (Guarcello & Raupp De Vargas, 2020). As grandes transformações impulsionadas pela tecnologia na última década na área da medicina, têm como resultado um avanço significativo em tecnologias de informação e comunicação, como a telemedicina, a produção de grandes volumes de dados diversificados (*big data*) e o desenvolvimento da inteligência artificial (Chen et al., 2020). Consequentemente, as transformações de sistemas tradicionais existentes nas organizações de saúde em sistemas inteligentes afetam a eficiência, eficácia e a economia de toda a organização (Vial, 2019).

Para que este processo seja bem-sucedido e consequentemente se obtenham resultados positivos nas organizações de saúde, estas devem ter em conta a perspetiva quer dos *stakeholders* quer dos *shareholders* (doentes, hospitais, empresas farmacêuticas, órgãos

públicos) no processo de transformação digital, bem como, a forma como exploram as tecnologias, de forma a obter qualidade de atendimento, criação de valor, maior crescimento e digitalização (Verhoef et al., 2021; Vial, 2019). A transformação digital apresenta assim, mudanças orientadas para a estratégia e centradas no doente, com base no uso inovador de tecnologias emergentes de informação e comunicação, de forma a melhorar os processos já existentes ou a implementar novos processos nas organizações (Pihir et al., 2019).

A denominada era da saúde 4.0 também denominada de medicina inteligente é caracterizada por um conjunto de tecnologias digitais que constituem o novo cérebro e as novas mãos nos cuidados de saúde (Chen et al., 2020). A inteligência artificial (IA), é uma das tecnologias que constituem o novo cérebro, sendo das tecnologias digitais que tem vindo a trazer inúmeras vantagens no campo da medicina de precisão com impacto significativo em áreas como o diagnóstico, prognóstico e tratamento de doenças, genómica, desenvolvimento de fármacos, gestão de serviços de saúde e gestão da saúde pública (Ahmed et al., 2020; Shuaib et al., 2020; Sunarti et al., 2021). Em períodos em que a escassez de recursos humanos é premente, como no caso de pandemias, a IA auxilia na tomada de decisões mais rápidas e corretas, relativas ao diagnóstico e tratamento dos indivíduos, melhorando a resposta dos profissionais de saúde nos cuidados ao doente (Koteluk et al., 2021; Wu et al., 2019).

A pandemia da doença provocada pelo coronavírus em 2019 (Covid-19) sobrecarregou os serviços de saúde, enfrentando o sistema de saúde o duplo desafio de atender às necessidades clínicas dos doentes com Covid-19, ao mesmo tempo que, tenta dar resposta às necessidades clínicas dos doentes que apresentam outras doenças que não Covid-19 (Auener et al., 2020; Gunasekeran et al., 2021). Porém, para além de todos os desafios que a atual pandemia acarreta, ela constitui uma possibilidade de incrementar a inovação na saúde (Auener et al., 2020; Mele et al., 2021), tendo catalisado os desenvolvimentos tecnológicos e a consciencialização da utilização da IA (*AI Adoption Skyrocketed Over the Last 18 Months*, n.d.). A crise provocada pela Covid-19 acelerou a adoção da IA e da análise de dados nos vários setores da economia, estimando-se que o mercado da IA aumentará mais de 28 biliões de dólares americanos até 2025 (*Healthcare AI Market Size 2025 Global Forecast*, n.d.). Na saúde, estima-se que o mercado da IA deverá atingir 44,5 biliões de dólares americanos em 2026, crescendo a um CAGR (*Compound Annual Growth Rate*) de 46,21%. O segmento dos prestadores de serviços e produtos de saúde representou a maior participação de mercado com cerca de 48% em comparação com outros segmentos em 2020 (*Healthcare Artificial Intelligence (AI) Market - Global Outlook & Forecast 2021-2026*, n.d.). A IA está a tornar-se assim o foco da pesquisa e

da investigação e uma ferramenta de valor estratégico para as organizações (Larentzakis & Lygeros, 2021), em especial para os profissionais de saúde.

A IA integra o campo da ciência da computação e apresenta vários subdomínios, entre os quais a aprendizagem da máquina ou *Machine Learning* (ML) e a aprendizagem profunda ou *Deep Learning* (DL) (Ball, 2021; Bhatt et al., 2021; Kumar et al., 2021). A IA utiliza técnicas de cálculo com recurso a métodos avançados de investigação e prognóstico de forma a processar não só um grande volume de dados, mas igualmente todo o tipo de dados (Ball, 2021; Koteluk et al., 2021). A aplicação das técnicas de ML nas várias áreas da medicina, tem permitido tomadas de decisão mais rápidas e corretas e uma melhoria nos padrões de tratamento (Koteluk et al., 2021). As áreas da medicina que mais têm vindo a beneficiar das potenciais aplicações do ML são várias, entre elas: cardiologia (Adler et al., 2020), oncologia (Hornbrook et al., 2017), medicina dentária (Kök et al., 2019), cirurgia (Kim et al., 2020), indústria farmacêutica (Yang et al., 2019) e a nutrição (Zeevi et al., 2015). Apesar do DL ser um subdomínio da IA, ele corresponde a um segmento do ML (Hinton & Osindero, 2006). O DL é a abordagem mais dominante do ML comparativamente com outros métodos convencionais de ML, uma vez que, pode aprender automaticamente processos complexos a partir de dados brutos, sem a necessidade da engenharia de recursos (Gupta et al., 2021). O DL processa uma enorme quantidade de dados como, registos dos doentes, relatórios médicos, dados pessoais entre outros, que são posteriormente utilizados com precisão no prognóstico, diagnóstico e tratamento de doentes (Bhatt et al., 2021; Gupta et al., 2021; Jain et al., 2021; Koteluk et al., 2021; Yang et al., 2021).

A implementação da IA torna-se assim, necessária para a eficiência da gestão dos serviços de saúde (Sunarti et al., 2021). Neste sentido, a contribuição de profissionais de saúde e de investigadores na interpretação dos modelos de IA, bem como, da sua aplicação, tem um papel crucial quer para prática clínica diária, quer para as organizações de saúde (Manco et al., 2021).

No ponto seguinte, é descrito o problema de investigação, bem como, a justificação para o mesmo. Seguidamente são apresentados os objetivos da dissertação e as questões de investigação. A última parte do capítulo descreve a organização da dissertação.

1.2. Problema de Investigação

Em todos os países da OCDE, os gastos com a saúde ultrapassaram o crescimento económico nas últimas décadas e as projeções até 2030 acompanham essa tendência crescente (Lorenzoni et al., 2019). O envelhecimento da população (Hermes et al., 2020; OECD, 2019; Proksch et al., 2019), o aumento da esperança média de vida e da prevalência de doenças crónicas associadas a um estilo de vida desequilibrado juntamente com um aumento da utilização dos serviços de saúde (Lorenzoni et al., 2019; OECD, 2019) acarretam um aumento dos custos e sobrecarregam os sistemas de saúde (Hermes et al., 2020; OECD, 2019; Proksch et al., 2019).

Em 2019, as 10 principais causas de morte a nível mundial ocorreram devido a doenças crónicas ou não transmissíveis, constituindo as doenças cardiovasculares, como a cardiopatia isquémica e o acidente vascular cerebral, a principal causa de morte, seguidas pelo cancro e pela doença pulmonar obstrutiva crónica (*Leading Causes of Death Worldwide 2019*, n.d.). A diabetes encontra-se no 9º lugar no ranking das principais causas de morte por doenças crónicas ou não transmissíveis (*Leading Causes of Death Worldwide 2019*, n.d.), podendo trazer consequências cardiovasculares, renais e ao nível do sistema nervoso, colocando assim em risco de vida quem a possui. Estima-se que entre 2021 e 2045, os gastos globais com o tratamento da diabetes cresçam de 966 biliões de dólares americanos para cerca de um trilião de dólares americanos (*Global Diabetes Healthcare Expenditure 2045*, n.d.). No que diz respeito à indústria farmacêutica, os gastos globais com medicamentos aumentaram globalmente e apresentam uma tendência crescente. Em 2020, aproximadamente 1,27 mil biliões de dólares americanos foram gastos em medicamentos, comparativamente a 2010, cujos gastos foram cerca de 887 biliões de dólares americanos. Estima-se que até 2025 os gastos com medicamentos atinjam os 1,6 mil biliões de dólares americanos (*Global Spending on Medicines 2025 Forecast*, n.d.). Por outro lado e no seguimento, do progresso tecnológico a utilização de tecnologias digitais na saúde é um dos principais fatores para o crescimento dos gastos em saúde (OECD, 2017).

A utilização do ML permite economia de tempo, dinheiro e o fornecimento de um tratamento mais personalizado e preciso. No entanto, a implementação progressiva do ML no vasto campo da medicina apresenta inúmeras limitações técnicas e éticas. O principal problema técnico que o ML precisa de superar é o número de possíveis manipulações de dados que podem influenciar as decisões do sistema (Koteluk et al., 2021), afetando o resultado do diagnóstico, prognóstico ou padrão de tratamento do doente. Relativamente às limitações éticas e de acordo com Saheb et al. (2021), uma das limitações diz respeito à ética normativa, que demonstra que

a IA pode resultar na discriminação pela generalização das conclusões, afetando a justiça, a equidade e acentuando a desigualdade. Atualmente, no domínio do ML, o DL é considerado um dos principais catalisadores do avanço tecnológico no campo da IA (Cai et al., 2020; Yang et al., 2021). Porém, o DL tende a aperfeiçoar-se cada vez mais quanto maior for a quantidade de dados, uma vez que esta é uma fase necessária para construir a rede neural ideal para um determinado problema clínico (Piccialli et al., 2021).

A confiabilidade e a robustez de qualquer modelo dependem de vários fatores, incluindo a qualidade e a quantidade dos dados utilizados para desenvolver os modelos de ML e DL, garantindo que são seguros, eficazes e reproduzíveis em cuidados de rotina (Scott, 2021).

Neste sentido, torna-se importante perceber o que nos diz a mais recente evidência científica sobre a aplicação do ML e do DL nas várias áreas da medicina, tendo em conta que as previsões apontam para um aumento do crescimento do mercado na saúde.

1.3. Justificação do Problema de Investigação

No setor da saúde a implementação da IA é acompanhada de potenciais benefícios, basta para isso, analisar o *Iron Triangle of Healthcare*: custo, qualidade e acesso. Tradicionalmente, este triângulo exige uma troca ao tentar melhorar qualquer um dos três elementos. Por exemplo, nos esforços para diminuir o custo, o acesso aumenta e muitas vezes a qualidade diminui (Ford E., 2018). No entanto, a IA tem o potencial de criar um caminho diferente que pode simultaneamente reduzir custos, aumentar a qualidade e aumentar o acesso (Ball, 2021; Piccialli et al., 2021).

Sistemas de saúde altamente fragmentados e diversos, a ausência de um protocolo para documentar os dados dos doentes, restrições ético-legais (privacidade dos dados) e limitações da própria IA (interpretação dos dados) ainda representam sérios desafios para a ampla adoção da IA. A título de exemplo e no campo do prognóstico de doenças, o desenvolvimento de algoritmos inovadores para obter o máximo de informações dos dados juntamente com o modelo de ML mais adequado é fundamental (Deshmukh, 2020). A aplicação do DL no campo do processamento de imagens médicas com o intuito de efetuar um diagnóstico e um prognóstico precisos de doenças com risco de vida associado, como é o caso do cancro da mama, pulmão e pâncreas é algo que já é efetuado. No entanto, os atuais modelos de DL apresentam algumas limitações que incentivam os investigadores a buscar melhorias adicionais (Ball, 2021; Piccialli et al., 2021). Os algoritmos de DL também apresentam problemas,

essencialmente de opacidade ou *black box*, o que torna difícil de entender como é que o modelo toma decisões ou por que existem falhas (Johnson, 2019).

A inovação dos serviços de saúde surge como uma prioridade de pesquisa para compreender melhor, como é que os prestadores de cuidados de saúde podem melhorar a prestação dos cuidados de saúde e promover os seus serviços, combinando e recombinação recursos inovadores e renovados (Guarcello & Raupp De Vargas, 2020).

1.4. Objetivos da Dissertação e Questões de Investigação

Há uma tendência crescente da produção científica sobre a aplicação dos modelos de IA na saúde, mais concretamente sobre a aplicação dos modelos de ML e de DL. Inúmeras revisões e revisões sistemáticas têm sido efetuadas sobre esta temática (Bakator & Radosav, 2018; Enholm et al., 2021; Gunasekeran et al., 2021; Houfani et al., 2021; Kourou et al., 2021; Supriya & Chattu, 2021). No entanto, as revisões anteriores são principalmente qualitativas. A motivação por detrás desta dissertação é complementar as revisões anteriores com uma análise bibliométrica, que contempla um método misto (qualitativo e quantitativo), de forma a revelar a estrutura intelectual e a trajetória da produção científica sobre a aplicação dos modelos de ML e DL na saúde desde 2019 até janeiro de 2022. Esta análise permitirá identificar as áreas da medicina onde o investimento está a ser aplicado, descobrir quais os modelos que estão a ser aplicados no prognóstico, diagnóstico e tratamento de determinadas doenças e recomendar futuras pesquisas.

Esta dissertação tem igualmente como objetivo fornecer uma resposta às seguintes questões de investigação:

QI1: Como é que a inteligência artificial, e as suas respetivas ferramentas aplicadas à saúde, evoluiu ao longo do tempo?

QI2: Quais são as tendências emergentes da aplicação da inteligência artificial, mais concretamente dos modelos de *machine learning* e *deep learning* na saúde, no que diz respeito ao prognóstico, diagnóstico e tratamento de doenças?

1.5. Estrutura da Dissertação

Esta dissertação é constituída por seis capítulos. Seguidamente é apresentado um breve resumo que compõe cada capítulo.

O capítulo 1 faz menção em primeiro lugar aos gastos e custos com a saúde e respetivas projeções para os anos vindouros. Seguidamente, faz referência à importância da inovação na

saúde como solução para diminuição dos custos e aumento do acesso e da qualidade dos cuidados de saúde, sendo a IA o centro das atenções em muitas áreas da medicina neste momento. Dá a conhecer quais os modelos da IA, que estão no centro do diagnóstico, prognóstico e tratamento de doenças e que serão objeto de estudo desta dissertação. Os restantes itens, dizem respeito ao problema de investigação, justificação do problema, objetivos da dissertação e questões de investigação.

O capítulo 2, assenta essencialmente no estado da arte dos modelos de ML e de DL com exemplos da aplicação de ambos os modelos nas várias áreas da medicina.

O capítulo 3 é dirigido à metodologia efetuada para que as questões de investigação possam ser respondidas. Neste sentido, foi efetuada uma análise bibliométrica descritiva e uma análise da estrutura conceptual recorrendo a um software específico para o efeito.

No capítulo 4, são apresentados os resultados obtidos mediante a metodologia apresentada no capítulo anterior.

O capítulo 5 inclui as principais conclusões do estudo efetuado e as limitações do mesmo.

Capítulo 2: Revisão da Literatura

2.1 Inteligência Artificial na Saúde

A IA não é uma temática recente na prática da medicina (Hussain, 2021). Na realidade, foi bastante cedo que a medicina foi identificada como sendo uma das áreas de aplicação da IA mais promissoras (Yu et al., 2018). Por exemplo, na década de 1970, foram inúmeras as aplicações da IA na prática clínica, quer no que diz respeito à precisão do diagnóstico (por exemplo: diagnóstico auxiliado por computador de doentes com dor aguda abdominal (Dombal et al., 1972)), quer no que diz respeito ao tratamento (por exemplo: um programa de computador interativo, denominado de MYCIN, que utiliza os critérios de decisão clínica de especialistas para aconselhar os médicos que solicitam aconselhamento sobre qual a terapia antimicrobiana apropriada para doentes com infeções bacterianas (Shortliffe et al., 1975)), auxiliando assim na tomada de decisão por parte dos profissionais de saúde (Dombal et al., 1972; Shortliffe et al., 1975; Szolovits & Pauker, 1978). No entanto, por vários anos, devido à escassez de financiamento para a investigação nesta área, a IA permaneceu adormecida até ter ressurgido no meio científico já no século XXI devido a avanços tecnológicos e a pesquisas efetuadas por cientistas e empresas (Yu et al., 2018).

Apesar do progresso tecnológico efetuado nas últimas décadas, a definição do termo de IA nem sempre foi clara, podendo até ser mal interpretada e o seu significado modificado ao longo do tempo (Cote et al., 2021; Yu et al., 2018). Neste sentido, importa esclarecer não só a definição do termo de IA, como igualmente, outros termos que lhe estão associados como os modelos de ML e DL.

Não existe uma definição única para IA, uma vez que, é um termo cujo significado pode mudar ao longo do tempo devido ao progresso da ciência. Cote et al. (2021, p. 1699) apresentam uma definição simplista de IA, designando-a como “...*computers that seem to demonstrate human-like intelligence.*” Por outro lado, Manco et al. (2021, p. 194) apresentam uma definição mais abrangente, referindo que “*AI is the entire universe of computer technology that exhibits anything remotely resembling human intelligence. Its objective is the development of machines whose cognitive functions related to mimic the perception, learning, problem-solving and decision-making exceed that of humans.*” Por último e ao contrário dos autores anteriores, Hussain (2021, p. 2) menciona o termo algoritmo para explicar o significado de IA, ou seja, “*Artificial intelligence is, therefore, the practice of using algorithms to analyze data, learn from it, and then decide or predict about something in the world.*”

Os algoritmos são um conjunto finito de instruções claras e bem definidas que os computadores são programados para utilizar e seguir passo-a-passo com o objetivo de agilizar o processo de procura de soluções para um determinado conjunto de problemas (*The Definitive Glossary of Higher Math Jargon*, n.d.). Os algoritmos são a base do ML, sendo este o ramo da ciência que estuda como é que os computadores aprendem através dos dados. O ML é um subdomínio da IA (Ray & Chaudhuri, 2021) e surge da junção entre a matemática, mais concretamente entre a estatística (que procura aprender a relação entre os dados) e a ciência da computação que estuda a implementação dos algoritmos na procura de soluções para determinados problemas (Deo, 2015). Na medicina, o ML tem sido a metodologia amplamente utilizada e igualmente bem-sucedida, por extrair conhecimento da grande quantidade de dados produzidos nesta área e encontrar igualmente novas informações contidas nesses mesmos dados, que de outra forma permaneceriam ocultas na massa do *big data* médica (Manco et al., 2021; Min et al., 2017; Secinaro et al., 2021; Yu et al., 2018). No domínio do ML, existem um conjunto de processos de aprendizagem, cada um deles com determinadas especificações (Ray & Chaudhuri, 2021). O DL é o processo de aprendizagem que tem vindo a despertar cada vez maior interesse no campo da medicina, tendo sido considerado desde 2013 como um dos 10 maiores avanços tecnológicos, devido à sua considerável capacidade de aplicação na análise de dados (Cai et al., 2020). Um número cada vez maior de estudos científicos produzidos nos últimos anos tem demonstrado as inúmeras aplicações da IA na área da saúde, incluindo algoritmos para interpretação de eletrocardiogramas (Deo, 2015), deteção de vários tipos de cancro, como o cancro da mama (Wu et al., 2019) e tumores cerebrais (Crimi et al., 2016), bem como, para identificação de lesões cancerígenas na pele (Esteva et al., 2017), para prever o desenvolvimento da doença de Alzheimer (Ding et al., 2019), para deteção de pólipos durante o procedimento por colonoscopia (Wang et al., 2018), para avaliação da qualidade do embrião determinando assim o sucesso da fertilização in vitro (Khosravi et al., 2019) entre outras aplicações em outros campos da medicina. Como é possível verificar, diferentes modelos de aprendizagem de IA podem ser aplicados nas diversas áreas da medicina, causando assim impacto na tomada de decisões, que vão desde o diagnóstico, passando pelo prognóstico e posteriormente pelo tratamento personalizado (Secinaro et al., 2021).

A IA está deste modo a modificar gradualmente a prática médica. Porém, dada a impressionante diversidade de estudos relativos a esta temática, é surpreendente que as implementações dos algoritmos de ML na prática clínica sejam raras (Kelly et al., 2019; Meyer et al., 2018; Piccialli et al., 2021).

O estado da arte desta dissertação, não pretende discutir a complexidade abstrata dos algoritmos de ML e mais concretamente do seu subdomínio, o DL, mas inclui as definições técnicas de cada um dos processos de aprendizagem do domínio de ML com ênfase no processo de aprendizagem de DL. Pretende igualmente categorizar os processos de aprendizagem de ML e mais concretamente de DL em relação às suas aplicações nas diferentes áreas médicas, uma vez que, e segundo vários autores, apesar de todas as limitações a IA terá futuramente um impacto positivo em muitas áreas da medicina (Cai et al., 2020; Kelly et al., 2019; Piccialli et al., 2021).

2.2. Modelos de *Machine Learning*

Considerado um subdomínio da IA, o ML é definido por Scott (2021, p. 1388) como sendo “*the process whereby advanced computer programs (machines) process huge datasets (big data) from many sources, with little or no human instruction, and discern patterns and associations which are then used to iteratively encode (or learn) a layered mathematical model (algorithm).*”

Existe um grande número de algoritmos de ML a serem utilizados e cujos detalhes vão além desta dissertação. No entanto, alguns algoritmos de ML mais comuns serão descritos seguidamente devido à sua relevância para a investigação médica e pelo seu uso frequente na literatura. Como referido anteriormente, o ML apresenta diversos conjuntos de processos de aprendizagem, dos quais irei destacar seis, cada um com determinadas especificações e aplicações na área da medicina, são eles: processo de aprendizagem supervisionado, não supervisionado, semi-supervisionado, de reforço, evolutivo e profundo (Ray & Chaudhuri, 2021). É de referir que os dados usados para desenvolver estes processos de aprendizagem vão desde imagens médicas, a registos médicos eletrónicos, conjuntos de dados administrativos, dados provenientes do genoma e de biomarcadores e também de *wearables devices* (Scott, 2021). Seguidamente é apresentada uma breve descrição de cada processo de aprendizagem.

2.2.1. Aprendizagem Supervisionada

A aprendizagem supervisionada, utiliza dados em que as condições ou eventos nos quais o modelo está a aprender apresentam um *output* já conhecido (o modelo aprende sob supervisão). (Deo, 2015; Ray & Chaudhuri, 2021; Scott, 2021). Todas as tarefas que uma pessoa treinada pode fazer bem, a máquina irá tentar executar essas mesmas tarefas, tentando aproximar-se à *performance* do humano (Deo, 2015). O método de aprendizagem supervisionado, divide-se em dois tipos: classificação e previsão ou regressão.

O método de aprendizagem por classificação, envolve classificar em 2 grupos um determinado conjunto de dados (classificação binária – por exemplo: doença presente ou ausente) ou classificar um determinado conjunto de dados em vários níveis (diferentes níveis de gravidade da doença).

A previsão ou regressão estima a probabilidade de um determinado valor numérico ou evento clínico acontecer utilizando um conjunto de dados anterior. Por exemplo, se pretender estimar a probabilidade de um indivíduo sofrer de doença cardíaca, o método por regressão irá utilizar dados provenientes de indicadores de doença cardíaca para efetuar essa estimativa (Deo, 2015; Ray & Chaudhuri, 2021). Máquina de vetores de suporte, classificadores *bayesianos*, *K-Nearest Neighbors* (KNN), árvores de decisão e modelos de regressão são algumas das ferramentas utilizadas nos modelos de aprendizagem supervisionada (Scott, 2021).

2.2.2. Aprendizagem Não Supervisionada

A aprendizagem não supervisionada consiste em treinar a máquina utilizando dados que não se encontram classificados ou identificados, permitindo que o algoritmo lide com essas informações sem orientação. A máquina agrupa dados não rotulados de acordo com semelhanças, não havendo como prever um *output* (Deo, 2015). Um exemplo mais comum de aprendizagem não supervisionada é o processo de *clustering*, que consiste na identificação de dados que compartilham semelhanças formando grupos ou *clusters* (Scott, 2021). É comumente utilizado no processamento de imagens, análise de dados e identificação de padrões (Ray & Chaudhuri, 2021).

A redução de dimensionalidade ou redução de dimensão é outra técnica de aprendizagem não supervisionada e refere-se ao processo de transformar dados de um espaço alta dimensão num espaço de baixa dimensão, de forma que a baixa dimensão retenha as propriedades significativas dos dados originais. A estratificação do risco da dor torácica em doentes que recorrem às urgências é um bom exemplo da aplicação desta técnica (Liu et al., 2021).

Por último, a deteção de anomalias ou *outlier detection* é o processo pelo qual um algoritmo percorre os dados à procura de padrões incomuns. É útil para encontrar doentes que não se enquadram na trajetória clínica média. Neste caso, o algoritmo é treinado num conjunto de dados de doentes onde os diagnósticos são conhecidos e quando aplicados a dados de novos doentes, alerta o médico quando um deles parece não se encaixar no padrão, sugerindo ao profissional uma alteração do tratamento, uma investigação adicional ou considerar existir um erro no diagnóstico (Handelman et al., 2018).

A análise de componentes principais, o agrupamento *K-means* e a detecção de anomalias são os modelos comumente utilizados na aprendizagem não supervisionada (Scott, 2021).

2.2.3. Aprendizagem Semi-supervisionada

É uma abordagem do ML que combina, durante o treino da máquina, uma pequena quantidade de dados identificados ou classificados (aprendizagem supervisionada) com uma grande quantidade de dados não identificados ou rotulados (aprendizagem não supervisionada) (Ray & Chaudhuri, 2021). Devido ao menor consumo de tempo, dinheiro e esforços para adquirir dados não rotulados, uma pequena fração de dados rotulados é utilizada com uma vasta quantidade de dados não rotulados na aprendizagem da máquina (Pramod & Tyagi, 2021). Um exemplo da aprendizagem semi-supervisionada encontra-se patente na área de radiologia, mais concretamente no que diz respeito às radiografias efetuadas ao tórax (Liu et al., 2020). A aprendizagem semi-supervisionada utiliza essencialmente métodos de regressão e classificação (Pramod & Tyagi, 2021).

2.2.4. Aprendizagem por Reforço

É uma técnica de aprendizagem no qual a máquina, na ausência de um conjunto de dados aprende com a experiência (Ray & Chaudhuri, 2021). Este tipo de aprendizagem concentra os seus esforços em auxiliar a máquina a atingir os seus objetivos rapidamente (Pramod & Tyagi, 2021). Um exemplo da aprendizagem por reforço diz respeito ao tratamento de doenças crónicas e em doentes em cuidados intensivos (Yu et al., 2021). *Deep Q-networks* (DQN), SARSA (estado-ação-recompensa-estado-ação) e gradientes de política determinísticos são alguns dos modelos utilizados neste tipo de aprendizagem.

2.2.5. Aprendizagem Evolutiva

É um processo de aprendizagem inspirado na biologia e uma abordagem confiável e eficaz para resolver problemas complexos. Este tipo de aprendizagem é utilizado para melhorar os outros processos de aprendizagem, melhorando os seus resultados (Telikani et al., 2022). Na área de cardiologia, um exemplo da aplicação da aprendizagem evolutiva, diz respeito à seleção dos candidatos que melhor se adequam à realização de uma cirurgia torácica (Mangat & Vig, 2014).

2.2.6. Deep Learning

Por último, a aprendizagem profunda ou *Deep Learning* (DL) é inspirado nos neurónios do cérebro humano, tendo sido denominado primeiramente de *Artificial Neural Network* (ANN). Atualmente, a clássica ANN foi substituída pela *Deep Neural Network* (DNN) (Lee et al., 2017), sendo esta descrita como um conjunto de modelos computacionais compostos por múltiplas camadas de processamento de dados, em que cada camada sucessiva utiliza a saída da camada anterior como entrada (Lecun et al., 2015). A rede neural é constituída por uma camada de entrada, uma camada oculta e uma camada de saída. A primeira camada é a camada de entrada que recebe o conjunto de dados e a última camada é a camada de saída e a que gera o resultado. No meio, as camadas que transformam o sinal são denominadas de camadas ocultas, sendo o número de camadas variável, correspondendo assim a vários níveis de abstração (Meyer et al., 2018). Seguidamente é apresentada uma breve descrição dos principais grupos de arquiteturas de DL.

2.3 Modelos de Deep Learning

Este tipo de aprendizagem tem vindo a ganhar grande expressão, especialmente na área da medicina. Em primeiro lugar, devido ao seu elevado nível de automação. Enquanto as outras técnicas de ML necessitam da engenharia de recursos para que o seu processo de aprendizagem seja efetuado, o DL é autónomo, sendo a aprendizagem realizada através do grande volume de dados (*big data*) fornecido (Meyer et al., 2018; Min et al., 2017). O elevado grau de flexibilidade e de interpretação de dados são duas outras razões para a utilização do DL, especialmente se tivermos em conta a área da medicina, uma vez que, os dados médicos incluem diferentes tipos de dados não estruturados, como imagens, expressões genéticas e dados administrativos. Desta forma, aplicação do DL pode resultar em inúmeras vantagens, como velocidade de execução, potencial redução de custos diretos e indiretos, melhor precisão no diagnóstico, maior eficiência clínica e operacional (as máquinas não necessitam de períodos de descanso) e a possibilidade de fornecer acesso às informações clínicas a pessoas que não podem beneficiar delas por razões geográficas, políticas e económicas (Piccialli et al., 2021). Em seguida encontram-se descritos os subdomínios do DL. As aplicações nas várias áreas da medicina são várias e dependem das arquiteturas de rede de DL utilizadas.

Muitas arquiteturas de rede de DL foram desenvolvidas dependendo dos dados fornecidos e dos aplicativos médicos desejados. Neste sentido, de acordo com os métodos de conexão e cálculo, existem diferentes tipos de redes neurais (Yang et al., 2021). Em seguida,

encontram-se listados os principais grupos das principais arquiteturas de DL, que constituem os métodos básicos de DL (Piccialli et al., 2021).

Fully Convolutional Neural Network (FCNN): é composta por camadas de redes neurais cujos neurónios estão completamente conectados. A FCNN é constituída por uma camada de entrada, uma camada oculta e uma camada de saída. A camada de entrada é responsável por receber os dados de entrada. A camada oculta é composta por inúmeras camadas de rede neural para extração de recursos. A camada de saída gera o resultado da previsão. A FCNN combinada com outras redes neurais é amplamente utilizada para efetuar prognósticos (Yang et al., 2021).

Convolutional Neural Network (CNN): projetada para processar vários tipos de dados, especialmente imagens bidimensionais, é amplamente utilizada no diagnóstico auxiliado por computador em imagens médicas e é inspirada diretamente no córtex visual do cérebro (Min et al., 2017). No que diz respeito à sua arquitetura básica, uma CNN é composta por 3 tipos de camadas: camadas convolucionais, *pooling layers* ou camadas agrupadas e camadas totalmente conectadas, cujo objetivo é encontrar características representativas da imagem de entrada, primeiro simples e depois mais elaboradas à medida que as camadas se sucedem (Lecun et al., 2015). A CNN é utilizada em várias áreas, desde imagiologia (por exemplo: identificação e classificação de vários tipos de tumores (Esteva et al., 2017; Ramadan, 2020)) à biomedicina (por exemplo: prever marcas de cromatina a partir de sequências de DNA (Zhou & Troyanskaya, 2015)) e aos registos eletrónicos de saúde (por exemplo: sistema de ponta a ponta para prever readmissão não planeada após a alta (Nguyen et al., 2016)). Para um melhor entendimento do funcionamento desta rede e tendo como exemplo Esteva et al. (2019), a figura seguinte ilustra como se processa o funcionamento de uma CNN na classificação de tumores.

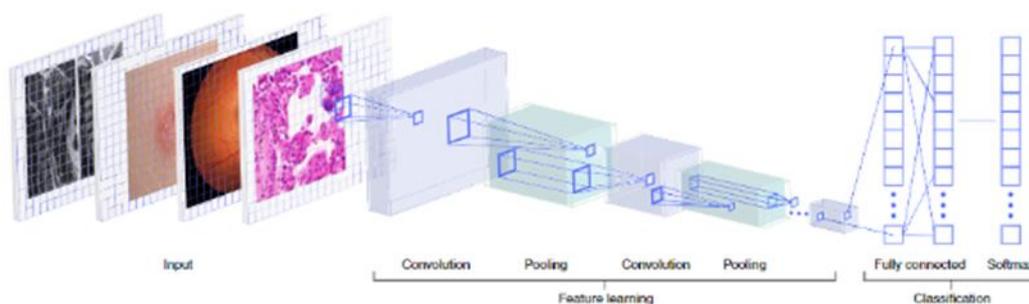


Figura 1 - Imagiologia Médica: Classificação de tumores utilizando uma CNN.

Fonte: (Esteva et al., 2019)

A informação flui da esquerda para a direita. A CNN agarra em imagens de entrada (*input*) e transformam-nas sequencialmente através de operações simples ao longo das camadas convolucionais e das *pooling layers*. Os elementos de saída (camada *softmax*) representam as

probabilidades da presença da doença. Durante o processo de treino, os parâmetros internos das camadas de rede são ajustados para melhorar a precisão (Esteva et al., 2019).

Recurrent Neural Network (RNN): é muito adequada para processar dados sequenciais, como é o caso de dados dependentes do tempo. Enquanto na FCNN e na CNN as entradas são independentes, na RNN a primeira entrada e a última entrada são dependentes e têm uma relação de sequência (Lecun et al., 2015; Yang et al., 2021). É uma rede adequada para processar dados biomédicos relacionados com uma sequência, como por exemplo, sequência de DNA, sequência de proteínas e registos eletrónicos médicos (Yang et al., 2021). A *Gated Recurrent Unit (GRU)* e a *Long Short-Term Memory (LSTM)* são variantes da RNN aplicadas igualmente em aplicativos médicos (Lecun et al., 2015; Piccialli et al., 2021) .

Autoencoder (AE): é um modelo que pratica a aprendizagem não supervisionada e é composto por um codificador e um decodificador. Os codificadores e decodificadores podem ser quaisquer modelos de redes neurais. O número de neurónios na camada de entrada e na camada de saída é o mesmo, mas o número de neurónios na camada oculta é menor do que nas camadas anteriores, o que é útil para compactar dados e aprender recursos eficazes a partir desses mesmos dados. Especificamente, o codificador reduz a dimensão dos dados originais para obter uma nova representação e em seguida, o decodificador restaura os dados de entrada por meio dessa nova representação. O codificador automático é utilizado em medicina na imagiologia e na genómica (Pramod & Tyagi, 2021; Yang et al., 2021) .

Deep Belief Network (DBN): é uma rede neural utilizada na aprendizagem supervisionada e na aprendizagem não supervisionada. É constituída por várias camadas de unidades ocultas com conexões entre as camadas, mas não entre unidades dentro de cada camada. É adequada para tarefas de extração automática de recursos, como na genómica e no desenvolvimento de novos fármacos (Yang et al., 2021).

Generative Adversarial Network (GAN): criada por Goodfellow et al. (2014) a GAN é uma estrutura na qual duas redes neurais competem entre si para se tornarem mais precisas nas suas previsões. As GAN fazem parte do modelo de aprendizagem não supervisionado e utilizam uma estrutura cooperativa de jogo de soma zero para aprender, o jogo termina quando o equilíbrio de *Nash* é atingido. A GAN é utilizada por exemplo para estimar a dose correta de uma determinada substância no tratamento de tumores cerebrais (Kazemifar et al., 2020).

2.4 Aplicação dos modelos de ML e DL na Medicina

Um grande número de publicações e pesquisas têm abordado a utilização do ML e mais concretamente do DL na medicina, com foco em determinadas áreas médicas, de forma a melhorar o atendimento ao doente (Handelman et al., 2018). A aplicação do ML na medicina de precisão ou personalizada reconhece a existência de variáveis únicas em cada doente, permitindo um atendimento individualizado (Holzinger, 2014). O poder do ML permite essa individualização a vários níveis: no prognóstico, diagnóstico e tratamento (Rajkomar et al., 2019).

No que diz respeito ao prognóstico são inúmeros os exemplos da aplicação dos modelos de ML, que vão desde a previsão de eventos cardiovasculares em doentes assintomáticos; à previsão do choque séptico; à estimativa da mortalidade hospitalar em doentes com sepsis; à estimativa da sobrevivência após correção do aneurisma da aorta; à recorrência do cancro da mama e à previsão da mortalidade por linfoma (Rajkomar et al., 2019; Scott, 2021).

Na triagem e diagnóstico a aplicação dos modelos de ML que utilizam dados de imagens permitem a classificação de lesões de pele como cancerígenas ou não; o diagnóstico de retinopatia diabética e outras doenças oculares; a deteção de metástases no cancro da mama e do pulmão e a diferenciação de arritmias em eletrocardiogramas (Scott, 2021; Topol, 2019).

Na seleção de tratamentos com base na resposta prevista, os modelos de ML visam tratamentos específicos para doentes com maior probabilidade de beneficiarem desses tratamentos ou com menor probabilidade de serem prejudicados recebendo esses tratamentos. Como exemplos temos: tratamento antirretroviral em doentes infetados pelo vírus da imunodeficiência humana; medicamentos combinados na doença de Parkinson; diferentes antidepressivos nos principais transtornos depressivos e quimioterapia coadjuvante no cancro da mama (Esteva et al., 2019; Rajkomar et al., 2019; Scott, 2021; Topol, 2019).

De acordo com Topol (2019), o risco de algoritmos anómalos é exponencialmente grande, mas a recompensa pela redução de erros, ineficiências e custos é substancial. Neste sentido, no campo da medicina, a integração da IA e, por conseguinte, dos modelos de ML e de DL, requerem estudos rigorosos, publicação dos resultados em periódicos *peer review*, validação clínica e implementação no atendimento ao doente.

A IA aplicada à saúde é um campo emergente na medicina, permitindo a fusão entre a ciência da computação, a estatística e os problemas médicos. Os defensores do ML e consequentemente do DL enaltecem a sua capacidade de lidar na área da medicina com um grande volume de dados complexos e desestruturados e consideram que o ML e o DL são o futuro da pesquisa biomédica. No entanto, há um potencial inexplorado no uso e na pesquisa do ML e do DL. Neste sentido e tendo em vista um necessário e um maior desenvolvimento e compreensão sobre esta temática, a bibliometria é a análise escolhida para responder às questões de investigação listadas no capítulo 1.

Capítulo 3: Metodologia

3.1. Análise Bibliométrica

A análise bibliométrica é um método de análise de grandes volumes de dados científicos e tem vindo a ganhar popularidade entre os investigadores nos últimos anos, devido ao avanço, disponibilidade e acessibilidade de softwares bibliométricos como o VOSviewer, Gephi, Leximancer e das bases de dados científicas como a Web of Science e a Scopus (Donthu et al., 2021). O termo bibliometria foi primeiramente utilizado em 1969 (Broadus, 1987), e definido por Pritchard (1969, p. 348) como “*the application of statistical and mathematical methods to books and other media of communication*”. A análise bibliométrica é uma ferramenta estatística indispensável para mapear o estado da arte de uma determinada área do conhecimento científico, identificar processos de disseminação do conhecimento e visualizar a dinâmica dos desenvolvimentos científicos, justificando assim as decisões sobre políticas de investigação (Ellegaard & Wallin, 2015; José de Oliveira et al., 2019).

A evolução do conhecimento é algo que ocorre a todo o momento e a produção de um trabalho científico de excelência é o alicerce para essa evolução (José de Oliveira et al., 2019). Neste sentido, a avaliação da pesquisa científica é crucial. Os métodos bibliométricos são, sobretudo ao nível dos grupos de investigação, departamentos universitários e institutos, um elemento indispensável, a seguir à revisão pelos pares, nos processos de avaliação da investigação. A revisão por pares é aplicada para analisar propostas de investigação, nomear grupos de investigação e avaliar grupos ou programas de investigação. Porém este método é tipicamente uma avaliação qualitativa do desempenho da investigação, ao contrário da análise bibliométrica que fornece uma avaliação quantitativa, através da utilização dos seus indicadores (Van Raan, 2003). De acordo com Abramo et al. (2019), apesar da revisão por pares ser o método preferido dos académicos e investigadores, a bibliometria demonstra ser um método superior à revisão por pares na previsão do impacto académico.

Os indicadores bibliométricos são ferramentas de avaliação da produtividade académica. Existem vários tipos de indicadores bibliométricos sendo o mais conhecido para avaliação de autores, a contagem de publicações, seguido da contagem de citações (Choudhri et al., 2015). A análise de citações é uma técnica bibliométrica que considera a citação como unidade básica de análise (Tu, 2012) e baseia-se na análise sobre quais os autores e artigos que são citados com maior frequência, e por conseguinte, mais valiosos e úteis para os outros

investigadores (Pasadeos et al., 1998). Porém, esta análise depende completamente de citações, e caso o autor não tenha identificado ou citado corretamente os artigos relacionados, a revisão da literatura não será abrangente. Essa dificuldade é encontrada em áreas emergentes e como tal, outro indicador bibliométrico deve ser tido em consideração. Neste sentido, análise de rede de palavras-chave é um método mais poderoso para áreas de pesquisa emergentes (Madani & Weber, 2016). As palavras-chave são consideradas os elementos básicos da representação de conceitos do conhecimento e têm sido comumente utilizadas para revelar a estrutura do conhecimento dos domínios da pesquisa (Su & Lee, 2010). De acordo com Pesta et al. (2018) a aplicação da bibliometria às palavras-chave do artigo, permite não só representar a opinião do autor, como também, detetar tópicos de pesquisa de tendências atuais e do passado. Estes autores referem igualmente outras vantagens da aplicação da bibliometria às palavras-chave, como por exemplo, perceber se a utilização de determinadas palavras-chave aumentou ou diminuiu no tempo e averiguar quais são as palavras-chave que estão associadas a uma maior probabilidade de um determinado artigo ser citado.

De acordo com Choudhri et al. (2015), a utilização da bibliometria na medicina está num estado relativamente incipiente. Por todas as razões apresentadas anteriormente, foi efetuada uma análise bibliométrica tendo por base a IA na saúde, podendo a temática abordada nesta dissertação constituir um contributo importante para a investigação e aplicação desta metodologia no campo da medicina.

3.2. Método de investigação

3.2.1. Fase I - Desenho do estudo

Primeiramente foram definidas duas questões de investigação. Posteriormente, foi seguida a pesquisa de palavras-chave, utilizando as *keywords Medical Subject Headings (MeSH): machine learning e deep learning* que originou 47,730 resultados. Em seguida, objetivou-se visualizar a estrutura do conhecimento a um nível micro, utilizando os termos *healthcare e artificial intelligence*, obtendo-se 707 resultados.

3.2.2. Fase II - Recolha e processamento de dados

A recolha de dados foi efetuada na base de dados da WoS (*Web of Science Core Collection*), propriedade da *Clarivate Analytics*. A escolha desta base de dados como ferramenta para pesquisas bibliométricas, decorre de um conjunto de fatores. Em primeiro lugar e segundo

Singh et al. (2020) a WoS apresenta uma maior precisão agregada, relativamente às bases de dados Scopus e Dimensions, ou seja, a WoS apresenta uma classificação de assuntos mais precisa e consistente em comparação com as outras bases de dados. Segundo os autores a classificação de artigos de pesquisa em diferentes áreas temáticas é uma tarefa extremamente importante na análise bibliométrica. Adriaanse et al. (2011) verificaram que a WoS apresenta periódicos mais exclusivos quando comparada com a Google Scholar e a Scopus. Por último, a cobertura de periódicos na WoS é mais elevada em áreas como a medicina e saúde, ciências naturais e tecnologia (Aghaei Chadegani et al., 2013; Birkle et al., 2020). Os periódicos em inglês encontram-se maioritariamente representados em detrimento de outros idiomas (Birkle et al., 2020), facto que para este estudo corresponde a um critério de inclusão.

Uma das bases de dados contidas na WoS, a WoS *Core Collection* fornece uma grande quantidade de fontes de periódicos e publicações oficiais, que podem ser exportadas e importadas para a plataforma de análise bibliométrica. A WoS *Core Collection* inclui 6 Índices de Citação (*Science Citation Index Expanded* (SCI-EXPANDED), *Social Sciences Citation Index* (SSCI), *Arts and Humanities Citation Index* (A&HCI), *Conference Proceedings Citation Index-Science* (CPCI-S), *Conference Proceedings Citation Index-Social Science & Humanities* (CPCI-SSH), *Emerging Sources Citation Index* (ESCI)) e 2 Índices Químicos (*Current Chemical Reactions* (CCR-EXPANDED), *Index Chemicus* (IC)). Para garantir a veracidade e abrangência dos dados, foram incluídos na pesquisa todos os bancos de dados acima mencionados. Seguiu-se a pesquisa avançada de palavras-chave, resultando o seguinte conjunto de palavras-chaves final: ALL= ("artificial intelligence") OR ALL= ("AI") AND ALL= ("healthcare") OR ALL= ("health care") AND ALL= ("machine learning") AND ALL= ("deep learning"). Com estas palavras-chave obtiveram-se 707 artigos. Posteriormente aplicaram-se critérios de exclusão aos itens “anos de publicação, idiomas e tipos de documentos”. Excluíram-se os anos de publicação anteriores a 2019 e todos os idiomas que não o inglês. No que diz respeito ao item “tipo de documentos” e de acordo com Bornmann et al. (2014), estes recomendam limitar a análise bibliométrica a determinados documentos específicos, excluindo-se o item “cartas”. Como resultado dos itens excluídos obtiveram-se 639 artigos. A etapa seguinte passou pela leitura dos resumos, refinando-se os resultados pela exclusão dos artigos cuja temática não se coaduna com o problema de investigação. Obtiveram-se assim 486 artigos. A base de dados da WoS permite a criação de um ficheiro em “BibTex” que será utilizado na etapa seguinte.

3.2.3. Fase III - Análise de dados

Para efetuar a análise bibliométrica foi utilizado o software Bibliometrix versão 3.1 para não programadores. O Bibliometrix é uma ferramenta de código aberto, programado em linguagem R para análise quantitativa em bibliometria e cientometria (Aria & Cuccurullo, 2017). Neste sentido, o conjunto de dados no formato “BibTex”, foi importado para o aplicativo Biblioshiny (incorporado no software Bibliometrix), procedendo-se à análise bibliométrica descritiva do tema em discussão, mais concretamente, no que diz respeito ao número e tipo de publicações, categorias da WoS, principais fontes de publicação, países e afiliações, autores mais produtivos, autores mais citados e ocorrência de palavras-chave de forma a perceber qual a tendência do desenvolvimento da IA na saúde.

3.2.4. Fase IV – Mapeamento e análise de rede de palavras-chave

O mapeamento da ciência permite a investigação do conhecimento científico a partir de um posto de vista estatístico (Aria & Cuccurullo, 2017). São 3 as estruturas do conhecimento que podem ser analisadas: estrutura conceptual, estrutura intelectual e estrutura social. De acordo com as questões de investigação será abordada nesta última etapa a estrutura conceptual, que incide sobre principais temas/tópicos e tendências da ciência.

A estrutura conceptual representa relações entre conceitos ou palavras de um conjunto de publicações. Palavras que aparecem juntas num documento, irão estar relacionadas numa rede, a que denominamos de rede de co-palavras. Esta estrutura é utilizada para compreender os tópicos cobertos por um campo de investigação de forma a definir quais são os temas mais importantes e mais recentes na literatura científica. A análise fatorial e o mapa temático serão igualmente abordados nesta fase. A análise fatorial permite identificar subtemas ao analisar a proximidade das palavras. Palavras que estão próximas indica que estas partilham do mesmo tópico e palavras que se encontram distantes umas das outras, indica que uma pequena porção de artigos utiliza estas palavras juntamente (Aria & Cuccurullo, 2017). O mapa temático avalia a evolução dos temas por intervalo de tempo.

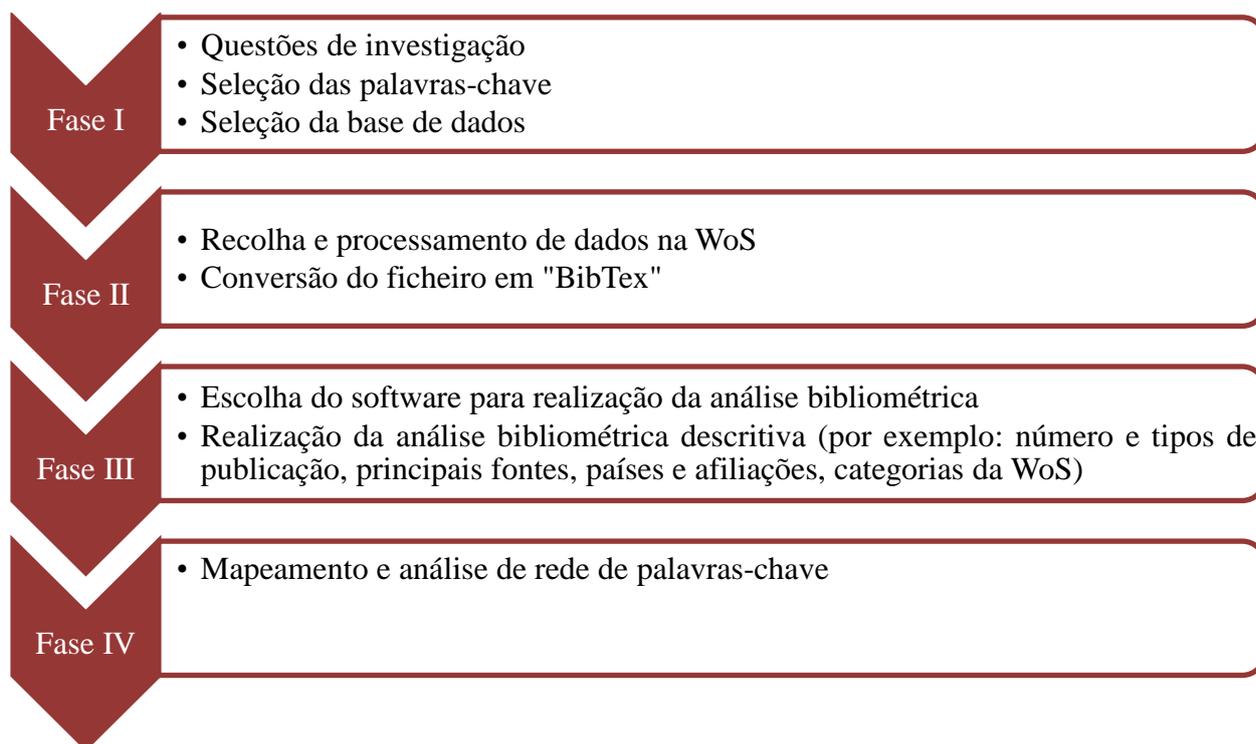


Figura 2 – Metodologia de investigação.

Fonte: produzido pela autora.

Capítulo 4: Resultados e Discussão

4.1 Análise Bibliométrica Descritiva

O conjunto de dados final, cujo intervalo de tempo vai desde 1 de janeiro de 2019 a 31 de janeiro de 2022, é composto por 486 documentos publicados em 333 fontes (revistas científicas, livros...), por 2548 autores, com um total de citações de 4713 e uma média de citações por documento de 9,7. Estas publicações foram citadas por 4166 outras publicações, 4069 das quais sem auto-citações, com um valor de h-index de 33¹ (*Clarivate Web of Science*). De acordo com Hirsch (2005), um valor de h-index de 20 é bom, de 40 é excelente e de 60 é algo único. Neste sentido, um valor de h-index de 33, sublinha a importância da aplicação da IA na saúde e como esta se está a tornar uma área significativa na investigação médica. No que diz respeito ao conteúdo dos documentos, as palavras-chave dos autores totalizam 1294 e as *Keyword Plus* 1058. O número de referências utilizadas corresponde a 25562 (Aria & Cuccurullo, 2017) .

De acordo com os dados da WoS a conjuntura da publicação anual de 2019 a 2022 é apresentada na Tabela 1.

Tabela 1 - Número de documentos por anos de publicação.

Anos de publicação	Número de documentos	% de 486
2022	14	2.881
2021	233	47.942
2020	160	32.922
2019	79	16.255

Fonte: *Clarivate Web of Science*. © Copyright Clarivate 2022.

Como se pode observar, de 2019 a 2021 verificou-se um aumento no número de publicações, o que indica o rápido desenvolvimento da IA na saúde. Os documentos obtidos em 2022 (ano corrente) correspondem apenas a 31 dias de publicação, porém caso o número de publicações por mês se mantenha constante, irá superar o ano de 2020.

Relativamente ao tipo de publicações e conforme a Tabela 2, verifica-se que a maioria das publicações provêm de artigos, contabilizando cerca de 54,5% do total das publicações. Os artigos de revisão e os artigos de conferências contabilizam cerca de 34,9% e 10,7%

¹ O h-index ou Hirsh index é uma métrica criada para quantificar a produtividade e o impacto de um autor e baseia-se no número de artigos desse autor e no número de citações que recebeu (Hirsch, 2005).

respetivamente. Os restantes tipos de documentos contabilizam um valor inferior a 10% do resultado total da pesquisa.

Tabela 2 - Estrutura da pesquisa por tipo de documentos.

Tipos de publicação	Número de documentos	% de 486
Artigos	265	54.527
Artigos de revisão	170	34.979
Artigos de conferências	52	10.700
Acesso antecipado	30	6.173
Capítulos de livros	2	0.412
Materiais editoriais	2	0.412

Fonte: *Clarivate Web of Science*. © Copyright Clarivate 2022.

Na avaliação da categorização das áreas de investigação da WoS relativa às publicações da presente temática, verifica-se que a área *Computer Science Artificial Intelligence* é a que mais se destaca com cerca de 15,23 % do total de publicações, seguida pela *Engineering Electrical Electronic* que contribui com cerca de 12,55% e seguida de perto pela *Computer Science Information Systems* com 11,93% e pela *Medical Informatics* com 11,73%. As restantes áreas contribuem com menos de 10% das publicações no total de 80 áreas identificadas na base de dados da WoS. As 10 principais áreas de investigação encontram-se listadas na Figura 3.

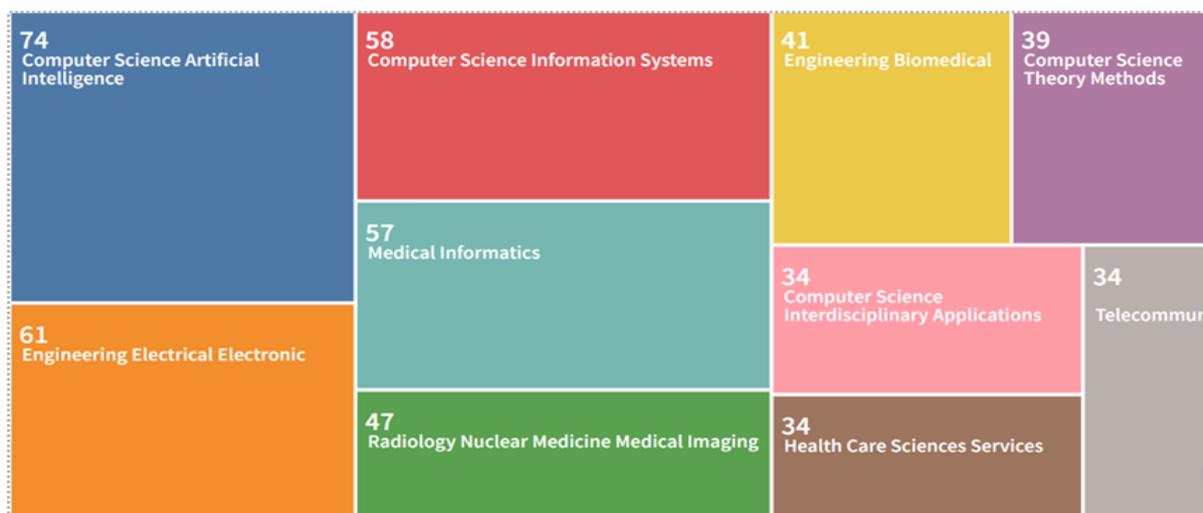


Figura 3 – As 10 principais áreas de investigação da WoS.

Fonte: *Citation Report graphic is derived from Clarivate Web of Science*, Copyright Clarivate 2022.

É igualmente fundamental identificar o núcleo de periódicos que estão particularmente dedicados a esta temática. De acordo com o postulado pela Lei de Bradford² e tal como consta na Figura 4, os periódicos *IEEE Access*, *Artificial Intelligence in Medicine* e *Journal of Medical Internet Research* fazem parte da Zona 1 – “Core Sources”. Na zona 1 constam 11,71 % do total dos periódicos, na zona 2 constam 40,24% das fontes e por último 48,05% dos periódicos fazem parte da zona 3.

² Lei de Bradford: os periódicos que contêm artigos sobre um determinado assunto estão organizados em ordem decrescente do número de artigos que publicaram sobre o assunto. Formam-se zonas sucessivas de periódicos com o mesmo número de artigos sobre o assunto (Alabi, 1979).

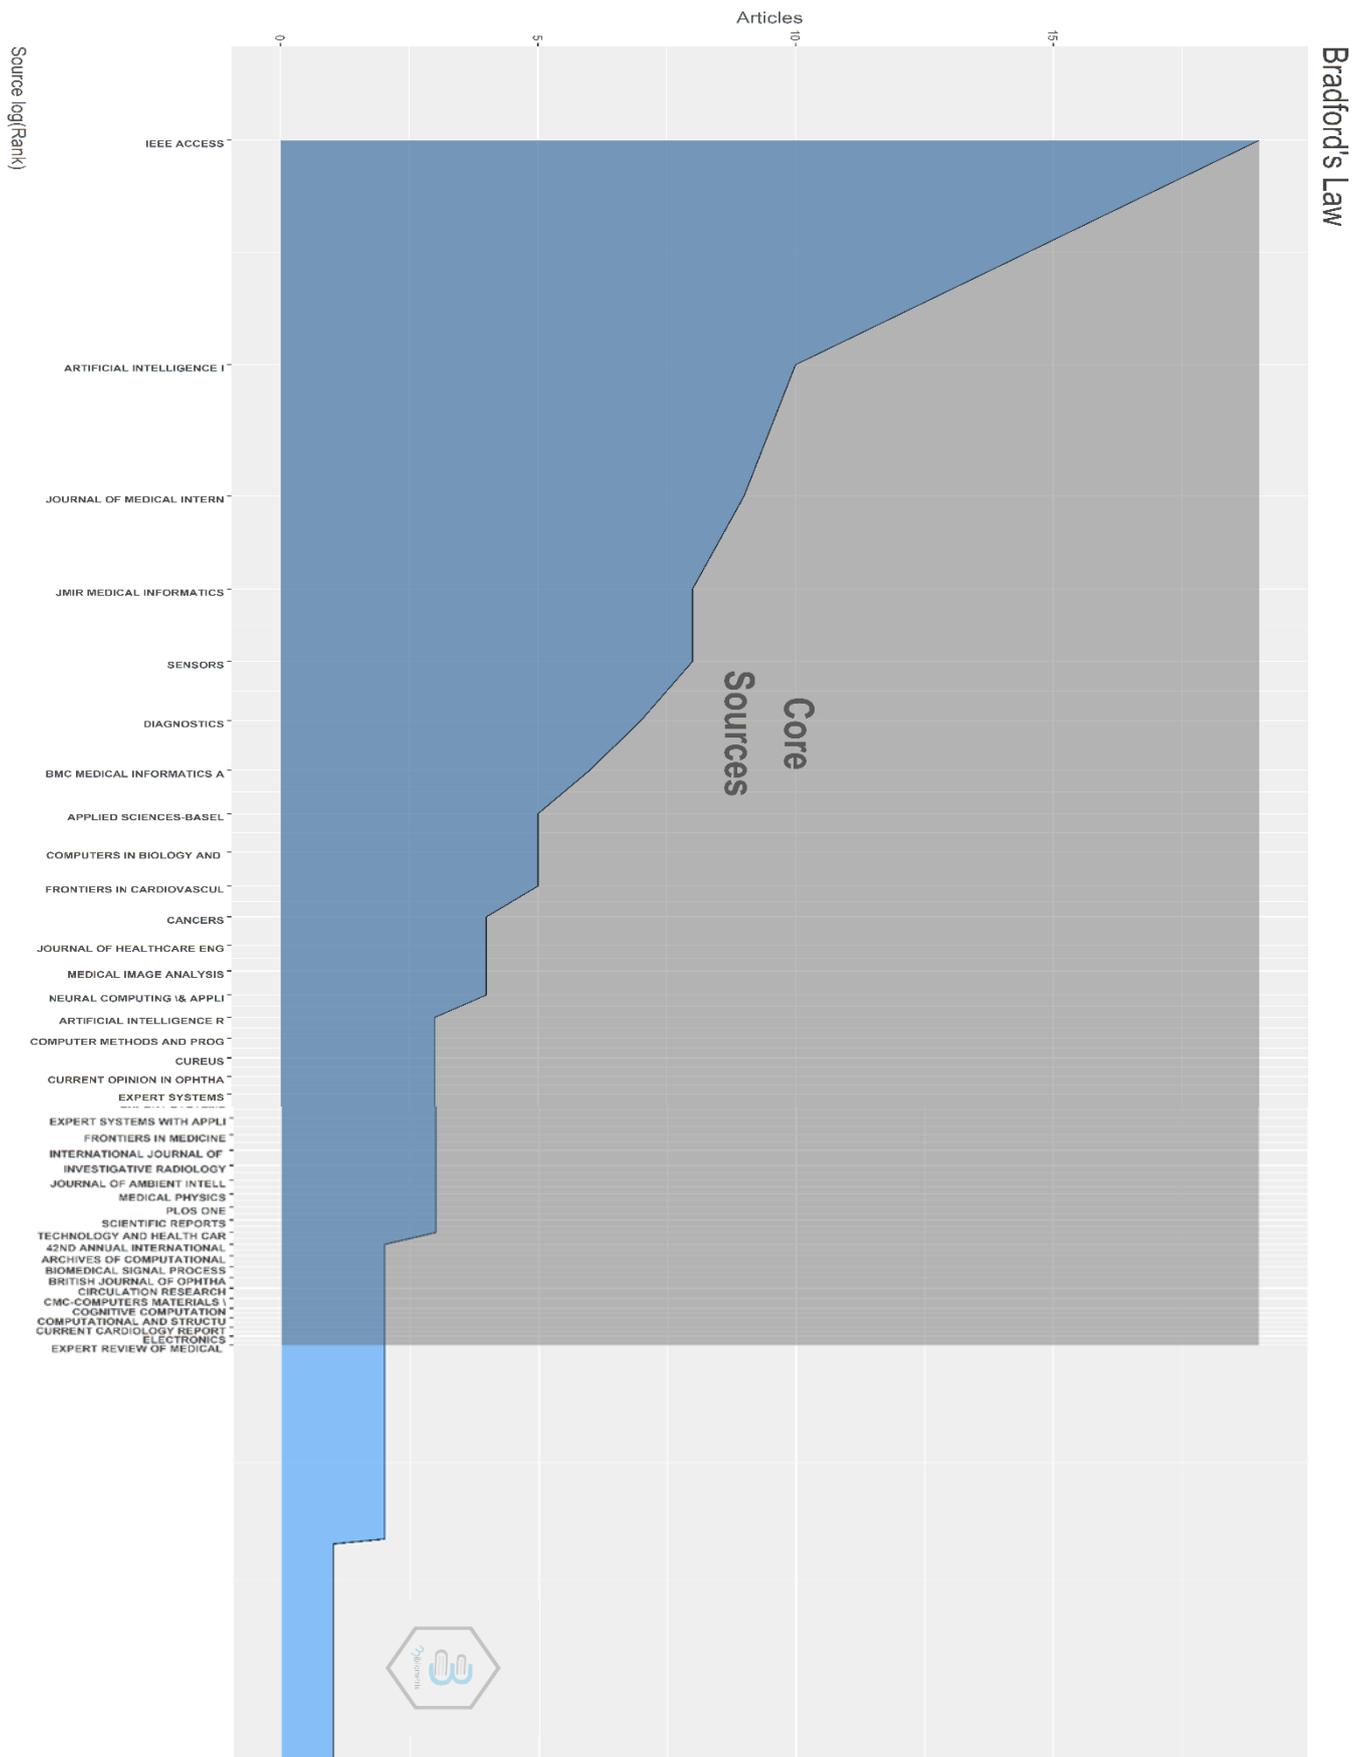


Figura 4 – Lei de Bradford: Core Sources (Zona 1): núcleo dos principais periódicos.

Fonte: produzido a partir do aplicativo Biblioshiny.

Nota: A Zona 1 é constituída por 40 periódicos. Uma vez que não é possível melhorar a qualidade da imagem, em seguida encontram-se listados os periódicos pertencentes à Zona 1, iniciando com a *IEEE Access* que está no primeiro lugar do ranking e terminando com a *Expert Review of Medical Devices*. Sendo assim:

IEEE ACCESS; Artificial Intelligence in Medicine; Journal of Medical Internet Research; JMIR Medical Informatics; Sensors; Diagnostics; BMC Medical; Informatics and Decision Making; Applied Sciences-Basel; Computers In Biology And Medicine; Frontiers In Cardiovascular Medicine; Cancers; Journal of Healthcare Engineering; Medical Image Analysis; Neural Computing & Applications; Artificial Intelligence Review; Computer Methods and Programs in Biomedicine; Cureus; Current Opinion in Ophthalmology; Expert Systems; Expert Systems with Applications; Frontiers in Medicine; International Journal of Advanced Computer Science and Applications; Investigative Radiology; Journal of Ambient Intelligence and Humanized Computing; Medical Physics; Plos One; Scientific Reports; Technology and Health Care; 42nd Annual International Conferences of the IEEE Engineering in Medicine and Biology Society: Enabling Innovative Technologies for Global Healthcare Embc'20; Archives of Computational Methods in Engineering; Biomedical Signal Processing and Control; British Journal of Ophthalmology; Circulation Research; CMC-Computers Materials & Continua; Cognitive Computation; Computational and Structural Biotechnology Journal; Current Cardiology Reports; Electronics; Expert Review of Medical Devices.

A Figura 5, apresenta as fontes de publicação mais relevantes que apresentam o maior número de artigos publicados sobre esta temática. Desta forma, a fonte de publicação com maior número de artigos publicados e, portanto, mais relevante é a *IEEE Access*, com 19 publicações, seguida da *Artificial Intelligence in Medicine* com 10 e do *Journal of Medical Internet Research* com 9 publicações.

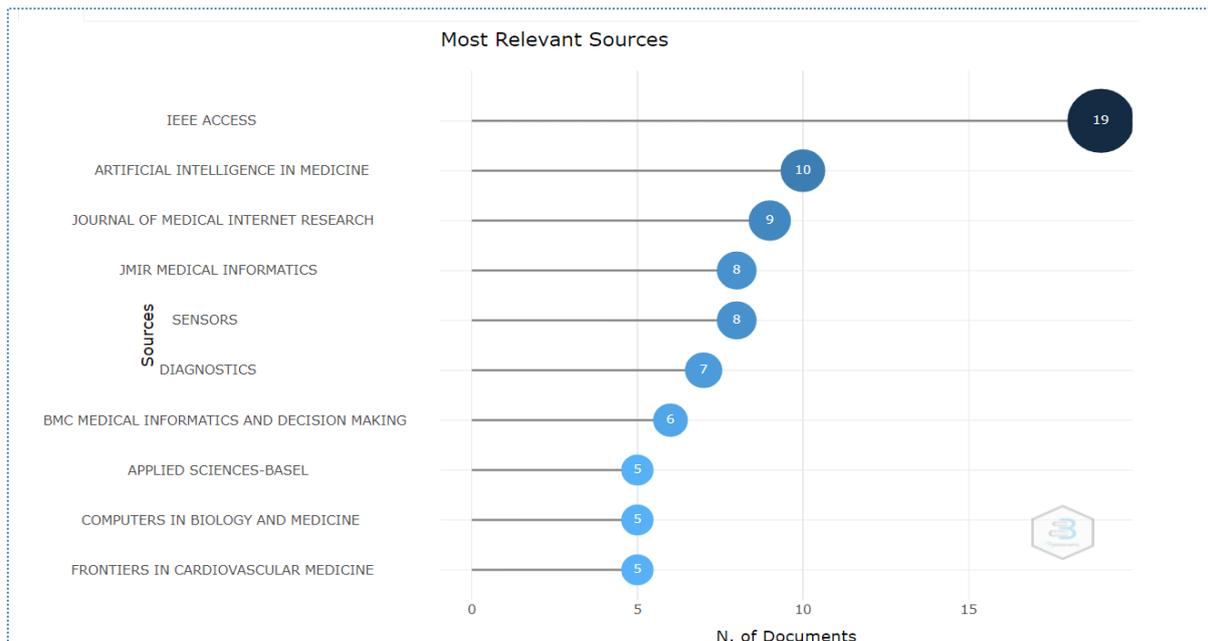


Figura 5 – Fontes de publicação com maior número de publicações.

Fonte: produzido a partir do aplicativo Biblioshiny.

Ao analisar o número de citações locais³ a partir das referências listadas, verifica-se, conforme a Figura 6 demonstra, que a *Plos One* é a fonte com maior número de citações locais a partir de referências listadas, contabilizando 423 citações locais, seguido da *Sci Rep-Uk*, com 409 e da *IEEE T Med Imaging* e *Lect Notes Comput Sc* ambas com 398 citações locais.

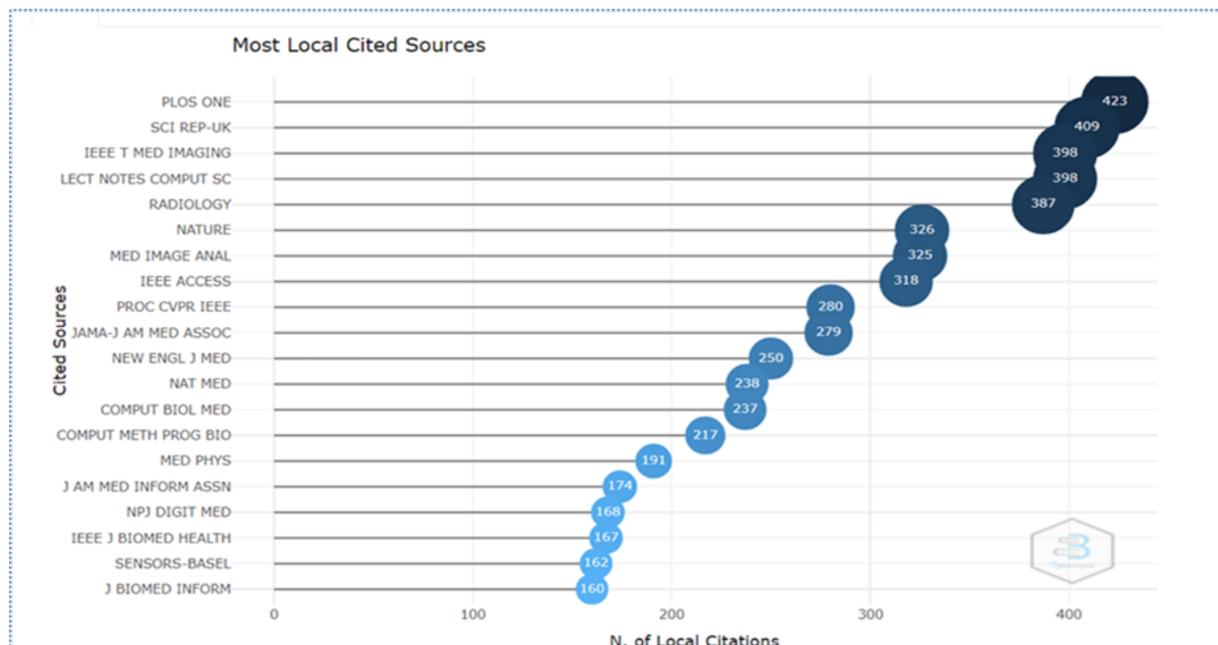


Figura 6 – Principais fontes de publicação e número de citações locais.

Fonte: produzido a partir do aplicativo Biblioshiny.

³Citações Locais (*Local Citations* = LC), corresponde ao número de vezes que um autor (ou um documento) incluído numa determinada coleção foi citado pelos documentos também incluídos nessa coleção (Aria & Cuccurullo, 2017).

No que respeita à análise efetuada aos autores e artigos, verifica-se que o autor mais produtivo é o Ting D.S.W., como consta na Figura 7 e reforçado na Tabela 3, com 7 artigos publicados (Foo et al., 2021; Grzybowski et al., 2020; Li et al., 2021; Ruamviboonsuk et al., 2020; Ting et al., 2021; Ting et al., 2019a; Xie et al., 2020) precedido por Chen J e Li J ambos com 6 artigos publicados. No entanto, como se pode observar pela Tabela 3 a maioria dos autores apenas contribuiu com 1 artigo.

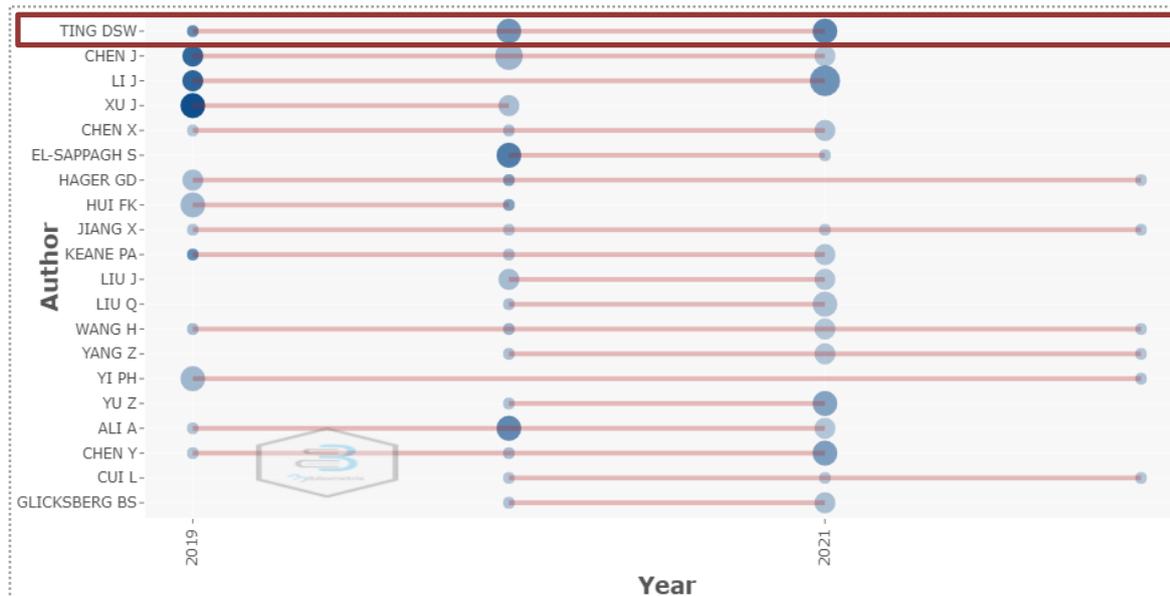


Figura 7 – Produtividade dos 20 principais autores de 2019 a 2022.

Fonte: produzido a partir do aplicativo Biblioshiny.

A linha vermelha representa a linha do tempo dos autores; o tamanho dos círculos é proporcional ao número de documentos produzidos por um autor por ano; a intensidade da cor do círculo é proporcional ao número total de citações por ano; o primeiro círculo na linha indica o momento a partir do qual o autor começou a publicar na área; quanto maior o círculo, maior o número de artigos que publicou um autor por ano; círculos com uma intensidade de cor mais profunda indicam contagens de citações mais elevadas.

Tabela 3 - Número de documentos e respetivo número de autores.

N documentos	N autores	Proporção de autores
1	2342	0,919
2	150	0,059
3	40	0,016
4	12	0,005
5	1	0
6	2	0,001
7	1	0

Fonte: produzido e adaptado a partir do aplicativo Biblioshiny.

Apesar do autor Ting D.S.W. ser o autor mais produtivo não é o autor mais citado. Ao avaliar o número de citações globais⁴ no intervalo de tempo de 2019 a 2022, verifica-se que o autor cujo artigo é mais citado é o Lundervold A.S. (Lundervold & Lundervold, 2019), descendo para a 4ª posição do ranking o autor Ting D.W.S., conforme pode ser observado na Tabela 4.

Tabela 4 - Os 10 principais autores com artigos mais citados.

Ranking	Autores	2019	2020	2021	2022	Média/ano	Citações Globais
1	Lundervold, AS and Lundervold, A	22	128	245	19	103,5	414
2	Chowdhury, MEH; (...); Islam, MT	0	20	155	23	66	198
3	Liang, H; (...); Xia, HM	35	55	74	6	42,5	170
4	Ting, DSW; (...); Wong, TY	8	49	56	4	29,25	117
5	Saba, L; (...); Suri, JS	11	36	50	7	26	104
6	Ali, F; (...); Kwak, KS	0	7	66	11	28	84
7	Waring, J; (...); Umeton, R	0	9	60	2	23,67	71
8	Schaffter, T; (...); Stolovitzky, G	1	11	55	2	23	69
9	Serag, A; (...); Hamilton, P	0	18	42	4	16	64
10	Rashidi, H; (...); Green, R	1	16	42	3	15,5	62

Fonte: produzido e adaptado a partir do WoS.

A análise da produção científica, no que diz respeito à contribuição dos países/regiões para o desenvolvimento da IA na área da saúde também foi efetuada. Os resultados demonstram

⁴Citações Globais (*Global Citations* ou *Total Citations* = TC), corresponde ao total de citações que um artigo, incluído na sua coleção recebeu, de documentos indexados de uma base de dados bibliográfica. Em suma, corresponde às citações recebidas por um artigo selecionado que consta na base de dados (Aria & Cuccurullo, 2017).

que Estados Unidos da América (EUA) são o país com maior produção científica nesta área, contribuindo com 135 artigos, seguindo-se a Índia com 52 e a China com 46 artigos.

Verifica-se igualmente que os países europeus estão a contribuir ativamente no desenvolvimento desta temática, contribuindo o Reino Unido com 26 artigos, a Itália com 19, a Alemanha com 11, a Espanha com 9, a França com 8 e a Holanda, a Irlanda e a Grécia com 7, 6 e 5 artigos respetivamente (Tabela 5).

Tabela 5 - Os 20 principais países mais produtivos.

Ranking	Países	Número de Artigos
1	EUA	135
2	Índia	52
3	China	46
4	Reino Unido	26
5	Itália	19
6	Coreia	17
7	Arábia Saudita	17
8	Canadá	12
9	Austrália	11
10	Egipto	11
11	Alemanha	11
12	Paquistão	10
13	Malásia	9
14	Singapura	9
15	Espanha	9
16	França	8
17	Japão	7
18	Holanda	7
19	Irlanda	6
20	Grécia	5

Fonte: produzido e adaptado a partir do aplicativo Biblioshiny.

Uma análise mais aprofundada pode ser observada na Tabela 6 na qual é possível verificar o total de citações e a média de citações por artigo e respetivo país. Os EUA continuam a ser o país com um maior número de citações, seguido pela China. No entanto, e surpreendentemente, a Noruega e o Qatar que não surgiram no top 20 dos países com maior produção científica na área de estudo, no que diz respeito à contagem de publicações, tornaram-se o 3º e o 5º países classificados com 410 e 222 de citações totais e uma média de citações por artigo de 102,50 e 111 respetivamente. Tal facto, implica que, embora a Noruega e o Qatar não

tenham produzido muitos artigos científicos sobre IA em saúde, os poucos publicados têm um grande impacto.

Tabela 6 - Total de citações e média de citações por artigo e por país.

Países	Total de Citações	Média de Citações por Artigo
EUA	1500	11,11
China	493	10,72
Noruega	410	102,50
Singapura	280	31,11
Qatar	222	111,00
Reino Unido	211	8,12
Coreia	190	11,18
Itália	150	7,89
Espanha	126	14,00
Índia	111	2,13
Holanda	104	14,86
Alemanha	101	9,18
Arábia Saudita	78	4,59
Irlanda	66	11,00
Paquistão	61	6,10
Canadá	58	4,83
Suiça	51	51,00
Brasil	49	16,33
Austrália	43	3,91
França	42	5,25

Fonte: produzido e adaptado a partir do aplicativo Biblioshiny.

Quanto à disseminação das instituições, os resultados revelam uma diversidade de afiliações, contando com 1185 espalhadas por 69 países. Como se pode observar pela Tabela 7, a produção científica nesta área provém essencialmente de países anglo-saxónicos.

Tabela 7 - Afiliações com maior produção científica e respetivo país de origem.

País	Afiliações	Número de Artigos
EUA	Icahn Sch Med Mt Sinai	39
EUA	Stanford Univ	35
EUA	Johns Hopkins Univ	32
Reino Unido	Imperial Coll London	22
Coreia	Seoul Natl Univ	20
EUA	Univ Calif San Diego	17
EUA	Duke Univ	15
China	Sun Yat Sen Univ	14
Canadá	Mcgill Univ	13
Reino Unido	Univ Oxford	13

Fonte: produzido e adaptado a partir do aplicativo Biblioshiny.

A análise de palavras-chave em publicações é uma ferramenta essencial para investigar quais são os tópicos/temas tendência numa determinada área (Song et al., 2019). No que diz respeito à análise de ocorrência das palavras mais frequentes, foram utilizados 2 parâmetros: as *Keywords Plus* e palavras-chave do autor. O termo *Keyword Plus*, consiste em palavras ou frases que aparecem com frequência nos títulos das referências de um artigo e não necessariamente no título do artigo ou como palavra-chave do autor. As palavras-chave do autor, consistem numa lista de termos, nos quais o autor acredita que melhor definem o conteúdo do seu artigo (Garfield, 1990). Para Garfield (1990) os termos das *Keywords Plus* são capazes de capturar o conteúdo de um artigo com maior profundidade e variedade. Porém e de acordo com Zhang et al. (2016), ao efetuarem uma análise comparativa entre as *Keyword Plus* e as palavras-chave do autor quer ao nível do campo de pesquisa quer ao nível do documento, verificaram que as estas são tão eficazes quanto as palavras-chave do autor na captação da estrutura do conhecimento do domínio científico, mas são menos abrangentes na representação do conteúdo de um artigo. Ao utilizar o parâmetro *Keywords Plus*, as palavras que ocorrem com maior frequência são *classification*, *prediction* e *diagnosis* (Figura 8), que estão relacionadas com as funções associadas aos métodos de ML e de DL na classificação, prognóstico e diagnóstico de inúmeras doenças.

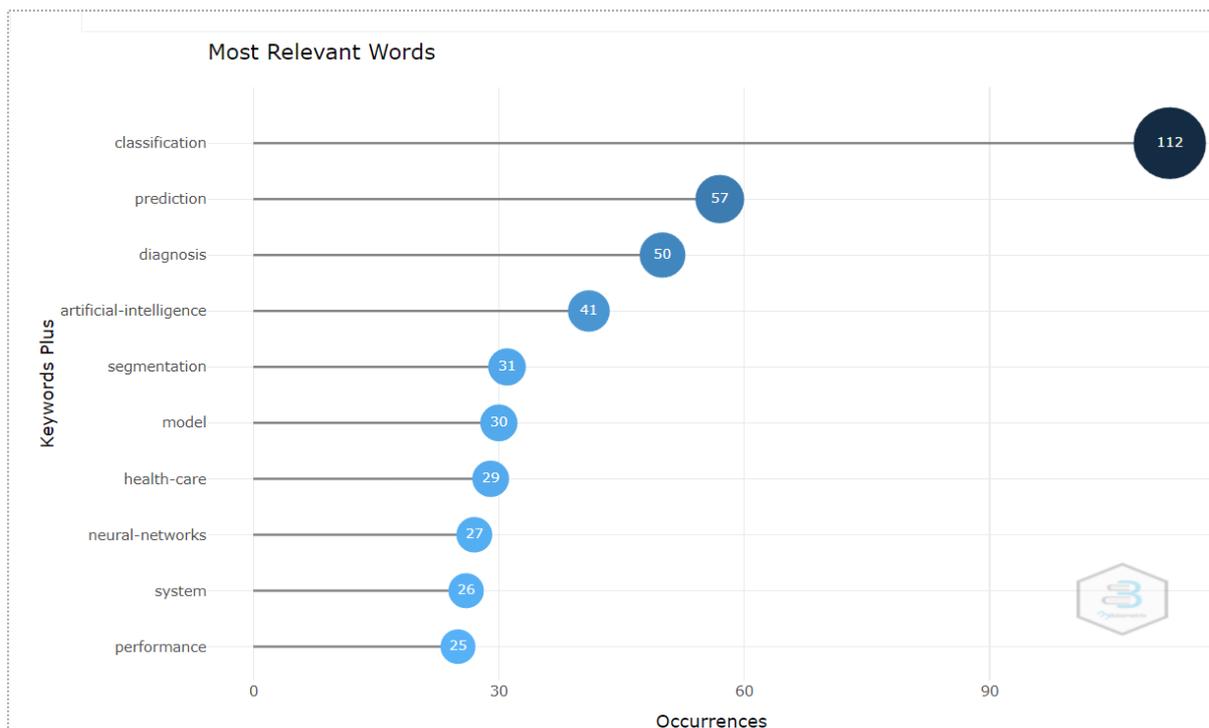


Figura 8 – Ocorrência das *Keywords Plus* com maior frequência.

Fonte: produzido a partir do aplicativo Biblioshiny.

Através da nuvem de palavras (Figura 9) é possível observar que, a palavra *classification* é a que apresenta um maior destaque, querendo dizer que grande parte dos artigos neste conjunto de dados incide sobre a utilização dos modelos de ML e mais concretamente de DL na classificação de doenças. A *word cloud* ou nuvem de palavras é uma representação visual da frequência das palavras. Este gráfico é utilizado para perceber rapidamente os termos mais proeminentes, e, por conseguinte, quanto maior for a frequência do termo dentro do texto que está a ser analisado, maior será a dimensão da palavra na imagem gerada. Porém as nuvens de palavras devem ser interpretadas com algumas ressalvas, uma vez que não conseguem agrupar palavras que têm o mesmo significado ou significado semelhante (Singh, 2012).



Figura 9 – Nuvem de palavras-chave utilizadas com frequência no campo da IA em saúde utilizando o parâmetro - *Keywords Plus*.

Fonte: produzido a partir do aplicativo Biblioshiny.

Ao utilizar as palavras-chave dos autores para determinar a frequência com que as palavras ocorrem, verifica-se que os dois primeiros termos são *deep learning* e *machine learning*, sendo o terceiro termo *artificial intelligence*. Porém e de acordo com Aria et al. (2017) os dois primeiros resultados são triviais porque consistem no conjunto de termos usados para construir a consulta de artigos. Sendo assim, as 5 principais palavras-chave dos autores com maior ocorrência são, *artificial intelligence*, *learning*, *Covid-19*, *healthcare* e *deep* (Figura 10).

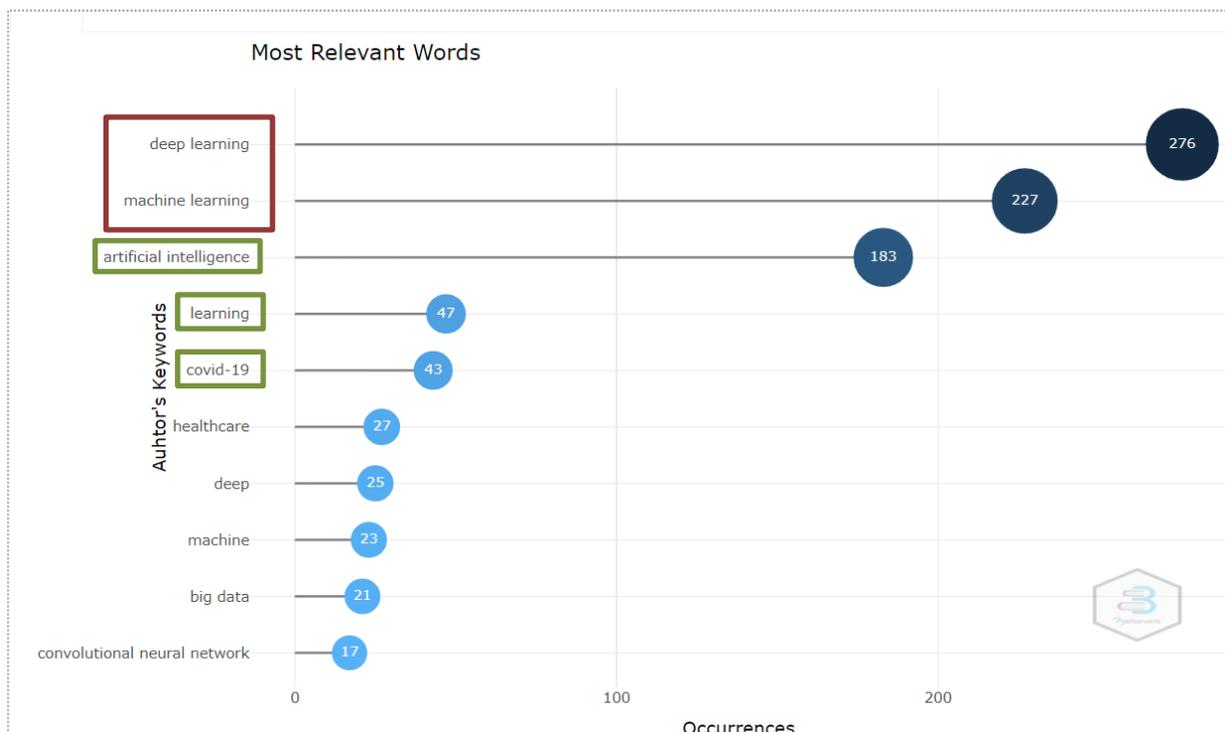


Figura 10 – Ocorrência das palavras-chave dos autores com maior frequência provenientes do conjunto de dados dos artigos relacionados com a IA na saúde.

Fonte: produzido a partir do aplicativo Biblioshiny.

O *tree map* ou mapa de árvore (Figura 11) corresponde a uma visualização de dados nos quais os mesmos são apresentados de forma hierárquica (Aria & Cuccurullo, 2017). Foi então gerado um mapa de árvore elaborado com as palavras-chave dos autores referente a um conjunto de dados proveniente de artigos relacionados à aplicação da IA na saúde. Verifica-se que os termos *deep learning* e *machine learning* correspondem respectivamente a 25% e a 20% do total de palavras-chave dos autores, seguindo-se os termos *artificial intelligence* com 17%, *learning* e Covid-19 ambos correspondendo a 4% do total de palavras-chave provenientes dos autores. De acordo com a Figura 12 que mostra o crescimento das palavras-chave dos autores desde 2019 a 2022, verifica-se um rápido crescimento dos termos *artificial intelligence* e *machine learning* a partir do ano de 2020. Porém é o termo *deep learning* que ocorre com maior frequência, apresentando um crescimento ascendente desde 2019, com maior expressão a partir de 2020. O termo *convolucional neural network*, é uma rede de DL e de acordo com a Figura 12, a ocorrência deste termo apresenta um ligeiro decréscimo a partir do início do ano de 2020 estabilizando o número de ocorrências ao longo do restante ano de 2020, 2021 e 2022. Não é surpreendente que o termo Covid-19 seja o termo que no início do ano de 2019 apresenta o mínimo de ocorrência, apresentando uma tendência crescente a partir de meados do ano de

2020. A análise de crescimento de palavras-chave valida ainda mais os resultados obtidos através da análise do mapa de árvore.

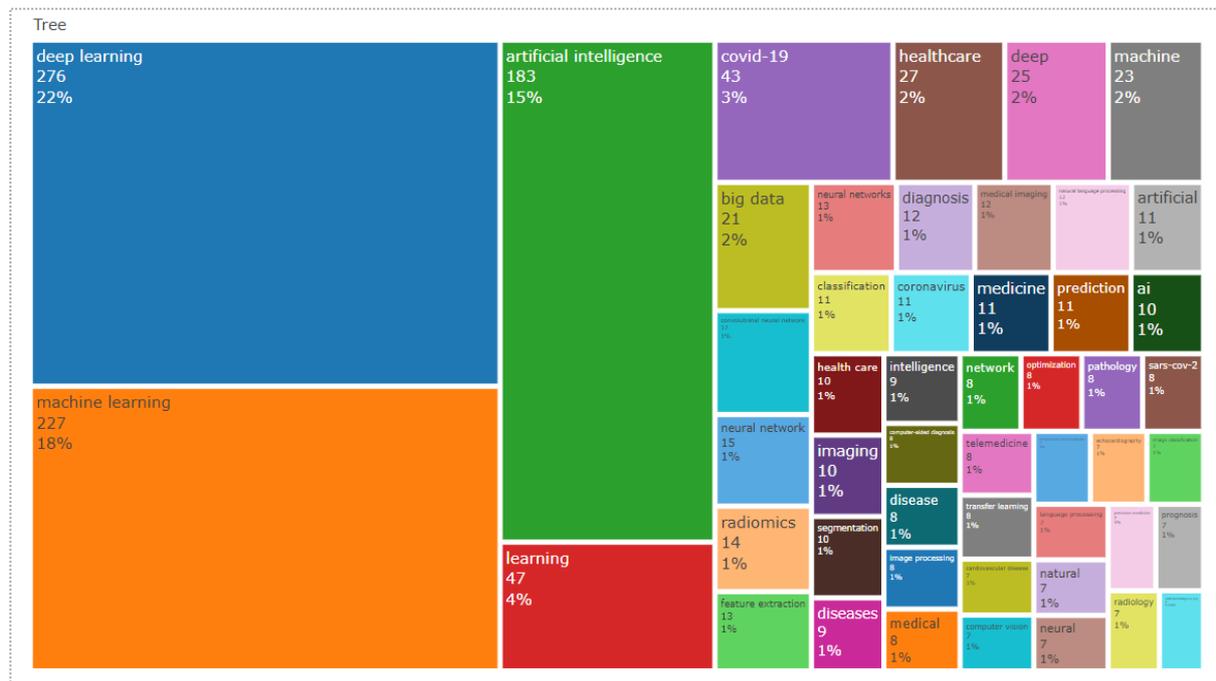


Figura 11 – Mapa de árvore gerado com as palavras-chave dos autores.

Fonte: produzido a partir do aplicativo Biblioshiny.

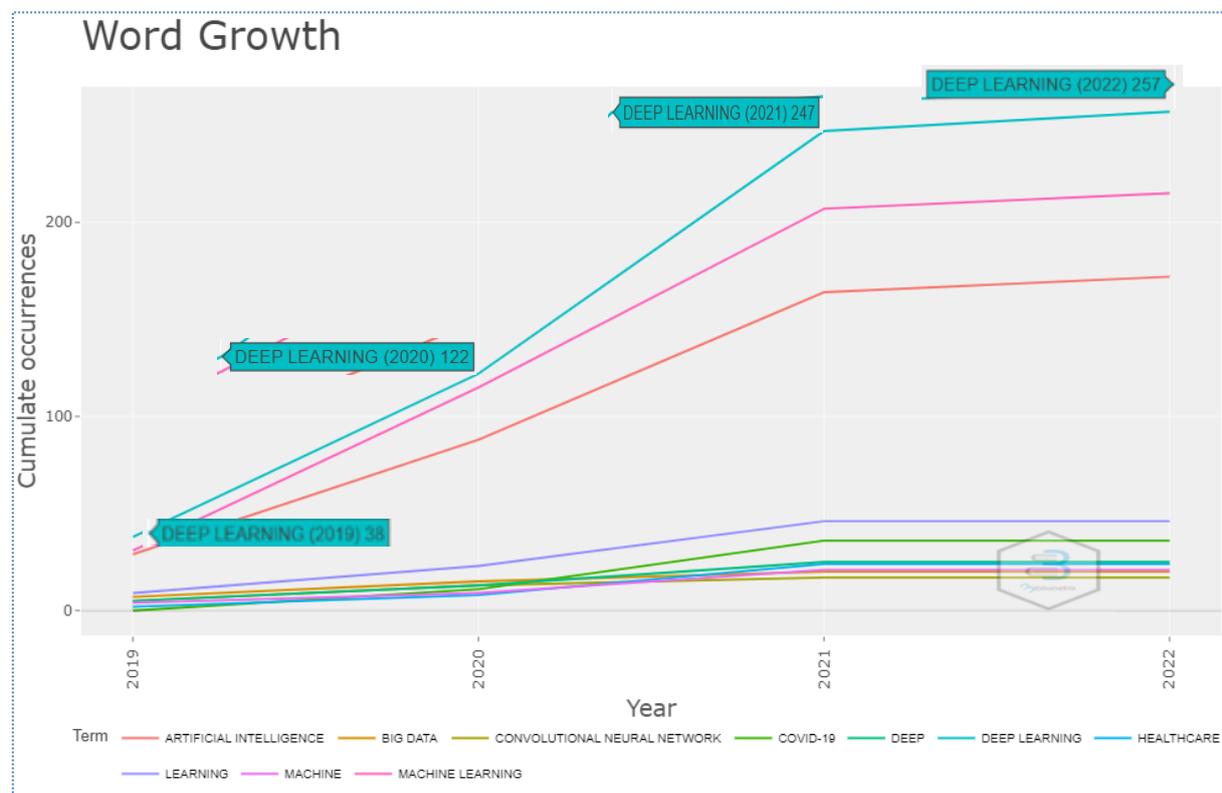


Figura 12 – Visão dinâmica das 10 principais palavras-chave dos autores de 2019 a 2022: visualização do crescimento das palavras-chave. Fonte: produzido a partir do Biblioshiny.

De forma a reforçar ainda mais os resultados obtidos e a relacionar as palavras-chave dos autores obtidas com a aplicação dos modelos de ML e de DL nas várias áreas médicas, foram analisados os 20 principais artigos com o maior número de citações locais. Consideraram-se os 20 principais artigos com o maior número de citações locais, uma vez que, correspondem a cerca de 57% do total das citações locais. Pode observar-se através da Tabela 8, uma maior aplicação do modelo de DL com a função de classificação nas diferentes áreas clínicas, com destaque para a área de cardiologia.

Tabela 8 - Para cada área médica esta tabela lista os modelos de ML e DL e as respectivas funções identificadas pelos 20 artigos mais citados.

Área	Tarefa	Descrição	Modelo
Pneumologia	Deteção	Deteção automática da pneumonia por COVID-19	CNN (1)
	Prognóstico	Risco de mortalidade por COVID-19	ANN (2)
Cardiologia	Diagnóstico; Classificação	Imagiologia cardíaca - estratificação do risco	DL (3)
	Classificação; Deteção; Prognóstico	Imagiologia para doença cardíaca isquêmica; deteção de arritmias; prognóstico de falência cardíaca	DL (4)
	Classificação; Deteção; Segmentação; Prognóstico; Diagnóstico; Tratamento	Previsão de dados sequenciais - ECG; determinação de risco cardiovascular; identificação de doentes para tratamento específicos	ML (clustering; deteção de anomalia); CNN; RNN (5)
	Diagnóstico; Classificação; Prognóstico	Imagiologia (ECG; Ressonância magnética; Tomografia Computadorizada)	ML; CNN (6)
Ortopedia	Classificação Segmentação; Prognóstico	Segmentação de imagens; diagnóstico auxiliado por computador; previsão de resultados clínicos e complicações	ML (classificação; regressão; clustering); ANN; CNN (7)
Oftalmologia	Diagnóstico; Deteção	Retinopatia diabética	CNN (8); CNN (9)
Oncologia	Extração; Classificação; Diagnóstico	Genómica	CNN; RNN; NPL; LSTM (10)
	Prognóstico	Cancro	FCN; CNN; RNN (11)
	Classificação; Deteção; Segmentação	Imagens médicas, aplicação em inúmeras doenças (tumores cerebrais, próstata, rim e coluna)	CNN; RNN (12)
Radiologia	Segmentação; Classificação; Diagnóstico; Prognóstico	Aplicação dos modelos em múltiplas doenças; cardíacas; cerebrais; pulmonares e oncológicas	FCN; CNN; RNN; DNN; AE (13)
	Classificação e Diagnóstico	Avaliação de imagens na doença pulmonar	CNN; RNN (14)
	Diagnóstico	Interpretação de mamografias	AI (15)
Patologia	Classificação	Identificação de novos padrões histológicos	VGG, ResNet, Inception - DL (16)
	Classificação; Extração	Aplicação de modelos a conjunto de dados	ML (clustering); CNN (17)
	Classificação; Diagnóstico	Aplicação do modelo em oncologia (identificação de metástases; classificação de imagens histológicas)	CNN (18)
Medicina Nuclear	Prognóstico	Previsão da resposta à terapia em oncologia e previsão de doença arterial coronária	ANN; Radiomics (19)
Medicina Interna	Identificação	Redução de erro humano	AutoML (20)

Nota⁵. Fonte: produzido pela autora.

⁵ (1) (Chowdhury et al., 2020);(2) (Abdulaal et al., 2020);(3) (Petersen et al., 2019);(4) (Krittawong et al., 2019);(5) (Benjamins et al., 2019);(6) (Romiti et al., 2020);(7) (Galbusera et al., 2019);(8) (Ting et al., 2019b);(9) (Shah et al., 2020);(10) (Xu et al., 2019);(11) (Zhu et al., 2020);(12) (Lundervold & Lundervold, 2019); (13) (Saba et al., 2019);(14) (Banerjee et al., 2019); (15) (Schaffter et al., 2020);(16) (Bizzego et al., 2019);(17) (Rashidi et al., 2019);(18) (Acs et al., 2020);(19) (Nensa et al., 2019);(20) (Waring et al., 2020).

4.2 Análise da Estrutura Conceptual

De forma a analisar a estrutura conceptual do conhecimento científico no âmbito da temática da IA na saúde, será necessário analisar o seu conteúdo. A estrutura conceptual representa as relações entre conceitos ou palavras num determinado conjunto de publicações (Aria & Cuccurullo, 2017). A análise desta estrutura contempla vários métodos de análise entre os quais a análise de rede por coocorrência de palavras-chave, a análise fatorial e de rede temática. A análise de rede por coocorrência de palavras-chave é utilizada quando se pretende compreender os tópicos incluídos num campo de pesquisa de forma a definir quais são os temas mais recentes e importantes no meio científico. A análise fatorial é similar à análise de rede e é útil para identificar subcampos de um determinado tema. A análise fatorial contempla técnicas de redução de dados, como é o caso da análise de correspondências múltiplas que permite estudar a associação entre variáveis qualitativas. Tal como na análise de rede por coocorrência de palavras-chave, os dados são agrupados em conjuntos (*clusters*). Por último a rede temática que efetua a análise de rede de coocorrência de palavras para definir quais os principais temas e tendências da ciência no momento.

Esta dissertação investigou em primeiro lugar a análise de rede de coocorrência de palavras-chave dos autores com o intuito de obter mais informações sobre as tendências da aplicação da IA na saúde e conseqüentemente dos modelos de ML e de DL. Na análise de rede, as redes compreendem representações gráficas dos relacionamentos (*edges* ou arestas) entre variáveis (*nodes* ou nós) (Hevey, 2018). Porém nem todos os “nós” que constam de uma rede são igualmente importantes na determinação da estrutura da rede. Por esse motivo são utilizados índices de centralidade que fornecem informações sobre a importância relativa de um nó na estrutura da rede. Os índices de centralidade mais comuns são: o grau; a força do nó; a proximidade ou *closeness*; a intermediação ou *betweenness* e o *clustering* (Golbeck, 2015; Hevey, 2018). No que diz respeito à análise em estudo, a mesma foi efetuada utilizando como algoritmo de *clustering*, o algoritmo de Louvain. Na Figura 13, pode observar-se que no *cluster deep learning*, as palavras *deep learning*, *machine learning* e *artificial intelligence* apresentam uma relação próxima. De acordo com Esfahani et al. (2019), as palavras-chave que são agrupadas no mesmo *cluster*, muito provavelmente refletem tópicos idênticos. A palavra *deep learning* apresenta um valor de *betweenness* e de *closeness* elevado (ANEXO A), o que indica que, por um lado, esta palavra desempenha um papel fundamental na rede, sendo importante na conexão que os outros “nós” têm entre eles e por outro, é uma palavra que está próxima dos outros “nós”. No que diz respeito ao *cluster learning*, as palavras *learning*, *machine* e *deep*

Nota: A cor representa os *clusters* aos quais cada palavra pertence; cada ponto colorido corresponde a uma palavra; o tamanho do ponto é proporcional à ocorrência dessa palavra; as linhas indicam a ligação entre palavras, desta forma uma linha mais grossa indica uma forte associação entre palavras-chave; as linhas mais finas representam uma associação fraca e palavras-chave sem linhas de conexão indicam que não foi estabelecida nenhuma associação. A cor correspondente aos 5 *clusters* identificados: ● *Deep Learning*; ● *Learning*; ● *Covid-19*; ● *Healthcare*; ● *Artificial*.

O mapa temático relativo à aplicação da IA na saúde é outra das análises realizada neste estudo. O objetivo de realizar um mapa temático é obter informações sobre a situação atual e futura da IA na saúde mais concretamente da aplicação dos modelos de ML e DL na saúde. A análise temática efetuada no aplicativo Biblioshiny aplica um algoritmo de *clustering* na rede de palavras, sendo possível destacar os diferentes temas de um determinado domínio (Aria & Cuccurullo, 2017). Desta forma, os *clusters* são considerados temas e o termo que está dentro da bolha representa o termo com maior valor de ocorrência, sendo o tamanho da bolha proporcional à ocorrência de palavras no *cluster*. Cada tema é caracterizado por dois parâmetros: a densidade e a centralidade. A densidade mede a coesão entre os “nós” e encontra-se representada no eixo vertical, enquanto a centralidade mede o grau de correlação entre os diferentes temas e encontra-se representada no eixo horizontal. Ambos os parâmetros medem se determinados temas estão bem desenvolvidos ou não e se são importantes ou não para o campo de pesquisa (Esfahani et al., 2019). É importante referir que o mapa temático está dividido em 4 quadrantes, sendo o quadrante superior esquerdo (Q1), o que representa temas muito desenvolvidos e isolados, ou seja, apresentam uma alta densidade, mas uma baixa centralidade. O quadrante superior direito (Q2), representa temas muito desenvolvidos e importantes para o campo de pesquisa ao contrário do quadrante inferior esquerdo (Q3), que representa temas emergentes ou desaparecidos. Por último, o quadrante inferior direito (Q4), representa temas básicos e transversais, ou seja, são importantes para um campo de pesquisa e são transversais às diferentes áreas de investigação (Agbo et al., 2021).

A partir da Figura 14 é possível observar que no Q2, o tema *big data* é um tema que está a ser bastante desenvolvido e é importante para o campo de pesquisa da aplicação da IA na saúde. Este tema está conectado com outros conceitos como *medical imaging*, *image segmentation*, *image classification* e *biomedical imaging*. Quanto à palavra *classification*, pode observar-se ser uma palavra com uma frequência de ocorrência elevada, ao analisar-se a ocorrência das *Keywords Plus*. Este quadrante apresenta assim uma elevada densidade e

centralidade. No que respeita ao Q1, os temas, *medicine* e *artificial* apresentam elevada densidade, mas baixa centralidade. Fazem parte do tema *medicine* conceitos como *prediction*, *diseases*, *clinical decision*, *support systems* e *personalized* (refere-se à medicina de precisão) e do tema *artificial*, fazem parte termos como *language processing*, *medical informatics* e *computer vision*, ou seja, são temas muito desenvolvidos, mas apenas importantes para um determinado campo de pesquisa. De ressaltar que o tema Covid apesar de estar neste quadrante não apresenta um grau de centralidade tão baixo comparativamente com os outros dois temas. O tema *precision medicine* que se encontra no Q3 é um tema emergente, fazendo parte deste tema termos como *artificial intelligence*, *machine learning*, *cardiovascular disease* e *detection*. É interessante notar que uma das palavras associadas ao tema *precision medicine* e mais recorrente em outros temas é *artificial intelligence*, o que indica que a medicina de precisão necessita do recurso à IA para entregar cuidados de saúde personalizados. Por último os temas *deep learning*, *healthcare* e *learning* são temas transversais e importantes para um campo de pesquisa, uma vez que, apresentam elevada centralidade, mas baixa densidade. Os valores de densidade e centralidade de cada *cluster* podem ser observados no ANEXO B.

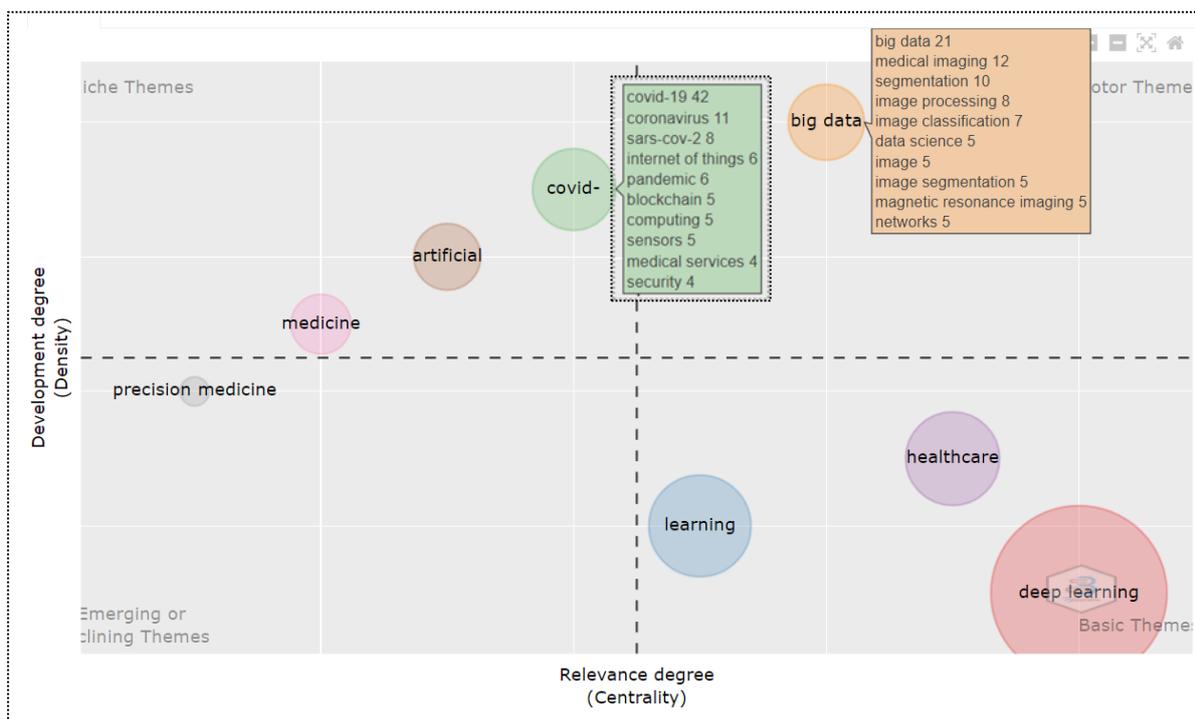


Figura 14 – Mapa Temático.

Fonte: produzido a partir do aplicativo Biblioshiny.

Uma evolução temática permite compreender quais os temas usados no início da pesquisa num determinado campo de investigação e os temas emergentes que são investigados na atualidade (Nath Sur et al., 2021).

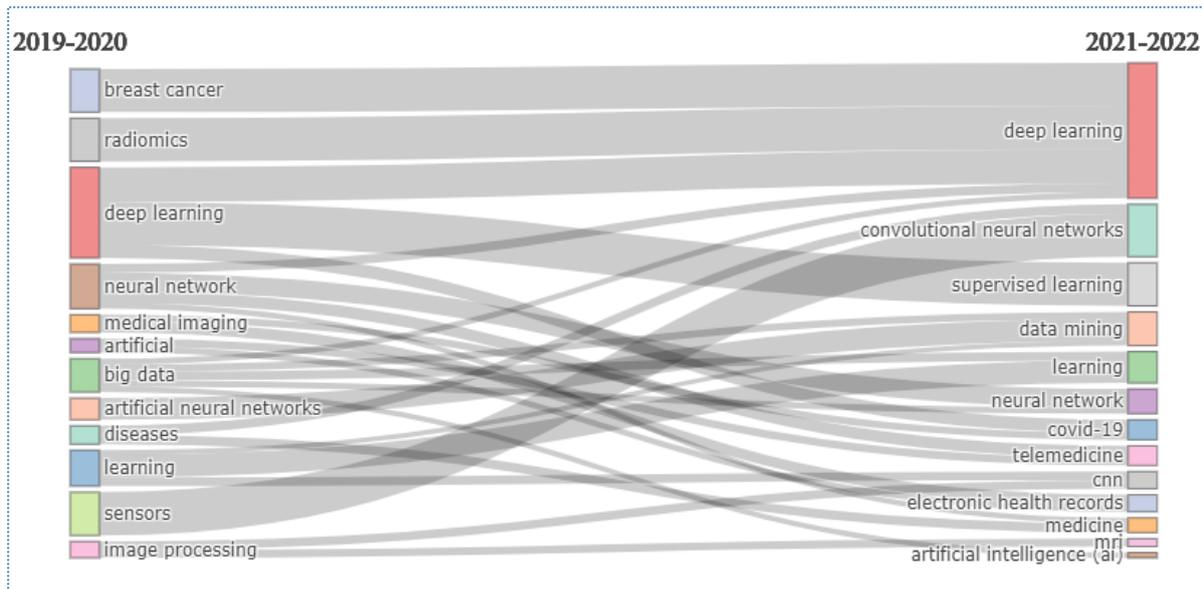


Figura 15 – Mapa de evolução temática das palavras-chave dos autores de 2019 a 2022, relativamente à aplicação da IA na saúde.

Fonte: produzido a partir do aplicativo Biblioshiny.

A Figura 15 demonstra a evolução das palavras-chave dos autores em 2 períodos de tempo (2019–2020 e 2021-2022). Observando o intervalo de tempo de 2019 a 2020, verifica-se que os principais temas sobre os quais os investigadores incidiram as suas pesquisas foram: *breast cancer*, *radiomics*, *deep learning*, *neural network*, *medical imaging*, *artificial*, *big data*, *artificial neural networks*, *diseases*, *learning*, *sensors* e *imaging processing*. Pode inferir-se que no período de tempo de 2019 a 2020, parte da investigação incidiu numa determinada área da medicina, a imagiologia, uma vez que apresenta 3 palavras-chave diretamente relacionadas com esta área: *radiomics*, *medical imaging*, *imaging processing*. As palavras-chave *deep learning* e *neural network* são palavras-chave importantes, uma vez que aparecem em ambos os períodos de tempo, revelando que os investigadores continuam a incidir as suas pesquisas na aplicação da IA e mais concretamente dos modelos de DL nas várias áreas da saúde, como iremos observar mais à frente. É de referir que para o mesmo período verifica-se a existência de palavras-chave relacionadas com as anteriores como *convolutional neural networks*, *supervised learning*, *learning*, e *artificial intelligence*. Verifica-se igualmente que no período de 2021 a 2022, surgem as palavras-chave *Covid-19*, *telemedicine* e *electronic health records*. A pandemia da doença Covid-19, permitiu por um lado alavancar outras áreas de pesquisa como

a telemedicina (Auener et al., 2020) e os registos eletrónicos de saúde (Javaid & Khan, 2021) e por outro permitiu que inúmeros investigadores se dedicassem à pesquisa de um tratamento preventivo desta doença (Casella et al., 2022).

A Análise de Correspondências Múltiplas (ACM) é, segundo Hoffman et al. (1992), um método de análise multivariada não linear que permite estudar a associação entre duas ou mais variáveis qualitativas. Para estes autores o conceito de homogeneidade constitui a base da ACM, uma vez que, a homogeneidade refere-se à extensão em que diferentes variáveis medem a mesma característica ou características, especificando assim algum tipo de similaridade. Como resultado da ACM é possível visualizar um gráfico, no qual são observadas as distâncias entre as categorias das variáveis e as observações.

Neste sentido e como se pode verificar na Figura 16, observam-se 2 *clusters* de palavras, um *cluster* com a cor azul e outro com a cor vermelha, que correspondem às palavras-chave dos autores e que estão identificados através do método hierárquico de *clusters* (Aria & Cuccurullo, 2017). Em cada *cluster* pode observar-se palavras que estão relacionadas entre si. No *cluster* com a cor azul, verifica-se que as palavras *sars.cov.2*, *coronavírus* e *natural language processing* estão relacionadas e por isso agrupadas. O *cluster* com a cor vermelha apresenta um maior número de palavras que se relacionam entre si, o que demonstra que inúmeras publicações relacionam as palavras listadas neste *cluster*.

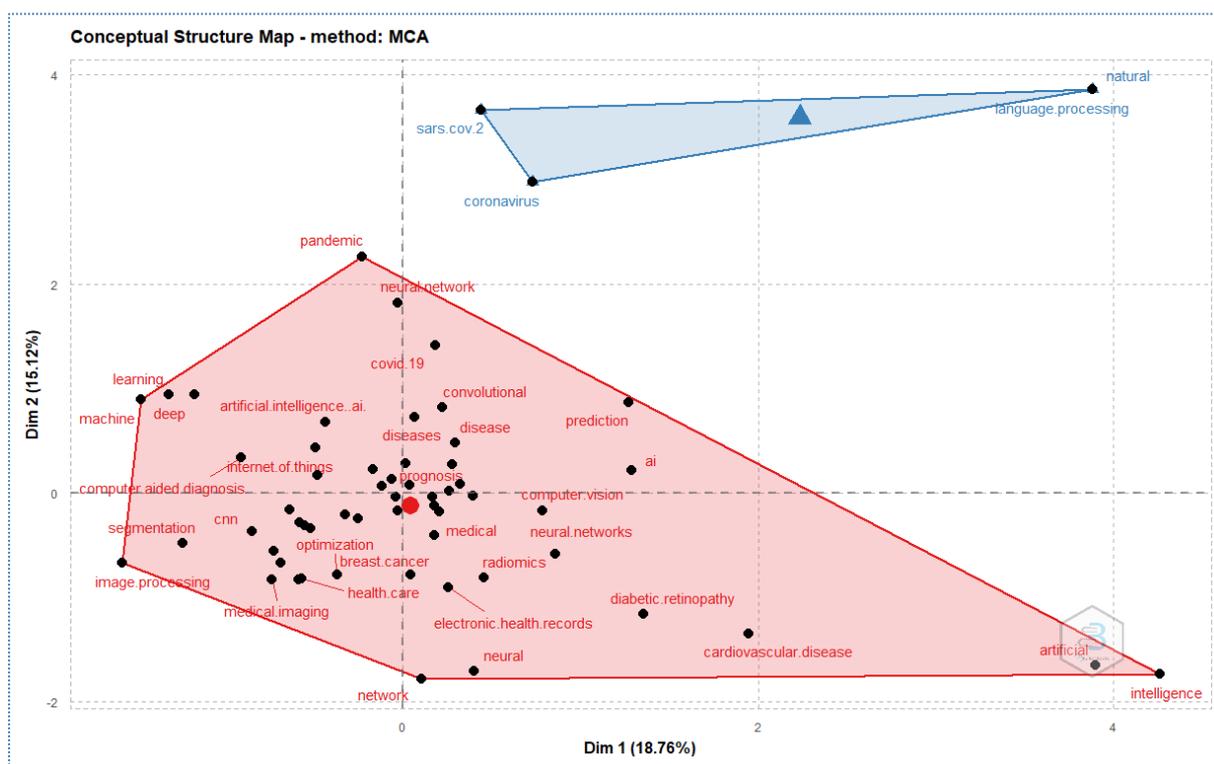


Figura 16 – Mapa da Estrutura Conceptual correspondente à aplicação da IA na saúde através do método: Análise de Correspondências Múltiplas.

Fonte: produzido a partir do aplicativo Biblioshiny.

A Figura 17 representa um dendrograma e é comumente criado como resultado do *cluster* hierárquico, apresentado anteriormente. O dendrograma é um diagrama de ramificação que mostra as relações hierárquicas entre categorias e variáveis. As categorias são organizadas de acordo com o quão semelhantes ou diferentes elas são umas das outras, ou seja, quanto maior o seu nível de similaridade mais correlacionadas estão as variáveis entre si (coeficiente de correlação de Pearson). Tal facto é verificado através da altura das categorias, isto é, categorias cujas alturas são próximas são semelhantes entre si, quanto maior a diferença na altura maior a discrepância entre as categorias (Forina et al., 2002). Neste sentido e avaliando o dendrograma produzido pelo aplicativo Biblioshiny, verifica-se que o mesmo está dividido em 2 categorias. Na primeira categoria, a palavra *Natural Language Processing* (NPL) surge relacionada com outras duas palavras, a *sars.cov.2* e o *coronavírus*. A NPL é uma área da ciência da computação, utilizada na análise preditiva da Covid-19 (Meystre et al., 2022). A segunda categoria pode dividir-se em 2 seções. A primeira seção é constituída pelas palavras *artificial* e *intelligence* e a segunda seção é a que apresenta um maior nível de similaridade e, portanto, uma maior correlação entre as palavras, apresentando igualmente um maior número de agrupamentos

finais. Desta forma, a segunda seção é constituída por palavras que remetem para diferentes métodos de aprendizagens, como *convolutional*, *cnn*, *segmentation*, *neural networks*, *machine learning*, *deep*, as suas funções, como *prediction*, *prognosis* e *diagnosis*, e a sua aplicação em diferentes áreas da medicina, como *cardiovascular disease*, *diabetic retinopathy* e *breast cancer*.

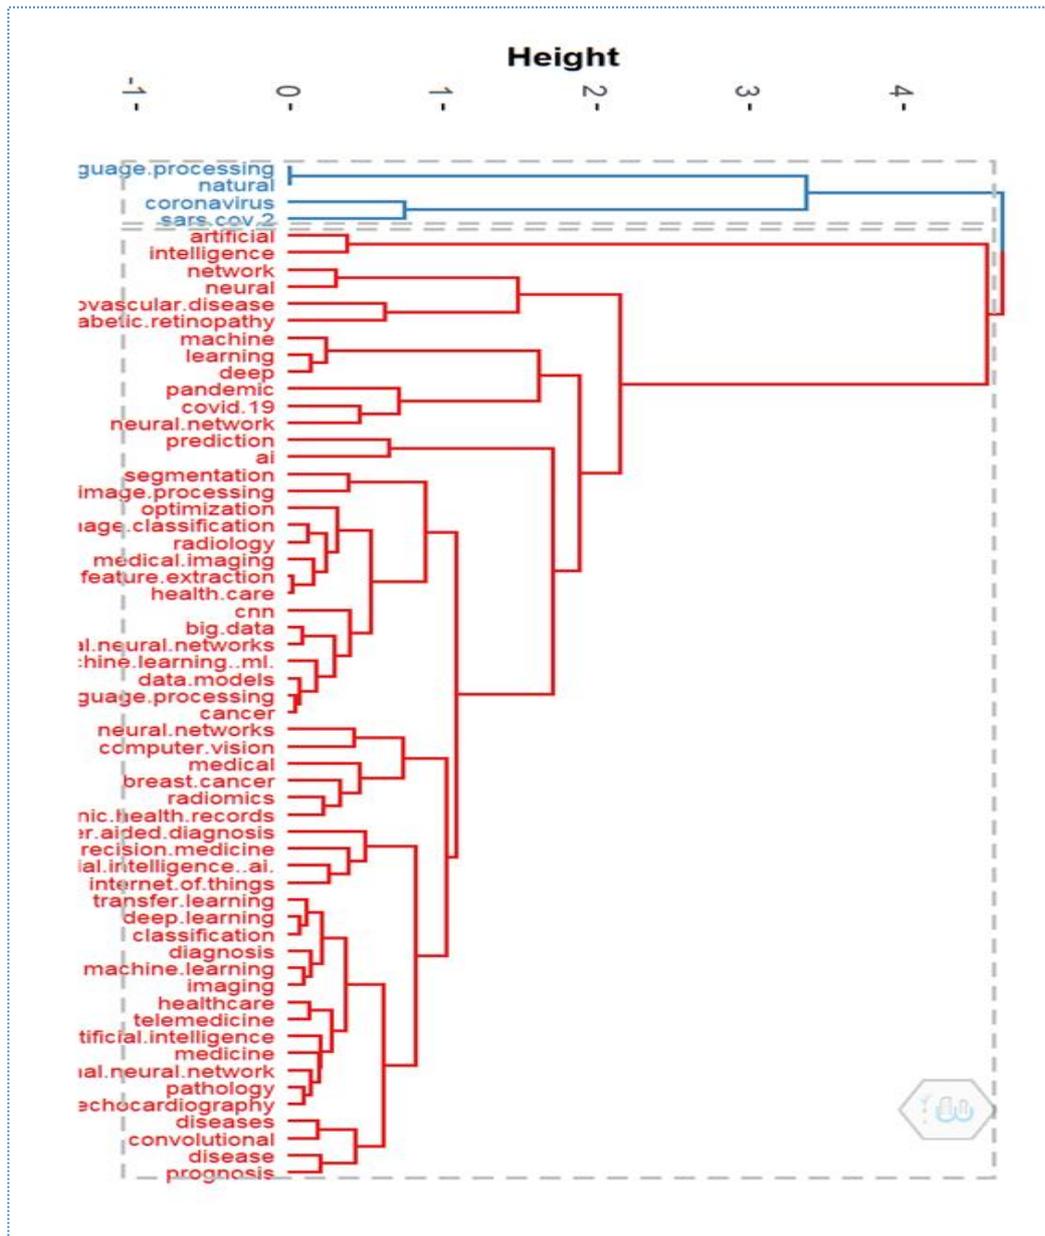


Figura 17 – Dendrograma efetuado a partir das palavras-chave dos autores tendo em conta o seu nível de similaridade.

Fonte: produzido a partir do aplicativo Biblioshiny.

4.3 Discussão dos Resultados

Este estudo teve por base as QI apresentadas no capítulo 1 e que nesta seção pretende-se dar resposta.

QI1: Como é que a inteligência artificial, e as suas respetivas ferramentas aplicadas à saúde, evoluiu ao longo do tempo?

Os resultados deste estudo indicam um interesse crescente em relação à aplicação da IA na saúde, constituindo um campo emergente de investigação em diversas áreas da medicina, com um maior foco na utilização de modelos de DL. Como evidenciado na Tabela 1, as pesquisas que têm por base a IA na saúde apresentam um crescimento de 2019 a 2021, sendo esse crescimento corroborado por outros autores (Fosso Wamba & Queiroz, 2021; López-Robles et al., 2021; Marreiros et al., 2021; Prema et al., 2021; Tran et al., 2019b). Os avanços na tecnologia, têm permitido soluções altamente sofisticadas, tecnologicamente avançadas e computacionalmente exigentes, o que provavelmente explica a expansão sem precedentes da literatura científica sobre IA na saúde (Tran et al., 2019a). Esse crescimento é atribuído à produção prolífica da pesquisa nos EUA, Índia e China, sendo nos EUA onde se concentra o maior número de afiliações mais produtivas neste campo. Segundo Tran et al. (2019b), os EUA são efetivamente o país com uma maior produção científica sobre esta temática, com um grande número de afiliações a apoiar esta produção, porém, coloca a Europa em segundo lugar, facto que não é corroborado por este estudo. Alguns países da Europa encontram-se efetivamente entre os 20 países mais produtivos, porém é a Índia que ocupa o segundo lugar nesta lista. Este resultado pode dever-se ao facto de nos últimos anos, o ecossistema de *startups* indiano apresentar um crescimento significativo, estando a Índia entre as principais nações que conseguiram milhões de financiamentos para *startups* de base tecnológica na área da saúde no ano de 2020 (Wisetsri, 2021). A análise indica um crescimento das palavras-chave, *deep learning*, desde 2019 a 2022 relativamente às palavras-chave *machine learning* e *artificial intelligence*, o que sugere uma maior produção científica relativamente à aplicação deste modelo nos diversos campos da medicina. O crescimento do *deep learning* na saúde é corroborado por Piccialli et al. (2021), no qual refere que, de 2016 até 2021 verificou-se uma produção superior a 1200 artigos respeitantes à aplicação do modelo de DL na medicina. Neste estudo, a análise de rede de coocorrência de palavras-chave dos autores indica igualmente que as palavras *deep learning* apresentam uma maior frequência de coocorrência, seguida das palavras *machine learning* e *artificial intelligence*. Este resultado é corroborado por Fosso Wamba et al (2021) e parcialmente corroborado por Tran et al. (2019a), no qual refere que as

palavras *deep learning* e *machine learning* são as que apresentam uma maior frequência de coocorrência na sua análise de rede, porém a palavra *robotics* surge como palavra-chave com maior frequência ao contrário do verificado neste estudo, no qual a palavra *artificial intelligence* se destaca. Segundo Penteado et al. (2021, p. 129) as palavras *deep learning* e *machine learning* dominaram igualmente a rede de coocorrência de palavras-chave dos autores no intervalo de tempo de 2016 a 2021 no seu estudo. É importante ressaltar que no estudo de Penteado et al. (2021, p. 129), as palavras *Internet of Things* (IoT), *Electronic Health Records* (EHR) e *big data*, fazem parte da análise de rede de coocorrência de palavras-chave neste intervalo de tempo. Neste estudo é possível observar no mapa de evolução temática das palavras-chave dos autores de 2019-2020, que as palavras *big data*, *deep learning*, ANN, *neural network*, *medical imaging*, *learning*, *imaging processing*, *radiomics* e *breast cancer* são algumas das palavras dominantes neste intervalo de tempo. Verifica-se também que no intervalo de tempo de 2021 a 2022 há uma consolidação do modelo de DL, através das palavras *deep learning*, *cnn*, *convolucional neural network*, *neural network*, *data mining* e *learning*. À semelhança dos autores Penteado et al. (2021, p. 129), as palavras *big data* e EHR, fazem igualmente parte das palavras dominantes neste mapa evolutivo. A reforçar a tendência crescente da pesquisa relacionada com o *big data*, observa-se que no mapa temático surge no Q2, o que significa que é um tópico tendência. Segundo Fosso Wamba et al. (2021) as ANN, CNN, *big data* são tópicos tendência, que estão a ser utilizados em diversas áreas, como no diagnóstico, EHR, prognóstico, detecção precoce de doenças e reconhecimento de imagem.

Q12: Quais são as tendências emergentes da aplicação da inteligência artificial, mais concretamente dos modelos de *machine learning* e *deep learning* na saúde, no que diz respeito ao prognóstico, diagnóstico e tratamento de doenças?

Verifica-se que o modelo de DL relativamente ao modelo de ML é aquele que é maioritariamente aplicado nas áreas clínicas identificadas. A cardiologia é a área na qual os modelos de ML e de DL são mais aplicados, com tarefas que incluem a detecção, classificação, diagnóstico e prognóstico de doenças cardiovasculares. Os autores Tran et al. (2019a) corroboram este facto, referindo que os modelos de ML e de DL são comumente utilizados na classificação, diagnóstico e prognóstico de doenças cardiovasculares. É possível igualmente observar na rede de coocorrência de palavras-chave, que as palavras *cardiovascular disease*, são representativas do *cluster artificial*, indicando que é uma área clínica com expressão neste conjunto de dados.

A palavra Covid-19 ganhou expressão neste conjunto de dados, uma vez que, tendo esta doença surgido em 2019, os investigadores em todo o mundo estão a concentrar os seus esforços na pesquisa de soluções (Auener et al., 2020). É na área da pneumologia que esta doença se enquadra, e na qual o modelo de DL ganha mais expressão. Este facto é corroborado por Piccialli et al. (2021). A aplicação do modelo nesta área incide na deteção e no prognóstico da Covid-19. Islam et al. (2021) corroboram este resultado no seu estudo bibliométrico, referindo que a pesquisa está focada no diagnóstico, deteção, classificação e reaproveitamento de medicamentos relacionados com a Covid-19. Neste estudo a Covid-19 surge igualmente como um *cluster*, como se pode observar no Mapa Temático estando associadas algumas das seguintes palavras: *blockchain*, *IoT*, *sensors* e *computing*.

A área da oftalmologia encontra-se igualmente representada neste conjunto de dados ao identificar a retinopatia diabética como uma palavra que ocorre com frequência neste conjunto de dados e na qual a aplicação da CNN é utilizada na deteção desta doença. Li et al. (2020) e Piccialli et al. (2021) reforçam este resultado.

A imagiologia, a radiologia e a patologia são campos da medicina que estão interligados com outras áreas clínicas, entre elas a oncologia e a ortopedia. Verifica-se que ambos os modelos são utilizados, com maior predominância pelo modelo de DL, e com uma maior utilização das redes de CNN e RNN. A deteção, segmentação, classificação, diagnóstico e prognóstico são as principais funções nas quais estas redes são aplicadas. É possível observar igualmente na rede de coocorrência de palavras-chave dos autores, que o cluster *healthcare* contempla as palavras *image classification*, *image processing*, *segmentation*, *medical imaging* e *extraction*, e que estas se encontram relacionadas com os três campos da medicina referidos anteriormente. O cluster *deep learning* contempla as palavras *imaging*, *radiology*, *pathology*, *diagnosis*, *prediction*, *prognosis* e *classification*. É possível concluir que a partir do conjunto de dados, o diagnóstico e prognóstico de doenças constituem a base da aplicação dos modelos de DL, ML e IA, com aplicação nas áreas de imagiologia, radiologia e patologia, sendo estas transversais às outras áreas clínicas. Piccialli et al. (2021) referem que na área de oncologia a CNN tem sido amplamente utilizada nas funções classificação e deteção. Na área da cardiologia é igualmente a CNN que é aplicada na análise de características cardíacas combinando imagens e ecocardiogramas. Na ortopedia é mais uma vez a CNN que é aplicada na sua maioria às imagens clínicas com as funções de classificação e segmentação e por último em pneumologia o principal modelo aplicado é o de DL.

É importante referir que existem outras áreas clínicas nas quais os modelos de DL e de ML estão a ser aplicados, como em gastroenterologia e em neurologia (Chen et al., 2021; Piccialli et al., 2021), porém neste conjunto de dados não são expressivos.

A CNN é a rede que aplicada à medicina, apresenta mais expressão dentro do modelo de DL e neste conjunto de dados. Vários autores corroboram estes resultados (Fosso Wamba & Queiroz, 2021; Marreiros et al., 2021; Piccialli et al., 2021)

Em suma, a medicina de precisão apoiada pela IA e mais concretamente, pela aplicação dos algoritmos de ML e de DL, está a permitir uma maior precisão na identificação e classificação de imagens médicas, permitindo um diagnóstico e um prognóstico com uma menor margem de erro em áreas como a cardiologia, oncologia, oftalmologia, pneumologia (Covid-19) e radiologia. Para que haja uma margem de erro cada vez menor e para que a “máquina” consiga interpretar os resultados corretamente de forma a identificar o problema, produzir um diagnóstico e auferir um prognóstico é necessário que exista um grande volume de dados. Neste sentido, a ciência de dados e mais concretamente o *big data*, como consta no mapa temático, é o tópico de pesquisa atual e base para o desenvolvimento dos próprios modelos de ML e de DL.

Capítulo 5: Conclusões e Recomendações

Tendo conta que as previsões apontam para um aumento do crescimento do mercado da IA na saúde (OECD, 2020), este estudo procurou fornecer *insights* sobre a mais recente evidência científica no que diz respeito à aplicação do ML e do DL nas várias áreas da medicina, permitindo não só, identificar as áreas da medicina onde o investimento está a ser aplicado, como também, descobrir quais os modelos que estão a ser aplicados no diagnóstico, prognóstico e tratamento de doenças e ainda recomendar futuras pesquisas.

Como foi possível observar através da metodologia aplicada neste estudo, as revisões e as revisões sistemáticas da literatura sobre esta temática são inúmeras, facto que contribuiu para a escolha da análise bibliométrica como metodologia diferenciadora para esta dissertação. A análise bibliométrica de palavras-chave, permite reduzir a subjetividade que caracteriza as revisões, direcionando assim, os investigadores para determinadas áreas de pesquisa.

É possível concluir-se através dos resultados obtidos, que a aplicação da IA na saúde é um tema emergente e que está a ser amplamente investigada em países como os EUA, a Índia, a China e ainda em alguns países da Europa, como no Reino Unido. Investir de forma estratégica e sustentável na pesquisa e desenvolvimento da IA na saúde, está a atrair de forma significativa muitos investidores. De acordo com os dados da OCDE (2020), apenas no primeiro semestre de 2018, as *startups* de IA na saúde atraíram 12% dos investimentos mundiais de *private equity* e tal como referido anteriormente, estima-se que o mercado da IA na saúde deverá atingir 44,5 biliões de dólares americanos em 2026, crescendo a um CAGR de 46,21% (*Healthcare Artificial Intelligence (AI) Market - Global Outlook & Forecast 2021-2026*, n.d.). Os resultados deste estudo, permitem concluir que o modelo de DL é o método de aprendizagem mais utilizado nas diferentes áreas clínicas. Tal facto, pode ser explicado pelas inúmeras vantagens deste modelo relativamente ao modelo de ML, nomeadamente, no que diz respeito ao tipo de dados que modelo de DL utiliza e à não utilização da engenharia de recursos em todo o seu processo de aprendizagem. É ao nível da classificação de doenças e consequentemente do diagnóstico e prognóstico, que o modelo de DL está a ser amplamente aplicado, com maior relevo nas áreas de cardiologia, oftalmologia e oncologia. As áreas médicas de imagiologia e patologia, são áreas transversais às outras áreas da medicina e que estão na base dos diagnósticos e dos prognósticos das múltiplas doenças. É possível concluir também, que a arquitetura de DL mais utilizada e, por conseguinte, alvo de uma maior pesquisa científica é a CNN.

O tópico tendência à luz deste conjunto de dados é o *big data*. O tema *big data* é um tópico que está a ser bastante desenvolvido, sendo importante para o campo de pesquisa da aplicação da IA na saúde, uma vez que, o modelo de ML e mais concretamente de DL, necessitam de um grande volume de dados para se aperfeiçoarem, e conseqüentemente, fornecerem resultados mais precisos ao nível do diagnóstico, prognóstico e tratamento de doenças. Existem vários desafios associados a cada etapa de manipulação do *big data* que só podem ser superados com a utilização de soluções de computação, ou seja, com o recurso à IA. Uma correta utilização, gestão e análise de dados, pode ter como resultado a melhoria dos serviços de saúde com impacto na prestação dos cuidados de saúde aos doentes, associada a vantagens financeiras para as organizações de saúde (Dash et al., 2019). O *big data* e a sua análise, encontra-se no centro da pesquisa científica, mais concretamente ao nível da imagiologia. É nesta área da medicina que a classificação de imagens médicas ganha maior expressão e cujo objetivo principal é auxiliar os profissionais de saúde no diagnóstico e prognóstico de doenças. O *data mining* é um tema que está a ser estudado na atualidade e que permite extrair informações do *big data*. Relacionado ainda com o tópico do *big data*, estão os EHR. A crescente adoção de sistemas EHR em todo o mundo tem possibilitado a captura de grandes quantidades de dados clínicos, com o intuito de promover a qualidade dos cuidados de saúde prestados (Agrawal et al., 2020) e que, como pudemos observar neste estudo, constitui um tema que está a ser desenvolvido na atualidade. Um outro campo de pesquisa emergente, diz respeito à doença provocada pela COVID-19, que permitiu alavancar outras áreas, nomeadamente o recurso à telemedicina e a utilização de sensores de IoT. A doença COVID-19 insere-se na área da pneumologia, porém é a cardiologia, a área da medicina que neste conjunto de dados, ganhou expressão e na qual os modelos de ML e de DL estão a ser mais aplicados, com tarefas que incluem a deteção, classificação, diagnóstico e prognóstico de doenças cardiovasculares. Pode concluir-se assim, que é na área de cardiologia que o investimento em IA tem sido depositado, muito provavelmente devido ao facto, de as doenças cardiovasculares se encontrarem entre as 10 principais causas de morte a nível mundial (*Leading Causes of Death Worldwide 2019*, n.d.). Desta forma, a implementação da IA é acompanhada de potenciais benefícios, entre eles a rapidez e a robustez dos resultados, permitindo tomadas de decisão mais rápidas e corretas e uma melhoria nos padrões de tratamento (Koteluk et al., 2021). Se por um lado o financiamento da IA no setor da saúde é consideravelmente elevado (OECD, 2017), por outro, tem o potencial de criar um caminho diferente que pode simultaneamente reduzir custos, aumentar a qualidade e o acesso aos

cuidados de saúde (Ball, 2021; Piccialli et al., 2021), modificando assim o *Iron Triangle of Healthcare*.

Neste conjunto de dados, concluiu-se igualmente que o tratamento de doenças é uma área na qual a aplicação destes modelos não é muito expressiva, podendo representar uma área de estudo e conseqüentemente de investimento a ser ponderada.

A contribuição deste estudo para a gestão, pretende-se não só com a identificação das áreas da medicina e do campo da computação no qual o investimento está a ser aplicado, mas também com as áreas onde a aplicação destes modelos é quase inexistente (segundo este conjunto de dados) e no qual um correto investimento poderá ter um retorno financeiro favorável. Claramente que será necessário avaliar o custo-benefício de tal investimento, constituindo assim uma área de pesquisa científica no setor da saúde e que de acordo com a revisão da literatura realizada por Wolff et al. (2020), o impacto económico da aplicação da IA nos cuidados de saúde tem sido abordado apenas esporadicamente. Uma outra área de estudo que pode emergir da contribuição desta dissertação prende-se com a gestão do conhecimento e com a criação de valor proporcionada pela aplicação da IA no ecossistema das organizações de saúde. Segundo os autores Leone et al. (2021) e a título de exemplo, a remoção do trabalho repetitivo dos colaboradores poderá aumentar a satisfação, o recrutamento e a retenção dos mesmos, permitindo que desempenhem funções mais analíticas, com resultados ao nível da produtividade e eficiência. Neste sentido, perceber de que forma a aplicação dos modelos de ML e de DL nas várias áreas da saúde, poderão melhorar não só os *outcomes* dos doentes como também dos colaboradores poderá ser uma área de pesquisa que advém da implementação deste estudo.

O estudo apresenta algumas limitações. Em primeiro lugar, o conjunto de dados foi obtido apenas a partir de uma única base de dados, a WoS, o que pode resultar na omissão de dados relevantes. A recolha de dados proveniente de várias bases de dados melhoraria o estudo de forma significativa, orientando de forma mais incisiva as futuras investigações a partir de temas provenientes de um conjunto de dados mais abrangente. Em segundo lugar, e apesar de, o número da amostra ser um valor próximo do recomendado e a partir do qual é indicado que se efetue uma análise bibliométrica (Donthu et al., 2021), um conjunto de dados maior irá beneficiar a própria análise bibliométrica, uma vez que a mesma é adequada para analisar um grande volume de dados. Para além do referido anteriormente, as palavras-chave utilizadas na consulta ao banco de dados podem ser melhoradas de forma a consistirem em palavras-chave mais relevantes e mais incisivas, de forma que seja efetuada uma análise mais aprofundada.

Espera-se assim que este estudo possa orientar outros investigadores a encontrar importantes lacunas neste amplo campo de pesquisa.

Referências Bibliográficas

- Abdulaal, A., Patel, A., Charani, E., Denny, S., Mughal, N., & Moore, L. (2020). Prognostic modeling of COVID-19 using artificial intelligence in the United Kingdom: Model development and validation. *Journal of Medical Internet Research*, 22(8), 1-10. <https://doi.org/10.2196/20259>
- Abramo, G., D'Angelo, C. A., & Reale, E. (2019). Peer review versus bibliometrics: Which method better predicts the scholarly impact of publications? *Scientometrics*, 121(1), 537–554. <https://doi.org/10.1007/s11192-019-03184-y>
- Acs, B., Rantalainen, M., & Hartman, J. (2020). Artificial intelligence as the next step towards precision pathology. *Journal of Internal Medicine*, 288(1), 62–81. <https://doi.org/10.1111/joim.13030>
- Adler, E. D., Voors, A. A., Klein, L., Macheret, F., Braun, O. O., Urey, M. A., Zhu, W., Sama, I., Tadel, M., Campagnari, C., Greenberg, B., & Yagil, A. (2020). Improving risk prediction in heart failure using machine learning. *European Journal of Heart Failure*, 22(1), 139–147. <https://doi.org/10.1002/ejhf.1628>
- Adriaanse, L. S., & Rensleigh, C. (2011). Comparing Web of Science, Scopus and Google Scholar from an Environmental Sciences perspective. *South African Journal of Libraries and Information Science*, 77(2), 169-178. <https://doi.org/10.7553/77-2-58>
- Agbo, F. J., Oyelere, S. S., Suhonen, J., & Tukiainen, M. (2021). Scientific production and thematic breakthroughs in smart learning environments: a bibliometric analysis. *Smart Learning Environments*, 8(1), 1-25. <https://doi.org/10.1186/s40561-020-00145-4>
- Aghaei Chadegani, A., Salehi, H., Md Yunus, M. M., Farhadi, H., Fooladi, M., Farhadi, M., & Ale Ebrahim, N. (2013). A comparison between two main academic literature collections: Web of science and Scopus databases. *Asian Social Science*, 9(5), 18–26. <https://doi.org/10.5539/ass.v9n5p18>
- Agrawal, R., Prabakaran, S. (2020). Big data in digital healthcare: lessons learnt and recommendations for general practice. *Heredity*, 124, 525–534. <https://doi.org/10.1038/s41437-020-0303-2>
- 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. *Database*, 1-35. <https://doi.org/10.1093/database/baaa010>
- AI Adoption Skyrocketed Over the Last 18 Months*. (n.d.). Harvard Business Review. Retrieved January 12, 2022, from <https://hbr.org/2021/09/ai-adoption-skyrocketed-over-the-last-18-months>
- Alabi, G. (1979). Bradford's Law and Its Application. *International Library Review*, 11(1), 151-158. [https://doi.org/10.1016/0020-7837\(79\)90044-X](https://doi.org/10.1016/0020-7837(79)90044-X)
- Aria, M., & Cuccurullo, C. (2017). Bibliometrix: An R-tool for comprehensive science mapping analysis. *Journal of Informetrics*, 11(4), 959–975. <https://doi.org/10.1016/j.joi.2017.08.007>

- Auener, S. I., Kroon, D. I., Wackers, E. I., Van Dulmen, S., & Jeurissen, P. (2020). COVID-19: A Window of Opportunity for Positive Healthcare Reforms. *Kerman University of Medical Sciences*, 9(10), 419–422. <https://doi.org/10.34172/ijhpm.2020.66>
- Bakator, M., & Radosav, D. (2018). Deep learning and medical diagnosis: A review of literature. *Multimodal Technologies and Interaction*, 2(3), 1-12. <https://doi.org/10.3390/mti2030047>
- Ball, H. C. (2021). Improving Healthcare Cost, Quality, and Access Through Artificial Intelligence and Machine Learning Applications. *Journal of Healthcare Management / American College of Healthcare Executives*, 66(4), 271–279. <https://doi.org/10.1097/JHM-D-21-00149>
- Banerjee, I., Ling, Y., Chen, M. C., Hasan, S. A., Langlotz, C. P., Moradzadeh, N., Chapman, B., Amrhein, T., Mong, D., Rubin, D. L., Farri, O., & Lungren, M. P. (2019). Comparative effectiveness of convolutional neural network (CNN) and recurrent neural network (RNN) architectures for radiology text report classification. *Artificial Intelligence in Medicine*, 97, 79–88. <https://doi.org/10.1016/j.artmed.2018.11.004>
- Benjamins, J. W., Hendriks, T., Knuuti, J., Juarez-Orozco, L. E., & van der Harst, P. (2019). A primer in artificial intelligence in cardiovascular medicine. *Netherlands Heart Journal*, 27(9), 392–402. <https://doi.org/10.1007/s12471-019-1286-6>
- Bhatt, C., Kumar, I., Vijayakumar, V., Singh, K. U., & Kumar, A. (2021). The state of the art of deep learning models in medical science and their challenges. *Multimedia Systems*, 27(4), 599–613. <https://doi.org/10.1007/s00530-020-00694-1>
- Birkle, C., Pendlebury, D. A., Schnell, J., & Adams, J. (2020). Web of Science as a data source for research on scientific and scholarly activity. *Quantitative Science Studies*, 1(1), 363–376. https://doi.org/10.1162/qss_a_00018
- Bizzego, A., Bussola, N., Chierici, M., Maggio, V., Francescato, M., Cima, L., Cristoforetti, M., Jurman, G., & Furlanello, C. (2019). Evaluating reproducibility of ai algorithms in digital pathology with dapper. *PLoS Computational Biology*, 15(3), 1-24. <https://doi.org/10.1371/journal.pcbi.1006269>
- Bornmann, L., Bowman, B. F., Bauer, J., Marx, W., Schier, H., & Palzenberger, M. (2014). Bibliometric standards for evaluating research institutes in the natural sciences. *B. Cronin & C. Sugimoto (Eds.), Beyond bibliometrics: harnessing multidimensional indicators of scholarly impact*, 201-223. Cambridge, MA, USA: MIT Press
- Broadus, R. N. (1987). Toward a definition of “bibliometrics”. *Scientometrics*, 12, 373–379. <https://doi-org.libproxy.viko.lt/10.1007/BF02016680>
- Cai, L., Gao, J., & Zhao, D. (2020). A review of the application of deep learning in medical image classification and segmentation. *Annals of Translational Medicine*, 8(11), 713–713. <https://doi.org/10.21037/atm.2020.02.44>

- Cascella, M., Rajnik, M., Cuomo, A., Dulebohn, S. C., & di Napoli, R. (2022). Features, Evaluation, and Treatment of Coronavirus (COVID-19). *StatPearls*. <https://www.ncbi.nlm.nih.gov/books/NBK554776/>
- Chen, C., Loh, E.-W., Kuo, K. N., & Tam, K.-W. (2020). The Times they Are a-Changin'-Healthcare 4.0 Is Coming! *Journal of Medical Systems*, 44(2), 1-4. <https://doi.org/10.1007/s10916-019-1513-0>
- Chen, X., Zhang, X., Xie, H., Tao, X., Wang, F. L., Xie, N., & Hao, T. (2021). A bibliometric and visual analysis of artificial intelligence technologies-enhanced brain MRI research. *Multimedia Tools and Applications*, 80(11), 17335–17363. <https://doi.org/10.1007/s11042-020-09062-7>
- Choudhri, A. F., Siddiqui, A., Khan, N. R., & Cohen, H. L. (2015). Understanding bibliometric parameters and analysis. *Radiographics*, 35(3), 736–746. <https://doi.org/10.1148/rg.2015140036>
- Chowdhury, M. E. H., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahbub, Z. bin, Islam, K. R., Khan, M. S., Iqbal, A., Emadi, N. al, Reaz, M. B. I., & Islam, M. T. (2020). Can AI Help in Screening Viral and COVID-19 Pneumonia? *IEEE Access*, 8, 132665–132676. <https://doi.org/10.1109/ACCESS.2020.3010287>
- Cote, M. P., Lubowitz, J. H., Brand, J. C., & Rossi, M. J. (2021). Artificial Intelligence, Machine Learning, and Medicine: A Little Background Goes a Long Way Toward Understanding. *Arthroscopy - Journal of Arthroscopic and Related Surgery*, 37(6), 1699–1702). <https://doi.org/10.1016/j.arthro.2021.04.022>
- Crimi, A., Menze, B., Maier, O., Reyes, M., Winzeck, S., & Handels, H. (Eds.). (2016). *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries* (Vol. 10154). Springer International Publishing. <https://doi.org/10.1007/978-3-319-55524-9>
- Dash, S., Shakyawar, S.K., Sharma, M. et al. (2019) Big data in healthcare: management, analysis and future prospects. *Journal of Big Data*, 54, 2-25. <https://doi.org/10.1186/s40537-019-0217-0>
- Deo, R. C. (2015). Machine learning in medicine. *Circulation*, 132(20), 1920–1930. <https://doi.org/10.1161/CIRCULATIONAHA.115.001593>
- Deshmukh, S. K. (2020). Machine Learning for Healthcare: Emerging Challenges and Opportunities in Disease Diagnosis. *J Cell Signal*, 1(3), 76-78. <https://www.scientificarchives.com/journal/journal-of-cellular-signaling>
- Ding, Y., Sohn, J. H., Kawczynski, M. G., Trivedi, H., Harnish, R., Jenkins, N. W., Lituiev, D., Copeland, T. P., Aboian, M. S., Aparici, C. M., Behr, S. C., Flavell, R. R., Huang, S. Y., Zalocusky, K. A., Nardo, L., Seo, Y., Hawkins, R. A., Pampaloni, M. H., Hadley, D., & Franc, B. L. (2019). A deep learning model to predict a diagnosis of Alzheimer disease by using 18 F-FDG PET of the brain. *Radiology*, 290(3), 456–464. <https://doi.org/10.1148/radiol.2018180958>
- Dombal, F. T., Leaper, D. J., Staniland, J. R., McCann, A. P., & Horrocks, J. C. (1972). Computer-aided Diagnosis of Acute Abdominal Pain. *British Medical Journal*, 2, 9-13.

- Donthu, N., Kumar, S., Mukherjee, D., Pandey, N., & Lim, W. M. (2021). How to conduct a bibliometric analysis: An overview and guidelines. *Journal of Business Research*, 133, 285–296. <https://doi.org/10.1016/j.jbusres.2021.04.070>
- Ellegaard, O., & Wallin, J. A. (2015). The bibliometric analysis of scholarly production: How great is the impact? *Scientometrics*, 105(3), 1809–1831. <https://doi.org/10.1007/s11192-015-1645-z>
- Enholm, I. M., Papagiannidis, E., Mikalef, P., & Krogstie, J. (2021). Artificial Intelligence and Business Value: a Literature Review. *Information Systems Frontiers*. <https://doi.org/10.1007/s10796-021-10186-w>
- Esfahani, H. J., Tavasoli, K., & Jabbarzadeh, A. (2019). Big data and social media: A scientometrics analysis. *International Journal of Data and Network Science*, 3(3), 145–164. <https://doi.org/10.5267/j.ijdns.2019.2.007>
- 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>
- Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., Cui, C., Corrado, G., Thrun, S., & Dean, J. (2019). A guide to deep learning in healthcare. *Nature Medicine*, 25 (1), 24–29. <https://doi.org/10.1038/s41591-018-0316-z>
- Foo, L. L., Ng, W. Y., Lim, G. Y. S., Tan, T.-E., Ang, M., & Ting, D. S. W. (2021). Artificial intelligence in myopia: current and future trends. *Current Opinion in Ophthalmology*, 32(5), 413-424. https://journals.lww.com/coophthalmology/Fulltext/2021/09000/Artificial_intelligence_in_myopia__current_and.5.aspx
- Ford E. (2018). Editorial. *Journal of healthcare management / American College of Healthcare Executives*, 63 (6), 357–359. <https://doi.org/10.1097/JHM-D-18-00211>
- Forina, M., Armanino, C., & Raggio, V. (2002). Clustering with dendrograms on interpretation variables. *Analytica Chimica Acta*, 454(1), 13-19. [https://doi.org/10.1016/S0003-2670\(01\)01517-3](https://doi.org/10.1016/S0003-2670(01)01517-3)
- Fosso Wamba, S., & Queiroz, M. M. (2021). Responsible Artificial Intelligence as a Secret Ingredient for Digital Health: Bibliometric Analysis, Insights, and Research Directions. *Information Systems Frontiers*. <https://doi.org/10.1007/s10796-021-10142-8>
- Galbusera, F., Casaroli, G., & Bassani, T. (2019). Artificial intelligence and machine learning in spine research. *JOR Spine*, 2(1), 1-20. <https://doi.org/10.1002/jsp2.1044>
- Garfield, E. (1990). KeyWords Plus®: ISI®'s breakthrough retrieval method. Part I. Expanding your searching power on Current Contents on Diskette®. *Current Contents* (32):5-9.

- Gastaldi, L., Appio, F., Corso, M., Pistorio, A. (2018) Managing the exploration-exploitation paradox in healthcare: Three complementary paths to leverage on the digital transformation. *Business Process Management Journal*, 24(5), 1200-1234. <https://doi.org/10.1108/BPMJ-04-2017-0092>.
- Global diabetes healthcare expenditure 2045*. (n.d.). Statista. Retrieved January 14, 2022, from <https://www.statista.com/statistics/241820/estimated-global-healthcare-expenditures-to-treat-diabetes/>
- Global spending on medicines 2025 forecast*. (n.d.). Statista. Retrieved January 14, 2022, from <https://www.statista.com/statistics/280572/medicine-spending-worldwide/>
- Golbeck, J. (2015). Analyzing networks. *Introduction to Social Media Investigation*, 221–235. <https://doi.org/10.1016/b978-0-12-801656-5.00021-4>
- Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative Adversarial Networks. 1-9. <http://arxiv.org/abs/1406.2661>
- Grzybowski, A., Brona, P., Lim, G., Ruamviboonsuk, P., Tan, G. S. W., Abramoff, M., & Ting, D. S. W. (2020). Artificial intelligence for diabetic retinopathy screening: a review. *Eye (Basingstoke)*, 34(3), 451–460. <https://doi.org/10.1038/s41433-019-0566-0>
- Guarcello, C., & Raupp De Vargas, E. (2020). *Service Innovation in Healthcare: A Systematic Literature Review*. *Latin American Business Review*, 21(4), 353-369. <https://doi.org/10.1080/10978526.2020.1802286>
- Gunasekeran, D. V., Tseng, R. M. W. W., Tham, Y. C., & Wong, T. Y. (2021). Applications of digital health for public health responses to COVID-19: a systematic scoping review of artificial intelligence, telehealth and related technologies. *NPJ Digital Medicine*, 4(1), 1-6. <https://doi.org/10.1038/s41746-021-00412-9>
- Gupta, M., Gupta, A., & Kaur, G. (2021). Chapter 15 Deep Learning for Medical Healthcare: Issues, Challenges, and Opportunities. In Amit Kumar Tyagi (Ed.), *Computational Analysis and Deep Learning for Medical Care: Principles, Methods, and Applications* (pp 363–392). <https://doi.org/10.1002/9781119785750.ch15>
- Handelman, G. S., Kok, H. K., Chandra, R. v., Razavi, A. H., Lee, M. J., & Asadi, H. (2018). eDoctor: machine learning and the future of medicine. *Journal of Internal Medicine*, 284(6), 603–619. <https://doi.org/10.1111/joim.12822>
- Healthcare AI market size 2025 global forecast*. (n.d.). Statista. Retrieved January 12, 2022, from <https://www.statista.com/statistics/826993/health-ai-market-value-worldwide/>
- Healthcare Artificial Intelligence (AI) Market - Global Outlook & Forecast 2021-2026*. (n.d.). ReportLinker. Retrieved January 12, 2022, from https://www.reportlinker.com/p06188649/Healthcare-Artificial-Intelligence-AI-Market-Global-Outlook-Forecast.html?utm_source=GNW
- Hermes, S., Riasanow, T., Clemons, E. K., Böhm, M., & Krcmar, H. (2020). The digital transformation of the healthcare industry: exploring the rise of emerging platform ecosystems and their influence on the role of patients. *Business Research*, 13(3), 1033–1069. <https://doi.org/10.1007/s40685-020-00125-x>

- Hevey, D. (2018). Network analysis: A brief overview and tutorial. *Health Psychology and Behavioral Medicine*, 6(1), 301–328. <https://doi.org/10.1080/21642850.2018.1521283>
- Hinton, G. E., & Osindero, S. (2006). A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*, 18(7), 1527–1554. <https://doi.org/10.1162/neco.2006.18.7.1527>
- Hirsch, J. E. (2005). An index to quantify an individual's scientific research output. *PNAS*, 102(46) 16569-16572. <https://doi.org/10.1073/pnas.0507655102>
- Hoffman, D. L., & de Leeuw, J. (1992). Interpreting Multiple Correspondence Analysis as a Multidimensional Scaling Method. *Marketing Letters*, 3(3), 259–272.
- Holzinger, A. (2014). Trends in Interactive Knowledge Discovery for Personalized Medicine: Cognitive Science meets Machine Learning. *IEEE Intell. Informatics Bull*, 15(1), 6-14. http://www.comp.hkbu.edu.hk/~cib/2014/Dec/article2/iib_vol15no1_article2.pdf
- Hornbrook, M. C., Goshen, R., Choman, E., O'Keeffe-Rosetti, M., Kinar, Y., Liles, E. G., & Rust, K. C. (2017). Early Colorectal Cancer Detected by Machine Learning Model Using Gender, Age, and Complete Blood Count Data. *Digestive Diseases and Sciences*, 62(10), 2719–2727. <https://doi.org/10.1007/s10620-017-4722-8>
- Houfani, D., Slatnia, S., Kazar, O., Saouli, H., & Merizig, A. (2021). Artificial intelligence in healthcare: a review on predicting clinical needs. *International Journal of Healthcare Management*, 1-10. <https://doi.org/10.1080/20479700.2021.1886478>
- Hussain, S. (2021). Artificial Intelligence in Healthcare Explained for Computer-Non-Experts. *Annals of King Edward Medical University*, 27, 1-13.
- Islam, M. M., Poly, T. N., Alsinglawi, B., Lin, L. F., Chien, S. C., Liu, J. C., & Jian, W. S. (2021). Application of artificial intelligence in covid-19 pandemic: Bibliometric analysis. *Healthcare (Switzerland)*, 9(4), 1-10. <https://doi.org/10.3390/healthcare9040441>
- Jain, S., Alam, M. A., Labib, N. M., & Yafi, E. (2021). Chapter 12 Health Prediction Analytics Using Deep Learning Methods and Applications. In Amit Kumar Tyagi (Ed.), *Computational Analysis and Deep Learning for Medical Care: Principles, Methods, and Applications* (pp293-328). <https://doi.org/10.1002/9781119785750.ch12>
- Javaid, M., & Khan, I. H. (2021). Internet of Things (IoT) enabled healthcare helps to take the challenges of COVID-19 Pandemic. *Journal of Oral Biology and Craniofacial Research*, 11(2), 209–214. <https://doi.org/10.1016/J.JOBCR.2021.01.015>
- Johnson, S. L. J. (2019). AI, Machine Learning, and Ethics in Health Care. *The Journal of Legal Medicine*, 39(4), 427–441. <https://doi.org/10.1080/01947648.2019.1690604>
- José de Oliveira, O., Francisco da Silva, F., Juliani, F., César Ferreira Motta Barbosa, L., & Vieira Nunhes, T. (2019). Bibliometric Method for Mapping the State-of-the-Art and Identifying Research Gaps and Trends

- in Literature: An Essential Instrument to Support the Development of Scientific Projects. *Scientometrics Recent Advances*, 1-20. <https://doi.org/10.5772/intechopen.85856>
- Kazemifar, S., Barragán Montero, A. M., Souris, K., Rivas, S. T., Timmerman, R., Park, Y. K., Jiang, S., Geets, X., Sterpin, E., & Owrangi, A. (2020). Dosimetric evaluation of synthetic CT generated with GANs for MRI-only proton therapy treatment planning of brain tumors. *Journal of Applied Clinical Medical Physics*, 21(5), 76–86. <https://doi.org/10.1002/acm2.12856>
- Kelly, C. J., Karthikesalingam, A., Suleyman, M., Corrado, G., & King, D. (2019). Key challenges for delivering clinical impact with artificial intelligence. *BMC Medicine*, 17(1), 1-9. <https://doi.org/10.1186/s12916-019-1426-2>
- Khosravi, P., Kazemi, E., Zhan, Q., Malmsten, J. E., Toschi, M., Zisimopoulos, P., Sigaras, A., Lavery, S., Cooper, L. A. D., Hickman, C., Meseguer, M., Rosenwaks, Z., Elemento, O., Zaninovic, N., & Hajirasouliha, I. (2019). Deep learning enables robust assessment and selection of human blastocysts after in vitro fertilization. *Npj Digital Medicine*, 2(1). <https://doi.org/10.1038/s41746-019-0096-y>
- Kim, J., Chang, H. L., Kim, D., Jang, D. H., Park, I., & Kim, K. (2020). Machine learning for prediction of septic shock at initial triage in emergency department. *Journal of Critical Care*, 55, 163–170. <https://doi.org/10.1016/j.jcrc.2019.09.024>
- Kök, H., Acilar, A. M., & İzgi, M. S. (2019). Usage and comparison of artificial intelligence algorithms for determination of growth and development by cervical vertebrae stages in orthodontics. *Progress in Orthodontics*, 20(1), 1-10. <https://doi.org/10.1186/s40510-019-0295-8>
- Koteluk, O., Wartecki, A., Mazurek, S., Kołodziejczak, I., & Mackiewicz, A. (2021). How do machines learn? Artificial intelligence as a new era in medicine. In *Journal of Personalized Medicine*, 11(1), 1–22. <https://doi.org/10.3390/jpm11010032>
- Kourou, K., Exarchos, K. P., Papaloukas, C., Sakaloglou, P., Exarchos, T., & Fotiadis, D. I. (2021). Applied machine learning in cancer research: A systematic review for patient diagnosis, classification and prognosis. In *Computational and Structural Biotechnology Journal*, 19, 5546–5555. <https://doi.org/10.1016/j.csbj.2021.10.006>
- Krittanawong, C., Johnson, K. W., Rosenson, R. S., Wang, Z., Aydar, M., Baber, U., Min, J. K., Wilson Tang, W. H., Halperin, J. L., & Narayan, S. M. (2019). Deep learning for cardiovascular medicine: A practical primer. *European Heart Journal*, 40(25), 2058-2069C. <https://doi.org/10.1093/eurheartj/ehz056>
- Kumar, A., Gadag, S., & Nayak, U. Y. (2021). The beginning of a new era: Artificial intelligence in healthcare. In *Advanced Pharmaceutical Bulletin*, 11(3), 414–425. <https://doi.org/10.34172/apb.2021.049>
- Larentzakis, A., & Lygeros, N. (2021). Artificial intelligence (Ai) in medicine as a strategic valuable tool. *Pan African Medical Journal*, 38, 1-12. <https://doi.org/10.11604/pamj.2021.38.184.28197>

- Leading causes of death worldwide 2019*. (n.d.). *Statista*. Retrieved January 14, 2022, from <https://www.statista.com/statistics/288839/leading-causes-of-death-worldwide/>
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Lee, J. G., Jun, S., Cho, Y. W., Lee, H., Kim, G. B., Seo, J. B., & Kim, N. (2017). Deep learning in medical imaging: General overview. In *Korean Journal of Radiology*, 18(4), 570–584. <https://doi.org/10.3348/kjr.2017.18.4.570>
- Leonea, D., Schiavone, F., Appio, F., Chiao, B. (2021). How does artificial intelligence enable and enhance value co-creation in industrial markets? An exploratory case study in the healthcare ecosystem. *Journal of Business Research*, 129, 849-859. <https://doi.org/10.1016/j.jbusres.2020.11.008>
- Li, J. P. O., Liu, H., Ting, D. S. J., Jeon, S., Chan, R. V. P., Kim, J. E., Sim, D. A., Thomas, P. B. M., Lin, H., Chen, Y., Sakomoto, T., Loewenstein, A., Lam, D. S. C., Pasquale, L. R., Wong, T. Y., Lam, L. A., & Ting, D. S. W. (2021). Digital technology, tele-medicine and artificial intelligence in ophthalmology: A global perspective. *Progress in Retinal and Eye Research*, 82, 1-32. <https://doi.org/10.1016/j.preteyeres.2020.100900>
- Li, Y., Xu, Z., Wang, X., & Wang, X. (2020). A bibliometric analysis on deep learning during 2007–2019. *International Journal of Machine Learning and Cybernetics*, 11(12), 2807–2826. <https://doi.org/10.1007/s13042-020-01152-0>
- Liu, N., Chee, M. L., Koh, Z. X., Leow, S. L., Ho, A. F. W., Guo, D., & Ong, M. E. H. (2021). Utilizing machine learning dimensionality reduction for risk stratification of chest pain patients in the emergency department. *BMC Medical Research Methodology*, 21(1), 1-13. <https://doi.org/10.1186/s12874-021-01265-2>
- Liu, Q., Yu, L., Luo, L., Dou, Q., & Heng, P. A. (2020). Semi-supervised Medical Image Classification with Relation-driven Self-Ensembling Model. *IEEE Transactions on Medical Imaging*, 39(11), 3429-3440. <https://doi.org/10.1109/TMI.2020.2995518>
- López-Robles, J. R., Cobo, M. J., Gutiérrez-Salcedo, M., Martínez-Sánchez, M. A., Gamboa-Rosales, N. K., & Herrera-Viedma, E. (2021). 30th Anniversary of Applied Intelligence: A combination of bibliometrics and thematic analysis using SciMAT. *Applied Intelligence*, 51(9), 6547–6568. <https://doi.org/10.1007/s10489-021-02584-z>
- Lorenzoni, L., Marino, A., Morgan, D., & James, C. (2019). Health Spending Projections to 2030: New results based on a revised OECD methodology. *Health Working Papers OECD. Health Working Paper*, 110. <https://www.oecd.org/els/health-systems/health-working-papers.htm>
- Lundervold, A. S., & Lundervold, A. (2019). An overview of deep learning in medical imaging focusing on MRI. *Zeitschrift für Medizinische Physik*, 29(2), 102–127. <https://doi.org/10.1016/j.zemedi.2018.11.002>

- Luz Tortorella, G., Sanson Fogliatto, F., Francisco Espôsto, K., Francisco Mac Cawley, A., Vassolo, R., Tlapa, D., & Narayanamurthy, G. (2020). Healthcare costs' reduction through the integration of Healthcare 4.0 technologies in developing economies. *Total Quality Management*, 1-22. <https://doi.org/10.1080/14783363.2020.1861934>
- Madani, F., & Weber, C. (2016). The evolution of patent mining: Applying bibliometrics analysis and keyword network analysis. *World Patent Information*, 46, 32–48. <https://doi.org/10.1016/j.wpi.2016.05.008>
- Manco, L., Maffei, N., Strolin, S., Vichi, S., Bottazzi, L., & Strigari, L. (2021). Basic of machine learning and deep learning in imaging for medical physicists. *Physica Medica*, 83, 194–205. <https://doi.org/10.1016/j.ejmp.2021.03.026>
- Mangat, V., & Vig, R. (2014). Novel associative classifier based on dynamic adaptive PSO: Application to determining candidates for thoracic surgery. *Expert Systems with Applications*, 41(18), 8234–8244. <https://doi.org/10.1016/j.eswa.2014.06.046>
- Marreiros, G., Melo, F. S., Lau, N., Lopes, H., Luís, C., & Reis, P. (2021). Progress in Artificial Intelligence. *Proceedings*. <https://doi.org/10.1007/978-3-030-86230-5>
- Mele, C., Russo-Spena, T., & Kaartemo, V. (2021). The impact of coronavirus on business: developing service research agenda for a post-coronavirus world. *Journal of Service Theory and Practice*, 31(2), 184–202. <https://doi.org/10.1108/JSTP-07-2020-0180>
- Meyer, P., Noblet, V., Mazzara, C., & Lallement, A. (2018). Survey on deep learning for radiotherapy. In *Computers in Biology and Medicine*, 98, 126–146. <https://doi.org/10.1016/j.combiomed.2018.05.018>
- Meystre, S. M., Heider, P. M., Kim, Y., Davis, M., Obeid, J., Madory, J., & Alekseyenko, A. (2022). Natural language processing enabling COVID-19 predictive analytics to support data-driven patient advising and pooled testing. *Journal of the American Medical Informatics Association*, 29(1), 12–21. <https://doi.org/10.1093/jamia/ocab186>
- Min, S., Lee, B., & Yoon, S. (2017). Deep learning in bioinformatics. *Briefings in bioinformatics*, 18(5), 851–869. <https://doi.org/10.1093/bib/bbw068>
- Nath Sur, S., Balas, V. E., Kumar Bhoi, A., & Nayyar, A. (2021). *IoT and IoE Driven Smart Cities*. Springer International Publishing. ISBN: 3030827151, 9783030827151
- Nensa, F., Demircioglu, A., & Rischpler, C. (2019). Artificial intelligence in nuclear medicine. *Journal of Nuclear Medicine*, 60(9), 29S-37S. <https://doi.org/10.2967/jnumed.118.220590>
- Nguyen, P., Tran, T., Wickramasinghe, N., & Venkatesh, S. (2016). Deeppr: A Convolutional Net for Medical Records. <https://doi.org/10.48550/arXiv.1607.07519>
- OECD. (2017). *New Health Technologies: Managing Access, Value and Sustainability*. OECD Publishing, Paris. <https://doi.org/http://dx.doi.org/10.1787/9789264266438-en>

- OECD. (2019). *Health at a Glance 2019: OECD Indicators*. OECD Publishing, Paris. <https://doi.org/10.1787/4dd50c09-en>
- OECD, (2020). *Trustworthy AI in Health*. OECD. <https://www.oecd.org/health/trustworthy-artificial-intelligence-in-health.pdf>
- OECD.Stat. (2021). *Health expenditure and financing*. OECD.Stat. <https://stats.oecd.org/Index.aspx?ThemeTreeId=9>
- Pasadeos, Y., Phelps, J., & Kim, B. H. (1998). Disciplinary Impact of Advertising Scholars: Temporal Comparisons of Influential Authors, Works and Research Networks. *Journal of Advertising*, 27(4), 53–70. <https://doi.org/10.1080/00913367.1998.10673569>
- Penteado, B.E., Fornazin, M., Castro, L. (2021). The Evolution of Artificial Intelligence in Medical Informatics: A Bibliometric Analysis. G. Marreiros et al. (Eds.): EPIA 2021, LNAI 12981, 121–133. https://doi.org/10.1007/978-3-030-86230-5_10.
- Pesta, B., Fuerst, J., & Kirkegaard, E. O. W. (2018). Bibliometric keyword analysis across seventeen years (2000–2016) of intelligence articles. *Journal of Intelligence*, 6(4), 1–12. <https://doi.org/10.3390/jintelligence6040046>
- Petersen, S. E., Abdulkareem, M., & Leiner, T. (2019). Artificial Intelligence Will Transform Cardiac Imaging—Opportunities and Challenges. *Frontiers in Cardiovascular Medicine*, 6, 1–6. <https://doi.org/10.3389/fcvm.2019.00133>
- Piccialli, F., Somma, V. di, Giampaolo, F., Cuomo, S., & Fortino, G. (2021). A survey on deep learning in medicine: Why, how and when? *Information Fusion*, 66, 111–137. <https://doi.org/10.1016/j.inffus.2020.09.006>
- Pihir, I., Tomičić-Pupek, K., & Furjan, M. T. (2019). Digital transformation playground - literature review and framework of concepts. *Journal of Information and Organizational Sciences*, 43(1), 33–48. <https://doi.org/10.31341/jios.43.1.3>
- Pramod, A., & Tyagi, A. K. (2021). Machine Learning and Deep Learning: Open Issues and Future Research Directions for the Next 10 Years. *Computational Analysis and Deep Learning for Medical Care: Principles, Methods, and Applications*, 463-490. <https://doi.org/10.1002/9781119785750>
- Prema, R. K., Kathiravan, M., & Shaikh, A. A. (2021). Artificial intelligence in healthcare: 21st century age of rifles-a bibliometric analysis. *Asia-Pacific Journal of Health Management*, 274-281. <https://doi.org/10.24083/apjhm.v16i4.1327>
- Pritchard, A. (1969). Statistical bibliography or bibliometrics? *Journal of Documentation*, 25(4), 348-349.
- Proksch, D., Busch-Casler, J., Haberstroh, M. M., & Pinkwart, A. (2019). National health innovation systems: Clustering the OECD countries by innovative output in healthcare using a multi-indicator approach. *Research Policy*, 48(1), 169–179. <https://doi.org/10.1016/J.RESPOL.2018.08.004>

- Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine Learning in Medicine. *New England Journal of Medicine*, 380(14), 1347–1358. <https://doi.org/10.1056/nejmra1814259>
- Ramadan, S. Z. (2020). Methods Used in Computer-Aided Diagnosis for Breast Cancer Detection Using Mammograms: A Review. *Journal of Healthcare Engineering*, 1-21. <https://doi.org/10.1155/2020/9162464>
- 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. *Academic Pathology*, 6, 1-17. <https://doi.org/10.1177/2374289519873088>
- Ray, A., & Chaudhuri, A. K. (2021). Smart healthcare disease diagnosis and patient management: Innovation, improvement and skill development. *Machine Learning with Applications*, 3, 1-24 <https://doi.org/10.1016/j.mlwa.2020.100011>
- Romiti, S., Vinciguerra, M., Saade, W., Anso Cortajarena, I., & Greco, E. (2020). Review Article - Artificial Intelligence (AI) and Cardiovascular Diseases: An Unexpected Alliance. *Cardiology Research and Practice*, 1-8. <https://doi.org/10.1155/2020/4972346>
- Ruamviboonsuk, P., Cheung, C. Y., Zhang, X., Raman, R., Park, S. J., & Ting, D. S. W. (2020). Artificial intelligence in ophthalmology: Evolutions in Asia. *Asia-Pacific Journal of Ophthalmology*, 9(2), 78–84. <https://doi.org/10.1097/01.APO.0000656980.41190.bf>
- Saba, L., Biswas, M., Kuppili, V., Cuadrado Godia, E., Suri, H. S., Edla, D. R., Omerzu, T., Laird, J. R., Khanna, N. N., Mavrogeni, S., Protogerou, A., Sfrikakis, P. P., Viswanathan, V., Kitas, G. D., Nicolaidis, A., Gupta, A., & Suri, J. S. (2019). The present and future of deep learning in radiology. *European Journal of Radiology*, 114,14–24. <https://doi.org/10.1016/j.ejrad.2019.02.038>
- Saheb, T., Saheb, T., & Carpenter, D. O. (2021). Mapping research strands of ethics of artificial intelligence in healthcare: A bibliometric and content analysis. *Computers in Biology and Medicine*, 135, 1-19. <https://doi.org/10.1016/j.combiomed.2021.104660>
- Schaffter, T., Buist, D. S. M., Lee, C. I., Nikulin, Y., Ribli, D., Guan, Y., Lotter, W., Jie, 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), 1-15. <https://doi.org/10.1001/jamanetworkopen.2020.0265>
- Scott, I. A. (2021). Demystifying machine learning: a primer for physicians. *Internal Medicine Journal*, 51(9), 1388–1400. <https://doi.org/10.1111/imj.15200>
- Secinaro, S., Calandra, D., Secinaro, A., Muthurangu, V., & Biancone, P. (2021). The role of artificial intelligence in healthcare: a structured literature review. *BMC Medical Informatics and Decision Making*, 21(1), 1-23. <https://doi.org/10.1186/s12911-021-01488-9>
- Shah, P., Mishra, D., Shanmugam, M., Doshi, B., Jayaraj, H., & Ramanjulu, R. (2020). Validation of Deep Convolutional Neural Network-based algorithm for detection of diabetic retinopathy-Artificial intelligence

- versus clinician for screening. *Indian Journal of Ophthalmology*, 68(2), 398–405. https://doi.org/10.4103/ijo.IJO_966_19
- Shortliffe, E. H., Davis, R., Axline, S. G., Buchanan, B. G., Cordell Green, C., & Cohen, S. N. (1975). Computer-Based Consultations in Clinical Therapeutics: Explanation and Rule Acquisition Capabilities of the MYCIN System. *Computers and Biomedical Research*, 8, 303-320.
- Shuaib, A., Arian, H., & Shuaib, A. (2020). The increasing role of artificial intelligence in health care: Will robots replace doctors in the future? *International Journal of General Medicine*, 13, 891–896. <https://doi.org/10.2147/IJGM.S268093>
- Singh, C. (2012). Word cloud analysis of the BJGP. *British Journal of General Practice*, 148. <https://doi.org/10.3399/bjgp12X630142>.
- Singh, P., Piryani, R., Singh, V. K., & Pinto, D. (2020). Revisiting subject classification in academic databases: A comparison of the classification accuracy of Web of Science, Scopus Dimensions. *Journal of Intelligent and Fuzzy Systems*, 39(2), 2471–2476. <https://doi.org/10.3233/JIFS-179906>
- Song, Y., Chen, X., Hao, T., Liu, Z., & Lan, Z. (2019). Exploring two decades of research on classroom dialogue by using bibliometric analysis. *Computers and Education*, 137, 12–31. <https://doi.org/10.1016/j.compedu.2019.04.002>
- Su, H. N., & Lee, P. C. (2010). Mapping knowledge structure by keyword co-occurrence: A first look at journal papers in Technology Foresight. *Scientometrics*, 85(1), 65–79. <https://doi.org/10.1007/s11192-010-0259-8>
- Sunarti, S., Fadzlul Rahman, F., Naufal, M., Risky, M., Febriyanto, K., & Masnina, R. (2021). Artificial intelligence in healthcare: opportunities and risk for future. *Gaceta Sanitaria*, 35, S67–S70. <https://doi.org/10.1016/j.gaceta.2020.12.019>
- Supriya, M., & Chattu, V. K. (2021). A review of artificial intelligence, big data, and blockchain technology applications in medicine and global health. *Big Data and Cognitive Computing*, 5(3), 1-20. <https://doi.org/10.3390/bdcc5030041>
- Szolovits, P., & Pauker, S. G. (1978). Categorical and Probabilistic Reasoning in Medical Diagnosis. *Artificial Intelligence*, 11, 115-144. [https://doi.org/10.1016/0004-3702\(78\)90014-0](https://doi.org/10.1016/0004-3702(78)90014-0)
- Telikani, A., Tahmassebi, A., Banzhaf, W., & Gandomi, A. H. (2022). Evolutionary Machine Learning: A Survey. *ACM Computing Surveys*, 54(8), 1-35. <https://doi.org/10.1145/3467477>
- The Definitive Glossary of Higher Math Jargon*. (n.d.). Math Vault. Retrieved January 22, 2022, from <https://mathvault.ca/math-glossary/#algo>
- Ting, D. S. J., Ho, C. S., Cairns, J., Elsahn, A., Al-Aqaba, M., Boswell, T., Said, D. G., & Dua, H. S. (2021). 12-year analysis of incidence, microbiological profiles and in vitro antimicrobial susceptibility of infectious keratitis: The Nottingham Infectious Keratitis Study. *British Journal of Ophthalmology*, 105(3), 328–333. <https://doi.org/10.1136/bjophthalmol-2020-316128>

- Ting, D. S. W., Peng, L., Varadarajan, A. v., Keane, P. A., Burlina, P. M., Chiang, M. F., Schmetterer, L., Pasquale, L. R., Bressler, N. M., Webster, D. R., Abramoff, M., & Wong, T. Y. (2019). Deep learning in ophthalmology: The technical and clinical considerations. *Progress in Retinal and Eye Research*, 72, 1-24. <https://doi.org/10.1016/j.preteyeres.2019.04.003>
- Topol, E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44–56. <https://doi.org/10.1038/s41591-018-0300-7>
- Tran, B. X., Latkin, C. A., Vu, G. T., Nguyen, H. L. T., Nghiem, S., Tan, M. X., Lim, Z. K., Ho, C. S. H., & Ho, R. C. M. (2019a). The current research landscape of the application of artificial intelligence in managing cerebrovascular and heart diseases: A bibliometric and content analysis. *International Journal of Environmental Research and Public Health*, 16(15). <https://doi.org/10.3390/ijerph16152699>
- Tran, B. X., Vu, G. T., Ha, G. H., Vuong, Q. H., Ho, M. T., Vuong, T. T., La, V. P., Ho, M. T., Nghiem, K. C. P., Nguyen, H. L. T., Latkin, C. A., Tam, W. W. S., Cheung, N. M., Nguyen, H. K. T., Ho, C. S. H., & Ho, R. C. M. (2019b). Global evolution of research in artificial intelligence in health and medicine: A bibliometric study. *Journal of Clinical Medicine*, 8(3), 1-18. <https://doi.org/10.3390/jcm8030360>
- Tu, P. (2012). Study of influential authors works and research network of advertising research: 1998 to 2007. *African Journal of Business Management*, 6(33), 9399–9417. <https://doi.org/10.5897/AJBM11.1513>
- Van Raan, A. (2003). The use of bibliometric analysis in research performance assessment and monitoring of interdisciplinary scientific developments. *TATuP - Zeitschrift Für Technikfolgenabschätzung in Theorie Und Praxis*, 12(1), 20–29. <https://doi.org/10.14512/tatup.12.1.20>
- Verhoef, P. C., Broekhuizen, T., Bart, Y., Bhattacharya, A., Qi Dong, J., Fabian, N., & Haenlein, M. (2021). Digital transformation: A multidisciplinary reflection and research agenda. *Journal of Business Research*, 122, 889–901. <https://doi.org/10.1016/J.JBUSRES.2019.09.022>
- Vial, G. (2019). Understanding digital transformation: A review and a research agenda. *The Journal of Strategic Information Systems*, 28(2), 118–144. <https://doi.org/10.1016/J.JSIS.2019.01.003>
- Wang, P., Xiao, X., Glissen Brown, J. R., Berzin, T. M., Tu, M., Xiong, F., Hu, X., Liu, P., Song, Y., Zhang, D., Yang, X., Li, L., He, J., Yi, X., Liu, J., & Liu, X. (2018). Development and validation of a deep-learning algorithm for the detection of polyps during colonoscopy. *Nature Biomedical Engineering*, 2(10), 741–748. <https://doi.org/10.1038/s41551-018-0301-3>
- Waring, J., Lindvall, C., & Umeton, R. (2020). Automated machine learning: Review of the state-of-the-art and opportunities for healthcare. *Artificial Intelligence in Medicine*, 104, 1-12. <https://doi.org/10.1016/j.artmed.2020.101822>
- Wisetsri, W. (2021). Rise of Artificial Intelligence in Healthcare Startups in India. *Advances in Management*, 14(1), 48-42. <https://www.researchgate.net/publication/349604103>

- Wolff J, Pauling J, Keck A, Baumbach J. (2020). The Economic Impact of Artificial Intelligence in Health Care: Systematic Review. *J Med Internet Res*, 22(2), 1-8. <https://doi.org/10.2196/16866>. PMID: 32130134; PMCID: PMC7059082
- Wu, H., Chan, N.-K., Zhang, C. J. P., & Ming, W.-K. (2019). The Role of the Sharing Economy and Artificial Intelligence in Health Care: Opportunities and Challenges. *Journal of Medical Internet Research*, 21(10), 1-7. <https://doi.org/10.2196/13469>
- Wu, N., Phang, J., Park, J., Shen, Y., Huang, Z., Zorin, M., Jastrz, S., Ebski, , Févry, T., Katsnelson, J., Kim, E., Wolfson, S., Parikh, U., Gaddam, S., Leng, L., Lin, Y., Ho, K., Weinstein, J. D., Reig, B., ... Geras, K. J. (2019). Deep Neural Networks Improve Radiologists' Performance in Breast Cancer Screening. *IEEE Trans Med Imaging*, 39(4):1184-1194. <https://doi.org/10.1109/TMI.2019.2945514>.
- Xie, Y., Nguyen, Q. D., Hamzah, H., Lim, G., Bellemo, V., Gunasekeran, D. v., Yip, M. Y. T., Qi Lee, X., Hsu, W., Li Lee, M., Tan, C. S., Tym Wong, H., Lamoureux, E. L., Tan, G. S. W., Wong, T. Y., Finkelstein, E. A., & Ting, D. S. W. (2020). Artificial intelligence for teleophthalmology-based diabetic retinopathy screening in a national programme: an economic analysis modelling study. *The Lancet Digital Health*, 2(5), e240–e249. [https://doi.org/10.1016/S2589-7500\(20\)30060-1](https://doi.org/10.1016/S2589-7500(20)30060-1)
- Xu, J., Yang, P., Xue, S., Sharma, B., Sanchez-Martin, M., Wang, F., Beaty, K. A., Dehan, E., & Parikh, B. (2019). Translating cancer genomics into precision medicine with artificial intelligence: applications, challenges and future perspectives. *Human Genetics*, 138(2), 109–124. <https://doi.org/10.1007/s00439-019-01970-5>
- Yang, J. H., Wright, S. N., Hamblin, M., McCloskey, D., Alcantar, M. A., Schrübbers, L., Lopatkin, A. J., Satish, S., Nili, A., Palsson, B. O., Walker, G. C., & Collins, J. J. (2019). A White-Box Machine Learning Approach for Revealing Antibiotic Mechanisms of Action. *Cell*, 177(6), 1649-1661.e9. <https://doi.org/10.1016/j.cell.2019.04.016>
- Yang, S., Zhu, F., Ling, X., Liu, Q., & Zhao, P. (2021). Intelligent Health Care: Applications of Deep Learning in Computational Medicine. *Frontiers in Genetics*, 12, 1-21. <https://doi.org/10.3389/fgene.2021.607471>
- Yu, C., Liu, J., Nemati, S., & Yin, G. (2021). Reinforcement Learning in Healthcare: A Survey. *ACM Computing Surveys*, 55(1), 1–36. <https://doi.org/10.1145/3477600>
- Yu, K. H., Beam, A. L., & Kohane, I. S. (2018). Artificial intelligence in healthcare. *Nature Biomedical Engineering*, 2(10), 719–731. <https://doi.org/10.1038/s41551-018-0305-z>
- Zeevi, D., Korem, T., Zmora, N., Israeli, D., Rothschild, D., Weinberger, A., Ben-Yacov, O., Lador, D., Avnit-Sagi, T., Lotan-Pompan, M., Suez, J., Mahdi, J. A., Matot, E., Malka, G., Kosower, N., Rein, M., Zilberman-Schapira, G., Dohnalová, L., Pevsner-Fischer, M., ... Segal, E. (2015). Personalized Nutrition by Prediction of Glycemic Responses. *Cell*, 163(5), 1079–1094. <https://doi.org/10.1016/j.cell.2015.11.001>
- Zhang, J., Yu, Q., Zheng, F., Long, C., Lu, Z., & Duan, Z. (2016). Comparing keywords plus of WOS and author keywords: A case study of patient adherence research. *Journal of the Association for Information Science and Technology*, 67(4), 967–972. <https://doi.org/10.1002/asi.23437>

- Zhou, J., & Troyanskaya, O. G. (2015). Predicting effects of noncoding variants with deep learning-based sequence model. *Nature Methods*, 12(10), 931–934. <https://doi.org/10.1038/nmeth.3547>
- Zhu, W., Xie, L., Han, J., & Guo, X. (2020). The application of deep learning in cancer prognosis prediction. *Cancers*, 12(3), 1-28. <https://doi.org/10.3390/cancers12030603>

ANEXOS

ANEXO A: Valores de *Betweenness* e *Closeness* - Análise de rede.

<i>Node</i>	<i>Cluster</i>	<i>Betweenness</i>	<i>Closeness</i>
<i>deep learning</i>	1	510,0871462	0,020408163
<i>machine learning</i>	1	302,2476636	0,019607843
<i>artificial intelligence</i>	1	137,4858768	0,017241379
<i>convolutional neural network</i>	1	0,033744583	0,011111111
<i>radiomics</i>	1	0	0,010752688
<i>neural networks</i>	1	0,139333202	0,011235955
<i>diagnosis</i>	1	0,262380631	0,011235955
<i>classification</i>	1	0	0,010752688
<i>medicine</i>	1	0	0,010869565
<i>prediction</i>	1	0,168978671	0,011235955
<i>imaging</i>	1	0,031874266	0,011111111
<i>diseases</i>	1	0	0,010869565
<i>disease</i>	1	0	0,010869565
<i>medical</i>	1	0,036267606	0,011111111
<i>network</i>	1	0	0,010869565
<i>pathology</i>	1	0	0,010752688
<i>telemedicine</i>	1	0	0,010638298
<i>convolutional neural networks</i>	1	0	0,010638298
<i>echocardiography</i>	1	0,002150538	0,010989011
<i>language processing</i>	1	0	0,010869565
<i>natural</i>	1	0	0,010869565
<i>neural</i>	1	0	0,010869565
<i>precision medicine</i>	1	0	0,010869565
<i>prognosis</i>	1	0	0,010869565
<i>radiology</i>	1	0	0,010869565
<i>learning</i>	2	13,59858289	0,012987013
<i>deep</i>	2	0	0,010869565
<i>machine</i>	2	0,679034533	0,011627907
<i>neural network</i>	2	0,15384045	0,011363636
<i>natural language processing</i>	2	0,002466091	0,010989011
<i>computer-aided diagnosis</i>	2	0	0,010869565
<i>covid-19</i>	3	5,641824405	0,0125
<i>coronavirus</i>	3	0,032967033	0,011111111
<i>sars-cov-2</i>	3	0,03760888	0,011235955
<i>transfer learning</i>	3	0	0,010869565
<i>computer vision</i>	3	0	0,010869565
<i>healthcare</i>	4	1,439450589	0,011764706
<i>big data</i>	4	2,087809031	0,012195122
<i>feature extraction</i>	4	0,255423762	0,011111111
<i>medical imaging</i>	4	0,794197222	0,011494253
<i>ai</i>	4	0,046632752	0,011111111
<i>health care</i>	4	0	0,010752688
<i>segmentation</i>	4	0,084377611	0,010989011
<i>image processing</i>	4	0,442810644	0,011363636
<i>optimization</i>	4	0,015748031	0,010869565
<i>image classification</i>	4	0,004179728	0,010989011
<i>artificial</i>	5	0,185434809	0,011111111
<i>intelligence</i>	5	0	0,010869565
<i>cardiovascular disease</i>	5	0,00219539	0,010989011

ANEXO B: Valores de Centralidade e Densidade – Mapa Temático.

<i>Cluster</i>	Centralidade	Densidade	Rank. Centralidade	Rank. Densidade
<i>deep learning</i>	13,17373167	58,84668167	8	1
<i>learning</i>	9,194201683	64,1098019	5	2
<i>covid-19</i>	8,506575569	88,54320988	4	7
<i>healthcare</i>	10,77353612	66,46968376	7	3
<i>big data</i>	9,278735622	112,6093611	6	8
<i>artificial</i>	8,410909883	85,62890813	3	6
<i>medicine</i>	7,923117344	83,85894934	2	5
<i>precision medicine</i>	2,51243522	72,4537037	1	4

Fonte: produzido a partir do aplicativo Biblioshiny.