

PREDIÇÃO DE LESÕES POR PRESSÃO ATRAVÉS DE INTELIGÊNCIA ARTIFICIAL EM UNIDADES DE CUIDADOS INTENSIVOS: PROTOCOLO DE SCOPING REVIEW

PRESSURE INJURY PREDICTION IN INTENSIVE CARE UNITS USING ARTIFICIAL INTELLIGENCE: SCOPING REVIEW PROTOCOL

PREDICCIÓN DE LESIONES POR PRESIÓN EN UNIDADES DE CUIDADOS INTENSIVOS MEDIANTE INTELIGENCIA ARTIFICIAL: PROTOCOLO DE SCOPING REVIEW

José Alves<sup>1</sup>  
Rita Azevedo<sup>2</sup>  
Ana Marques<sup>3</sup>  
Paulo Alves<sup>4</sup>

<sup>1</sup>Universidade Católica Portuguesa, Faculdade de Ciências da Saúde e Enfermagem, Porto, Portugal; Unidade Local de Saúde de Braga, Hospital de Braga, Serviço de Medicina Intensiva, Braga, Portugal  
<https://orcid.org/0009-0004-5809-3788>

<sup>2</sup>Universidade Católica Portuguesa, Faculdade de Ciências da Saúde e Enfermagem, Porto, Portugal; Unidade Local de Saúde de Braga, Hospital de Braga, Serviço de Medicina Intensiva, Braga, Portugal  
<https://orcid.org/0000-0001-8499-8856>

<sup>3</sup>Universidade Católica Portuguesa, Faculdade de Ciências da Saúde e Enfermagem, Porto, Portugal; Unidade Local de Saúde Gaia e Espinho, Serviço de Medicina Intensiva, Gaia, Portugal  
<https://orcid.org/0000-0003-3603-2656>

<sup>4</sup>Universidade Católica Portuguesa, Faculdade de Ciências da Saúde e Enfermagem, Porto, Portugal; Centro de Investigação Interdisciplinar em Saúde (CIIS), Porto, Portugal | <https://orcid.org/0000-0002-6348-3316>

Corresponding Author  
José Alves  
R. de Diogo Botelho 1327  
4169-005 Porto

RECEIVED: 16th July, 2024  
ACCEPTED: 14th May, 2025  
PUBLISHED: 30th June, 2025

Servir, 2(12), e36731

DOI:10.48492/servir0212.36731

2025



## RESUMO

**Introdução:** As lesões por pressão são eventos adversos frequentes em unidades de cuidados intensivos, com impacto na qualidade de vida das pessoas e nos custos em saúde. As escalas tradicionais de avaliação de risco apresentam limitações no contexto do doente crítico. A inteligência artificial tem vindo a afirmar-se como uma abordagem promissora na identificação precoce do risco, com maior sensibilidade e capacidade de integração de dados clínicos complexos.

**Objetivo:** Identificar e mapear a evidência científica sobre a utilização de inteligência artificial na predição de lesões por pressão em adultos em situação crítica internados em unidades de cuidados intensivos.

**Métodos:** Será realizada uma *scoping review* segundo a metodologia do Joanna Briggs Institute e a *checklist* PRISMA-ScR. A pesquisa incluirá bases de dados e literatura cinzenta, sem restrições de idioma ou data. Serão incluídos estudos que abordem a utilização de inteligência artificial na predição de lesões por pressão em unidades de cuidados intensivos.

**Resultados:** Os dados serão apresentados de forma descritiva e narrativa, com quadros e tabelas que evidenciam os tipos de inteligência artificial, variáveis preditoras, desempenho dos modelos e implicações clínicas.

**Conclusão:** Esta revisão permitirá sistematizar o conhecimento disponível, identificar lacunas na literatura e apoiar a integração de soluções baseadas em inteligência artificial na prática de enfermagem em cuidados intensivos.

**Palavras-chave:** inteligência artificial; úlcera por pressão; unidades de terapia intensiva; cuidados críticos; enfermagem de cuidados críticos.

## ABSTRACT

**Introduction:** Pressure injuries are common adverse events in intensive care units, impacting individuals' quality of life and increasing healthcare costs. Traditional risk assessment scales have significant limitations in the context of critically ill patients. Artificial intelligence has emerged as a promising approach for early risk identification, offering greater sensitivity and the ability to integrate complex clinical data.

**Objective:** To identify and map the available scientific evidence on the use of artificial intelligence for predicting pressure injuries in critically ill adult patients admitted to intensive care units.

**Methods:** A scoping review will be conducted according to the Joanna Briggs Institute methodology and the PRISMA-ScR checklist. The search will include scientific databases and grey literature sources, with no restrictions on language or publication date. Studies addressing the use of artificial intelligence to predict pressure injuries in intensive care settings will be included.

**Results:** Data will be presented descriptively and narratively, using summary tables to highlight types of artificial intelligence, predictive variables, model performance, and clinical implications.

**Conclusion:** This review will systematize current knowledge, identify research gaps, and support the integration of artificial intelligence-based solutions in nursing practice within intensive care contexts.

**Keywords:** artificial intelligence; pressure ulcer; intensive care units; critical care; critical care nursing.

## RESUMEN

**Introducción:** Las lesiones por presión son frecuentes en cuidados intensivos, afectando la calidad de vida y aumentando los costes sanitarios. Las escalas tradicionales presentan limitaciones en pacientes críticos. La inteligencia artificial surge como alternativa prometedora para una detección precoz más precisa.

**Objetivos:** Identificar y mapear la evidencia científica disponible sobre el uso de inteligencia artificial para la predicción de lesiones por presión en pacientes adultos en situación crítica ingresados en unidades de cuidados intensivos.

**Métodos:** Se realizará una *scoping review* según la metodología del Joanna Briggs Institute y la *checklist* PRISMA-ScR. La búsqueda incluirá bases de datos científicas y literatura gris, sin restricciones de idioma o fecha. Se considerarán estudios que aborden el uso de inteligencia artificial para predecir lesiones por presión en cuidados intensivos.

**Resultados:** Los datos se presentarán de forma descriptiva y narrativa, con tablas que resuman tipos de inteligencia artificial, variables predictoras, rendimiento de los modelos e implicaciones clínicas.

**Conclusión:** Esta revisión permitirá sistematizar el conocimiento actual, identificar vacíos en la literatura y apoyar la integración de soluciones basadas en inteligencia artificial en la práctica enfermera en cuidados intensivos.

**Palabras Clave:** inteligencia artificial; úlcera por presión; unidades de cuidados intensivos; cuidados críticos; enfermería de cuidados críticos.

## Introdução

As lesões por pressão (LPP) são um problema transversal aos vários contextos de cuidados de saúde, sejam hospitalares ou extra-hospitalares, com um importante impacto na pessoa e no sistema de saúde. O desenvolvimento de uma LPP pode levar à redução da qualidade de vida, agravamento da dor, risco de infeção, aumento do tempo de internamento hospitalar e permanência em cuidados intensivos, encontrando-se ainda associado a aumentos das taxas de readmissão hospitalar e mortalidade. Representa desta forma um importante acréscimo no custo associado aos cuidados de saúde (Gefen et al., 2020; Roussou et al., 2023).

Uma LPP define-se como uma lesão localizada da pele e/ou tecidos subjacentes em resultado de pressão, ou de uma combinação de forças de pressão e torção, habitualmente localizada em áreas de proeminência óssea. A lesão surge devido às forças exercidas pelo peso corporal do indivíduo, ou como resultado de forças externas como as que são aplicadas por um dispositivo médico ou outro objeto, ou uma combinação destas. O dano tecidual ocorre como resultado de uma exposição prolongada e sustentada a deformações de compressão (perpendiculares à superfície dos tecidos), tensão e torção (paralelo à superfície dos tecidos), ou uma combinação de ambas (Haesler, 2019).

Apesar de frequentemente preveníveis, as lesões por pressão continuam a apresentar elevada prevalência em contexto hospitalar, o que reforça a necessidade de estratégias mais eficazes de prevenção. Numa revisão sistemática realizada por Mutairi et al. (2018) estimou-se que esta pode atingir os 14,8%, com uma incidência média de 6,3%.

As unidades de cuidados intensivos (UCI) caracterizam-se por unidades hospitalares altamente diferenciadas que providenciam suporte e monitorização de forma contínua a pessoas em situação crítica e aguda (Marshall et al., 2017). Fatores como a falência multiorgânica, instabilidade hemodinâmica, insuficiente perfusão e oxigenação, múltiplas comorbilidades, mobilidade reduzida, medicação específica e suporte nutricional insuficiente encontram-se relacionados, neste contexto de cuidados, com um aumento expressivo do risco de desenvolver LPP e consequente aumento da prevalência do fenómeno (Fulbrook et al., 2023). Chaboyer et al. (2018) estimaram uma prevalência cumulativa de LPP em UCI de 16,9%-23,8%, e uma incidência média de 10,0-25,9%. Estes resultados são recentemente reforçados por um estudo observacional prospetivo de grande dimensão realizado em 1117 UCI de 90 países em que foram colhidos dados de 13254 indivíduos. Este revelou uma prevalência global de LPP em UCI de 26,6%, sendo a prevalência de LPP adquirida em cuidados intensivos de 16,2% (Labeau et al., 2021).

Sendo a LPP um evento adverso prevenível e indicador da qualidade dos cuidados de enfermagem, é essencial identificar eficazmente os indivíduos em risco. A identificação do risco é o ponto de partida para a implementação de medidas preventivas adequadas e uma eficaz gestão dos recursos disponíveis. Para este fim foram desenvolvidos diversos instrumentos de avaliação de risco como as escalas de Norton, Braden e Waterlow. Embora considerem fatores gerais, estas escalas não integram variáveis clínicas relevantes, como valores hematológicos, oxigenação, perfusão ou comorbilidades específicas (ex.: diabetes, doença vascular). Não são ainda considerados fatores de risco de populações específicas como é o caso do doente internado em contexto de cuidados intensivos. Por este motivo, quando aplicadas neste contexto, as escalas demonstram baixo poder preditivo: apresentam sensibilidade elevada, mas especificidade reduzida, o que limita a sua capacidade de discriminar efetivamente o risco (Ladios-Martin et al., 2020; Picoito et al., 2023; Wei et al., 2020).

Para dar resposta a esta problemática desenvolveram-se instrumentos específicos para o contexto de cuidados intensivos como as escalas de Cubbin & Jackson, CALCULATE e EVARUCI que apresentam maior poder preditivo nesta população de doentes. No entanto, são instrumentos estáticos, aplicados pontualmente e sem resposta dinâmica ao estado clínico em tempo real (Picoito et al., 2023).

A crescente disponibilidade de dados eletrónicos em saúde tem impulsionado o desenvolvimento de ferramentas tecnológicas, como a inteligência artificial (IA), com potencial para responder a esta problemática. A IA refere-se à capacidade de sistemas computacionais realizarem tarefas que normalmente requerem inteligência humana, como



aprendizagem, raciocínio e tomada de decisão. No contexto da saúde, a IA engloba técnicas como aprendizagem automática (machine learning), aprendizagem profunda (deep learning), redes neurais e processamento de linguagem natural, aplicadas para analisar grandes volumes de dados clínicos e auxiliar na tomada de decisões (De Micco et al., 2025).

Para a predição de fenómenos destacam-se habitualmente as técnicas de *data mining*, que permitem a extração e categorização de grandes quantidades de dados dos registos eletrónicos; e modelos de *machine learning*, um tipo de ferramenta de IA que permite a sistemas de computação a aprendizagem com base em exemplos, dados e experiências, para a construção de modelos preditivos (Raju et al., 2015). Estas técnicas identificam padrões complexos nos registos eletrónicos de saúde e detetam relações entre variáveis que permitem prever o desenvolvimento de LPP (Ladios-Martin et al., 2020). Estudos recentes demonstram a eficácia da IA na predição de LPP em ambientes de cuidados intensivos. Por exemplo, um modelo baseado em XGBoost combinado com SHAP foi desenvolvido para prever o risco de LPP em doentes ventilados mecanicamente, identificando fatores de risco como sépsis, idade e tempo de permanência na UCI (Zheng et al., 2025).

Estes modelos, ao contrário das escalas tradicionais, permitem uma análise mais abrangente dos fatores de risco, bem como a quantificação da relevância relativa de cada variável na predição de LPP. Permitem ainda a aprendizagem constante e adaptação autónoma do modelo a novas situações ao longo do tempo, à medida que novos casos vão surgindo e são integrados nos sistemas de informação (Ladios-Martin et al., 2020; Luo et al., 2020).

A evidência atual destaca o papel crucial das equipas de enfermagem na prevenção das LPP. Desta forma, o desenvolvimento de ferramentas mais eficazes na deteção e estratificação dos indivíduos em risco tem um enorme potencial, assim como profundas implicações, na implementação de medidas preventivas e, de uma forma mais global, na prática de enfermagem (Alderden et al., 2022).

Foi realizada uma pesquisa preliminar nas bases de dados *MEDLINE Complete* (via EBSCOhost), *Scopus*, *CINAHL Complete* (via EBSCOhost), *Pubmed*, *Cochrane Database for Systematic Reviews*, *Joanna Briggs Institute (JBI) Evidence Synthesis*, *Web of Science Core Collection*, *PROSPERO* e *Open Science Framework* e não foram encontradas revisões publicadas, ou em curso, acerca da utilização de IA na predição de LPP na pessoa em situação crítica internada em UCI.

Foi identificada uma revisão sistemática que investiga os modelos de *machine learning* utilizados na avaliação de risco em contexto hospitalar, porém não no contexto específico de cuidados intensivos (Barghouthi et al., 2023), e uma revisão sistemática que aborda as tecnologias de IA na gestão de risco em cuidados intensivos, porém não direcionada para o fenómeno das LPP (Çayırtepe & Şenel, 2022).

A escolha por uma *scoping review* deriva da ausência de uma revisão da literatura direcionada para a temática em questão. Apesar do crescente interesse na aplicação de IA em saúde, são escassas as revisões que abordam especificamente o uso de IA na predição de LPP em UCI. As revisões existentes focam-se, maioritariamente, em contextos hospitalares generalistas ou em áreas como a gestão do risco clínico em UCI, mas não exploram de forma aprofundada este fenómeno em particular. Esta lacuna evidencia a importância e a originalidade da presente revisão, ao sistematizar e mapear a evidência disponível sobre modelos de IA aplicados à predição de LPP em contexto de cuidados intensivos.

Com base no modelo PCC (População, Conceito, Contexto), em que a População corresponde à pessoa em situação crítica; o Conceito, a IA na predição de LPP; e o Contexto, as UCI, e em resposta aos objetivos da revisão determinou-se a seguinte questão de revisão:

- Quais os instrumentos de IA utilizados na predição de risco de lesão por pressão na pessoa em situação crítica internada em cuidados intensivos?

Determinaram-se ainda as seguintes questões secundárias:

- Quais os resultados da aplicação de instrumentos de IA na predição de lesões por pressão na pessoa em situação crítica internada em cuidados intensivos?
- Quais as variáveis identificadas pelos instrumentos de IA na predição de lesões por pressão na pessoa em situação crítica internada em cuidados intensivos?
- Quais as implicações para a prática de enfermagem da utilização de instrumentos de IA na predição de lesões por pressão na pessoa em situação crítica internada em cuidados intensivos?

O objetivo principal é identificar e mapear a evidência científica disponível acerca da utilização de IA na predição de lesão por pressão na pessoa em situação crítica internada em UCI. Pretende-se identificar quais os instrumentos utilizados na predição de LPP, quais os resultados da sua aplicação, quais as variáveis apontadas por esses instrumentos como mais relevantes para a predição de LPP e quais as implicações para a prática de enfermagem da utilização destas ferramentas.

## 1. Métodos

A *scoping review* proposta será realizada em de acordo com a metodologia mais recente proposta pelo *Joanna Briggs Institute* (Peters et al., 2020), e redigida de acordo com a *checklist Preferred Reporting Items for Systematic reviews and Meta-Analyses extension for Scoping Reviews* (PRISMA-ScR) (Tricco et al., 2018). O protocolo desta revisão seguiu a metodologia e itens propostos por Peters et al. (2022), e encontra-se registado no *Open Science Framework* (<https://osf.io/f63vh>).

### 1.1 Critérios de elegibilidade

#### 1.1.1 População

Esta revisão considerará estudos que incluam como participantes pessoas em situação crítica, adultas (com idade igual ou superior a 18 anos). Não serão aplicadas restrições de género, etnia ou outras características pessoais. Considera-se pessoa em situação crítica, aquela que experiencia uma doença crítica, um comprometimento do estado de saúde com potencial de reversibilidade, caracterizado pela falência de órgãos vitais, e um alto risco de morte iminente, se não forem providenciados cuidados adequados (Kayambankadzanja, et al., 2022).

#### 1.1.2 Conceito

Serão considerados estudos que abordam a utilização de IA para a predição de LPP. Entende-se por IA a simulação da inteligência humana por um sistema ou máquina (Xu et al., 2021). Este conceito inclui, mas não se limita a, aprendizagem automática (*machine learning*), aprendizagem profunda (*deep learning*), redes neuronais (*neural networks*) e processamento de linguagem natural (*natural language processing*). Serão excluídos os estudos que explorem outros tipos de instrumentos ou ferramentas. Uma LPP é uma lesão ou ulceração provocada por pressão prolongada sobre a pele e tecidos subjacentes, geralmente resultante da permanência numa mesma posição durante um período prolongado, como por exemplo deitado na cama. Adicionalmente, serão também consideradas as LPP associadas a dispositivos médicos, conhecidas como *medical device-related pressure injuries*, que habitualmente se desenvolvem em localizações diferentes das LPP tradicionais (Haesler, 2019).

#### 1.1.3 Contexto

No que concerne ao contexto serão incluídos estudos realizados em UCI, específicas ou polivalentes, inseridas em hospitais públicos ou privados, sem limitação de contexto geográfico ou cultural. Serão excluídas UCI pediátricas e neonatais. Uma UCI é um sistema organizado para a prestação de cuidados a pessoas em estado crítico, que oferece cuidados médicos e de enfermagem intensivos e especializados, uma capacidade aumentada para monitorização, e múltiplas modalidades de suporte fisiológico de órgãos para sustentar a vida durante um período de insuficiência aguda do sistema de órgãos (Marshall et al., 2017).



#### 1.1.4 Tipos de fontes

Esta scoping review considerará para inclusão estudos quantitativos, qualitativos e de métodos mistos. Serão considerados estudos primários com desenho experimental e quase-experimental, incluindo ensaios clínicos randomizados, ensaios clínicos não randomizados, estudos de antes e depois e séries temporais interrompidas. Serão também considerados estudos observacionais de coorte (prospetivos e retrospectivos), de caso-controlo e transversais analíticos. Esta revisão considerará ainda estudos descritivos observacionais incluindo séries de casos, estudos de caso individuais e estudos descritivos transversais.

Serão também considerados estudos qualitativos como estudos fenomenológicos, grounded theory, descrição qualitativa e investigação-ação. E ainda revisões sistemáticas, dissertações, artigos de opinião e literatura cinzenta de acordo com os critérios de inclusão, e atendendo à metodologia proposta pelo *Joanna Briggs Institute* para *scoping reviews* (Peters et al., 2020).

Não serão aplicadas restrições linguísticas. Serão incluídos estudos em texto integral, e, nos casos em que o texto esteja redigido noutra língua que não o português, inglês ou espanhol, será procurada tradução sempre que possível, desde que o estudo reúna os restantes critérios de elegibilidade. Não serão aplicadas restrições temporais, de forma a mapear exhaustivamente a evidência científica disponível sobre esta temática.

#### 1.2 Estratégia de pesquisa

A estratégia de pesquisa tem como objetivo identificar estudos publicados e não publicados (literatura cinzenta) acerca da temática.

Numa primeira fase foi realizada uma pesquisa nas bases de dados *MEDLINE Complete*, *CINAHL Complete* e *Scopus* para identificar publicações relevantes. Esta pesquisa preliminar permitiu identificar os termos utilizados nos títulos, resumos e palavras-chave das publicações pertinentes. Foram identificados também os termos de indexação (*Medical Subject Headings/CINAHL Subject Headings*) mais relevantes para descrever os conceitos a pesquisar, sendo estes: “*Pressure Ulcer*”; “*Machine Learning*”; “*Artificial Intelligence*”; “*Critical Care*”; “*Intensive Care*”; “*Critical Illness*”; “*Intensive Care Units*”; e “*Critically Ill Patients*”.

Numa segunda fase os termos identificados foram compilados para produzir uma estratégia completa de pesquisa para as bases de dados científicas *MEDLINE Complete* (via *EBSCOhost*), *Scopus*, *CINAHL Complete* (via *EBSCOhost*), *Pubmed*, *Cochrane Library* (*Cochrane Database for Systematic Reviews* e *Cochrane Central Register of Controlled Trials*) e *Web of Science Core Collection*. Um exemplo de uma estratégia completa de pesquisa para a base de dados *CINAHL Complete* (via *EBSCOhost*) encontra-se no Apêndice I.

Para pesquisa de literatura cinzenta elencaram-se as bases de dados: *OpenAIRE*, *Bielefeld Academic Search Engine* (BASE), Repositórios Científicos de Acesso Aberto de Portugal (RCAAP) e ProQuest.

A estratégia de pesquisa, incluindo todas as palavras-chave identificadas e termos de indexação, serão adaptados para cada uma das bases de dados.

Numa terceira fase será realizada uma análise da lista de referências bibliográficas das publicações relevantes para identificar estudos adicionais.

#### 1.3 Seleção de fontes de evidência

Após a pesquisa, todas as referências identificadas serão carregadas para o software Rayyan (Ouzzani et al., 2016) e serão removidos os duplicados. Seguidamente, todos os títulos e resumos serão analisados por dois revisores independentes para verificação (JA e AM), tendo em conta os critérios de inclusão/exclusão da revisão. As fontes de evidência potencialmente relevantes serão recuperadas na forma de texto completo, que será analisado em detalhe por

dois revisores independentes, tendo em conta os critérios de inclusão/exclusão da revisão. Os motivos para exclusão de fontes de evidência após análise do texto completo serão registados e reportados na scoping review. As discrepâncias entre os revisores em qualquer fase do processo serão resolvidas através de consenso, ou recorrendo a um terceiro revisor independente (RA). Os resultados da pesquisa e inclusão das publicações serão relatados de forma completa na scoping review e apresentados recorrendo ao diagrama Preferred Reporting Items for Systematic Reviews and Meta-analyses extension for scoping reviews (PRISMA-ScR) (Tricco et al., 2018).

#### 1.4 Extração de dados

Os dados serão extraídos por dois revisores independentes (JA e AM) através da utilização de um instrumento desenvolvido para o efeito. Serão extraídos dados sobre participantes, conceito, contexto e metodologia dos estudos. Serão ainda extraídos resultados relevantes para dar resposta às questões de revisão, nomeadamente, os tipos de instrumentos de IA utilizados, os resultados obtidos da sua aplicação, as variáveis elencadas por estes instrumentos e as vantagens ou implicações da sua utilização para a prática de enfermagem.

O instrumento de extração de dados resulta de uma adaptação do instrumento de extração de dados proposto pelo *Joanna Briggs Institute* (Peters et al., 2020), e encontra-se no Apêndice II. Esta ferramenta será revista e modificada consoante se torne necessário durante o processo de extração de dados de cada uma das fontes de evidência. Qualquer modificação será detalhada no relatório da scoping review.

Em caso de discordância entre os revisores (JA e AM), será consultado um terceiro revisor independente (RA). Se apropriado, os autores das publicações irão ser contactados no sentido de solicitar quaisquer dados em falta ou adicionais que se tornem necessários.

#### 1.5 Análise e apresentação de dados

No relatório final da scoping review pretende-se uma exposição narrativa dos dados extraídos, podendo recorrer-se a tabelas, quadros, diagramas e/ou figuras, caso necessário e apropriado. A síntese será orientada pelas questões de revisão, com vista a cumprir os objetivos definidos. A síntese de dados será realizada por dois revisores independentes (JA e AM) e, em caso de desentendimento, as decisões serão tomadas através de discussão e obtenção de consenso. Se tal não for possível, encontra-se previsto recorrer a um terceiro revisor para resolução (RA).

### 2. Resultados

Os resultados desta scoping review serão apresentados de forma descritiva e estruturada, em consonância com a metodologia do *Joanna Briggs Institute*. A síntese será organizada em torno das questões de investigação formuladas, com destaque para os tipos de modelos de IA utilizados, variáveis envolvidas na predição de LPP, resultados obtidos e implicações para a prática clínica de enfermagem.

A apresentação incluirá:

- Quadros resumo com as principais características dos estudos incluídos (ano, país, desenho metodológico, tipo de UCI, população, fontes de dados, tipo de IA, variáveis utilizadas, métricas de desempenho, entre outros);
- Tabelas comparativas com os modelos de predição utilizados e respetivos desempenhos (ex.: AUROC, sensibilidade, especificidade, etc.);
- Síntese narrativa dos principais achados, com categorização temática das abordagens identificadas, contextualização clínica e análise das lacunas existentes;
- Apresentação gráfica do processo de seleção dos estudos segundo o diagrama PRISMA-ScR;
- Integração de materiais suplementares, nomeadamente as estratégias de pesquisa, variáveis utilizadas e métricas detalhadas de desempenho dos modelos.





Este formato visa assegurar uma leitura clara, abrangente e alinhada com os objetivos da revisão, permitindo a identificação de padrões emergentes, limitações metodológicas e oportunidades para investigação futura no domínio da predição de LPP em UCI com recurso a IA.

Com esta revisão, pretende-se sistematizar o conhecimento científico atual sobre a utilização de inteligência artificial na predição de lesões por pressão em unidades de cuidados intensivos, identificando tendências, abordagens metodológicas emergentes e áreas clínicas ainda pouco exploradas.

A realização deste trabalho poderá gerar contributos significativos para a investigação, a prática clínica e a formação em enfermagem, ao sistematizar a evidência disponível, identificar lacunas que justifiquem novos estudos e apoiar a integração de ferramentas digitais preditivas na tomada de decisão clínica. Ao clarificar o estado atual do conhecimento, esta revisão poderá ainda constituir uma base sólida para o desenvolvimento de protocolos assistenciais, a definição de prioridades de investigação e a formulação de políticas de saúde centradas na prevenção de lesões por pressão com recurso a tecnologias baseadas em dados.

## Conclusão

As limitações dos instrumentos atualmente disponíveis para identificar o risco de lesões por pressão em cuidados intensivos têm impulsionado profissionais e investigadores a procurar soluções alternativas mais eficazes. As escalas tradicionais, embora amplamente utilizadas, apresentam diversas restrições, incluindo a subjetividade na avaliação e a falta de precisão em diferentes contextos clínicos. Consequentemente, as tecnologias de IA têm o potencial de se apresentarem como uma abordagem dinâmica e inovadora, com capacidade de identificar os fatores de risco e prever antecipadamente este fenómeno.

Tecnologias como o machine learning permitem analisar grandes volumes de dados clínicos com rapidez e precisão, proporcionando uma avaliação mais robusta e personalizada do risco. Além disso, a integração de IA nos sistemas de saúde poderá proporcionar alertas em tempo real e recomendações personalizadas para intervenções preventivas, melhorando significativamente os resultados obtidos.

Esta revisão insere-se numa área emergente e ainda pouco explorada, propondo-se a mapear, de forma sistemática, a aplicação da IA na predição de lesões por pressão em UCI — um contexto particularmente complexo e exigente. Ao clarificar o estado atual do conhecimento, esta scoping review permitirá identificar lacunas na literatura, contribuindo para orientar futuras investigações neste domínio. A sistematização da evidência disponível fornecerá uma base científica sólida para o desenvolvimento de intervenções mais eficazes e inovadoras. Adicionalmente, poderá apoiar a formulação de diretrizes e protocolos clínicos que incorporem ferramentas de IA na prática de enfermagem, promovendo uma abordagem mais proativa, personalizada e eficaz na prevenção de LPP.

Deste modo, esta revisão poderá contribuir não só para o avanço da investigação, mas também para a melhoria dos cuidados centrados na pessoa em situação crítica, ao fomentar uma prática baseada em evidência suportada por tecnologias emergentes.

## Conflito de Interesses

Os autores declaram não haver conflito de interesses.

## Agradecimentos e Financiamento

Os autores agradecem à Faculdade de Ciências da Saúde e Enfermagem da Universidade Católica Portuguesa.

Não existe financiamento previsto para a realização desta revisão.



## Referências bibliográficas

- Al Mutairi, K. B., & Hendrie, D. (2018). Global incidence and prevalence of pressure injuries in public hospitals: A systematic review. *Wound Medicine*, 22, 23–31. <https://doi.org/10.1016/j.wndm.2018.05.004>
- Alderden, J., Kennerly, S. M., Wilson, A., Dimas, J., McFarland, C., Yap, D. Y., Zhao, L., & Yap, T. L. (2022). Explainable Artificial Intelligence for Predicting Hospital-Acquired Pressure Injuries in COVID-19-Positive Critical Care Patients. *Computers, Informatics, Nursing : CIN*, 40(10), 659–665. <https://doi.org/10.1097/CIN.0000000000000943>
- Barghouthi, E. D., Owda, A. Y., Asia, M., & Owda, M. (2023). Systematic Review for Risks of Pressure Injury and Prediction Models Using Machine Learning Algorithms. *Diagnostics*, 13(17), 2739. <https://doi.org/10.3390/diagnostics13172739>
- Çayırtepe, Z., & Şenel, A. C. (2022). Risk Management In Intensive Care Units With Artificial Intelligence Technologies: Systematic Review of Prediction Models Using Electronic Health Records. *Journal of Basic and Clinical Health Sciences*, 6(3), 958–976. <https://doi.org/10.30621/jbachs.993798>
- Chaboyer, W. P., Thalib, L., Harbeck, E. L., Coyer, F. M., Blot, S., Bull, C. F., Nogueira, P. C., & Lin, F. F. (2018). Incidence and Prevalence of Pressure Injuries in Adult Intensive Care Patients: A Systematic Review and Meta-Analysis. *Critical Care Medicine*, 46(11), e1074–e1081. <https://doi.org/10.1097/CCM.0000000000003366>
- De Micco, F., Di Palma, G., Ferorelli, D., De Benedictis, A., Tomassini, L., Tambone, V., Cingolani, M., & Scendoni, R. (2025). Artificial intelligence in healthcare: Transforming patient safety with intelligent systems—A systematic review. *Frontiers in Medicine*, 11. <https://doi.org/10.3389/fmed.2024.1522554>
- Fulbrook, P., Lovegrove, J., Hay, K., & Coyer, F. (2023). State-wide prevalence of pressure injury in intensive care versus acute general patients: A five-year analysis. *Journal of Clinical Nursing*, 32(15–16), 4947–4961. <https://doi.org/10.1111/jocn.16687>
- Gefen, A., Alves, P., Ciprandi, G., Coyer, F., Milne, C. T., Ousey, K., Ohura, N., Waters, N., & Worsley, P. (2020). Device-related pressure ulcers: SECURE prevention. *Journal of Wound Care*, 29(Sup2a), S1–S52. <https://doi.org/10.12968/jowc.2020.29.Sup2a.S1>
- Haesler, E. (Ed.). (2019). Prevention and treatment of pressure ulcers/injuries: Clinical practice guideline: the international guideline (3. edition). Epuap, European Pressure Ulcer Advisory Panel.
- Kayambankadzanja, R. K., Schell, C. O., Gerdin Wärnberg, M., Tamras, T., Mollazadegan, H., Holmberg, M., Alvesson, H. M., & Baker, T. (2022). Towards definitions of critical illness and critical care using concept analysis. *BMJ Open*, 12(9), e060972. <https://doi.org/10.1136/bmjopen-2022-060972>
- Labeau, S. O., Afonso, E., Benbenishty, J., Blackwood, B., Boulanger, C., Brett, S. J., Calvino-Gunther, S., Chaboyer, W., Coyer, F., Deschepper, M., François, G., Honore, P. M., Jankovic, R., Khanna, A. K., Llauro-Serra, M., Lin, F., Rose, L., Rubulotta, F., Saager, L., ... Erdogan, E. (2021). Prevalence, associated factors and outcomes of pressure injuries in adult intensive care unit patients: The DecubICUs study. *Intensive Care Medicine*, 47(2), 160–169. <https://doi.org/10.1007/s00134-020-06234-9>
- Ladios-Martin, M., Fernández-de-Maya, J., Ballesta-López, F.-J., Belso-Garzas, A., Mas-Asencio, M., & Cabañero-Martínez, M. J. (2020). Predictive Modeling of Pressure Injury Risk in Patients Admitted to an Intensive Care Unit. *American Journal of Critical Care : An Official Publication, American Association of Critical-Care Nurses*, 29(4), e70–e80. <https://doi.org/10.4037/ajcc2020237>
- Luo, Y., Yin, L., Bai, W., & Mao, K. (2020). An Appraisal of Incremental Learning Methods. *Entropy*, 22(11), 1190. <https://doi.org/10.3390/e22111190>
- Marshall, J. C., Bosco, L., Adhikari, N. K., Connolly, B., Diaz, J. V., Dorman, T., Fowler, R. A., Meyfroidt, G., Nakagawa, S., Pelosi, P., Vincent, J.-L., Vollman, K., & Zimmerman, J. (2017). What is an intensive care unit? A report of the task force of the World Federation of Societies of Intensive and Critical Care Medicine. *Journal of Critical Care*, 37, 270–276. <https://doi.org/10.1016/j.jcrc.2016.07.015>
- Ouzzani, M., Hammady, H., Fedorowicz, Z., & Elmagarmid, A. (2016). Rayyan—A web and mobile app for systematic reviews. *Systematic Reviews*, 5(1). <https://doi.org/10.1186/s13643-016-0384-4>
- Peters, M. D. J., Godfrey, C., McInerney, P., Khalil, H., Larsen, P., Marnie, C., Pollock, D., Tricco, A. C., & Munn, Z. (2022). Best practice guidance and reporting items for the development of scoping review protocols. *JBIM Evidence Synthesis*, 20(4), 953. <https://doi.org/10.11124/JBIES-21-00242>
- Peters, M. D. J., Marnie, C., Tricco, A. C., Pollock, D., Munn, Z., Alexander, L., McInerney, P., Godfrey, C. M., & Khalil,



- H. (2020). Updated methodological guidance for the conduct of scoping reviews. *JB I Evidence Synthesis*, 18(10), 2119–2126. <https://doi.org/10.11124/JBIES-20-00167>
- Picoito, R. J. de B. R., Lapuente, S. M. M. P. da C., Ramos, A. C. P., Rabiais, I. C. M., Deodato, S. J., & Nunes, E. M. G. T. (2023). Risk assessment instruments for pressure ulcer in adults in critical situation: A scoping review. *Revista Latino-Americana de Enfermagem*, 31(e3983). <https://doi.org/10.1590/1518-8345.6659.3983>
- Raju, D., Su, X., Patrician, P. A., Loan, L. A., & McCarthy, M. S. (2015). Exploring factors associated with pressure ulcers: A data mining approach. *International Journal of Nursing Studies*, 52(1), 102–111. <https://doi.org/10.1016/j.ijnurstu.2014.08.002>
- Roussou, E., Fasoi, G., Stavropoulou, A., Kelesi, M., Vasilopoulos, G., Gerogianni, G., & Alikari, V. (2023). Quality of life of patients with pressure ulcers: A systematic review. *Medicine and Pharmacy Reports*, 96(2), 123–130. <https://doi.org/10.15386/mpr-2531>
- Tricco, A. C., Lillie, E., Zarin, W., O'Brien, K. K., Colquhoun, H., Levac, D., Moher, D., Peters, M. D. J., Horsley, T., Weeks, L., Hempel, S., Akl, E. A., Chang, C., McGowan, J., Stewart, L., Hartling, L., Aldcroft, A., Wilson, M. G., Garritty, C., ... Straus, S. E. (2018). PRISMA Extension for Scoping Reviews (PRISMA-ScR): Checklist and Explanation. *Annals of Internal Medicine*, 169(7), 467–473. <https://doi.org/10.7326/M18-0850>
- Wei, M., Wu, L., Chen, Y., Fu, Q., Chen, W., & Yang, D. (2020). Predictive Validity of the Braden Scale for Pressure Ulcer Risk in Critical Care: A Meta-Analysis. *Nursing in Critical Care*, 25(3), 165–170. <https://doi.org/10.1111/nicc.12500>
- Xu, Y., Liu, X., Cao, X., Huang, C., Liu, E., Qian, S., Liu, X., Wu, Y., Dong, F., Qiu, C.-W., Qiu, J., Hua, K., Su, W., Wu, J., Xu, H., Han, Y., Fu, C., Yin, Z., Liu, M., ... Zhang, J. (2021). Artificial intelligence: A powerful paradigm for scientific research. *The Innovation*, 2(4), 100179. <https://doi.org/10.1016/j.xinn.2021.100179>
- Zheng, L., Xue, Y., Yuan, Z., & Xing, X. (2025). Explainable SHAP-XGBoost models for pressure injuries among patients requiring with mechanical ventilation in intensive care unit. *Scientific Reports*, 15(1), 9878. <https://doi.org/10.1038/s41598-025-92848-2>

Alves, J., Azevedo, R., Marques, A., & Alves, P. (2025).

Predição de lesões por pressão através de inteligência artificial em unidades de cuidados intensivos: protocolo de scoping review

*Servir*, 2(12), e36731. <https://doi.org/10.48492/servir0212.36731>

## Apêndice I: Estratégia Completa de Pesquisa

CINAHL Complete (via EBSCOhost)

Searched on 01/03/2024

Search	Search Query	Records Retrieved
S1	TI ( "Pressure ulcer*" OR Bedsore* OR "Bed Sore*" OR "Decubitus Ulcer*" OR "Pressure Sore*" OR "Pressure Injur*" ) OR AB ( "Pressure ulcer*" OR Bedsore* OR "Bed Sore*" OR "Decubitus Ulcer*" OR "Pressure Sore*" OR "Pressure Injur*" ) OR MH "Pressure Ulcer"	18618
S2	TI ( "Machine Learning" OR "Artificial Intelligence" OR "Deep Learning" OR "Supervised Machine Learning" OR "Unsupervised Machine Learning" OR "Neural Networks" OR "Support Vector Machine" ) OR AB ( "Machine Learning" OR "Artificial Intelligence" OR "Deep Learning" OR "Supervised Machine Learning" OR "Unsupervised Machine Learning" OR "Neural Networks" OR "Support Vector Machine" ) OR MH ( "Machine Learning" OR "Artificial Intelligence" OR "Deep Learning" OR "Support Vector Machine" OR "Neural Networks" )	39469
S3	TI ( "ICU" OR "Critical Care" OR "Intensive Care" OR "Critical Illness" OR "Critically Ill Patient*" OR "Intensive Care Unit*" ) OR AB ( "ICU" OR "Critical Care" OR "Intensive Care" OR "Critical Illness" OR "Critically Ill Patient*" OR "Intensive Care Unit*" ) OR MH ( "Critical Care" OR "Intensive Care Units" OR "Critical Illness" OR "Critically Ill Patients" )	149423
S4	S1 AND S2 AND S3	10



## Apêndice II: Instrumento de Extração de Dados

Detalhes da Scoping Review		
Título da Scoping Review	Predição de lesões por pressão através de inteligência artificial em unidades de cuidados intensivos: scoping review	
Objetivo	Identificar e mapear a evidência científica disponível acerca da utilização de inteligência artificial na predição de lesão por pressão na pessoa em situação crítica internada em unidades de cuidados intensivos.	
Questões de revisão	<ul style="list-style-type: none"> <li>Quais os instrumentos de inteligência artificial utilizados na predição de risco de lesão por pressão na pessoa em situação crítica internada em cuidados intensivos?</li> <li>Quais os resultados da aplicação de instrumentos de inteligência artificial na predição de risco de lesão por pressão na pessoa em situação crítica internada em cuidados intensivos?</li> <li>Quais as variáveis identificadas pelos instrumentos de inteligência artificial na predição de risco de lesão por pressão na pessoa em situação crítica internada em cuidados intensivos?</li> <li>Quais as implicações para a prática de enfermagem da utilização de instrumentos de inteligência artificial na predição de risco de lesão por pressão na pessoa em situação crítica internada em cuidados intensivos?</li> </ul>	
Revisor responsável pela extração de dados		
Detalhes e características da fonte de evidência		
Detalhes de Citação	Autor	
	Data	
	Título	
	Revista	
	Volume	
	Número	
	Páginas	
País		
Contexto		
Participantes/População		
Tipo de estudo		
Objetivos		
Metodologia		
Detalhes e resultados extraídos da fonte de evidência		
Instrumento de inteligência artificial		
Principais resultados da aplicação do instrumento		
Variáveis identificadas pelo instrumento para a predição de LPP		
Implicações para a prática de enfermagem		
Referências Bibliográficas		