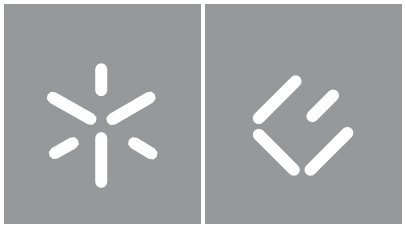
Universidade do Minho
Escola de Economia e Gestão

Noémia Cristina Pereira Joaquim Monteiro

Registo de Saúde Eletrónico

Fevereiro, 2026

Registo de Saúde Eletrónico
Noémia Cristina Pereira Joaquim Monteiro
UMinho | 2026



Universidade do Minho
Escola de Economia e Gestão

Noémia Cristina Pereira Joaquim Monteiro

Registo de Saúde Eletrónico

Dissertação de Mestrado
Gestão de Unidades de Saúde

Trabalho realizado sob a orientação do
Professor Doutor José António Almeida Crispim

Fevereiro, 2026

DIREITOS DE AUTOR E CONDIÇÕES DE UTILIZAÇÃO DO TRABALHO POR TERCEIROS

Este é um trabalho académico que pode ser utilizado por terceiros desde que respeitadas as regras e boas práticas internacionalmente aceites, no que concerne aos direitos de autor e direitos conexos.

Assim, o presente trabalho pode ser utilizado nos termos previstos na licença abaixo indicada.

Caso o utilizador necessite de permissão para poder fazer um uso do trabalho em condições não previstas no licenciamento indicado, deverá contactar o autor, através do RepositóriUM da Universidade do Minho.



Atribuição
CC BY
https://creativecommons.org/licenses/by/4.0/

Agradecimentos

A conclusão desta dissertação representa o encerrar de uma etapa académica assente num percurso de desafios que assumi na perspetiva de procura de conhecimento e aprendizagem de novas competências. Ao longo da sua construção tive o privilégio de beneficiar de diferentes contributos resultantes da interação académica e familiar. Ciente da preponderância do seu contributo, não posso deixar de expressar o meu agradecimento.

Começo por agradecer ao meu orientador, o professor doutor José António Almeida Crispim, por me guiar na construção desta dissertação e cuja orientação foi fundamental no seu desenvolvimento e no potenciar do meu conhecimento e das minhas competências no processo de investigação.

Agradeço aos professores por todo o apoio académico e aos meus colegas de mestrado pelas discussões construtivas e pelo companheirismo durante estes dois últimos anos.

Quero, ainda, deixar um agradecimento especial à minha família deixando aqui o meu sincero reconhecimento e gratidão por toda a compreensão e apoio incondicional que me deram forças e motivação para seguir em frente mesmo perante os desafios mais exigentes.

Este, não foi, por isso, um percurso solitário, pelo que, para finalizar, expresso aqui a minha profunda gratidão para com todos os que contribuíram e que deram o seu contributo para a elaboração e conclusão deste estudo.

O meu muito obrigada a todos.

"O importante é não parar de questionar.

A curiosidade tem a sua própria razão de existir."

Albert Einstein

DECLARAÇÃO DE INTEGRIDADE

Declaro ter atuado com integridade na elaboração do presente trabalho académico e confirmo que não recorri à prática de plágio nem a qualquer forma de utilização indevida ou falsificação de informações ou resultados em nenhuma das etapas conducente à sua elaboração.

Mais declaro que conheço e que respeitei o Código de Conduta Ética da Universidade do Minho.

RESUMO

O Registo de Saúde Eletrónico nos Cuidados de Saúde Primários.

A digitalização da saúde e os avanços tecnológicos na área da Inteligência Artificial (IA), têm permitido otimizar as intervenções de saúde tornando-as mais ágeis e eficientes. Neste contexto, o Registo de Saúde Eletrónico (RSE) constitui uma peça fundamental. O grande número de dados, a complexidade dos registos de saúde e a necessidade de otimizar a gestão do tempo dos profissionais de saúde gera preocupações. Os desafios relacionados com a interoperabilidade dos diferentes sistemas, o armazenamento, propriedade, segurança e privacidade dos dados, assim como, com a acessibilidade, controlo, validade e integridade, dos mesmos, e ainda, com o risco de sobrecarga cognitiva dos profissionais de saúde tem impulsionado o desenvolvimento de novas tecnologias baseadas em IA que prometem otimizar o processo.

Objetivo: Neste sentido, foi formulada a seguinte questão de investigação: Quais as novas tecnologias capazes de melhorar a eficiência do procedimento de RSE, em contexto de Cuidados de Saúde Primários? Pretende-se identificar na literatura novas tecnologias que demonstrem ganhos em eficiência no procedimento de RSE na vertente de introdução e análise de dados de saúde, e, a perceção dos profissionais sobre as mesmas.

Método: Para o seu desenvolvimento optou-se por uma metodologia qualitativa operacionalizada através de uma revisão sistemática da literatura (RSL). A RSL foi conduzida seguindo a metodologia da Joanna Briggs Institute (JBI) e as diretivas PRISMA.

Resultados: A RSL evidenciou um interesse a nível mundial sobre a aplicação de tecnologias de IA na área da saúde. Foi reforçada a potencialidade dos sistemas de RSE e os diversos benefícios da integração de tecnologias de IA. Verificou-se um maior investimento em investigação de soluções tecnológicas direcionadas à análise de dados de saúde e de ferramentas preditivas, nomeadamente, para processamento de dados de saúde, para gerar conhecimento sobre previsões, ou, riscos associados e para identificação das mais diversas condições de saúde. A opção pela tecnologia de IA surge associada ao objetivo pretendido, ao tipo de dados e ao tamanho da base de dados verificando-se maior incidência na utilização de tecnologias de *machine learning* e *natural language processing*. Foram identificados ganhos em eficiência associados à utilização de tecnologias de IA em três áreas de intervenção: cuidados de saúde, recursos e processos. A utilização de IA é percebida pelos profissionais de saúde (PS) como positiva embora surjam preocupações relacionadas com a autonomia profissional, níveis de colaboração entre IA e PS e os novos modelos de cuidados de saúde.

Palavras Chave: Registo de Saúde Eletrónico; Inteligência Artificial; Eficiência; Cuidados de Saúde Primários.

ABSTRACT

Electronic Medical Records in Primary Health Care.

The digitalization of healthcare and technological advances in Artificial Intelligence (AI) have enabled the optimization of healthcare interventions, making them more agile and efficient. In this context, the Electronic Health Record (EHR) is a fundamental element. The large amount of data, the complexity of medical records, and the need to optimize healthcare professionals' time management raise concerns. Challenges related to the interoperability of different systems, data storage, ownership, security, and privacy, as well as data accessibility, control, validity, and integrity, as well as the risk of cognitive overload for healthcare professionals, have driven the development of new AI-based technologies that promise to optimize the process.

Objective: In this sense, the following research question was formulated: What new technologies can improve the efficiency of the EHR process in the Primary Health Care context? The aim is to identify new technologies in the existing literature that demonstrate efficiency gains in the EHR process regarding health data entry and analysis, and the perception of professionals regarding these technologies.

Method: A qualitative methodology operationalized through a systematic literature review (SLR) was used for this study. The SLR was conducted following the Joanna Briggs Institute (JBI) methodology and the PRISMA guidelines.

Results: The SLR highlighted worldwide interest in the application of AI technologies in healthcare. The potential of EHR systems and the diverse benefits of integrating AI technologies were reinforced. A major investment was observed in research into technological solutions aimed at analysing health data and predictive tools through the use of health data to generate knowledge about predictions or associated risks and to identify a wide range of health conditions. The choice of AI technology is associated with the intended objective, the type of data, and the size of the database, with a greater incidence in the use of machine learning and natural language processing technologies. Efficiency gains associated with the use of AI technologies were identified in three areas of intervention: healthcare, resources, and processes. The use of AI is perceived by healthcare professionals (HCPs) as positive, although concerns arise regarding professional autonomy, levels of collaboration between AI and HCPs, and new healthcare models.

Keywords: Electronic Health Record; Artificial intelligence; Efficiency; Health Care.

ÍNDICE

INTRODUÇÃO 16

1. REVISÃO DA LITERATURA 20

1.1 Eficiência e Qualidade em Saúde 21

1.2 Registo de Saúde Eletrónico 23

1.3 Inteligência Artificial 24

1.4 Benefícios da IA na Saúde 25

1.5 Desafios da IA na Saúde 26

1.6 Cuidados de Saúde Primários 27

2. METODOLOGIA 29

2.1 Estratégia de Pesquisa 30

2.2 Protocolo de Revisão 31

3. APRESENTAÇÃO DOS RESULTADOS 39

3.1 Objetivo nº1 | Identificar novas tecnologias de inserção/análise de dados de saúde 54

3.1.1 Gestão de documentação 54

3.1.2 Análise de dados de saúde 55

3.2 Objetivo nº2 | Identificar ganhos em eficiência 57

3.3 Objetivo nº3 | Identificar a perceção dos profissionais de saúde sobre a utilização de tecnologias de IA 64

4. DISCUSSÃO DE RESULTADOS 68

4.1 Papel dos Sistemas de RSE 69

4.2 Tecnologias de IA 70

4.3 Ganhos em Eficiência 76

4.4 Perceção dos Profissionais de Saúde 81

4.5 Limitações e Recomendações Futuras 83

CONCLUSÃO 85

REFERÊNCIAS BIBLIOGRÁFICAS 86

ÍNDICE DE FIGURAS

Figura 1 | Descritores identificados com base no método PICOS.....30

Figura 2 | Fluxograma PRISMA 2020 para Revisão Sistemática da Literatura em Bases de Dados...34

Figura 3 | Objetivos da RSL.....35

Figura 4 | Metodologia de Investigação dos Artigos de Revisão.....54

Figura 5 | Desenho do Estudo de Investigação.....68

Figura 6 | País de origem do estudo de investigação.....69

Figura 7 | Relação Tecnologias de IA/campo de intervenção.....76

Figura 8 | Perceção dos PS sobre tecnologias de IA nos CS.....82

ÍNDICE DE TABELAS

Tabela 1 | Critérios de Inclusão/exclusão para seleção artigos de revisão.....31

Tabela 2 | Listas de Verificação Metodológica de acordo com a metodologia do estudo.....35

Tabela 3 | Níveis classificação do Grau de Conformidade com a Qualidade Metodológica.....38

Tabela 4 | Artigos de investigação selecionados para RSL na base de dados *Pubmed*.....39

Tabela 5 | Artigos Científicos Incluídos na RSL.....44

Tabela 6 | Modelos de ML testados.....55

Tabela 7 | Ganhos em eficiência associados ao uso de tecnologias de IA identificados pelos autores..57

Tabela 8 | Resultados da identificação da perceção dos profissionais de saúde relativamente à tecnologia de IA.....64

Tabela 9 | Lista de Tecnologia de IA e atividades associadas por autor.....71

Tabela 10 | Ganhos em Eficiência identificados na RSL.....77

Lista de Abreviaturas

ACSS – Administração Central do Sistema de Saúde.

AUROC – *Area Under the Receiver Operating Characteristics*.

BWH – Brigham Women's Hospital.

CEO – Chief Executive Officer.

CDSS – *Clinical Decision Support System*

CHOP – *Children's Hospital of Philadelphia.*

CNN – *Convolutional Neural Network.*

COREQ – *Consolidated Criteria for Reposting Qualitative Research.*

CONSORT-AI – *Consolidated Standards of Reporting Trials–Artificial Intelligence.*

CSP – Cuidados de Saúde Primários.

DA – Doença de Alzheimer.

DGS – Direção Geral de Saúde.

DMRI – Doença Macular Relacionada à idade.

DL – *Deep Learning.*

DQS – Departamento da Qualidade da Saúde.

ECG – Eletrocardiograma.

EEDS – Espaço Europeu de Dados de Saúde.

EUA – Estados Unidos da América.

FA – Fibrilação Auricular.

GPU –*Graphics Processing Unit.*

IA – Inteligência Artificial.

IC – Índice de Conformidade.

IC – Insuficiência Cardíaca.

ICD – *International Classification of Diseases.*

ICPC – *International Classification of Primary Care.*

IMEUA - Instituto de Medicina dos Estados Unidos da América.

IoT – *Internet-of-Things.*

JBI – *Joanna Brigs Institute.*

LLMs – *Large Language Models.*

NHS – *National Health System*.

NLP – *Natural Language Processing.*

NSDGRI – Núcleo de Saúde Digital Global e Relações Internacionais.

MGH – *Massachusetts General Hospital.*

ML – *Machine Learning.*

OMS – Organização Mundial da Saúde.

OMOP CDM – *Observational Medical Outcomes Partnership Common Data Model*.

PRISMA – *Preferred Reporting Items for Systematic Reviews e Meta-Analysis*.

PS – Professional de Saúde.

QALY – *Quality-Adjusted Life Years*,

RME – Registo Médico Eletrónico.

RPS – Registo Pessoal de Saúde.

RSE – Registo de Saúde Eletrónico.

RSL – Revisão Sistemática da Literatura.

SANRA – *Scale for the Assessment of Narrative Review Articles.*

SNS – Serviço Nacional de Saúde.

SPMS – Serviços Partilhados do Ministério da Saúde.

SQUIRE – *Standards for Quality Improvement Reporting Excellence.*

STROBE - *Strengthening the reporting of Observational Studies in Epidemiology*.

SVM – *Support Vector Machine.*

TCO – Tomografia de Coerência Ótica.

TRIPOD – *Transparent Reporting of a Multivariable Prediction Model for Individual Prognosis or Diagnosis.*

TRIPOD-AI – *Transparent Reporting of a Multivariable Prediction Model for Individual Prognosis or Diagnosis - Artificial Intelligence.*

UE – União Europeia.

UM – Universidade do Minho.

WHO – *World Health Organization*

INTRODUÇÃO

O desenvolvimento tecnológico tem tradução em todos os setores da sociedade atual, tem transformado procedimentos, perspetivas e demonstrado potencial para promover ganhos em eficiência. Esta transformação é igualmente preponderante no setor da saúde onde assistimos, de ano para ano, ao desenvolvimento de novas terapias e tecnologias baseadas em tecnologias emergentes. Já em 2001, o *Institute of Medicine United States of America* referia que o desenvolvimento do conhecimento e de novas tecnologias na área da saúde nunca tinha sido tão intenso. Também Sataya Nadella (CEO da Microsoft, 2019) no prefácio do livro Aplicando a Quarta Revolução Industrial, considera o setor da saúde um dos setores da sociedade em que é mais urgente aplicar inteligência artificial (IA), desde a investigação ao ensino e à prática clínica.

Os cuidados de saúde, atualmente prestados, tornam necessário intervenções realizadas por profissionais de diversas áreas, cada vez mais diferenciadas, e de diversas instituições (Barbosa & Pereira, 2022). A par deste fato, a maior mobilidade de pessoas, a nível mundial, torna ainda mais importante uma comunicação eficaz entre os diferentes prestadores de cuidados de saúde. A Direção Geral de Saúde (DGS), (2017), define, na Norma nº 001/2017 de 08/02/2017, comunicação eficaz entre profissionais de saúde, como a transmissão de informação *"oportuna, precisa, completa, sem ambiguidade, atempada e compreendida pelo recetor",* (p.4). Considera também que a transição de cuidados são momentos de maior vulnerabilidade, referindo que as falhas na comunicação constituem uma das principais causas de eventos adversos na saúde a nível internacional, com um peso de cerca de 70% do total de eventos.

O acesso a dados de saúde fiáveis e atempadamente contribui para assegurar a continuidade de cuidados e a tomada de decisões clínicas informadas (Barbosa & Pereira, 2022), assim como, para aumentar a satisfação de profissionais e cidadãos (SPMS/SNS, 2019).

A partilha de informação na área da saúde é igualmente fundamental no contexto de formação contínua, na investigação e na gestão, contribuindo para o desenvolvimento de novos procedimentos terapêuticos e tecnológicos assim como tornando a gestão de cuidados de saúde mais eficiente.

Neste sentido, União Europeia (UE) tem vindo a implementar a digitalização do setor da saúde constituindo um dos seus eixos o Registo de Saúde Eletrónico (RSE) operacionalizado na plataforma *MyHealth@EU*. Em 2022, o Parlamento Europeu aprovou a criação de um Espaço Europeu de Dados de Saúde, para melhorar o acesso aos dados pessoais de saúde e promover a

partilha segura, perspetivando o interesse público, (UE, 2022). No RSE, o doente permite através do seu consentimento que os profissionais de saúde possam aceder aos seus ficheiros de saúde, a partir de outros países da UE, onde constam os seus resumos de saúde, as receitas e dispensas eletrónicas, as imagens médicas e relatórios imagiológicos, resultados laboratoriais e relatórios de alta.

Portugal, a par da UE tem implementado o programa de digitalização da saúde, desenvolvendo e pondo em uso diversas aplicações informáticas de apoio às atividades de saúde e através da recolha e divulgação de dados de avaliação dos cuidados de saúde, promovendo uma política de transparência, na saúde.

O registo de saúde eletrónico (RSE) é um registo de saúde longitudinal, do paciente, (WHO, 2012) que contem o *"registo médico completo ou documentação equivalente, em formato eletrónico, dos antecedentes e do estado de saúde atual, físico e mental, de uma pessoa, que permite obter prontamente estes dados para fins de tratamento médico e outros, estreitamente conexos"* (ACSS, 2009, p.19). Estes registos são essenciais para assegurar cuidados de saúde eficientes, seguros e com fundamentação científica (*Institute of Medicine United States of America*, 2001).

Os registos de saúde têm também um papel importante nas decisões de gestão em saúde fornecendo dados que constroem os indicadores de qualidade capazes de medir o resultado da atividade assistencial o que contribui para o processo de melhoria contínua dos cuidados e para a tomada de decisões eficientes na gestão de cuidados de saúde (Bao et al., 2018). No entanto, a informação a ser utilizada deve ser válida e validada evitando o risco de distorcer o desempenho das equipas, desmotivando os profissionais (Vituri & Matsuda, 2009). Indicadores fiáveis permitem gestão mais eficiente quer de recursos humanos quer de instalações e equipamentos o que contribui para cuidados de saúde de qualidade e personalizados.

A digitalização da saúde impulsionada pela União Europeia e os avanços tecnológicos na área da IA, têm permitido otimizar as intervenções de saúde tornando-as mais ágeis e eficientes, permitindo melhorar a forma como os profissionais prestam cuidados, mas também melhorar a forma como as pessoas gerem a sua saúde.

Ainda recentemente, a pandemia de COVID 19 realçou a necessidade de melhorarmos as estratégias para prestar cuidados de saúde à distância e de termos acesso a informação de saúde atualizada em qualquer instituição ou local de prestação de cuidados de saúde. Apesar do fim da declaração de pandemia, as estratégias desenvolvidas são ainda relevantes na prestação de

cuidados de saúde em contexto de cuidados de saúde primários, principalmente no acompanhamento de doentes em ambiente domiciliário.

Apesar das vantagens do RSE os profissionais de saúde na área médica são, atualmente, confrontados com um grande número de dados congregados pelos RSE colocando-os em risco de sobrecarga cognitiva (Fennelly et al., 2020). Este fato requere que as instituições de saúde invistam em sistemas de otimização de dados evitando a insatisfação do paciente e o esgotamento médico associados aos RSE (Gal et al., 2021). De acordo com Al Kuwaiti et al. (2023) a IA pode contribuir positivamente para a redução do peso da atividade administrativa, que nos EUA, corresponde a um quarto do tempo da atividade de enfermagem.

A complexidade dos registos de saúde e a gestão do tempo que os profissionais de saúde tem impulsionado a adoção de estratégias que agilizem o processo. Segundo o Instituto Kaizen gestão de dados de saúde pode ser agilizada por tecnologias como a Inteligência Artificial (IA), a *Internet of Things* (IoT) e *Machine Learning* (ML). Os contributos desta transformação digital são visíveis em áreas diversas da saúde como; a telemedicina e consultas virtuais que permitem o acesso a cuidados de saúde em locais remotos; registos médicos de saúde acessíveis pelos diferentes profissionais de saúde e nas diferentes instituições de prestação de cuidados; a *Internet of Things* (IoT) e dispositivos médicos interligados de monitorização e recolha de dados de forma remota e em tempo real; a Inteligência Artificial (IA) no papel de assistente ao diagnóstico na análise de imagens e na elaboração de diagnósticos e previsão da condição de saúde; aplicações de saúde (*mHealth)* que promovem a gestão individual da saúde e assistem na gestão do regime terapêutico; a análise de *Big Data* de saúde com evidência na saúde pública e personalização de tratamentos; e ainda a realidade aumentada e virtual cuja contribuição se verifica ao nível da melhoria de diagnóstico, acesso a cuidados de saúde, formação e redução de custos.

Apesar dos benefícios evidentes, a utilização de tecnologias baseadas em Inteligência Artificial (IA), nos sistemas de registo de saúde eletrónico, traz consigo alguns desafios éticos e sociais, tecnológicos e de governação (Al Kuwaiti et al., 2023) que é necessário ter em consideração de forma a uma mais eficiente implementação. Todas estas tecnologias dependem da introdução de dados, que atualmente são uma mercadoria valiosa na área da saúde. O grau de sensibilidade dos dados de saúde exige que as organizações implementem formas seguras sobre como os utilizar (Silcox et al.,2024). Pap & Oniga (2022) referem, ainda, que um dos desafios que se apresenta na adoção de IA em cuidados de saúde é compreender como ela é percebida e que requisitos são necessários para a sua adoção nas práticas de cuidados de saúde,

recomendando investigação futura sobre a utilização de IA como assistente de documentação no contexto específico de consultas nos cuidados de saúde primários.

Consciente da preponderância dos profissionais de saúde na produção de dados de saúde, através dos registos clínicos, e perspetivando o desenvolvimento tecnológico que se vive atualmente na área da Inteligência artificial procuro com este estudo encontrar novas tecnologias e procedimentos que tornem mais eficiente o procedimento de registo de dados de saúde pelos diversos profissionais envolvidos.

Neste sentido, escolhi como tema para esta Dissertação o registo eletrónico nos cuidados de saúde, no âmbito do qual formulei a seguinte pergunta de partida: *Quais as novas tecnologias capazes de melhorar a eficiência do procedimento de registo eletrónico de saúde em contexto de Cuidados de Saúde?*

O desenvolvimento deste estudo pretende identificar na literatura existente novas tecnologias com potencial para melhorar a eficiência do procedimento de RSE, de forma geral e especificamente:

1. Identificar novas tecnologias de inserção ou análise de dados de saúde.
2. Identificar ganhos em eficiência.
3. Identificar a perceção dos profissionais sobre a sua utilização.

Para o seu desenvolvimento irei seguir uma metodologia qualitativa operacionalizada através de uma revisão sistemática da literatura.

1. REVISÃO DA LITERATURA

O direito consagrado na Constituição portuguesa que prevê acesso universal à saúde traz grandes desafios na sociedade atual. Os recursos existentes não são ilimitados o que torna imperativo um modelo de gestão que consiga garantir a sustentabilidade do sistema de saúde. A procura de sustentabilidade da saúde implica investimento na eficiência das suas infraestruturas e procedimentos, mas também da gestão de tempo dos recursos humanos, para não comprometer a qualidade e segurança dos cuidados (Catarinucci et al., 2015).

Tanto a nível nacional como internacional, os diferentes intervenientes na atividade de saúde, sejam eles organizações governamentais ou não governamentais têm adotado esta visão comum de qualidade e segurança dos cuidados de saúde. A OMS (2020) refere que os cuidados de saúde, devem ser centrados nas pessoas, seguros e eficazes, garantido a sua implantação atempada e eficiente de forma equitativa e integrada. Em Portugal, na Lei de Bases da Saúde, aprovada na Lei nº95/2019, de 4 de setembro, está consagrado o princípio da qualidade no Serviço Nacional de Saúde (SNS), cuja operacionalização é desenvolvida pelo Departamento da Qualidade em Saúde (DQS) da Direção Geral de Saúde (DGS), e, cujas estruturas asseguram o planeamento e implementação de medidas de melhoria da qualidade em saúde assim como a sua monitorização. Este princípio veicula a atuação do SNS à prestação de cuidados de saúde efetivos, seguros e eficientes. Neste sentido, verifica-se que o conceito de eficiência surge alocado ao princípio de qualidade na saúde do que podemos depreender a importância da integração nos sistemas de saúde de estratégias capazes de promover a eficiência dos cuidados e subsequente promoção da qualidade.

Neste sentido, a digitalização da saúde impulsionada pela União Europeia e os avanços tecnológicos na área da IA, têm permitido otimizar as intervenções de saúde tornando-as mais ágeis e eficientes, redesenhando a forma como os profissionais prestam cuidados, mas também como as pessoas gerem a sua saúde (Comissão Europeia, 2025). Um dos seus eixos da digitalização do setor da saúde é constituído pelo Registo de Saúde Eletrónico (RSE) operacionalizado na plataforma *MyHealth@EU*. Em 2022, o Parlamento Europeu aprovou a criação de um Espaço Europeu de Dados de Saúde, para melhorar o acesso aos dados pessoais de saúde e promover a partilha segura, perspetivando o interesse público, (UE, 2022). Já em 2023, o Núcleo de Saúde Digital Global e Relações Internacionais (NSDGRI) dos Serviços Partilhados do Ministério da Saúde (SPMS) continuou o investimento na saúde digital global, de forma a fortalecer a resiliência dos sistemas de saúde e preparação para o Espaço Europeu de

Dados de Saúde (EEDS), (SPMS, 2024).

O registo de saúde eletrónico "*é um registo eletrónico longitudinal da informação de saúde do paciente gerada por um ou mais encontros em qualquer ambiente de prestação de cuidados*" (WHO, 2012). A informação que consta no RSE inclui "*os dados demográficos do paciente, notas de progresso, problemas, medicação, sinais vitais, histórico médico passado, imunizações, dados laboratoriais e relatórios radiológicos*" (WHO, 2012).

Perspetivando cuidados de saúde eficientes e a transformação digital dos sistemas de saúde que assenta uma das suas intervenções no RSE procura-se com esta dissertação identificar quais as novas tecnologias baseadas em IA capazes de melhorar a eficiência do procedimento de RSE em cuidados de saúde primários. A RSL realizada teve como propósito a identificação de novas tecnologias capazes de gerir dados em saúde e quais os seus contributos na procura da eficiência dos cuidados de saúde tendo em vista as vantagens e condições para a sua implementação assim como a perceção dos profissionais de saúde.

Com a perspetiva de conhecer melhor o que se tem investigado sobre o RSE, sistemas de registo de dados de saúde, o uso de tecnologias emergentes e possíveis vantagens/desvantagens, efetuou-se uma pesquisa nas bases de dados disponibilizadas pela Universidade do Minho. Desta pesquisa inicial surgiram alguns temas de relevância para o contexto descrito.

1.1 Eficiência e Qualidade em Saúde:

A definição de qualidade não tem consenso a nível mundial. De acordo com a Organização Mundial de Saúde (2020), na área da saúde, tem sido adotado o conceito do Instituto de Medicina dos Estados Unidos da América (IMEUA):

> *"A medida em que os serviços de saúde prestados aos indivíduos e às populações aumentam a probabilidade de se obterem os resultados desejados na saúde e são consistentes com os atuais conhecimentos profissionais"* (p.13).

Segundo os quais, esta definição pretende ter um efeito positivo nos resultados em saúde do individuo e das populações reforçando a importância do conhecimento profissional fundamentado em evidência. De acordo com o IMEUA, a qualidade em saúde deve garantir o cumprimento de seis atributos, declarando que os cuidados de saúde devem ser seguros, eficazes, centrados no doente, oportunos, eficientes e equitativos.

A eficiência surge associada à qualidade em saúde. A importância da eficiência em contexto de cuidados de saúde é transversal aos seus muitos campos de atuação. Frequentemente, a

eficiência em saúde é interpretada como um conceito de produção que se debruça sobre a relação entre consumos (*inputs*) e produtos (*outputs*), (Lötscher-Stamm & Lenzin, 2024). No entanto, a eficiência em saúde não deve ter uma visão apenas de controle de custos, muito associada à gestão, cujo objetivo visa a otimização de meios em relação aos fins traduzido num "*ideal de aproveitamento absolutamente equilibrado entre recursos disponíveis e resultados obtidos*", (Borges & Bordin, 2023, pg.620). Marinho e Ocké-Reis (2022) associam eficiência na economia da saúde ao conceito de eficácia e efetividade. A eficácia traduz o alcance dos objetivos onde, o papel dos processos é contribuir para o atingir dos resultados esperados enquanto efetividade está relacionada diretamente com o efeito de uma intervenção de saúde sobre a população, (Borges & Bordin, 2023). Marinho & Ocké-Reis (2022) consideram três tipos de eficiência na área da saúde, eficiência técnica, eficiência de distribuição e eficiência de escala, salientando que nem sempre bons indicadores financeiros e de custo-efetividade estão alinhados com o interesse público ou das políticas de saúde. A eficiência técnica pressupõe uma relação quantitativa entre recursos utilizados e os recursos necessários para o nível de produção desejado em que, a produção pode ser representada por produtos de saúde (como número de consultas realizadas, número de doentes tratados) ou resultados em saúde (aumento da qualidade e espectativa de vida). Já a eficiência distributiva estabelece a relação entre o custo real e o custo mínimo para o nível de cuidados pretendido. Por fim, eficiência de escala é definida como o tamanho ótimo dividido pelo tamanho observado. É necessário ter em consideração na avaliação de eficiência o alinhamento entre eficiência técnica e a análise de critérios de qualidade dos cuidados ou resultados em saúde de forma a ser coerente com os prestadores de cuidados e com as políticas de saúde, (Lötscher-Stamm & Lenzin, 2024).

No entanto, a avaliação económica não deixa de estar associada à análise de eficiência em saúde. Neste sentido, a relação entre os custos e as consequências da atividade em saúde é avaliada pelas relações custo-benefício, custo-efetividade e custo-utilidade, (Borges & Bordin, 2023). A análise custo-benefício evidencia, em termos monetários, qual das alternativas possíveis tem menor custo. Os benefícios podem ser diretos como poupança por tratamentos evitados ou indiretos que se referem á influência sobre a capacidade produtiva da população quando se diminui a morbilidade ou a mortalidade. Quando nos referimos a uma análise de custo-utilidade estamos a avaliar as consequências de determinada intervenção em saúde em termos de um valor ajustado para a qualidade de vida: *Quality-Ajusted Life Ears*, (QALY). Por fim uma análise custo-efetividade, mede os resultados em unidades de valor real como "ganhos em anos de vida",

"doenças evitáveis", o que tem subjacente a definição de objetivos de forma a desenvolver e estruturar os meios para os alcançar, (Borges & Bordin, 2023).

1.2 Registo de Saúde Eletrónico:

Relativamente a registo eletrónicos de informação de saúde, a OMS (2012) faz a distinção entre registos médicos eletrónicos (RME), registo de saúde eletrónico (RSE) e registo pessoal de saúde (RPS). O RME é considerado "*(...) um registo de saúde do paciente em tempo real com acesso a ferramentas de suporte à decisão, baseadas em evidências, que podem ser utilizadas para auxiliar os médicos na tomada de decisões*", (OMS, 2012, p.11). Já o RPS é uma ferramenta para gerir informações importantes de promoção e manutenção da saúde que ajudam na gestão de doenças crónicas. Este tipo de registo é controlado e gerido pela pessoa. Relativamente ao RSE, a mesma, refere que "*é um registo eletrónico longitudinal da informação de saúde do paciente gerada por um ou mais encontros em qualquer ambiente de prestação de cuidados"* (OMS, 2012, p.11).

O RSE tem vindo a ser associado pela literatura a benefícios em diversas áreas de atuação. O acesso a informação completa e atualizada permite disgnósticos mais corretos, com melhores resultados para o doente evitando interações medicamentosas, polimedicação e duplicação de meios de diagnóstico, o que contribui para melhores resultados para o doente e melhor segurança e eficiência nos cuidados (Barbosa, 2022; OMS, 2020). Brender (2006) associa o RSE a benefícios como a melhoria das taxas de imunização, melhor recolha e acesso aos dados, diminuição dos erros médicos, um aumento da produtividade da equipa com gestão de tempo mais eficiente e melhor comunicação, melhor qualidade de cuidados e aumento de utentes satisfeitos com os cuidados de saúde.

A OMS refere, ainda, que o RSE além da importância clínica, ao garantir a comunicação das informações de saúde, pode ser um meio de recolha de dados direcionados para além do cuidado clínico, como para gestão em saúde, gestão da qualidade, faturação ou na vigilância epidemiológica em saúde pública com potencial para melhorar a eficiência e a qualidade dos cuidados de saúde.

Apesar das vantagens do RSE os mesmos são associados a alguns desafios a ter em conta na sua implementação. Os profissionais de saúde são, atualmente, confrontados com um grande número de dados congregados pelos RSE o que os coloca em risco de sobrecarga cognitiva. Este facto requere que as instituições de saúde invistam em sistemas de otimização de dados evitando

a insatisfação do paciente e o esgotamento médico associados aos RSE (Gal et al., 2021). A complexidade dos registos de saúde e a gestão do tempo dos profissionais de saúde tem impulsionado a adoção de estratégias que agilizem o processo. Brender, no seu estudo sobre fatores que influenciam o sucesso e falha do RSE identifica também a entrada e acesso lento aos dados e diminuição da qualidade da interação médico-doente como desvantagens.

O sucesso da implementação de um sistema de RSE requere interoperabilidade dos dados e a capacidade de ligação entre a pessoa e os dados recolhidos ao longo do tempo, mantendo a sua disponibilidade aos diferentes profissionais envolvidos, (WHO, 2012; *European Comission*, 2022), garantindo a qualidade (WHO,2012) e segurança (*European Comission*, 2022) dos dados. A complexidade dos sistemas de RSE exige um bom design, formação dos profissionais e implementação de aplicações informáticas (Brender, 2006) para garantir a sua funcionalidade.

A digitalização dos diferentes setores da sociedade torna notável a velocidade e o volume de dados gerados (Varian, 2014). Os dados que integram o RSE podem ser estruturados e não estruturados, constituindo um poderoso repositório de informação clínica (Raghavan et al., 2014). Denominados *Big data,* por se tratar de um enorme conjunto de dados, que ultrapassa a capacidade de gestão por humanos, o que, requer ferramentas digitais de assistência ao processamento e análise dos mesmos (Martins et al., 2018). Estes autores referem, ainda, que tecnologias de *machine learning* (ML) podem contribuir com algoritmos capazes de processar este grande volume de dados, em tempo real, de modo a assistir na tomada de decisão clínica o que salienta o papel que tecnologias de IA podem assumir nos sistemas de saúde. De igual modo, Madi et al. (2024) salientam que as tecnologias de IA como algoritmos de ML e DL facilitam o processamento de informação complexa e de grande volume de forma eficaz e precisa.

1.3 Inteligência Artificial:

A inteligência artificial é uma das tecnologias emergentes que está a marcar presença em diversos setores na sociedade. O Parlamento Europeu define IA como *"a capacidade que uma máquina tem para reproduzir competências semelhantes às humanas como é o caso do raciocínio, a aprendizagem, o planeamento e a criatividade".* Já McCarty, (2007) vê a IA como a ciência e a engenharia que fabrica máquinas ou programas de computador inteligentes, estando relacionado com a tarefa de utilizar computadores para compreender a inteligência humana, mas sem que a IA precise de se limitar a métodos que sejam biologicamente observáveis. A sua utilização tem-se expandido de forma notável em várias áreas, como: a saúde, indústria e automação, transportes

e mobilidade, setor financeiro e bancário, educação, media e entretenimento, segurança, serviços e atendimento ao cliente, pesquisa e desenvolvimento. Ela oferece uma vasta gama de soluções promissoras em termos de eficiência, precisão e personalização.

1.4 Benefícios da IA na Saúde:

De acordo com Pap e Oniga (2022), um dos benefícios dos algoritmos de IA com a sua capacidade de imitar alguns aspetos do pensamento humano, sendo capazes de integrar e gerir entradas de dados estruturados e não estruturados com um objetivo específico. Os mesmos, citaram como áreas em que foi demonstrada vantagem na utilização de IA: a melhoria da previsão de diagnóstico, na previsão do risco, em aplicações clínicas, na otimização de procedimentos de cuidados de saúde, na gestão de circuitos dos doentes, na deteção automática de eventos clínicos, na qualidade dos cuidados de saúde, e na descoberta de efeitos adversos da medicação.

No campo da gestão de saúde a implementação de IA nos cuidados de saúde pode potenciar a diminuição de custos económicos (Alnasser, 2023; Pap & Oniga, 2022). A IA tem impulsionado soluções inovadoras que permitem otimizar operações de faturação e aumentar a precisão o que contribui para melhorar resultados financeiros (Kilanko, 2023).

A par da IA, também as tecnologias inteligentes como *Internet-of-Things* (*IoT)* e *mobile health* (*mHealth)* estão a ser aplicadas em contextos específicos, da área da saúde, facilitando o acesso a monitorização remota, em tempo real, assim como o introdução e acesso de registos eletrónicos de saúde do doente (Barbosa & Pereira, 2022). A *IoT* envolve a interligação de diferentes tipos de objetos físicos, tipos de equipamentos e sensores através da Internet, permitindo-lhes comunicar entre si e partilhar dados. Na área da saúde, as tecnologias *IoT* já estão a ser utilizadas para melhorar os cuidados e os resultados dos doentes, oferecendo novas oportunidades de monitorização remota, ou localização de doentes em situações de emergência ou críticas, permitindo agilizar a introdução de dados e o acesso remoto em tempo real ao RSE (Barbosa & Pereira, 2022).

Um estudo cujo objetivo foi analisar as experiências de enfermeiros com o uso de RSE num dispositivo móvel na atividade diária demonstrou que os enfermeiros, no geral, tiveram experiências positivas ao documentar os dados do cliente em um dispositivo móvel, considerando-os benéficos na atividade em contexto domiciliar. O registo de dados num dispositivo móvel reduziu o tempo de trabalho destinado à atividade de registo clínico (Paatela et al., 2024).

Por seu lado, *mHealth*, são aplicações móveis de saúde permitem que os pacientes façam

a “gestão” da sua saúde, rastreiem sintomas e recebam lembretes de medicamentos ou direcionadas para os profissionais de saúde assumindo funções de assistentes de diagnóstico e terapêutica (Shiyab et al., 2024). Shiyab et al. (2024) desenvolveram um estudo para “explorar o uso de aplicativos de *mHealth* por enfermeiros para apoiar adultos com ou em risco de condições crónicas e entender os fatores que influenciam a adoção da tecnologia” evidenciando que o uso de aplicativos de *mHealth* a título pessoal, por enfermeiros, é muito comum o que aumenta a probabilidade da sua utilização na atividade profissional contribuindo para a autonomia dos doentes na autogestão da sua doença crónica.

1.5 Desafios da IA na Saúde:

No entanto, e, apesar dos benefícios percebidos da sua utilização, a mesma levanta questões sobre a privacidade dos dados, a transparência dos algoritmos e os impactos sociais ligados ao risco de substituição de empregos, sendo que para ultrapassar estes desafios é necessário implementar medidas no sentido de criar regulamentação, para uma utilização fundamentada por princípios éticos, de forma a garantir que a sua utilização não seja prejudicial para a sociedade e seja levada a cabo de forma responsável e transparente (Kuwaiti et al., 2023).

O uso de IA em cuidados de saúde é socialmente controverso, gerando preocupações nos vários intervenientes (Kuwaiti et al., 2023) sendo uma delas a segurança dos sistemas de IA (Liu et al., 2020). No entanto, segundo o Instituto Kaizen, a transformação digital tem trazido benefícios em áreas como: a telemedicina e consultas virtuais que possibilitam o acesso a cuidados de saúde à distancia promovendo a acessibilidade em lugares remotos; melhoria da acessibilidade aos registos de saúde por diferentes profissionais de saúde e nas diferentes instituições de prestação de cuidados; IoT e dispositivos médicos interligados que permitem a monitorização e recolha de dados em tempo real ou remotamente; a IA como assistente de diagnóstico através de análise de imagens e na elaboração de diagnósticos e previsão da condição de saúde; aplicações *mhealth* que permitem a gestão individual da saúde e servem de assistente na gestão do regime terapêutico; a análise de *Big Data* de saúde permite agilizar o processo de investigação epidemiológica e a personalização de tratamentos; por fim a utilização de realidade aumentada e virtual tem contribuído com benefícios ao nível da melhoria de diagnóstico, acesso a cuidados de saúde, formação e redução de custos. Considera-se, portanto, crucial enfrentar desafios como privacidade de dados, viés de algoritmo e a necessidade de infraestrutura e treinamento robustos para garantir uma implementação bem-sucedida (Kilanko, 2023). À medida que a saúde continua

a evoluir, adotar essas tecnologias enquanto se mantém a supervisão humana será fundamental para alcançar um sistema de saúde mais eficiente e centrado no paciente (Ogochukwu & Chimaobi, 2024).

Noutra perspetiva, para a adoção de IA em cuidados de saúde é necessário compreender como ela é percebida e que requisitos são necessários para a sua adoção nas práticas de cuidados de saúde. Pap e Oniga (2022), reiteram a necessidade de se investir em investigação para aplicação de IA como assistente de gestão de informação e documentação nas consultas dos cuidados de saúde primários.

O tempo dedicado aos registos clínicos eletrónicos, na prestação de cuidados de saúde primários, tem um peso considerável na atividade diária dos diferentes profissionais envolvidos o que é evidenciado por Kuwaiti et al. (2023) quando referem que nos EUA um quarto do tempo da atividade de enfermagem é utilizado em atividades administrativas. As tecnologias de IA podem ser uma ferramenta fundamental na otimização do procedimento de RSE. Um estudo cujo objetivo constituía analisar as experiências de enfermeiros com o uso de RSE num dispositivo móvel, na atividade diária, demonstrou ser benéfico na atividade em contexto domiciliar traduzindo-se na redução de tempo de trabalho (Paatela et al., 2024).

1.6 Cuidados de Saúde Primários:

Os cuidados de saúde primários (CSP) são o contato mais próximo entre as pessoas e famílias e o sistema nacional de saúde. O seu início remonta a 1970, data em que foram criados os centros de saúde (Silva, 2023) e têm sido motivo de atenção internacional pelos resultados mostrados (USF-AN, 2024). Segundo o Observatório Europeu de Políticas e Sistemas de Saúde (2023), Portugal tem das mais baixas taxas de hospitalizações evitáveis referindo que as "*mudanças organizacionais e o envolvimento dos CSP, nomeadamente o recurso às consultas digitais ou à tele-especialização entre equipas*" de saúde e a melhoria de acessibilidade ás populações mais vulneráveis e rurais, sugerem CSP eficazes. Este facto salienta a importância de CSP eficientes para a melhoria da acessibilidade a cuidados de saúde e consequentemente para a qualidade e sustentabilidade do sistema de saúde. No entanto o relatório da USF-AN, de 2024, sobre o estado atual dos CSP em Portugal evidencia através do relato dos coordenadores das unidades de saúde familiar alguns dos problemas que enfrentam na sua atividade diária. Um dos problemas identificados é a falta de interoperabilidade entre programas informáticos, em uso, insuficiências nos sistemas de informação, assim como, a falta de equipamento para realização

de teleconsulta. Este facto reforça o que tem sido referido pela literatura sobre a importância da interoperabilidade dos sistemas de RSE (WHO, 2012; *European Commission*, 2022).

Apesar dos desenvolvimentos tecnológicos evidenciados pela literatura, não existe ainda, uma aplicação alargada e sustentada aos diferentes contextos da saúde. A evidência de que mais de 75% dos enfermeiros e médicos em ambientes de cuidados intensivos usam seus smartphones pessoais para apoiar a sua atividade profissional mostra a existência de um distanciamento entre a política e a prática (de Jong et al., 2020).

2. METODOLOGIA

Vilela (2022) define investigação "*como sendo um sistema de atividades intelectuais e manuais destinado à obtenção de informação capaz de resolver determinados problemas"*. Com esta visão em mente apresenta-se de seguida a descrição das atividades implementadas com o objetivo de obter informação relevante e, com potencial de contribuir para encontrar uma resposta para a questão de investigação deste estudo.

Este estudo de investigação segue uma filosofia de investigação orientada pelo pragmatismo. O pragmatismo considera que o conhecimento é relevante quando apoia a ação, ou seja, no seu papel enquanto instrumento de ação e nas consequências práticas verificadas em determinado contexto, valorizando tanto a realidade objetiva como a subjetiva (Kelemen & Rumens, 2008, citado por Saunders, M., Lewis, P., & Thornhill, A., 2023). O pensamento pragmático é direcionado para as consequências futuras, atuando no presente para antecipar e projetar o futuro mais do que avaliar o passado (Kelemen & Rumens, 2012). A filosofia pragmática permite, por isso, investigar questões complexas em contextos práticos como é o caso da área da saúde. Neste sentido, considero ser uma escolha adequada pois permite a procura com o objetivo de não apenas compreender o fenómeno, mas também contribuir para gerar mudanças e melhorias práticas.

Relativamente ao tipo de pensamento lógico pretendo seguir uma lógica de investigação indutiva. Na abordagem indutiva partimos da observação para gerar conclusões a investigar utilizando a recolha de dados, para explorar um fenómeno, identificar temas e padrões e, por fim, gerar uma teoria (Saunders et al., 2023).

A metodologia escolhida para explorar a questão de investigação formulada foi a metodologia qualitativa. A metodologia tem como função direcionar o procedimento de investigação, indicando quais os temas dignos de serem investigados, como os enquadrar e de que forma podem serem explorados, ou seja, como gerar dados adequados e como proceder a associações lógicas entre o problema, os dados gerados e a respetiva análise, demonstrando confiabilidade ao ser assegurada a credibilidade, transferibilidade, confiabilidade e confirmabilidade (Jackson et al., 2007).

A análise qualitativa foi conduzida através de uma revisão sistemática da literatura. Uma revisão sistemática da literatura é um método sistemático, explícito e capaz de ser reproduzido de forma a identificar, avaliar e sintetizar o conhecimento existente (Fink, 2005), o que a diferencia de uma revisão da literatura tradicional. A revisão de literatura inicial permitiu objetivar a questão

de investigação cuja definição é fundamental num processo de investigação regido por uma prática baseada na evidência. A questão de investigação nasce do problema identificado que questiona a eficiência do procedimento de registos eletrónicos de saúde e o papel das tecnologias emergentes na sua melhoria. O processo de investigação subjacente surge da dúvida e da curiosidade do investigador e é conduzido de forma a dar resposta ao problema e gerar conhecimento científico, (Oliveira, E., 2014).

Deste processo reflexivo nasce a questão de investigação que foi estruturada de acordo com estratégia designada pelo acrónimo PICOS, nos seus cinco componentes: *Population, Intervention, Context, Outcome, Study Desing*. A estratégia PICOS orienta a construção da questão de investigação e da procura bibliográfica permitindo ao investigador localizar de forma precisa e rápida a melhor informação científica disponível (Santos et al., 2007). A pratica baseada na evidência está "associada a uma prática reflexiva e cuidadosa" (Nobre et al., 2004), assim como, a uma definição clara da questão de investigação que permita definir uma estrutura lógica, de procura bibliográfica, de modo a facilitar a identificação de estudos relevantes na literatura (Santos et al., 2007).

2.1 Estratégia de Pesquisa

A estratégia de pesquisa foi implementada através da seleção dos descritores relacionados com cada um dos componentes da estratégia PICOS: *Registos Eletrónicos de Saúde; Inteligência Artificial; Eficiência de Cuidados de Saúde, Cuidados de Saúde Primários.* Dos descritores identificados, emergiram os termos de pesquisa, que foram traduzidos para língua inglesa: *Health; Electronic; Records; AI; Efficiency; Primary healthcare.*

Assim, com base nos descritores identificados foi construída a questão para a procura bibliográfica de evidências: *Quais as novas tecnologias capazes de melhorar a eficiência do procedimento de registo eletrónico de saúde, realizado por profissionais de saúde, em contexto de Cuidados de Saúde?*

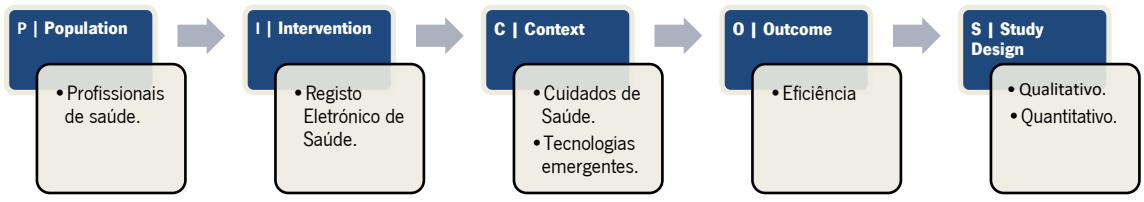


Figura 1 | Descritores identificados com base no método PICOS.

A população (P, *Population*) alvo do estudo são os profissionais de saúde (médicos, enfermeiros, técnicos de saúde, entre outros). A intervenção (I, *Intervention*) constitui o procedimento de registo eletrónico de saúde, tendo como contexto (C, *Context*) a prestação de cuidados de saúde em ambiente hospitalar ou ambiente de CSP e as tecnologias emergentes, que resultem (O, *Outcome*) em ganhos em eficiência. Serão comtemplados estudos desenvolvidos com metodologia qualitativa, quantitativa ou mista (S, *Study Design*). Após a formulação da a questão de investigação, a etapa seguinte é o início da procura bibliográfica, de forma, a viabilizar a identificação de evidências na base de dado selecionada (Santos et al., 2007, Bernardo et al., 2004).

2.2 Protocolo de Revisão:

Na continuação do processo de pesquisa foi elaborado o protocolo de revisão. No protocolo de revisão, encontram-se definidos e clarificados os critérios de inclusão e de exclusão a ter em consideração na seleção dos artigos, a incluir na RSL, que se apresentam na tabela seguinte.

Tabela 1 - Critérios de Inclusão/exclusão para seleção artigos de revisão.

PICOS	**Critérios de Inclusão**	**Critérios de exclusão**
População *"Population"*	Profissionais de saúde: não exclusivamente médicos, enfermeiros, técnicos de radiologia, fisioterapeutas, terapeutas ocupacionais, farmacêuticos.	Assistentes operacionais. Secretários clínicos.
Intervenção *"Intervention"*	Utilização de tecnologia de inteligência artificial (IA) aplicada em sistemas de documentação clínica.	Produção de documentação não clínica com recurso a tecnologias de IA.
Contexto *"Context"*	Qualquer contexto cuja atividade principal seja a prestação de cuidados de saúde, cuidados de saúde primários ou diferenciados.	Contexto cuja atividade principal não seja prestação de cuidados de saúde.
Resultado *"Outcome"*	Os estudos selecionados devem incluir pelo menos uma medida de resultado de interesse: - Qualidade da documentação produzida. - Eficiência no processo de produção/análise de dados de saúde; - Usabilidade de tecnologias de IA para produção de documentação;	Resultados focados na avaliação da tecnologia de IA em si e não na avaliação do procedimento de produção/análise/gestão de dados de saúde.

	- Opinião dos profissionais ou *stakeholders* sobre a utilização da tecnologia de IA.	
Desenho do Estudo *"Study design"*	Artigos científicos com metodologia qualitativa, quantitativa ou mista.	Artigos não disponíveis nas bases de dados PubMed.

A pesquisa de artigos foi delimitada à Base de Dados PubMed, cujo acesso é disponibilizado pelos serviços de Biblioteca no portal do aluno da Universidade do Minho (UM). A seleção desta base de dados é fundamentada pela sua relevância na área da saúde.

Para dar início à procura de artigos científicos a incluir na RSL, os termos de pesquisa foram combinados, de forma restritiva, através da aplicação do operador booleano *AND*, e aplicados na base de dados selecionada. No decorrer da pesquisa de artigos científicos foram aplicados os filtros: *"full text"; "language - English"; "open access".* Foi ainda definida uma delimitação temporal de forma a incluir apenas estudos publicados após 2020.

A procura de artigos a incluir no estudo foi realizada a 14.03.2025, com recurso ao acesso disponibilizado pelos serviços da Biblioteca da UM, a bases de dados de referência.

No seguimento do explicitado anteriormente serão incluídos nesta revisão sistemática da literatura artigos em que a população alvo sejam profissionais de saúde que no exercício da sua atividade profissional utilizem registos eletrónicos de saúde com recurso a tecnologias emergentes, explicitando as suas vantagens e desafios, perceção dos profissionais, contributos em eficiência ou ganhos em saúde, em contexto de prestação de cuidados de saúde. Relativamente à metodologia serão aceites quer estudos quantitativos e qualitativos ou mistos cujo idioma seja português ou inglês.

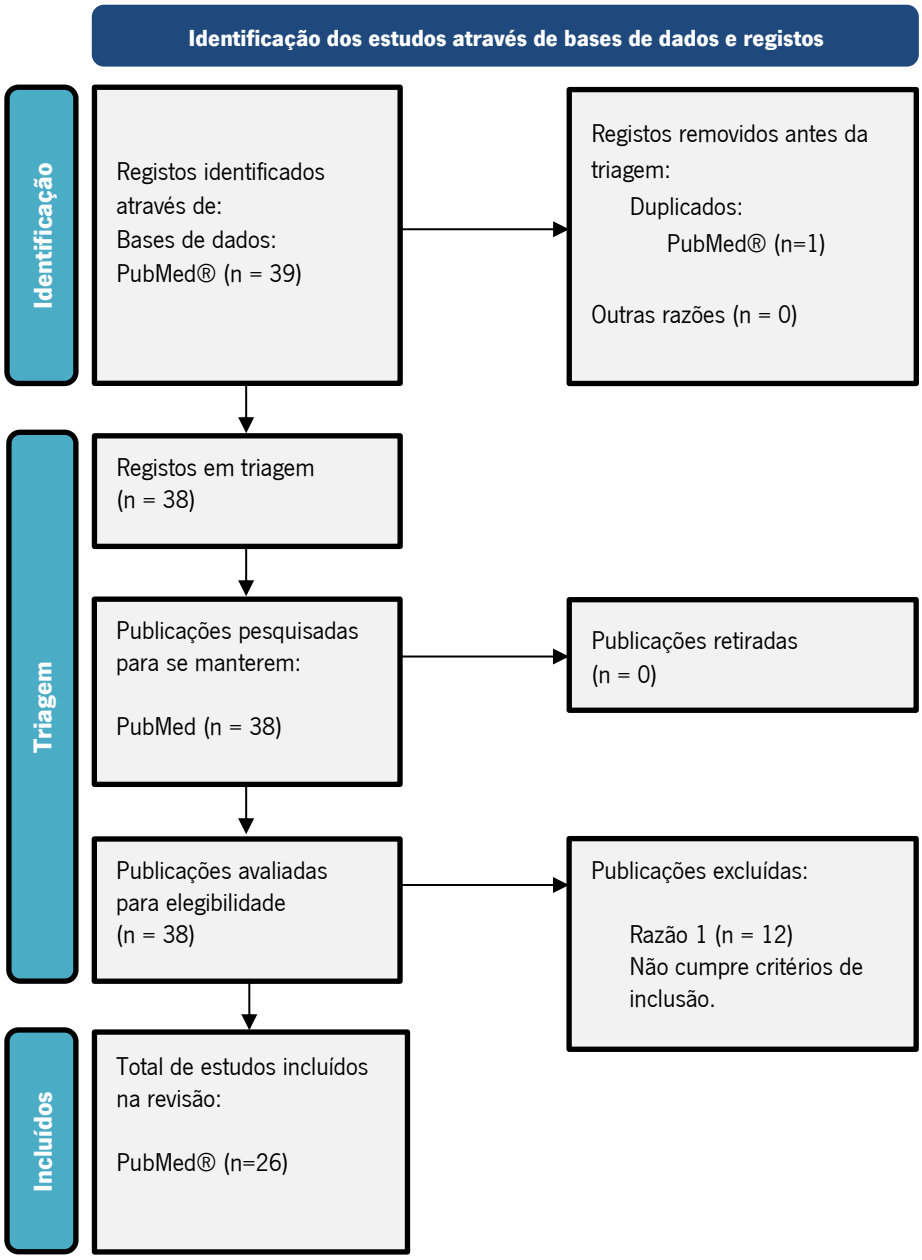
A revisão sistemática da literatura seguiu a metodologia da *Joanna Briggs Institute* (JBI) (Aromataris et al., 2024) e as diretivas PRISMA (*Preferred Reporting Items for Systematic Reviews e Meta-Analysis*) (Page et al., 2021), de forma ser conduzida uma pesquisa abrangente através da base de dados PubMed. A JBI é uma organização internacional de saúde que se propõe melhorar os resultados de saúde, a um nível global, por meio da produção e divulgação de evidências de pesquisa, software, treino, recursos e publicações relacionadas com cuidados de saúde, baseados em evidência, e que, por sua vez, permitem identificar práticas de saúde viáveis, apropriadas, significativas e eficazes promovendo a melhoria dos resultados dos cuidados de saúde (Aromataris et al., 2024). A metodologia JBI assume um processo de pesquisa em 3 etapas:

1. No primeiro passo é realizada uma pesquisa exploratória inicial para encontrar artigos científicos que se enquadrem nos critérios de inclusão da questão de revisão, para encontrar referências preliminares.
2. No segundo passo é estruturada uma estratégia de pesquisa abrangente em que são usadas as palavras-chave identificadas, de forma combinada, e, os termos de pesquisa associados, confirmando se as referências iniciais estão presentes na estratégia de pesquisa.
3. O terceiro passo refere-se a uma pesquisa suplementar da *literatura cinzenta*.

(Aromataris et al., 2024)

Embora a metodologia JBI recomende a inclusão de literatura cinzenta para ampliar a abrangência da procura e reduzir o viés de publicação, esta RSL optou por restringir a procura a bases bibliográficas indexadas e com revisão por pares. A decisão foi baseada na expectativa de que as principais evidências relevantes sobre o tema em estudo estivessem concentradas em artigos científicos. Esta decisão foi ainda influenciada por limitações de natureza operacional relacionadas com constrangimentos temporais. Neste sentido, foi uma decisão tomada de forma consciente ficando aqui a referência para garantir a transparência metodológica desta RSL.

A declaração PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*), publicada em 2009 e atualizada em 2020, tem como objetivo auxiliar, os autores de revisões sistemáticas, a dar a conhecer de forma transparente, o motivo que levou à realização da revisão, e o que foi efetuado e concluído (Page et al., 2021) . Destinada, na sua base, a revisões sistemáticas de literatura que avaliam os efeitos das intervenções de saúde, independentemente do desenho dos estudos incluídos (Page et al., 2021).



Traduzido por: Verónica Abreu, Sónia Gonçalves-Lopes*, José Luís Sousa* e Verónica Oliveira / *ESS Jean Piaget - Vila Nova de Gaia – Portugal. Fonte:* Page MJ, McKenzie JE, Bossuyt PM, Boutron I, Hoffmann TC, Mulrow CD, et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. BMJ 2021;372:n71. doi: 10.1136/bmj.n71

Figura 2 | Fluxograma PRISMA 2020 para Revisão Sistemática da Literatura em Bases de Dados.

Os estudos incluídos nesta RSL foram compilados em ficheiro de Word (Microsoft Office Professional Plus, 2021), do qual, foram extraídos os seguintes dados: ano de publicação, país de origem do estudo, metodologia, amostra, tipo de tecnologia de IA utilizada, contexto do estudo, resultados principais, ganhos em eficiência referidos, perceção dos profissionais de saúde sobre a tecnologia se referida.



Figura 3 | Objetivos da RSL

Na avaliação da qualidade metodológica dos artigos científicos incluídos nesta RSL foram aplicadas diferentes listas de verificação metodológica. A sua seleção resultou da identificação do tipo de estudo aplicado em cada um dos 26 artigos que demonstraram conformidade com os critérios de inclusão. A escolha das listas de verificação da qualidade metodológica, dos artigos científicos admitidos para RSL, foi discutida com os assistentes de IA, *Chat GPT -Plus* e *Adobe* versão *Standard,* e validada por pesquisa bibliográfica sobre as opções apresentadas nas bases de dados on-line e respetivas páginas de internet, resultando na seguinte lista de opções aplicadas:

Tabela 1 | Listas de Verificação Metodológica de acordo com a metodologia do estudo.

Metodologia de Investigação	**Listas de Verificação Metodológica**
Estudos Observacionais	STROBE | *Strengthening the reporting of Observational Studies in Epidemiology.*
Revisões Sistemáticas da Literatura	PRISMA | *Preferred Reporting Items for Systematic Reviews and Meta-Analyses.*
Ensaios Clínicos Randomizados	CONSORT-AI | *Consolidated Standards of Reporting Trials– Artificial Intelligence.*
Desenvolvimento e Validação de Modelo Preditivo	TRIPOD+AI | *Transparent Reporting of a Multivariable Prediction Model for Individual Prognosis or Diagnosis + Artificial Intelligence.*
Estudos Qualitativos de melhoria da qualidade.	SQUIRE | *Standards for Quality Improvement Reporting Excellence.*
Estudos Qualitativos	COREQ | *Consolidated Criteria for Reposting Qualitative Research.*
Revisões Narrativas	SANRA | *Scale for the Assessment of Narrative Review Articles.*

Estudos Observacionais:

A avaliação da qualidade metodológica dos artigos de estudos observacionais seguiu a lista de verificação da *Strengthening the reporting of Observational Studies in Epidemiology* (STROBE). A Declaração STROBE apresenta uma lista de verificação constituída por vinte e dois critérios cujo objetivo é o de oferecer orientações sobre como relatar estudos observacionais de forma mais clara e completa contribuindo para a qualidade da sua descrição e para potenciar a generalização (Malta et al., 2010).

Revisões Sistemáticas da Literatura:

A avaliação da qualidade metodológica dos artigos de revisão sistemática da literatura foi efetuada através da lista de verificação *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA). A declaração PRISMA, foi desenvolvida para revisões sistemáticas da literatura que analisam os resultados de intervenções em saúde (Page et al., 2020), o que se coaduna com os artigos científicos incluídos nesta RSL. O seu propósito é o de auxiliar, os autores de revisões sistemáticas da literatura, a garantir que as mesmas sejam publicadas de forma completa, precisa e transparente, facilitando a avaliação da confiabilidade dos resultados, a replicação dos estudos e a tomada de decisões baseadas na evidência (Page et al., 2020). Embora esta RSL se dirija a intervenções na área da saúde baseadas em tecnologias de IA não utilizada a lista de verificação PRISMA AI por não ser possível aceder através dos recursos bibliográficos disponíveis.

Ensaios clínicos randomizados:

A *Consolidated Standards of Reporting Trials–Artificial Intelligence* (CONSORT-AI) é uma extensão da declaração CONSORT 2010 que foi desenvolvida para melhorar a transparência e a consistência dos relatos de ensaios clínicos que avaliem intervenções com tecnologias de IA (Liu et al., 2020). Esta lista tem um total de vinte e cinco critérios de validação, dos quais 14 constituem extensões da CONSORT 2010 que abordam aspetos essenciais para garantir a elaboração do relatório de ensaios clínicos que envolvem IA seja estruturado de forma clara e detalhada, permitindo a replicabilidade e a avaliação crítica, minimizando potenciais enviesamentos e promovendo confiança nos resultados (Liu et al., 2020).

Estudos de desenvolvimento e validação de modelos preditivos:

A Declaração *Transparent Reporting of a Multivariable Prediction Model for Individual Prognosis or Diagnosis* (TRIPOD/TRIPOD+AI) foi aplicada na validação metodológica de estudos de desenvolvimento e validação de modelos preditivos baseados em tecnologias de IA. Esta declaração, apresenta um conjunto de orientações para melhorar a transparência no

desenvolvimento e validação de modelos de predição multivariáveis em medicina, quer se destinem a prognóstico ou a diagnóstico, (Collins, et al., 2024), tendo sido objetivada numa *checklist* de vinte e sete critérios de validação essenciais para garantir a qualidade dos relatos dos estudos (TRIPOD-*statement.org*, 2025). A TRIPOD+AI é uma evolução da TRIPOD (2015), adaptada para incluir modelos preditivos baseados em IA, como os que utilizam métodos de ML, e não apenas modelos de regressão. Um modelo preditivo assenta numa equação matemática que combina informação de origem diversa para prever a probabilidade, ou, presença atual ou ocorrência futura de determinada condição (diagnóstico/prognóstico), (Collins et al., 2015).

Estudos de melhoria da qualidade de intervenções de saúde:

Nos artigos científicos que versam sobre estudos de melhoria da qualidade em intervenções de saúde foi aplicada a lista de verificação metodológica *Standards for Quality Improvement Reporting Excellence* (SQUIRE). A SQUIRE 2.0 é composta por 18 critérios que servem de guia para uma escrita o mais transparente, completa e precisa possível (Ogrinc et al., 2016), tendo sido construída para ser de possível aplicação a uma gama diversa de metodologias de investigação. A sua aplicação é indicada na avaliação da qualidade metodológica de estudos de melhoria de processos ou práticas clínicas em saúde enquadrados numa perspetiva de melhoria da qualidade dos cuidados de saúde.

Estudos Qualitativos:

Relativamente à avaliação da qualidade metodológica de estudos qualitativos utilizou-se a *Consolidated Criteria for Reposting Qualitative Research* (COREQ). Esta lista de verificação tem como objetivo promover a transparência e integridade na elaboração do relatório de investigação incentivando melhores práticas na condução de estudos qualitativos, o que aumenta a sua qualidade e reconhecimento como uma abordagem científica válida (Tong et al., 2007). É composta por trinta e dois critérios distribuídos por três domínios: equipa de investigação e reflexividade, desenho do estudo e análise e resultados.

Revisões narrativas:

Os artigos de revisão narrativa são muito comuns na literatura médica (Baethge et al., 2019). A *Scale for the Assessment of Narrative Review Articles* (SANRA) é uma escala breve de verificação da qualidade de artigos de revisões narrativas. É composta por seis itens: justificação da importância do tema para o leitor; descrição de objetivos concretos e formulação de questões; descrição da revisão de literatura; referências; discussão científica; apresentação de dados apropriada (Baethge et al., 2019).

A aplicação das listas de verificação da qualidade metodológica adequadas a cada tipo de estudo, selecionado, para RSL, resultou numa classificação percentual do grau de conformidade com os critérios de validação de cada uma das listas. Para operacionalização da classificação foi atribuído o valor de 1 por cada critério totalmente cumprido; o valor de 0,5 por cada critério parcialmente cumprido e o valor de 0 por cada critério não cumprido. Desta avaliação resultou um valor compreendido entre 0 > 100% a que corresponde o grau de conformidade. O grau de conformidade, relativamente à lista de verificação metodológica, foi estratificado em quatro níveis: GC < 50% foi considerado com baixa conformidade, GC entre 50 > 69% foi considerado de conformidade aceitável, GC entre 70 > 84% foi considerado com boa conformidade, e, um GC > 90% foi considerado com excelente conformidade.

Tabela 3| Níveis classificação do Grau de Conformidade com a Qualidade Metodológica.

Grau de Conformidade		
85 –100%	Excelente conformidade	Cumpre quase todos os critérios de validação metodológica com elevado rigor. Elevado grau de transparência de integridade e confiabilidade.
70 – 84%	Boa conformidade	Cumpre a maioria dos critérios de validação metodológica, com algumas lacunas menores. O estudo é claro e suficientemente bem documentado, mas poderia melhorar em alguns critérios.
50 – 69%	Aceitável	Cumpre parcialmente os critérios de validação metodológica. Existem algumas fragilidades ou omissões metodológicas relevantes.
< 69%	Baixa conformidade	Apresenta lacunas importantes no cumprimento dos critérios de validação metodológica. A fiabilidade e reprodutibilidade está comprometida.

3. APRESENTAÇÃO DOS RESULTADOS

A pesquisa de artigos de investigação foi conduzida na base de dados PubMed®, através da aplicação da frase booleana definida na estratégia de pesquisa – *Health electronic records AND Artificial intelligence AND Efficiency AND Primary healthcare*, com associação dos filtros *"open access", "full text" e "english"*, o que resultou na identificação dos artigos de investigação a analisar nesta RSL (n=39). Inicialmente, foram excluídos os artigos de investigação duplicados (n=1). De seguida, foi efetuada uma nova triagem ao total de artigos resultantes da primeira triagem (n=38) para avaliar a adequação relativamente aos critérios de inclusão. Após esta segunda triagem foram removidos desta RSL os artigos que não cumpriam os critérios de inclusão (n=12), nomeadamente, por o propósito do estudo não envolver tecnologias de IA. Os restantes artigos de investigação (n=26) foram incluídos nesta RSL. A avaliação da qualidade metodológica dos estudos de investigação (n=26), foi verificada através da aplicação das listas de verificação da qualidade metodológica descritas no capítulo anterior, conforme a metodologia utilizada em cada um dos artigos de revisão. Após leitura e análise dos artigos, de revisão, foi atribuída a pontuação correspondente a cada um dos critérios de validação e efetuado cálculo percentual do índice de conformidade (IC). O resultado obtido foi discutido com os assistentes de IA, *Chat GPT -Plus* e *Adobe* versão *Standard.* A classificação do IC final encontra-se descrita na tabela n°5.

Tabela 4 | Artigos de investigação selecionados para RSL na base de dados Pubmed.

Autores	**Origem**	**Título**	**Classificação JBI**
Bracken, A., Reilly, C., Feeley, A., Sheehan, E., Merghani, K., & Feeley, I.	Irlanda 2025	*Powered Documentation Systems in Healthcare: A Systematic Review.*	100%
Autores	**Origem**	**Título**	**Classificação SANRA**
Bednorz, A., Mak, J. K. L., Jylhävä, J., & Religa, D.	Suécia 2023	*Use of Electronic Medical Records (EMR) in Gerontology: Benefits, Considerations and a Promising Future.*	91,7%
Autores	**Origem**	**Título**	**Classificação CONSORT-AI**
Seol, H. Y., Shrestha, P., Muth, J. F., Wi, C. I., Sohn, S., Ryu, E., Park, M., Ihrke, K., Moon, S., King, K., Wheeler, P., Borah, B., Moriarty, J., Rosedahl, J., Liu, H., McWilliams, D. B., & Juhn, Y. J.	EUA 2021	*Artificial intelligence-assisted clinical decision support for childhood asthma management: A randomized clinical trial.*	84%

Autores	Origem	Título	Classificação COREQ
Kocaballi, A. B., Ijaz, K., Laranjo, L., Quiroz, J. C., Rezazadegan, D., Tong, H. L., Willcock, S., Berkovsky, S., & Coiera, E.	Austrália 2020	*Envisioning an artificial intelligence documentation assistant for future primary care consultations: A co-design study with general practitioners.*	81%
Johnson OA, McCrorie C, McInerney C, Mebrahtu TF, Granger J, Sheikh N., Lawton, T., Habli, I., Randell, R., Benn, J.	Reino Unido 2024	*Implementing an artificial intelligence command centre in the NHS: a mixed-methods study.*	84%

Autores	Origem	Título	Classificação CLAIM
Leingang, O., Riedl, S., Mai, J., Reiter, G., Faustmann, G., Fuchs, P., Scholl, H., Sivaprasad, S., Rueckert, D., Lotery, A., Schmidt-Erfurth, U., Bogunovic, H.	Reino Unido 2023	*Automated deep learning-based AMD detection and staging in real-world OCT datasets (PINNACLE study report 5).*	84,5%

Autores	Origem	Título	Classificação SQUIRE
Duggan, M. J., Gervase, J., Schoenbaum, A., Hanson, W., Howell, J. T., 3rd, Sheinberg, M., & Johnson, K. B.	EUA 2025	*Clinician Experiences With Ambient Scribe Technology to Assist With Documentation Burden and Efficiency.*	88,9%

Autores	Origem	Título	Classificação TRIPOD
Weissenbacher, D., Dutcher, L., Boustany, M., Cressman, L., O'Connor, K., Hamilton, K. W., Gerber, J., Grundmeier, R., & Gonzalez-Hernandez, G.	EUA 2025	*Automated Evaluation of Antibiotic Prescribing Guideline Concordance in Pediatric Sinusitis Clinical Notes.*	93%

Autores	Origem	Título	Classificação TRIPOD+AI
Khurshid S, Friedman S, Reeder C, Di Achille P, Diamant N, Singh P, Harrington LX, Wang X, Al-Alusi MA, Sarma G, Foulkes AS, Ellinor PT, Anderson CD, Ho JE, Philippakis AA, Batra P, Lubitz SA.	EUA Reino Unido 2022	*ECG-Based Deep Learning and Clinical Risk Factors to Predict Atrial Fibrillation.*	85,7%
Gutiérrez, F.; Kennedy, J.I.; Cooksey, R.; Atkinson, M.; Choy, E.; Brophy, S.; Huo, L.; Zhou, S.-M.	Reino Unido 2021	*Mining Primary Care Electronic Health Records for Automatic Disease Phenotyping: A*	72,6%

		Transparent Machine Learning Framework.	
Taylor, N., Kormilitzin, A., Lorge, I., Nevado-Holgado, A., Cipriani, A., & Joyce, D. W.	Reino Unido 2024	*Model development for bespoke large language models for digital triage assistance in mental health care.*	75%
Santos, R., Ribeiro, B., Sousa, I., Santos, J., Guede-Fernández, F., Dias, P., Carreiro, A. V., Gamboa, H., Coelho, P., Fragata, J., & Londral, A.	Portugal 2024	*Predicting post-discharge complications in cardiothoracic surgery: A clinical decision support system to optimize remote patient monitoring resources.*	75%
Zapata, R. D., Huang, S., Morris, E., Wang, C., Harle, C., Magoc, T., Mardini, M., Loftus, T., & Modave, F.	EUA 2023	*Machine learning-based prediction models for home discharge in patients with COVID-19: Development and evaluation using electronic health records.*	65,5%
Ahn, I., Gwon, H., Kang, H., Kim, Y., Seo, H., Choi, H., Cho, H. N., Kim, M., Jun, T. J., & Kim, Y. H.	Coreia do Sul 2021	*Machine Learning-Based Hospital Discharge Prediction for Patients With Cardiovascular Diseases: Development and Usability Study.*	71,4%
Lee, R. Y., Kross, E. K., Torrence, J., Li, K. S., Sibley, J., Cohen, T., Lober, W. B., Engelberg, R. A., & Curtis, J. R.	EUA 2023	Assessment of Natural Language Processing of Electronic Health Records to Measure Goals-of-Care Discussions as a Clinical Trial Outcome.	72,2%
Lee, H., Kim, S., Moon, H. W., Lee, H. Y., Kim, K., Jung, S. Y., & Yoo, S.	Coreia do Sul 2024	*Hospital Length of Stay Prediction for Planned Admissions Using Observational Medical Outcomes Partnership Common Data Model: Retrospective Study.*	79%
Homburg, M., Meijer, E., Berends, M., Kupers, T., Olde Hartman, T., Muris, J., de Schepper, E., Velek, P., Kuiper, J., Berger, M., & Peters, L.	Países Baixos 2023	*A Natural Language Processing Model for COVID-19 Detection Based on Dutch General Practice Electronic Health Records by Using Bidirectional Encoder Representations From Transformers: Development and Validation Study.*	77,3%

Bellocchio, F., Lonati, C., Ion Titapiccolo, J., Nadal, J., Meiselbach, H., Schmid, M., Baerthlein, B., Tschulena, U., Schneider, M., Schultheiss, U. T., Barbieri, C., Moore, C., Steppan, S., Eckardt, K. U., Stuard, S., & Neri, L.	Alemanha Itália 2021	*Validation of a Novel Predictive Algorithm for Kidney Failure in Patients Suffering from Chronic Kidney Disease: The Prognostic Reasoning System for Chronic Kidney Disease (PROGRES-CKD).*	80,9%
Shao, Y., Zhang, S., Raman, V. K., Patel, S. S., Cheng, Y., Parulkar, A., Lam, P. H., Moore, H., Sheriff, H. M., Fonarow, G. C., Heidenreich, P. A., Wu, W. C., Ahmed, A., & Zeng-Treitler, Q.	EUA 2024	*Artificial intelligence approaches for phenotyping heart failure in U.S. Veterans Health Administration electronic health record.*	79,1%
Richter-Laskowska, M., Sobotnicka, E. & Bednorz,	Polónia 2025	*Cognitive performance classification of older patients using machine learning and electronic medical records.*	81%
Autores	**Origem**	**Título**	**Classificação STROBE**
Du, X., Novoa-Laurentiev, J., Plasek, J. M., Chuang, Y. W., Wang, L., Marshall, G. A., Mueller, S. K., Chang, F., Datta, S., Paek, H., Lin, B., Wei, Q., Wang, X., Wang, J., Ding, H., Manion, F. J., Du, J., Bates, D. W., & Zhou, L.	EUA 2024	Enhancing early detection of cognitive decline in the elderly: a comparative study utilizing large language models in clinical notes.	91,7%
Alexander, N., Alexander, D. C., Barkhof, F., & Denaxas, S.	Reino Unido 2021	*Identifying and evaluating clinical subtypes of Alzheimer's disease in care electronic health records using unsupervised machine learning.*	90,6%
Qian, H., Dong, B., Yuan, J. J., Yin, F., Wang, Z., Wang, H. N., Wang, H. S., Tian, D., Li, W. H., Zhang, B., Zhao, L. B., & Ning, B. T.	China 2021	*Pre-Consultation System Based on the Artificial Intelligence Has a Better Diagnostic Performance Than the Physicians in the Outpatient Department of Pediatrics.*	80%
Mermin-Bunnell, K., Zhu, Y., Hornback, A., Damhorst, G., Walker, T., Robichaux, C., Mathew, L., Jaquemet, N., Peters, K., Johnson, T. M., 2nd, Wang, M. D., & Anderson, B.	EUA 2023	*Use of Natural Language Processing of Patient-Initiated Electronic Health Record Messages to Identify Patients With COVID-19 Infection.*	100%
Hernandez-Boussard, T., Blayney, D. W., & Brooks, J. D.	EUA 2020	*Leveraging Digital Data to Inform and Improve Quality Cancer Care. Cancer.*	77%

DiMartino, L., Miano, T., Wessell, K., Bohac, B., & Hanson, L. C.	EUA 2022	*Identification of Uncontrolled Symptoms in Cancer Patients Using Natural Language Processing.*	91%

Dos vinte e seis artigos incluídos nesta RSL todos apresentam um grau de conformidade com as listas de verificação da qualidade metodológica, selecionadas, superior a 50%. Cerca de 96% (n=25) apresentam um grau de conformidade, com a lista de verificação da qualidade metodológica selecionada, de bom ou excelente, sendo que 34,6%, (n=9) conseguiu um grau de conformidade excelente, ou seja, superior a 85%.

O objetivo principal que conduziu este estudo previa a identificação de novas tecnologias, baseadas em IA, que evidenciassem capacidade para melhorar a eficiência do processo de registo eletrónico de saúde. Os vinte e seis artigos de investigação analisados encontram-se sumarizados, relativamente à tecnologia de IA alvo do estudo, a metodologia e os principais resultados no quadro seguinte.

Tabela 5| Artigos Científicos Incluídos na RSL.

Autores **Ano**	**Tecnologia** **Objetivo**	**Metodologia**	**Amostra** **Fonte de Dados**	**Resultados Principais**
Bracken, et al., (2025).	**Qualquer tecnologia de IA.** (*CHAT-GPT, ambient IA*) capaz de gerar documentação clínica. Avaliar a eficiência, qualidade e opinião dos *stakeholders* sobre sistemas de documentação clínica conduzidos por IA.	Metodologia Qualitativa Revisão sistemática da literatura.	Bases de dados: PubMed, Embase e Cochrane library. 3.969 estudos identificados em pesquisa nas bases de dados. 11 estudos foram considerados elegíveis para inclusão.	As tecnologias de IA, como o Chat GPT e a IA ambiente, prometem melhorar a eficiência e a qualidade da documentação clínica. A variabilidade na qualidade da documentação compromete os ganhos de eficiência. Mais investigação é necessária para o desenvolvimento contínuos e para aperfeiçoar ferramentas de IA, melhorar a sua fiabilidade e garantir que podem garantir que cumprem de forma consistente os elevados padrões exigidos na documentação clínica.
Khurshid et al., (2022).	***Deep Learning,* Rede neural convolucional, ECG-AI.** Treino de modelo preditivo de fibrilação auricular (FA), através da análise de ECG de 12 derivações.	Metodologia Quantitativa Estudo retrospetivo. Desenvolvimento de modelo preditivo.	Contexto de treino/validação: 45,770 indivíduos do *Massachusetts General Hospital* (MGH). Conjuntos de teste: - MGH-4 166; - *Brigham and Women's Hospital* (BWH)-37 963. 2000 e 2019 *UK Biobank*–41 033. 2006 e 2010.	A análise de ECG de 12 derivações com tecnologia de IA tem uma utilidade preditiva semelhante a um modelo de fatores de risco clínico estabelecido para a FA – CHARGE-AF. O modelo combinado CH-AI (ECG-AI + CHARGE-AF) teve melhor desempenho comparado com os modelos individuais, tornando a quantificação do risco futuro de FA mais eficiente.
Fernández-Gutiérrez et al., (2021).	***Machine Learning*** Desenvolver uma estrutura transparente de ML capaz de identificar de forma automática uma determinada condição de saúde a partir de RSE.	Metodologia Quantitativa. Estudo Retrospetivo. Desenvolvimento de modelo preditivo.	SAIL *Databank* 544,537 RSE de doentes do ABMU CELLMA *Database* 150,417 RSE de doentes do *Cardiff CELLMA Database*. 917,496,869 registos dos CSP.	O modelo demonstrou ser uma opção eficiente para a identificação de doentes com uma condição de saúde particular a partir de RSE com potencial para contribuir positivamente no processo de decisão clínica. A estrutura desenvolvida reduziu substancialmente a dimensão do conjunto de dados e selecionou um conjunto parcimonioso de características para cada patologia, mantendo a capacidade preditiva.

			40,656,805 registos dos Cuidados de Saúde Diferenciados (CSD). 2002 e 2012	Demonstrou potencial promissor de ser utilizada em estudos relacionados com a saúde.
Taylor et al., (2024).	***Large Language Models:*** *RoBERTa-base; RoBERTa-base-OHFT; Clinical Longformer*. Desenvolver e avaliar 3 abordagens baseadas em LLM para analisar dados não estruturados de RSE para assistir na triagem de referenciações médicas.	Metodologia Quantitativa. Estudo Retrospetivo. Desenvolvimento de modelo preditivo.	RSE de 200,000 doentes, ao longo de uma década, do *Oxford Health NHS Foundation Trust.*	A abordagem *segment-and-batch* demonstrou consistentemente melhor desempenho a processar dados do RSE, e, demonstrou ser adequada para ambientes com recursos limitados (exige apenas uma GPU para treino e inferência). O modelo demonstrou facilidade de treino sem grande necessidade de intervenção humana e potencial para fornecer recomendações de triagem.
Santos et al., (2024).	***Machine Learning*** Desenvolvimento e validação de sistema de suporte à decisão clínica baseado em ML para prever o risco de complicações graves nos 90 dias seguintes a cirurgia cardiotorácica.	Metodologia Quantitativa Estudo Retrospetivo Desenvolvimento de modelo preditivo.	Hospital de Santa Marta, em Lisboa, Portugal. Número de pacientes: 5.045 Número de cirurgias: 5.247 Número de procedimentos médicos: 5.625 2008 e 2019	Os resultados demonstraram capacidade dos modelos para prever complicações pós-alta em cirurgias cardiotorácicas, a longo prazo, o que melhora a eficiência na alocação de recursos de monitorização remota. O modelo preditivo mais eficaz foi o *Random Forrest* (RF) em dois conjuntos de teste distintos. Foram identificadas as caraterísticas mais importantes para o processo preditivo.
Du et al., (2024).	***Large Language Models*** (GPT-4 e LLaMA2) com engenharia de *prompt* ***e Machine Learning*** *(XGBoost, Attention based DNN).* Avaliar a eficácia de modelos de LLMs e de modelos tradicionais de ML na deteção de declínio	Metodologia Quantitativa. Estudo Observacional Retrospetivo, de análise comparativa.	RSE do sistema de saúde *Mass General Brigham, Massachusetts.* Amostra de treino; 4 949 notas clínicas (aleatórias) de 1 969 pacientes, filtradas com palavras-chave.	O modelo ensemble, que combina LLMs (GPT-4) e modelos tradicionais de ML (XGBoost e rede neural profunda baseada em atenção), superou significativamente os modelos individuais em termos de precisão, *recall* e F1-*score*. A combinação dos diferentes modelos pode complementar as suas capacidades e melhorar a precisão diagnóstica de declínio cognitivo com base em notas clínicas de RSE.

	cognitivo em notas clínicas de RSE.		Amostra de teste: 1 996 notas de 1 161 doentes sem filtragem por palavras-chave. 2008 e 2029.	
Alexander et al., (2021).	***Machine Learning*** Aplicação de algoritmos: - *k-means* - *kernel k-means* - *Affinity propagation* - *Latent class analysis* Identificar subgrupos clinicamente relevantes na doença de Alzheimer (DA) através de RSE.	Metodologia Quantitativa. Estudo Observacional Retrospetivo. Desenvolvimento de modelo preditivo.	10 065 doentes com doença de Alzheimer e 9124 com outras demências. 11,3 milhões de RSE de CSP. RSE do *Clinical Practice Research Datalink*, Reino Unido. 1997 e 2016.	O método k-means apresentou os resultados mais consistentes com base em quatro medidas de avaliação identificando cinco subgrupos clinicamente relevantes. As técnicas de ML não supervisionada podem identificar subgrupos de DA clinicamente relevantes. O subgrupo com pior prognóstico recorrente é caraterizado por depressão e ansiedade. O uso de RSE permite o acesso a um registo longitudinal de dados clínicos e não apenas um episódio, o que permite recolher uma ampla gama de variáveis.
Leingang et al., (2023).	***Deep Learning*** Redes neurais convolucionais. Desenvolver e avaliar um modelo de DL para deteção e estadiamento automático de degeneração macular relacionada com a idade (DMRI).	Metodologia Quantitativa. Estudo observacional retrospetivo. Desenvolvimento de modelo preditivo.	Bases de dados de RSE de dois hospitais no Reino Unido: - *University Hospital Southampton;* - *Moorfields Eye Hospital.* 156 872 imagens de tomografia de coerência ótica (TCO) de 6 616 doentes com DMRI e mais de 50 anos. 2007 e 2019. 199 TCO da Base de dados OPTIMA Lab da Universidade Médica de Viena, Áustria.	O modelo mostrou um elevado nível de desempenho a classificar e identificar biomarcadores de DMRI em TCO reais com alta precisão. Demonstro potencial para deteção retrospetiva de início de DMRI e classificação eficiente de conjuntos de dados longitudinais. Potencial de generalização face aos resultados na validação externa (ROC-AUC de 0,994 para diferentes equipamentos de RCO).

Richter-Laskowska et al. (2025).	***Machine Learning*** Avaliar qual o algoritmo de ML mais eficaz na identificação de compromisso cognitivo, através do RSE.	Metodologia Quantitativa. Observacional Retrospetivo.	283 doentes idosos hospitalizados no Hospital Geriátrico João Paulo II, Polónia. Grupo controle – 101 idosos sem comprometimento cognitivo. Grupo comprometimento cognitivo leve – 144 idosos. Demência – 38 idosos. 2015 e 2019.	Os modelos de ML mais eficazes foram SVM com *kernel RBF e Random Forest.* Os modelos podem ser utilizados como ferramenta de triagem em CSP. Modelos aplicáveis em contextos de recursos limitados, pela sua simplicidade e acessibilidade, uma vez que utilizam modelos clássicos de ML e dados do RSE.
Johnson et al., (2024).	**Inteligência Artificial.** Arquitetura de três camadas. Avaliar o impacto do *Bradford Command Centre (BCC)*, ferramenta digital baseada em IA, nos cuidados aos doentes e nos processos hospitalares.	Metodologia Quantitativa e Qualitativa. Estudo Comparativo Misto.	Contexto de Teste: *Bradford Royal Infirmary.* Contexto de controle: *Huddersfield Royal Infirmary.* Estudo qualitativo: - Observações etnográficas. - Entrevistas com pessoal hospitalar, entre 2021 e 2022. Estudo quantitativo: Dados do RSE: *Bradford Royal Infirmary:* 203 807 emergências; 34 625 cirurgias. *Huddersfield Royal Infirmary:* 291 018 emergências 2018 e 2021	Estudo quantitativo: O Centro de Comando foi implementado com sucesso. Verificou-se uma diminuição da taxa de mortalidade. Redução do número de readmissões, a 72 horas, durante o período de estudo. Não se confirmou impacto na qualidade dos dados e no circuito de doentes. Estudo Qualitativo: Os profissionais perceberam o centro de Comando como efetivo na gestão das operações hospitalares durante a pandemia. No entanto, manifestaram preocupação com a qualidade dos dados, a tensão entre a centralização do processo de decisão e a autonomia local, assim como, com um sentimento de estarem a ser vigiados.
Bednorz, et al., (2023).	***Electronic Medical Records* (EMRs) / Inteligência Artificial.**	Metodologia Qualitativa. Revisão narrativa.	Não é especificada a estratégia de procura de artigos científicos.	Os dados de RSE gerados durante os cuidados de saúde a idosos podem ser utilizados para investigação clínica e para promoção da qualidade de cuidados.

	Revisão narrativa sobre o futuro do RSE na gerontologia a aplicação de tecnologia de IA e ML na investigação clínica.			A integração de RSE e IA/ML pode promover a eficiência e segurança dos cuidados. Uma vez que melhora aa comunicação e coordenação de cuidados e pode assistir na tomada de decisão, ou na previsão de risco. A colaboração interdisciplinar e ajuste ao contexto específico é fundamental para garantir o seu sucesso. No entanto, desafios associados a privacidade e segurança, preocupações éticas, qualidade dos dados, carga de trabalho dos profissionais, interoperabilidade têm de ser avaliadas para potenciar o uso de RSE.
Duggan et al., (2025).	***Ambient Scribe Technology* baseada em IA.** (*DAX Copilot; Nuance*| *Haiku; Epic Systems*) Avaliar qualitativamente e quantitativamente a experiência dos profissionais de saúde antes e após a introdução de tecnologia de escrita ambiente, baseada em IA, e, integrada no RSE, enquanto assistente de documentação clínica.	Metodologia Qualitativa e Quantitativa Estudo Misto Prospetivo.	Amostra: 46 profissionais de saúde (médicos, enfermeiros, assistentes de medicina) de um centro médico académico dos EUA. Julho e agosto de 2024.	Redução do tempo por registo clínico, em 20,4%. Aumento do número de registos clínicos efetuadas no próprio dia (9,3%). Diminuição do tempo de trabalho após conclusão do turno para registos clínicos, em 30%. Redução da carga mental atribuída a atividade de documentação clínica. Melhor interação com os doentes percecionada pelos profissionais de saúde. A tecnologia foi considerada de fácil uso, mas não houve consenso sobre a qualidade das notas geradas entre os diferentes profissionais de saúde.
Shao et al., (2024).	***Natural Language Processing. Machine Learning.*** Desenvolver modelos de IA que utilizam tecnologia de ML e NLP para identificar e classificar doentes com insuficiência	Metodologia quantitativa Estudo observacional retrospetivo.	RSE do *Veterans Affairs* dos EUA. Total de 20 000 doentes (10 000 com IC e 10 000 sem registo de IC): - Treino do modelo: 16 000 doentes;	Os modelos de IA com tecnologia de NLP e ML separados ou combinados superaram a classificação tradicional por códigos de *International Classification of Diseases* (ICD) na identificação de doentes com IC nos RSE. O modelo combinado de NLP + MI apresentou a melhor capacidade de precisão na identificação de IC. Os registos criados podem

	cardíaca (IC) no RSE do *Veterans Affairs* dos EUA.	Desenvolvimento de modelo preditivo.	- Validação do modelo: 2 000 doentes; - Teste do modelo: 2 000 doentes; 2014 e 2016.	potenciar estudos de qualidade dos cuidados e de resultados, assim como, de eficácia clínica e de produção de hipóteses.
Qian et al., (2021).	***Natural Language Processing, Deep Learning.*** Avaliar a capacidade diagnóstica de um sistema de pré-consulta, baseado em IA, comparativamente ao desempenho médico e analisar o efeito da consistência dos respetivos registos clínicos, na atividade diagnóstica.	Metodologia Quantitativa. Estudo observacional comparativo.	*Shanghai Children's Medical Center.* RSE de 1 573 utentes da consulta ambulatória de pediatria. 11. 2019 e 05.2020.	Em cenários de análise de dados não tratados, o desempenho do modelo de IA foi inferior ao dos médicos. No cenário com dados consistentes o modelo de IA teve melhor desempenho que os médicos. O modelo de IA demostrou capacidade de produção de registos médicos mais estruturados.
Bellocchio et al., (2021).	***Machine Learning, Naïve Bayes Classifier.*** Treino e validação do modelo de ML, (classificador *Naïve Bayes) - Prognostic Reasoning System for Chronic Kidney Disease* PROGRES-CKD, capaz de prever falência renal em doentes renais crónicos em horizontes de 6 e 24 meses.	Metodologia Quantitativa. Estudo observacional retrospetivo de desenvolvimento e validação de modelo preditivo.	Doentes com doença renal crónica. Treino do modelo: - 17 775 doentes acompanhados no *Fresenius Medical Care (FMC) - NephroCare network* pertencentes a 15 países (Europa, África e América do Sul), de 2017 e 2018. Validação do modelo: - 6 760 doentes do FMC (coorte independente da coorte de treino). - 4 058 doentes do German Chronic Kidney Disease.	O algoritmo PROGRES-CKD demonstrou excelente capacidade preditiva, nas duas coortes independentes, para o risco de terapia de substituição renal, em doentes com doença renal crónica, em horizontes de 6 e 24 meses. O PROGRES-CKD teve resultados não inferiores a equações de risco de falência renal a 24 meses e superiores em previsões aa 6 meses. Pode ser aplicado a todos os doentes mesmo aqueles com dados incompletos, o que, não é possível na aplicação de equações de Risco de Falência Renal. Forneceu métricas, de impacto, especificas para cada doente.

Homburg et al.,(2023).	***Natural Language Processing.*** Desenvolver e validar um modelo BERT para identificar diagnósticos de COVID-19 em RSE de consultas de medicina geral.	Metodologia Quantitativa. Estudo observacional retrospetivo de desenvolvimento e validação de modelo preditivo.	Dados de RSE de 3 centros médicos universitários nos Países Baixos extraídos de 300 359 consultas médicas ou de enfermagem realizadas entre 2019 e 2021. Amostra: - treino: 180 215 consultas. - validação: 60 072 consultas.	O modelo BERT demonstrou: - Uma alta precisão na identificação de casos de COVID-19 em consultas de medicina geral. - Capacidade para identificação precoce de doenças infeciosas. Os 3 métodos de validação do modelo, (validação externa, validação por teste PCR e validação em consultas anteriores a existência de código ICPC para COVID-19), demonstraram fiabilidade e utilidade em diferentes contextos médicos.
Lee et al., (2024).	***Machine Learning.*** Desenvolver a validar um modelo preditivo da duração do internamento hospitalar em admissão planeadas utilizando o modelo de dados comum – *Observational Medical Outcomes Partnership Common Data Model* (OMOP CDM).	Metodologia Quantitativa. Estudo de coorte observacional retrospetivo.	Dados do sistema de RSE, convertidos em OMOP CDM, de 137 437 admissões planeadas, em 2 hospitais da Coreia do Sul (*Seoul National University Bundang Hospital e Seoul National University Hospital).* 2016 a 2020.	O desempenho dos modelos foi consistente e confirmado por validação externa. O modelo *Extreme Gradient Boosting* demonstrou o melhor desempenho na classificação binária com previsões de 7 ou mais dias. O modelo *Light Gradient Boosting* demonstrou o melhor desempenho para múltiplas classificações na previsão de 3 ou mais dias. Já na validação externa o modelo *Random Forest* foi o mais robusto com previsão a 7 ou mais dias. O uso do OMOP CDM permitiu construir modelos reprodutíveis e aplicáveis a diferentes cenários clínicos, com bom desempenho preditivo.
Lee et al., (2023).	***Natural Language Processing*** Avaliar o desempenho, viabilidade e implicações do uso de NLP na medição do resultado principal das discussões sobre objetivos de cuidados documentados nos RSE de ensaios clínicos randomizados.	Metodologia Quantitativa Estudo diagnóstico comparativo.	Doentes com doença grave (n=2 512) hospitalizados em 3 hospitais dos EUA de 23.04.2020 a 26.03.2021. Análise de 44324 registos clínicos do RSE. Validação do modelo: 159 doentes aleatórios e 2480 registos clínicos.	O modelo de NLP, BERT, demonstrou precisão moderada na identificação de objetivos de cuidados documentados. A estratégia de abstração humana aplicada a um conjunto de dados, previamente extraídos pelo modelo, revelou um desempenho robusto, alta sensibilidade, grande economia de tempo e com uma perda mínima de poder estatístico que promete ser uma estratégia promissora para medir resultados complexos em ensaios clínicos, com dados do RSE.

Ahn et al., (2021).	***Machine Learning, Extreme Gradient Boosting (XGB).*** Desenvolver e avaliar a usabilidade de um modelo de ML capaz de prever a probabilidade de alta hospitalar de doentes com doença cardiovascular, num horizonte de 3 dias.	Metodologia Quantitativa. Estudo de desenvolvimento e validação de modelo preditivo.	Registos clínicos (n=84 251) de 63 261 doentes, anónimos, internados nos serviços de cardiologia ou cirurgia torácica do *Asan Medical Center* extraídos da base de dados *CardioNet*, de 2000 a 2016.	O modelo XGB foi o escolhido como modelo preditivo por desempenho superior aos outros modelos testados (AUROC de 0,865). Verificou-se capacidade de previsão de alta clínica num horizonte de 3 dias. O modelo fornece uma explicação individual diária com a previsão de alta clínica e a influência de critérios específicos, que influenciam a probabilidade de alta clínica, para cada doente durante o internamento.
Mermin-Bunnell et al., (2023).	***Natural Language Processing*** Desenvolver e avaliar um modelo de NLP capaz de classificar mensagens enviadas pelos doentes no RSE e identificar, nestas, casos positivos de COVID-19 de forma a reduzir o tempo de resposta médica e de acesso a tratamento antiviral.	Metodologia Quantitativa. Estudo observacional de coorte retrospetivo.	Mensagens (n=187 217) enviadas por adultos para as suas equipas de saúde através do portal do doente (RSE) de 5 hospitais de Atlanta, Geórgia (EUA), entre 30.03.2022 e 01.09.2022. Treino do modelo: 14 537 mensagens.	Elevada precisão e sensibilidade demonstrada pelo modelo de NLP (modelo eCOV). Precisão na classificação das mensagens do modelo de NLP (de 3048 mensagens a comunicar testes positivos de SARS-CoV-2, 97,8% não estavam documentados no RSE. Redução do tempo de resposta clínica melhorando a probabilidade de acesso atempado a prescrição antiviral.
Hernandez-Boussard et al., (2020).	***Natural Language Processing, Machine Learning, Deep Learning.*** Demonstrar a potencialidade da aplicação de tecnologias de NLP e ML/DL em dados de RSE para gerar evidências da qualidade dos cuidados de saúde a doentes oncológicos, num nível populacional.	Metodologia Quantitativa. Estudo observacional retrospetivo.	Doentes de Oncologia que receberam cuidados de saúde no *Stanford Health Care*, entre 2005 - 2018. Fontes de dados: *Stanford Health Care, Califórnia Cancer Registry e Veterans Health Administration*.	Os dados do RSE foram usados com sucesso na avaliação da adesão a *guidelines* e medidas de qualidade no tratamento de doentes com cancro. O sistema CAPTIVE demonstrou capacidade para extrair e transformar dados digitais do RSE fornecendo informação capaz de contribuir para melhorar os cuidados de saúde. A aplicação de tecnologias de NLP/ML/DL em dados de RSE mostraram potencial para melhorar os cuidados de saúde oncológicos e suportar estudos epidemiológicos.

Kocaballi et al., (2020).	**Inteligência Artificial** Perceber o potencial de assistentes de documentação baseados em IA nas consultas de cuidados de saúde primários. Identificar as implicações para médicos, doentes, sistemas de saúde e desenho da tecnologia na perspetiva dos médicos de CSP.	Metodologia Qualitativa. *Workshops.*	Médicos de CSP (n=16), e exercer na Austrália há mais de 3 anos, que utilizassem RSE regularmente. Foram realizados três *wokshops*, dois dos quais na *Macquarie University* (*Sidney*, Austrália) e um na *Cirqit Health* (*Melbourne*, Austrália).	A análise temática identificou três temas principais: autonomia profissional, colaboração humana-IA e novos modelos de cuidado. Assistentes de documentação baseados em IA vão provavelmente ser integrados no futuro nas consultas em CSP. No entanto estas tecnologias vão necessitar de supervisão humana até termos uma evidência muito forte de confiança no seu desempenho autónomo. - A autonomia profissional deverá ser considerada no desenho do sistema. - Será necessária a investigação sobre diferentes modelos de colaboração humana-IA. - A IA pode suportar novos modelos de cuidado.
DiMartino et al., (2022).	***Natural Language Processing, Machine Learning.*** Avaliar a viabilidade da utilização de NLP para identificar no RSE sintomas não controlados (dor, dispneia, náusea e vómitos) em doentes internados com cancro em estado avançado.	Metodologia quantitativa. Estudo observacional retrospetivo.	Conjunto de dados de 1 644 internamentos, nos hospitais da *University of North Caroline* entre 01.01.2017 e 30.06.2019. 15 580 notas clínicas do Carolina *Data Warehouse for Health* da Universidade da Carolina do Norte.	O modelo de NLP demonstrou utilidade na identificação de dor não controlada, embora com um elevado número de falsos positivos. A capacidade de identificação de dispneia, náusea/vómitos foi mais limitada com baixa sensibilidade. É necessário mais estudos para melhorar a sensibilidade do modelo e permitir uma aplicação mais ampla.
Seol et al., (2021).	***Clinical Decision Support, Natural Language Processing, Machine Learning*** Avaliar a eficácia e eficiência de uma ferramenta de suporte à decisão clínica assistida por IA (A-	Estudo quantitativo. Ensaio clínico randomizado.	Crianças, (n=184), com diagnóstico de asma, dos CSP pediátricos da *Mayo Clínic (MC), Minnesota,* EUA. Dados de saúde do sistema de RSE da MC.	Não houve evidência de diferença na ocorrência de episódios de exacerbação da asma entre o grupo de teste e o grupo de controle. Redução substancial do tempo necessário para análise dos RSE para gestão clínica da asma o que pode contribuir para diminuir o desgaste dos profissionais de saúde. Redução dos custos diretos com cuidados de saúde, na gestão da asma, embora não seja significativa.

	GPS), capaz de otimizar a gestão clínica da asma em crianças.			
Zapata et al., (2023)	***Machine Learning*.** Desenvolvimento e validação de modelo preditivo, supervisionado, para prever se um doente hospitalizado com COVID-19 teria como destino o domicílio ou teria necessidade de continuidade de cuidados.	Metodologia Quantitativa Estudo de coorte retrospetivo. Desenvolvimento de modelo preditivo.	Sistema de RSE da *University of Florida Health Integrated Data Repository.* 1 578 adultos com teste positivo para COVID-19, entre 01.01.2020 e 08.11.2020.	Desenvolvimento de seis modelos baseados em ML supervisionada *(logistic regression, Gaussian Naïve Bayes, k-nearest neighbors, decision trees, random forest,* e *vector machine classifier*) para previsão de condição para alta médica. O modelo *random forest classifier* foi o que demonstrou melhor desempenho. Os modelos de ML utilizaram dados do RSE para compreender o prognóstico de saúde. O modelo permitiu melhor compreensão dos fatores que influenciam a condição de saúde e pode auxiliar no processo de triagem precoce, hospitalar, ao identificar doentes que vão necessitar continuidade de cuidados.
Weissenbacher et al., (2025).	***Modelos generativos de Large Language para processar Linguagem Natural*** Desenvolvimento e avaliação de sistema generativo com técnicas de processamento de NLP para verificar a adequação da prescrição de antibióticos a crianças com sinusite.	Metodologia Quantitativa. Estudo de Coorte retrospetivo de desenvolvimento e validação de modelo preditivo.	Centros de cuidados de saúde primários da rede do Children's Hospital of Philadelphia (n=32), entre 01.07.2017 e 30.06.2021. Seleção aleatória de 300 notas clínicas de 10311 doentes < 18 anos com diagnóstico de sinusite.	O LLM mais abrangente *Llama 3.1 405B-instruct model* mostrou melhores resultados na identificação de notas clínicas com prescrição adequada para Sinusite. A combinação de técnicas de *prompt – few-shot learning e chain-of-thought prompting*, assim como a introdução de normas clínicas simplificadas e explicações com exemplos melhoraram o desempenho do modelo. O desempenho do modelo demonstrou potencial para ser aplicado em RSE como assistente de prescrição e na monitorização da prescrição em larga escala. Notas clínicas vagas ou ambíguas são um desafio ao desempenho do modelo.

Relativamente às opções de metodologia de investigação dos artigos de revisão, verificamos que 80,8%, (n=21), representam estudos que utilizam metodologia quantitativa dos quais: estudos observacionais (n = 6), estudos de desenvolvimento/validação de modelo preditivo (n = 13), ensaios clínicos randomizados (n = 1). A metodologia qualitativa foi opção em cerca de 11,5% dos estudos, (n=3), e cerca de 7% apresentam uma metodologia mista (n=2).

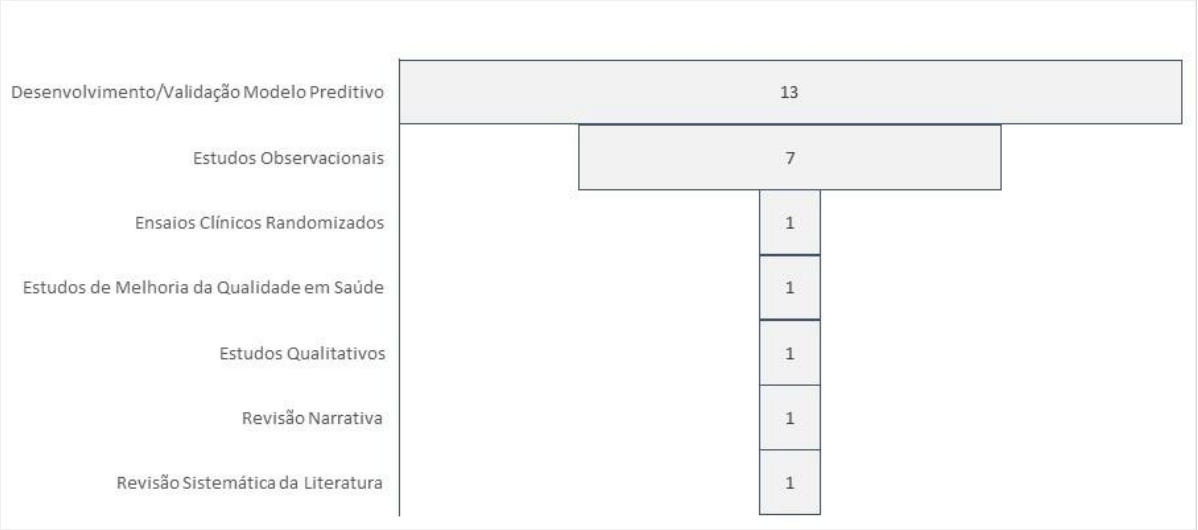


Figura 4 | Metodologia de Investigação dos Artigos de Revisão.

3.1 Objetivo nº1 | Identificar novas tecnologias de inserção/análise de dados de saúde.

3.1.1 Gestão de documentação:

Nesta RSL encontramos três estudos de investigação direcionados à utilização de IA para a gestão de documentação: Bracken, et al., (2025), Duggan et al., (2024) e Kocaballi et al., (2020), o que representa cerca de 11,5% do total de artigos.

Bracken et al. (2025) evidencia numa RSL o potencial de tecnologias como o CHAT-GPT e tecnologias de *ambient AI* para gerar documentação clínica de forma mais eficiente e com maior qualidade. Por sua vez Duggan et al. (2024) testa quantitativamente e qualitativamente o Ambient Scribe Tecnology (DAX CoPilot; Nuance) e um sistema de RSE integrado numa aplicação móvel (Heiku: Epic Systems) que permite gravar consultas em CSP, de forma a automaticamente gerar um quadro de informação relevante que emerge da gravação da consulta. Kocaballi et al., (2020), embora não centre o seu estudo na aplicação de uma tecnologia específica, faz um estudo qualitativo para perceber o potencial de tecnologias de IA enquanto assistentes à documentação clínica do ponto de vista dos

profissionais de saúde.

3.1.2 Análise de dados de saúde:

Do total de artigos desta RSL cerca de 85%, (n=22), têm como objetivo o processamento de dados de saúde para gerar conhecimento sobre previsões, riscos associados e a identificação das mais diversas condições de saúde.

A tecnologia de ***machine learning*** (ML) foi utilizada em oito dos estudos desta RSL com o objetivo de desenvolver e validar modelos preditivos (n=5) com aplicação na previsão de alta médica hospitalar, (Zapata et al., 2023; Ahn et al., 2021), na duração provável do internamento hospitalar (Lee et al., 2024) e na previsão de agravamento da doença/complicações pós-cirúrgicas (Bellocchio et al., 2021; Santos et al., 2024), e ainda, com o objetivo de avaliar a capacidade dos modelos na identificação de grupos/subgrupos de determinadas condições de saúde (n=3), clinicamente relevantes. Estes incidem sobre a identificação de declínio cognitivo em idosos (Richter-Laskowska et al., 2025), a identificação de subgrupos com interesse clínico na DA (Alexander et al., 2021) ou a identificação automatizada de uma determinada condição de saúde (Fernández-Gutiérrez et al., 2021). Os modelos com melhor desempenho identificados pelos autores estão apresentados no quadro seguinte:

Tabela 6| Modelos de ML testados.

Autores	**Modelo de ML**	**Desempenho**
Fernández-Gutiérrez et al., (2021).	Árvores de decisão.	Opção mais eficiente. Maior transparência no processo de transformação de dados em conhecimento.
Santos et al., (2024).	*Random Forest Classifier.*	Modelo mais eficaz no desenvolvimento do CDSS.
Zapata et al., (2023).		Modelo com melhor desempenho na previsão de alta médica.
Alexander et al., (2021).	Algoritmo *K – means.*	Apresentou os resultados mais consistentes na identificação de subgrupos relevantes na DA.
Richter-Laskowska et al. (2025).	SVM com *kernel RBF e Random Forest.*	Maior eficácia. Aplicabilidade em contextos de recursos limitados pela sua simplicidade e acessibilidade
Bellocchio et al., (2021).	Classificador Naïve Bayes.	O algoritmo desenvolvido *Prognostic Reasoning System for Chronic Kidney Disease* PROGRES-CKD revelou excelente capacidade preditiva.

Lee et al., (2024).	*Extreme Gradient Boosting.* *Light Gradient Boosting.* *Random Forest.*	Os modelos apresentaram bom desempenho preditivo no geral embora se destaquem individualmente de acordo com o tipo de classificações e horizonte de previsão pretendida.
Ahn et al., (2021).	*Extreme Gradient Boosting.*	Modelo preditivo com desempenho superior, com boa capacidade preditiva de alta médica a três dias.

A tecnologia de ***deep learning*** (DL) foi aplicada em dois dos estudos desta RSL cujo objetivo se relaciona com o desenvolvimento de modelos preditivos. Kurshid et al. (2022) desenvolveram um modelo preditivo (ECG-AI) capaz de prever incidentes de FA através da análise de ECG de 12 derivações, enquanto que Leingang et al. (2023) desenvolveram um modelo preditivo para deteção e estadiamento automático de degeneração macular relacionada com a idade (DMRI) através do processamento de imagens de TCO.

Outra das tecnologias de IA identificada nos estudos desta RSL permite a comunicação entre humanos e máquinas através de linguagem natural. Tecnologia de ***natural language processing*** (NLP) foi aplicada na identificação de casos de COVID-19 através de notas clínicas de RSE referentes a consultas de CSP por Homburg et al. (2023) e através de mensagens enviadas pelos doentes no sistema de RSE (Mermin-Bunnell et al.,2023). Lee et al., (2023) utilizou NLP para medir resultados complexos de ensaios clínicos.

Encontrou-se ainda a aplicação de ***large language model*** por Taylor et al. (2024) para desenvolver uma ferramenta para assistência à triagem de referenciações médicas através de dados não estruturados de RSE.

Em sete dos estudos de investigação (26,9%) foram combinadas mais do que uma das referidas tecnologia de IA com o propósito de:

- Avaliar a qualidade dos cuidados de saúde, em que Hernandez-Boussard et al., (2020) recorrem a uma combinação de NLP, ML e DL, DiMartino et al., (2022) recorrem a NLP e ML e Weissenbacher et al., (2025) recorrem a LLM e NLP;
- Desenvolver ferramentas de identificação e classificação de determinada condição de saúde em que Du et al., (2024) recorrem a LLM e ML e Shao et al., (2024) utilizam uma combinação de NLP e ML.
- Avaliar a capacidade diagnóstica de um modelo em que Qian et al., (2021) utilizam uma combinação de NLP e DL.
- E avaliar a eficácia e eficiência de ferramentas de apoio à decisão clínica para o qual, Seol et al., (2021) combinam NLP e ML.

Resultado desta RSL restam dois artigos de investigação, num dos quais Bednorz, et al., (2023) conduzem uma revisão narrativa sobre o futuro do RSE e a aplicação de tecnologias de IA e ML na investigação clínica de forma geral e no segundo Johnson et al., (2024) avaliam o impacto de uma ferramenta digital baseada em IA nos cuidados de saúde e nos processos hospitalares, mas não especificam qual a tecnologia utilizada.

3.2 Objetivo nº2 | Identificar ganhos em eficiência.

De forma a dar resposta ao segundo objetivo desta RSL procurou-se identificar os ganhos em eficiência associados diretamente à utilização da tecnologia ou a potenciais ganhos, referidos pelos autores. Consideraram-se os ganhos em eficiência associados aos cuidados de saúde, à otimização de processos, e à gestão de recursos.

Tabela 7 | Ganhos em eficiência associados ao uso de tecnologias de IA identificados pelos autores.

Autor	Tecnologia	Ganhos em Eficiência
Bracken, et al., (2025).	**Qualquer tecnologia de IA** (*CHAT-GPT, ambient IA*) capaz de gerar documentação clínica.	Eficiência de processo: - O Chat GPT e o *ambient* IA prometem melhoria da eficiência da documentação clínica, pela diminuição do tempo necessário para a mesma e o tempo necessário para cada consulta.
Khurshid et al., (2022).	***Deep Learning*** **Rede neural convolucional, ECG-AI.**	Eficiência de cuidados de saúde: - O ECG-IA, demonstrou capacidade de quantificar de forma rápida e automática o risco futuro de FA, utilizando apenas o ECG de 12 derivações. - A identificação de indivíduos com risco acrescido de FA, a longo prazo, (5 anos) permite melhorar atitudes preventivas e de monitorização.
Fernández-Gutiérrez et al., (2021).	***Machine Learning***	Eficiência de processo: - Ferramenta eficiente para identificar coortes de doentes com uma condição específica, no RSE, especialmente útil em estudos de saúde, recrutamento para ensaios clínicos, análise de sobrevivência e previsão de resultados.
Taylor et al., (2024).	***Large language models:***	Eficiência de recursos: - Redução do tempo de triagem de referenciações médicas, o que, permite otimizar o tempo dos profissionais com tarefas administrativas. - Tecnologia viável em sistemas de saúde com recursos limitados, treino completo do modelo realizado em 12 horas em uma única *Graphics Processing Unit* (GPU) o que representa um custo inferior quando comparado com serviços comerciais de ML.

Santos et al., (2024).	***Machine Learning CDSS.***	Eficiência de recursos: - A identificação automática de doentes de alto risco de complicações graves pós cirurgia cardiotorácica permite uma atribuição mais eficiente de equipamentos de monitorização remota. Eficiência de cuidados de saúde: - Possibilita a monitorização o nível de risco semanalmente após a alta hospitalar permitindo melhor acompanhamento clínico.
Du et al., (2024).	***Large Language Models e Machine Learning (***	Eficiência de cuidados de saúde: - Deteção precoce e automática de declínio cognitivo através de registos no RSE. Identificação de sinais de declínio cognitivo até 4 anos antes do diagnóstico, potenciando intervenções clínicas precoces, otimizar longitudinalmente o acompanhamento clínico.
Alexander et al., (2021).	***Machine Learning***	Eficiência de cuidados de saúde: - Identificação automatizada e mais eficiente de subgrupos relevantes, da DA, na prática clínica, o que potencia tratamentos personalizados, prognósticos mais preciso e uma gestão mais eficiente da doença.
Leingang et al., 2023.	***Deep Learning***	Eficiência de recursos: - O modelo de *deep learning* permite automatizar o processo de identificação e estadiamento de DMRI, através de TCO reais, em bases de dados de grandes volumes. Eficiência de processo. - A localização de biomarcadores facilita a atenção ao especialista sobre áreas especificas, o que leva a economia de tempo e esforço. Eficiência de cuidados de saúde: - A identificação retrospetiva do início de DMRI em dados longitudinais permite uma identificação mais precisa da sua progressão.
Richter-Laskowska et al. (2025).	***Machine Learning Supervisionada.***	Eficiência de cuidados de saúde: - Capacidade de identificar declínio cognitivo com elevada precisão através dos registos do RSE, de forma automatizada. Eficiência de recursos: - A simplicidade e acessibilidade dos modelos permite implementar esta tecnologia em contextos de recursos limitados. A utilização de dados do RSE evita a necessidade de exames dispendiosos e especializados.
Johnson et al., 2024.	**Inteligência Artificial.** *Bradford Command Center* (ferramenta digital baseada em IA)	Eficiência de processo: - Otimização do processo de alta clínica. Facilitou o planeamento das altas clínicas ao identificar precocemente doentes prontos a ter alta, reduzindo atrasos. - Otimização do circuito dos doentes: Melhorou a gestão de camas e as transferências de doentes. - Processo de decisão mais rápido: Dados em tempo real permite decisões mais informadas e atempadas. - Melhor coordenação das equipas e melhor comunicação entre os diferentes intervenientes do circuito do doente.

		- Melhoria da capacidade de monitorização de indicadores e de resposta proativa a desafios emergentes percecionado pelos gestores.
Bednorz, et al., (2023).	***Electronic Medical Records* (EMRs) / Inteligência Artificial.**	Eficiência de processo: - Documentação mais compreensiva e precisa; otimização da comunicação entre os diferentes profissionais e contextos clínicos; acesso remoto a dados de saúde; redução da redundância da informação; automatização de tarefas administrativas otimizando o fluxo de trabalho; melhoria no processo de gestão de terapêutica; otimização da monitorização de tendências. - Disponibilização automatizada de dados; redução de custos de pesquisa; acompanhamento longitudinal da condição de saúde dos indivíduos e populações. - Desenvolvimento de modelos preditivos; capacidade de processar grandes volumes de dados; gerar simulações prognósticas e de previsão de risco.
Duggan et al., (2025).	***Ambient Scribe Technology* baseada em IA.**	Eficiência de recursos: - Redução do tempo utilizado por registo clínico. Eficiência de processos: - Aumento dos registos clínicos concluídos no próprio dia. - Redução do tempo de trabalho fora do horário de trabalho para completar registos clínicos.
Shao et al., (2024).	***Natural Language Processing, Machine Learning.***	Eficiência de processo: - Maior capacidade e sensibilidade em identificar doentes com IC, reduzindo falsos positivos, comparativamente a modelos tradicionais baseados em códigos. - Padronização do processo de classificação da IC eliminando a variabilidade entre revisores médicos e entre diferentes instituições conferindo maior consistência do resultado. - Disponibilização de recursos úteis (dados longitudinais e representativos de populações reais) para estudos clínicos e qualidade dos cuidados. Eficiência de recursos: - Automatização do processo de classificação IC em grandes volumes de dados do RSE eliminando o procedimento de revisão manual de registos clínicos.
Qian et al., (2021).	***Natural Language Processing, Deep Learning.***	Eficiência de cuidados de saúde: - O modelo demonstrou capacidade de gerar dados mais estruturados e padronizados o que facilita o processo de diagnóstico, aumentando a sua eficiência e a redução de erros de diagnóstico. Eficiência de recursos: - O modelo de IA pode contribuir para a redução da carga de trabalho médico enquanto assistente na atividade diagnóstica em pré-consulta.

Bellocchio et al., (2021).	***Machine Learning, Naïve Bayes Classifier.***	Eficiência de cuidados de saúde: - Identificação precoce de doentes com maior risco de falência renal permitindo encaminhamento oportuno ou colocação de acesso vascular atempadamente. - Personalização de cuidados através do fornecimento de métricas específicas para cada doente. Eficiência de recursos: - Previsão do risco de falência renal automatizada reduzindo o trabalho cognitivo do profissional médico no seu cálculo manual. - A precisão da identificação evita referenciações desnecessárias para tratamentos dispendiosos.
Homburg et al., (2023).	***Natural Language Processing.***	Eficiência de cuidados de saúde: - Deteção precoce de doenças infeciosas o que pode potenciar a preparação e resposta atempada a surtos epidémicos, assim como, tratamento atempado. - Elevada precisão no processo de identificação de casos de COVID-19, contribuindo para redução de erros de diagnóstico e melhorado a eficiência diagnóstica. Eficiência de recursos: - Automatização da identificação de consultas de COVI-19 através de dados não estruturados, evitando uma análise manual. - O modelo BERT, pré-treinado e de código aberto, constitui uma abordagem custo-efetiva pois minimizou a necessidade de recursos computacionais alargados e dados rotulados.
Lee et al., (2024).	***Machine Learning.***	Eficiência dos cuidados de saúde: - Oferece uma visão longitudinal do doente permitindo personalizar os cuidados de saúde e adequar as estratégias de alta clínica. Eficiência de processo: - Maior coordenação de cuidados entre os diferentes serviços do hospital. - Otimização da ocupação de camas hospitalares. - Facilidade de integração em sistemas de RSE padronizados. Eficiência de recursos: - A precisão da predição do tempo de internamento permite melhor planeamento e gestão dos recursos hospitalares, reduzindo custos.
Lee et al., (2023).	***Natural Language Processing***	Eficiência de recursos: - Redução do tempo e recursos necessários para colheita de dados manual mantendo perda mínima de valor estatístico e sensibilidade aceitável, que se traduz em eficiência de tempo dos profissionais e de custos. Eficiência de processo: - Precisão na identificação de resultados permitindo aos investigadores identificar resultados dos cuidados em grandes bases de dados.

Ahn et al., (2021).	***Machine Learning, Extreme Gradient Boosting (XGB).***	Eficiência de processos: - Eficiência na gestão operacional do hospital pela melhoria de processos hospitalares relacionados com a gestão de camas de internamento. - Eficiência distributiva pela automatização do processo de previsão de alta, diminuindo a carga de trabalho médica. Eficiência de cuidados de saúde: - Cuidados mais personalizados proporcionados pela identificação de fatores de risco possíveis de influenciar a alta de cada doente.
Mermin-Bunnell et al., (2023).	***Natural Language Processing***	Eficiência de processo: - Automatização do processo de triagem de mensagens iniciadas pelos doentes reduzindo carga de trabalho dos profissionais. - Potencial para melhorar sistema de documentação ao identificar casos positivos de COVID-19 não documentados no RSE. Eficiência de cuidados de saúde: - Redução do tempo de resposta médica com consequente probabilidade de acesso a tratamento adequado.
Hernandez-Boussard et al., 2020.	***Natural Language Processing, Machine Learning, Deep Learning***	Eficiência de processos: - O RSE permitiu o acesso a dados de saúde reais, longitudinais, multidisciplinares e de diferentes populações que podem potenciar estudos epidemiológicos mais custo eficientes. - Extração automática de informação clínica relevante do sistema de RSE, através de dados estruturados e não estruturados o que pode contribuir para economizar tempo e recursos humanos necessários em revisões manuais. Eficiência de cuidados de saúde: - Monitorização em tempo real da qualidade dos cuidados através do sistema CAPTIVE facilitando a decisão clínica.
Kocaballi et al., 2020.	**Inteligência Artificial**	Eficiência de processos: - Automatização do procedimento de documentação clínica e de tarefas repetitivas burocráticas. Novos modelos de cuidados de saúde: - Possibilidade de pré-consulta de dados de saúde digitais ou auto-registos de sintomas nos sistemas de saúde com recurso a tecnologias de IA capazes de apresentar informações de apoio à decisão clínica. - Otimização de fluxos de atendimento e possibilidade de consultas para doentes em locais remotos, através de teleconsultas - *mobilhealth,* ferramentas de suporte que permitem ao doente a gestão da sua doença.

DiMartino et al., 2022.	***Natural Language Processing, Machine Learning.***	Eficiência de cuidados de saúde: - Identificação automática de doentes com sintomas não controlados, principalmente a dor, através de dados não estruturados dos sistemas de RSE. - Identificação e encaminhamento precoce de doentes para os Cuidados Paliativos. Eficiência de recursos: - Redução de internamentos não planeados por descontrolo de sintomas em estádios avançados de cancro.
Seol et al., 2021.	***Clinical Decision Support, Natural Language Processing, Machine Learning***	Eficiência de processo: - Diminuição do tempo para revisão clínica manual de RSE resultado numa mais eficiente gestão da asma e na redução da sobrecarga dos profissionais de saúde. Eficiência de cuidados de saúde: - Seguimento mais oportuno após a exacerbação da asma.
Zapata et al., 2023.	***Machine Learning.***	Eficiência de cuidados: - Conhecer melhor os fatores que contribuem para o prognóstico do doente com COVID-19. Eficiência de recursos: - A identificação precoce (triagem) de doentes que vão necessitar de mais cuidados permite decisões mais rápidas de alocação de recursos.
Weissenbacher et al., 2025.	***Modelos generativos de Large Language para processar Linguagem Natural***	Eficiência de processo: - Possibilita a monitorização da prescrição automática e em larga escala permitindo agilizar a revisão manual da prescrição. Eficiência de cuidados: - Potencial para melhorar a prática clínica permitindo revisões periódicas da prescrição.

Em todos os estudos desta RSL foram identificados ganhos em eficiência associados à utilização de tecnologias de IA relacionados com as três áreas anteriormente referidas definidas: cuidados de saúde, recursos e processos. Foram relatados contributos para a eficiência dos cuidados de saúde em cerca de 69%, (n=18), contributos para a eficiência dos recursos em cerca de 50%, (n=13) e contributos para a eficiência de processos em cerca de 54%, (n=14), dos estudos.

Uma vez que os recursos afetos aos cuidados de saúde são um dos eixos fundamentais do funcionamento dos sistemas de saúde vou iniciar por apresentar os ganhos em eficiência a eles associados e identificados nesta RSL. Encontramos relatos que evidenciam melhorias na eficiência da gestão do tempo dos PS relacionadas com tarefas administrativas. São vários os autores que referem a diminuição do tempo necessário com documentação clínica quer seja através de tecnologias para registo automatizado de dados de saúde (Lee et al. 2023; Taylor et al. 2024; Duggan et al. 2025) quer através

de algoritmos que permitem a identificação automatizada de diagnósticos através de sistemas de RSE (Qian et al. 2021; DiMartino et al. 2022; Homburg et al. 2023; Shao et al. 2024). A capacidade de automatização de tarefas administrativas associadas a grandes volumes de dados foi igualmente identificada como um indicador de eficiência de recursos de que é exemplo a classificação automatizada de imagens de TCO para identificação de DMRI (Lleingang et al. 2023). Outro indicador de eficiência de recursos resulta da precisão demonstrada dos modelos preditivos que permitem conhecer a probabilidade de agravamento da condição de saúde (Bellocchio et al. 2021; Santos et al. 2024) ou a necessidade de cuidados especializados (Zapata et al. 2023) ou mais prolongados (Lee et al. 2024) o que permite programar atempadamente necessidades de recursos humanos e evitar tratamentos desnecessários. Ainda na procura de eficiência de recursos, Richter-Laskowska et al., (2025) referem que a utilização de modelos clássicos de ML e bases de RSE tornam a tecnologia acessível a contextos de baixos recursos.

De igual modo foram procuradas referencias a melhorias da eficiência de processos relacionados com a atividade de saúde, independentemente de serem processos de gestão, operacionais ou de suporte. Neste sentido, encontramos referencia a melhorias associadas uma mais eficiente gestão de camas hospitalares e melhor coordenação entre os diferentes serviços com a aplicação de um modelo preditivo de ML num estudo em que se pretendia prever a probabilidade de alta de doentes cardiovasculares a três dias (Ahn et al., 2021) e noutro em que se pretendia prever a duração do internamento em admissões planeadas (Lee et al., 2024). Johnson et al. (2024) refere otimização do processo de alta clínica e do circuito dos doentes com a instalação de um centro de comando baseado em IA capaz de detetar precocemente doentes com probabilidade de alta.

Relativamente a melhorias na eficiência de cuidados de saúde foram consideradas que diretamente ou indiretamente contribuem para melhorar os cuidados prestados pelos profissionais de saúde. A capacidade das tecnologias de IA de extraírem informação relevante em grandes bases de dados foi aplicada nas mais diversas áreas de intervenção nos estudos desta RSL. Hernandez-Boussard et al., (2020), evidencia como exemplo a revisão manual de informação clínica que é extremamente consumidora de tempo e difícil de abranger um grande número de dados. Encontrou-se referencia a diminuição do tempo para revisões clínicas com a utilização de tecnologias de IA em Hernandez-Boussard et al., (2020), Weissenbacher et al., (2025), e em Seol et al., (2021). Weissenbacher et al., (2025) conseguiu-o com recurso a tecnologia de LLM associada a NLP para automatizar a monitorização da prescrição de antibioterapia em crianças com diagnóstico de sinusite, em larga escala, enquanto, Seol et al., (2021) utiliza um CDSS para otimizar a gestão da asma em crianças. Este último refere ainda que

a tecnologia utilizada permitiu uma mais eficiente gestão da asma e uma redução na carga de trabalho dos profissionais. As tecnologias de IA integradas em sistemas de RSE além da extração automatizada de informação relevante, têm acesso a dados de saúde longitudinais, multidisciplinares e relativos a diferentes populações o que pode potenciar a eficiência de estudos de epidemiológicos ao reduzir os custos associados (Hernandez-Boussard et al., 2020), assim como, de estudos clínicos e de qualidade de cuidados (Shao et al., 2024). Outra área de aplicação de tecnologias de IA com relato de melhoria na eficiência de cuidados está relacionada com ferramentas de IA capazes de identificar determinada condição de saúde relevante para o contexto através do acesso a dados estruturados ou não estruturados que podem ter origem no RSE, (Alexander et al., 2021; Qian et al., 2021; Lee et al., 2023; Leingang et al., 2023; Shao et al., 2024) ou em mensagens com origem nos doentes (Mermin-Bunnell et al., 2023). A melhoria de eficiência foi associada à diminuição do número de erros de diagnóstico (Qian et al., 2021; Shao et al., 2024) e à possibilidade de realizar intervenções mais direcionadas, mais precisas e personalizadas (Alexander et al., 2021). Na documentação de dados de saúde, Mermin-Bunnell et al., (2023) referem que o desempenho dos modelos de IA utilizados gerou informação mais estruturada e padronizada o que facilita o processo de diagnóstico aumentando a sua eficiência.

3.3 Objetivo nº3 | Identificar a perceção dos profissionais de saúde sobre a utilização de tecnologias de IA.

Os resultados da identificação da perceção dos profissionais de saúde nos estudos da RSL foram sumarizados no quadro seguinte.

Tabela 8| Resultados da identificação da perceção dos profissionais de saúde relativamente à tecnologia de IA.

Autores	Tecnologia	Perceção dos Profissionais de Saúde
Bracken, et al., 2025.	**Tecnologias de IA para gestão documental.** (*CHAT-GPT, ambient IA*)	A opinião dos *stakeholders* foi geralmente positiva. - Facilidade de utilização com interfaces simples e intuitivas. - Redução da carga de trabalho com documentação, especialmente em casos complexos. - Capacidade de gerar documentação com formatação estruturada e clara. No entanto expressaram algumas preocupações relativas a: - Precisão da informação geradas associadas a erros e "alucinações". - Preocupação com perda de detalhes importantes na narrativa clínica. - Fiabilidade e validade dos sistemas de IA.

Fernández-Gutiérrez et al., 2021.	***Machine Learning***	Não avaliada. Ressalvam a importância da transparência e do poder explicativo dos modelos de ML para que sejam amplamente aceites, pelos PS.
Taylor et al., (2024).	***Large language models:***	Não avaliada. Recomendam avaliar a aceitação e utilidade da tecnologia através de testes com profissionais de saúde em ambientes simulados com o objetivo de perceber como se processa a interação com o sistema e como pode influenciar as decisões, em futuras investigações.
Santos et al., (2024).	***Machine Learning, CDSS.***	Não avaliada. Referem a participação ativa, dos PS, através de reuniões e discussões, na criação do sistema.
Bednorz, et al., (2023).	***Electronic Medical Records* (EMRs) / Inteligência Artificial.**	Não avaliada. Refere a perceção positiva pelos PS dos benefícios do RSE e tecnologias de IA na promoção de melhores cuidados de saúde e na eficiência dos mesmos. No entanto, abordam aspetos negativos como ferramentas pouco intuitivas, *burnout* associado ao tempo necessário para o RSE e diminuição da satisfação profissional. Referem necessidade de treino adequado no uso de RSE e ferramentas de IA, não adequação aos fluxos de trabalho e a falta de soluções ajustadas ao contexto para um uso efetivo. Recomendam uma colaboração interdisciplinar, equipas de apoio técnico para acompanhar problemas de usabilidade e um desenho centrado na pessoa.
Duggan et al., (2025).	***Ambient Scribe Technology* baseada em IA,** (*DAX Copilot; Nuance / Haiku; Epic Systems*)	A perceção dos profissionais envolvidos evidenciou: - Menor carga mental com a documentação. - Melhor interação com os doentes. - A tecnologia foi considerada fácil de usar. - Falta de consenso relativamente à qualidade das notas clínicas divergindo entre os que consideraram as notas precisas e detalhadas e os que relataram necessidade de revisão e edição substancial.
Homburg et al., (2023).	***Natural Language Processing.***	Não avaliada. Referido que o desenvolvimento do modelo resultou de um esforço multiprofissional.
Hernandez-Boussard et al., (2020).	***Natural Language Processing, Machine Learning, Deep Learning.***	Não avaliada. Referida a colaboração entre médicos, epidemiologistas, informáticos e técnicos de qualidade no desenvolvimento do algoritmo.

Kocaballi et al., (2020).	**Inteligência Artificial** assistentes de documentação baseados em IA.	Reconhecem o potencial e inevitável integração de IA nos cuidados de saúde primários: - Reconhecem a importância da IA como assistente de cuidados, mas não como substituta dos profissionais. - Reconhecem potenciais ganhos de eficiência através da otimização do procedimento de registo de dados de saúde com consequente otimização da gestão de tempo. - Reivindicam participação ativa no desenho do sistema. - Revelam preocupação com segurança, autonomia de decisão e introdução de viés nas decisões clínicas. - Valorizam a relação humana entre médico/doente. - Referem novos modelos de cuidado que facilitam a acessibilidade a cuidados de saúde e fornecem suporte na autogestão da doença.

A perceção dos profissionais de saúde sobre a utilização de tecnologias de IA foi avaliada em três dos estudos de investigação, desta RSL, representando cerca de 12% do total. Neles verificamos que a perceção dos PS é condicionada por três fatores. O primeiro são as preocupações e reservas relativas à tecnologia, o segundo as condições ou requisitos percecionados como essenciais e os ganhos percebidos. Kocaballi et al. (2020) diz-nos que os PS consideram ser inevitável e positiva a integração de tecnologias de IA nos sistemas de documentação clínica dos CSP, reconhecendo a importância da IA no papel de assistente de cuidados, mas não em substituição dos PS, e, potenciando o desenvolvimento de novos modelos de cuidado. Por seu lado, Bracken, et al., (2025), refere que os PS associam as ferramentas de gestão de documentação clínica a maior eficiência e qualidade, embora ressalve a necessidade de mais investigação para garantir os modelos apresentam critérios de fiabilidade e cumprem de forma consistente os elevados padrões exigidos na documentação clínica, Duggan et al., (2025).

Noutros estudos (N=6), embora os seus objetivos não contemplem a avaliação da perceção dos PS sobre as tecnologias de IA, foi possível extrair informação que refere a colaboração entre profissionais de diversas áreas da saúde no desenvolvimento dos modelos de IA (Hernandez-Boussard et al., 2020; Homburg et al., 2023; Bednorz, et al., 2023; Santos et al., 2024), sendo também referida a importância de abordagens transparentes e explicáveis para promover a confiança nos PS, e garantir a fiabilidade e usabilidade na prática clínica (Fernández-Gutiérrez et al., 2021; Homburg et al.,2023; Santos et al., 2024). Para Bednorz et al. (2023) os PS revelam uma atitude positiva sobre os benefícios dos sistemas de RSE e tecnologias de IA enquanto potenciadores de melhores cuidados de saúde e da sua eficiência. No entanto, ressalvam que para isso é necessário investir no treino dos PS, assegurar que os sistemas são intuitivos de não consumidores de tempo extra de trabalho e que o seu desenho esteja centrado na

pessoa. Neste sentido, Taylor et al. (2024) sugerem mais investigação em que a tecnologia seja alvo de avaliação por PS em ambiente simulado de forma a compreender as interações com o sistema e como este pode influenciar as decisões na prática clínica.

4. DISCUSSÃO DE RESULTADOS

Esta RSL partiu de um processo de reflexão sobre quais as tecnologias de IA que poderiam otimizar o procedimento de registo eletrónico de dados de saúde, quais os seus contributos em termos de eficiência e como são vistas pelos PS. Nesta perspetiva foi concebido um desenho para um estudo de investigação.

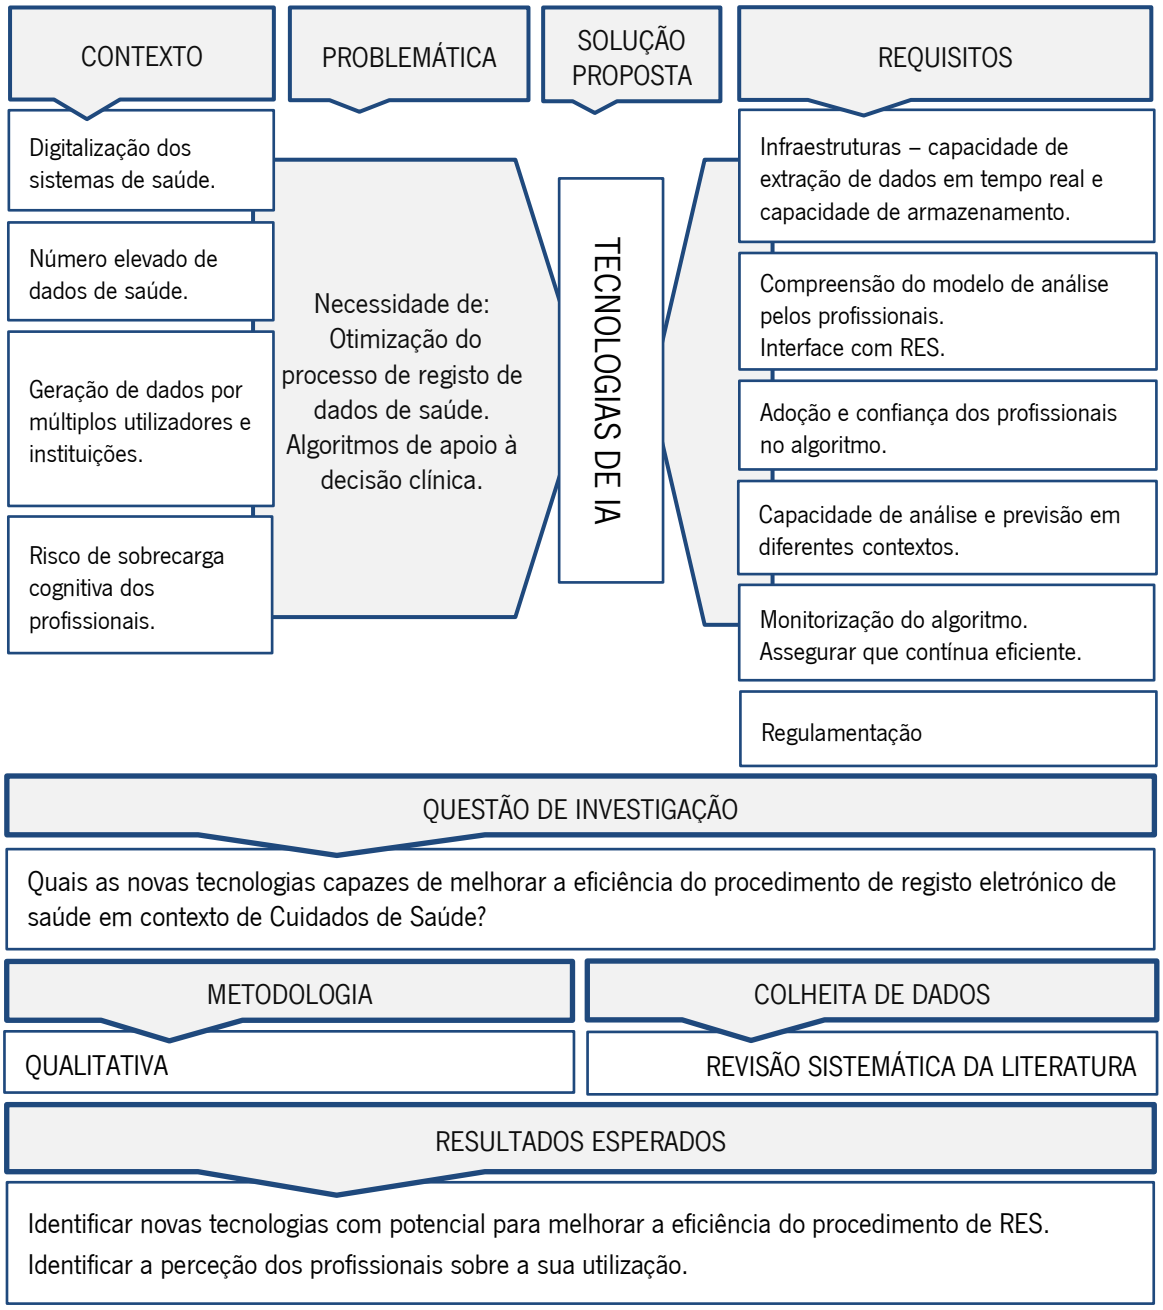


Figura 5 | Desenho do estudo de investigação.

Foram incluídos nesta RSL 26 estudos de investigação onde se verificou que a nacionalidade de origem dos artigos de revisão tem maior representatividade em países como os EUA (n = 11) e Reino Unido (n = 7), representando cerca de 69% do total. No entanto, verificou-se uma grande diversidade na nacionalidade de origem dos restantes artigos. Verificou-se ainda que cerca de 69% (n=18) dos vinte e seis artigos desta RSL foram publicados entre 2023 e 2025. Os dados recolhidos evidenciam um interesse crescente a nível mundial sobre a aplicação de tecnologias de IA na área da saúde o que vai ao encontro dos resultados de Bracken et al. (2025).

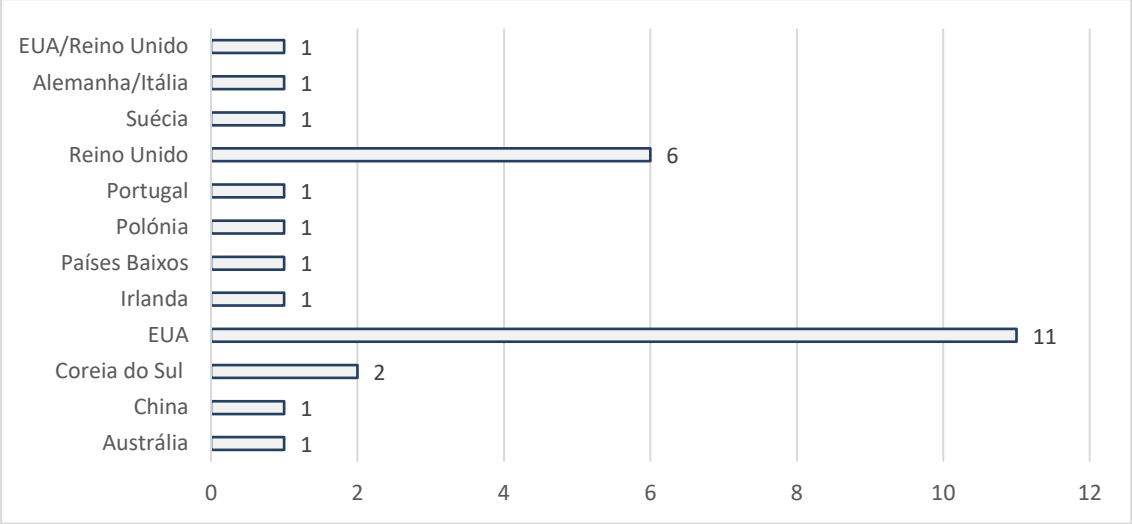


Figura 6 | País de origem do estudo de investigação.

4.1 Papel dos Sistemas de RSE.

Nela, foi reforçada a potencialidade dos sistemas de RSE e os diversos benefícios da integração de tecnologias digitais de IA. A utilização de sistemas de RSE esteve presente em 100% dos estudos incluídos na RSL o que é revelador da sua importância, nos dias de hoje. Alexander et al., (2021) e Qian et al. (2021) referem-se aos sistemas de RSE como um repositório de informação, longitudinal, que permite a colheita de inúmeras variáveis individuais assim como de coortes representativas o que vai ao encontro da literatura atual. Contextos de saúde que contemplam acesso universal a toda a população, como é o caso de Portugal, e em que é possível ter um sistema de RSE que integra todas as instituições públicas, e, dentro de algumas funcionalidades as instituições privadas de saúde, congregam dados digitais de saúde que conseguem uma grande representatividade da sua população. Este contexto abre novas e inúmeras possibilidades para a investigação em saúde e para estudos epidemiológicos e de saúde das populações, (Hernandez-Boussard, 2020) e também para a identificação de diagnósticos ou níveis de risco específicos o que permite a implementação de medidas preventivas ou mais

personalizadas (Alexander et al., 2021), assim como, melhorar a precisão dos processos de decisão, os processos de previsão de resultados em saúde e de estratificação de risco, contribuindo para melhores cuidados de saúde (Qian 2021).

A par da inegável importância do RSE como fonte de informação para tecnologias de IA surgem preocupações associadas ao registo de dados não estruturados, em texto narrativo, muitas vezes com linguagem idiossincrática, o que, dificulta a extração de informações relevantes para decisões clínicas, assim como preocupações associadas com a qualidade dos registos aí incorporados (Alexander et al., 2021), o que põe alguns desafios na implementação de tecnologias de IA nos sistemas de RSE.

4.2 Tecnologias de IA.

Esta RSL evidenciou um maior investimento em soluções tecnológicas direcionadas a análise de dados de saúde e de ferramentas preditivas apresentando um rácio de 22/26. No entanto, sabemos pela literatura que o peso do tempo destinado à atividade de registo de notas clínicas e a sua complexidade é fator de sobrecarga nos profissionais (Gaffney A. et al., 2022; Budd J. et al., 2023). Nesta RSL encontramos três estudos de investigação direcionados à utilização de IA para a gestão de documentação: Bracken, et al., (2025), Duggan et al., (2024) e Kocaballi et al., (2020), o que representa um rácio de 3/26. Duggan et al., (2025), apresenta uma solução que demonstrou capacidade para reduzir o esforço mental associado à atividade de registo clínico e agilizar o fluxo de trabalho ao tornar a introdução e registo de notas clínicas mais eficiente com recurso a uma ferramenta de tradução ambiente (Haiku, da Epic Systems). Embora não tenha sido consensual, entre os profissionais, a capacidade da ferramenta na produção de notas clínicas de qualidade, os profissionais referiram como vantagem o fato de não terem de começar do zero o registo e a utilidade dos dados registados na condução do registo final, reduzindo o esforço mental, assim como, a melhoria da interação com o doente. Já Bracken et al. (2025) numa RSL melhoria de eficiência e de qualidade na produção de documentação clínica com recurso a tecnologia de IA generativa, como o CHAT-GPT, e tecnologias de *ambient AI*. Estes resultados vão ao encontro de Paatela et al., (2024) que associa a utilização de equipamentos de IoT para registos clínicos, em contexto domiciliário, a redução do tempo necessário para a realização dos mesmos e a Bongurala, A., et al., (2024) que associa tecnologia de transcrição oral de notas clínicas à redução do tempo necessário para introdução manual o que otimiza o processo de registo clínico. Pelo contrário, Heponiemi et al. (2021) associa negativamente o uso de dispositivos móveis e o bem-estar dos PS, sugerindo que para a sua implementação com sucesso será necessário torná-los de fácil utilização, adequa-los ao fluxo de trabalho e capacitar os PS na sua utilização. Outro tema que surge na RSL,

abordado por Kocaballi et al., (2020) e Bracken et al. (2025) é que apesar da potencialidade dos assistentes de documentação baseados em IA para integrar as consultas de CSP, é necessário assegurar uma supervisão humana que garanta a segurança, qualidade de cuidados e precisão destas tecnologias.

As tecnologias de IA presentes nos estudos desta RSL foram aplicadas no processamento de dados de saúde para gerar conhecimento sobre previsões, riscos associados e a identificação das mais diversas condições de saúde. A sua escolha surge associada ao objetivo pretendido, ao tipo de dados e ao tamanho da base de dados como sugere o quadro seguinte onde se apresentam as diferentes tecnologias de IA e atividades associadas em estudo que emergiram desta RSL.

Tabela 9 | Lista de Tecnologia de IA e atividades associadas por autor.

PROCESSO	TECNOLOGIA	ATIVIDADE	AUTORES
Infraestruturas de Suporte	Transcrição ambiente IoT	Colheita de dados de saúde, localmente ou remotamente. Transcrição ambiente de notas clínicas.	Bracken, et al., 2025. Duggan et al., 2025.
Processamento de linguagem natural.	NLP	Identificação e classificação diagnóstica.	Mermin-Bunnell et al., (2023).
			Homburg et al.,(2023).
		Extração de informação clínica.	Lee et al., (2023).
	NLP LLMs	Extração de informação clínica.	Hernandez-Boussard, (2020).
		Monitorizar a qualidade da prescrição.	Weissenbacher et al., (2025).
	NLP | ML	Identificação e classificação diagnóstica.	Shao et al., (2024).
		Identificação de determinada condição de saúde.	DiMartino et al., 2022.
	LLM	Assistente de triagem.	Taylor et al., (2024).
		Produção de documentação clínica.	Bracken, et al., (2025).
	LLM | ML	Interpretação diagnóstica de notas clínicas.	Du et al., (2024).
	NLP | DL	Atividade diagnóstica.	Qian et al., (2021).
	NLP | DL | ML	Avaliação da qualidade de cuidados. Suportar estudos epidemiológicos.	Hernandez-Boussard et al., 2020.
Modelos de aprendizagem por máquina.	ML	Identificação de determinada condição de saúde.	Alexander et al., (2021).
			Richter-Laskowska et al. (2025).
			Fernández-Gutiérrez, 2021.
		Previsão de tempo de internamento.	Lee et al., (2024).

		Previsão de alta clínica.	Ahn et al., (2021).
			Zapata et al., 2023
		Monitorização e avaliação em tempo real da qualidade dos cuidados.	Boussard, 2020.
		Previsão de complicações clínicas.	Bellocchio et al., (2021).
		Otimização de fluxos hospitalares.	Zapata et al., (2023).
Processar grandes volumes de dados.	DL	Interpretação de imagens médicas.	Leingang et al., (2023).
		Modelos preditivos	Khurshid et al., (2022).
		Gestão da documentação clínica.	Bracken, et al., 2025.
Sistemas de apoio à decisão clínica. (CDSS)	NLP ML	Assistente na decisão clínica.	Seol et al., 2021.
		Fenotipagem de patologias.	Shao et al., 2024.
		Previsão de risco de complicações graves pós-cirúrgicas pós-alta.	Santos et al. 2024).

Um dos critérios sugeridos por Taylor et al., (2024) para o sucesso da integração de tecnologias de IA na saúde é a sua adequabilidade aos recursos limitados dos sistemas de saúde. Este aspeto é também evidenciado por alguns dos autores desta RSL (Homburg et al., 2023; Shao et al., 2024) e Taylor et al., 2024) referindo-se à vantagem de certos modelos de IA quando se analisa a relação custo-eficiência. Homburg et al., (2023) refere a vantagem da utilização de um modelo de código aberto e pré-treinado para minimizar os custos de implementação. Também, Shao et al., (2024) e Taylor et al., (2024) sugerem a utilização de modelos de código de público e arquitetura simples para facilitar a reprodução do modelo e a implementação/adaptação a outros contextos de saúde. O potencial de generalização, enquanto capacidade de aplicar os padrões aprendidos em novos conjuntos de treino e de escabilidade, enquanto capacidade de manter o desempenho perante um aumento de dados, complexidade ou procura, implica a validação dos modelos em diferentes contextos de cuidados de saúde e em diferentes contextos clínicos (DiMartino et al., 2022; Homburg et al., (2023); Santos et al., 2024; Leingang et al., 2023; Lee et al., 2024) o que vai ao encontro do que é referido na literatura por Bongurala, A., et al., (2024).

Na tabela anterior podemos verificar a maior incidência da aplicação de tecnologias de ML e NLP, em combinação com outras tecnologias ou isoladamente.

A ML desenvolve algoritmos pode aprender relações a partir de dados, sem estarem necessariamente definidas à partida e que melhoram automaticamente com a experiência tendo atualmente um vasto leque de aplicações na saúde que abrangem desde a previsão de eventos,

classificação e análise (Seth et al., 2024). O procedimento de ML envolve quatro etapas, a harmonização de dados, aprendizagem da representação, ajuste do modelo e validação. Um dos principais atrativos desta tecnologia é a capacidade de gerar modelos preditivos, (Miotto et al., 2018). Os modelos preditivos baseados em ML, aplicados nos estudos desta RSL, são unanimes sobre o potencial desta tecnologia na produção de cuidados de saúde mais personalizados contribuindo para um maior equilíbrio entre as necessidades individuais dos doentes e a utilização dos recursos disponíveis (Zapata et al., 2023), promovendo ganhos de eficiência (Bellocchio, 2021). A persecução de cuidados de saúde personalizados não é apenas relevante quando visamos a eficiência, um estadiamento mais preciso da patologia evita tratamentos desnecessários, que ocorrem em maior risco de efeitos adversos, e, no desenvolvimento de fadiga terapêutica com consequente diminuição da adesão terapêutica (Bellocchio et al., 2021). De acordo com Davenport & Kalakota (2019), ML representa a forma mais comum de IA e, na saúde, a sua aplicação mais frequente é na medicina de precisão o que vai ao encontro Zapata et al. (2023) e Bellocchio et al. (2021). A precisão requer um conjunto de dados de treino para o qual a variável de resultado é conhecida e nestes casos designa-se por aprendizagem supervisionada (Davenport & Kalakota, 2019). Os algoritmos de ML, standard, necessitam de milhares de exemplos para atingir um desempenho aceitável o que se traduz num processo dispendioso e consumidor de recursos, (Weissenbacher et al., 2024). O mesmo é referido por Clark & Michaels, (2024) salientando que se não foram salvaguardados os requisitos de acesso a dados pode-se dar origem a modelos com treino incompleto o que resulta em menor capacidade de resultado. O desenvolvimento de modelos de ML requer ainda acesso a bases de dados com informação estruturada e robusta de forma a garantir o bom desempenho do modelo o que torna necessário o processamento prévio de dados para criar conjuntos adequados ao treino dos modelos (Ahn et al., 2023). A potencialidade desta tecnologia requere por isso sistemas de RSE estruturados e capazes de armazenar grandes quantidades de dados e, que esses dados tenham rigor científico e sejam generalizáveis de forma a fazer face a preocupações relacionadas com enviesamento e equidade dos algoritmos (Hernandez-Boussard et al., 2020). Também Qian et al. (2021) identifica como um desafio na introdução de tecnologias de IA nos RSE a garantia de um conjunto preciso de dados iniciais que permita aos modelos extrair um conjunto estruturado de dados. Estes autores mostram alinhamento com Gianfrancesco, (2018) quando refere que a presença de enviesamento no processamento de dados pode levar os sistemas de IA a gerar decisões incorretas. É, portanto, fundamental que estes modelos tenham uma política de transparência relativamente aos dados usados para treinar e validar os modelos (Hernandez-Boussard, 2020).

Neste sentido, o investimento em instrumentos capazes de agilizar e tornar mais eficiente o

processo de assimilação de dados pelos sistemas de RSE, assim como sistemas de validação externa poderão contribuir para sistemas mais robustos e mais estruturados, com maior confiabilidade nos algoritmos e assegurar aplicabilidade em diferentes populações.

Um subgrupo de ML também presente nesta RSL é a tecnologia de DL que permite a extração automática de padrões e representações complexas, de fontes heterogéneas de dados brutos, com recurso apenas a um procedimento de aprendizagem geral e sem necessidade de intervenção de engenharia humana. Esta tecnologia trouxe grandes avanços no processamento de imagens, vídeo, fala e aúdio. (LeCun, Y., Bengio, Y., & Hinton, G. (2015) e Miotto et al. (2018). Esta RSL este potencial como vemos no modelo preditivo de FA através da leitura de ECG de 12 derivações de Kurshid et al. (2022) ou no modelo preditivo de deteção e estadiamento de DMRI através do processamento de imagens de TCO de Leingang et al. (2023). A tecnologia de DL surge ainda associada a ML e NLP. Hernandez-Boussard et al., (2020) associam NLP, DL e ML num sistema de RSE para obter evidências da qualidade de cuidados a doentes oncológicos a nível populacional enquanto Qian et al., (2021) utilizaram NLP num sistema de préconsulta para comunicar com os doentes e DL para extrair informação diagnóstica e disponibilizando no RSE informação diagnóstica estruturada o que facilita o processo de diagnóstico médico.

NLP representa a segunda tecnologia mais frequente nesta RSL. A NLP possibilita a comunicação entre pessoas e máquinas utilizando a linguagem do dia a dia, permitindo ao software compreender e responder à linguagem humana. O seu desempenho depende da capacidade de captar as palavras e de compreender a linguagem humana e esta compreensão torna necessário a associação de outras tecnologias de IA como a ML e DL. (Du et al., 2024). A LLMs é uma das áreas do NLP que surge associada a cinco dos estudos desta RSL. A LLM é uma tecnologia de processamento de linguagem natural, que modela a linguagem humana de forma matemática e com capacidade para usar grandes quantidades de dados, através dos quais treina modelos de ML, para realizar tarefas de NLP de forma mais eficiente e precisa (Xu, D., 2024). Recentemente, modelos de LLM generativos têm mostrados resultados notáveis na compreensão e produção de textos (Xu, D., 2024). Como exemplos temos o Open AI GPT-3 e GPT-4 da Open AI ou os modelos Llama da Meta, os modelos PaLM, codificadores bidirecionais da Google, transformadores BERT/RoBERTA, os modelos Granite da IBM. Os sistemas generativos têm interfaces que permitem aos utilizadores a introdução de prompts em linguagem natural para desempenhar uma tarefa (Weissenbacher et al., 2024). Um *prompt* são instruções que especificam a ação desejada assim como os dados necessários para desempenhar a tarefa (Weissenbacher et al., 2024).

A utilização de modelos de NLP promete agilizar o processo ao facilitar a extração de dados de saúde digitais de texto livre, presentes em muitos registos clínicos de saúde (Hernandez-Boussard et al., 2020; Homburg et al., 2023). A analise de dados de RSE recorrendo a NLP, isoladamente ou em combinação com ML, foi alvo de investigação em alguns dos artigos desta RSL. Mermim-Bunnell et al. (2023) demonstrou a elevada precisão e sensibilidade, de um modelo de NLP, na classificação e triagem de mensagens iniciadas pelo doente, e, recebidas no sistema de RSE, o que permitiu diminuir o tempo de resposta clínica e a redução da carga de trabalho dos profissionais de saúde, assim como, potencia o acesso atempado a tratamento adequado. Similarmente, Qian et al. (2021) analisou o desempenho de um modelo de pré-consulta capaz de produção diagnóstica através de dados clínicos introduzidos pelos doentes em dispositivos médicos. Já Homburg et al. (2023) desenvolveu e validou um modelo de NLP para identificar, nos RSE de consultas dos CSP, casos de COVID-19 verificando-se uma elevada precisão em diferentes contextos.

Apesar das vantagens descritas na utilização desta tecnologia de IA, DiMartino et al. (2022) evidencia que a aplicação de tecnologia de NLP em cuidados de saúde requer refinamento técnico ajustado ao contexto clínico e melhoria de práticas de documentação inseridas nos sistemas de RSE. Este requisito é de igual modo referido por Du et al. (2024) para os quais, as tecnologias de LLMs, de domínio geral, devem ser sujeitas a um maior refinamento quando o propósito se destina a aplicações de apoio à decisão clínica, necessitando de aprimorar estratégias de *prompting*, de *fine-tuning*. O potencial desta tecnologia não se limita a aumentar a eficiência técnica relacionada com a realização de tarefas clínicas, mas também na disponibilização de recursos que podem ser utilizados para estudos de investigação para avaliar eficácia clínica, qualidade de cuidados de saúde e de resultados assim como gerar hipóteses (Shao et al., 2024; Fernández-Gutiérrez et al., 2021). O potencial de NLP para a produção, compreensão e classificação de documentação clínica é também referido na literatura por Davenport, & Kalakota, 2019). Também referem a capacidade destes sistemas para analisar notas clínicas não estruturadas e daí produzir relatórios, transcrever interações com os doentes e conduzir conversação.

A combinação das diferentes tecnologias de IA permite tirar benefícios das potencialidades individuais de cada uma face ao objetivo e condicionantes do contexto individual.

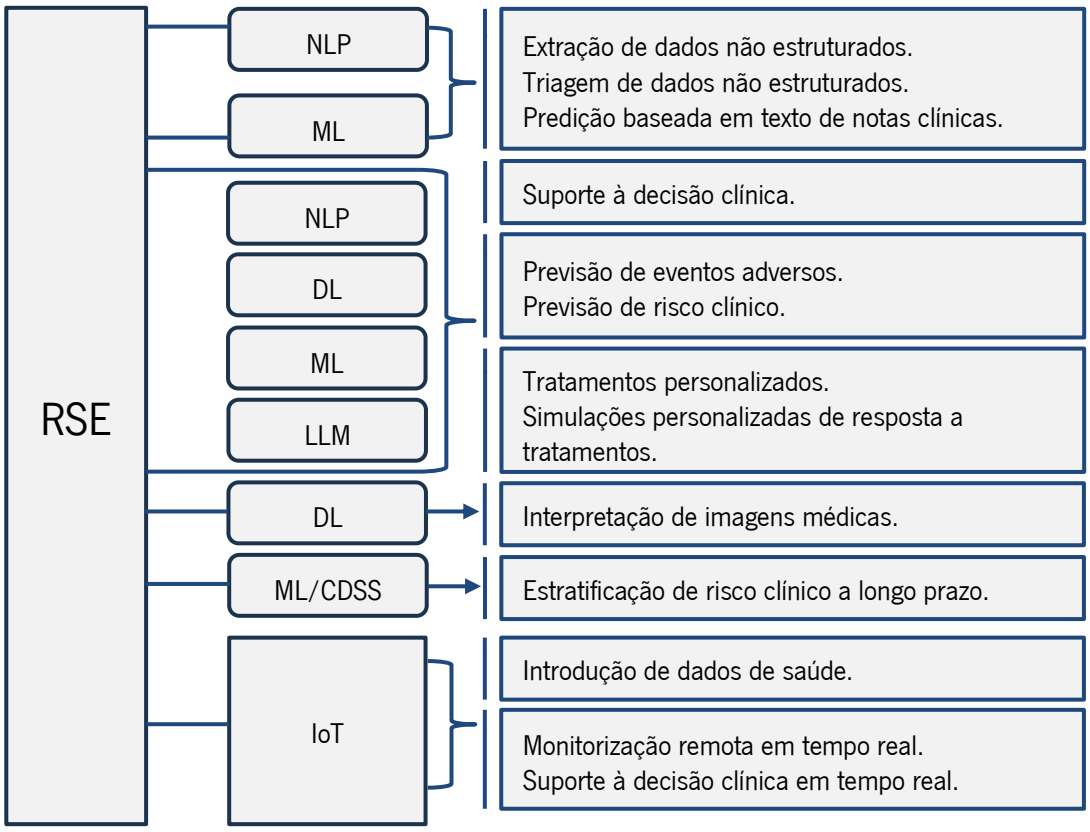


Figura 7| Relação Tecnologias de IA/campo de intervenção.

4.3 Ganhos em eficiência:

O objetivo principal que foi traçado para este estudo prende-se com a identificação de novas tecnologias, baseadas em inteligência artificial, que mostrem evidência de capacidade para melhorar a eficiência do procedimento de registo eletrónico de saúde. Em todos os estudos desta RSL foram identificados ganhos em eficiência associados à utilização de tecnologias de IA relacionados com três áreas de intervenção: cuidados de saúde, recursos e processos. Em treze dos estudos foram identificadas referência a ganhos em **eficiência de recursos** resultantes da otimização de tempos de trabalho associados à documentação clínica (Kocaballi et al., 2020; Seol et al., 2021; Bracken et al., 2025; Weissenbacher et al., 2025). Bracken et al. (2025) refere que o processo de documentação clínica, com assistência de IA, promete ganhos em eficiência associados à redução do tempo necessário para a sua realização, o que, tem um efeito positivo na prevenção do *burnout* associado à sobrecarga do processo de documentação clínica e ao uso intensivo de RSE o que vai ao encontro de Fennlly, (2020); Paatela et al., (2024) e Bongurala et al., (2024). Neste contexto, Fennily (2020), refere preocupação com sobrecarga de informação associada à grande variedade e grande volume de dados o que pode

ultrapassar a capacidade humana de tomada de decisão sobre cuidados de saúde.

Nos estudos analisados constata-se o potencial da IA para automatizar tarefas repetitivas ou que requerem análise de um grande número de dados como as revisões de processos, monitorização da prescrição ou estudos de investigação (Bednorz, et al., 2023; Lee et al., 2023; Mermin-Bunnell et al., 2023; Kocaballi et al., 2020; Seol et al., 2021), o mesmo, defende Davenport et al. (2019). Ele considera que as tecnologias de IA possibilitam automatizar processos repetitivos e a extração de informação valiosa a partir de grandes volumes de dados, promovendo a eficiência e a precisão no cuidado do doente.

Outro tema que surgiu desta RSL foi a capacidade da tecnologia de IA promover a otimização de processos de gestão de altas/internamentos/triagem e do circuito dos doentes, assim como, melhorar a coordenação entre equipas (Johnson et al., 2024; Lee et al., 2024; Ahn et al., 2021) e contribuir para novos modelos de cuidados (Kocaballi et al., 2020).

Tabela 10 | Ganhos em Eficiência identificados na RSL.

Eficiência	Autores	Ganhos em Eficiência associados a Tecnologias de IA.
Eficiência de Processos	Bracken, et al., (2025).	Redução do tempo com documentação clínica. Redução do tempo por consulta.
	Leingang et al., (2023).	Identificação e estadiamento automático de DMRI, de TCO.
	Johnson et al., (2024).	Otimização do processo de alta clínica. Otimização do circuito dos doentes. Melhor coordenação das equipas. Melhoria da capacidade de monitorização de indicadores e de resposta proativa a desafios emergentes.
	Bednorz, et al., (2023).	Documentação mais compreensiva e precisa. Otimização da comunicação entre os diferentes profissionais e contextos clínicos. Disponibilização automatizada de dados de saúde mesmo em locais remotos. Automatização de tarefas administrativas otimizando o fluxo de trabalho. Melhoria no processo de gestão de terapêutica; otimização da monitorização de tendências. Redução de custos de pesquisa; Capacidade de processar grandes volumes de dados, gerar simulações prognósticas e de previsão de risco.
	Duggan et al., (2025).	Aumento dos registos clínicos concluídos no próprio dia. Redução do tempo de trabalho fora do horário de trabalho para completar registos clínicos.
	Shao et al., (2024).	Maior sensibilidade em identificar doentes com IC. Padronização do processo de classificação da IC. Disponibilização de recursos úteis para estudos clínicos e qualidade dos cuidados.

	Lee et al., (2024).	Melhor coordenação de cuidados entre os diferentes serviços do hospital. Otimização da ocupação de camas hospitalares. Facilidade de integração em sistemas de RSE padronizados.
	Lee et al., (2023).	Identificação precisa de resultados dos cuidados a doentes incluídos nos ensaios clínicos em grandes bases de dados.
	Ahn et al., (2021).	Melhoria de processos hospitalares relacionados com a gestão de camas de internamento. Processo de previsão de alta, automatizado, diminuindo a carga de trabalho médica.
	Mermin-Bunnell et al., (2023).	Automatização do processo de triagem de mensagens iniciadas pelos utentes. Potencial para melhorar sistema de documentação ao identificar casos positivos de COVID-19 não documentados no RSE.
	Kocaballi et al., (2020).	Automatização do procedimento de documentação clínica e de tarefas repetitivas burocráticas. Novos modelos de cuidados de saúde: assistentes de pré-consulta, *mhealth.*
	Seol et al., (2021).	Diminuição do tempo para revisão clínica manual de RSE resultado numa mais eficiente gestão da asma e na redução da sobrecarga dos profissionais de saúde.
	Weissenbacher et al., (2025).	Possibilita a monitorização da prescrição automática e em larga escala permitindo agilizar a revisão manual da prescrição.
Eficiência de Recursos	Bracken, et al., (2025).	Redução do tempo com documentação. Potencial para reduzir *burnout.*
	Taylor et al., (2024).	Redução do tempo de triagem menor tempo para tarefas administrativas. Tecnologia viável em sistemas de saúde com recursos limitados.
	Santos et al., (2024).	Identificação automática de doentes com risco de complicações pós-cirurgia cardíaca, otimiza gestão de equipamentos de monitorização remota.
	Leingang et al., 2023.	A localização de biomarcadores na TCO facilita a atenção ao especialista sobre áreas especificas.
	Duggan et al., (2025).	Redução do tempo utilizado por registo clínico.
	Shao et al., (2024).	Automatização do processo de classificação IC em grandes volumes de dados do RSE.
	Qian et al., (2021).	Potencial de redução da carga de trabalho médico enquanto assistente na atividade diagnóstica em pré-consulta.
	Bellocchio et al., (2021).	Reduz o trabalho cognitivo do profissional médico no seu cálculo de risco de falência renal em doentes com IRC. A precisão da identificação evita referenciações desnecessárias para tratamentos dispendiosos.
	Homburg et al., (2023).	Identificação automatizada de consultas de COVI-19 através de dados não estruturados, evitando uma análise manual. Modelo, pré-treinado e de código aberto, constitui uma abordagem custo-efetiva.
	Lee et al., (2024).	A precisão da predição do tempo de internamento permite melhor planeamento e gestão dos recursos hospitalares, reduzindo custos.
	Lee et al., (2023).	Redução do tempo e recursos necessários para colheita de dados manual.
	Hernandez-Boussard et al., 2020.	Extração automática de informação clínica relevante do sistema de RSE.
	DiMartino et al., 2022.	Redução de internamentos não planeados por descontrolo de sintomas em estádios avançados de cancro.

	Zapata et al., 2023.	A identificação precoce (triagem) de doentes com COVID-19 que vão necessitar de mais cuidados permite decisões mais rápidas de alocação de recursos.
Eficiência dos Cuidados de Saúde	Khurshid et al., (2022).	Identificação automática de risco de FA. Cuidados de saúde atempados e personalizados.
	Fernández-Gutiérrez et al., (2021).	Identificação automática uma determinada condição de saúde a partir de RSE.
	Santos et al., (2024).	Melhor acompanhamento clínico pós-alta com monitorização, semanal, do risco de complicações pós-cirurgia cardiotorácica.
	Alexander et al., (2021).	Identificação automática de subgrupos relevantes, da DA potencia tratamento personalizado, prognóstico mais preciso gestão mais eficiente da doença.
	Leingang et al., (2023).	A identificação retrospetiva do início de DMRI em dados longitudinais permite uma identificação mais precisa da sua progressão.
	Richter-Laskowska et al. (2025).	Identificação automática de declínio cognitivo através dos registos do RSE.
	Qian et al., (2021).	Capacidade de gerar dados mais estruturados e padronizados o que facilita o processo de diagnóstico.
	Bellocchio et al., (2021).	Identificação precoce de doentes com IRC e com maior risco de falência renal permitindo gestão atempada da doença. Personalização de cuidados através do fornecimento de métricas específicas para cada doente.
	Homburg et al., (2023).	Deteção precoce de doenças infeciosas potenciando a preparação atempada da resposta a surtos epidémicos, assim como, do tratamento. Elevada precisão no processo de identificação de casos de COVID-19, o que melhora a eficiência diagnóstica.
	Lee et al., (2024).	Oferece uma visão longitudinal do doente permitindo personalizar os cuidados de saúde e adequar as estratégias de alta clínica.
	Ahn et al., (2021).	Cuidados personalizados proporcionados pela identificação de fatores de risco possíveis de influenciar a alta de cada doente.
	Mermin-Bunnell et al., (2023).	Redução do tempo de resposta médica a mensagens iniciadas pelos doentes, com consequente probabilidade de acesso a tratamento adequado.
	Hernandez-Boussard et al., (2020).	Monitorização em tempo real da qualidade dos cuidados através do sistema CAPTIVE facilitando a decisão clínica.
	DiMartino et al., (2022).	Identificação automática de doentes com doença terminal e sintomas não controlados, através de dados não estruturados dos sistemas de RSE. Identificação e encaminhamento precoce de doentes para os Cuidados Paliativos.
	Seol et al., (2021).	Seguimento mais oportuno após a exacerbação da asma.
	Zapata et al., (2023).	Conhecer melhor os fatores que contribuem para o prognóstico do doente com COVID-19.
	Weissenbacher et al., (2025).	Potencial para melhorar a prática clínica permitindo revisões periódicas da prescrição.

Os ganhos em eficiência de recursos estão diretamente relacionados com os **ganhos de eficiência de processos**. As evidências encontradas mostram o potencial ganho de eficiência com a

utilização de tecnologias de IA ao nível dos processos de comunicação entre profissionais, e, com os decisores e utentes, ao nível dos processos relacionados com a atividade assistencial e não assistencial dos PS e ao nível da investigação em saúde. Alguns dos autores (n=3) evidenciam a capacidade da IA na otimização da gestão de camas hospitalares através de modelos de previsão de alta ou cuidados adicionais (Ahn et al., 2021; Lee et al., 2024; Jonhson et al., 2024). Outro ponto de melhoria ao nível dos processos de gestão está relacionado com a otimização do circuito dos doentes (Jonhson et al., 2024), melhoria da comunicação entre diferentes profissionais e diferentes contextos de saúde (Bednorz et al., 2023), e, uma melhor coordenação de cuidados entre equipas (Jonhson et al., 2024; Lee et al., 2024).

A literatura analisada evidencia também o potencial da IA para promover ganhos em eficiência dentro dos processos assistenciais. Este ganho em eficiência resulta da otimização do tempo dos PS necessário para o processo de documentação clínica (Bracken, et al., 2025; Duggan et al., 2025) e para a realização de tarefas burocráticas (Kocaballi et al., 2020; Bednorz et al., 2023). A IA de acordo com Mermin-Bunnell et al., (2023) mostrou capacidade para automatizar o processo de triagem de doentes possibilitando cuidados mais atempados e adequados. Finalmente, outro aspeto relevante dos processos assistenciais é o potencial da IA evidenciado por Kocaballi et al., (2020) enquanto promovedor de novos modelos de cuidados mais eficientes e equitativos.

Nos processos não assistenciais verificou-se que a automatização de tarefas relacionadas com revisões clínicas manuais, como a revisão de prescrição ou de cuidados traz maior eficiência relacionada com a redução do tempo de trabalho necessário para a mesma e por permitir libertar mais tempo dos PS para os cuidados assistenciais (Seol et al., 2021; Leingang et al., 2023; Zapata et al., 2023; Lee et al., 2023; Shao et al., 2024; Weissenbacher et al., 2025). A otimização do processo de revisão manual permite gerar indicadores (Jonhson et al., 2024) de desempenho e de qualidade que serão ainda valiosos na gestão de saúde e na melhoria da qualidade dos cuidados.

Para terminar, a capacidade da IA para extrair dados de grandes bases de dados (Shao et al., 2024) com consequente redução de custos de pesquisa (Bednorz et al., 2023) pode potenciar a eficiência do processo de investigação clínica e de qualidade de cuidados.

Na literatura incluída nesta RSL não encontramos estudos cujo propósito principal fosse a avaliação da influência das tecnologias de IA na **eficiência dos cuidados de saúde.** No entanto, pode-se encontrar em alguns artigos, (n=17) a associação dos resultados da aplicação de tecnologias de IA a maior eficiência dos cuidados de saúde. Uma das potencialidades das tecnologias de IA está associada a capacidade de identificar de forma automática condicionantes de saúde (Alexander et al., (2021;

Fernández-Gutiérrez et al., 2021; DiMartino et al., 2022; Leingang et al., 2023; Lee et al., 2024; Richter-Laskowska et al. 2025), fatores de risco associados (Ahn et al., 2021; Bellocchio et al., 2021; Khurshid et al., 2022; Mermin-Bunnell et al., 2023; Santos et al., 2024; Khurshid et al., 2022), assim como, produzir documentação mais estruturada e padronizada ou inferir um diagnóstico facilitando o processo de diagnóstico do profissional (Qian et al., 2021; Homburg et al., 2023), através da extração de dados de RSE. A capacidade de automatização identificada traz associada a possibilidade dos sistemas de saúde conseguirem prestar cuidados de saúde mais atempados e personalizados e (Ahn et al., 2021; Bellocchio et al., 2021Khurshid et al., 2022; Homburg et al., 2023; Mermin-Bunnell et al., 2023; Lee et al., 2024). A melhoria dos cuidados de saúde prestado não se limita ao contexto interno das instituições, mas também em contexto domiciliário como no acompanhamento pós-alta (Santos et al., 2024). Este contexto gerado em volta da intervenção da IA parece poder contribuir para melhorar a qualidade dos cuidados e da prática clínica quer pelo aumento da eficiência de diagnóstico e conhecimento dos fatores associados, mas também pela eficiência do processo de monitorização de prescrição (Weissenbacher et al., 2025) que permite aos clínicos e decisores avaliar o impato das suas intervenções.

Estes resultados vão ao encontro da literatura onde se refere a utilidade, dos sistemas de IA, em áreas como a decisão clínica, a decisão organizacional, e a decisão partilhada, demonstrando potencial para melhorar a qualidade e a eficiência das decisões clínicas (Khosravi, et al., 2024). Neste sentido, a introdução de IA pode contribuir para assistir no processo de diagnóstico clínico de forma a torna-lo mais ágil e eficiente o que vai permitir acesso a cuidados de saúde mais atempados e mais personalizados, (Rajagopal & Subramanian, 2024) assim como, desenvolver novas formas de cuidados que podem tronar a assistência em saúde mais equitativa (Seth et al., 2024). Bajwa et al. (2021) reforça esta ideia dizendo que os PS irão aproveitar a IA para melhorar os cuidados que prestam de forma a promover cuidados mais seguros, padronizados e eficazes no máximo da sua capacidade de atuação.

4.4 Perceção dos Profissionais de Saúde:

A perceção dos profissionais de saúde sobre a utilização de tecnologias de IA foi avaliada em três dos estudos de investigação, desta RSL onde se identificaram três fatores condicionantes. O primeiro são as preocupações e reservas relativas à tecnologia, o segundo as condições ou requisitos percecionados como essenciais e os ganhos percebidos.

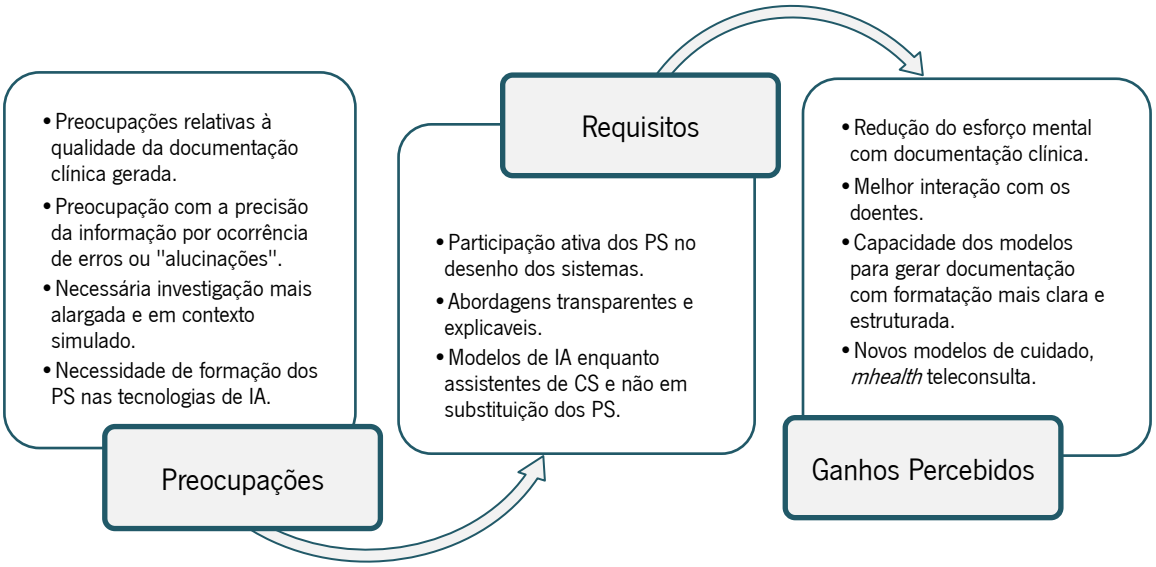


Figura 8 | Perceção dos PS sobre tecnologias de IA nos CS.

A integração de tecnologias de IA nos sistemas de documentação clínica gera preocupações nos médicos de clínica geral relacionadas com a autonomia profissional, níveis de colaboração entre IA e profissionais de saúde e os novos modelos de cuidados de saúde, salientando que a procura de eficiência documental nem sempre gera melhores cuidados de saúde (Kocaballi et al., 2020). Por seu lado, Duggan et al., (2025) refere que os PS descreveram melhor interação com os doentes associada a redução do tempo para documentação clínica proporcionada por tecnologias de IA. A aceitação e participação dos profissionais de saúde, no desenvolvimento e integração das tecnologias de IA na prática clínica, será fundamental não só para assegurar a sua adequabilidade aos fluxos de trabalho, mas também para conquistar a confiança dos mesmos. Neste sentido, Santos et al., (2024) e Kocaballi et al. (2020) referem a importância do envolvimento ativo dos profissionais de saúde desde a conceção/desenvolvimento dos modelos de IA até à sua validação, posição que é igualmente aceite por Hernandez-Boussard et al., (2020), Homburg et al., (2023) e Bednorz, et al., (2023). Outro requisito referido estudos desta RSL é a importância de abordagens de IA transparentes e explicáveis para promover a confiança nos PS, e garantir a fiabilidade e usabilidade na prática clínica (Fernández-Gutiérrez et al., 2021; Homburg et al.,2023; Santos et al., 2024) o que mostra alinhamento com Bongurala et al., (2024).

A opinião dos *stakeholders* sobre sistemas de documentação clínica geridos por IA é de forma geral positiva (Bracken et al., 2025). Kocaballi et al. (2020) dizem-nos que os PS consideram ser inevitável e positiva a integração de tecnologias de IA nos sistemas de documentação clínica dos CSP, reconhecendo a importância da IA no papel de assistente de cuidados, mas não em substituição dos PS, e, no desenvolvimento de novos modelos de cuidado. Esta posição é sustentada por Bajwa et al. (2021).

Segundo estes autores, devemos olhar para a IA de forma ampliar a inteligência a humana e não substituí-la, ou seja, é essencial que a IA não substitua a relação terapêutica da medicina mas sim, ajudar a foca-la no aumento da eficiência e eficácia dessa interação.

O processo de documentação clínica está associado a *burnout* dos PS (Bongurala et al., 2024; Wu et al., 2024). As tecnologias de transcrição ambiente e de IA generativa revelaram facilidade de uso pelos PS, reduzindo o tempo necessário para documentação clínica e capacidade de gerar documentação com formatação mais estruturada e clara (Bracken et al., 2025; Duggan et al., 2025) o que vai ao encontro de Bongurala et al., (2024) quando refere que as tecnologias de registo voz/texto com IA como *Nuance Dragon Medical, Robin Healthcare*, agilizam o processo de documentação, reduzindo o tempo de digitação manual e podem incluir ferramentas de suporte à decisão clínica. Duggan et al., (2025), pelo lado contrário refere a falta de consenso entre PS sobre a qualidade das notas clínicas geradas por IA por tecnologia de escrita ambiente, entre os que as consideram precisas e detalhadas e os que consideram que requerem revisão e edição substancial.

4.5 Limitações e Recomendações Futuras:

Uma limitação importante desta RSL está relacionada com a ausência de procura de evidências em fontes de literatura cinzenta, como por exemplo repositórios de teses ou relatórios institucionais. De igual modo, a delimitação da estratégia de pesquisa à base de dados PubMed, e a exclusão de artigos de investigação em língua, que não a inglesa, poderá também constituir uma limitação na procura de artigos científicos. Estas condicionantes, podem, de corto modo, limitar a abrangência da síntese e contribuir para viés da publicação.

Os artigos apresentados mostram as potencialidades e reservas das tecnologias de IA em diversos campos de atuação na saúde e com diferentes objetivos. Nos artigos que envolvem o desenvolvimento e validação de modelos de IA verificamos que o contexto de teste e validação é na sua totalidade localizado a um contexto específico. Um futuro caminho na procura da integração de modelos de IA nos sistemas de RSE passará sem dúvida por um desenho de investigação que consiga uma integração mais ampla e nos diferentes contextos de saúde o que requer envolvimento das estruturas de decisão dos sistemas de saúde. De igual modo serão necessários estudos adicionais que avaliem a eficiência do modelo, mas também, o impacto da sua introdução nos fluxos de trabalho e na prestação e qualidade de cuidado. Esta integração deverá, ainda, ser assegurada por modelos de governança capazes de ir ao encontro das preocupações éticas e de segurança no uso de dados de saúde que garantam transparência, justiça, responsabilidade e confiança (Seth et al., 2024).

Embora os estudos dedicados à utilização de IA para a gestão de documentação representem apenas cerca de 11,5% do total de artigos esta é, sem dúvida, uma área de intervenção onde aumentar a eficiência do processo poderá dar contributos muito positivos para a prática clínica. A eficiência do processo de introdução de registos clínicos pelos PS tem potencial para garantir que os dados disponíveis nos RSE são fiáveis e de qualidade o que, empiricamente podemos inferir que poderá contribuir para o melhor desempenho de tecnologias de análise de dados de saúde. Estudos mais abrangentes poderão contribuir para fomentar a mais rápida adoção destas tecnologias nas instituições de saúde onde os PS de debatem com sobrecarga cognitiva induzida pelos RSE e a gestão de tempo dedicado aos mesmos.

CONCLUSÃO

A utilização de tecnologias baseadas em inteligência artificial no procedimento de registo eletrónico de dados de saúde representa um avanço significativo, oferecendo soluções inovadoras para desafios relacionados com a gestão dos dados e a assistência à decisão clínica. Essas tecnologias possibilitam automatizar processos repetitivos, a redução de erros humanos e a extração de informação valiosa a partir de grandes volumes de dados, promovendo a eficiência e a precisão no cuidado do doente. A integração de IA em sistemas de RSE apresenta potencial transformador na gestão de dados de saúde que vai desde o procedimento de inserção de dados, extração e análise dentro da atividade diagnóstica, preditiva, de gestão e de investigação clínica e epidemiológica.

Os requisitos relacionados com questões de governança e questões de garantia de segurança e privacidade de dados de saúde que são necessários para a implementação destas tecnologias são condicionantes na sua implementação. O alargamento da disponibilização destas tecnologias aos profissionais que integram os CSP e que desenvolvem a sua atividade em contexto institucional, mas também em contexto domiciliário e cuja intervenção tem impacto na gestão da doença crónica tem o potencial de ter um impacto positivo na melhoria da qualidade dos cuidados e na satisfação dos profissionais.

Assim, este estudo procurou explorar as possibilidades e os desafios da integração de tecnologias de IA no procedimento de registo clínico de saúde, no contexto de cuidados de saúde primários, de forma a melhorar a eficiência dos mesmos de forma a gerar recomendações que promovam a eficiência do procedimento e dos cuidados de saúde o que por sua vez poderá contribuir, ao nível da gestão organizacional, para desenhar um modelo de implementação capaz de ultrapassar de forma mais eficiente os desafios e barreiras identificados.

REFERÊNCIAS BIBLIOGRÁFICAS

ACSS Administração Central do Sistema de Saúde (2009). Registo de saúde Eletrónico, Documento de "Estado da Arte", versão 2, adaptado de "Handbook of Medical Informatics" – JH van Bemmel http://ser.cies.iscte.pt/index_ficheiros/ACSS2009.pdf

Al Kuwaiti, A., Nazer, K., Al-Reedy, A.; Al-Shehri, S., Al-Muhanna, A., Subbarayalu, A.V., Al Muhanna, D., Al-Muhanna, F.A., (2023). A Review of the Role of Artificial Intelligence in Healthcare. J. Pers. Med., 13, 951. https://doi.org/10.3390/jpm13060951

Alnasser, B. (2023). A Review of Literature on the Economic Implications of Implementing Artificial Intelligence in Healthcare. E-Health Telecommunication Systems and Networks, 12, 35-48. https://doi.org/10.4236/etsn.2023.123003

Aromataris E., Lockwood C., Porritt K, Pilla B. & Jordan Z. (2024). JBI Manual for Evidence Synthesis. JBI. Available from: https://synthesismanual.jbi.global.
ISBN: 978-0-6488488-06

Assembleia da República, (2019). Lei nº95/2019, de 4 de setembro. Lei de Bases da Saúde. Diário da República, 1.ª série, Nº169/55.
https://files.dre.pt/1s/2019/09/16900/0005500066.pdf

Associação Nacional de Unidades de Saúde Familiar (USF-NA). (2024). O Momento Atual da Reforma dos Cuidados de Saúde Familiar em Portugal 2023/2024. https://usf-an.pt/relatorio-do-estudo-o-momento-atual-da-reforma-dos-cuidados-de-saude-primarios-em-portugal-2023-2024/

Baethge, C., Goldbeck-Wood, S., & Mertens, S. (2019). SANRA-a scale for the quality assessment of narrative review articles. *Research integrity and peer review*, *4*, 5. https://doi.org/10.1186/s41073-019-0064-8

Bajwa, J., Munir, U., Nori, A., & Williams, B. (2021). Artificial intelligence in healthcare: transforming the practice of medicine. *Future healthcare journal*, *8*(2), e188–e194. https://doi.org/10.7861/fhj.2021-0095

Báo ACP, Amestoy SC, Moura GMSS, Trindade LL., (2019). Quality indicators: tools for the management of best practices in Health. Rev Bras Enferm.;72(2):360-6. doi: http://dx.doi.org/10.1590/0034-7167-2018-0479

Barbosa C., Pereira AD. (2022). Interoperabilidade europeia de registos de saúde eletrónicos e segurança do paciente. Cadernos Ibero-Americanos de Direito Sanitário, jul./set.;11(3): 162-167. https://doi.org/10.17566/ciads.v11i3.966

Bernardo, W. M., Nobre, M. R., & Jatene, F. B. (2004). A prática clínica baseada em evidências. Parte II-Buscando as evidências em fontes de informação [Evidence-based clinical practice. Part II–Searching evidence databases]. *Revista da Associacao Medica Brasileira (1992)*, *50*(1), 104–108. https://doi.org/10.1590/s0104-42302004000100045

Borges, J. & Bordin, R. (2023). Eficiência em saúde pública: a trajetória de um conceito proveniente da engenharia. SAÚDE DEBATE | Rio de Janeiro, V. 47, N. 138, P. 616-629, Jul-Set. DOI: 10.1590/0103-1104202313818

Bongurala, A. R., Save, D., Virmani, A., & Kashyap, R. (2024). Transforming Health Care With Artificial Intelligence: Redefining Medical Documentation. *Mayo Clinic proceedings. Digital health*, *2*(3), 342–347. https://doi.org/10.1016/j.mcpdig.2024.05.006

Brender J., Ammenwerth E., Nykänen P., Talmon J., (2006). Factors influencing success and failure of health informatics systems–a pilot Delphi study. Methods Inf Med.;45(1):125-36. PMID: 16482383. https://pubmed.ncbi.nlm.nih.gov/16482383/

Budd J. Burnout Related to Electronic Health Record Use in Primary Care. *Journal of Primary Care & Community Health*. 2023;14. doi:10.1177/21501319231166921

Catarinucci, Luca & De Donno, Danilo & Mainetti, Luca & Palano, Luca & Patrono, Luigi & Stefanizzi, Maria & Tarricone, Luciano. (2015). An IoT-Aware Architecture for Smart Healthcare Systems. IEEE Internet of Things Journal. 2. 1-1. 10.1109/JIOT.2015.2417684.

Clark, W. H., IV, & Michaels, A. J. (2024). Training from Zero: Forecasting of Radio Frequency Machine Learning Data Quantity. *Telecom*, *5*(3), 632-651. https://doi.org/10.3390/telecom5030032

Collins, G., Reitsma, J., Altman, D., Moons, K. (2015). Transparent Reporting of a multivariable prediction model for Individual Prognosis or Diagnosis (TRIPOD): The TRIPOD Statement. Ann Intern Med. 2015; 162:55-63. [Epub 6 January 2015]. doi:10.7326/M14-0697

Collins, G. S., Moons, K. G. M., Dhiman, P., Riley, R. D., Beam, A. L., Van Calster, B., Ghassemi, M., Liu, X., Reitsma, J. B., van Smeden, M., Boulesteix, A. L., Camaradou, J. C., Celi, L. A., Denaxas, S., Denniston, A. K., Glocker, B., Golub, R. M., Harvey, H., Heinze, G., Hoffman, M. M., Logullo, P. (2024). TRIPOD + AI statement: updated guidance for reporting clinical prediction models that use regression or machine learning methods. *BMJ (Clinical research ed.)*, *385*, e078378. https://doi.org/10.1136/bmj-2023-078378

Comissão Europeia, (2025, consulta em junho 20). Inteligência Artificial no domínio dos cuidados de saúde.https://health.ec.europa.eu/ehealth-digital-health-and-care/artificial-intelligence-healthcare_pt

Davenport, T. & Kalakota, R. (2019). The potential for artificial intelligence in healthcare. *Future healthcare journal*, *6*(2), 94–98. https://doi.org/10.7861/futurehosp.6-2-94

de Jong, A., Donelle L., Kerr M. (2020). Nurses' Use of Personal Smartphone Technology in the Workplace: Scoping Review. JMIR Mhealth Uhealth 2020;8(11):e18774 URL: https://mhealth.jmir.org/2020/11/e18774 DOI: 10.2196/18774

Direção Geral da Saúde, (2017). Norma 001/2017 de 08.02.2017 - Comunicação eficaz na Transição de Cuidados, Departamento da Qualidade em Saúde.

Elhaddad, M., & Hamam, S. (2024). AI-Driven Clinical Decision Support Systems: An Ongoing Pursuit of Potential. *Cureus*, *16*(4), e57728. https://doi.org/10.7759/cureus.57728

European Commission, (2022). European Health Data Space. May 03. Disponível em: https://health.ec.europa.eu/system/files/2022-05/com_2022-197_annex_en.pdf

European Observatory on Health Systems and Policies, (2023). State of Health in EU - Portugal, Perfil de Saúde do país 2023. European Commission. https://health.ec.europa.eu/state-health-eu/country-health-profiles_pt

Fennelly, O., Cunningham, C., Grogan, L., Cronin, H., O'Shea, C., Roche, M., Lawlor, F., & O'Hare, N. (2020). Successfully implementing a national electronic health record: a rapid umbrella review. *International journal of medical informatics*, *144*, 104281. https://doi.org/10.1016/j.ijmedinf.2020.104281

Fink, A., (2014). Conducting Research Literature Reviews: From the Internet to Paper (4ª edição). Sage Publications.

Gaffney, A., Woolhandler, S., Cai, C., Bor, D., Himmelstein, J., McCormick, D., & Himmelstein, D., (2022). Medical Documentation Burden Among US Office-Based Physicians in 2019: A National Study. *JAMA Intern Med.* 2022;182(5):564–566. doi:10.1001/jamainternmed.2022.0372

Gal, D., Han, B., Longhurst, C., Scheinker, D., & Shin, A. (2021). Quantifying Electronic Health Record Data: A Potential Risk for Cognitive Overload. *Hosp Pediatr* February; 11 (2):175–178. https://doi.org/10.1542/hpeds.2020-002402

Gianfrancesco, M. A., Tamang, S., Yazdany, J., & Schmajuk, G. (2018). Potential Biases in Machine Learning Algorithms Using Electronic Health Record Data. *JAMA internal medicine*, *178*(11), 1544–1547. https://doi.org/10.1001/jamainternmed.2018.3763

Health Information Quality Authority (HIQA), (2011). Developing National EHealth Interoperability Standards for Ireland: A Consultation Document. https://www.hiqa.ie/sites/default/files/2017-01/eHealthInteroperabilityConsultation.pdf.

Heponiemi, T., Kaihlanen, A. M., Gluschkoff, K., Saranto, K., Nissinen, S., Laukka, E., & Vehko, T. (2021). The Association Between Using a Mobile Version of an Electronic Health Record and the Well-Being of Nurses: Cross-sectional Survey Study. *JMIR medical informatics*, *9*(7), e28729. https://doi.org/10.2196/28729

Hsu, E., & Roberts, K. (2025). LLM-IE: a python package for biomedical generative information extraction with large language models. *JAMIA open*, *8*(2), ooaf012. https://doi.org/10.1093/jamiaopen/ooaf012

Institute of Medicine (USA), (2001). Crossing the quality chasm: a new health system for the 21st century. Washington (DC): National Academies Press. https://pubmed.ncbi.nlm.nih.gov/25057539/

Jackson, R. L., Drummond, D. K., & Camara, S. (2007). What Is Qualitative Research? *Qualitative Research Reports in Communication*, *8*(1), 21–28. https://doi.org/10.1080/17459430701617879

KAIZEN Institute, (n.d.). Como pode a digitalização contribuir para Operações Ágeis no setor da Saúde, consulta em 30.11.2024. https://kaizen.com/pt/insights-pt/digitalizacao-operacoes-ageis-saude/

Kelemen, M., Rumens, N. (2012). Pragmatism and heterodoxy in organization research: Going beyond the quantitative/qualitative divide, The international journal of organizational analysis, 09 Mar, Vol. 20, Issue 1, pages 5 – 12, ISSN: 19348835, DOI: 10.1108/19348831211215704

Kilanko, V. (2023). The Transformative Potential of Artificial Intelligence in Medical Billing: A Global Perspective. International Journal Of Scientific Advances, 4(3). https://doi.org/10.51542/ijscia.v4i3.8

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436–444. https://doi.org/10.1038/nature14539

Liu, X., Cruz Rivera, S., Moher, D. Calvert, M., Denniston, A. (2020). Reporting guidelines for clinical trial reports for interventions involving artificial intelligence: the CONSORT-AI extension. *Nat Med* 26, 1364–1374. https://doi.org/10.1038/s41591-020-1034-x

Lötscher-Stamm, M., & Lenzin, G. (2024). Definition and understanding of "efficiency" in healthcare provision research: a scoping review. *Frontiers in public health*, *12*, 1439788. https://doi.org/10.3389/fpubh.2024.1439788

Madi, I., Redjdal, A., Bouad, J., Seroussi, B. (2024). Exploring Explainable AI Techniques for Text Classification in Healthcare: A Scoping Review. Digital Health and Informatics Innovations for Sustainable Health Care Systems. J. Mantas et al. (Eds.). doi:10.3233/SHTI240544

Malta, M., Cardoso, L., Bastos, F., Magnanini, M., Silva, C. (2010). Iniciativa STROBE: subsídios para a comunicação de estudos observacionais. STROBE initiative: guidelines on reporting observational studies, Revista Saúde Pública, 44(3):559-65 https://www.strobe-statement.org/translations/

Marinho A., Ocké-Reis, CO. (2022). Sistema Único de Saúde: o debate em torno da eficiência. Rio de Janeiro: Editora Fiocruz; Cad. Saúde Pública 39 (4), 132. p. (Coleção Temas em Saúde), 2023. ISBN:. 978-65-5708-133-4.

Martins, G., Costa, L., Martins, G. (2016). Big Data use in medical research. einstein (São Paulo). 2018;16(3):eED4087. https://doi.org/10.1590/S1679-45082018ED4087

McCarthy J., (2007). What is artificial intelligence? Computer Science Department Stanford University Stanford, Nov 12, 2:05 a.m. CA 94305 jmc@cs.stanford.edu http://www-formal.stanford.edu/jmc/

Miotto, R., Wang, F., Wang, S., Jiang, X., Dudley, J. (2018). Deep learning for healthcare: review, opportunities and challenges, *Briefings in Bioinformatics*, Volume 19, Issue 6, November, Pages 1236–1246, https://doi.org/10.1093/bib/bbx044

Nobre, M. R., Bernardo, W. M., & Jatene, F. B. (2003). A prática clínica baseada em evidências. Parte I - Questões clínicas bem construídas [Evidence based clinical practice. Part 1–well structured clinical questions]. *Revista da Associacao Medica Brasileira (1992)*, *49*(4), 445–449. https://doi.org/10.1590/s0104-42302003000400039

Ogrinc, G., Davies, L., Goodman, D., Batalden, P., Davidoff, F., & Stevens, D. (2016). SQUIRE 2.0 (Standards for QUality Improvement Reporting Excellence): revised publication guidelines from a detailed consensus process. *BMJ quality & safety*, *25*(12), 986–992. https://doi.org/10.1136/bmjqs-2015-004411

Ogochukwu C. & Chimaobi, E., 2024. Enhancing Healthcare Data Entry Efficiency and Accuracy through Voice Assistant Systems: A Case Study of Obijackson Hospital Okija. International Journal of Research and Innovation in Applied Science (IJRIAS) ISSN No. 2454-6194 | Volume IX Issue X October. DOI: https://doi.org/10.51584/IJRIAS.2024.910028

Oliveira, E. & Ferreira, P. (2014). Métodos de Investigação – da interrogação à Descoberta Científica, Vida económica – Editorial, SA, ISBN:978-989-768-053-3. https://books.google.pt/

Organização Mundial de Saúde, (2020). Manual de políticas e estratégias para a qualidade dos cuidados de saúde: uma abordagem prática para formular políticas e estratégias destinadas a melhorar a qualidade dos cuidados de saúde [Handbook for national quality policy and strategy: a practical approach for developing policy and strategy to improve quality of care]. Genebra. Licença: CC BY-NC-SA 3.0 IGO. ISBN 978-92-4-000570-9

Okoli, C., (2019). Guia para realizar uma revisão sistemática da literatura. Tradução de David Wesley Amado Duarte; Revisão técnica e introdução de João Mattar. eaD em Foco, 2019;9 (1): e748. DOI: https://doi.org/10.18264/eadf.v9i1.748

Page, M., McKenzie, J., Bossuyt, P., Boutron, I., Hoffmann, T., Mulrow, C., Shamseer, L., ~ Tetzlaff, J., Akl, E., Brennan, S., Chou, R., Glanville, J., Grimshaw, J., Hróbjartsson, A., Lalu, M., Li, T., Loder, E., Mayo-Wilson, E., McDonald, S., McGuinness, L., Stewart, L., Thomas, J., Tricco, A., Welch, V., Whiting, P., Moher, D. (2024). Declaração PRISMA 2020: uma diretriz atualizada para publicação de revisões sistemáticas, Germinare n.º 4, Instituto Piaget. Doi: https://doi.org/10.5281/zenodo.13271469

Pap, I.A.; Oniga, S. A., (2022). Review of Converging Technologies in eHealth Pertaining to Artificial Intelligence. Int. J. Environ. Res. Public Health, 19, 11413. https://doi.org/10.3390/ijerph191811413

Paatela, S., Kyytsönen, M., Saranto, K., Kinnunen, U. M., & Vehko, T. (2024). Experiences of Electronic Health Records' and Client Information Systems' Use on a Mobile Device and Factors Associated With Work Time Savings Among Practical Nurses: Cross-Sectional Study. *Journal of medical Internet research*, *26*, e46954. https://doi.org/10.2196/46954

Raghavan, P., Chen, J. L., Fosler-Lussier, E., & Lai, A. M. (2014). How essential are unstructured clinical narratives and information fusion to clinical trial recruitment?. *AMIA Joint Summits on Translational Science proceedings. AMIA Joint Summits on Translational Science*, *2014*, 218–223.

Rajagopal, D., & Subramanian, P. K. T. (2025). AI augmented edge and fog computing for Internet of Health Things (IoHT). *PeerJ. Computer science*, *11*, e2431. https://doi.org/10.7717/peerj-cs.2431

Santos, C., Pimenta, C., & Nobre, M. (2007). A estratégia PICO para a construção da pergunta de pesquisa e busca de evidências. Rev Latino-am Enfermagem, maio-junho; 15(3) www.eerp.usp.br/rlae. https://doi.org/10.1590/S0104-11692007000300023

Saunders, M., Lewis, P., & Thornhill, A. (2023). Research Methods for Business Students, 9th ed., Edinburgh: Pearson Education Limited.

Schawb, K., Davis, N. (2019). Aplicando a Quarta Revolução Industrial, World Economic Fórum, edipro, ISBN 978-85-521-0049-2.

Serviços Partilhados do Ministério da Saúde/SNS, (2019). Sistemas de Informação. https://www.spms.min-saude.pt/wp-content/uploads/2019/04/NEWSLETTER_DSI.pdf

Serviços Partilhados do Ministério da Saúde/SNS. (2024). SPMS na liderança da saúde digital global em 2024. SPMS na liderança da saúde digital global em 2024 – SPMS

Sheth, V., Priyal, A., Mehta, K., Desai, N., Shah, M., (2024). Schematized study for tackling COVID-19 with Machine Learning (ML), Artificial Intelligence (AI), and Internet of Things (IoT): Intelligent Pharmacy 2 (2024) 756–767. ISSN 2949-866X. https://doi.org/10.1016/j.ipha.2024.04.003

Shiyab, W., Rolls, K., Ferguson, C., & Halcomb, E. (2024). Nurses' Use of mHealth Apps for Chronic Conditions: Cross-Sectional Survey. *JMIR nursing*, *7*, e57668. https://doi.org/10.2196/57668

Silcox, C., Zimlichmann, E., Huber, K. et al., (2024). The potential for artificial intelligence to transform healthcare: perspectives from international health leaders. *npj Digit. Med.* 7, 88. https://doi.org/10.1038/s41746-024-01097-6

Silva M., (2023). Os cuidados de saúde primários em Portugal: uma história de mais de 50 anos – a perspetiva de um futuro médico de família. *Revista Portuguesa De Medicina Geral E Familiar*, *39*(4), 355-9. https://doi.org/10.32385/rpmgf.v39i4.13732

Tejani, A. S., Klontzas, M. E., Gatti, A. A., Mongan, J. T., Moy, L., Park, S. H., Kahn, C. E., Jr, & CLAIM 2024 Update Panel (2024). Checklist for Artificial Intelligence in Medical Imaging (CLAIM): 2024 Update. *Radiology. Artificial intelligence*, *6*(4), e240300. https://doi.org/10.1148/ryai.240300

Tong, A., Sainsbury, P., & Craig, J. (2007). Consolidated criteria for reporting qualitative research (COREQ): a 32-item checklist for interviews and focus groups. *International journal for quality in health care : journal of the International Society for Quality in Health Care*, *19*(6), 349–357. https://doi.org/10.1093/intqhc/mzm042

Varian, Hal R., (2014). Big Data: New Tricks for Econometrics. Journal of Economic Perspectives 28 (2): 3–28**.** DOI: 10.1257/jep.28.2.3. https://www.aeaweb.org/articles?id=10.1257/jep.28.2.3

Vilela, J. (2022). Investigação, O Processo de Construção do Conhecimento, 3ª edição, SÍLABO, ISBN:978-989-561-097-6.

Vituri, D., Matsuda, L., (2009). Validação de Conteúdo de Indicadores de Qualidade para Avaliação do Cuidado de Enfermagem, Rev. Esc. Enferm USP, 43(2):429-37. DOI: 10.1590/S0080-62342009000200024

Xu, D., Chen, W., Peng, W., Zhang, C., Xu, T., Zhao, X., Wu, X., Zheng, Y., Wang, Y., Chen, E. (2024). Large language models for generative information extraction: a survey. *Front. Comput. Sci.* 18, 186357 (2024). https://doi.org/10.1007/s11704-024-40555-y

WHO Global Observatory for eHealth, (2012). Management of patient information: trends and challenges in Member States: based on the findings of the second global survey on eHealth. World Health Organization. https://iris.who.int/handle/10665/76794

Wu, Y., Wu, M., Wang, C., Lin, J., Liu, J., & Liu, S. (2024). Evaluating the Prevalence of Burnout Among Health Care Professionals Related to Electronic Health Record Use: Systematic Review and Meta-Analysis. *JMIR medical informatics*, *12*, e54811. https://doi.org/10.2196/54811

Artigos de Revisão Sistemática da Literatura

Bracken, A., Reilly, C., Feeley, A., Sheehan, E., Merghani, K., & Feeley, I. (2025). Artificial Intelligence (AI) - Powered Documentation Systems in Healthcare: A Systematic Review. *Journal of medical systems*, *49* (1), 28. https://doi.org/10.1007/s10916-025-02157-4

Khurshid, S., Friedman, S., Reeder, C., Di Achille, P., Diamant, N., Singh, P., Harrington, L. X., Wang, X., Al-Alusi, M. A., Sarma, G., Foulkes, A. S., Ellinor, P. T., Anderson, C. D., Ho, J. E., Philippakis, A. A., Batra, P., & Lubitz, S. A. (2022). ECG-Based Deep Learning and Clinical Risk Factors to Predict Atrial Fibrillation. *Circulation*, AHA,*145*(2), 122–133. https://doi.org/10.1161/CIRCULATIONAHA.121.057480

Fernández-Gutiérrez, F., Kennedy, J. I., Cooksey, R., Atkinson, M., Choy, E., Brophy, S., Huo, L., & Zhou, S. M. (2021). Mining Primary Care Electronic Health Records for Automatic Disease Phenotyping: A Transparent Machine Learning Framework. *Diagnostics (Basel, Switzerland)*, *11*(10), 1908. https://doi.org/10.3390/diagnostics11101908

Taylor, N., Kormilitzin, A., Lorge, I., Nevado-Holgado, A., Cipriani, A., & Joyce, D. W. (2024). Model development for bespoke large language models for digital triage assistance in mental health care. *Artificial intelligence in medicine*, *157*, 102988. https://doi.org/10.1016/j.artmed.2024.102988

Santos, R., Ribeiro, B., Sousa, I., Santos, J., Guede-Fernández, F., Dias, P., Carreiro, A. V., Gamboa, H., Coelho, P., Fragata, J., & Londral, A. (2024). Predicting post-discharge complications in cardiothoracic surgery: A clinical decision support system to optimize remote patient monitoring resources. *International journal of medical informatics*, *182*, 105307. https://doi.org/10.1016/j.ijmedinf.2023.105307

Du, X., Novoa-Laurentiev, J., Plasek, J. M., Chuang, Y. W., Wang, L., Marshall, G. A., Mueller, S. K., Chang, F., Datta, S., Paek, H., Lin, B., Wei, Q., Wang, X., Wang, J., Ding, H., Manion, F. J., Du, J., Bates, D. W., & Zhou, L. (2024). Enhancing early detection of cognitive decline in the elderly: a comparative study utilizing large language models in clinical notes. *EBioMedicine*, *109*, 105401. https://doi.org/10.1016/j.ebiom.2024.105401

Alexander, N., Alexander, D. C., Barkhof, F., & Denaxas, S. (2021). Identifying and evaluating clinical subtypes of Alzheimer's disease in care electronic health records using unsupervised machine learning. *BMC medical informatics and decision making*, *21*(1), 343. https://doi.org/10.1186/s12911-021-01693-6

Leingang, O., Riedl, S., Mai, J., Reiter, G., Faustmann, G., Fuchs, P., Scholl, H., Sivaprasad, S., Rueckert, D., Lotery, A., Schmidt-Erfurth, U., Bogunovic, H., (2023). Automated deep learning-based AMD detection and staging in real-world OCT datasets (PINNACLE study report5). *Sci Rep* 13, 19545. https://doi.org/10.1038/s41598-023-46626-7

Richter-Laskowska, M., Sobotnicka, E. & Bednorz, A., (2025). Cognitive performance classification of older patients using machine learning and electronic medical records. *Sci Rep* 15, 6564. https://doi.org/10.1038/s41598-025-90460-y

Johnson OA, McCrorie C, McInerney C, Mebrahtu TF, Granger J, Sheikh N., Lawton, T., Habli, I., Randell, R., Benn, J., (2024). Implementing an artificial intelligence command centre in the NHS: a mixed-methods study. *Health Soc Care Deliv Res*;12(41). https://doi.org/10.3310/TATM3277

Bednorz, A., Mak, J. K. L., Jylhävä, J., & Religa, D. (2023). Use of Electronic Medical Records (EMR) in Gerontology: Benefits, Considerations and a Promising Future. *Clinical interventions in aging*, *18*, 2171–2183. https://doi.org/10.2147/CIA.S400887

Duggan, M. J., Gervase, J., Schoenbaum, A., Hanson, W., Howell, J. T., 3rd, Sheinberg, M., & Johnson, K. B. (2025). Clinician Experiences With Ambient Scribe Technology to Assist With Documentation Burden and Efficiency. *JAMA network open*, *8*(2), e2460637. https://doi.org/10.1001/jamanetworkopen.2024.60637

Shao, Y., Zhang, S., Raman, V. K., Patel, S. S., Cheng, Y., Parulkar, A., Lam, P. H., Moore, H., Sheriff, H. M., Fonarow, G. C., Heidenreich, P. A., Wu, W. C., Ahmed, A., & Zeng-Treitler, Q. (2024). Artificial intelligence approaches for phenotyping heart failure in U.S. Veterans Health Administration electronic health record. *ESC heart failure*, *11*(5), 3155–3166. https://doi.org/10.1002/ehf2.14787

Qian, H., Dong, B., Yuan, J. J., Yin, F., Wang, Z., Wang, H. N., Wang, H. S., Tian, D., Li, W. H., Zhang, B., Zhao, L. B., & Ning, B. T. (2021). Pre-Consultation System Based on the Artificial Intelligence Has a Better Diagnostic Performance Than the Physicians in the Outpatient Department of Pediatrics. *Frontiers in medicine*, *8*, 695185. https://doi.org/10.3389/fmed.2021.695185

Bellocchio, F., Lonati, C., Ion Titapiccolo, J., Nadal, J., Meiselbach, H., Schmid, M., Baerthlein, B., Tschulena, U., Schneider, M., Schultheiss, U. T., Barbieri, C., Moore, C., Steppan, S., Eckardt, K. U., Stuard, S., & Neri, L. (2021). Validation of a Novel Predictive Algorithm for Kidney Failure in Patients Suffering from Chronic Kidney Disease: The Prognostic Reasoning System for Chronic Kidney Disease (PROGRES-CKD). *International journal of environmental research and public health*, *18*(23), 12649. https://doi.org/10.3390/ijerph182312649

Homburg, M., Meijer, E., Berends, M., Kupers, T., Olde Hartman, T., Muris, J., de Schepper, E., Velek, P., Kuiper, J., Berger, M., & Peters, L. (2023). A Natural Language Processing Modelfor COVID-19 Detection Based on Dutch General Practice Electronic Health Records by Using Bidirectional Encoder Representations From Transformers: Development and V alidation Study. *Journal of medical Internet research*, *25*, e49944. https://doi.org/10.2196/49944

Lee, H., Kim, S., Moon, H. W., Lee, H. Y., Kim, K., Jung, S. Y., & Yoo, S. (2024). Hospital Length of Stay Prediction for Planned Admissions Using Observational Medical Outcomes Partnership Common Data Model: Retrospective Study. *Journal of medical Internet research*, *26*, e59260. https://doi.org/10.2196/59260

Lee, R. Y., Kross, E. K., Torrence, J., Li, K. S., Sibley, J., Cohen, T., Lober, W. B., Engelberg, R. A., & Curtis, J. R. (2023). Assessment of Natural Language Processing of Electronic Health Records to Measure Goals-of-Care Discussions as a Clinical Trial Outcome. *JAMA network open*, *6*(3), e231204. https://doi.org/10.1001/jamanetworkopen.2023.1204

Ahn, I., Gwon, H., Kang, H., Kim, Y., Seo, H., Choi, H., Cho, H. N., Kim, M., Jun, T. J., & Kim, Y. H. (2021). Machine Learning-Based Hospital Discharge Prediction for Patients With Cardiovascular Diseases: Development and Usability Study. *JMIR medical informatics*, *9*(11), e32662. https://doi.org/10.2196/32662

Mermin-Bunnell, K., Zhu, Y., Hornback, A., Damhorst, G., Walker, T., Robichaux, C., Mathew, L., Jaquemet, N., Peters, K., Johnson, T. M., 2nd, Wang, M. D., & Anderson, B. (2023). Use of Natural Language Processing of Patient-Initiated Electronic Health Record Messages to Identify Patients With COVID-19 Infection. *JAMA network open*, *6*(7), e2322299. https://doi.org/10.1001/jamanetworkopen.2023.22299

Hernandez-Boussard, T., Blayney, D. W., & Brooks, J. D. (2020). Leveraging Digital Data to Inform and Improve Quality Cancer Care. *Cancer epidemiology, biomarkers & prevention: a publication of the American Association for Cancer Research, cosponsored by the American Society of Preventive Oncology*, *29*(4), 816–822. https://doi.org/10.1158/1055-9965.EPI-19-0873

Kocaballi, A. B., Ijaz, K., Laranjo, L., Quiroz, J. C., Rezazadegan, D., Tong, H. L., Willcock, S., Berkovsky, S., & Coiera, E. (2020). Envisioning an artificial intelligence documentation assistant for future primary care consultations: A co-design study with general practitioners. *Journal of the American Medical Informatics Association: JAMIA*, *27*(11), 1695–1704. https://doi.org/10.1093/jamia/ocaa131

DiMartino, L., Miano, T., Wessell, K., Bohac, B., & Hanson, L. C. (2022). Identification of Uncontrolled Symptoms in Cancer Patients Using Natural Language Processing. *Journal of pain and symptom management*, *63*(4), 610–617. https://doi.org/10.1016/j.jpainsymman.2021.10.014

Seol, H. Y., Shrestha, P., Muth, J. F., Wi, C. I., Sohn, S., Ryu, E., Park, M., Ihrke, K., Moon, S., King, K., Wheeler, P., Borah, B., Moriarty, J., Rosedahl, J., Liu, H., McWilliams, D. B., & Juhn, Y. J. (2021). Artificial intelligence-assisted clinical decision support for childhood asthma management: A randomized clinical trial. *PloS one*, *16*(8), e0255261. https://doi.org/10.1371/journal.pone.0255261

Zapata, R. D., Huang, S., Morris, E., Wang, C., Harle, C., Magoc, T., Mardini, M., Loftus, T., & Modave, F. (2023). Machine learning-based prediction models for home discharge in patients with COVID-19: Development and evaluation using electronic health records. *PloS one*, *18*(10), e0292888. https://doi.org/10.1371/journal.pone.0292888

Weissenbacher, D., Dutcher, L., Boustany, M., Cressman, L., O'Connor, K., Hamilton, K. W., Gerber, J., Grundmeier, R., & Gonzalez-Hernandez, G. (2025). Automated Evaluation of Antibiotic Prescribing Guideline Concordance in Pediatric Sinusitis Clinical Notes. *Pacific Symposium on Biocomputing. Pacific Symposium on Biocomputing*, *30*, 138–153. https://doi.org/10.1136/bmjhci-2024-101134