

Impacto clínico da inteligência artificial na detecção precoce da sepse em pacientes adultos hospitalizados: ênfase em Unidades de Terapia Intensiva

Clinical impact of artificial intelligence on early sepsis detection in hospitalized adults: emphasis on Intensive Care Units

Laura Leão Carneiro Frezza

Laura Luiza Parreira Borges

Pedro Henrique Motta Moreira

Rita Alessandra Cardoso

e-mail: Leaolaura06@gmail.com

DOI: [10.47224/revistamaster.v11i21.858](https://doi.org/10.47224/revistamaster.v11i21.858)

Resumo

A sepse constitui uma condição clínica grave, cujo reconhecimento precoce permanece desafiador, especialmente em pacientes críticos. Nesse contexto, o presente estudo teve como objetivo analisar as evidências científicas atuais sobre o impacto clínico da inteligência artificial na detecção precoce da sepse em pacientes adultos hospitalizados, com ênfase em Unidades de Terapia Intensiva, identificando os modelos utilizados, sua acurácia diagnóstica e seus efeitos nos desfechos clínicos. Trata-se de uma revisão integrativa da literatura, com busca nas bases PubMed/MEDLINE, Scopus, BVS e SciELO, incluindo estudos publicados entre 2020 e março de 2025. Oito estudos compuseram a amostra final. Os resultados demonstraram a utilização de diferentes modelos de *machine learning* e *deep learning*, com desempenho preditivo relevante, incluindo valores elevados de AUC/AUROC, sensibilidade, especificidade e acurácia. Alguns modelos também demonstraram capacidade de antecipar a identificação da sepse em relação ao seu início. Entretanto, os estudos concentraram-se predominantemente no desenvolvimento, validação e desempenho preditivo dos algoritmos, sendo menos consistente a avaliação de seus efeitos diretos sobre desfechos clínicos. Conclui-se que a inteligência artificial apresenta potencial para auxiliar na detecção precoce da sepse, embora sejam necessárias evidências adicionais sobre os benefícios clínicos decorrentes de sua implementação.

Palavras-chave: Sepse; Inteligência artificial; Aprendizado de máquina; Diagnóstico precoce; Unidade de terapia intensiva.

Abstract

Sepsis is a severe clinical condition whose early recognition remains challenging, particularly in critically ill patients. In this context, this study aimed to analyze current scientific evidence on the clinical impact of artificial intelligence on the early detection of sepsis in hospitalized adult patients, with an emphasis on Intensive Care Units, identifying the models used, their diagnostic accuracy, and their effects on clinical outcomes. This integrative literature review searched PubMed/MEDLINE, Scopus, BVS, and SciELO for studies published between 2020 and March 2025. Eight studies comprised the final sample. The results showed the use of different machine learning and deep learning models, with relevant predictive performance, including high AUC/AUROC, sensitivity, specificity, and accuracy values. Some models also demonstrated the ability to anticipate the identification of sepsis before its onset. However, the studies focused predominantly on algorithm development, validation, and predictive performance, while evidence regarding their direct effects on clinical outcomes was less consistent. It is concluded that artificial intelligence has the potential to support the early detection of sepsis, although additional evidence is needed regarding the clinical benefits resulting from its implementation.

Keywords: Sepsis; Artificial Intelligence; Machine Learning; Early Diagnosis; Intensive Care Unit

1 INTRODUÇÃO

A sepse permanece entre as condições de maior gravidade no ambiente hospitalar, especialmente em pacientes críticos, nos quais seu reconhecimento precoce representa um desafio clínico. A semelhança entre manifestações apresentadas por pacientes com e sem sepse pode dificultar sua identificação, exigindo acompanhamento contínuo e avaliação de diferentes parâmetros clínicos para reconhecer aqueles com maior risco de desenvolver a condição (Sjövall; Persson, 2022).

A disponibilidade crescente de dados clínicos registrados eletronicamente tem favorecido o desenvolvimento de novas estratégias para auxiliar esse reconhecimento. Informações obtidas rotineiramente durante a internação, como sinais vitais e resultados de exames laboratoriais, podem ser utilizadas por modelos computacionais para identificar padrões associados à sepse. Nesse contexto, técnicas de *machine learning* permitem analisar simultaneamente diferentes variáveis clínicas e construir modelos voltados à identificação de pacientes em risco (Wang *et al.*, 2021).

O desempenho desses modelos tem sido avaliado por diferentes métricas, como área sob a curva ROC, sensibilidade, especificidade e acurácia. Além do desempenho preditivo, a possibilidade de validação em diferentes populações constitui aspecto relevante para avaliar a aplicabilidade dessas ferramentas. Em estudo multicêntrico envolvendo dados de pacientes com sepse em contextos de saúde dos Estados Unidos e da China, modelos de *machine learning* apresentaram AUC superior a 0,8 e mantiveram desempenho na validação externa (Shi *et al.*, 2025).

Outra característica relevante dessas tecnologias é a possibilidade de antecipar o reconhecimento da sepse. Algoritmos desenvolvidos a partir de parâmetros clínicos obtidos rotineiramente na UTI têm demonstrado capacidade de identificar pacientes sob risco antes do estabelecimento da condição. Sjövall e Persson observaram acurácia de 0,79, sensibilidade de 0,80 e especificidade de 0,78 na predição do desenvolvimento da sepse três horas antes de seu início, evidenciando a possibilidade de utilização dessas ferramentas como apoio ao reconhecimento precoce (Sjövall; Persson, 2022).

Entretanto, o desempenho preditivo de um algoritmo não representa, por si só, demonstração de benefício clínico. A validação dos modelos em diferentes populações e contextos assistenciais permanece necessária para determinar sua capacidade de generalização, e os resultados obtidos em uma população não podem ser automaticamente transferidos para outros cenários de cuidado. Essa necessidade foi ressaltada por Wang *et al.* (2021), que, apesar do bom desempenho de seu modelo, apontaram a importância de estudos de validação externa para confirmar sua aplicabilidade em outras populações.

Diante desse cenário, o presente estudo tem como objetivo analisar as evidências científicas atuais (2020–2025) sobre o impacto clínico da inteligência artificial na detecção precoce de sepse em pacientes adultos hospitalizados, com ênfase em Unidades de Terapia Intensiva, identificando os modelos utilizados, sua acurácia diagnóstica e seus efeitos nos desfechos clínicos.

2 METODOLOGIA

Trata-se de uma revisão integrativa da literatura, de caráter exploratório e descritivo, com abordagem qualitativa, elaborada com o objetivo de sintetizar as evidências científicas disponíveis sobre o uso de modelos de inteligência artificial na detecção, predição e diagnóstico precoce da sepse em pacientes adultos hospitalizados, com ênfase em Unidades de Terapia Intensiva (UTIs). Esse tipo de revisão permite reunir e analisar estudos com diferentes delineamentos metodológicos, favorecendo uma compreensão abrangente do fenômeno investigado.

A condução metodológica contemplou as etapas de definição da questão de pesquisa, estabelecimento dos critérios de inclusão e exclusão, busca nas bases de dados, seleção dos estudos, extração das informações e síntese dos resultados. O processo de identificação, triagem, elegibilidade e inclusão dos estudos foi apresentado por meio de fluxograma adaptado das recomendações do *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA 2020).

2.1 Questão de pesquisa

A questão norteadora foi estruturada com base na estratégia PECO:

P (População): pacientes adultos (≥ 18 anos) hospitalizados, com ênfase naqueles internados em Unidades de Terapia Intensiva;

E (Exposição): utilização de modelos de inteligência artificial, *machine learning* ou *deep learning* aplicados à detecção, predição ou diagnóstico precoce da sepse;

C (Comparação): escores clínicos tradicionais, como SOFA, qSOFA, SIRS ou NEWS, ou outras estratégias de avaliação, quando disponíveis;

O (Desfecho): desempenho diagnóstico ou preditivo dos modelos, incluindo AUC/AUROC, sensibilidade, especificidade, acurácia e tempo de antecipação da sepse, além de desfechos clínicos, quando avaliados.

Com base nessa estrutura, formulou-se a seguinte questão de pesquisa:

Quais são as evidências científicas publicadas entre 2020 e março de 2025 sobre o uso de modelos de inteligência artificial na detecção, predição ou diagnóstico precoce da sepse em pacientes adultos hospitalizados, com ênfase em Unidades de Terapia Intensiva?

1. 2.2 Estratégia de busca e fontes de dados

A busca bibliográfica foi realizada nas bases PubMed/MEDLINE, Scopus, Biblioteca Virtual em Saúde (BVS) e Scientific Electronic Library Online (SciELO).

Foram utilizados descritores controlados e termos livres provenientes dos vocabulários MeSH (*Medical Subject Headings*) e DeCS (Descritores em Ciências da Saúde), relacionados à inteligência artificial, sepse, detecção precoce e cuidados intensivos, combinados pelos operadores booleanos AND e OR.

Entre os termos utilizados estavam: "Artificial Intelligence", "Machine Learning", "Deep Learning", "Sepsis", "Septic Shock", "Intensive Care Unit", "Critical Care", "Early Detection", "Prediction", "Diagnosis", "Clinical Decision Support", "Electronic Health Records" e "Risk Prediction".

Como exemplo, a estratégia empregada no PubMed/MEDLINE foi:

("Artificial Intelligence" OR "Machine Learning" OR "Deep Learning")
AND ("Sepsis" OR "Septic Shock")
AND ("Intensive Care Unit" OR "Critical Care")
AND ("Early Detection" OR "Prediction" OR "Diagnosis")

Foram consideradas publicações entre janeiro de 2020 e março de 2025, nos idiomas português, inglês ou espanhol, envolvendo população humana adulta e com texto completo disponível.

2.3 Critérios de inclusão e exclusão

Foram incluídos artigos originais publicados entre janeiro de 2020 e março de 2025, envolvendo pacientes adultos (≥ 18 anos) hospitalizados, predominantemente em contexto de terapia intensiva, que utilizaram modelos de inteligência artificial, *machine learning* ou *deep learning* aplicados à detecção, predição ou diagnóstico precoce da sepse. Os estudos deveriam apresentar medidas de desempenho dos modelos, como AUC/AUROC, sensibilidade, especificidade, acurácia ou outras métricas de desempenho preditivo. Foram considerados estudos observacionais retrospectivos ou prospectivos, estudos de coorte, estudos de desenvolvimento e validação de modelos e outros delineamentos originais compatíveis com a questão investigada.

Foram excluídos revisões sistemáticas, meta-análises, *umbrella reviews*, revisões narrativas, revisões integrativas e *scoping reviews*; editoriais, cartas ao editor, comentários, resumos de congressos, relatos de caso e protocolos sem resultados publicados; estudos realizados exclusivamente com população pediátrica ou neonatal, modelos animais ou experimentos *in vitro*; propostas teóricas sem validação ou avaliação de desempenho; artigos que não abordassem a utilização de inteligência artificial na detecção ou predição da sepse; registros duplicados e artigos sem acesso ao texto completo.

2.4 Seleção dos estudos

A busca nas bases de dados resultou na identificação de 124 registros. Após a remoção de 19 duplicatas, permaneceram 105 estudos para triagem por título e resumo. Nessa etapa, 74 estudos foram excluídos por não atenderem aos critérios de elegibilidade, resultando em 31 artigos selecionados para leitura na íntegra.

Após a avaliação dos textos completos, 23 artigos foram excluídos por não atenderem aos critérios de inclusão estabelecidos. Ao final do processo de seleção, oito estudos compuseram a amostra final da revisão integrativa.


O processo de identificação, triagem, elegibilidade e inclusão dos estudos foi representado por meio de fluxograma baseado nas recomendações do PRISMA 2020.

2.5 Extração e análise dos dados

Os dados dos oito estudos incluídos foram extraídos de forma padronizada e organizados em quadro de síntese.

3 RESULTADOS

Seleção dos artigos nas bases de dados



Fluxograma de Prisma 2020

Síntese dos artigos selecionados

Autor (Ano)	Desenho do estudo	Objetivo principal	Síntese dos resultados
Yang et al. (2020)	Observacional retrospectivo	Desenvolver IA explicável para predição horária de sepse.	Modelo desenvolvido com 40.336 registros e 168 características clínicas, com proposta de predição em tempo real e interpretabilidade das variáveis.
Yuan et al. (2020)	Coorte prospectiva aberta	Desenvolver algoritmo baseado em XGBoost para diagnóstico precoce de sepse e compará-lo ao SOFA.	AUROC próxima de 0,89, superior à obtida pelo SOFA (aproximadamente 0,59).
Cooper et al. (2021)	Revisão retrospectiva	Avaliar ferramenta automatizada de triagem de sepse em hospital comunitário.	Modelo de regressão logística com seis variáveis; AUC de 0,857 e rastreamento automatizado das internações sem triagem manual da enfermagem.
Wang et al. (2021)	Coorte observacional	Desenvolver modelo Random Forest para predição do início da sepse.	AUC de 0,91, sensibilidade de 87% e especificidade de 89%.
Sjövall e Persson	Estudo clínico em UTI	Validar a acurácia prognóstica de algoritmo de machine learning para predição do desenvolvimento de sepse.	Acurácia de 0,79, sensibilidade de 0,80 e especificidade de 0,78, com predição 3 horas antes do início da sepse.
Kim et al. (2023)	Retrospectivo	Desenvolver e validar o sistema DeepSEPS para predição precoce de sepse e choque séptico.	AUROC de 0,7888 para sepse e 0,8494 para choque séptico, chegando a 0,9346 no momento do início da sepse; desempenho superior a NEWS, SOFA e qSOFA.
Gupta et al. (2024)	Desenvolvimento e validação	Desenvolver o SepsisAI com foco na predição precoce e redução de falsos alarmes.	AUROC de 0,95, sensibilidade de 88,19%, especificidade de 96,75% e taxa de falsos alarmes

Autor (Ano)	Desenho do estudo	Objetivo principal	Síntese dos resultados
			de 3,18%; aviso mediano 6 h antes e alerta 4 h antes da sepse.
Shi et al. (2025)	Coorte retrospectiva multicêntrica	Desenvolver modelo de machine learning para triagem rápida e predição de desfechos em pacientes com sepse nas primeiras 24 h de UTI.	Com 31 características clínicas, os modelos alcançaram AUCs >0,8; na validação externa, os escores variaram de 0,63 a 0,77.

Quadro 1: Características dos artigos selecionados

4 DISCUSSÃO

Os estudos incluídos nesta revisão demonstram que diferentes modelos de inteligência artificial têm sido empregados na detecção e predição da sepse em pacientes críticos, com predomínio de técnicas de *machine learning* e *deep learning*. Entre as abordagens avaliadas estão XGBoost, Random Forest, regressão logística, redes neurais profundas e redes LSTM, além de outros modelos de aprendizado de máquina. Apesar das diferenças metodológicas, os estudos apresentaram, de modo geral, desempenho satisfatório na identificação de pacientes com sepse ou sob risco de desenvolvê-la.

Entre os modelos de *machine learning*, Yuan *et al.* (2020) obtiveram AUROC próxima de 0,89, enquanto Wang *et al.* (2021), utilizando Random Forest, alcançaram AUC de 0,91, sensibilidade de 87% e especificidade de 89%. Cooper *et al.* (2021), por sua vez, desenvolveram um modelo de regressão logística baseado em seis variáveis, com AUC de 0,857. Esses resultados mostram que desempenhos relevantes foram obtidos com diferentes abordagens algorítmicas, inclusive com modelos construídos a partir de um número reduzido de variáveis.

Resultados expressivos também foram observados com modelos de *deep learning*. O DeepSEPS, desenvolvido por Kim *et al.* (2023), apresentou AUROC de 0,7888 para sepse e 0,8494 para choque séptico, chegando a 0,9346 no momento do início da sepse. No estudo de Gupta *et al.* (2024), o SepsisAI apresentou AUROC de 0,95, sensibilidade de 88,19% e especificidade de 96,75%. Além do desempenho discriminatório, esse modelo apresentou mediana de seis horas para emissão de aviso e de quatro horas para alerta antes do início da sepse, indicando a possibilidade de identificação antecipada de pacientes em risco.

A antecipação também foi observada por Sjövall e Persson, cujo algoritmo apresentou acurácia de 0,79, sensibilidade de 0,80 e especificidade de 0,78 na predição do desenvolvimento da sepse **três horas antes de seu início**. Esse resultado é particularmente relacionado ao objetivo desta revisão, pois demonstra a utilização da inteligência artificial não apenas para reconhecer casos já estabelecidos, mas para identificar previamente pacientes com maior risco de desenvolver sepse.

Shi *et al.* (2025) ampliaram essa perspectiva ao avaliar modelos de aprendizado de máquina utilizando 31 características clínicas obtidas nas primeiras 24 horas de internação na UTI. Os modelos alcançaram AUCs superiores a 0,8 e mantiveram escores entre 0,63 e 0,77 na validação externa realizada em diferentes contextos de saúde. Entretanto, diferentemente dos estudos direcionados à antecipação do início da sepse, o trabalho concentrou-se na triagem e predição de desfechos em pacientes com sepse, devendo seus resultados ser interpretados dentro dessa finalidade específica.

Embora os resultados indiquem bom desempenho dos modelos avaliados, **o impacto sobre os desfechos clínicos permanece menos esclarecido**. Entre os oito estudos selecionados, predominam investigações voltadas ao desenvolvimento, validação e desempenho preditivo dos algoritmos. Assim, a possibilidade de detecção antecipada demonstrada em alguns estudos não deve ser interpretada, por si só, como evidência de redução de mortalidade ou melhora de outros desfechos clínicos. Os próprios resultados disponíveis sustentam com maior consistência a capacidade preditiva dessas ferramentas do que seus efeitos diretos sobre a evolução dos pacientes.

No conjunto, as evidências analisadas mostram que a inteligência artificial apresenta potencial para auxiliar a detecção precoce da sepse em adultos internados em UTI, com resultados relevantes de acurácia, sensibilidade, especificidade e capacidade de antecipação em diferentes modelos. Entretanto, a heterogeneidade das abordagens e das métricas utilizadas, associada à limitada avaliação de desfechos clínicos, exige cautela na comparação direta entre os estudos. Os achados sustentam o potencial dessas ferramentas como apoio à identificação precoce da sepse, mas ainda deixam uma lacuna quanto à demonstração de benefício clínico decorrente de sua implementação.

5 CONCLUSÕES

Os estudos analisados indicam que modelos de inteligência artificial apresentam bom desempenho na detecção e predição precoce da sepse, com resultados relevantes de acurácia, sensibilidade, especificidade e capacidade de antecipação do quadro clínico. Em alguns estudos, esses modelos apresentaram desempenho superior aos escores clínicos tradicionais. Entretanto, diferenças entre os algoritmos, populações e estratégias de validação limitam a comparação direta dos resultados, e as evidências sobre seus efeitos nos desfechos clínicos ainda são restritas. Assim, embora a inteligência artificial apresente potencial como ferramenta de apoio à identificação precoce da sepse, sua incorporação à prática clínica requer maior validação em diferentes populações e contextos assistenciais.

Nota sobre o uso de ferramentas de IA: Este manuscrito contou com o apoio de ferramentas de Inteligência Artificial de forma assistiva, exclusivamente para revisão textual, organização do conteúdo e tradução do resumo para o abstract. As ferramentas não foram utilizadas para a geração de resultados, análise de dados ou formulação de conclusões. Todo o conteúdo foi revisado criticamente pelos autores, que assumem integral responsabilidade pela interpretação dos dados encontrados, pelo rigor científico e integridade acadêmica do trabalho.

6 REFERÊNCIAS

COOPER, P. *et al.* Implementation of an automated sepsis screening tool in a community hospital setting. **Journal of Nursing Care Quality**, 2020. DOI: 10.1097/NCQ.0000000000000501.

GUPTA, A. *et al.* Improving sepsis prediction in intensive care with SepsisAI: a clinical decision support system with a focus on minimizing false alarms. **PLOS Digital Health**, v. 3, n. 8, e0000569, 2024. DOI: 10.1371/journal.pdig.0000569.

KIM, T. *et al.* Development and validation of deep-learning-based sepsis and septic shock early prediction system (DeepSEPS) using real-world ICU data. **Journal of Clinical Medicine**, v. 12, n. 22, p. 7156, 2023. DOI: 10.3390/jcm12227156.

SHI, S. *et al.* Developing a rapid screening tool for high-risk ICU patients of sepsis: integrating electronic medical records with machine learning methods for mortality prediction in hospitalized patients — model establishment, internal and external validation, and visualization. **Journal of Translational Medicine**, v. 23, p. 123, 2025. DOI: 10.1186/s12967-025-06102-4.

SJÖVALL, F. *et al.* A machine learning algorithm for early prediction of sepsis in intensive care. **Critical Care Medicine**, v. 50, n. 1, p. e62, 2022. DOI: 10.1097/01.ccm.0000910620.81838.07.

WANG, D. *et al.* A machine learning model for accurate prediction of sepsis in ICU patients. **Frontiers in Public Health**, v. 9, p. 754348, 2021. DOI: 10.3389/fpubh.2021.754348.

YANG, M. *et al.* An explainable artificial intelligence predictor for early detection of sepsis. **Critical Care Medicine**, 2020. DOI: 10.1097/CCM.0000000000004550.

YUAN, K. *et al.* The development of an artificial intelligence algorithm for early sepsis diagnosis in the intensive care unit. **International Journal of Medical Informatics**, v. 142, p. 104176, 2020. DOI: 10.1016/j.ijmedinf.2020.104176.