



Abordagens e eficácia da inteligência artificial na predição de fatores de risco para sepse neonatal

Approaches and effectiveness of artificial intelligence in predicting risk factors for neonatal sepsis

Enfoques y efectividad de la inteligencia artificial en la predicción de factores de riesgo de sepsis neonatal

Polyana Alves Bernardino¹, Driele da Silva Pereira², Maria Eduarda da Silva Lira², Andréa de Oliveira Ribeiro Cavalcanti³, Jacqueline Lira Braga⁴, Rizonaide Oliveira Silva⁴, José William Araújo do Nascimento⁵.

RESUMO

Objetivo: Identificar abordagens e eficácia da Inteligência Artificial (IA) na predição de fatores de risco para sepse neonatal. **Métodos:** Trata-se de uma revisão integrativa, realizada nas bases de dados PubMed, Scopus, Web of Science e IEEE, por meio dos seguintes descritores: "neonatal sepsis", "intensive care units, neonatal", "artificial intelligence", "machine learning" e "deep learning". Foram incluídos estudos publicados entre 2014 a 2024 que incluíam sepse neonatal em unidades de terapia intensiva. **Resultados:** A amostra final consistiu em 06 artigos, com uma concentração mais elevada de publicações em 2021. A maioria dos estudos foi conduzida no EUA, e os designs de pesquisa predominantes foram estudos de coorte retrospectivo. Verificou-se que os modelos de IA, como Random Forest, SVM e Regressão Logística, são eficazes na predição de fatores de risco críticos para sepse neonatal, permitindo intervenções clínicas mais precoces e precisas, o que pode melhorar significativamente os desfechos clínicos em neonatos vulneráveis. **Considerações finais:** Esta revisão destaca o impacto dos modelos de IA na predição de sepse neonatal, mostrando seu potencial para intervenções clínicas antecipadas. No entanto, futuras pesquisas devem focar na validação externa e na integração cuidadosa desses modelos na prática clínica.

Palavras-chave: Inteligência Artificial, Recém-Nascido, Sepse Neonatal.

ABSTRACT

Objective: To identify approaches and the effectiveness of Artificial Intelligence (AI) in predicting risk factors for neonatal sepsis. **Methods:** This is an integrative review conducted across the PubMed, Scopus, Web of Science, and IEEE databases using the following descriptors: "neonatal sepsis," "intensive care units, neonatal," "artificial intelligence," "machine learning," and "deep learning." Studies published between 2014 and 2024 that included neonatal sepsis in intensive care units were included. **Results:** The final sample

¹ Universidade Católica de Pernambuco, Recife - PE.

² Faculdade dos Palmares, Palmares - PE.

³ Universidade Federal da Paraíba, João Pessoa - PB.

⁴ Faculdade Santa Emilia do Rodar, João Pessoa - PB.

⁵ Centro de Informática da Universidade Federal de Pernambuco (Cin-UFPE), Recife - PE.

consisted of 06 articles, with a higher concentration of publications in 2021. Most studies were conducted in the USA, and the predominant research designs were retrospective cohort studies. It was found that AI models, such as Random Forest, SVM, and Logistic Regression, are effective in predicting critical risk factors for neonatal sepsis, allowing for earlier and more precise clinical interventions, which can significantly improve clinical outcomes in vulnerable neonates. **Final considerations:** This review highlights the impact of AI models in predicting neonatal sepsis, demonstrating their potential for early clinical interventions. However, future research should focus on external validation and the careful integration of these models into clinical practice.

Keywords: Artificial Intelligence, Infant Newborn, Neonatal Sepsis.

RESUMEN

Objetivo: Identificar enfoques y la eficacia de la Inteligencia Artificial (IA) en la predicción de factores de riesgo para la sepsis neonatal. **Métodos:** Se trata de una revisión integradora realizada en las bases de datos PubMed, Scopus, Web of Science e IEEE, utilizando los siguientes descriptores: "neonatal sepsis", "intensive care units, neonatal", "artificial intelligence", "machine learning" y "deep learning". Se incluyeron estudios publicados entre 2014 y 2024 que incluyeron sepsis neonatal en unidades de cuidados intensivos.

Resultados: La muestra final consistió en 06 artículos, con una mayor concentración de publicaciones en 2021. La mayoría de los estudios se realizaron en EE.UU., y los diseños de investigación predominantes fueron estudios de cohorte retrospectiva. Se encontró que los modelos de IA, como Random Forest, SVM y Regresión Logística, son eficaces en la predicción de factores de riesgo críticos para la sepsis neonatal, lo que permite intervenciones clínicas más tempranas y precisas, lo que puede mejorar significativamente los resultados clínicos en neonatos vulnerables. **Consideraciones finales:** Esta revisión destaca el impacto de los modelos de IA en la predicción de la sepsis neonatal, demostrando su potencial para intervenciones clínicas anticipadas. Sin embargo, futuras investigaciones deben centrarse en la validación externa y en la cuidadosa integración de estos modelos en la práctica clínica.

Palabras clave: Inteligencia Artificial, Recién Nacido, Sepsis Neonatal.

INTRODUÇÃO

A sepse neonatal constitui uma condição clínica de extrema gravidade, caracterizada pela presença de infecção sistêmica em recém-nascidos, resultante da colonização por bactérias, vírus ou fungos (RUSSELL N, et al., 2024). Esta síndrome clínica é reconhecida como uma das principais causas de mortalidade neonatal em escala global, com incidência estimada entre 4 a 22 casos para cada 1000 nascidos vivos (DONG Y, et al., 2019). A prevalência da sepse neonatal é particularmente elevada em países de baixa e média renda, onde é responsável por aproximadamente 30-40% dos óbitos neonatais (SHANE AL, et al., 2017). No contexto brasileiro, a sepse está associada a 60% das mortes infantis ocorridas no período neonatal, evidenciando a importância de intervenções precoces para a sobrevivência dos neonatos (OLIVEIRA SG, et al., 2020).

Classificada em dois subtipos principais, a sepse neonatal inclui a sepse de início precoce (EOS) e a sepse de início tardio (LOS), diferenciados pelo momento de apresentação clínica (WYNN JL, 2016). A EOS manifesta-se nas primeiras 72 horas de vida e, frequentemente, resulta da transmissão vertical de patógenos da mãe para o recém-nascido durante o parto. Entre os patógenos mais comuns na EOS, destacam-se o *estreptococo* do grupo B (GBS), *Escherichia coli* e *Listeria monocytogenes*. Fatores maternos, como corioamnionite, colonização por GBS, parto prematuro e ruptura prolongada das membranas, são amplamente reconhecidos como determinantes do risco para o desenvolvimento de EOS (CAMARGO JF, et al., 2022).

Em contraste, a LOS ocorre após 72 horas de vida e é predominantemente adquirida por transmissão horizontal a partir do ambiente que circunda o neonato, frequentemente envolvendo o contato com profissionais de saúde ou cuidadores (PUOPOLO KM, et al., 2018). A LOS é associada ao uso prolongado de dispositivos invasivos, como cateteres intravasculares e tubos endotraqueais, que são frequentemente

necessários em neonatos prematuros ou em recém-nascidos com condições clínicas graves que exigem cuidados intensivos prolongados. A vulnerabilidade dos neonatos prematuros à LOS é agravada pela imaturidade de seu sistema imunológico, que se caracteriza por uma resposta inflamatória deficiente e uma produção inadequada de imunoglobulinas (COGGINS SA, et al., 2022).

A suscetibilidade dos neonatos à sepse está intimamente ligada à imaturidade do sistema imunológico, especialmente em casos de prematuridade extrema e baixo peso ao nascer. Essas crianças apresentam uma função comprometida dos neutrófilos, macrófagos e linfócitos T, o que resulta em uma resposta inflamatória ineficaz frente à presença de patógenos. Além disso, a transferência insuficiente de imunoglobulinas da mãe para o feto, particularmente em prematuros, aumenta consideravelmente o risco de infecção. Estes fatores tornam a sepse neonatal uma condição com alta taxa de morbidade e mortalidade, demandando estratégias diagnósticas e terapêuticas eficientes para mitigar seu impacto na saúde neonatal (RAYMOND SL, et al., 2017; DELANEY RM, et al., 2019).

Considerando essa complexidade e a necessidade de intervenções precisas e tempestivas, surge a aplicação da inteligência artificial (IA) como uma abordagem promissora na medicina moderna. A IA tem demonstrado potencial para transformar significativamente a abordagem ao diagnóstico e tratamento de diversas condições clínicas, incluindo a sepse neonatal (GIANNINI HM, 2019).

Modelos de IA, como algoritmos de aprendizado de máquina, são capazes de analisar grandes volumes de dados clínicos, identificando padrões complexos que poderiam passar despercebidos em análises tradicionais. Esse aspecto é especialmente relevante na predição de sepse neonatal, onde a identificação precoce dos fatores de risco pode ser crucial para a implementação de intervenções eficazes, com o objetivo de reduzir a mortalidade e a morbidade associadas à condição (REYNA MA, et al., 2019).

A aplicação de IA na predição de sepse neonatal se baseia na utilização de dados clínicos e laboratoriais, incluindo sinais vitais, características demográficas, histórico médico materno, e resultados de exames laboratoriais (SAHU P, et al., 2022). Algoritmos de aprendizado de máquina, como redes neurais artificiais, árvores de decisão e modelos de regressão, têm sido treinados para reconhecer padrões de risco em neonatos, fornecendo previsões que podem guiar as decisões clínicas. Estudos têm demonstrado que esses modelos podem alcançar altos níveis de sensibilidade e especificidade, superando abordagens convencionais na detecção precoce de sepse, o que pode resultar em intervenções mais rápidas e precisas (MANI S, et al., 2014; BURDICK H, et al., 2020).

Apesar dos avanços promissores, a implementação ampla de IA na predição de sepse neonatal ainda enfrenta desafios significativos. A variabilidade dos dados entre diferentes populações de neonatos, a necessidade de validação externa dos modelos em contextos clínicos diversos, e questões éticas relacionadas à transparência e interpretabilidade dos algoritmos são alguns dos obstáculos que precisam ser superados. Este contexto realça a importância de continuar a explorar e validar essas abordagens, evidenciando uma lacuna na literatura sobre a eficácia comparativa das diferentes técnicas de IA aplicadas à predição de sepse neonatal. Deste modo, o objetivo deste estudo é identificar abordagens e eficácia da Inteligência Artificial (IA) na predição de fatores de risco para sepse neonatal.

MÉTODOS

Para o presente estudo, foi adotada a metodologia de revisão integrativa da literatura, uma abordagem que permite a síntese de conhecimentos existentes e a análise crítica de múltiplos estudos primários sobre um determinado tema. Este método é particularmente útil para reunir e avaliar as evidências disponíveis, identificando lacunas no conhecimento e apontando direções para futuras pesquisas (SOUZA MT, et al., 2010).

A revisão integrativa foi escolhida por sua capacidade de fornecer uma visão abrangente sobre o estado atual das pesquisas em torno da aplicação de Inteligência Artificial (IA) na predição de fatores de risco para sepse neonatal, apoiando o desenvolvimento de práticas baseadas em evidências robustas.

O processo de revisão foi conduzido seguindo um protocolo metodológico rigoroso, dividido em várias etapas: 1) Definição clara da pergunta de pesquisa e dos objetivos específicos do estudo; 2) Estabelecimento de critérios de inclusão e exclusão para a seleção dos artigos a serem analisados; 3) Realização de uma busca sistemática em bases de dados científicas relevantes; 4) Seleção dos estudos encontrados e avaliação crítica da qualidade metodológica de cada um, seguida pela extração das informações pertinentes; 5) Análise detalhada e interpretação dos dados obtidos; 6) Síntese das conclusões com base nas evidências coletadas, discutindo suas implicações teóricas e práticas (SOUZA MT, et al., 2010).

Para orientar esta revisão, foi aplicada a estrutura metodológica PICOC, ajustada para refletir os objetivos específicos do estudo. O "P" (População) foca em neonatos, tanto a termo quanto prematuros, que representam a população em risco para o desenvolvimento de sepse neonatal.

O "I" (Intervenção) refere-se à aplicação de tecnologias de IA para a predição de fatores de risco para sepse neonatal, analisando como esses modelos podem melhorar a acurácia na identificação precoce de neonatos em risco.

O "C" (Comparação) neste contexto não é aplicável diretamente, pois o foco do estudo está em explorar as abordagens existentes de IA em vez de compará-las com outros métodos.

O "O" (Outcomes) aborda a eficácia das intervenções baseadas em IA em prever sepse neonatal, incluindo a avaliação de medidas como sensibilidade, especificidade e precisão preditiva dos modelos. Finalmente, o "C" (Contexto) examina o ambiente clínico no qual os dados foram coletados e as tecnologias de IA aplicadas, considerando variáveis como a infraestrutura hospitalar, práticas clínicas padrão e a experiência da equipe de saúde com o uso de tecnologias avançadas, fatores que podem influenciar significativamente os resultados obtidos.

Com base nessa estruturação, a pergunta de pesquisa central foi definida como: "Quais as principais abordagens e eficácia da IA na predição de fatores de risco para sepse neonatal, por meio de evidências na literatura científica?".

Assim, os critérios de inclusão estabelecidos foram: artigos completos disponíveis em qualquer idioma, estudos publicados entre janeiro de 2014 e julho de 2024, que incluam sepse neonatal em unidades de terapia intensiva; coortes caso-controlado – estudos prospectivos/retrospectivos que devem ser positivos e negativos em termos de cultura; modelos de aprendizado de máquina e aprendizado profundo incorporados para seleção de características e geração de modelos preditivos; e validação de modelos desenvolvidos dentro do conjunto de dados ou generalizados.

Por sua vez, foram excluídos artigos sem análise estatística, estudos que não utilizem algoritmos específicos de IA como aprendizado de máquina e aprendizado profundo, e aqueles que não apresentem parâmetros de desempenho, como a Área sob a curva operatória do receptor (AUROC).

Além disso, foram excluídos artigos de opinião, estudos duplicados nas bases de dados, revisões de literatura (narrativas, scoping, integrativas, sistemáticas e meta-análises), artigos editoriais, dissertações, teses e quaisquer publicações que não estivessem diretamente alinhadas com o objetivo principal desta investigação.

Para a identificação dos estudos primários, foram selecionadas quatro bases de dados relevantes na área médica: National Institute of Medicine (NIH-PubMed), Scopus, Web of Science e IEEE Xplore. O levantamento bibliográfico foi conduzido entre maio e julho de 2024.

Os componentes do acrônimo PICOC foram combinados utilizando descritores controlados específicos, com base nos termos do Medical Subject Headings (MeSH). Os descritores utilizados foram: "neonatal sepsis", "intensive care units, neonatal", "artificial intelligence", "machine learning" e "deep learning". A estratégia de busca foi refinada através do uso de operadores booleanos "AND" e "OR", permitindo a criação de combinações precisas para cada base de dados, assegurando uma pesquisa abrangente e direcionada. As combinações detalhadas dos descritores estão apresentadas no **Quadro 1**.

Quadro 1 - Estratégias de busca nas bases de dados.

Base de dados (artigos recuperados)	Estratégia de busca
PubMed (56)	("neonatal sepsis"[MeSH Terms] OR "intensive care units, neonatal"[All Fields]) AND ("artificial intelligence"[MeSH Terms] OR "artificial intelligence"[All Fields] OR "machine learning"[All Fields] OR "deep learning"[All Fields])
IEEE Xplore (51)	("All Metadata": "neonatal sepsis") AND ("All Metadata": "intensive care units, neonatal") AND ("All Metadata": ("artificial intelligence" OR "machine learning" OR "deep learning"))
Scopus (48)	TITLE-ABS-KEY ("neonatal sepsis" AND "intensive care units, neonatal" AND ("artificial intelligence" OR "machine learning" OR "deep learning"))
Web of Science (31)	TS=("neonatal sepsis" AND "intensive care units, neonatal" AND ("artificial intelligence" OR "machine learning" OR "deep learning"))

Fonte: Bernardino PA, et al., 2024.

Os artigos selecionados para esta revisão passaram por uma avaliação criteriosa conduzida por uma equipe de revisores independentes, que seguiram rigorosamente os critérios de inclusão e exclusão previamente definidos.

Na fase inicial, os revisores examinaram os títulos e resumos dos estudos utilizando uma plataforma digital especializada, onde registraram suas decisões preliminares. A concordância entre os revisores foi avaliada utilizando o coeficiente Kappa, que atingiu um valor de 0,91, indicando alta confiabilidade e substancial concordância no processo de seleção (MCHUGH ML, 2012).

Discrepâncias identificadas nesta etapa foram discutidas e resolvidas em reuniões conjuntas, garantindo que todos os critérios fossem devidamente considerados. Os artigos aprovados nesta triagem inicial foram organizados e catalogados com o auxílio do software de gerenciamento de referências EndNote (versão XII - Desktop), facilitando a organização e recuperação das informações durante o processo de revisão.

Para garantir um processo rigoroso de coleta e análise dos dados, foi estabelecido um protocolo detalhado que incluiu a identificação completa dos artigos, abrangendo informações como título, autores, revista, ano de publicação, país de origem, índice de impacto de acordo com o *Journal Citation Reports* (JCR), classificação no Qualis Capes para o período 2017-2020, e a base de dados onde o estudo foi localizado. Além disso, foram documentadas as características metodológicas de cada estudo, incluindo o tipo de estudo, nível de evidência, a população estudada, os fatores preditivos identificados e os principais resultados obtidos.

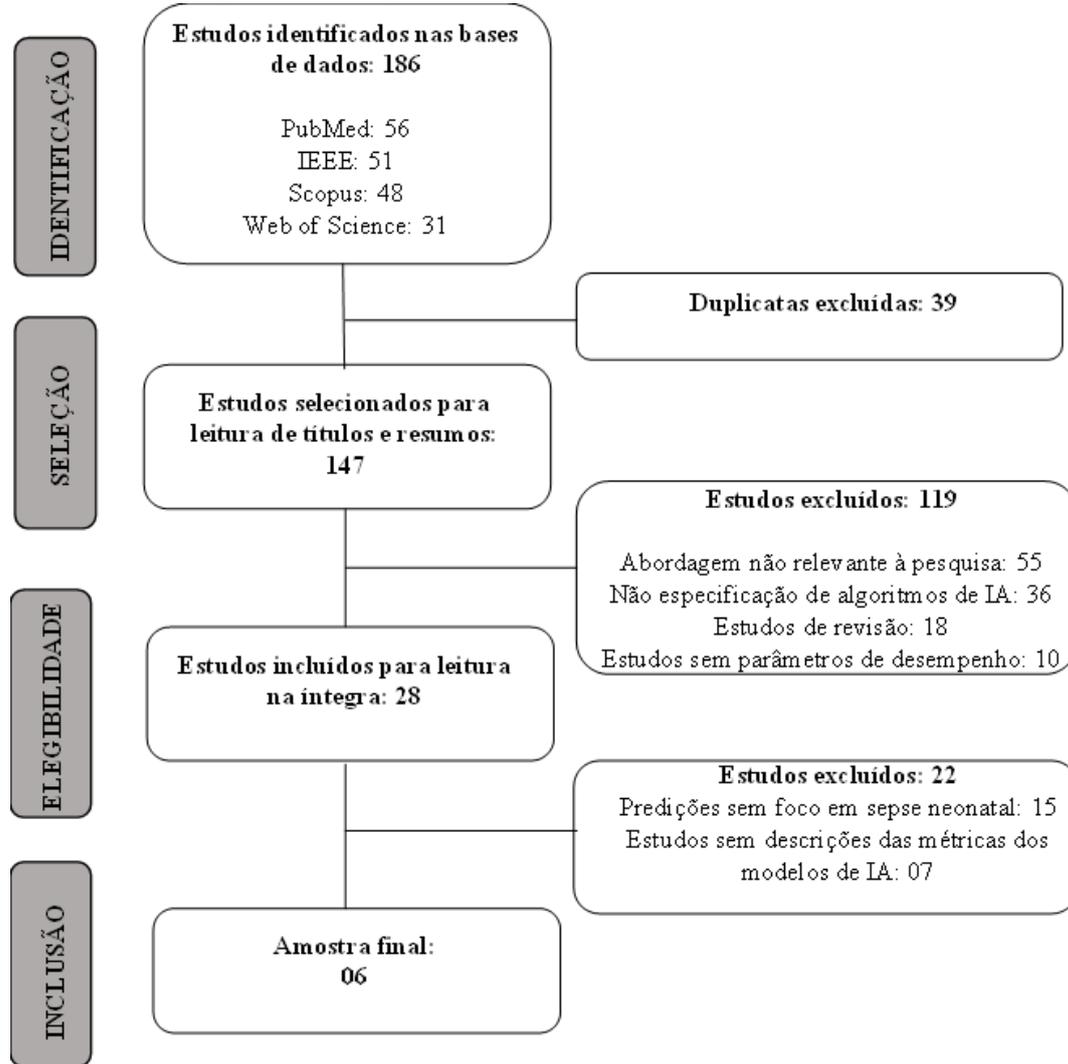
Na busca inicial realizada nas bases de dados selecionadas, foram identificados 186 artigos científicos. Desses, 39 estavam duplicados e foram contabilizados apenas uma vez, resultando em 147 artigos para uma análise inicial baseada em títulos e resumos.

Após essa triagem preliminar, 55 artigos foram excluídos por não estarem diretamente relacionados ao tema central da pesquisa, 36 estudos foram excluídos por não utilizarem algoritmos de aprendizado de máquina ou aprendizado profundo, 18 estudos foram removidos por se tratarem de revisões literárias de diversos tipos e 10 por não apresentarem parâmetros de desempenho, como a Área sob a curva operatória do receptor (AUROC).

Dos 28 artigos restantes, submetidos a uma avaliação detalhada do texto completo, 15 foram excluídos por se concentrarem em predições de complicações gerais em neonatos ou outras condições clínicas, sem um foco exclusivo na sepse neonatal. Além disso, sete estudos foram descartados por não apresentarem descrições claras das métricas dos modelos de IA utilizados na predição de sepse neonatal.

Ao final, um total de 06 artigos foi incluído na revisão integrativa. O processo de seleção e exclusão dos artigos é ilustrado no fluxograma desenvolvido conforme as diretrizes do Preferred Reporting Items for Systematic reviews and Meta-Analyses (PRISMA), adaptado para revisões integrativas, como apresentado na **Figura 1**.

Figura 1 - Fluxograma do processo de seleção dos estudos.



Fonte: Bernardino PA, et al., 2024.

A seleção dos estudos incluídos nesta revisão foi realizada com base em um rigoroso modelo de Hierarquia de Evidências, amplamente reconhecido por sua eficácia em avaliar a qualidade e a confiabilidade das pesquisas. Esse modelo assegura que somente dados altamente relevantes e metodologicamente sólidos sejam utilizados para fundamentar práticas acadêmicas e clínicas (STILLWELL S, et al., 2010). Foram priorizados estudos de Nível I e II, como ensaios clínicos randomizados e meta-análises de alta qualidade, que fornecem evidências robustas para a prática clínica.

Além disso, estudos de Nível III e IV, incluindo coortes e estudos caso-controle, foram considerados por seu valor em fornecer dados observacionais significativos, embora com menor rigor metodológico, o que pode limitar a generalização dos resultados. Também foram analisados estudos classificados entre os Níveis V a VII, como relatos de casos, opiniões de especialistas e estudos descritivos, que, embora apresentem menor nível de evidência, oferecem insights valiosos e contribuem para preencher lacunas existentes na literatura (STILLWELL S, et al., 2010).

Adicionalmente, esta revisão seguiu rigorosamente os princípios éticos em todas as etapas do processo. Foi assegurada a devida atribuição de crédito aos autores dos estudos analisados e a conformidade com as normas internacionais de direitos autorais e boas práticas em pesquisa. Esses cuidados refletem o compromisso com a integridade acadêmica e o respeito pela construção contínua do conhecimento científico (BRASIL, 1998).

RESULTADOS

Nesta revisão, um total de 06 estudos foi meticulosamente selecionado para análise, conforme detalhado no **Quadro 2**. Observou-se uma concentração de publicações entre os anos de 2024 a 2022, com maior frequência em 2021, com dois estudos (ID04-05). Em termos geográficos, os EUA foi os país mais representado, com quatro publicações (ID01-04). A avaliação da qualidade dos periódicos revelou uma predominância de publicações nos estratos A1 a A4 segundo a classificação da CAPES, destacando-se o "Journal of the American Medical Informatics Association" pelo seu notável fator de impacto de 7.942. Os estudos predominaram no design de coorte retrospectivo, atribuídos com um nível de evidência III, focando no desenvolvimento e validação de modelos preditivos para a sepse neonatal através de técnicas de aprendizado de máquina, utilizando uma variedade de dados clínicos e laboratoriais.

Quadro 2 - Caracterização geral dos artigos da amostra final.

ID	Autoria/ano	País	Periódico (Qualis – JCR)	Design do estudo (NE*)	Objetivos
01	Mani S, et al., 2014	EUA	Journal of the American Medical Informatics Association (A1 – 7.942)	Coorte retrospectivo (III)	Desenvolver modelos preditivos não invasivos para sepse neonatal tardia a partir de dados médicos prontos para uso e prontuários médicos eletrônicos (EMR).
01	Bartz-Kurycki MA, et al., 2018	EUA	The American Journal of Surgery (A2 - 2.7)	Coorte retrospectivo (III)	Determinar quais características clínicas e do paciente estavam associadas com infecção de sitio cirúrgico e desenvolver o modelo mais preciso para prever essas infecções.
03	Masino AJ, et al., 2019	EUA	PLoS One (A1 – 3.730)	Caso-controle retrospectivo (III)	Desenvolver um modelo usando dados de prontuário eletrônico capaz de reconhecer a sepse infantil pelo menos 4 horas antes do reconhecimento clínico.
04	Huang B, et al., 2021	EUA	International journal of laboratory hematology (A4 – 3.450)	Coorte retrospectivo (III)	Desenvolver um modelo de aprendizado de máquina para identificação de sepse bacteriana na unidade de terapia intensiva neonatal usando dados do analisador hematológico.
05	Cabrera-Quiros L, et al., 2021	Países Baixos	Critical care explorations (2.0)	Coorte retrospectivo (III)	Previsão de sepse de início tardio (início após o terceiro dia de vida) em bebês prematuros, com base em múltiplos sinais de monitoramento do paciente 24 horas antes do início.
06	Sokou R, et al., 2022	Itália	Frontiers in pediatrics (A2 – 3.6)	Coorte retrospectivo (III)	Desenvolver e validar um modelo diagnóstico para sepse entre neonatos avaliados por suspeita de sepse.

Nota: NE* - Nível de evidência. **Fonte:** Bernardino PA, et al., 2024.

Conforme demonstrado no **Quadro 3**, esta revisão integra informações de seis estudos que exploram a aplicação de modelos de IA na predição de fatores de risco para sepse neonatal, abrangendo uma amostra diversificada de neonatos em unidades de terapia intensiva (N total: 17.218).

A análise dos estudos revela a utilização de uma variedade de algoritmos de IA, como Random Forest, Support Vector Machine (SVM), e Regressão Logística, que foram aplicados a diferentes conjuntos de dados clínicos e laboratoriais. Entre os fatores de risco preditivos identificados, destacam-se parâmetros como hematócrito baixo, presença de corioamnionite materna, frequência respiratória elevada, variabilidade da frequência cardíaca e amplitude da firmeza do coágulo, refletindo a complexidade e multifatoriedade da sepse neonatal.

Os resultados principais desses estudos indicam que os modelos de IA foram capazes de superar a acurácia diagnóstica dos métodos tradicionais em vários cenários clínicos, com destaque para a capacidade de identificar a sepse horas antes da manifestação clínica. Em particular, o NeoSeD Score (ID06) apresentou excelente capacidade discriminatória para sepse e choque séptico, com AUC de até 0,974, superando outras escalas diagnósticas como Töllner e nSOFA. Outros modelos, como o Random Forest e SVM, também demonstraram alta eficácia, com valores de AUC variando de 0,68 a 0,74 em diferentes estudos. Estes achados sublinham o potencial dos modelos de IA como ferramentas robustas para a predição precoce da sepse neonatal, permitindo intervenções mais rápidas e precisas, o que pode melhorar significativamente os desfechos clínicos nesses pacientes vulneráveis.

Quadro 3 – Características dos estudos e eficácia dos modelos de IA na predição de fatores de risco para sepse neonatal.

ID	População do estudo	Modelos de IA utilizados	Fatores de risco identificados	Principais resultados
01	299 neonatos	Naive Bayes (NB), Random Forest (RF), Vector Machine (SVM), K-Nearest Neighbors (KNN) e Regressão Logística	Hematócrito baixo, presença de corioamnionite materna, frequência respiratória elevada, histórico de infecção, prematuridade, baixo peso ao nascer, e necessidade de suporte respiratório.	NB e RF superaram os médicos com 95% e 94% de sensibilidade, respectivamente, e 47% de especificidade na detecção de sepse tardia. Modelos de IA foram mais eficazes do que médicos na detecção precoce e redução de tratamentos desnecessários.
02	13.589 neonatos	Random Forest Classifier (RFC), Regressão Logística Múltipla	Tempo operatório prolongado, idade avançada na cirurgia, diálise pré-operatória, choque séptico pré-operatório, classe de ferida contaminada, peso baixo na cirurgia.	RFC apresentou AUC de 0,68 na validação, superando outros modelos. O modelo híbrido teve AUC de 0,67 e menor complexidade com 18 variáveis significativas.
03	618 neonatos	Support Vector Machine (SVM), AdaBoost, K-Nearest Neighbors (KNN), Regressão Logística	Pressão arterial diastólica, pressão arterial média, frequência cardíaca, variação da frequência cardíaca, pressão arterial sistólica, temperatura corporal.	SVM apresentou o melhor desempenho no conjunto CPOly. Modelos de IA identificaram sepse até 4 horas antes da detecção clínica com AUC superior aos modelos tradicionais.
04	2.357 neonatos	K-Nearest Neighbors (KNN), Regressão Logística, Random Forest (RF), XGBoost	Valores alterados de neutrófilos foram os mais importantes na detecção de sepse, refletindo a resposta inflamatória sistêmica. Fatores clínicos adicionais incluíram sinais vitais e histórico de infecções.	RF, Regressão Logística e XGBoost tiveram o melhor desempenho. Modelos com dados hematológicos superaram os que usaram apenas características clínicas, com AUC-ROC de até 0,74 e especificidade de 0,88.
05	64 neonatos prematuros (32 com sepse, 32 controles)	Regressão Logística, Naive Bayes, Nearest Mean Classifier	Variabilidade da frequência cardíaca, padrões respiratórios anormais, movimento corporal reduzido. Sinais monitorados mostraram diferenças significativas até 5 horas antes do início da sepse.	Modelos previram sepse tardia com precisão média de 0,79 e taxa de precisão de 0,82, até 3 horas antes da manifestação clínica.
06	291 neonatos	Regressão Logística com LASSO (NeoSeD Score)	Amplitude da firmeza do coágulo aos 10 minutos (EXTEM A10), idade gestacional, PCR elevada, mudança significativa na coloração da pele, aumento do fígado, desvio à esquerda dos neutrófilos.	O NeoSeD Score apresentou excelente capacidade discriminatória para sepse e choque séptico com AUC de 0,918 e 0,974, respectivamente, superando as pontuações Töllner e nSOFA.

Fonte: Bernardino PA, et al., 2024.

DISCUSSÃO

Esta revisão focou na análise das abordagens de IA para a predição de sepse neonatal, uma condição crítica e desafiadora que continua a ser uma das principais causas de mortalidade entre recém-nascidos em unidades de terapia intensiva neonatal. Identificar com precisão os fatores de risco para a sepse neonatal é essencial para intervenções precoces que possam melhorar significativamente os desfechos clínicos. A sepse neonatal é influenciada por uma combinação complexa de fatores, que variam desde parâmetros clínicos, como variabilidade da frequência cardíaca e valores hematológicos, até características maternas e condições pré-existent no neonato.

Os modelos de IA analisados nesta revisão demonstram a capacidade de integrar esses múltiplos fatores em sistemas preditivos avançados, oferecendo uma abordagem mais detalhada e precisa para a detecção precoce da sepse. Estes sistemas têm o potencial de revolucionar o manejo clínico em neonatologia, permitindo intervenções mais rápidas e baseadas em dados robustos, que podem ser adaptadas ao perfil de risco individual de cada paciente (CABRERA-QUIROS L, et al., 2021; SOKOU R, et al., 2022).

À luz dos resultados desta revisão, observa-se que os modelos de IA aplicados à predição de sepse neonatal têm demonstrado significativa eficácia na identificação precoce dessa condição crítica, abordando um problema de extrema relevância para a saúde neonatal. Os seis estudos analisados utilizaram uma variedade de algoritmos de IA, como Random Forest, Support Vector Machine (SVM), Regressão Logística e outros, cada um contribuindo para a melhoria da acurácia diagnóstica em diferentes contextos clínicos.

A eficácia desses modelos está diretamente relacionada à sua capacidade de integrar e analisar múltiplos fatores de risco, que variam desde parâmetros laboratoriais, como valores alterados de neutrófilos e amplitude da firmeza do coágulo, até características clínicas, como presença de corioamnionite materna e variabilidade da frequência cardíaca (MANI S, et al., 2014; BARTZ-KURYCKI MA, et al., 2018; MASINO AJ, et al., 2019; HUANG B, et al., 2021; CABRERA-QUIROS L, et al., 2021; SOKOU R, et al., 2022). Esses fatores são críticos na detecção precoce da sepse, refletindo a complexidade e multifatorialidade da resposta inflamatória neonatal (TANERI PE, et al., 2024).

Os algoritmos de IA, como o Random Forest e o SVM, apresentam vantagens notáveis, incluindo a capacidade de lidar com grandes volumes de dados e identificar padrões complexos que não são facilmente detectáveis por métodos tradicionais. O uso do Random Forest, por exemplo, é destacado por sua habilidade em manejar conjuntos de dados extensos e diversos, proporcionando uma precisão preditiva elevada. No entanto, uma limitação desse modelo é sua complexidade, que pode dificultar a interpretação dos resultados, especialmente em cenários clínicos onde a clareza e a justificativa das decisões são cruciais (LANGSETMO L, et al., 2023).

Por outro lado, a Regressão Logística, embora mais simples e de fácil interpretação, pode não capturar completamente as interações não lineares entre as variáveis, o que limita sua eficácia em situações mais complexas. Esses aspectos ressaltam a importância de selecionar cuidadosamente o modelo de IA mais adequado para cada contexto clínico (SCHOBBER P, et al., 2021).

Os principais fatores de risco identificados nos estudos analisados refletem a natureza complexa da sepse neonatal. Parâmetros como hematócrito baixo, presença de corioamnionite materna e variabilidade da frequência cardíaca surgiram repetidamente como preditores robustos. Esses achados corroboram a literatura existente, que já destacava a importância dessas variáveis na evolução clínica dos neonatos (MANI S, et al., 2014; HUANG B, et al., 2021; CABRERA-QUIROS L, et al., 2021; SOKOU R, et al., 2022).

Além disso, a inclusão de fatores como a amplitude da firmeza do coágulo (EXTEM A10) e níveis elevados de proteína C-reativa (PCR) nos modelos de predição evidencia a relevância da inflamação sistêmica e da coagulação na patogênese da sepse neonatal (HELGUERA-REPETTO AC, et al., 2020). A combinação desses fatores nos modelos de IA permite uma abordagem mais holística e precisa, melhorando significativamente a capacidade de predição e, conseqüentemente, a tomada de decisões clínicas (SOKOU R, et al., 2022).

A comparação dos resultados dos modelos de IA com os métodos tradicionais de diagnóstico revela que os primeiros não apenas superam os métodos clínicos em termos de sensibilidade e especificidade, mas também oferecem a possibilidade de intervenções mais rápidas. A capacidade de detectar sepse horas antes da manifestação clínica, como observado nos estudos de Mani S, et al. (2014) e Cabrera-Quiros L, et al. (2021), é um avanço significativo que pode transformar o manejo da sepse neonatal. Essa precocidade na detecção permite que intervenções sejam realizadas em um estágio onde a eficácia do tratamento pode ser maximizada, potencialmente reduzindo a mortalidade e as complicações associadas à sepse (SCHOBER P, et al., 2021).

Contudo, é crucial destacar que a generalização desses modelos para diferentes populações neonatais ainda enfrenta desafios. A variabilidade nos dados entre diferentes unidades de terapia intensiva, como diferenças nos protocolos de cuidado e nas características demográficas dos pacientes, pode influenciar o desempenho dos modelos de IA. A necessidade de validação externa desses modelos em populações diversas é fundamental para garantir sua aplicabilidade e eficácia em diferentes contextos clínicos. Uma revisão sistemática recente enfatiza a necessidade de validação multinacional para assegurar que os modelos preditivos sejam eficazes em uma ampla variedade de ambientes clínicos e demográficos (PARVIN S, et al., 2023).

Outro ponto a ser considerado é o impacto da implementação desses modelos na prática clínica. Embora os modelos de IA, como o *Neonatal Sepsis Diagnostic (NeoSeD) score*, implementado por Sokou R, et al. (2022) tenham demonstrado excelente capacidade discriminatória, sua adoção clínica em larga escala depende de fatores como custo, complexidade operacional e aceitação pelos profissionais de saúde. A integração desses modelos aos fluxos de trabalho clínicos diários deve ser feita de forma que não sobrecarregue os profissionais, mas sim que os auxilie na tomada de decisões críticas, proporcionando um suporte robusto e eficiente na detecção precoce da sepse neonatal. A implementação de ferramentas de IA deve ser vista como um complemento ao julgamento clínico, não como um substituto, para maximizar os benefícios no cuidado neonatal (VERSTRAETE EH, et al., 2015; FLEUREN LM, et al., 2020; PARVIN S, et al., 2023).

Além disso, é importante considerar as implicações éticas e legais associadas ao uso de IA na medicina. A transparência e a interpretabilidade dos modelos são aspectos fundamentais para garantir a confiança dos profissionais de saúde e a segurança dos pacientes. Modelos complexos, como o Random Forest, que podem ser considerados caixas-pretas, apresentam desafios nesse sentido, pois a falta de clareza na tomada de decisões pode gerar desconfiança e resistência por parte dos médicos. Portanto, a aplicação da IA na prática clínica deve ser acompanhada de diretrizes claras e de um esforço contínuo para aumentar a transparência dos processos algorítmicos (ALOWAIS SA, et al., 2023). Deste modo, os modelos de IA analisados nesta revisão apresentam um grande potencial para melhorar o manejo da sepse neonatal, oferecendo ferramentas preditivas mais precisas e permitindo intervenções precoces que podem salvar vidas. No entanto, a implementação eficaz desses modelos requer uma abordagem equilibrada que leve em conta tanto os benefícios quanto as limitações, garantindo que a IA seja integrada de forma segura e eficiente à prática clínica.

CONSIDERAÇÕES FINAIS

Esta revisão consolidou o impacto significativo dos modelos de IA na predição de sepse neonatal, destacando a eficácia de algoritmos como Random Forest, SVM e Regressão Logística na identificação precoce de fatores de risco críticos, como hematócrito baixo, corioamnionite materna e variabilidade da frequência cardíaca. Os modelos analisados demonstraram potencial notável para intervenções clínicas antecipadas, permitindo uma abordagem mais ágil e precisa no manejo de neonatos em risco. No entanto, é crucial que futuras pesquisas se concentrem na validação externa desses modelos em diferentes populações e contextos clínicos, assegurando sua aplicabilidade e robustez universal. Além disso, a integração desses modelos na prática clínica requer atenção cuidadosa às questões de transparência, interpretabilidade e aceitação por parte dos profissionais de saúde, a fim de maximizar os benefícios dessas ferramentas tecnológicas no cuidado neonatal.

REFERÊNCIAS

1. ALOWAIS AS, et al. Revolutionizing healthcare: the role of artificial intelligence in clinical practice. *BMC Med Educ.*, 2023; 23(1): 689.
2. BARTZ-KURYCKI MA, et al. Enhanced neonatal surgical site infection prediction model utilizing statistically and clinically significant variables in combination with a machine learning algorithm. *Am. J. Surg.*, 2018; 216: 764-77.
3. BRASIL. Ministério da Saúde (MS). Lei no 9.610, de 19 de fevereiro de 1998, que altera, atualiza e consolida a legislação sobre direitos autorais e dá outras providências. *Diário Oficial da União*. Brasília: Ministério da Saúde, 1998.
4. BOETTIGER M, et al. Nurses' early recognition of neonatal sepsis. *J Obstet Gynecol Neonatal Nurs.*, 2017; 46(6): 834-845.
5. BURDICK H, et al. Validation of a machine learning algorithm for early severe sepsis prediction: a retrospective study predicting severe sepsis up to 48 h in advance using a diverse dataset from 461 US hospitals. *BMC Med. Inform. Decis. Mak.*, 2020; 20: 1-10.
6. CABRERA-QUIROS L, et al. Prediction of Late-Onset Sepsis in Preterm Infants Using Monitoring Signals and Machine Learning. *Crit Care Explor.*, 2021; 3(1): e0302.
7. CAMARGO JF, et al. Sepsis neonatal precoce: prevalência, complicações e desfechos em recém-nascidos com 35 semanas ou mais de idade gestacional. *Rev. paul. Pediatr.*, 2022; 40: e2020388.
8. COGGINS SA, et al. Updates in Late-Onset Sepsis: Risk Assessment, Therapy, and Outcomes. *Neoreviews*, 2022; 23(11): 738-755.
9. DELANEY RM, et al. The immune system. In: Jnah AJ, Trembath AN, eds. *Fetal and Neonatal Physiology for the Advanced Practice Nurse*. New York, NY: Springer Publishing Company, 2019; 267-306.
10. DONG Y, et al. Late-onset sepsis caused by gram-negative bacteria in very low birthweight infants: a systematic review. *Expert Rev Anti Infect Ther.*, 2019; 17(3): 177-88.
11. FLEUREN LM, et al. Machine learning for the prediction of sepsis: A systematic review and meta-analysis of diagnostic test accuracy. *Intensive Care Med.*, 2020; 46:383-400.
12. GIANNINI HM. A machine learning algorithm to predict severe sepsis and septic shock: Development, implementation, and impact on clinical practice. *Crit. Care Med.*, 2019; 47: 1485-92.
13. HELGUERA-REPETTO AC, et al. Neonatal sepsis diagnosis decision-making based on artificial neural networks. *Front Pediatr.*, 2020; 8: 525.
14. HUANG B, et al. Aiding clinical assessment of neonatal sepsis using hematological analyzer data with machine learning techniques. *Int J Lab Hematol.*, 2021; 43(6): 1341-56.
15. LANGSETMO L, et al. Advantages and Disadvantages of Random Forest Models for Prediction of Hip Fracture Risk Versus Mortality Risk in the Oldest Old. *JBMR Plus*, 2023; 7(8): e10757.
16. OLIVEIRA SG, et al. Sepsis bacteriana do recém-nascido no Brasil nos anos de 2013 a 2017. *Brazilian Journal of Health Review*, 2017; 3(2): 1404-1421.
17. MANI S, et al. Medical decision support using machine learning for early detection of late-onset neonatal sepsis. *J. Am. Med. Inform. Assoc.*, 2014; 21: 326-36.
18. MASINO AJ, et al. Machine learning models for early sepsis recognition in the neonatal intensive care unit using readily available electronic health record data. *PLoS One*, 2019; 14(2): e0212665.
19. MCHUGH ML. Interrater reliability: the kappa statistic. *Biochemia Medica*, 2012; 22(3): 276-82.
20. PARVIN S, et al. Analysis of machine learning and deep learning prediction models for sepsis and neonatal sepsis: A systematic review. *ICT Express*, 2023; 9(6): 1215-25.
21. PUOPOLO KM, et al. Management of neonates born at ≥ 35 0/7 weeks' gestation with suspected or proven early-onset bacterial sepsis. *Pediatrics*, 2018; 142(6): e20182894.
22. RAYMOND SL, et al. Immunological Defects in Neonatal Sepsis and Potential Therapeutic Approaches. *Front Pediatr.*, 2017; 5: 14.
23. REYNA MA, et al. Early prediction of sepsis from clinical data: The PhysioNet/Computing in cardiology challenge 2019. *Crit. Care Med.*, 2019; 210-17.
24. RUSSELL N, et al. Early-versus late-onset sepsis in neonates - time to shift the paradigm? *Clin Microbiol Infect.*, 2024; 30(1): 38-43.
25. SCHOBBER P, et al. Logistic Regression in Medical Research. *Anesth Analg.*, 2021; 132(2): 365-366.
26. SAHU P, et al. Prediction modelling in the early detection of neonatal sepsis. *World J. Pediatr.*, 2022; 18: 160-75.
27. SHANE AL, et al. Neonatal sepsis. *Lancet*, 2017; 390(10104): 1770-80.
28. SOUZA MT, et al. Integrative review: what is it? How to do it? *Einstein*, 2010; 8(1): 102-6.
29. SOKOU R, et al. Development and validation of a sepsis diagnostic scoring model for neonates with suspected sepsis. *Front Pediatr.*, 2022; 10: 1004727.
30. STILLWELL S, et al. Evidence-based practice: step by step. *Am J Nurs*, 2010; 110(5): 41-7.
31. TANERI PE, et al. Outcomes of interventions in neonatal sepsis: A systematic review of qualitative research. *Int J Gynaecol Obstet.*, 2024.
32. VERSTRAETE EH, et al. Prediction models for neonatal health care-associated sepsis: A meta-analysis. *Pediatrics*, 2015; 135: e1002-e1014.
33. WYNN JL. Defining neonatal sepsis. *Curr Opin Pediatr.*, 2016; 28(2): 135-40.