



DEPARTAMENTO DE ENGENHARIAS E CIÊNCIAS DA COMPUTAÇÃO
MESTRADO EM ENGENHARIA INFORMÁTICA E DE TELECOMUNICAÇÕES
UNIVERSIDADE AUTÓNOMA DE LISBOA
“LUÍS DE CAMÕES”

Análise da literatura científica das aplicações da Inteligência
Artificial na medicina com VOSviewer

Dissertação para a obtenção do grau de Mestre em Engenharia Informática e de
Telecomunicações

Autor: André Pedro Aradas Pimparel

Orientador: Professor Doutor Laercio Cruvinel Júnior

Número do candidato: 30008881

Julho de 2024

Lisboa

Agradecimentos

Quero agradecer aos meus pais Pedro e Sónia, por todo o apoio ao longo da minha vida escolar e por sempre proporcionarem as melhores condições para aprender e me motivarem a nunca parar de estudar. Aos meus avós Adriano e Fernanda, por todo apoio e carinho que me deram desde sempre, e que sem eles nunca seria possível realizar este mestrado. À minha irmã Beatriz que sempre me ajudou durante a realização desta dissertação. Ao meu tio Paulo por me ter ajudado no mundo do trabalho, onde aprendi conhecimentos que me ajudaram, na realização deste trabalho. E aos restantes membros da minha família por todo o apoio e carinho demonstrado.

Ao meu orientador, Laercio Cruvinel, que esteve disponível para ajudar, e sempre me orientou da melhor maneira possível, o meu grande obrigado.

Também quero agradecer a todos os professores que me ensinaram bastante ao longo da Licenciatura e do Mestrado, para no futuro me tornar um bom profissional.

Quero agradecer aos meus amigos da UBI que iniciaram a tradição de agradecer nas dissertações de mestrado aos membros do grupo, e é com muito orgulho e felicidade, que lhes devolvo o meu agradecimento. Obrigado: Conrado G., Jorge B., José F. e André L.

Também quero agradecer à minha namorada Liliana que sempre me incentivou a acabar o mestrado. E aos meus restantes amigos, com quais partilhei bons momentos, durante a realização deste trabalho.

E agradecer aos meus chefes da CGI, João Paulo Pereira e Mónica Vaz, que me permitiram tirar uma sabática do trabalho para concluir a minha dissertação.

Resumo

A rápida expansão da investigação em Inteligência Artificial (IA) resultou num número esmagador de artigos científicos, particularmente no setor da saúde. Esta abundância de literatura representa um desafio para os investigadores que procuram identificar tendências críticas, lacunas de investigação e oportunidades futuras. Esta dissertação tem como objetivo avaliar sistematicamente a eficácia do VOSviewer, uma ferramenta bibliométrica amplamente utilizada, na análise de artigos científicos para verificar o estado atual da pesquisa em IA em medicina.

O estudo concentra-se em artigos de IA relacionados à saúde do repositório PubMed, abrangendo os últimos quatro anos. Procura determinar a melhor metodologia de pesquisa bibliométrica para responder duas questões-chave: (1) Que subáreas dos cuidados de saúde são mais frequentemente abordadas no contexto da IA? (2) Que nichos inexplorados existem onde a investigação futura poderia ser particularmente valiosa?

Ao aplicar o VOSviewer a este conjunto de dados, a pesquisa visa: (a) Identificar subáreas pouco exploradas da saúde; (b) Fornecer uma revisão sistemática e perspectivas para orientar a investigação futura nestas subáreas; (c) Explorar esta ferramenta de forma a otimizar os resultados da pesquisa bibliométrica.

Palavras-chave: inteligência artificial, análise de dados, redes bibliométricas, VOSviewer

Abstract

The rapid expansion of research in Artificial Intelligence (AI) has resulted in an overwhelming number of scientific articles, particularly within the healthcare sector. This abundance of literature poses a challenge for researchers seeking to identify critical trends, research gaps, and future opportunities. This dissertation aims to systematically evaluate the effectiveness of VOSviewer, a widely-used bibliometric tool, in analyzing scientific articles to assess the current state of AI research in medicine.

The study focuses on health-related AI articles from the PubMed repository, spanning the last four years. It seeks to determine the best bibliometric research methodology to answer two key questions: (1) Which sub-areas of healthcare are most frequently addressed in the context of AI? (2) What untapped niches exist where future research could be particularly valuable?

By applying VOSviewer to this dataset, the research aims to: (a) Identify underexplored sub-areas of healthcare; (b) Provide a systematic review and insights to guide future research in these sub-areas; (c) Explore this tool to optimize bibliometric research results.

Keywords: *artificial intelligence, data analysis, bibliometric networks, VOSviewer*

Índice

1	INTRODUÇÃO	11
1.1	FORMULAÇÃO DO PROBLEMA	11
1.2	OBJETIVOS	11
1.3	JUSTIFICAÇÃO	12
1.4	METODOLOGIA	12
2	INTRODUÇÃO TEÓRICA E REVISÃO DE LITERATURA	14
2.1	REDES BIBLIOMÉTRICAS	14
2.1.1	<i>Análise bibliométrica das aplicações da IA na hipertensão pulmonar</i>	15
2.1.1.1	Definição de pesquisa	16
2.1.1.2	Coleta de dados	16
2.1.1.3	Processamento de dados	16
2.1.1.4	Análise de dados	16
2.1.1.5	Visualização de dados	16
2.2	VOSVIEWER	17
2.2.1	<i>Revisão bibliométrica com VOSviewer</i>	18
2.2.2	<i>Funcionalidades do VOSviewer</i>	18
2.3	UMA ANÁLISE BIBLIOMÉTRICA DA APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL NA MEDICINA	21
2.4	APLICAÇÕES DA IA NA MEDICINA	22
2.4.1	<i>Análise de imagens</i>	22
2.4.2	<i>Deteção de doenças</i>	22
2.4.3	<i>Chatbots médicos</i>	23
2.4.4	<i>Cirurgia robótica</i>	23
2.4.5	<i>Descoberta de novos tratamentos</i>	24
2.4.6	<i>Desafios da utilização da IA na medicina</i>	24
3	ABORDAGEM	26
3.1	DEFINIÇÃO DE PESQUISA	26
3.2	EXTRAÇÃO DE DADOS	27
3.3	PROCESSAMENTO, ANÁLISE E VISUALIZAÇÃO DE DADOS	27

3.3.1	<i>Dados de texto</i>	27
3.3.1.1	Aplicação dos Parâmetros Ótimos	35
3.3.2	<i>Coocorrência de conceitos</i>	38
3.3.2.1	Eliminação de clusters (EC)	40
3.3.2.2	Aplicação da técnica EC para os restantes anos	42
4	ANÁLISE DE RESULTADOS	48
4.1	ANÁLISE DOS RESULTADOS DE 2020	48
4.2	ANÁLISE DOS RESULTADOS DE 2021	48
4.3	ANÁLISE DOS RESULTADOS DE 2022	48
4.4	ANÁLISE DOS RESULTADOS DE 2023	49
4.5	ANÁLISE DOS RESULTADOS DE 2024	49
4.6	CONSIDERAÇÕES GERAIS	49
5	CONCLUSÃO	51
5.1	LIMITAÇÕES DO TRABALHO	51
5.2	CONSIDERAÇÕES FINAIS	51
5.3	TRABALHO FUTURO	52
	REFERÊNCIAS BIBLIOGRÁFICAS	53
	APÊNDICES	56
	CRONOGRAMA	56

Lista de Figuras

Figura 1 – Diagrama do processo aplicado durante a análise realizada em [12]	18
Figura 2 - mapa obtido com SPSS. Imagem de [13]	19
Figura 3- Mapa obtido com Pajek. Imagem de [13]	19
Figura 4 - Janela do VOSviewer. Imagem de [13]	20
Figura 5 - Tipo de dados bibliométricos	28
Figura 6 - Dados escolhidos para analisar na pesquisa	28
Figura 7 - Widget métodos de contagem	28
Figura 8 - Percentagem de termos mais relevantes	29
Figura 9 - Número mínimo de ocorrências	29
Figura 10 - Dados PubMed 2020 MOT 10 PTMR 60%	30
Figura 11 - Dados PubMed 2020 MOT 50 PTMR 60%	31
Figura 12 - Dados PubMed 2020 MOT 10 PTMR 10%	32
Figura 13 - Cluster laranja PubMed 2020 MOT 50 PTMR 10%	33
Figura 14 - Cluster Vermelho PubMed 2020 MOT 50 PTMR 10%	33
Figura 15 - Cluster azul-claro PubMed 2020 MOT 50 PTMR 10%	33
Figura 16 - Dados PubMed 2020 MOT 25 PTMR 30%	34
Figura 17 - Dados PubMed 2021 MOT 10 PTMR 10%	35
Figura 18 - Dados PubMed 2022 MOT 10 PTMR 10%	36
Figura 19 - Dados PubMed 2023 MOT 10 PTMR 5.7%	36
Figura 20 - Dados PubMed 2024 MOT 10 PTMR 10%	37
Figura 21 - Mapa baseado em dados bibliográficos	38
Figura 22 - Tipo de análise e método de contagem	38
Figura 23 - Links entre autores e documentos. Imagem de [28]	39
Figura 24 - Rede de coautoria usado contagem completa, na esquerda, ou contagem fracionária, na direita. Imagem de [28]	39
Figura 25 - Dados PubMed 2020 COC Original	40
Figura 26 - Diagrama da técnica de eliminação de clusters	40
Figura 27 - Dados PubMed 2020 COC EC	42
Figura 28 - Dados PubMed 2021 COC Original	43
Figura 29 - Dados PubMed 2021 COC EC	43
Figura 30 - Dados PubMed 2022 COC Original	44

Figura 31 - Dados PubMed 2022 COC EC	44
Figura 32 - Dados PubMed 2023 COC Original	45
Figura 33 - Dados PubMed 2023 COC EC	45
Figura 34 - Dados PubMed 2024 COC Original	46
Figura 35 - Dados PubMed 2024 COC EC	46

Lista de Tabelas

Tabela 1- Cronograma	56
----------------------	----

Lista de Equações

(Equação 1)	27
(Equação 2)	35
(Equação 3)	35
(Equação 4)	35
(Equação 5)	35

Lista de Algoritmos

Algoritmo 1 Eliminação de clusters	41
---	----

Lista de Siglas e Acrónimos

AI	<i>Artificial Intelligence</i>
API	<i>Application Programming Interface</i>
COC	Coocorrência de Conceitos
EC	Eliminação de Clusters
IA	Inteligência artificial
LDA	<i>Latent Dirichlet Allocation</i>
MCA	<i>Multiple Correspondence Analysis</i>
MDS	<i>Multidimensional Scaling</i>
MOT	Mínimo de Ocorrências de um Termo
PCA	<i>Principal component analysis</i>
PTMR	Porcentagem de Termos Mais Revelantes
UE	União Europeia

1 Introdução

O VOSviewer é um software de construção e visualização de redes bibliométricas. A investigação no campo das redes bibliométricas remonta aos anos 1960 [1], e ao longo do tempo, uma diversidade de métodos tem sido empregue tanto na sua visualização e análise [2], como na construção eficaz dessas redes [3]. É, portanto, particularmente instigante aplicar essas técnicas em áreas atuais, como a Inteligência Artificial e a medicina. Este domínio de conhecimento gera milhares de artigos anualmente. Dada a amplitude e complexidade inerentes à IA e à medicina, a criação de análises sobre os diversos artigos que abordam este tópico representa um desafio significativo. Por isso, a utilização de um software como o VOSviewer pode agilizar a procura de lacunas na bibliografia atual e, de forma rápida, ajudar os académicos a encontrar os artigos mais relevantes nas aplicações de IA na medicina. Adicionalmente, com as técnicas abordadas adiante neste documento, será ainda realizada uma melhoria dos resultados obtidos.

1.1 Formulação do Problema

O problema que esta dissertação se propõe a resolver consiste em determinar quais subáreas da saúde são mais abordadas no contexto de aplicações da Inteligência Artificial e averiguar se existem nichos inexplorados onde futuro trabalho científico valioso na área das aplicações de IA na medicina possa ser conduzido.

Para abordar esta questão, será realizada uma análise abrangente do VOSviewer, um software gratuito e popular de pesquisa bibliométrica, examinando o seu funcionamento, características, vantagens e desvantagens. Isto permitirá a realização de correlações, identificação de lacunas e análise de artigos científicos.

Por fim, será realizado um estudo aprofundado dos resultados obtidos e do impacto deste software, otimizações do processo de criação de mapas bibliométricos, bem como a análise da possibilidade de aplicação destes processos em outros domínios de conhecimento.

1.2 Objetivos

O objetivo desta dissertação consiste em analisar as lacunas existentes na bibliografia das aplicações da IA na área da saúde, identificar áreas que requerem estudos mais aprofundados, determinar os tópicos de maior relevância nos artigos científicos e fornecer *insights* que possam orientar futuras pesquisas nas subáreas em questão. Além disso, pretende-

se realizar uma revisão sistemática do software VOSviewer, de forma a determinar um procedimento que conduza a melhores resultados e que também possa ser aplicado a outros tópicos.

1.3 Justificação

Atualmente, assistimos a uma proliferação de milhões de artigos nas áreas de inteligência artificial. Contudo, este domínio é notoriamente abrangente, abrigando uma miríade de subcampos especializados. Num mundo em constante mutação, a necessidade de aprender de forma rápida e precisa é imperativa. Adicionalmente, anualmente, são investidos milhares de milhões de euros na União Europeia (UE) no programa de investigação científica [4]. Neste contexto, surge a pertinência de utilizar um software capaz de identificar as áreas que demandam aprofundamento e determinar quais são os temas de maior relevância para a elaboração de orçamentos financeiros em projetos de pesquisa. Além disso, ainda não existe nenhum estudo que procure otimizar os resultados do VOSviewer e que faça um resumo detalhado do estado da arte das aplicações de IA na medicina nos últimos quatro anos, com base nos resultados dos mapas bibliométricos gerados pelo VOSviewer.

1.4 Metodologia

O início desta dissertação foi marcado pela escolha do tema a ser abordado e pela definição do problema: determinar quais subáreas da saúde são mais abordadas no contexto de aplicações da Inteligência Artificial e averiguar se existem nichos inexplorados onde futuro trabalho científico valioso na área das aplicações de IA na medicina possa ser conduzido. Foram definidos os objetivos a serem alcançados: identificar tópicos mais relevantes no campo mencionado, averiguar se existem lacunas na bibliografia e definir um procedimento de utilização do VOSviewer que conduza a melhores resultados e que também possa ser aplicado a outros tópicos, bem como definir possíveis aplicações.

Com o intuito de responder ao problema desta dissertação, foi conduzida uma revisão bibliográfica no capítulo 0. Escolheu-se um software gratuito e popular para a realização do estudo bibliométrico, nomeadamente o VOSviewer. Dados foram coletados anualmente desde 2021 até 2024 do repositório de artigos científicos PubMed, utilizando a Application Programming Interface (API) OpenAlex.

No capítulo 3, selecionaram-se os parâmetros da pesquisa e experimentaram-se empiricamente diferentes processos de criação de mapas bibliométricos focados nos tópicos de

aplicação de IA na medicina, eliminando aqueles que não apresentavam resultados satisfatórios para todos os anos incluídos na pesquisa. O objetivo era encontrar um procedimento genérico, evitando a necessidade de limpeza de dados em cada pesquisa, que pudesse ser utilizado em outros domínios. Uma vez obtido um resultado satisfatório, replicou-se o mesmo procedimento para os diferentes anos do estudo.

Em seguida, estes resultados foram analisados detalhadamente no capítulo 4. Por fim, no capítulo 5, concluiu-se o documento, apresentaram-se as limitações e possíveis trabalhos futuros.

2 Introdução Teórica e Revisão de Literatura

Este capítulo tem como objetivo fornecer uma fundamentação teórica abrangente e uma revisão crítica da literatura existente sobre a aplicação da Inteligência Artificial (IA) na área da saúde. Inicialmente, será apresentado um panorama geral da evolução da IA, destacando suas principais técnicas e metodologias. Em seguida, a discussão focará nas aplicações específicas da IA na medicina, examinando os avanços recentes, as áreas de maior impacto e as principais contribuições científicas. A revisão da literatura identificará lacunas e oportunidades de pesquisa, bem como os desafios enfrentados na integração da IA no contexto médico. Além disso, será abordado o papel do VOSviewer como ferramenta de análise bibliométrica, destacando sua importância na identificação de tendências e na avaliação da produção científica. De acordo com Tomaszewski (2023), os softwares de bibliometria desempenham um papel crucial na visibilidade, impacto e aplicações da pesquisa científica. Esses programas facilitam a análise detalhada das tendências de pesquisa e permitem uma compreensão aprofundada das áreas de estudo emergentes e bem estabelecidas [5]. Este capítulo fornecerá o embasamento necessário para entender o estado da arte e orientar os estudos subsequentes desta dissertação.

2.1 Redes bibliométricas

No amálgama de descobertas e desafios que definem o panorama científico global, a incessante busca pelo entendimento e inovação permanece constante. A ciência, como catalisadora do progresso humano, transcende fronteiras geográficas, conectando mentes brilhantes e laboratórios em todo o mundo. À medida que avançamos no século XXI, testemunhamos uma era de interconexão e interdependência, onde avanços em um canto do planeta reverberam globalmente. Do entendimento das leis fundamentais da natureza à aplicação inovadora desse conhecimento em soluções práticas, a ciência permeia todos os aspectos da sociedade.

A bibliometria consiste na utilização de métodos estatísticos para analisar livros, artigos e outras publicações, especialmente em domínios científicos. Um método bibliométrico comum é a análise de citações, que envolve a construção de gráficos de citações ou a representação gráfica das citações compartilhadas entre documentos. A maioria dos campos de pesquisa utiliza métodos bibliométricos para explorar o impacto de seu campo, de um conjunto de pesquisadores, de um artigo específico ou para identificar artigos particularmente impactantes

dentro de um campo específico de pesquisa. As ferramentas bibliométricas têm sido comumente integradas na linguística descritiva e na avaliação do uso do leitor.

As redes bibliométricas são uma das aplicações da bibliometria que mapeiam as relações entre diferentes áreas de pesquisa. Elas são construídas a partir de dados bibliográficos, como citações entre artigos científicos, e podem ser usadas para visualizar a estrutura da pesquisa científica, identificar áreas de pesquisa emergentes e rastrear o fluxo de conhecimento entre diferentes áreas. Essas redes ajudam a visualizar a estrutura da pesquisa científica, identificar áreas emergentes e partilhar informação entre diferentes áreas de conhecimento, o que permite entender como o conhecimento é distribuído na comunidade científica [6].

As redes bibliométricas podem ser usadas para várias aplicações, tais como:

- Visualizar a estrutura da pesquisa científica e identificar áreas de pesquisa emergentes
- Avaliar a pesquisa de autores, instituições e países
- Identificar especialistas em diferentes áreas de pesquisa
- Desenvolver políticas de pesquisa que apoiem áreas promissoras de investigação

Essas redes acompanham a evolução de um campo de pesquisa ao longo do tempo. Através da análise da frequência de palavras-chave em títulos e resumos de artigos científicos, é possível identificar as principais tendências e os temas emergentes em um determinado período. Técnicas como análise de clusters e análise de tópicos podem ser utilizadas para agrupar artigos por temas semelhantes e identificar áreas de pesquisa com alto crescimento.

Além disso, as redes bibliométricas podem ser utilizadas para identificar áreas de pesquisa que ainda não foram exploradas em profundidade. Através da análise da densidade da rede, é possível identificar áreas com poucas publicações e, consequentemente, com maior potencial para novas pesquisas. Por exemplo, em um estudo sobre bioinformática para o diagnóstico de doenças, as redes bibliométricas podem identificar lacunas de pesquisa. A análise da densidade da rede pode revelar áreas com poucas pesquisas, como o desenvolvimento de ferramentas bioinformáticas para o diagnóstico precoce de doenças raras.

2.1.1 Análise bibliométrica das aplicações da IA na hipertensão pulmonar

Nas últimas décadas, diversas análises bibliométricas foram realizadas utilizando várias metodologias. O trabalho de [7] demonstra uma metodologia aplicada a uma análise bibliométrica em um tema semelhante ao deste trabalho, mas em uma área mais específica: a aplicação da inteligência artificial na hipertensão pulmonar.

Os autores do artigo [7] recomendam a seguinte metodologia dividida em cinco fases: definição da pesquisa, coleta de dados, processamento de dados, análise de dados e visualização de dados.

2.1.1.1 *Definição de pesquisa*

Definir as palavras-chave e expressões a serem utilizadas como input para extrair os documentos. No nosso trabalho, usaremos palavras como: AI, *artificial intelligence*. Optaremos por palavras em inglês, visto que 95% dos artigos são escritos nesse idioma [8]. Por esse motivo, limitaremos nossa pesquisa apenas a artigos científicos escritos em inglês.

2.1.1.2 *Coleta de dados*

Identificar publicações importantes de conferências, livros, capítulos de livros, artigos e jornais, verificando se estas publicações possuem os seguintes critérios: nome do autor e ano da publicação. Neste trabalho, utilizaremos as bases de dados mencionadas anteriormente, que já possuem este tipo de documentos.

2.1.1.3 *Processamento de dados*

Neste passo, os autores definem as técnicas a serem usadas para processar os dados: limpeza de dados para eliminar redundâncias, transformação de dados para criar a matriz quadrada (documentos x atributos) e, por fim, normalização dos dados.

2.1.1.4 *Análise de dados*

Este é o passo mais importante na revisão bibliométrica. Inclui uma análise bibliométrica descritiva e a redução de dados por vários métodos, tais como: *clustering*, análise de componentes principais (*Principal component analysis* – PCA), análise de correspondência múltipla (*Multiple Correspondence Analysis* – MCA), escalonamento multidimensional (*Multidimensional Scaling* – MDS) e agrupamento bibliométrico com análise histográfica.

2.1.1.5 *Visualização de dados*

Visualização dos resultados da análise, proporcionando uma sumarização dos dados e das relações entre eles. Pode ser realizada na forma de mapas, gráficos, diagramas ou tabelas. Neste trabalho, utilizaremos as capacidades de visualização do VOSviewer.

2.2 VOSviewer

O VOSviewer é uma ferramenta de software utilizada para construir e visualizar redes bibliométricas. Estas redes podem incluir elementos como periódicos, investigadores ou publicações individuais e suportam análises de citações, acoplamento bibliográfico, co-citação ou relações de coautoria. Além disso, o VOSviewer oferece funcionalidades de mineração de texto e é capaz de construir e visualizar redes de termos importantes extraídos do corpo da literatura científica [9].

Neste trabalho, escolheu-se utilizar o VOSviewer por ser um software gratuito e de código aberto que permite aos usuários criar mapas visuais de dados bibliométricos, como redes de co-citação e coocorrência de palavras. O VOSviewer é particularmente útil para analisar grandes conjuntos de dados, pois pode lidar com milhões de registos e fornece uma variedade de recursos avançados, como a deteção de clusters e a visualização de tendências temporais [10].

Este software pode extrair dados de arquivos descarregados do WoS, Scopus, Dimensions e PubMed no formato RIS. Além disso, é possível consultar interativamente a API do Crossref, Europa PMC e Medline. Se houver mais de um conjunto de dados, é possível obter os dados através das APIs do OpenALex, Semantic Scholar, Open Citations e Wikidata.

O VOSviewer constrói um mapa com base numa matriz de coocorrência em três etapas. Primeiro, calcula uma matriz de similaridade para aplicar a técnica de mapeamento VOS, utilizando a força de associação. Depois, utiliza a técnica de mapeamento VOS para construir um mapa que reflete a medida de similaridade entre os itens. Por fim, realiza tradução, rotação e reflexão para corrigir o problema de otimização descrito na literatura.

No que diz respeito às capacidades de visualização, este software oferece três opções: rede, sobreposição e densidade. É de salientar que o VOSviewer incorpora funcionalidades de zoom, bem como um algoritmo de classificação inteligente para evitar a sobreposição de etiquetas. O VOSviewer permite uma observação detalhada do mapa gerado através da opção de zoom. Finalmente, todas as visualizações geradas podem ser guardadas em diferentes formatos, permitindo incluir a saída da análise em qualquer formato digital ou impresso. Este software também pode ser iniciado diretamente a partir da página web [11].

2.2.1 Revisão bibliométrica com VOSviewer

Singh e colaboradores [12] utilizaram a mesma ferramenta bibliométrica que vamos empregar neste trabalho (VOSviewer) para realizar uma análise dos padrões de sono em sobreviventes do cancro da mama.




Figura 1 – Diagrama do processo aplicado durante a análise realizada em [12]

Na Figura 1, podemos observar um resumo do processo aplicado durante a sua pesquisa. Inicialmente, definiram-se as palavras-chave a serem utilizadas como input de pesquisa na base de dados Scopus. O resultado gerou um ficheiro CSV contendo os seguintes atributos: ano da publicação, jornal, título, nome do autor, organização e detalhes de afiliação, informação de financiamento, palavras-chave, tipo de documento, resumos e citações. Os autores certificaram-se de que não havia duplicados nos dados.

Após o processamento dos dados, utilizaram o VOSviewer para analisar resultados de coocorrência, coautoria, citações, agrupamento bibliográfico, tendências e temas, que são aspectos importantes também para a análise nesta dissertação. Além disso, a revisão desses trabalhos revelou que a metodologia para realizar uma análise bibliométrica, seja com o software VOSviewer ou sem ele, é bastante semelhante.

2.2.2 Funcionalidades do VOSviewer

Nees e Waltman, pesquisadores holandeses e criadores do software VOSviewer, comparam em [13] as funcionalidades deste programa com outros do mesmo gênero. Neste estudo, eles utilizaram como exemplo dados da revista Thomson Reuters com artigos publicados em 2005 e com pelo menos 25 co-citações entre 2005 e 2007. Apenas 232 jornais




Figura 2 - mapa obtido com SPSS. Imagem de [13]




Figura 3- Mapa obtido com Pajek. Imagem de [13]

Como se pode ver pela Figura 2 e pela Figura 3, ambos os programas apresentam graves problemas de sobreposição de legendas, o que torna difícil analisar os resultados em detalhe.




Figura 4 - Janela do VOSviewer. Imagem de [13]

Na Figura 4, o estudo demonstra como o software VOSviewer ultrapassa esses problemas.

O VOSviewer apresenta três maneiras de visualizar gráficos: *network*, *overlay* e *density*, sendo esta última dividida em *item density* e *cluster density* [9]:

- *Network visualization*: Neste modo de visualização, os itens são representados por uma legenda e um círculo. O tamanho da legenda e do círculo indica a importância do item, e a cor do item é determinada pelo cluster ao qual pertence. Pode mostrar, por defeito, até 1000 linhas de ligação forte entre os itens.
- *Overlay visualization*: Nesta visualização, os itens são indicados por uma legenda de maneira semelhante à *network visualization*, mas cada item no mapa é colorido de forma diversa. Se houver valoração dos itens, cada item tem uma cor determinada pela sua pontuação, variando de azul (menor pontuação) e passando pelo verde, indo até ao amarelo (maior pontuação). Caso contrário, os itens têm as cores que o utilizador definir.
- *Item Density visualization*: Nesta visualização, os itens são representados por uma legenda de maneira semelhante à *network visualization* e à *overlay visualization*.

Cada ponto no mapa tem uma cor que depende da densidade de itens nesse ponto, refletindo o número de itens na vizinhança e a importância dos itens vizinhos.

- *Cluster Density visualization*: Esta visualização estará disponível se os itens tiverem sido agrupados em *clusters*. A visualização é semelhante àquela da *item density*, mas a densidade dos itens é mostrada separadamente para cada *cluster* de itens, e a cor de um ponto na visualização é obtida pela mistura das cores dos diferentes *clusters*. O peso de um *cluster* é definido pelo número de itens pertencentes ao *cluster* na vizinhança do ponto.

2.3 Uma análise bibliométrica da aplicação da inteligência artificial na medicina

Alhashmi *et al.* [14] realizaram um estudo semelhante ao nosso, contudo, eles usaram o VOSviewer apenas para visualização dos mapas e aplicaram uma técnica chamada Latent Dirichlet Allocation (LDA) para a criação dos mesmos. Esta técnica é um modelo estatístico usado para identificar os principais tópicos em uma coleção de documentos e agrupar documentos com base nos tópicos que contêm. Para aplicar LDA ao seu conjunto de dados, eles realizaram um pré-processamento dos dados, que incluiu a remoção de URLs, pontuações e preposições, além da tokenização dos termos. Em seguida, criaram uma matriz TF-IDF (Term Frequency-Inverse Document Frequency), uma fórmula estatística que converte textos de documentos em vetores com base na relevância das palavras [15], e utilizaram-na como input do modelo. Após isso, geraram a matriz de resultados. Foram utilizados dados da base de dados Scopus entre 1991 e 2022. Ao contrário do nosso trabalho, Alhashmi *et al.* focaram-se mais em encontrar os top 20 países mais citados, documentos, fontes e palavras-chave mais citadas, onde surgiam palavras genéricas como “*healthcare*” e “*deep learning*”.

Andrade-Arenas *et al.* [16] realizaram uma pesquisa bibliométrica no mesmo domínio deste trabalho, contudo, com uma abordagem diferente e utilizando dados distintos. Eles selecionaram dados da base de dados Scopus entre 2015 e 2023, com palavras-chave relacionadas com IA, aprendizado de máquina, aprendizado profundo e medicina. Foram utilizados o VOSviewer e o Bibliometrix para a criação e visualização dos mapas bibliométricos. O estudo focou-se na distribuição geográfica dos artigos mais citados, jornais e documentos mais citados. Apenas um mapa bibliográfico foi criado, sem qualquer referência à exploração de como foi elaborado. A discussão sobre o estado das aplicações de IA na medicina foi baseada apenas em uma pequena lista de artigos mais citados, sem indicação dos critérios para sua seleção.

Jimma [17] também realizou uma análise bibliométrica da IA na medicina, utilizando o VOSviewer para a visualização dos resultados. A análise foi semelhante aos trabalhos de Alhashmi *et al.* [14] e Andrade-Arenas *et al.* [16], focando-se nos países, fontes e documentos mais citados. A discussão foi realizada com base em apenas um mapa, observando as palavras-chave com mais ocorrências, que incluíam termos genéricos como “*machine learning*” e “*deep learning*”. Os dados foram extraídos da base de dados Scopus, excluindo artigos que não estavam em inglês, literatura cinzenta, documentação de conferências e capítulos de livros.

2.4 Aplicações da IA na medicina

A inteligência artificial está a revolucionar a área da saúde, com aplicações promissoras no diagnóstico médico. A sua capacidade de analisar grandes conjuntos de dados e identificar padrões complexos torna-a uma ferramenta poderosa para auxiliar na deteção precoce e precisa de doenças. A IA está a ser utilizada em diversas áreas do diagnóstico médico. A seguir, são apresentados alguns exemplos:

2.4.1 Análise de imagens

A IA pode identificar com precisão o cancro de mama em mamografias, com uma sensibilidade comparável à dos radiologistas experientes [18]. Além disso, pode detetar pneumonia em radiografias de tórax com alta precisão, ajudando a reduzir o tempo de diagnóstico e melhorar o tratamento dos pacientes [19]. A IA também é capaz de segmentar automaticamente órgãos em imagens médicas, como tomografias e ressonâncias magnéticas, o que pode ajudar os médicos a diagnosticar doenças com mais precisão e rapidez.

2.4.2 Deteção de doenças

Nesta área a IA destaca-se pela:

- **Previsão de ataque cardíaco:** Análise de dados de pacientes, como histórico médico, resultados de exames e estilo de vida, para identificar pacientes com risco de ataque cardíaco. Isto permite que os médicos intervenham precocemente e previnam o desenvolvimento da doença [20].
- **Identificação de pacientes com risco de sepse:** Análise de dados em tempo real para identificar pacientes com risco de desenvolver sepse, uma infeção grave que pode ser fatal. Isso permite que os médicos intervenham rapidamente e aumentem as chances de sobrevivência dos pacientes.

- **Deteção de doenças genéticas:** A IA pode analisar o genoma de um paciente para identificar mutações genéticas associadas a doenças, como cancro e doenças neurodegenerativas. Isso permite que os médicos diagnostiquem doenças em seus estágios iniciais e ofereçam tratamento preventivo aos pacientes [21].

2.4.3 Chatbots médicos

Um exemplo recente é o assistente virtual para pacientes com diabetes, que auxilia na gestão da doença. O chatbot pode fornecer informações sobre diabetes, responder perguntas dos pacientes e ajudar a monitorar os níveis de glicose no sangue [22]. Os chatbots também foram usados para triar pacientes com sintomas de COVID-19, fazendo perguntas sobre os sintomas e fornecendo orientações sobre como procurar atendimento médico [23].

2.4.4 Cirurgia robótica

A IA oferece aos cirurgiões ferramentas avançadas que aumentam a precisão, a segurança e a eficiência dos procedimentos, proporcionando melhores resultados para os pacientes. Pode ser utilizada para auxiliar os cirurgiões em diversas etapas da cirurgia robótica, incluindo:

- **Planeamento pré-operatório:** Analisar imagens médicas para criar modelos 3D detalhados da anatomia do paciente, permitindo que os cirurgiões planejem o procedimento com mais precisão.
- **Navegação intraoperatória:** Fornecer aos cirurgiões orientação em tempo real durante a cirurgia, ajudando-os a identificar estruturas anatómicas importantes e evitar erros.
- **Execução de tarefas:** Realizar tarefas repetitivas e complexas com maior precisão do que os humanos, como suturas e dissecções.

Esta tecnologia oferece diversos benefícios para os pacientes, como maior precisão nos procedimentos, menor invasividade, o que significa menos dor e tempo de recuperação, e até mesmo a possibilidade de realizar cirurgias complexas que antes eram impossíveis. Alguns exemplos atuais de aplicações robóticas na cirurgia incluem [24]:

- **Cirurgia cardíaca:** Realização de cirurgias cardíacas complexas, como a revascularização miocárdica.
- **Cirurgia oncológica:** Realização de cirurgias oncológicas complexas, como o tratamento de um tumor retal.

- **Cirurgia urológica:** Auxílio na realização de cirurgias urológicas complexas.

Apesar dos benefícios da IA na cirurgia robótica, existem alguns desafios que precisam ser superados, como o alto custo da tecnologia, a necessidade de treinamento para os cirurgiões e a regulamentação para garantir a segurança e a ética da sua utilização. No entanto, o potencial da IA para melhorar a qualidade do tratamento médico para os pacientes é enorme e é provável que esta tecnologia continue a desempenhar um papel cada vez mais importante no futuro da medicina.

2.4.5 Descoberta de novos tratamentos

A IA também pode ajudar na pesquisa de novos medicamentos, acelerando o processo de descoberta e desenvolvimento de tratamentos inovadores. Pode identificar novos alvos terapêuticos, utilizando grandes volumes de dados de pacientes, incluindo imagens médicas e resultados de laboratório. A IA otimiza o processo de desenvolvimento de medicamentos modelando a interação entre moléculas, o que pode auxiliar na seleção de candidatos a medicamentos com maior potencial de sucesso. Além disso, reduz o tempo e o custo do desenvolvimento de medicamentos ao automatizar tarefas repetitivas e complexas. Algumas das aplicações incluem [25]:

- **Descoberta de novos antibióticos:** Identificar novos compostos com potencial para combater bactérias resistentes a antibióticos.
- **Desenvolvimento de terapias personalizadas para cancro:** Identificar mutações genéticas associadas ao cancro e desenvolver terapias personalizadas para pacientes com essas mutações.
- **Desenvolvimento de medicamentos para doenças raras:** Descoberta de novos alvos terapêuticos para doenças raras e desenvolvimento de medicamentos para essas doenças.

2.4.6 Desafios da utilização da IA na medicina

A aplicação da inteligência artificial (IA) na detecção de doenças enfrenta vários desafios técnicos e éticos. Um dos principais desafios é a qualidade e a quantidade de dados necessários para treinar os modelos de IA. Dados de saúde são frequentemente fragmentados, incompletos ou de baixa qualidade, o que pode afetar a precisão e a confiabilidade dos algoritmos de IA. Além disso, há preocupações com a privacidade e a segurança dos dados dos pacientes. A coleta e o uso de dados de saúde exigem a implementação de rigorosos padrões de segurança para

proteger a informação sensível e garantir a conformidade com as regulamentações de proteção de dados, como o Regulamento Geral sobre a Proteção de Dados (GDPR) na Europa.

Nos *chatbots* médicos, desafios adicionais incluem a capacidade de entender e responder adequadamente às perguntas dos pacientes. *Chatbots* precisam ser capazes de interpretar corretamente uma ampla variedade de sintomas e contextos, o que requer algoritmos de processamento de linguagem natural (NLP) altamente avançados. A falta de nuances e a incapacidade de lidar com situações complexas ou emergências médicas são limitações significativas. Além disso, há o risco de dependência excessiva desses sistemas, o que pode levar a diagnósticos imprecisos se os pacientes não forem devidamente encaminhados para cuidados humanos quando necessário.

Na cirurgia robótica, os desafios incluem o alto custo dos sistemas de IA e robótica, que pode limitar o acesso a essas tecnologias avançadas em muitas instituições de saúde. Além disso, a integração de IA nos procedimentos cirúrgicos requer um treinamento extensivo dos cirurgiões para operar as máquinas e interpretar os dados fornecidos. A IA também precisa ser precisa e confiável para evitar erros durante os procedimentos, o que exige desenvolvimento contínuo e rigorosos testes.

Na pesquisa de medicamentos e novos tratamentos, a IA enfrenta desafios relacionados à validação e aceitação regulatória. Os modelos de IA devem demonstrar eficácia e segurança em testes clínicos rigorosos antes de serem adotados. Além disso, a complexidade biológica e a variabilidade genética entre indivíduos podem dificultar a generalização dos resultados obtidos pelos algoritmos de IA. Também há necessidade de garantir a proteção da privacidade dos dados dos pacientes e a mitigação de vieses nos algoritmos.

No entanto, o potencial da IA para melhorar a qualidade do tratamento médico é enorme e é provável que continue a desempenhar um papel cada vez mais importante no futuro da medicina.

3 Abordagem

Este capítulo descreve detalhadamente a metodologia e os componentes utilizados na nossa solução, focando-se na pesquisa bibliométrica das aplicações de IA na medicina. A primeira etapa consistiu na definição das palavras-chave e das limitações da pesquisa, restringindo-a aos artigos científicos publicados entre 2020 e 2024 e escritos em inglês. Esta decisão foi baseada na predominância da língua inglesa na literatura científica e na capacidade do VOSviewer de processar apenas artigos neste idioma.

Para a extração de dados, utilizou-se a API OpenAlex, uma ferramenta gratuita integrada no VOSviewer, que permitiu coletar dados anuais do repositório PubMed. Os dados extraídos incluíram títulos, resumos, autores, palavras-chave, entre outros atributos essenciais para a análise bibliométrica. A seguir, procedeu-se ao processamento e análise dos dados, criando mapas bibliométricos baseados em texto e na coocorrência de conceitos (COC), com o objetivo de identificar padrões e tendências nas aplicações de IA na medicina.

Finalmente, os resultados obtidos foram visualizados utilizando as capacidades avançadas do VOSviewer, incluindo visualizações de rede, sobreposição e densidade. Estas visualizações permitiram uma análise detalhada das relações entre os diferentes tópicos e subáreas de pesquisa, proporcionando insights valiosos sobre as tendências emergentes e as lacunas existentes na bibliografia das aplicações de IA na medicina. No próximo capítulo, discutiremos os resultados em pormenor, avaliando a eficácia da metodologia adotada e os principais achados desta pesquisa.

3.1 Definição de pesquisa

No capítulo anterior, discutimos a importância de definir palavras-chave específicas e delimitar o escopo da nossa pesquisa bibliométrica. Dado o crescimento exponencial das aplicações da IA nos últimos anos, decidimos focar nossa análise em artigos científicos publicados entre 2020 e 2024, exclusivamente em língua inglesa. Essa decisão baseia-se no fato de que a maioria dos artigos científicos atualmente é escrita em inglês, e nossa ferramenta bibliométrica, o VOSviewer, está preparada para processar apenas artigos neste idioma.

O VOSviewer permite analisar diversos tipos de dados bibliográficos, incluindo coautoria, coocorrência de palavras-chave, citações, acoplamento bibliográfico e co-citação, além de dados textuais. Neste estudo, dada a relevância das aplicações de IA, focaremos

especificamente na análise de conteúdo dos artigos acadêmicos. Portanto, restringimos nossa pesquisa aos dados textuais e à coocorrência entre conceitos (COC).

Para garantir que nossa pesquisa se concentre exclusivamente no campo da medicina, utilizamos o PubMed, um dos maiores repositórios nas áreas de biomedicina e ciências da vida [26]. Este repositório contém documentos exclusivamente relacionados à medicina e ciências da vida, o que nos permite uma análise mais precisa e relevante. As palavras-chave definidas para nossa pesquisa são:

- AI
- Artificial Intelligence

Esta abordagem permitirá identificar padrões e tendências nas aplicações de IA na medicina, fornecendo insights valiosos para futuras pesquisas e desenvolvimento na área.

3.2 Extração de dados

Para a extração de dados usou-se uma ferramenta já embutida no VOSviewer, uma *application programming interface* (API) de uso gratuito e livre denominada *OpenAlex*.

A (Equação 1) traduz de forma lógica a primeira pesquisa efetuada na API:

$$\begin{aligned} Fulltext &= ("AI" \parallel "Artificial Intelligence") \\ &\&\& language = "English" \&\& year = 2020 \&\& \\ repository &= "PubMed" \parallel "PubMed Central" \parallel "Europe PMC (PubMed Central)" \end{aligned} \quad (Equação 1)$$

3.3 Processamento, análise e visualização de Dados

3.3.1 Dados de texto

Numa primeira abordagem começou-se por criar um mapa baseado em dados de texto, demonstrado na Figura 5, para tratamento dos mesmos e análise de quais parâmetros levariam a melhores resultados.

Devido à limitação da API que permite um máximo de 50.000 artigos por extração [27], optou-se por extrair os dados ano a ano. Esta abordagem não apenas evita ultrapassar o limite, mas também facilita a análise das tendências ao longo do tempo. Utilizando o widget do VOSviewer, iniciamos a análise pelos títulos e resumos dos artigos.




Figura 5 - Tipo de dados bibliométricos

Conforme ilustrado na Figura 6, utilizamos as funções nativas do VOSviewer para o tratamento de dados, removendo afirmações de direitos autorais e ignorando termos comuns que não acrescentam significado relevante à pesquisa, tais como: *aim, background, conclusion, design, discussion, finding, introduction, material, method, objective, purpose, result, setting, summary* [28]. A seguir, foi necessário escolher entre dois métodos de contagem: binário ou completo. No modo completo, todas as ocorrências dos termos são contadas, enquanto no modo binário conta-se apenas se o termo aparece ou não no documento [29].

Para esta pesquisa, optou-se pelo método binário, conforme mostrado na Figura 7. Este método foi escolhido porque o mais importante era observar a prevalência de cada tema na totalidade dos documentos analisados, e não a frequência de ocorrência dentro de um único documento. Esta abordagem permite identificar de maneira mais eficiente as tendências gerais e a importância relativa dos diferentes tópicos ao longo do tempo.




Figura 6 - Dados escolhidos para analisar na pesquisa




Figura 7 - Widget métodos de contagem

Após a escolha do método de contagem, procedeu-se à seleção do mínimo de ocorrências de um termo (MOT) e da percentagem de termos mais relevantes (PTMR). Para simplificação, referir-nos-emos a estas métricas como MOT e PTMR, respectivamente.

A seleção dos termos mais relevantes é feita através de uma técnica inovadora para selecionar as frases substantivas mais relevantes. Essencialmente, esta técnica determina a distribuição de coocorrências (de segunda ordem) para cada frase substantiva em relação a todas as frases substantivas. Esta distribuição é comparada com a distribuição global de coocorrências das frases substantivas. Quanto maior a diferença entre as duas distribuições, medida através da distância de Kullback-Leibler [30], maior a relevância de uma frase substantiva. Intuitivamente, frases substantivas com baixa relevância ou com significado geral, como “papel”, “resultado interessante” e “novo método”, apresentam uma distribuição de coocorrências mais uniforme. Em contrapartida, frases substantivas com maior relevância ou com significado específico, como “visualização”, “mineração de texto” e “processamento de linguagem natural”, têm uma distribuição de coocorrências significativamente tendenciosa [29].

Para alcançar os parâmetros que produzissem os melhores resultados visuais, realizou-se uma análise sistemática dos mesmos. Inicialmente, foram selecionados os valores padrão do VOSviewer: número mínimo de ocorrências de 10, abrangendo 8.029 termos (Figura 9), e percentagem de termos mais relevantes de 60%, resultando na seleção de 4.817 termos (Figura 8). Esta abordagem garantiu uma visualização clara e eficaz das tendências e padrões presentes nos dados analisados.




Figura 9 - Número mínimo de

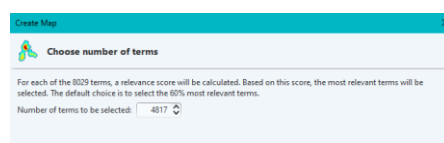


Figura 8 - Percentagem de termos mais relevantes

Por fim, utilizou-se o algoritmo do software VOSviewer para criar e visualizar a rede bibliométrica demonstrada na Figura 10.




Figura 10 - Dados PubMed 2020 MOT 10 PTMR 60%

Com base nos resultados da nossa pesquisa, ilustrados na Figura 10, concluímos que o mapa apresentava os seguintes problemas:

I. Excesso de termos representados: O elevado número de termos (os círculos representam o número de ocorrências de cada termo na Figura 10) inviabiliza a análise humana deste gráfico, tornando muito difícil tirar conclusões relevantes em relação ao problema desta dissertação.

II. Termos relacionados com IA e tecnologia: Nosso objetivo é analisar as tendências dos campos mais investigados na área da saúde com aplicações de IA, e não propriamente as tecnologias aplicadas. A inclusão de muitos termos técnicos e tecnológicos desvia o foco da pesquisa.

III. Termos irrelevantes: Houve uma representação elevada de palavras genéricas, como "pathway", "experiment", "property", que não acrescentam valor significativo à nossa pesquisa. Essas palavras genéricas dificultam a identificação de tendências e insights específicos.

IV. Elevado tempo de criação dos mapas: Para efeitos de benchmarking, utilizando um computador com os seguintes requisitos: processador AMD Ryzen 7 3800XT 8-Core Processor 3.90 GHz, memória RAM de 32 GB e GPU NVIDIA GeForce GTX

Levando em consideração os quatro problemas mencionados anteriormente, realizamos uma experimentação com a alteração de parâmetros para otimizar o resultado visual obtido. Mantendo a pesquisa indicada na Equação 1 e utilizando o método de contagem binário, ajustamos o mínimo de ocorrências de um termo (MOT) para 50, mantendo a percentagem de termos mais relevantes (PTMR) em 60%. Com essa alteração, abrangemos 926 termos e obtivemos o resultado ilustrado na Figura 11.



31

comparar o número de termos representados no gráfico (926), continuamos nossa pesquisa utilizando os mesmos parâmetros da pesquisa anterior, mas mantendo o MOT em 10 e alterando o PTMR para 10%. Com esses parâmetros, 803 termos obedeciam a estas condições, o que é positivo, visto que este número é similar à nossa base de comparação (926 termos abrangidos), ajudando a resolver o problema I.







Figura 12 - Dados PubMed 2020 MOT 10 PTMR 10%

Figura 13, Figura 14, e Figura 15 demonstram mais detalhadamente alguns dos clusters da nossa pesquisa. No VOSviewer, cada cluster pode ser visto como um tópico, calculado usando uma técnica semelhante à discutida no artigo de Zhu, Takigawa, Zeng, & Mamitsuka (2009) [31].

Apesar de a criação do mapa bibliométrico com os novos parâmetros apresentar um resultado melhor em comparação com os mapas anteriores, é necessário verificar se a restrição desses parâmetros, embora melhore a clareza visual, não está a eliminar informação valiosa da nossa pesquisa. Avaliar a presença de informações essenciais é crucial para garantir que os dados mais relevantes não sejam omitidos durante o processo de filtragem e análise.



Procedemos, portanto, à criação de um novo mapa utilizando a lógica representada na Equação 1, com contagem binária, mas restringindo ligeiramente menos os parâmetros. Utilizamos um MOT de 25 e um PTMR de 30%, abrangendo 918 termos, mantendo-se abaixo do número inicial de benchmarking para termos representados no gráfico. Esta abordagem permitiu equilibrar a quantidade de informações visuais com a relevância dos termos, garantindo que não ultrapassássemos o limite inicial de termos representados, enquanto melhoramos a precisão e a utilidade dos dados apresentados.




Figura 16 - Dados PubMed 2020 MOT 25 PTMR 30%

Após a análise do gráfico da Figura 16, constatou-se que a folga nos parâmetros não acrescentou valor significativo à nossa pesquisa e voltou a introduzir os problemas II (**Termos relacionados com IA e tecnologia**) e III (**Termos irrelevantes**) nos resultados. Embora o problema IV (Elevado tempo de criação dos mapas) persista, não conseguimos eliminá-lo na criação de mapas baseados em dados textuais, a menos que reduzamos drasticamente o volume de dados analisados, o que comprometeria a qualidade da pesquisa bibliométrica. Em seguida, verificamos se os parâmetros ótimos identificados para a pesquisa do ano de 2020 (MOT de 10 e PTMR igual ou inferior a 10%) também produzem bons resultados para os anos subsequentes.

3.3.1.1 Aplicação dos Parâmetros Ótimos

Uma vez obtidos os parâmetros ótimos, conduzimos a pesquisa utilizando esses mesmos parâmetros para os anos subsequentes.

$Fulltext = ("AI" \parallel "Artificial Intelligence")$
 $\&\& \text{ language} = "English" \&\& \text{ year} = 2021 \&\&$
 $\text{repository} = "PubMed" \parallel "PubMed Central" \parallel "Europe PMC (PubMed Central)"$ (Equação 2)

$Fulltext = ("AI" \parallel "Artificial Intelligence")$
 $\&\& \text{ language} = "English" \&\& \text{ year} = 2022 \&\&$
 $\text{repository} = "PubMed" \parallel "PubMed Central" \parallel "Europe PMC (PubMed Central)"$ (Equação 3)

$Fulltext = ("AI" \parallel "Artificial Intelligence")$
 $\&\& \text{ language} = "English" \&\& \text{ year} = 2023 \&\&$
 $\text{repository} = "PubMed" \parallel "PubMed Central" \parallel "Europe PMC (PubMed Central)"$ (Equação 4)

$Fulltext = ("AI" \parallel "Artificial Intelligence")$
 $\&\& \text{ language} = "English" \&\& \text{ year} = 2024 \&\&$
 $\text{repository} = "PubMed" \parallel "PubMed Central" \parallel "Europe PMC (PubMed Central)"$ (Equação 5)

As equações: (Equação 2), (Equação 3), (Equação 4) e (Equação 5) demonstram os parâmetros utilizados para filtrar os resultados da API. Os resultados obtidos são apresentados a seguir:




Figura 17 - Dados PubMed 2021 MOT 10 PTMR 10%




Figura 18 - Dados PubMed 2022 MOT 10 PTMR 10%




Figura 19 - Dados PubMed 2023 MOT 10 PTMR 5.7%




Figura 20 - Dados PubMed 2024 MOT 10 PTMR 10%

Para a análise do ano de 2023, cujo resultado está na Figura 19, reduziu-se o PTMR para 5,7%, devido ao elevado volume de dados nesse ano. Com os parâmetros ótimos iniciais, o número de termos abrangidos ultrapassava 1000, reintroduzindo o problema I (**Excesso de termos representados**). Após a criação de todos os mapas, verificou-se que os parâmetros ótimos não apresentavam mais a mesma qualidade de resultados.

Especificamente, reintroduziram-se os problemas II (**Termos relacionados com IA e tecnologia**) e III (**Termos irrelevantes**). Por exemplo, na Figura 17, o cluster verde apresenta termos como "svm" e "cnn model", e na Figura 18, os clusters vermelho e amarelo escuro incluem maioritariamente termos relacionados com IA e matemática. Além disso, na Figura 20, o cluster azul-claro contém apenas palavras genéricas que não contribuem para nossa pesquisa, como "friend", "colleague" e "box" (problema III – **Termos irrelevantes**). O problema IV (**Elevado tempo de criação dos mapas**) também se manteve.

Como um dos objetivos desta dissertação é criar uma metodologia eficaz para realizar uma pesquisa bibliométrica, não fazia sentido descobrir os parâmetros ótimos para cada ano individualmente. Outra opção seria realizar um tratamento de dados adicional às funcionalidades do VOSviewer para obter bons resultados para todos os anos. No entanto, a criação desse tipo de mapas exige bastante tempo e recursos computacionais. A adição de um processo externo de tratamento de dados poderia acrescentar ainda mais complexidade e demora à nossa pesquisa. Por isso, decidiu-se seguir outra abordagem: analisar a coocorrência de conceitos.

3.3.2 Coocorrência de conceitos

Inicialmente, selecionou-se a criação de um mapa utilizando dados bibliográficos (Figura 21). Em seguida, escolheu-se o método de abordagem pretendido, neste caso, a coocorrência de conceitos (Figura 22) e o método de contagem. Nesta abordagem, os métodos de contagem são semelhantes aos utilizados na análise de dados textuais, porém possuem algumas diferenças significativas.

Existem dois métodos de contagem: contagem completa e contagem fracionária. A seguir, exploramos as diferenças entre eles. Por exemplo, considere uma rede de coautoria construída com quatro autores (A1, A2, A3 e A4) e três documentos (D1, D2 e D3). O documento D1 é de autoria de A1, A2 e A3; o documento D2 é de autoria de A1 e A3; e o documento D3 é de autoria de A2 e A4, conforme demonstrado na Figura 23.

A única diferença entre as duas redes é a força das ligações. Na rede de contagem completa, a força do vínculo entre dois autores é determinada pelo número de documentos em coautoria. Por exemplo, A1 e A3 são coautores de dois documentos (D1 e D2), dando ao seu link uma força de 2. Outros links, onde os autores são coautores de um documento, têm uma força de 1.

Na contagem fracionária, a força de um link de coautoria é ajustada pelo número total de autores de cada documento coautor. Se um autor foi coautor de um documento com "n" outros autores, cada ligação tem uma força de $1/n$. Esta abordagem reduz a influência de documentos com muitos autores. Neste tipo de contagem, a força total dos links de coautoria para um documento é igual a 1, ao contrário da contagem completa, onde cada link tem uma força de 1, independentemente do número de autores [28].




Figura 21 - Mapa baseado em dados bibliográficos




Figura 22 - Tipo de análise e método de contagem




Figura 23 - Links entre autores e documentos. Imagem de [28]




Figura 24 - Rede de coautoria usado contagem completa, na esquerda, ou contagem fracionária, na direita. Imagem de [28]

Como o exemplo fornecido pelos autores do software VOSviewer no manual [28] também se aplica à coocorrência de conceitos, optou-se pelo método de contagem completa. Esta escolha deve-se ao nosso interesse em analisar a prevalência de cada conceito no conjunto total de documentos, sem "penalizar" os conceitos que aparecem em conjunto com outros no mesmo documento.

Seguindo uma lógica semelhante à abordagem anterior e utilizando a pesquisa definida pela Equação 1, começamos por definir os parâmetros MOT e PTMR, usando os valores padrão do software, que são 5 e 28%, respectivamente, abrangendo um total de 1000 conceitos. O resultado, ilustrado na Figura 25, demonstra os resultados da coocorrência de conceitos (COC). Numa primeira análise, este resultado apresenta os mesmos problemas iniciais da abordagem anterior, exceto pelo **problema IV**, que foi completamente eliminado. Usando o mesmo computador, a criação deste mapa demorou apenas alguns segundos.

Dado que na abordagem anterior a otimização dos parâmetros MOT e PTMR não contribuiu para bons resultados em todos os anos de pesquisa, e considerando que a rapidez da criação do mapa com a abordagem COC permite experimentar várias análises e conjuntos de dados mais rapidamente, decidiu-se experimentar outra técnica: a eliminação de clusters (EC).




Figura 25 - Dados PubMed 2020 COC Original

3.3.2.1 Eliminação de clusters (EC)

À primeira vista, apenas o cluster vermelho, que inclui palavras relacionadas com IA e engenharia, e o cluster azul-escuro, que apresenta conceitos genéricos e termos diversos, contêm conceitos que não têm valor científico para a nossa pesquisa. Como o ruído estava concentrado em apenas dois clusters, surgiu a necessidade de criar um algoritmo que eliminasse esses clusters para verificar se isso resultaria em um melhor resultado. A Figura 26 resume o funcionamento desta técnica, e o **Algoritmo 1** mostra como foi implementada.




Figura 26 - Diagrama da técnica de eliminação de clusters

Algoritmo 1 Eliminação de clusters

Parameterize FILE_PATH

Open FILE_NAME in read mode with utf-8 encoding

 Read the file contents into file_data

Decode file_data to handle utf-8-sig encoding

Parse decoded_data into json_data

Open CLUSTER_FILE in read mode with utf-8 encoding

 Read the file contents into cluster_data

Decode cluster_data to handle utf-8-sig encoding

Parse cluster_decoded_data into cluster_json_data

Initialize labels list

Define clusters_to_remove

For item in cluster_json_data["network"]["items"]:

If item's cluster in clusters_to_remove :

 Convert item["label"] to lowercase and remove parentheses

 Append the processed label to labels list

endIf

endFor

Define common_words list with values (e.g., "medicine")

Append each word from common_words to labels list

For result in json_data["results"]:

 Filter result["concepts"] to exclude concepts whose display names match any label in labels list

endFor

Write the modified json_data to the output file

Após observar o mapa da Figura 25, definiram-se os clusters a eliminar (vermelho e azul-escuro). Utilizando o *widget* "itens" auxiliar do VOSviewer, identificou-se o ID de cada cluster e criou-se uma lista de conceitos englobados nos mesmos. Como havia uma exceção à nossa regra — a palavra "medicina", que apresenta um significado demasiado global para a nossa pesquisa e aparecia em outros clusters — optou-se por adicioná-la manualmente à lista.

Com base nesta lista, eliminamos os conceitos dos dados originais e geramos um novo mapa bibliométrico.






Figura 27 - Dados PubMed 2020 COC EC

A Figura 27 demonstra que, com a nossa técnica, conseguimos eliminar os problemas observados na criação do mapa da Figura 25, especificamente a existência de termos genéricos e relacionados com IA. Além disso, mantivemos a curta duração na criação do mapa, garantindo eficiência no processamento dos dados.

3.3.2.2 Aplicação da técnica EC para os restantes anos

Como o resultado da Figura 27 foi bastante satisfatório, procedeu-se à repetição desta técnica para os restantes anos abordados na nossa pesquisa. Segue-se, nas Figuras 28 a 35, a ilustração dos mesmos e também a ilustração dos mapas COC Original, ou seja, sem a técnica de remoção de clusters, para efeito de comparação.






Figura 32 - Dados PubMed 2023 COC Original






Figura 33 - Dados PubMed 2023 COC EC



As figuras dos mapas criados com a técnica de Eliminação de Clusters (Figura 29, Figura 31, Figura 33 e Figura 35) mostram que, em todos os anos analisados, obtivemos a mesma qualidade de resultados comparativamente ao nosso ponto de partida, a Figura 27. Não observamos excesso de conceitos representados, nem termos genéricos ou relacionados com IA, e a criação desses mapas foi bastante rápida.

Além disso, em todos os anos de pesquisa, foram identificadas melhorias visuais em relação ao mapa original (Figura 28, Figura 30, Figura 32 e Figura 34) do respectivo ano. Os mapas originais de diferentes anos eram bastante semelhantes entre si, o que impossibilitava a descoberta de qualquer tipo de tendência. No capítulo seguinte, procederemos a uma análise detalhada desses resultados.

4 Análise de Resultados

Neste capítulo, analisaremos os resultados apresentados no capítulo anterior com mais pormenor e rigor, especificamente os mapas da Figura 27, Figura 29, Figura 31, Figura 33 e Figura 35. O objetivo é identificar os tópicos mais abordados e eventuais lacunas de pesquisa no domínio das aplicações de IA na medicina, atendendo aos problemas levantados nesta dissertação.

4.1 Análise dos Resultados de 2020

Começando pelo ano de 2020 (Figura 27), os termos de maior relevância incluem "medicina interna", indicando um foco significativo nesta área. Outros tópicos destacados são "patologias e doenças", sugerindo um grande interesse nas causas e tratamento de doenças; "psicologia e psiquiatria", refletindo a importância da saúde mental durante a pandemia; e "biologia, ecologia, botânica, bioquímica e microbiologia", mostrando a interligação da medicina com outras ciências. Os termos "pandemia", "virologia" e "covid-19" evidenciam a rápida resposta da comunidade científica à pandemia global. A pesquisa oncológica e os estudos sobre genética e células também tiveram destaque, assim como temas relacionados com animais e reprodução humana.

4.2 Análise dos Resultados de 2021

Em 2021 (Figura 29), o foco na medicina interna continuou predominante, com subáreas como cardiologia e optometria ganhando relevância. A pandemia ainda influenciou significativamente as pesquisas, com aumentos notáveis em estudos sobre covid-19, virologia e vacinação. No entanto, a saúde mental teve menos destaque comparado a 2020. Os estudos sobre cancro e diversas ciências (biologia, ecologia, botânica, bioquímica) mantiveram-se relevantes, com a química ganhando mais importância. Os estudos sobre IA relacionados com animais e gravidez humana também continuaram.

4.3 Análise dos Resultados de 2022

Em 2022 (Figura 31), o cenário permaneceu semelhante aos anos anteriores. A medicina interna e tópicos relacionados continuaram a ter grande destaque, assim como as pesquisas sobre doenças e patologias. A pandemia e covid-19 ainda foram temas de interesse, mas a saúde

mental voltou a ganhar relevância. A pesquisa oncológica e genética continuou forte, e os estudos sobre biologia e química aumentaram. A relevância dos estudos sobre gravidez e animais manteve-se constante.

4.4 Análise dos Resultados de 2023

Em 2023 (Figura 33), observou-se uma diminuição significativa nos estudos sobre covid-19, refletindo o fim da pandemia. No entanto, a genética também viu uma redução nos estudos. De forma geral, o cenário não mudou drasticamente, com a medicina interna, doenças, patologias, e ciências diversas mantendo-se relevantes.

4.5 Análise dos Resultados de 2024

No ano presente, 2024 (Figura 35), o cenário da literatura científica sobre aplicações de IA na medicina permaneceu semelhante ao de 2023. Os tópicos de destaque continuaram os mesmos, refletindo uma estabilidade nas áreas de interesse da pesquisa acadêmica.

4.6 Considerações Gerais

De uma perspectiva geral, concluímos que o cenário dos artigos acadêmicos sobre aplicações de IA na saúde não mudou significativamente nos últimos quatro anos. Observamos um grande volume de estudos sobre covid-19 durante a pandemia, além de uma notável integração interdisciplinar entre áreas como biologia, genética e bioinformática com a medicina. O número de artigos sobre IA na medicina cresceu substancialmente, de 13.780 documentos em 2020 para quase três vezes mais em 2023.

O Dr. Peter Attia, em seu bestseller "Outlive", definiu quatro principais causas de morte natural: doenças cardíacas, cancro, doenças neurodegenerativas e diabetes tipo 2 [32]. Nossa pesquisa confirmou que cardiologia e oncologia foram tópicos amplamente estudados. Embora a neurologia também tenha sido abordada, teve menor prevalência. A aplicação de IA na diabetes foi pouco explorada, representando uma lacuna significativa. Estudos sobre obesidade e impactos ambientais dos cuidados médicos também foram insuficientes. Em 2023 e 2024, houve uma diminuição nos estudos relacionados com virologia, o que pode ser arriscado considerando a probabilidade de futuras pandemias [33].

Finalmente, apesar de existirem lacunas não abordadas, nomeadamente em campos específicos da medicina, o tempo e os recursos necessários para uma análise exaustiva estão

além do escopo deste trabalho. No entanto, os mapas criados serão disponibilizados publicamente, permitindo que equipes de investigação avaliem a prevalência de suas pesquisas no contexto global da literatura acadêmica sobre IA na medicina.

5 Conclusão

No início deste trabalho, definiram-se duas questões principais: determinar quais subáreas da saúde são mais abordadas no contexto das aplicações de Inteligência Artificial (IA) e averiguar se existem nichos inexplorados onde futuros trabalhos científicos valiosos possam ser conduzidos. Verificamos que, nos últimos anos, o estudo das aplicações de IA na medicina não mudou significativamente, e as subáreas mais abordadas foram medicina interna, patologias e doenças, diversas ciências como biologia, ecologia, botânica, bioquímica e microbiologia, pandemia, virologia e covid-19, devido ao contexto mundial vivido nestes anos. Outro tópico amplamente investigado foi a oncologia, com numerosos artigos publicados sobre cânceres específicos. Tópicos relacionados com genética e células também apareceram frequentemente.

Além disso, identificamos algumas lacunas na investigação académica, tais como diabetes, obesidade e os impactos ambientais dos cuidados médicos. Essas áreas representam oportunidades para futuras pesquisas, considerando sua importância e relevância para a saúde global.

5.1 Limitações do Trabalho

Este trabalho apresenta algumas limitações. Primeiramente, utilizamos apenas artigos do repositório PubMed, o que pode ter limitado o escopo da nossa análise. Além disso, só conseguimos criar mapas com um número máximo de 50.000 documentos, o que pode ter restringido a abrangência dos dados analisados. Não foi possível determinar todas as lacunas existentes neste campo, e não exploramos quais aplicações específicas de IA foram aplicadas em cada subtópico.

5.2 Considerações Finais

Comparado com a literatura atual sobre pesquisas bibliométricas na área das aplicações de IA na medicina, este estudo explorou detalhadamente a ferramenta VOSviewer. Focamos numa análise de conceitos, ano a ano, permitindo identificar melhor as tendências neste domínio nos últimos anos. Qualitativamente, apresentamos melhores resultados comparados com a revisão de literatura apresentada no capítulo 2, eliminando termos genéricos dos mapas bibliométricos que não acrescentavam valor aos resultados no contexto da nossa pesquisa.

5.3 Trabalho Futuro

Ao longo deste trabalho, procuramos criar um método genérico que permita obter melhores resultados para diferentes pesquisas, sem a necessidade de uma limpeza de dados específica para cada caso. Por isso, disponibilizamos o código de eliminação de clusters no seguinte repositório: <https://github.com/andrepimparel/Dissertation/tree/main> e encorajamos o uso deste processo em pesquisas bibliométricas de outros domínios. Além disso, disponibilizamos os mapas utilizados como input na criação dos mapas bibliométricos do VOSviewer e imagens deste trabalho no link abaixo para quem desejar realizar análises mais aprofundadas do estado da literatura científica das aplicações de IA na medicina:

https://drive.google.com/drive/folders/19R9L81hOiVTFmWnxH_J54ePJTL4p35gs?usp=sharing

Finalmente, desejamos estudar ainda mais maneiras de otimizar estas redes e criar processos embutidos e automáticos para que o utilizador final possa utilizar o procedimento descrito nesta dissertação de uma maneira mais simples, juntamente com o VOSviewer.

Referências Bibliográficas

- [1] D. J. D. S. Price, “Science Vol.149,” *Networks of Scientific Papers*, pp. 510-515, 30 julho 1965.
- [2] L. Waltman and N. J. van Eck, “Visualizing bibliometric networks,” in *Measuring scholarly impact: Methods and practice*, Springer International Publishing, 2014, pp. 285-320.
- [3] A. Perianes-Rodriguez, L. Waltman and N. J. van Eck, “Constructing bibliometric networks,” *A comparison between full and fractional counting*, 24 outubro 2016.
- [4] E. Commission, “European Commission,” 2022 12 6. [Online]. Available: https://ec.europa.eu/commission/presscorner/detail/en/IP_22_7404. [Accessed 18 setembro 2023].
- [5] R. Tomaszewski1, “Scientometrics,” *Visibility, impact, and applications of bibliometric software*, 1 julho 2023.
- [6] R. N. M. D. S. Kobashi, *BIBLIOMETRICS, SCIENTOMETRICS, INFORMETRICS: CONCEPTS AND APPLICATIONS.*, 2009.
- [7] G. T. K. Tchuente Foguem, “Artificial intelligence applied in pulmonary hypertension: a bibliometric analysis,” in *AI Ethics* 3, 2023, p. 1063–1093.
- [8] J. M. H. Bonilla, “Em 95% dos artigos científicos, inglês cria ‘ditadura da língua’. Apenas 1% está em português e espanhol,” *EL PAÍS*, 2021.
- [9] “VOSviewer,” [Online]. Available: <https://www.vosviewer.com/>. [Accessed 1 janeiro 2024].
- [10] A. S.-O. o. t. U. o. N. F. II, “Main software to analyze bibliometric data,” 2023 fevereiro 22. [Online]. Available: <https://www.bibliometrix.org/home/index.php/blog/135-main-software-to-analyze-bibliometric-data>. [Accessed 14 dezembro 2023].
- [11] e. a. J. A. Moral-Muñoz, *Software tools for conducting bibliometric analysis in science: An up-to-date review. Profesional de la Información.*, 2020.
- [12] S. Singh and S. Sharma, “A Bibliometric Analysis of Sleep Pattern Prediction of Breast Cancer Survivors Using VOSviewer,” in *International Conference on Computational Intelligence, Communication Technology and Networking (CICTN) Computational Intelligence, Communication Technology and Networking (CICTN)*, 2023.

- [13] N. Eck and L. Waltman, "Scientometrics Vol. 84," *Software survey VOSviewer, a computer program for bibliometric mapping*, pp. 523-538, agosto 2010.
- [14] "Artificial Intelligence applications in healthcare: A bibliometric and topic model-based analysis," *Intelligent Systems with Applications*, março 2024.
- [15] A. A. Awan, "Convert Text Documents to a TF-IDF Matrix with tfidfvectorizer," 7 setembro 2022. [Online]. Available: <https://www.kdnuggets.com/2022/09/convert-text-documents-tfidf-matrix-tfidfvectorizer.html>. [Accessed 2024 junho 3].
- [16] L. A.-A. C. Yactayo-Arias, "A bibliometric analysis of the advance of artificial intelligence in medicine," *International Journal of Electrical and Computer Engineering (IJECE)*, pp. 3350-3361, junho 2024.
- [17] B. L. Jimma, "Artificial intelligence in healthcare: A bibliometric analysis," *Telematics and Informatics Reports*, 2023.
- [18] N. M and Y. UK, "Deep Learning Based Methods for Breast Cancer Diagnosis: A Systematic Review and Future Direction," 2023.
- [19] H. Ahmad, M. Milne, Q. Buchlak, N. Ektas, G. Sanderson, H. Chamtie, S. Karunasena, J. Chiang, X. Holt, C. Tang and e. al, "Machine Learning Augmented Interpretation of Chest X-rays: A Systematic Review," 2023.
- [20] X. e. a. Yang, *Machine Learning-Driven Models to Predict Prognostic Outcomes in Patients Hospitalized With Heart Failure Using Electronic Health Records: Retrospective Study.*, 2021.
- [21] L. Millner and L. Strotman, *The Future of Precision Medicine in Oncology.*, 2016.
- [22] T. LeDain, "My Diabetes Coach – A Holistic Care Management Solution," 2017. [Online]. Available: <https://www.emids.com/insights/my-diabetes-coach-a-holistic-care-management-solution/>. [Accessed fevereiro 2024].
- [23] E. Thwala, A. Adegun and M. Adigun, "2023 International Conference on Science, Engineering and Business for Sustainable Development Goals," *Self-Assessment Chatbot for COVID-19 prognosis using Deep Learning-based Natural Language Processing (NLP)*, pp. 1-8, 2023.
- [24] "Dedicated Area Robotic Surgery," 2024. [Online]. Available: <https://www.hospitaldaluz.pt/lisboa/en/dedicated-areas/robotic-surgery#tabp-0>. [Accessed 09 01 2024].

- [25] I. M. G. T. K. S. W. J. H. M. H. J. L. X. Y. H. A. T. Qureshi R, “AI in drug discovery and its clinical relevance,” 2023.
- [26] PubMed, “PubMed Overview,” 2023 agosto 15. [Online]. Available: <https://pubmed.ncbi.nlm.nih.gov/about/>. [Accessed 2024 maio 21].
- [27] L. Waltman and N. J. van Eck, *VOSviewer [Computer software]*, 2009.
- [28] L. Waltman and N. J. van Eck, “Manual for VOSviewer version 1 .6.8,” outubro 2023. [Online]. Available: https://www.vosviewer.com/documentation/manual_vosviewer_1.6.8.pdf. [Accessed maio 2024].
- [29] L. Waltman and N. J. van Eck, “Text mining and visualization using VOSviewer,” setembro 2011.
- [30] J. Joyce, “Kullback-Leibler Divergence,” Lovric, M. (eds) *International Encyclopedia of Statistical Science*, 2011.
- [31] N. J. van Eck, L. Waltman, R. Dekker and J. van den Berg, “A Comparison of Two Techniques for Bibliometric Mapping: Multidimensional Scaling and VOS,” *American Society for Information Science and Technology. Journal*, vol. 61, no. 12, pp. 2405-2416, 2010.
- [32] P. Atitta, Outlive, Penguin , 2023, p. 10.
- [33] M. Castro, “O risco de uma nova pandemia,” [Online]. Available: <https://www1.folha.uol.com.br/colunas/marcia-castro/2024/05/o-risco-de-uma-nova-pandemia.shtml>. [Accessed 6 junho 2024].

Apêndices

Cronograma

Na Tabela 1 podemos observar o cronograma utilizado durante esta dissertação.

Tabela 1- Cronograma

Atividades/Meses	Nov 23	Dez 23	Jan 24	Fe v 24	Mar 24	Abr 24	Mai 24	Ju n 24	Jul 24	Aug 24
Pesquisa prática sobre estudo de ferramentas para componente prática	X	X	X	X	X	X	X			
Desenvolvimento de um metodologia de pesquisa				X	X	X	X			
Descrição das componentes práticas na Dissertação						X	X			
Análise dos Resultados							X	X		
Entrega									X	
Revisão do Orientador									X	X
Preparação para defesa										X