

Referenciação de pacientes aos Cuidados Paliativos usando modelos preditivos de Inteligência Artificial

Mariana Paulino Ferreira de Castro

Dissertação para obtenção do Grau de Mestre em
Medicina
(Mestrado Integrado)

Orientador: Mestre Dr. Abel García Abejas

janeiro de 2024



Declaração de Integridade

Eu, Mariana Paulino Ferreira de Castro, que abaixo assino, estudante com número de inscrição 41868 de Medicina da Faculdade de Ciências da Saúde, declaro ter desenvolvido o presente trabalho e elaborado o presente texto em total consonância com o Código de Integridade da Universidade da Beira Interior.

Mais concretamente afirmo não ter incorrido em qualquer das variedades de Fraude Académica, e que aqui declaro conhecer, e que em particular atendi à exigida referenciação de frases, extratos, imagens e outras formas de trabalho intelectual, e assim assumo na íntegra as responsabilidades da autoria.

Universidade da Beira Interior, Covilhã 23 / 01 / 2024

Mariana Paulino Ferreira de Castro

(assinatura conforme Cartão de Cidadão ou preferencialmente assinatura digital no documento original se naquele mesmo formato)

Agradecimentos

Tenho sem dúvida muito a agradecer ao meu orientador, Dr. Abel, por ter aceitado a minha proposta de trabalho relativa a um tema algo “fora da caixa”, novo e com ainda muito por descobrir, mas certamente com muito potencial para o futuro. Agradecer ainda por me ter proporcionado, desde o início até ao fim, inúmeras oportunidades para não só divulgar o presente trabalho, como aprofundar o meu conhecimento nesta área.

À minha mãe, que está sempre lá, que sabe sempre o que dizer, que acompanha sempre o meu percurso e a quem eu devo mais do que alguma vez poderei retribuir.

Ao meu pai e ao meu irmão, por acreditarem em mim e serem sempre uma inspiração, à minha avó por me ter sempre no pensamento e mesmo à distância me dar forças com as suas palavras sem igual.

Aos meus amigos por sorrirem comigo e por traçarmos o nosso percurso académico lado a lado, tanto nos momentos de felicidade como nos de medo e dúvida.

Ao Luís por sorrir genuinamente com as minhas conquistas e pela sua capacidade inata de descomplicar todos os obstáculos que possam surgir nesta aprendizagem constante que é a vida.

A todos vós, obrigada do fundo do coração.

Prefácio

“You matter because you are you, and you matter to the last moment of your life. We will do all that we can not only to help you die peacefully, but also to live until you die.”

quoted in Robert Twycross ‘A Tribute to Dame Cicely Saunders’, 8 March 2006

Resumo

Introdução: A Inteligência Artificial (IA) assume um papel cada vez mais relevante nas nossas vidas, tendo potencial para, no futuro, transformar o atual paradigma da prestação de cuidados de saúde. Uma área na qual esta tecnologia tem demonstrado avanços promissores é na referenciação de pacientes aos Cuidados Paliativos (CP). Os CP têm como objetivo fornecer apoio a pacientes com doenças graves, procurando aliviar sintomas, melhorar a qualidade de vida e atender às necessidades emocionais e psicológicas dos pacientes e das suas famílias. Ao aproveitar o poder da previsão e capacidade dos algoritmos de se treinarem a si mesmos, a IA tem o potencial de revolucionar a identificação e encaminhamento atempados de pacientes que beneficiariam de CP, por forma a discutir atempadamente com estes e com as suas famílias, as expetativas e perspetivas de fim de vida.

Objetivo: Analisar os modelos de previsão já construídos para referenciação aos CP, assim como perceber se a utilização destes como auxiliares de decisão pelos profissionais de saúde realmente aumenta a qualidade de vida dos pacientes.

Métodos: Esta dissertação é uma revisão sistemática com síntese narrativa. Foram incluídos artigos originais *Peer-Reviewed*, os quais foram submetidos a critérios de avaliação de qualidade. Foi excluída a literatura cinzenta. A população de interesse focou-se em dados de pacientes com uma patologia com prognóstico limitado, dados de mortalidade dos pacientes de uma instituição de saúde ou dados dos pacientes de uma instituição de saúde.

Resultados: Foram incluídos 22 artigos dos 217 obtidos aquando da pesquisa nas diferentes bases de dados. A maioria dos estudos correspondiam a estudos quantitativos, nos quais o tamanho das amostras mostrou-se bastante variado, assim como a população escolhida, adaptando-se esta ao objetivo do estudo. Também estão presentes tanto estudos retrospectivos como prospetivos. Os algoritmos de IA obtiveram melhores resultados relativamente aos métodos tradicionais de referenciação, como o recurso a métodos tradicionais de estatística ou ferramentas de prognóstico com inserção manual de dados. Também foi verificado que esta abordagem aumenta a qualidade de vida dos pacientes, verificando-se a antecipação e o aumento no número de consultas de CP, diminuição da mortalidade intra-hospitalar, das readmissões por qualquer causa em 30 dias e das admissões e tempo de internamento. Aumentou também a referenciação para

prestação de CP ao domicílio, estando estes também associados a uma melhor qualidade de vida para os pacientes.

Discussão/Conclusões: As novas tecnologias são muitas vezes vistas como potenciais substitutos para os trabalhos e funções que os seres humanos sempre desempenharam, no entanto, esse não é de todo o objetivo da implementação da IA na referenciação aos CP, que deve apenas ser usada com uma ferramenta de apoio à decisão, sendo o veredicto final sempre dado pelos profissionais de saúde. O uso destes algoritmos tem o potencial de aumentar significativamente a qualidade de vida dos pacientes, ao permitir uma sinalização e acesso atempados aos CP, focados não na cura, mas na gestão individualizada de sintomas e emoções, tendo sido obtidos bons resultados a nível de *outcomes* de saúde dos pacientes sinalizados por estes algoritmos.

Palavras-chave

Cuidados de fim de vida;Cuidados Paliativos;Inteligência Artificial;Machine Learning; Referenciação de pacientes;Ferramentas de suporte de decisão

Abstract

Introduction: Artificial Intelligence (AI) has been playing an increasingly relevant role in our lives, having the potential to transform the current paradigm of healthcare provision in the future. One area in which this technology has demonstrated promising advances is in referring patients to Palliative Care (PC). PC aims to provide support to patients with serious illnesses, seeking to alleviate symptoms, improve quality of life and meet the emotional and psychological needs of patients and their families. By harnessing the power of prediction and the ability of algorithms to train themselves, AI has the potential to revolutionize the timely identification and referral of patients who would benefit from PC, enabling timely discussions with them and their families about end-of-life expectations and perspectives.

Aim: Analyze the already existing prediction models for PC referral, as well as understand whether the use of these as decision aids by health professionals, really increases the quality of life of patients.

Methods: This is a systematic review with narrative synthesis. Original Peer-Reviewed articles were included, which were subjected to quality assessment criteria. Grey literature was excluded. The population of interest focused on data from patients with a pathology with limited prognosis, mortality data from patients in a healthcare institution, or data from patients in a healthcare institution.

Results: 22 studies were included from the 217 found when the databases were searched. Most of the studies were quantitative, with variable sample sizes and populations chosen in accordance with the studies' objectives. Retrospective and prospective studies are present. AI algorithms obtained better results when compared to traditional referral methods, such as traditional statistical methods or prognostic tools with manual data entry. The use of AI to improve PC referral has yielded favorable results in terms of improving patients' quality of life with the anticipation and increase in the number of PC consultations, reduction of in-hospital mortality, reduction of readmissions for any cause within 30 days and admissions and less days of hospitalization. Referrals for home-based PC services have also increased, which is also associated with a better quality of life for patients.

Discussion/Conclusions: New technologies are often seen as potential substitutes for the jobs and functions that humans have always performed. However, this is not the goal

of implementing AI in PC referral, since this technology should only be used as a decision support tool, with the final verdict always being given by healthcare professionals. The use of these algorithms has the potential to significantly increase patients' quality of life, by allowing timely signaling and access to PC, focused not on cure, but on the individualized management of symptoms and emotions, with good results being obtained in terms of patient health outcomes signaled by these algorithms.

Keywords

End-of-life care; Palliative Care; Artificial Intelligence; Machine Learning; Patient Referral; Decision Support Systems

Índice

Agradecimentos	iv
Prefácio	vi
Resumo	viii
Abstract.....	xi
Lista de Figuras.....	xvii
Lista de Tabelas	xix
Lista de Acrónimos	xxi
Capítulo 1. Introdução	23
Capítulo 2. Contextualização Teórica e enquadramento	25
2.1 Conceitos: Cuidados Paliativos e Inteligência Artificial.....	25
2.2 Critérios de Referenciação aos Cuidados Paliativos – <i>Early Palliative Care</i>	28
Capítulo 3. Metodologia.....	30
3.1 Objetivos	30
3.1.1 Hipótese de Pesquisa.....	30
3.2 Desenho da revisão	31
3.3 Estratégia de pesquisa.....	31
3.3.1 Termos de pesquisa em bases de dados.....	32
3.4 Critérios de elegibilidade	33
3.5 Análise de qualidade dos estudos.....	34
Capítulo 4. Resultados	35
4.1 Seleção dos estudos	35
4.2 Qualidade dos estudos	36
4.3 Características dos estudos	37
4.4 Características da amostra/população.....	37
4.5 Características do contexto de prestação de cuidados	37
4.6 Características dos algoritmos de IA.....	37
4.7 Extração de dados dos estudos incluídos na revisão	38
4.8 Síntese e sistematização de resultados	38
4.8.1 Performance dos algoritmos de IA	38
4.8.2 <i>Outcomes</i> de saúde dos pacientes	39
4.8.3 Variáveis clínicas consideradas mais relevantes.....	40
4.8.4 Opinião dos profissionais de saúde acerca da integração de AI na prática clínica.....	42
4.8.5 Considerações éticas e de privacidade	42
Capítulo 5. Discussão.....	43
Capítulo 6. Limitações e trabalho futuro	45

Capítulo 7. Conclusões	46
7.1 Impacto do uso de algoritmos de IA na qualidade de vida dos pacientes	46
7.2 Comparação do uso de algoritmos de IA com a referenciação exclusivamente humana e opinião dos profissionais de saúde	46
7.3 Seleção dos dados, parâmetros e técnicas de IA utilizadas na construção dos algoritmos	47
Referências Bibliográficas	48
Apêndice 1.	53
Apêndice 2.	56
Apêndice 3.	57

Lista de Figuras

Figura 1 - Processo de treino de modelos de <i>Machine Learning</i>	26
Figura 2 - Fluxograma PRISMA do processo de pesquisa e seleção dos artigos a ser incluídos na revisão sistemática.	36

Lista de Tabelas

Tabela 1 – Critérios de inclusão e de exclusão.....	33
---	----

Lista de Acrónimos

IA	Inteligência Artificial (<i>Artificial Intelligence</i>)
CP	Cuidados Paliativos (<i>Palliative Care</i>)
OMS	Organização Mundial de Saúde
EAPC	<i>European Association for Palliative Care</i>
ML	<i>Machine Learning</i>
PROSPERO	<i>International Prospective Register of Systematic Reviews</i>
SPICT™	<i>Supportive & Palliative Care Indicators Tool</i>
NECPAL 4.0	<i>NECesidades PALiativas</i>
PRISMA	<i>Preferred Reporting Items for Systematic Reviews and Meta-analyses</i>
PRESS	<i>Peer Review Electronic Search Strategies</i>
MeSH	<i>Medical Subject Headings</i>
EHR	<i>Electronic Health Records</i>
DPOC	Doença Pulmonar Obstrutiva Crónica
AVD	Atividades de Vida Diária
AUC	<i>Area Under the Curve</i>
OASIS-SQ	<i>Outcomes and Assessment Information Set-Surprise Question</i>
AUROC	<i>Area Under the Receiver Operating Characteristic</i>

Capítulo 1. Introdução

A Inteligência Artificial (IA), cada vez mais faz parte das nossas vidas. Apesar de não ter uma definição estabelecida, a IA pode ser entendida como a tentativa de usar máquinas para mimetizar funções cognitivas dos humanos, sendo que estas podem ter *performances* por vezes mesmo superiores às dos seres humanos. Mais especificamente na saúde, os avanços da IA também são notórios, sendo que uma das áreas que tem vindo a ser estudada é a referenciação aos Cuidados Paliativos (CP). (1)

Segundo a OMS, os CP fazem parte de uma abordagem multidisciplinar que tem como objetivo melhorar a qualidade de vida dos pacientes, das suas famílias e cuidadores, através de prevenção, identificação precoce e redução do sofrimento decorrente da dor ou outras condições físicas, psicossociais ou espirituais associadas a uma doença crónica e incurável, com grande impacto na vida do paciente e daqueles que o rodeiam. Assim, os CP abordam variadas patologias, desde doenças cardiovasculares (38,5%), a cancro (34%), doenças respiratórias crónicas (10,3%), a Síndrome da Imunodeficiência Adquirida (5,7%) e a diabetes (4,6%), entre outras. No entanto, o acesso aos CP está longe daquilo que seria ideal, especialmente nos países de baixo e médio rendimento, sendo uma possível explicação a ideia ainda muitas vezes errada de que estes cuidados estão reservados para aqueles que estão em final de vida. (2)

O acesso antecipado aos CP está associado a melhor colaboração, estado de espírito e mecanismos de *coping* por parte dos pacientes, assim como menores custos de tratamento e menor tempo de internamento. Observa-se também uma taxa reduzida de hospitalizações, o que permite aumentar de forma significativa a qualidade de vida daqueles que já estão sujeitos a um elevado nível de sofrimento. (3)

Com o aumento do número de pessoas com necessidade de CP, a IA aplicada aos CP pode ajudar a melhorar as atuais capacidades de prognóstico e, assim, identificar mais precocemente os pacientes com maior risco de mortalidade ou de exacerbação de sintomas, evitando que algumas decisões em relação a opções de tratamento sejam tomadas apenas nos últimos momentos de vida. Qualquer profissional de saúde deve reger-se pela máxima "*Primum non nocere*" (em português, "Primeiro, não causar dano"), promovendo cuidados que estejam no melhor interesse do paciente, respeitando a sua autonomia e preservando a "humanidade, dignidade e valor" inerentes ao paciente. Desta forma, os modelos preditivos têm e terão cada vez mais um importante papel no auxílio da prática clínica, contribuindo para as equipas de CP poderem discutir mais precocemente opções de tratamento com os pacientes e com as suas famílias e

cuidadores, por forma a tomar decisões partilhadas e concordantes com as necessidades e desejos dos pacientes. No entanto é de extrema importância lembrar que os algoritmos não devem enfraquecer a relação médico-paciente, sendo esta de extrema importância na prática da medicina, assim como a capacidade de comunicar um mau prognóstico. (4–6)

Assim, perante os recentes avanços da IA no mundo atual e a necessidade de melhorar e agilizar a referenciação aos CP, pretende-se com esta revisão sistemática tirar conclusões com base na evidência já existente, de forma a perceber o futuro do uso destas tecnologias na saúde.

Um aspeto relevante desta revisão é a integração de vários modelos de IA com vários contextos de atuação dos CP.

Capítulo 2. Contextualização Teórica e enquadramento

2.1 Conceitos: Cuidados Paliativos e Inteligência Artificial

Os CP fazem parte de uma abordagem multidimensional que tem como objetivo aumentar a qualidade de vida, promover a dignidade e a autonomia das pessoas portadoras de doença crónica e dar apoio à família nestas condições severas, tanto agudas como crónicas, através da prestação de apoio nas 3 dimensões do paciente: biológica, psicossocial e espiritual. De acordo com a *European Association for Palliative Care* (EAPC), é estimado que 4.4 milhões de pessoas por ano na Europa necessitem de CP. Ainda mais, nos últimos anos tem-se verificado um aumento na esperança média de vida, embora tal tenha vindo acompanhado com o aumento da cronicidade. No que toca aos CP propriamente ditos, nos últimos anos, apesar de ter havido um aumento de unidades de CP, estas não se mostram suficientes nem eficientes, para acompanhar as necessidades dos portugueses, uma vez que ainda há poucos anos vivíamos muito centrados em cuidados dirigidos à cura da doença, sendo que agora assistimos à mudança de paradigma do foco na cura das doenças agudas para a gestão das doenças crónicas. (2,7)

Os CP surgiram pela vontade dos profissionais de saúde em continuar a tratar pacientes com cancros incuráveis, por forma a aumentar o seu bem-estar e qualidade de vida com o controlo de sintomas e gestão das emoções. No entanto, a receção destes cuidados não deveria ser só determinada pelo diagnóstico, mas sim pelas necessidades de cada paciente em particular, medicina baseada na narrativa e as necessidades. (7)

Ao contrário do que muitas vezes se pensa, os CP não se limitam a doentes em fim de vida, pelo contrário, podem ser necessários em qualquer estadio de uma doença. Podem incluir: pacientes com doenças agudas, severas e ameaçadoras de vida (onde a cura e a reversibilidade da situação podem ser possíveis, apesar de o tratamento poder afetar a qualidade de vida e causar sofrimento ao paciente e à família); pacientes com doenças crónicas progressivas; pessoas com doenças severas e ameaçadoras de vida, mas que escolheram não ser tratados para a mesma; pessoas com lesões crónicas e limitantes devido a alguma forma de trauma e, por último, doentes terminais (por exemplo estados avançados de demência ou cancro). (7)

A IA refere-se a algoritmos e modelos de computação que conseguem desempenhar tarefas humanas, como interpretar imagens, reconhecer o discurso, planear, organizar e aprender.

Machine Learning (ML) corresponde a um subconjunto de algoritmos e modelos dentro da IA que usa metodologias de análise estatística para “treinar” modelos a partir de dados, ao ir encontrando padrões estatísticos e usá-los para atribuir relevância estatística a cada parâmetro em estudo, para assim fazer a previsão dos *outcomes* com base nos dados inicialmente inseridos. Assim, os modelos de ML são como um médico que progressivamente vai ganhando experiência. Quer isto dizer que os modelos usam *training datasets* (os dados utilizados para treinar o algoritmo), para ir ajustando os seus parâmetros internos (como o peso relativo de certas características ou parâmetros), por forma a minimizar a diferença entre as previsões do algoritmo e os resultados contidos nos dados inicialmente inseridos no modelo. Esta eficácia depois é testada no *testing dataset*, que incorpora dados que o modelo nunca analisou, testando a sua capacidade de lidar com dados diferentes dos do *training dataset*. (1,8)

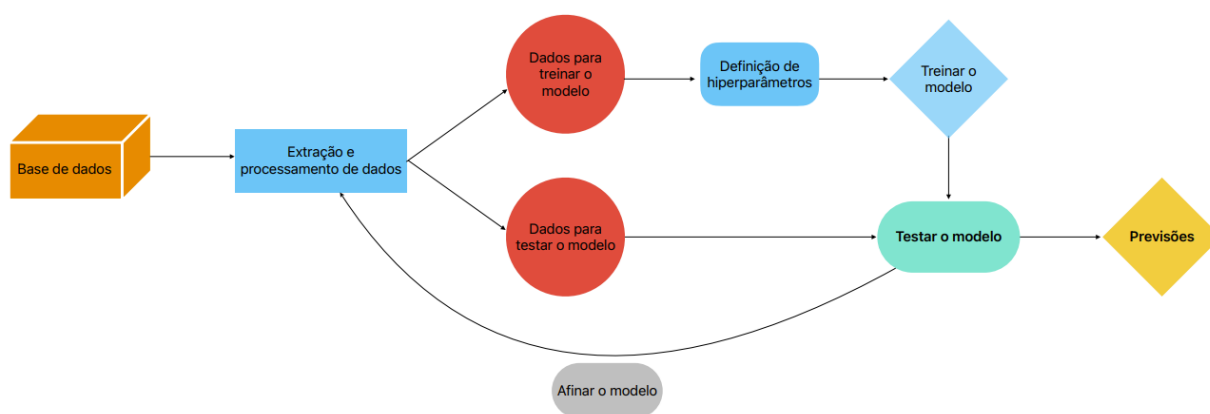


Figura 1 - Processo de treino de modelos de *Machine Learning*.

Ainda dentro da IA, temos também um subconjunto de ML, intitulado de *Deep Learning*, onde os algoritmos se podem treinar a si mesmos usando conjuntos de dados de dimensões e complexidade consideravelmente superiores aos usados em ML. A base destes modelos usa redes neuronais artificiais, que são modelos computacionais inspirados no cérebro humano, em que estes neurónios estão interconectados e organizados em camadas e onde grande quantidade de informação vai passando por cada uma destas, sendo processada e interpretada, para encontrar padrões e tirar conclusões a partir dos dados. (1)

Outras técnicas de ML (*Random Forest*, *Gradient Boosting Trees*, *AdaBoost*) baseiam-se em agrupar várias árvores de decisão com incontáveis ramificações e variáveis. Assim, perante uma determinada informação clínica, os ramos da árvore são percorridos até o algoritmo chegar a uma conclusão e apresentá-la. (9)

Já técnicas de *Natural Language Processing* usam dados em linguagem não estruturada, como algumas anotações clínicas inseridas nos programas usados pelos

sistemas de saúde. Assim, estes modelos podem ser usados para analisar e interpretar conversas complexas como as que ocorrem nos cuidados de saúde, especialmente em cuidados paliativos, área onde estes modelos apresentam grande potencial. Em suma, a análise sistemática do diálogo entre prestadores de saúde e pacientes pode dar-nos muita informação e melhor entendimento acerca dos padrões de comunicação na presença de condições ameaçadoras de vida e assim melhorar a qualidade dos cuidados prestados a estes pacientes com necessidades tão especiais. (8)

Estes modelos contrastam com o tradicional uso de métodos analíticos, que são de mais simples interpretação, mas que têm pior desempenho em quantidades muito grandes e complexas de dados, como é o caso dos dados em saúde. Já nos modelos de IA, o objetivo será rapidamente identificar padrões em bases de dados enormes e complexas e assim tirar conclusões a partir das mesmas. Os desafios a enfrentar na utilização de modelos de IA serão monetários, uma vez que estes são de cara implementação, assim como o facto de por vezes poder ser difícil perceber como é que estes chegam às previsões, pois por vezes os algoritmos são muito complexos e com várias camadas, como é o caso das redes neuronais anteriormente referidas. Para colmatar esta barreira, são necessárias ferramentas de interpretação, chamadas *explainable AI*, comuns a todos os modelos de IA, que são técnicas que os tornam mais transparentes e facilmente compreensíveis e interpretáveis. (5,10)

Por conseguinte, com base nestas ferramentas são criados modelos preditivos que auxiliam na referenciação de pacientes aos CP, usando dados existentes nos registos clínicos dos pacientes. Existem 2 tipos de modelos: modelos preditivos de diagnóstico, que fazem previsões acerca do estado de saúde de um paciente com uma determinada condição, assim como modelos preditivos de prognóstico, que por sua vez estimam a probabilidade de um dado *outcome* em saúde (como por exemplo a mortalidade num determinado intervalo temporal) ocorrer. (5)

Ensaio clínicos randomizados mostraram que a referenciação mais antecipada aos CP aumenta a qualidade de vida dos pacientes com cancro em estadios avançados, assim como dos seus cuidadores, no entanto muitas vezes tal não se verifica na prática clínica. A Sociedade Americana de Oncologia sugere que esta referenciação seja feita até 8 semanas após o diagnóstico de doença avançada. No entanto, devido à heterogeneidade de doenças que têm indicação para CP, torna-se difícil criar uma meta temporal de referenciação a todas elas, sendo ainda necessário mais pesquisa relativamente a este tópico. Acrescenta-se a isto que, devido a esta falta de critérios definidos de rastreio e de seleção de candidatos aos CP, oncologistas, por exemplo, referenciam os pacientes com base na sua percepção das necessidades dos mesmos, o que muitas vezes leva a uma

referenciação tardia, sendo que isto tem um impacto negativo nos cuidados dos pacientes com doenças avançadas. Ainda não existe consenso acerca da tendência para um atraso na referenciação, mas segundo alguns investigadores pode dever-se ao estigma e ideias erradas daquilo em que consistem os CP. (10,11)

No entanto não podemos esquecer que como estes modelos lidam com grandes e complexas quantidades de dados, a segurança destes e a qualidade e praticidade dos algoritmos têm de ser asseguradas antes do seu uso na prática clínica poder ser disseminado. Hond et al. refere a necessidade da criação de uma estrutura sistemática para avaliar a qualidade dos modelos durante todo o seu desenvolvimento, avaliação e implementação e aponta ainda que a falta deste tipo de sistemas pode ser a causa da escassa utilização destes modelos até ao momento. (5)

2.2 Critérios de Referenciação aos Cuidados Paliativos – *Early Palliative Care*

A adequada e atempada referenciação aos CP é de extrema importância, de forma a diminuir o sofrimento e cessar a tentativa de cuidados curativos em pacientes que já não respondem nem beneficiam dos mesmos. Desta forma, existem ferramentas que auxiliam na identificação destes pacientes, permitindo assim direcionar os cuidados para uma abordagem paliativa.

SPICITTM (*Supportive & Palliative Care Indicators Tool*) é uma ferramenta de fácil e rápida utilização, sendo usada na identificação de pacientes com doença grave ou irreversível que leva a uma deterioração do seu estado de saúde, de modo que possam beneficiar de uma abordagem paliativa, com uma avaliação holística e planeamento antecipado de cuidados. A utilização desta ferramenta inicia-se pela procura de indicadores gerais de deterioração de saúde, seguida pela procura de indicadores clínicos mais específicos das condições limitantes da vida, oncológicas ou não, que o paciente apresenta, acrescentando-se a avaliação da adequação dos cuidados atuais e planeamento dos futuros. (12)

Outro instrumento utilizado intitula-se NECPAL 4.0 (NECesidades PALiativas), que é uma aplicação móvel cujo objetivo principal é detetar antecipadamente a necessidade de CP, estimando o risco de mortalidade em pessoas com doenças crónicas avançadas. Inicialmente avalia-se a perceção dos profissionais das necessidades de CP do paciente a partir da chamada "pergunta surpresa" - "Ficaria surpreendido se este paciente morresse no próximo ano?" – caso a resposta seja não, procede-se com a medição de outros parâmetros, nomeadamente o pedido pelo paciente ou a necessidade de CP percecionada pelos profissionais, o declínio funcional e nutricional do paciente, a multimorbilidade, o

uso de recursos e serviços como as urgências e ainda critérios relacionados com a condição específica do paciente. (13)

Assim, estas ferramentas são capazes de auxiliar na percepção da necessidade de referenciação dos pacientes. No entanto, devido à atual falta de formação básica dos profissionais em CP, muitas vezes estas ferramentas não são utilizadas nos serviços sendo que, quando aplicadas, por exemplo num serviço de Medicina Interna de um hospital terciário em Portugal, a prevalência das necessidades paliativas dos 148 pacientes internados a 20 de abril de 2022 foi de 88.5%. Logo, 122 cumpriram os critérios de elegibilidade necessários para aplicação do NECPAL e 72,2% encontravam-se no estadio 3 de prognóstico do NECPAL (média de sobrevivência de 3,6 meses). (14)

Com isto, percebemos a importância da implementação de formação básica em CP por forma a melhorar a identificação dos pacientes com necessidades paliativas, assim como o potencial da IA na praticidade da coleção de informação acerca de cada paciente com o consequente processamento da mesma e sugestão de referenciação, conseguindo uma identificação mais rápida das necessidades dos pacientes e evitando um aumento na carga de trabalho dos profissionais.

Capítulo 3. Metodologia

Foi conduzida uma revisão sistemática integrativa com síntese narrativa, que teve por objetivo principal averiguar os avanços existentes acerca do uso de modelos preditivos de IA para a seleção de pacientes candidatos aos CP.

O protocolo desta revisão sistemática encontra-se registado na base de dados internacional de registo de revisões sistemáticas PROSPERO¹, encontrando-se o link disponível em rodapé.

3.1 Objetivos

Objetivo principal:

- Perceber se existe realmente um benefício e um aumento da qualidade da vida dos pacientes sinalizados por modelos de IA, contribuindo para um final de vida mais digno e mais de acordo com as expectativas dos pacientes e das suas famílias.

Objetivos secundários:

- Averiguar se a introdução da IA como auxílio à referenciação exclusivamente humana traz benefícios relativamente ao atual modo de referenciação, assim como qual a opinião dos profissionais de saúde acerca da utilização da IA na sua prática clínica.
- Perceber que tipo de técnicas de IA são utilizadas para a construção dos modelos de referenciação, que informação é usada e como são definidos os parâmetros relevantes para analisar a elegibilidade dos pacientes.

3.1.1 Hipótese de Pesquisa

A hipótese de pesquisa foi construída a partir da estrutura PICO:

P = Participantes/População (pacientes com uma patologia com prognóstico limitado, dados de mortalidade dos pacientes de uma instituição de saúde, dados dos pacientes de uma instituição de saúde)

I = Intervenção/Fenómeno de interesse (seleção de pacientes elegíveis aos CP com o uso de modelos de IA)

¹ https://www.crd.york.ac.uk/prospero/display_record.php?ID=CRD42023398866

C = Contexto (referenciação de pacientes aos CP exclusivamente humano ou com recurso a modelos de IA)

O = Resultados (melhor referenciação aos CP e qualidade de vida dos pacientes)

Hipótese de pesquisa:

- Será a seleção de pacientes elegíveis aos CP utilizando modelos de IA vantajosa para as pessoas portadoras de doença crónica e condições limitantes, aumentando a sua qualidade de vida?

3.2 Desenho da revisão

Não existem ainda muitos estudos na área da IA aplicada aos CP, pelo que esta revisão sistemática inclui estudos heterogéneos, sendo que não se foca apenas num tipo de modelo de IA nem em apenas uma população com uma determinada condição.

Esta revisão irá seguir o *Preferred Reporting Items for Systematic Review and Meta-Analyses* (PRISMA) como modelo de revisão. (15)

O protocolo de pesquisa foi composto por 4 etapas:

1. Seleção de bases de dados para executar a pesquisa sistemática de acordo com o *Peer Review Electronic Search Strategies* (PRESS) e o *Preferred Reporting Items for Systematic Review and Meta-Analyses* (PRISMA).
2. Identificação e seleção de estudos considerados relevantes segundo os critérios de inclusão e de exclusão previamente definidos.
3. Avaliação da qualidade da evidência nos estudos selecionados, usando os critérios de *Hawker et al.* (16)
4. Extração da informação e síntese dos dados dos artigos selecionados com base numa síntese temática e narrativa.

3.3 Estratégia de pesquisa

A pesquisa efetuada para a realização desta revisão sistemática ocorreu em dois momentos distintos. Primeiramente, após definir qual seria o foco do trabalho, foi realizada uma pesquisa mais abrangente por forma a tentar compreender a quantidade de conteúdo científico já existente até à data acerca do tema, assim como averiguar se nos últimos anos o mesmo estaria a ter atualizações e novos artigos e com que frequência,

tentando perceber se se consideraria uma área de interesse para a comunidade científica. Esta pesquisa foi efetuada na *PubMed*, com a leitura dos *abstracts* e de alguns textos integrais de acesso livre. Concomitantemente, foi sendo realizada a colheita de palavras-chave, termos gerais e *Medical Subject Headings* (MeSH) que iam surgindo com maior regularidade.

De seguida efetuou-se a escolha das bases de dados consideradas relevantes para selecionar sistematicamente os artigos para a revisão sistemática. Para isto, foi possível o acesso às bases de dados utilizando o acesso universitário institucional. Assim, a pesquisa foi feita nas seguintes bases de dados: *PubMed*, *Scopus*, *Science Direct* e *Clarivate Web of Science*.

A pesquisa nas bases de dados foi concluída em dezembro de 2022. A estratégia de pesquisa foi adaptada dependendo da base de dados, sendo que esta estratégia será detalhada no Apêndice 1. Foi também realizada uma análise das referências bibliográficas dos artigos selecionados por forma a procurar artigos que pudessem vir a ser incluídos no corpo da revisão sistemática. Não foi incluída literatura cinzenta.

Os MeSH *terms* foram combinados com outros sinónimos, havendo desta forma o risco de diminuir a precisão, mas, em contrapartida, de obter uma elevada sensibilidade podendo assim potencialmente obter os artigos mais relevantes no tema.

De seguida foram removidos os duplicados e após isto foram selecionados os artigos publicados a partir de 2016 e artigos originais *Peer-Reviewed*. Como idioma de publicação apenas se incluiu o inglês, português, espanhol e italiano.

Os artigos resultantes desta seleção foram lidos na íntegra para uma análise mais aprofundada, por forma a assegurar que cumpriam os critérios de inclusão e exclusão. A maioria destes artigos encontrava-se em acesso livre, podendo ter acesso a estes através do acesso institucional universitário. Uma minoria de artigos não tinha o texto completo disponível, tendo sido por isso necessário contactar os autores para a obtenção dos mesmos.

3.3.1 Termos de pesquisa em bases de dados

Para a pesquisa nas bases de dados, com operadores booleanos, usou-se uma combinação de MeSH, palavras-chave e *subject headings*. Os termos usados tiveram como objetivo a obtenção de artigos com os *abstracts* em inglês, por forma a conseguir incluir um conjunto maior de referências em cada base de dados. Contudo, os textos

completos mantiveram-se nos idiomas presentes nos critérios de inclusão (português, inglês, espanhol e italiano).

Os termos de pesquisa foram escolhidos ao selecionar os mais frequentes na literatura científica, dentro dos domínios que definem esta revisão (Inteligência Artificial, Cuidados Paliativos e Referenciação de Pacientes).

Assim sendo, a pesquisa foi efetuada utilizando as seguintes combinações de termos e palavras-chave nos 3 domínios de pesquisa:

- Inteligência Artificial: *artificial intelligence* OR *deep learning* OR *machine learning* OR *supervised machine learning* OR *unsupervised machine learning* OR *computation intelligence* OR *reinforcement learning* OR *deep neural network* OR *electronic health records* OR *administrative claims* OR *clinical informatics*.
- Cuidados Paliativos: *palliative care*.
- Referenciação de Pacientes: *precision medicine* OR *patient referral* OR *decision support systems* OR *predictive modeling* OR *risk stratification* OR *decision making*.

A estratégia de pesquisa completa encontra-se detalhada no Apêndice 1.

3.4 Critérios de elegibilidade

Tabela 1 – Critérios de inclusão e de exclusão

Critérios de inclusão	<ul style="list-style-type: none"> • Artigos originais <i>peer-reviewed</i> focando no uso da Inteligência Artificial para a referenciação aos Cuidados Paliativos. • Artigos em inglês, italiano, português e espanhol. • Estudos quantitativos, qualitativos, mistos, relatórios de casos e séries de casos.
Critérios de exclusão	<ul style="list-style-type: none"> • Literatura cinzenta, comentários, artigos de opinião, resumos de conferências, protocolos de estudos não publicados, artigos só com <i>abstract</i>, relatórios breves. • Teses/dissertações. • Artigos publicados antes de 2016. • Artigos que mencionem o uso da Inteligência Artificial em qualquer área que não os Cuidados Paliativos ou que não mencionem o uso da Inteligência Artificial de todo.

3.5 Análise de qualidade dos estudos

Numa revisão sistemática é de extrema importância garantir a qualidade dos artigos incluídos, sendo que as ferramentas de análise de qualidade de publicações científicas fazem parte do esqueleto de uma revisão com o máximo rigor científico possível e, por isto mesmo, todas as publicações incluídas nesta revisão sistemática foram sujeitas aos critérios de avaliação de qualidade de *Hawker et al.* (16) (Apêndice 2). Esta análise permitiu assim obter uma visão geral das metodologias e resultados dos vários artigos. Não foi utilizada como critério de exclusão, mas possibilitou uma avaliação crítica da relevância dos mesmos.

Capítulo 4. Resultados

4.1 Seleção dos estudos

Da pesquisa nas 4 bases de dados (*PubMed*, *Scopus*, *Science Direct* e *Clarivate Web of Science*) resultaram 217 artigos, dos quais 52 foram identificados como duplicados, sendo retirados prontamente, o que resultou em 165 artigos originais.

De seguida, verificou-se a data de publicação de cada artigo, tendo sido retirados aqueles publicados antes de 2016, o que resultou na exclusão de 17 artigos, ficando assim com 148 publicações para leitura dos títulos e *abstracts*. Estes foram lidos por forma a seleccionar os artigos considerados relevantes para a revisão sistemática e também que cumpriam os critérios de inclusão e de exclusão.

Assim, 1 artigo foi excluído por estar escrito em alemão, 17 artigos eram correspondentes a literatura cinzenta, 103 artigos foram considerados como não relevantes uma vez que não mencionavam os três domínios definidos para esta revisão, não indo por isso de encontro ao objetivo da mesma. Para além destes, 1 artigo foi excluído por corresponder a um protocolo de estudo sem publicação de resultados até à data da pesquisa nas bases de dados. Em 3 artigos não foi possível obter o texto na íntegra após contacto com os autores, por falta de resposta por parte dos mesmos. Por último foi excluída uma revisão sistemática, mas esta foi posteriormente analisada pela possibilidade de incluir artigos relevantes para complementar a presente revisão sistemática, tendo acabado por integrar a mesma como pesquisa complementar.

Concluiu-se então esta fase com 22 artigos para leitura na íntegra e posterior extração de dados e resultados.

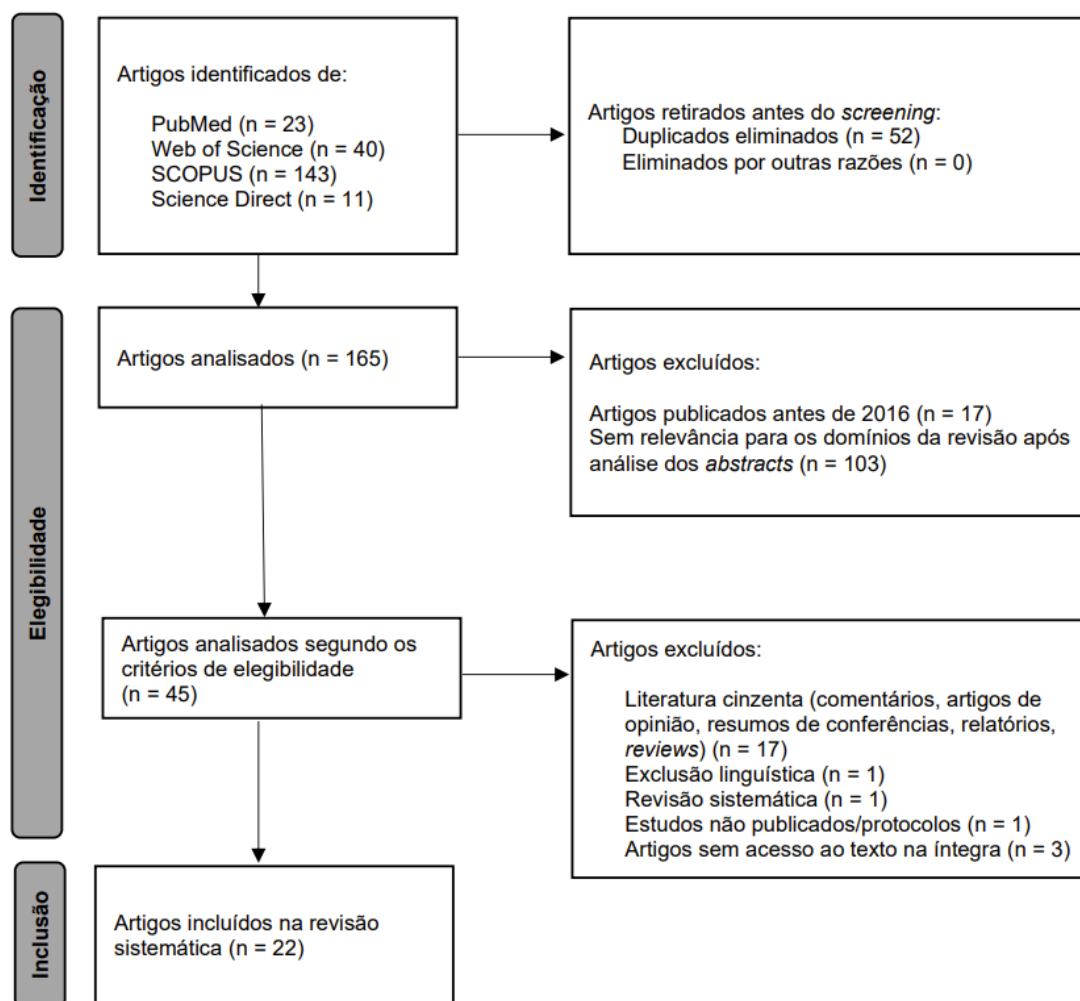


Figura 2 - Fluxograma PRISMA do processo de pesquisa e seleção dos artigos a ser incluídos na revisão sistemática.

4.2 Qualidade dos estudos

Como foi anteriormente referido, os critérios de avaliação de qualidade de *Hawker et al.* (16) foram usados para analisar e avaliar, numa pontuação de 9 a 36 pontos, a qualidade científica dos artigos selecionados. Este instrumento de avaliação avalia os artigos em variadas componentes e cada uma delas é atribuída uma classificação de 1 ponto (muito fraco), 2 pontos (fraco), 3 pontos (razoável), 4 pontos (bom). As componentes analisadas são: resumo e título, introdução e objetivos, métodos e dados, amostragem, análise de dados, ética e viés, resultados, transferibilidade e/ou generalização e implicações e utilidade.

Posto isto, dos 22 artigos submetidos a esta análise, 18 pontuaram entre 30 e 36 pontos e 4 artigos entre 28 e 29 pontos. Assim, os valores desta análise de qualidade variaram

entre 28 e 35 pontos. A pontuação atribuída a cada parâmetro e as informações detalhadas de cada artigo encontram-se no Apêndice 2.

4.3 Características dos estudos

Dos 22 artigos analisados, 21 correspondem a estudos quantitativos, focando-se em testar uma determinada hipótese através de uma análise que pretende comparar uma abordagem já usada a outra nova e experimental, chegando posteriormente a uma conclusão, usando os dados obtidos. 1 artigo tem uma abordagem qualitativa, recorrendo a entrevistas telefónicas semiestruturadas para posteriormente analisar as repostas obtidas.

4.4 Características da amostra/população

A amostra/população é muito variada, estando dependente do tipo de estudo. No estudo com abordagem qualitativa temos tipicamente amostras mais pequenas, neste caso com 29 profissionais de saúde. Já os estudos quantitativos variam entre 115 e 349.667, neste caso, dados de pacientes ou registos clínicos. Geralmente, são usados dados clínicos já existentes de pacientes de uma determinada instituição de saúde ou de *Electronic Health Records* (registos digitais de todos os dados de saúde, clínicos e administrativos, de pacientes que são partilhados entre hospitais, clínicas e laboratórios), decorrentes de hospitalizações ou de acompanhamentos regulares, ou mesmo de pacientes que já faleceram, por forma a testar a capacidade de previsão dos *outcomes* dos pacientes. Por norma, os pacientes abrangem uma ampla variedade de patologias, sendo maioritariamente oncológicas, mas também do foro cardíaco ou pulmonar.

4.5 Características do contexto de prestação de cuidados

Nesta revisão sistemática estão incorporados vários contextos de prestação de cuidados, incluindo 2 em contexto domiciliário, 12 em contexto hospitalar, 2 em cuidados primários e 1 em terciários. Existem também 5 estudos que não se focam propriamente num determinado contexto de prestação de cuidados, mas utilizam dados de uma base de dados nacional como por exemplo uma base de dados específica para pacientes diagnosticados com cancro. Assim, foram abrangidos vários contextos por forma a perceber o impacto da referenciação antecipada aos CP a partir de diferentes tipos de instituições de prestação de cuidados.

4.6 Características dos algoritmos de IA

A grande maioria dos estudos (mais especificamente 19 dos artigos selecionados) utilizaram técnicas de ML para realizar os modelos. Apenas 2 artigos (17,18) utilizaram métodos estatísticos tradicionais (*Cox Model*) que, embora não sejam especificamente

de IA, foram incluídos por apresentarem muito potencial para serem usados em conjunto com a mesma. Por exemplo, os modelos estatísticos tradicionais podem ser muito úteis para determinar as variáveis que depois serão usadas pelos modelos para determinar a pertinência ou não da referenciação aos CP, sendo que um dos artigos selecionados usa essa abordagem mesmo para criar o algoritmo de prognóstico, posteriormente usado para analisar a necessidade de referenciação (19). Por último, 1 artigo (20) dedica-se à análise da percepção dos profissionais de saúde acerca da utilização de modelos de ML para melhorar as previsões de mortalidade de pacientes com certas condições, por forma a poder antecipar as conversações com os pacientes acerca das suas preferências de tratamento e de fim de vida.

No que toca ao tipo de previsões feitas pelos modelos para melhorar a notificação aos CP, vários métodos são utilizados. 16 modelos optam pela previsão da mortalidade/probabilidade de mortalidade num determinado período (1 mês, 2 meses, 3 meses, 6 meses, 1 ano, 1 ano e meio ou mesmo 5 anos), enquanto 6 artigos focam-se na pesquisa de características nos registos clínicos dos pacientes que permitam alertar os clínicos para a possibilidade da necessidade de CP, independentemente da estimativa de mortalidade, uma vez que não são apenas os pacientes em fim de vida que podem necessitar de CP.

4.7 Extração de dados dos estudos incluídos na revisão

A extração da informação dos artigos selecionados encontra-se apresentada numa tabela no Apêndice 3. É então primeiramente apresentada a referência do artigo em análise e, depois, para uma análise mais aprofundada de cada artigo, averiguaram-se os participantes, a intervenção, o contexto, os resultados e ainda algumas notas consideradas relevantes.

4.8 Síntese e sistematização de resultados

4.8.1 Performance dos algoritmos de IA

Os algoritmos de IA superaram os métodos tradicionais de referenciação como o recurso a métodos tradicionais de estatística ou ferramentas de prognóstico com inserção manual de dados. (21)

Num estudo que se focou na criação de um algoritmo capaz de identificar pacientes com cancro avançado que poderiam beneficiar de cuidados diferenciados, como CP, apenas 46,3% dos pacientes sinalizados sobreviveram 6 meses após a sinalização e apenas 31,8% sobreviveram 1 ano. Assim, o algoritmo identificou com sucesso pacientes em que os CP podem aumentar significativamente a qualidade de vida nos últimos meses de vida. (22)

Outro estudo, retrospectivo, focado nos pacientes dos cuidados primários, elaborou um algoritmo para prever o risco de mortalidade num ano. Dos 349 667 pacientes analisados, 90,8% dos que faleceram nesse intervalo temporal não tiveram nenhuma interação com cuidados hospitalares até à data de morte e apenas 1,6% dos pacientes tinham tido acesso aos CP. O objetivo deste estudo foi perceber se pacientes dos cuidados primários que não frequentam com frequência os cuidados hospitalares podem beneficiar de um algoritmo que identifique os que poderiam ser referenciados aos CP, tendo chegado à conclusão que com a implementação deste algoritmo seria possível identificar mais pacientes que teriam a sua qualidade de vida aumentada caso tivessem acesso a CP. (23)

Ainda noutro estudo onde foi desenvolvido um algoritmo de ML para prever o risco de mortalidade num ano, demonstrou-se um aumento da identificação de pacientes com risco elevado de mortalidade e ainda se demonstrou uma redução dos custos por exemplo em internamentos e medicação. 74,6% dos pacientes sinalizados que responderam a um breve inquérito referiram um aumento na qualidade de vida e 89,6% referiram que recomendariam este programa de referenciação. (24)

Outro modelo de ML desenvolvido para prever a sobrevivência em 6 meses e 1 ano, numa população de pacientes com cancro da bexiga. O modelo baseado em 6 variáveis clínicas mostrou boa discriminação na previsão da sobrevivência em 6 meses ou 1 ano, categorizando também os pacientes como de baixo ou elevado risco. (19)

4.8.2 Outcomes de saúde dos pacientes

A referenciação antecipada aos CP tem o potencial de aumentar a compreensão dos pacientes acerca da sua condição, o que leva a decisões de fim de vida mais informadas e em maior concordância com os objetivos e preferências dos pacientes. (25)

Mesmo com novas opções de tratamento, muitos pacientes com cancro avançado eventualmente chegam a uma fase em que tratamentos agressivos não vêm acompanhados de um aumento na qualidade de vida, sendo que alguns pacientes ainda recebem tratamentos intensivos nesta fase, conhecida como o fim da vida, que normalmente ocorre nos últimos meses antes da morte e na qual os pacientes devem receber cuidados focados não na cura, mas numa abordagem holística alinhada com as suas preferências. Quando os clínicos têm ferramentas que permitem estimar com precisão o prognóstico, podem encaminhar os pacientes para CP mais cedo. Para além disto, certas abordagens de CP são mais eficazes do ponto de vista económico do que os cuidados curativos, permitindo não só um aumento da qualidade de vida do paciente, como uma redução dos custos hospitalares. (26,27)

Num estudo retrospectivo onde foram usados dados de pacientes hospitalizados para a criação de um algoritmo de referenciação, com o intuito de ser usado nas 24h após a hospitalização, encontrou-se uma correlação entre a previsão de alto risco de mortalidade em 6 meses e a consequente referenciação desses pacientes aos CP. Os pacientes que morreram dentro de 6 meses após a alta apresentaram pontuações de risco previstas superiores a 10%, enquanto pacientes que não faleceram dentro do mesmo período mostraram um risco abaixo de 10%; 41% dos pacientes classificados como de alto risco de mortalidade nos 6 meses seguintes pelo modelo, tiveram acesso a consultas de CP pouco depois das suas hospitalizações e destes 41%, apenas 11% tinham tido anteriormente acesso aos CP nos 6 meses que antecederam a sua admissão no hospital. Assim, com base na correlação entre risco de mortalidade e provável necessidade de referenciação aos CP, os profissionais de saúde podem utilizar a previsão de risco realizada pelo algoritmo para estudar a necessidade de referenciação de pacientes hospitalizados. (28)

Já um estudo prospectivo usou um modelo de ML para, no segundo dia de hospitalização dos pacientes, estimar o seu risco de mortalidade em 6 meses, sendo que os que tivessem um *score* superior a um determinado limiar, ficavam sinalizados e a equipa de CP era notificada acerca da possibilidade da necessidade de uma consulta para esses pacientes. A equipa era livre de aceitar ou recusar as sugestões dadas pelo algoritmo, sendo que esta aceitou perto de metade das sinalizações, recusando as restantes por acreditar que os pacientes em questão não necessitavam de CP. Com esta dinâmica, as consultas de CP aumentaram quase 4 vezes, ocorreram um dia e meio mais cedo, diminuiu a mortalidade intra-hospitalar, diminuíram as readmissões por qualquer causa em 30 dias e as admissões e tempo de internamento nos Cuidados Intensivos. Aumentou ainda a referenciação para prestação de CP ao domicílio, sendo que este tipo de abordagem está associado a menos hospitalizações nos últimos meses de vida, menor duração das mesmas e menos idas às urgências. (21,29)

4.8.3 Variáveis clínicas consideradas mais relevantes

Os algoritmos de IA têm uma performance cada vez melhor quanto mais variáveis são utilizadas. No entanto, segundo alguns autores dos estudos incluídos, a partir de um certo número de variáveis a diferença de performance já não é estatisticamente significativa. Assim, por forma a facilitar a interpretação e utilização dos algoritmos, são selecionadas as variáveis determinadas como mais relevantes na previsão de um determinado *outcome* de saúde, através de modelos de IA ou de estatística tradicional. (27,30)

Um estudo avaliou a necessidade de pacientes hospitalizados terem uma consulta de CP nos sete dias seguintes, sendo que caso essa necessidade fosse positiva, era emitido um aviso à equipa de CP. Neste caso, a história prévia de CP, a unidade hospitalar em que o paciente se encontrava, os níveis de albumina e troponina, assim como a presença ou não de cancro metastizado eram as variáveis mais relevantes para desencadear o aviso. (31)

Num artigo acerca da pesquisa de indicadores para a análise mais precoce da necessidade de CP em pacientes com cancro do pulmão, as variáveis com maior peso foram: idade do paciente, existência de comorbilidades, independência funcional, estadio tumoral avançado, histologia tumoral e o leque de possibilidades de tratamento para o cancro em questão. (25)

Noutro estudo, onde foi criado um algoritmo de referenciação aos CP, a ser usado nas 24h após a hospitalização de pacientes, as variáveis mais relevantes foram o *Braden score* (uma escala na qual um *score* baixo significa um risco aumentado do desenvolvimento de uma úlcera de pressão), presença ou não, à admissão, de uma ordem de não reanimação, assim como a condição existente à admissão e o serviço de admissão. Outras variáveis também consideradas relevantes foram: idade, sexo, se o paciente foi transferido de uma unidade de saúde externa, número de hospitalizações nos últimos 12 meses, níveis de saturação de oxigénio e 6 análises laboratoriais à admissão: albumina, amplitude de distribuição eritrocitária, volume corpuscular médio, uremia e contagem de leucócitos e plaquetas. (28)

Ainda outro artigo, acerca da previsão da mortalidade num ano de doentes com Doença Pulmonar Obstrutiva Crónica (DPOC), os autores utilizaram como valores prognósticos o Índice de Massa Corporal, análises sanguíneas, idade, sintomas respiratórios (como o grau de obstrução das vias respiratórias, presença e número de exacerbações e se é ou não fumador) e, por fim, as comorbilidades existentes. Este modelo tenta usar variáveis que possam ser obtidas em contexto de cuidados primários por forma a facilitar a referenciação aos CP logo a partir destes. (18)

Um estudo onde foi desenvolvida uma aplicação simples que ajuda na previsão da probabilidade de mortalidade num ano, em doentes hospitalizados, as variáveis utilizadas foram a idade, a medicação aquando da hospitalização, o índice de *Charlson* (índice que prevê o risco de mortalidade em dez anos em pacientes com múltiplas comorbilidades) e o índice de *Barthel* (índice que avalia a independência funcional e capacidade de realização das atividades de vida diária (AVD)). (27)

Adicionalmente à previsão do risco de mortalidade num determinado período de tempo, um estudo tomou também em consideração a fragilidade dos pacientes, criando um

modelo de previsão baseado no índice de fragilidade de pacientes acima dos 65 anos, para ser usado em combinação com o modelo de previsão do risco de mortalidade. (32)

4.8.4 Opinião dos profissionais de saúde acerca da integração de AI na prática clínica

Um estudo dedicou-se a perceber a opinião de profissionais de saúde na área da oncologia acerca da utilidade e barreiras na utilização de algoritmos de prognóstico para melhorar as previsões de mortalidade e antecipar as conversações acerca dos objetivos e preferências de tratamento dos pacientes. Assim, é acreditado por estes profissionais que os algoritmos de IA podem ser usados como um auxílio na validação das suas próprias intuições acerca do prognóstico dos pacientes. No entanto, mostram preocupação acerca da possibilidade de erros por parte dos algoritmos, assim como o excesso de confiança nos mesmos poder levar à perda da atual dinâmica entre médico e paciente. (20)

4.8.5 Considerações éticas e de privacidade

Os desafios éticos apontados nos estudos analisados consistiram no facto de, ao haver uma previsão de mortalidade de um dado paciente, essa mesma informação terá de ser comunicada ao mesmo, o que levanta o dilema da possibilidade de a previsão estar errada, ou de o doente sobrevalorizar a mesma. (20)

Na opinião de outros autores, outro fator muito importante a ser considerado é a importância da criação de ferramentas de interpretação (*explainable AI*) capazes de explicar como é que os algoritmos chegaram às previsões que determinam a necessidade ou não de CP, assim como as variáveis que mais pesaram nas mesmas, por forma a aumentar a transparência de todo o processo e os níveis de confiança e entendimento dos profissionais de saúde nas previsões. Num estudo, foi usada uma ferramenta de interpretação que criava gráficos para representar os valores que mais afetavam o prognóstico. No entanto, os algoritmos serão sempre apenas uma ferramenta de apoio, sendo que o objetivo será sempre a decisão final ser tomada pelos profissionais de saúde. (27,33)

Capítulo 5. Discussão

Atualmente, os CP não chegam a muitas pessoas que poderiam beneficiar enormemente deles. Estes podem aumentar de forma significativa a qualidade de vida e reduzir custos de intervenções que pacientes com patologias debilitantes em fases mais avançadas já não irão provavelmente beneficiar. Acrescido a isto, ainda temos o fator de que os profissionais de saúde tendem a ser demasiado otimistas relativamente ao prognóstico dos pacientes com doenças avançadas, ou então a tentar prolongar a vida destes com tratamentos ou medicamentos que por vezes não aumentam a qualidade de vida, por vezes até acontecendo mesmo o contrário. Assim, quando nos debruçamos na questão de se o uso destes algoritmos como auxiliares de decisão ou como ferramentas de alarme para a referenciação, realmente aumenta a qualidade de vida dos pacientes, podemos verificar que as vantagens são variadas. Ao identificar pacientes que tenham um risco elevado de mortalidade num determinado intervalo temporal, é possível identificar os que o têm devido a condições reversíveis que, ao serem tratadas, podem aumentar a qualidade de vida dos pacientes e diminuir as idas ao hospital e às urgências. (20,34,35)

A identificação atempada da necessidade de referenciação aos CP permite que seja possível conversar com os pacientes acerca da sua patologia, explicar a sua condição e tomar decisões partilhadas com estes, por forma a perceber as preferências de tratamento e os seus objetivos. Simultaneamente, pacientes que realmente entendem a sua situação de saúde estão muito mais capacitados e tendem a tomar decisões mais alinhadas com as suas preferências, não caindo na ideia errada de que o correto é tentar obstinadamente tratar uma doença até aos últimos dias. (26)

Outra estatística muito relevante é que ao sinalizar os pacientes com necessidade de CP, estes serão acompanhados numa fase em que o controlo dos sintomas e a gestão de emoções é crucial, verificando-se uma diminuição nas idas à urgência, nas hospitalizações e no tempo de hospitalização, assim como uma redução nas mortes em contexto hospitalar, que tanto impacto têm tanto nas famílias como nos pacientes, que sentem que gostariam de passar as últimas horas num ambiente mais familiar para eles. A referenciação atempada também permite que alguns pacientes sejam acompanhados no domicílio, o que representa ganhos incalculáveis na qualidade de vida dos pacientes. (21,29)

Os estudos mostraram, com recurso a diferentes métricas de avaliação da *performance* dos modelos, que estes conseguem ter resultados bastante satisfatórios. Quando comparada a decisão de especialistas com a de um algoritmo acerca do tratamento de

pacientes com cancro do pulmão, com base em informações clínicas e a histologia e o estadio do cancro, a concordância média foi de cerca de 92,4%, sendo que em casos de cancro metastizado foi de 100%. (36)

Vários tipos de modelos podem ser usados para entender quais as variáveis com mais impacto nas previsões para certas populações dependendo da patologia ou da condição em questão. Podem ser desde algoritmos de ML a métodos de análise estatística para identificar a relação entre as diferentes variáveis e os *outcomes* registados. (28)

Assim, diferentes modelos podem ter diferentes finalidades para as quais desempenham melhor as suas tarefas. Temos desde *Deep Learning*, a *Random Forests*, modelos de *Natural Language Processing* e *deep Natural Language Processing*. Cada um destes modelos tem mais potencial em diferentes situações, tal como um médico que se especializa numa área específica. Por exemplo, modelos de *Natural Language Processing* e *deep Natural Language Processing* analisam a informação contida nos registos clínicos de um paciente e, com a mesma, identificam os que podem necessitar ou beneficiar de algum tipo de tratamento ou de uma referenciação a uma área em específico, trabalhando sempre estes modelos como um auxiliar de decisão dos profissionais de saúde. Os restantes modelos também já foram brevemente abordados anteriormente. (37)

Capítulo 6. Limitações e trabalho futuro

Com a presente revisão sistemática foi possível perceber que os estudos existentes acerca do uso da IA na referenciação aos CP apresentam ainda muitas limitações. Assim, é muito importante aprofundar a pesquisa nesta área por forma a entender melhor o impacto do uso destas tecnologias na saúde, assim como as suas implicações éticas e financeiras.

Uma das limitações desta revisão terá sido o facto de ser difícil ter bons conjuntos de dados que possam ser representativos da população, ou seja, os dados muitas vezes referem-se a pacientes de apenas um determinado hospital num determinado local ou então dados de apenas um tipo de patologia, o que dificulta a generalização para outras populações ou outras condições de saúde.

Como os dados não conseguem abranger todos os grupos populacionais, pode haver alguns que ao não serem representados ou estarem sub-representados, poderão ser alvo de previsões desajustadas às suas necessidades reais. Assim, os modelos dependem muito da qualidade e representatividade dos dados, logo se estes forem incompletos ou não refletirem os diversos grupos populacionais, os resultados serão tendenciosos.

Os estudos analisados demonstravam, para além do tipo de população escolhida, variações frequentes na forma como os algoritmos eram implementados, o que tornou difícil a comparação entre estudos e a generalização de certos achados e conclusões.

No que toca a limitações do processo de revisão, é de apontar a incapacidade de obter 3 artigos na íntegra, mesmo após contacto com os autores, que se enquadravam no tema e poderiam ter dados e conclusões relevantes para o tema em questão.

A nível de futuros estudos, seria importante um foco maior em estudos que avaliem os resultados da referenciação antecipada aos CP usando IA, a nível da experiência não só do paciente, mas também da família. Também seria útil perceber se efetivamente os profissionais de saúde utilizariam os algoritmos apenas como um auxiliar de decisão, por forma a não correr o risco de cair na referenciação excessiva que iria consequentemente sobrecarregar o sistema de saúde.

Capítulo 7. Conclusões

O uso da IA na referenciação de pacientes aos CP representa uma possibilidade de, se corretamente utilizada, obter avanços muito importantes na medicina. Ao longo desta revisão sistemática foram exploradas as formas como a IA pode auxiliar na identificação de pacientes com condições graves e debilitantes de saúde, que beneficiariam de cuidados mais centrados na gestão de sintomas e de emoções e não tanto na cura. A IA consegue, em muito pouco tempo, processar grandes quantidades de dados e identificar padrões que podem por vezes passar despercebidos aos profissionais de saúde.

Assim, concluímos com a resposta aos objetivos iniciais desta revisão:

7.1 Impacto do uso de algoritmos de IA na qualidade de vida dos pacientes

Apesar de a utilização da IA na medicina ainda suscitar muitas dúvidas e preocupações, os estudos demonstraram bons resultados a nível do aumento da qualidade de vida e dos *outcomes* de saúde, comprovando como o uso desta tecnologia tem o potencial de revolucionar o atual paradigma da referenciação aos CP. Verificou-se não só um aumento nas consultas de CP e na referenciação para prestação de CP ao domicílio, como também uma diminuição na mortalidade intra-hospitalar e nas admissões e tempo de internamento nos Cuidados Intensivos. Com isto, os pacientes podem ter um final de vida mais de acordo com as suas expectativas e das suas famílias evitando, dentro dos possíveis, hospitalizações recorrentes e mesmo o falecimento num ambiente não familiar.

7.2 Comparação do uso de algoritmos de IA com a referenciação exclusivamente humana e opinião dos profissionais de saúde

Podemos inferir que o uso concomitante da IA na referenciação aos CP traz vantagens relativamente à referenciação exclusivamente médica, ao sinalizar mais atempadamente pacientes que beneficiariam desses cuidados, após rapidamente processar grandes quantidades de dados que demorariam muito mais tempo aos profissionais a analisar, permitindo assim a estes dedicar mais tempo a conversar com os pacientes acerca dos seus objetivos e expectativas na gestão da sua condição.

Foi também obtida uma boa aceitação por parte dos profissionais de saúde a este tipo de tecnologia, que consideraram ser uma boa ferramenta para validar a sua intuição acerca da referenciação aos CP, permitindo a antecipação das conversas com os pacientes acerca dos seus objetivos e preferências de cuidados.

7.3 Seleção dos dados, parâmetros e técnicas de IA utilizadas na construção dos algoritmos

Os dados para a construção dos algoritmos foram retirados de bases de dados de instituições de prestação de cuidados de saúde, de *Electronic Health Records* e de bases de dados de pacientes com doenças oncológicas. Já a definição dos parâmetros considerados como mais relevantes para analisar a elegibilidade dos pacientes aos CP é realizada por modelos de ML ou mesmo por métodos de análise estatística tradicional. O objetivo é identificar padrões entre certas variáveis e os *outcomes* dos pacientes, percebendo quais serão os parâmetros com mais peso na previsão do prognóstico destes.

Relativamente ao tipo de algoritmos mais comumente utilizados, temos vários subgrupos de ML, que variam entre si não só pela forma como usam a informação que lhes é fornecida para se treinarem e, conseqüentemente, melhorarem cada vez mais a sua performance, como também na forma como fazem as previsões e a quantidade de dados que são capazes de processar.

Concluindo, é importante realçar que os profissionais de saúde terão sempre um papel preponderante na tomada de decisão, não sendo de todo o objetivo da implementação destas tecnologias a confiança cega nas mesmas. Também nunca deve ser esquecido de que o intuito será sempre cuidar e tentar aumentar a qualidade de vida dos pacientes e não de dados sem expressões faciais nem sentimentos, dando sempre prioridade à empatia para com o paciente e a tomada de decisões partilhadas com este.

Assim, apesar de parecer um desafio implementar esta nova forma de exercer medicina, esta traz inúmeras oportunidades para a melhoria da qualidade dos cuidados prestados e também para o aumento da qualidade de vida dos pacientes que deles usufruem, o que é, no final do dia, o objetivo de todos aqueles que escolheram dedicar a maior parte do seu tempo à área da saúde.

Referências Bibliográficas

1. Busnatu Ștefan, Niculescu AG, Bolocan A, Petrescu GED, Păduraru DN, Năstasă I, et al. Clinical Applications of Artificial Intelligence—An Updated Overview. Vol. 11, *Journal of Clinical Medicine*. MDPI; 2022.
2. WHO Definition of Palliative care [Internet]. [citado 16 de Agosto de 2023]. Disponível em: <https://www.who.int/news-room/fact-sheets/detail/palliative-care>
3. Wilson PM, Ramar P, Philpot LM, Soleimani J, Ebbert JO, Storlie CB, et al. Effect of an Artificial Intelligence Decision Support Tool on Palliative Care Referral in Hospitalized Patients: A Randomized Clinical Trial. *J Pain Symptom Manage*. 1 de Julho de 2023;66(1):24–32.
4. Peruselli C, Panfilis L De, Gobber G, Melo M, Tanzi S. Artificial intelligence and palliative care: Opportunities and limits [Intelligenza artificiale e cure palliative: Opportunità e limiti]. *Recenti Prog Med* [Internet]. 2020;111(11):639–45. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85096348367&doi=10.1701%2f3474.34564&partnerID=40&md5=b1991f73ac1e4246c3302e40619c69ae>
5. de Hond AAH, Leeuwenberg AM, Hooft L, Kant IMJ, Nijman SWJ, van Os HJA, et al. Guidelines and quality criteria for artificial intelligence-based prediction models in healthcare: a scoping review. Vol. 5, *npj Digital Medicine*. Nature Research; 2022.
6. Mckillip KM, Lott AD, Swetz KM. Respecting Autonomy and Promoting the Patient’s Good in the Setting of Serious Terminal and Concurrent Mental Illness. Vol. 92, *YALE JOURNAL OF BIOLOGY AND MEDICINE*. 2019.
7. Braga Da Cruz M, Nunes R. Palliative care and the portuguese health system. Vol. 1, *Porto Biomedical Journal*. Elsevier Espana S.L.; 2016. p. 72–6.
8. Peruselli C, De Panfilis L, Gobber G, Melo M, Tanzi S. Intelligenza artificiale e cure palliative: opportunità e limiti.
9. Mahesh B. Machine Learning Algorithms-A Review. *International Journal of Science and Research* [Internet]. 2018; Disponível em: www.ijsr.net
10. Storick V, O’Herlihy A, Abdelhafeez S, Ahmed R, May P. Improving palliative and end-of-life care with machine learning and routine data: a rapid review. *HRB Open Res*. 15 de Julho de 2019;2:13.
11. Pigni A, Alfieri S, Caraceni AT, Zecca E, Fusetti V, Tallarita A, et al. Development of the palliative care referral system: proposal of a tool for the referral of cancer patients to specialized palliative care. *BMC Palliat Care*. 1 de Dezembro de 2022;21(1).
12. SPICT – Supportive & Palliative Care Indicators Tool [Internet]. [citado 27 de Outubro de 2023]. Disponível em: <https://www.spict.org.uk/the-spict/spict-pt/>

13. Calsina-Berna A, Amblàs Novellas J, González-Barboteo J, Bardés Robles I, Beas Alba E, Martínez-Muñoz M, et al. Prevalence and clinical characteristics of patients with Advanced Chronic Illness and Palliative Care needs, identified with the NECPAL CCOMS-ICO© Tool at a Tertiary Care Hospital. *BMC Palliat Care*. 1 de Dezembro de 2022;21(1).
14. Moura de Azevedo S, Miguel Pereira N, Fonseca Silva I, Vidigal Bertão M, Alves lia, Arau J, et al. ARTIGOS ORIGINAIS Retrato das Necessidades Paliativas de um Serviço de Medicina Interna de um Hospital Terciário em Portugal Portrait of the Palliative Needs of an Internal Medicine Service of a Tertiary Hospital in Portugal. 30. Disponível em: <https://doi.org/10.24950/rspmi.1594>
15. Moher D, Liberati A, Tetzlaff J, Altman DG, Antes G, Atkins D, et al. Preferred reporting items for systematic reviews and meta-analyses: The PRISMA statement. Vol. 6, *PLoS Medicine*. Public Library of Science; 2009.
16. Hawker S, Payne S, Kerr C, Hardey M, Powell J. Appraising the Evidence: Reviewing Disparate Data Systematically. *Qual Health Res* [Internet]. 2002;12(9):1284–99. Disponível em: <https://doi.org/10.1177/1049732302238251>
17. Gensheimer MF, Henry AS, Wood DJ, Hastie TJ, Aggarwal S, Dudley SA, et al. Automated Survival Prediction in Metastatic Cancer Patients Using High-Dimensional Electronic Medical Record Data. *J Natl Cancer Inst*. 1 de Junho de 2019;111(6):568–74.
18. Bloom CI, Ricciardi F, Smeeth L, Stone P, Quint JK. Predicting COPD 1-year mortality using prognostic predictors routinely measured in primary care. *BMC Med*. 5 de Abril de 2019;17(1).
19. Yao Z, Zheng Z, Ke W, Wang R, Mu X, Sun F, et al. Prognostic nomogram for bladder cancer with brain metastases: A National Cancer Database analysis. *J Transl Med*. 9 de Dezembro de 2019;17(1).
20. Parikh RB, Manz CR, Nelson MN, Evans CN, Regli SH, O'Connor N, et al. Clinician perspectives on machine learning prognostic algorithms in the routine care of patients with cancer: a qualitative study. *Supportive Care in Cancer*. 1 de Maio de 2022;30(5):4363–72.
21. Soltani M, Farahmand M, Pourghaderi AR. Machine learning-based demand forecasting in cancer palliative care home hospitalization. *J Biomed Inform*. 1 de Junho de 2022;130.
22. Rhodes RL, Kazi S, Xuan L, Amarasingham R, Halm EA. Initial Development of a Computer Algorithm to Identify Patients With Breast and Lung Cancer Having Poor Prognosis in a Safety Net Hospital. *American Journal of Hospice and Palliative Medicine*. 1 de Agosto de 2016;33(7):678–83.
23. Jung K, Sudat SEK, Kwon N, Stewart WF, Shah NH. Predicting need for advanced illness or palliative care in a primary care population using electronic health record data. *J Biomed Inform*. 1 de Abril de 2019;92.

24. Zhang H, Li Y, McConnell W. Predicting potential palliative care beneficiaries for health plans: A generalized machine learning pipeline. *J Biomed Inform.* 1 de Novembro de 2021;123.
25. Kelly M, O'Brien KM, Lucey M, Clough-Gorr K, Hannigan A. Indicators for early assessment of palliative care in lung cancer patients: A population study using linked health data. *BMC Palliat Care.* 26 de Fevereiro de 2018;17(1).
26. Chalkidis G, Mcpherson J, Beck A, Newman ; Michael, Yui S, Staes C. Development of a Machine Learning Model Using Limited Features to Predict 6-Month Mortality at Treatment Decision Points for Patients With Advanced Solid Tumors [Internet]. Vol. 6, *JCO Clin Cancer Inform.* 2022. Disponível em: <https://doi.org/10.>
27. Blanes-Selva V, Doñate-Martínez A, Linklater G, Garcés-Ferrer J, García-Gómez JM. Responsive and minimalist app based on explainable ai to assess palliative care needs during bedside consultations on older patients. *Sustainability (Switzerland).* 1 de Setembro de 2021;13(17).
28. Agarwal R, Domenico HJ, Balla SR, Byrne DW, Whisenant JG, Woods MC, et al. Palliative Care Exposure Relative to Predicted Risk of Six-Month Mortality in Hospitalized Adults. *J Pain Symptom Manage.* 1 de Maio de 2022;63(5):645–53.
29. Courtright KR, Chivers C, Becker M, Regli SH, Pepper LC, Draugelis ME, et al. Electronic Health Record Mortality Prediction Model for Targeted Palliative Care Among Hospitalized Medical Patients: a Pilot Quasi-experimental Study. *J Gen Intern Med.* 15 de Setembro de 2019;34(9):1841–7.
30. Oliveira T, Silva A, Satoh K, Julian V, Leão P, Novais P. Survivability prediction of colorectal cancer patients: A system with evolving features for continuous improvement. *Sensors (Switzerland).* 6 de Setembro de 2018;18(9).
31. Murphree DH, Wilson PM, Asai SW, Quest DJ, Lin Y, Mukherjee P, et al. Improving the delivery of palliative care through predictive modeling and healthcare informatics. *J Am Med Inform Assoc.* 12 de Junho de 2021;28(6):1065–73.
32. Blanes-Selva V, Doñate-Martínez A, Linklater G, García-Gómez JM. Complementary frailty and mortality prediction models on older patients as a tool for assessing palliative care needs. *Health Informatics J.* 1 de Abril de 2022;28(2).
33. Avati A, Jung K, Harman S, Downing L, Ng A, Shah NH. Improving palliative care with deep learning. *BMC Med Inform Decis Mak.* 12 de Dezembro de 2018;18.
34. Gajra A, Zettler ME, Miller KA, Blau S, Venkateshwaran SS, Sridharan S, et al. Augmented intelligence to predict 30-day mortality in patients with cancer. *Future Oncology.* 1 de Outubro de 2021;17(29):3797–807.

35. Pierce RP, Raithel S, Brandt L, Clary KW, Craig K. A Comparison of Models Predicting One-Year Mortality at Time of Admission. *J Pain Symptom Manage.* 1 de Março de 2022;63(3):e287–93.
36. Kim MS, Park HY, Kho BG, Park CK, Oh IJ, Kim YC, et al. Artificial intelligence and lung cancer treatment decision: Agreement with recommendation of multidisciplinary tumor board. *Transl Lung Cancer Res.* 1 de Junho de 2020;9(3):507–14.
37. Leiter RE, Santus E, Jin Z, Lee KC, Yusuf M, Chien I, et al. Deep Natural Language Processing to Identify Symptom Documentation in Clinical Notes for Patients With Heart Failure Undergoing Cardiac Resynchronization Therapy. *J Pain Symptom Manage.* 1 de Novembro de 2020;60(5):948-958.e3.
38. Sullivan SS, Casucci S, Li CS. Eliminating the Surprise Question Leaves Home Care Providers With Few Options for Identifying Mortality Risk. *American Journal of Hospice and Palliative Medicine.* 1 de Julho de 2020;37(7):542–8.

Apêndice 1.

ESTRATÉGIA DE PESQUISA NAS BASES DE DADOS

Termos de pesquisa nas bases de dados:

Fez-se uma combinação de *Medical Subject Headings* (MeSH), *subject headings* e palavras-chave para realizar a pesquisa, usando operadores booleanos. Os termos de pesquisa escolhidos tentaram abranger alguns sinónimos e também vários tipos diferentes de modelos de IA, por forma a também obter artigos que pudessem não usar o termo mais abrangente “*Artificial Intelligence*”. Os termos de pesquisa foram adaptados consoante as bases de dados, devido a restrições no número de termos permitidos.

PUBMED

Index date: none to 2022-12-19

```
("palliative care"[Title/Abstract]) AND ("artificial intelligence"[Title/Abstract] OR "deep learning"[Title/Abstract] OR "machine learning"[Title/Abstract] OR "supervised machine learning"[Title/Abstract] OR "unsupervised machine learning"[Title/Abstract] OR "computation intelligence"[Title/Abstract] OR "reinforcement learning"[Title/Abstract] OR "deep neural network"[Title/Abstract] OR "electronic health records"[Title/Abstract] OR "administrative claims"[Title/Abstract] OR "clinical informatics"[Title/Abstract])) AND ("precision medicine"[Title/Abstract] OR "patient referral"[Title/Abstract] OR "decision support systems"[Title/Abstract] OR "predictive modeling"[Title/Abstract] OR "risk stratification"[Title/Abstract] OR "decision making"[Title/Abstract])
```

Clarivate Web of Science

Index date: none to 2022-12-19

```
((((((((((TS=("artificial intelligence")) OR TS=("deep learning")) OR TS=("machine learning")) OR TS=("supervised machine learning")) OR TS=("unsupervised machine learning")) OR TS=("computation intelligence")) OR TS=("reinforcement learning")) OR TS=("deep neural network")) OR TS=("electronic health records")) OR TS=("administrative claims")) OR TS=("clinical informatics") AND TS=("palliative care") AND (((((TS=("precision medicine")) OR TS=("patient referral")) OR
```

TS=("decision support systems")) OR TS=("predictive modeling")) OR TS=("risk stratification")) OR TS=("decision making"))

Scopus

Index date: none to 2022-12-19

((TITLE-ABS-KEY ("precision medicine") OR TITLE-ABS-KEY ("patient referral") OR TITLE-ABS-KEY ("decision support systems") OR TITLE-ABS-KEY ("predictive modeling") OR TITLE-ABS-KEY ("risk stratification") OR TITLE-ABS-KEY ("decision making"))) AND ((TITLE-ABS-KEY ("artificial intelligence") OR TITLE-ABS-KEY ("deep learning") OR TITLE-ABS-KEY ("machine learning") OR TITLE-ABS-KEY ("supervised machine learning") OR TITLE-ABS-KEY ("unsupervised machine learning") OR TITLE-ABS-KEY ("computation intelligence") OR TITLE-ABS-KEY ("reinforcement learning") OR TITLE-ABS-KEY ("deep neural network") OR TITLE-ABS-KEY ("electronic health records") OR TITLE-ABS-KEY ("administrative claims") OR TITLE-ABS-KEY ("clinical informatics"))) AND (TITLE-ABS-KEY ("palliative care"))

Science Direct:

Index date: none to 2022-12-19

Title, abstract, keywords: ("artificial intelligence" OR "deep learning" OR "machine learning" OR "electronic health records" OR "administrative claims" OR "clinical informatics") ("palliative care") ("patient referral" OR "decision support systems" OR "predictive modeling" OR "risk stratification")

MeSH terms:

SET1: Artificial Intelligence

SET2: Palliative Care

SET3: Patient Referral

Artificial Intelligence	Patient Referral	Palliative Care
Intelligence, Artificial	Eligibility Determination	Care, Palliative
Computational Intelligence	Determination, Eligibility	Care, Long-Term
Intelligence, Computational	Determinations, Eligibility	Long Term Care
Machine Learning	Eligibility Determinations	Patient care
Learning, Machine	Eligibility Certification	Care, terminal
Machine Intelligence	Certification, Eligibility	End-of-life care
Intelligence, Machine	Referral	
Computer Reasoning	Hospital referral	

Reasoning, Computer AI (Artificial Intelligence) Computer Vision System System, Computer Vision System, Computer Automated Medical Records Systems Computerized Medical Record Systems Medical Informatics Medical Informatics Applications Information Systems Clinical Decision Support Systems Clinical Decision Support Decision Supports, Clinical Support, Clinical Decision Decision Support, Clinical Decision Making, Computer Assisted Computer-Assisted Decision Making Medical Decision Making, Computer-Assisted Health Information System Information System, Health Information Systems, Health System, Health Information Systems, Health Information Algorithms Data Analysis	Referral, Hospital Gatekeepers, Health Service Gatekeeper, Health Service Health Service Gatekeeper Consultation, Ethics Ethics Consultations	
--	--	--

SET 1:

"artificial intelligence" OR "deep learning" OR "machine learning" OR "supervised machine learning" OR "unsupervised machine learning" OR "computation intelligence" OR "reinforcement learning" OR "deep neural network" OR "electronic health records" OR "administrative claims" OR "clinical informatics"

SET 2:

"palliative care"

SET 3:

precision medicine" OR "patient referral" OR "decision support systems" OR "predictive modeling" OR "risk stratification" OR "decision making"

Apêndice 2.

QUALITY APPRAISAL ASSESSMENT CRITERIA (Hawker et al.'s, 2002)

Autores/Ano de publicação	Abstract e Título	Introdução e Objetivos	Métodos e Dados	Amostr a	Análise de dados	Ética e Viés	Resultados	Transferibilidade e Generalização	Implicações e Utilidade	TOTAL
<i>Pierce et al. 2022</i>	3	3	2	4	4	3	3	3	4	29
<i>Kim et al. 2020</i>	4	4	3	3	4	4	3	3	3	31
<i>Gajra et al. 2021</i>	3	3	4	3	3	4	3	3	3	29
<i>Gensheimer et al. 2018</i>	3	3	4	4	4	3	4	2	3	30
<i>Parikh et al. 2022</i>	4	3	3	3	3	3	3	4	4	30
<i>Blanes-Selva et al. 2022</i>	3	4	4	3	4	3	4	4	4	33
<i>Leiter et al. 2020</i>	4	4	3	3	3	3	3	3	4	30
<i>Chalkidis et al. 2022</i>	4	4	4	3	4	4	4	3	4	34
<i>Courtright et al. 2019</i>	3	4	4	3	3	3	3	4	4	31
<i>Sullivan et al. 2020</i>	3	4	4	3	4	3	4	3	3	31
<i>Avati et al. 2018</i>	3	4	4	4	4	3	3	4	4	33
<i>Murphree et al. 2021</i>	4	4	4	3	4	3	4	4	4	34
<i>Kelly et al. 2018</i>	4	4	4	4	3	3	3	3	4	32
<i>Rhodes et al. 2016</i>	4	4	3	3	3	4	3	3	2	29
<i>Soltani et al. 2022</i>	4	4	4	3	3	3	3	3	4	31
<i>Agarwal et al. 2022</i>	4	3	3	4	3	3	4	3	3	30
<i>Bloom et al. 2019</i>	4	4	3	4	3	3	3	3	3	30
<i>Jung et al. 2019</i>	4	4	4	4	4	4	4	3	4	35
<i>Zhang et al. 2021</i>	3	4	4	3	3	3	3	4	4	31
<i>Yao et al. 2019</i>	4	4	3	4	2	4	2	2	3	28
<i>Blanes-Selva et al. 2021</i>	4	4	4	3	3	4	3	2	4	31
<i>Oliveira et al. 2018</i>	3	4	4	3	3	3	3	3	4	30

Apêndice 3.

EXTRAÇÃO DE DADOS DOS ARTIGOS INCLUÍDOS NA REVISÃO

Referência	População	Intervenção	Contexto	Resultados	Notas
Pierce et al. 2022 (35)	93 941 pacientes hospitalizados/admissões hospitalares	Comparar o uso de modelos de <i>Random Forest</i> para criar um modelo de regressão logística para identificar pacientes com risco de mortalidade um ano após admissão, usando dados demográficos e dados recolhidos à admissão.	Ao identificar pacientes que podem falecer um ano após admissão hospitalar, podemos começar a conversar com estes acerca de objetivos e preferências de final de vida.	O modelo <i>Random Forest</i> provou ser mais sensível e possuir valores preditivos positivos e negativos mais altos.	As intervenções no final da vida são subutilizadas, sendo que estas podem melhorar a qualidade de vida e reduzir os custos de saúde. A admissão hospitalar é um momento propício para identificar esses pacientes usando dados disponíveis. Existe uma "lacuna de implementação" com modelos de ML, pois as informações sobre os efeitos de sua implementação são escassas. O uso de modelos de ML é superior aos modelos de regressão logística, de acordo com vários estudos, para identificar pacientes de alto risco.
Kim et al. 2020 (36)	405 pacientes diagnosticados com cancro do pulmão que ainda não tinham previamente recebido tratamento antitumoral no Hospital Nacional Chonnam University Hwasun.	A análise foi realizada utilizando o <i>Watson for Oncology</i> , um sistema de computação que explora opções de tratamento, considerando 4 opções de tratamento: cirurgia, radioterapia, quimiorradioterapia e cuidados paliativos. De seguida, essas opções foram comparadas com a opinião de uma equipa multidisciplinar.	Comparar o uso de um sistema de computação cognitiva (algoritmos de ML e técnicas de <i>Natural Language Processing</i>) com a opinião de uma equipa multidisciplinar, para identificar informações-chave do paciente e opções de tratamento em pacientes com cancro do pulmão.	As conclusões foram altamente semelhantes entre os algoritmos e a equipa multidisciplinar, especialmente para o cancro em estadio metastático, independentemente da histologia, com 100% de concordância entre a equipa e as decisões do <i>Watson for Oncology</i> . A concordância geral entre a equipa multidisciplinar e o <i>Watson for Oncology</i> foi de 92,4%.	Os pacientes foram analisados com base em algumas características, como idade, sexo, estado funcional de acordo com o <i>Eastern Cooperative Oncology Group</i> , histologia do cancro e estadio da doença. Os casos de cancro de pulmão de não pequenas células de estágio I e IV e cancro de pulmão de células pequenas em estágio avançado tiveram altas taxas de concordância. As taxas de concordância nos estágios II e III do cancro de pulmão de não pequenas células e no de células pequenas foram mais baixas. Algumas discordâncias entre o modelo e a equipa multidisciplinar ocorreram devido a diversos fatores relacionados ao paciente, como comorbilidades, preferências do paciente, seguro de saúde ou situação socioeconómica.

<p><i>Gajra et al. 2021</i> (34)</p>	<p>Pacientes com cancro. População geral de pacientes (n=3671). Subpopulação A (n=1732): com mais de 18 anos e pelo menos 2 consultas médicas nos últimos 180 dias. Subpopulação B (n=3053): com mais de 18 anos e pelo menos 1 consulta médica nos últimos 180 dias.</p>	<p>Os pacientes foram divididos em dois conjuntos, um para treinar o modelo e outro para testá-lo. O modelo de ML utilizou dados socioeconómicos, comportamentais, ambientais e clínicos em EHR de pacientes anonimizados para prever o risco de mortalidade em 30 dias no noroeste do Pacífico dos Estados Unidos da América.</p>	<p>O desempenho do modelo foi determinado pela comparação entre a data de morte registada nos EHR e a previsão fornecida pelo algoritmo de ML. A medida principal de resultados foi a mortalidade em 30 dias e após essa foi a mortalidade em 60, 90 e 180 dias. O algoritmo também identificou os principais 5% de pacientes em risco de mortalidade nos próximos 30 dias.</p>	<p>Para os pacientes que o algoritmo de ML identificou como sendo de maior risco para mortalidade em 30 dias, a <i>area under the curve</i> (AUC, que indica a capacidade do modelo de fazer previsões corretas) para o modelo de mortalidade em 30 dias foi de 0,86 (sensibilidade: 28,1% e especificidade: 95,2%). Valores semelhantes foram obtidos para mortalidade em 60, 90 e 180 dias. A AUC sugere que o modelo tem boa capacidade de discriminação para distinguir pacientes que experimentarão mortalidade em 30 dias daqueles que não o farão. Os pacientes marcados pelo algoritmo como de alto risco (risco 6,7 a 7,4 vezes maior do que os pacientes considerados de baixo risco) tiveram taxas de mortalidade significativamente mais altas (4,9%-7,2%). As taxas de mortalidade aumentaram em 60, 90 e 180 dias, e os 5% dos pacientes identificados pelo algoritmo como de maior risco atingiram um risco de mortalidade 8,5 vezes maior do que os de menor risco.</p>	<p>O desempenho do modelo melhora à medida que mais dados são fornecidos. Este estudo demonstra que a identificação de pacientes em risco de mortalidade devido a complicações reversíveis pode melhorar os seus outcomes ou garantir a sua integração nos cuidados paliativos, além de melhorar a qualidade de vida de pacientes em fase terminal. Também seria possível reduzir as visitas ao departamento de emergência e os internamentos não planeados.</p>
<p><i>Gensheimer et al. 2018</i> (17)</p>	<p>12 588 pacientes com cancro metastático no sistema de Saúde de Stanford, de 2008 a 2017.</p>	<p>Os pacientes foram divididos em dois grupos, um para treinar o modelo e outro para testá-lo, com o objetivo de utilizar um algoritmo para prever a sobrevivência de pacientes com cancro metastático. A previsão do tempo de sobrevivência dos pacientes ocorreu não apenas a partir do</p>	<p>Comparar o uso de modelos prognósticos mais simples que usam variáveis introduzidas pelo médico, com o uso de um modelo prognóstico automatizado que utiliza dados dos EHR e milhares de variáveis preditivas. Para o conjunto de teste, o desempenho do modelo na determinação do prognóstico de pacientes em tratamento de</p>	<p>O modelo demonstrou uma precisão superior na taxa de sobrevivência em comparação com modelos prognósticos anteriores. O índice C no conjunto de teste foi de 0,786. Para os pacientes em tratamento de radioterapia paliativa, o índice C também foi superior aos outros modelos prognósticos. O modelo foi capaz de identificar áreas de melhoria, uma vez que,</p>	<p>A fonte mais valiosa de informação para construir os conjuntos de dados foi o texto das notas médicas, seguido de diagnósticos, procedimentos e medicamentos, e por último, sinais vitais e análises laboratoriais. Estes modelos também podem ser usados para analisar padrões de prática e possíveis áreas de melhoria.</p>

		momento do diagnóstico do cancro metastático, mas também a partir de momentos posteriores, usando dados dos EHR.	radioterapia paliativa foi comparado com o de dois modelos prognósticos já existentes.	entre os pacientes em tratamento de Radioterapia paliativa, alguns dos que foram previstos para viver menos de 6 meses estavam a receber pelo menos 10 frações de radiação quando poderiam receber apenas uma, reduzindo significativamente os efeitos colaterais.	
<i>Parikh et al. 2022 (20)</i>	29 médicos oncologistas e prestadores de cuidados avançados em 6 locais diferentes de prática oncológica terciária ou comunitária dentro de um centro académico. Alguns destes médicos já tinham sido expostos a um algoritmo de prognóstico de ML.	Realizar entrevistas telefónicas para compreender a opinião e percepção dos clínicos sobre o uso e as barreiras dos algoritmos de prognóstico de ML para melhorar as previsões de risco de mortalidade e permitir conversas mais antecipadas sobre os objetivos e preferências de cuidados.	Melhorar os cuidados no final de vida através da melhoria das previsões de risco de mortalidade de pacientes com cancro. Compreender se existem diferenças na opinião dos médicos que já tinham sido expostos a algoritmos de previsão em comparação com aqueles que não tinham.	Os clínicos acreditam que os algoritmos podem ser usados para prognósticos avançados e ajudá-los a validar a sua própria intuição sobre o prognóstico, especialmente em pacientes cuja doença é difícil de prever, permitindo antecipar conversas com os pacientes sobre os seus objetivos e preferências. No entanto, também estão preocupados com a precisão dos algoritmos e com a possibilidade de se criar uma dependência excessiva das suas previsões que poderia levar à perda da relação humana e a implicações éticas. Os desafios éticos estão relacionados com o facto de que a previsão teria sempre de ser partilhada com os pacientes e, no caso de erros do algoritmo, isso levanta um dilema sobre partilhar essas previsões com os pacientes.	Os oncologistas podem ter uma visão excessivamente otimista do prognóstico dos seus pacientes com cancro, o que pode resultar em atrasos de discussões importantes sobre os objetivos dos pacientes e a qualidade dos cuidados que recebem no final da vida (menos quimioterapia no final da vida e aumento da adesão aos cuidados paliativos). No futuro, é importante considerar uma estratégia para notificar os clínicos quando um paciente tem um alto risco de mortalidade, uma vez que a "fadiga de alerta" é um fenómeno crescente. Os vieses de confirmação e automação são riscos inerentes aos algoritmos de prognóstico de ML (se o algoritmo for treinado com dados pouco diversificados este pode ter tendência para confirmar esses padrões em vez de procurar ou ponderar realidades diferentes ou mais complexas).
<i>Blanes-Selva et al. 2022 (32)</i>	Registos de admissão hospitalar de 1 de janeiro de 2011 a 31 de dezembro de 2018, para pacientes com mais de 65 anos. Foram excluídos pacientes psiquiátricos e obstétricos. O conjunto de dados continha 39 310 episódios de hospitalização	Desenvolvimento de ferramentas de ML para prever a mortalidade e fragilidade de pacientes idosos, oncológicos e não oncológicos, a fim de auxiliar na identificação de pacientes que necessitam de Planeamento de Cuidados Avançados. Os	Criação de três modelos de previsão complementares: um modelo de mortalidade de 1 ano, um modelo de regressão de sobrevivência para prever o número de dias desde a admissão até a morte e uma escala de fragilidade para prever o índice de fragilidade 1 ano após a admissão.	O modelo de mortalidade de 1 ano classificou-se como um dos melhores modelos em termos de AUC. A regressão de sobrevivência também superou outros modelos já existentes. A associação entre fragilidade e mortalidade está documentada, pelo que os autores sugerem que as	Ao usar o horizonte de risco de mortalidade a 1 ano, os profissionais de saúde podem lidar melhor com as necessidades imediatas dos pacientes. A integração destes modelos na prática clínica pode ajudar os profissionais de saúde a antecipar o declínio do paciente e alocar recursos de forma mais eficaz. A principal contribuição deste estudo é o desenvolvimento de um modelo preditivo

	(correspondentes a 19.753 pacientes).	modelos preditivos utilizados foram <i>Gradient Boosting Machines</i> e <i>Deep Neural Networks</i> .	Comparação destes com ferramentas de previsão já existentes.	duas variáveis são importantes, devendo ser consideradas como critérios complementares. O modelo preditivo de fragilidade baseado no Índice de Fragilidade de pacientes com mais de 65 anos será uma grande melhoria na identificação de pacientes que necessitam de Planeamento de Cuidados.	de fragilidade, o que complementa a abordagem tradicional de mortalidade.
<i>Leiter et al. 2020 (37)</i>	Coorte de pacientes com insuficiência cardíaca com fração de ejeção reduzida no Brigham and Women's Hospital e Massachusetts General Hospital que foram submetidos à implantação de terapia de ressincronização cardíaca entre janeiro de 2004 e dezembro de 2015. Amostra aleatória de 154 notas de alta hospitalar de hospitalizações de 115 pacientes que ocorreram antes da implantação de terapia de ressincronização cardíaca.	Desenvolvimento, treino e teste de um modelo de <i>Natural Language Processing</i> para identificar sintomas nos EHR e prever quais pacientes com insuficiência cardíaca congestiva beneficiam de terapia de ressincronização cardíaca.	A precisão, a precisão, a sensibilidade e o score F1 (medida combinada de precisão e sensibilidade) foram usados para comparar o desempenho do modelo com as anotações dos investigadores. As pontuações variaram de 0 a 1, sendo 0 a pior e 1 a melhor precisão e sensibilidade.	O modelo de <i>deep Natural Language Processing</i> identificou 64% dos sintomas presentes, 71% dos sintomas ausentes e 41% dos sintomas dependentes de contexto, com uma precisão de 79%, 79% e 58%, respetivamente, quando comparado com a codificação manual. Foram identificados alguns problemas, por exemplo, quando uma única palavra num sintoma de várias palavras era perdida pelo modelo, este não conseguia reconhecer o sintoma e toda a frase se tornava um falso negativo. A precisão foi de 77,6%, com 47 palavras marcadas incorretamente como sintomas.	No passado, a extração de sintomas de notas clínicas exigia abstração manual de registos, o que era ineficiente e demorado. No entanto, os avanços em inteligência artificial, especificamente em <i>Deep Learning</i> , oferecem o potencial para melhorar este processo. Ao combinar <i>Natural Language Processing</i> com algoritmos de <i>Deep Learning</i> , podem ser aprendidos padrões flexíveis e generalizáveis a partir de conjuntos de notas de texto livre, tornando a identificação de sintomas mais eficiente e adaptável, melhorando os processos de tomada de decisão.
<i>Chalkidis et al. 2022 (26)</i>	4.192 pacientes com tumores sólidos avançados (cancro maligno do cérebro ou sistema nervoso ou qualquer outro tumor sólido com metástases) que receberam cuidados no âmbito da University of Utah Health. Com 18 anos ou mais, data de diagnóstico de tumores sólidos avançados	Utilização de um algoritmo de ML para prever o risco de mortalidade em 6 meses em pacientes com tumores sólidos avançados, nos momentos de decisão de tratamento para novas linhas terapêuticas, usando dados de EHR. Estratificação de risco de pacientes.	Ao identificar melhor os pacientes em risco, podemos melhorar a toma de decisões compartilhadas entre pacientes e clínicos. Quando ambas as partes têm uma compreensão clara do prognóstico e dos resultados previstos do tratamento, isso pode levar a um melhor alinhamento dos cuidados com as expectativas de fim de vida do paciente.	Clínicos escolheram um conjunto específico de características preditivas e relevantes. Ao prever o risco de mortalidade em 6 meses em vários momentos de decisão de tratamento, considerando diferentes linhas de tratamento, o modelo completo alcançou uma AUC de 0,81 (com um intervalo de confiança de 95% de 0,79 a 0,82). No grupo de pacientes com tumores sólidos avançados, a taxa de mortalidade aos 6 meses aumentou constantemente à	Entre os pacientes que foram previstos como tendo uma baixa probabilidade de sobrevivência e que de facto faleceram dentro de 6 meses, em média apenas 15% deles foram encaminhados para hospícios, 51% para cuidados paliativos e 60% foram hospitalizados entre o momento da decisão de tratamento e a sua morte.

	registada entre 1/06/2014 e 1/06/2020.			medida que progrediram através de diferentes linhas de tratamento. Começou em 18% após o início da primeira linha de tratamento e atingiu 47% após o início da sexta linha. Isto destaca a importância de melhorar a precisão da previsão de mortalidade ao considerar novas linhas de tratamento.	
<i>Courtright et al. 2019 (29)</i>	Este estudo envolveu uma ampla variedade de pacientes (64.246 admissões entre 46.305 pacientes únicos) que se previa terem uma alta probabilidade de falecer nos próximos 6 meses.	O <i>Palliative Connect</i> , uma abordagem que combina análises preditivas com consultas oportunas, poderia melhorar a prestação de cuidados paliativos num ambiente hospitalar. Utiliza modelos de previsão de ML com informações dos EHR para identificar pacientes com risco de falecer nos próximos 6 meses e, em seguida, desencadeiam uma consulta de cuidados paliativos no segundo dia de internamento.	Em cada dia útil, foi calculada uma pontuação que indicava o risco estimado de morte de um paciente nos próximos 6 meses (pontuação do <i>Palliative Connect</i>) para aqueles que estavam no segundo dia de internamento hospitalar. Os pacientes com uma pontuação de 0,3 ou superior eram listados numa interface baseada na web. Esta lista ordenava os pacientes do maior para o menor risco (a previsão de risco real não era visível). A enfermeira de triagem da equipa de cuidados paliativos contactava os clínicos que tratavam esses pacientes por ordem decrescente na lista. Aos clínicos foi dada a opção de recusar a consulta automaticamente desencadeada.	As consultas de cuidados paliativos aumentaram quase 4 vezes em comparação com o grupo de controlo, ocorreram um dia e meio mais cedo e com taxas mais elevadas de documentação de Planeamento Antecipado de Cuidados. Houve também um aumento nas referências para cuidados paliativos em casa e para hospícios. Houve diminuições significativas na mortalidade hospitalar, readmissões por todas as causas dentro de 30 dias, admissões na unidade de cuidados intensivos e no tempo de permanência na Unidade de Cuidados Intensivos. A equipa principal aceitou quase metade das consultas desencadeadas. Para as consultas recusadas, os clínicos acreditavam que o paciente não necessitava de cuidados paliativos.	
<i>Sullivan et al. 2020 (38)</i>	Pacientes nos serviços de cuidados ao domicílio durante janeiro de 2012, com um total de 69 097 indivíduos incluídos.	Criar um método prático que auxilia os prestadores de cuidados ao domicílio na avaliação da probabilidade de deterioração ou morte em indivíduos idosos que estão a receber serviços de cuidados ao domicílio especializados,	Após a divisão dos pacientes em "vivos" ou "não vivos", após 24 meses, analisaram as suas pontuações totais nas AVD, usando um algoritmo <i>k-means</i> para agrupar essas pontuações, que é uma ferramenta de IA que ajuda a encontrar padrões em grandes conjuntos de	O OASIS-SQ fornece uma ferramenta valiosa, embora restrita, para avaliar o potencial declínio ou risco de mortalidade de um indivíduo tanto aos 12 como aos 24 meses. A "pontuação total de AVD" e o OASIS-SQ, exibem uma concordância modesta, mas	A abordagem de referenciar pacientes com base em intuição geral apenas, é suscetível de resultar em casos em que pacientes que poderiam beneficiar de serviços de cuidados paliativos ou de hospício possam não ser encaminhados de forma adequada.

		especialmente agora que o OASIS-SQ (uma combinação das ferramentas de avaliação de saúde "Home Health Outcomes and Assessment Information" e a "Surprise Question")	dados, identificando relações. Examinar o nível de concordância entre grupos baseados em "pontuações totais de AVD", o OASIS-SQ e a mortalidade aos 24 meses.	significativa. É justificável utilizar a "pontuação total de AVD" como substituto do OASIS-SQ.	
Avati et al. 2018 (33)	Dados de EHR de 221.284 pacientes do Hospital Stanford ou do Hospital Infantil Lucile Packard, armazenados numa base de dados entre 1990 e 2014.	Utilizar técnicas de ML e dados de EHR dos pacientes para treinar um modelo de <i>Deep Neural Network</i> com base em dados de EHR de anos anteriores. O modelo foi projetado para prever a mortalidade do paciente dentro de um período de 3 a 12 meses.	O resultado desta previsão serve para identificar pacientes que podem beneficiar dos cuidados paliativos. Esta abordagem elimina a necessidade da equipa de cuidados paliativos de rever manualmente os registos de cada admissão.	Utilizando informações de EHR é possível desenvolver um modelo capaz de prever a mortalidade por todas as causas, o que pode servir como um indicador da necessidade de uma consulta de cuidados paliativos. Também foi introduzida uma abordagem inovadora para gerar explicações a partir das previsões de modelos complexos de <i>Deep Learning</i> , o que ajuda a aumentar a confiança dos profissionais quando tomam decisões com base nas sugestões do sistema. O modelo de ML teve uma pontuação de previsão média de 0,69 (0,65 para pacientes admitidos) e uma AUROC de 0,93 (0,87 para pacientes admitidos).	Quando se trata de decisões clínicas automatizadas, é crucial construir a confiança do profissional nas escolhas do modelo para garantir o seu conforto com as decisões tomadas. Fornecer explicações juntamente com essas decisões desempenha um papel significativo em fortalecer essa confiança. O fator humano continua a ser essencial, tomando sempre a decisão final sobre se avançar com uma consulta após examinar cuidadosamente o histórico do paciente.
Murphree et al. 2021 (31)	Dados de 68.349 registos de encontros de 50.143 pacientes (com 18 anos de idade ou mais) que foram admitidos num hospital da Mayo Clinic durante o período de um ano, de 1 de janeiro de 2017 a 31 de dezembro de 2017.	Os dados dos EHR foram usados para treinar um modelo de ML para prever a necessidade de uma consulta de cuidados paliativos.	O objetivo é prever a probabilidade de um paciente ter uma consulta de cuidados paliativos ocorrer nos próximos 7 dias. Quando essa probabilidade ultrapassa um limite predeterminado, serve como um gatilho, desencadeando uma notificação à equipa de CP, ajudando a garantir uma comunicação e intervenção atempadas da equipa quando necessário.	O modelo alcançou um valor de AUC de 0,90. Entre os mais de 500 pacientes avaliados na aplicação do mundo real entre 14 de novembro de 2019 e 13 de janeiro de 2020, a equipa de cuidados paliativos aceitou 43% dos pacientes que ultrapassaram este limite, rejeitando apenas 29% (com 28% adiados para o dia seguinte). As variáveis mais influentes foram o histórico anterior de cuidados paliativos dos pacientes, a unidade hospitalar em que estavam, os	Em contraste com métodos anteriores, este estudo prevê diretamente consultas de cuidados paliativos em vez de usar a mortalidade como medida indireta. Usar a mortalidade como substituto é menos eficaz, uma vez que numerosos pacientes podem beneficiar de consultas de cuidados paliativos mesmo que o seu risco imediato de mortalidade seja mínimo. Foram implementados os resultados do modelo num ambiente operacional do mundo real e integraram as previsões de forma contínua no fluxo de trabalho prático de uma equipa de cuidados paliativos.

				níveis de Albumina e Troponina, bem como se tinham cancro metastático.	
<i>Kelly et al. 2018 (25)</i>	Foram incluídos 16.638 pacientes com diagnóstico recente de cancro do pulmão entre 2005 e 2012, inclusive, que faleceram antes de 01/01/2014 (n=14.228). Os dados de alguns pacientes eram insuficientes, pelo que foram considerados 13.845 casos no conjunto de dados final. Estes dados dos pacientes foram obtidos do Registo Nacional de Cancro da Irlanda (dados hospitalares).	Foi utilizado um processo de duas etapas para construir um modelo preditivo para determinar se ocorreu morte nos 30 dias seguintes ao diagnóstico (sim ou não) utilizando uma análise de regressão logística. Na primeira etapa, foi estudada a influência dos atributos do paciente prontamente acessíveis no momento da apresentação. Em seguida, os efeitos de fatores clínicos (como histologia do tumor e estadiamento) foram avaliados ao incorporá-los no modelo.	Comparar indivíduos que faleceram nos 30 dias seguintes ao diagnóstico com aqueles que viveram mais tempo. Esta comparação foi realizada utilizando métodos estatísticos como regressão logística.	Descobriu-se que pacientes com 80 anos ou mais, com qualquer comorbidade existente e que passaram por internamentos de emergência no momento do diagnóstico, têm uma maior probabilidade de falecer nos 30 dias seguintes ao diagnóstico em comparação com pacientes mais jovens sem comorbidades que foram internados eletivamente. Essas características identificáveis, presentes no momento do diagnóstico, podem servir como elementos preditivos valiosos para orientar decisões sobre o início oportuno de cuidados paliativos para indivíduos com cancro do pulmão.	A pesquisa demonstrou que a administração de cuidados paliativos numa fase inicial a indivíduos diagnosticados com cancro do pulmão de não pequenas células metastático pode resultar em períodos de sobrevivência mais longos e numa redução da utilização de tratamentos médicos intensivos durante as fases finais da vida, em contraste com pacientes que recebem cuidados convencionais. Pacientes com períodos de sobrevivência mais longos têm maior probabilidade de receber tratamentos direcionados para o tumor, que estão associados a melhores resultados de sobrevivência. Devido aos períodos de sobrevivência notavelmente curtos, torna-se crucial identificar indicadores precoces para a avaliação dos cuidados paliativos.
<i>Rhodes et al. 2016 (22)</i>	Foram obtidas informações, tanto clínicas como não clínicas, a partir dos registos eletrónicos de saúde de 369 pacientes com cancro da mama (42%) e cancro do pulmão (58%) (com ou sem metástases) que estiveram internados num importante centro médico urbano (Hospital <i>Parkland</i>) durante o ano de 2010.	Detalhar a criação de um algoritmo capaz de identificar em tempo real pacientes com cancro avançado que poderiam beneficiar de discussões sobre as suas opções de cuidados. Estas incluem o planeamento antecipado dos cuidados, cuidados paliativos e, se desejado, serviços de hospício.	Avaliar a precisão do algoritmo comparando a sua sensibilidade, especificidade e valores preditivos com as avaliações médicas. Além disso, analisar a validade deste método investigando as taxas de sobrevivência destes pacientes.	O algoritmo baseou-se em informações sobre a existência de doença metastática e níveis baixos de albumina em pacientes com cancro do pulmão e da mama que foram admitidos num hospital. O algoritmo apresentou uma elevada especificidade e um valor preditivo positivo forte, atingindo 96% e 91%, respetivamente. No entanto, a sua sensibilidade e valor preditivo negativo foram comparativamente mais baixos, com 21% e 42%, respetivamente. Apesar disso, o algoritmo demonstrou uma sólida validade de construção, uma vez que os casos assinalados pelo algoritmo apresentaram taxas de	Os resultados de sobrevivência para indivíduos que testaram positivo utilizando o algoritmo foram significativamente piores do que aqueles que testaram negativo. Embora a sensibilidade e o valor preditivo negativo do algoritmo tivessem margem para melhorias, tal indica que futuras interações do algoritmo devem incorporar variáveis adicionais para melhorar a sua precisão.

				sobrevivência significativamente mais baixas.	
<i>Soltani et al. 2022 (21)</i>	<p>Foram realizados testes utilizando um conjunto de dados com mais de 4000 pacientes com cancro que tinham uma pontuação na Escala de Desempenho Paliativo de 40 ou menos. Estes pacientes foram dados como alta de um hospital para as suas casas através de um serviço de hospitalização domiciliária prestado por um centro nacional de cuidados paliativos no Irão. Os dados abrangeram o período de setembro de 2012 a julho de 2019.</p>	<p>Desenvolvimento de dois modelos de <i>Deep Learning</i>: um modelo opera ao nível individual, prevendo o serviço necessário para um paciente específico com dados demográficos e de saúde conhecidos, ajudando isto a prevenir visitas de emergência, agendando consultas periódicas; outro modelo, que opera ao nível da população, antecipa os requisitos de serviço da próxima semana em várias categorias para um centro que atende a um grupo de pacientes distintos.</p>	<p>Equilibrar a oferta e a procura com os pedidos urgentes e problemas de transporte, representou dificuldades num centro que fornece cuidados paliativos a pacientes com cancro, devido à notável flutuação na procura. A pesquisa visava otimizar a alocação de serviços neste contexto complexo.</p>	<p>Os modelos de <i>Deep Learning</i> introduzidos demonstraram proficiência na previsão da procura, tanto ao nível individual quanto ao nível populacional. O modelo focado em indivíduos alcançou uma precisão média de 69,75% e um F1 score (métrica usada para avaliar a precisão e confiabilidade de um modelo de classificação binária) de 66,8%. Além disso, realizou-se uma comparação entre o desempenho do modelo e o de duas técnicas tradicionais de previsão, ambas pertencentes à categoria de auto-regressão. Os resultados revelaram uma substancial superioridade do modelo de IA em comparação aos métodos de auto-regressão. Essa vantagem pode ser atribuída à excepcional capacidade das <i>Deep Neural Networks</i> de extrair características e compreender padrões complexos nos dados, melhorando assim a sua precisão preditiva.</p>	<p>Prever a procura futura para pacientes individuais melhora o planeamento de recursos, eleva a qualidade do serviço e reduz as admissões hospitalares desnecessárias e mortes indesejadas.</p>
<i>Agarwal et al. 2022 (28)</i>	<p>O desenvolvimento do modelo incluiu 176.672 internamentos de adultos de 1 de outubro de 2013 a 1 de outubro de 2017. Um conjunto distinto de casos, abrangendo o período de 1 de janeiro de 2018 a 31 de julho de 2020, foi reunido separadamente para validação.</p>	<p>O objetivo é criar um modelo preditivo em tempo real que possa estimar a probabilidade de mortalidade de um paciente dentro de seis meses. Este modelo será desenvolvido usando informações clínicas e laboratoriais regularmente obtidas nas primeiras 24 horas de internamento.</p>	<p>Auxiliar no prognóstico clínico e na tomada de decisões, melhorando a prestação de cuidados paliativos de forma a otimizar os cuidados no final da vida.</p>	<p>As variáveis com associação mais robusta com a mortalidade em 180 dias foram: Pontuação de <i>Braden</i> (relativa a risco de desenvolver úlcera de pressão), presença de ordem de não ressuscitação, estado de admissão e serviço.</p>	

<p><i>Bloom et al. 2019 (18)</i></p>	<p>Foram selecionados dois grupos de participantes. O primeiro grupo (n=54.990) começou em 1 de janeiro de 2010, com uma data de índice específica definida como a sua primeira revisão anual da DPOC a ocorrer 12 meses após a elegibilidade. Este grupo foi usado para desenvolver e validar o modelo de prognóstico internamente. O segundo grupo (n=4931), sem datas registradas de revisões anuais, tinha dados a partir de 1 de janeiro de 2004, e a data de índice foi determinada como o dia seguinte a 12 meses de dados elegíveis.</p>	<p>Desenvolver um instrumento preditivo (índice BARC) utilizando fatores comuns recolhidos no ambiente de cuidados primários que tem como objetivo fornecer um prognóstico de mortalidade de 12 meses para pacientes típicos com DPOC.</p>	<p>A adoção de cuidados paliativos para DPOC avançada continua limitada, em parte devido aos desafios na previsão precisa da mortalidade de um ano.</p>	<p>Quando avaliado usando validação externa, o índice BARC demonstrou níveis satisfatórios de precisão. As capacidades preditivas do modelo foram mais favoráveis em comparação com outros índices de avaliação clínica para prever <i>outcomes</i> de pacientes com DPOC. A AUROC para o índice BARC permaneceu consistentemente acima das curvas correspondentes aos outros índices.</p>	<p>A sigla 'BARC' foi atribuída ao índice, refletindo os seus componentes relacionados com possíveis elementos prognósticos. Estes componentes incluem o índice de massa corporal e resultados sanguíneos (B), idade (A), fatores respiratórios (como obstrução do fluxo de ar, exacerbações e tabagismo) (R) e comorbidades (C). Isto pode facilitar uma estratégia de cuidados paliativos iniciada a partir dos cuidados primários. A incorporação de fatores clínicos adicionais, especialmente comorbilidades, melhora substancialmente a eficácia preditiva do modelo.</p>
<p><i>Jung et al. 2019 (23)</i></p>	<p>Dados de 349.667 pacientes recolhidos entre julho de 2011 e junho de 2014. Os participantes do estudo preenchiam critérios se tivessem uma relação de cuidados primários com a Sutter Health (pelo menos duas visitas a médicos específicos) e idades entre os 65 e os 89 anos. Os pacientes foram divididos em 4 subpopulações, nomeadamente aqueles que faleceram nos primeiros 3 meses, entre 3 e 6 meses, entre 6 e 9 meses e entre 9 e 12 meses após o momento da previsão.</p>	<p>Foi construído um algoritmo de ML usando dados de EHR para prever o risco de mortalidade por todas as causas, dentro de um ano, em pacientes de cuidados primários.</p>	<p>A antecipação de resultados entre indivíduos não hospitalizados pode facilitar o envolvimento proativo do paciente e a assistência numa fase mais precoce de doença avançada, idealmente antes de ocorrerem incidentes críticos que levem à hospitalização.</p>	<p>Entre os conjuntos de dados combinados de treino e teste, 90,8% dos pacientes que faleceram dentro de um ano após a sua previsão não tiveram interações com hospitais dentro do período observado. Além disso, 93,1% desses pacientes não tiveram admissões em instalações de internamento durante a mesma duração. Notavelmente, apenas 1,6% desses pacientes foram designados para Cuidados Paliativos.</p>	<p>Optou-se por modelos lineares e <i>gradient boosted trees</i>, que superaram consistentemente a regressão logística por margens significativas. Isso sugere que a incorporação de não linearidades e interações desempenha um papel crucial nesta aplicação específica.</p>

<i>Zhang et al. 2021 (24)</i>	A técnica de Previsão Generalizada de Mortalidade foi implementada dentro de um plano de saúde regional, envolvendo um conjunto de dados de 17 197 pacientes. O ano de referência foi entre 1 de janeiro de 2017 e 31 de dezembro de 2017, e o ano de acompanhamento entre 1 de janeiro de 2018 e 31 de dezembro de 2018.	A introdução de um modelo de ML teve como objetivo identificar proativamente potenciais candidatos a CP no âmbito da gestão da saúde da população, usando o risco de mortalidade como uma estimativa prática da necessidade de cuidados paliativos. Os dados passados de cada indivíduo foram utilizados para prever a sua probabilidade de sobrevivência no ano subsequente.	Vários modelos de ML foram avaliados com base numa métrica de desempenho única. Foram desenvolvidas várias versões do Índice de Comorbidade de <i>Charlson</i> , uma ferramenta clínica para avaliar comorbidades, para utilizar dados já existentes para prever o risco de mortalidade em pacientes com condições de saúde subjacentes específicas.	O modelo mais eficaz apresentou uma precisão de 71,43% e uma sensibilidade de 67,98%. Verificou-se uma melhoria na identificação de pacientes com alto risco de mortalidade, redução dos custos totais, melhoria de 74,6% na qualidade de vida, 89,6% recomendá-lo-iam e 82,1% classificaram a sua experiência de forma positiva, confirmando a melhoria na qualidade dos cuidados para os beneficiários.	
<i>Yao et al. 2019 (19)</i>	Dados do Registo Nacional de Cancro de 234 doentes diagnosticados com cancro da bexiga entre 2004 e 2015.	Prever a sobrevivência global de doentes com cancro da bexiga com metástases cerebrais com base em seis variáveis clínicas e avaliar abordagens de tratamento adequadas para este grupo específico.	Ao integrar atributos clínicos para calcular probabilidades personalizadas de resultados clínicos, os algoritmos podem ajudar na tomada de decisões clínicas e apoiam o avanço da medicina personalizada.	O modelo de ML demonstrou uma categorização eficaz dos doentes em grupos de alto risco e baixo risco. As previsões de sobrevivência a 0,5 ou 1 ano após abordagens de tratamento (cirurgia) alinharam-se bem com os resultados observados. Foram obtidos valores de AUC de 0,838 e 0,809 para a estimativa da sobrevivência a 0,5 e 1 ano respetivamente.	Fatores prognósticos estão intimamente ligados às escolhas de tratamento, bem como a comorbidades e metástases. O <i>score</i> de <i>Charlson/Deyo</i> mais elevado é um fator prognóstico reconhecido para a mortalidade global e específica do cancro no cancro da bexiga metastático, alinhando-se com os resultados deste estudo. O cancro da bexiga avançado pode levar a problemas como obstrução ureteral, hemorragia, dor e problemas urinários, nos quais os CP podem potencialmente aumentar a qualidade de vida.
<i>Blanes-Selva et al. 2021 (27)</i>	Foram recolhidos dados dos EHR das admissões hospitalares de pacientes idosos (idade ≥ 65), com exceção dos admitidos no departamento de psiquiatria. Os dados abrangeram o período de 1 de janeiro de 2011 a 31 de dezembro de 2018, incluindo 39 310 ocorrências únicas de admissão envolvendo 19.753 pacientes distintos.	Criar uma aplicação web simples e de fácil utilização, usada em smartphones ou tablets, que integre um modelo de previsão de mortalidade de 1 ano, permitindo consultas à cabeceira para avaliar a necessidade de cuidados paliativos.	Com o aumento previsto da procura de cuidados paliativos, é crucial identificar pacientes adequados para esses programas com base em critérios e <i>timings</i> personalizados, o que garante a alocação eficiente de recursos de saúde.	O algoritmo preditivo teve uma AUC ROC de 0,83. As variáveis-chave do algoritmo incluem a contagem de grupos de medicamentos ativos, o Índice de <i>Charlson</i> (índice que prevê o risco de mortalidade em dez anos em pacientes com múltiplas comorbidades), o Índice de <i>Barthel</i> (avaliação das atividades da vida diária e independência funcional do paciente) e a idade do paciente. Embora o aumento do número de	Os médicos precisam de compreender porque é que a ferramenta faz certas sugestões, por isso este estudo utiliza uma abordagem visual chamada Valores de <i>Shapley</i> para mostrar quais os fatores que afetam a previsão de maiores ou menores hipóteses de alguém falecer num ano.

	<p>A data de óbito dos pacientes, disponível no EHR, foi utilizada para determinar a variável de resultado de mortalidade de um ano.</p>			<p>variáveis aumente os valores médios da AUC ROC, as mudanças não são estatisticamente significativas quando se utilizam mais de 9 variáveis. Um maior número de variáveis afeta diretamente o fluxo de trabalho clínico e a probabilidade de adoção bem-sucedida do modelo.</p>	
<p><i>Oliveira et al. 2018 (30)</i></p>	<p>O conjunto de dados contém informações sobre pacientes diagnosticados com cancro do cólon ou reto abrangendo os anos de 1973 a 2012. O conjunto de testes para o cancro do cólon tinha 2221 registos e o conjunto de treino tinha 20 061 registos. O cancro do reto tinha um conjunto de testes com 551 registos e o conjunto de treino tinha 4962 registos.</p>	<p>Criar modelos compatíveis com dispositivos móveis para prever quanto tempo pacientes com cancro do cólon ou reto podem sobreviver após o tratamento, abrangendo um período de um a cinco anos.</p>	<p>Há escassez de ferramentas para prever a sobrevivência de pacientes com cancro do cólon e do reto.</p>	<p>As métricas de desempenho indicam valores melhorados para a sobrevivência estimada a cada ano: 95,660%, 96,200% e 97,450% de precisão, juntamente com valores de AUC de 0,980, 0,984 e 0,985 para os anos 1, 2 e 5, respetivamente. Além disso, a diferença de desempenho entre os modelos que utilizam 18 atributos e aqueles que utilizam apenas 6 atributos é relativamente pequena. Isso sugere que o último fornece uma aproximação satisfatória aos modelos de 18 atributos e é adequado para um sistema de previsão com requisitos de entrada de dados reduzidos.</p>	<p>Estatísticas de sobrevivência são úteis para oncologistas, sendo possível adaptar e atualizar os modelos de previsão à medida que novos dados são incorporados, garantindo uma evolução contínua ao longo do tempo.</p>