REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

APLICAÇÕES DA INTELIGÊNCIA ARTIFICIAL (IA) NA NEONATOLOGIA: POTENCIAL NO DIAGNÓSTICO PRECOCE E NA TOMADA DE DECISÃO CLÍNICA

APPLICATIONS OF ARTIFICIAL INTELLIGENCE (AI) IN NEONATOLOGY: POTENTIAL FOR EARLY DIAGNOSIS AND CLINICAL DECISION-MAKING

APLICACIONES DE LA INTELIGENCIA ARTIFICIAL (IA) EN NEONATOLOGÍA: POTENCIAL PARA EL DIAGNÓSTICO PRECOZ Y LA TOMA DE DECISIONES CLÍNICAS.

Renata Alves Velasque Negri
Médica Pediatra e residente em Neonatologia, Hospital universitário Maria Aparecida Pedrossian (HUMAP), Brasil.
E-mail: renataa.velasque@gmail.com

Keila Maria Lima Miguel Lorenzi
Médica Neonatologista, Hospital universitário Maria Aparecida Pedrossian (HUMAP), Brasil.
E-mail: keilalorenzi@terra.com.br

Resumo

A Inteligência Artificial (IA) apresenta crescente aplicação na assistência neonatal, especialmente diante da necessidade de identificação precoce de alterações clínicas e análise de grandes volumes de dados. Este estudo teve como objetivo analisar as aplicações da IA na neonatologia, com ênfase em seu potencial para o diagnóstico precoce e o apoio à tomada de decisão clínica. Realizou-se uma revisão integrativa da literatura, com buscas entre junho e agosto de 2026 nas bases PubMed/MEDLINE, Biblioteca Virtual em Saúde, Scopus, Web of Science e SciELO. Foram incluídos artigos originais publicados entre 2021 e 2026, totalizando 12 estudos na síntese final. As principais aplicações envolveram predição e identificação de sepse neonatal, enterocolite necrosante, retinopatia da prematuridade, displasia broncopulmonar e crises epilépticas, além de avaliação nutricional, interpretação de ultrassonografia pulmonar e estimativa de sobrevida e mortalidade. Predominaram técnicas de machine learning e deep learning, com resultados relevantes na identificação precoce de alterações clínicas, estratificação de risco e avaliação prognóstica. Entretanto, foram observadas limitações relacionadas ao tamanho amostral, estudos unicêntricos, uso de dados retrospectivos e ausência de validação externa ou prospectiva em parte dos modelos. Conclui-se que a IA apresenta potencial para complementar a assistência neonatal, contribuindo para a identificação precoce de riscos e o suporte à tomada de decisão clínica. Contudo, estudos multicêntricos e prospectivos são necessários para ampliar a validação dessas ferramentas antes de sua incorporação à prática assistencial, preservando a supervisão e o julgamento profissional.

Palavras-chave: Aprendizado de máquina; Recém-nascido; Diagnóstico precoce; Prognóstico;

CC BY

REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

Sistemas de apoio à decisão clínica.

Abstract

Artificial Intelligence (AI) has been increasingly applied in neonatal care, particularly given the need for early identification of clinical changes and analysis of large volumes of data. This study aimed to analyze the applications of AI in neonatology, emphasizing its potential for early diagnosis and clinical decision support. An integrative literature review was conducted, with searches performed between June and August 2026 in PubMed/MEDLINE, Virtual Health Library, Scopus, Web of Science, and SciELO. Original articles published between 2021 and 2026 were included, resulting in 12 studies in the final synthesis. The main applications involved the prediction and identification of neonatal sepsis, necrotizing enterocolitis, retinopathy of prematurity, bronchopulmonary dysplasia, and neonatal seizures, as well as nutritional assessment, lung ultrasound interpretation, and survival and mortality prediction. Machine learning and deep learning techniques predominated, showing relevant results in the early identification of clinical changes, risk stratification, and prognostic assessment. However, limitations included small sample sizes, single-center studies, retrospective data, and lack of external or prospective validation in some models. AI therefore shows potential to complement neonatal care by contributing to early risk identification and clinical decision support. Nevertheless, multicenter and prospective studies are needed to further validate these tools before their incorporation into clinical practice, while preserving professional supervision and clinical judgment.

Keywords: Machine learning; Infant, newborn; Early diagnosis; Prognosis; Clinical decision support systems.

Resumen

Incluya el resumen en inglés. La Inteligencia Artificial (IA) presenta una aplicación creciente en la atención neonatal, especialmente ante la necesidad de identificar precozmente alteraciones clínicas y analizar grandes volúmenes de datos. Este estudio tuvo como objetivo analizar las aplicaciones de la IA en neonatología, con énfasis en su potencial para el diagnóstico precoz y el apoyo a la toma de decisiones clínicas. Se realizó una revisión integrativa de la literatura, con búsquedas entre junio y agosto de 2026 en PubMed/MEDLINE, Biblioteca Virtual en Salud, Scopus, Web of Science y SciELO. Se incluyeron artículos originales publicados entre 2021 y 2026, con un total de 12 estudios en la síntesis final. Las principales aplicaciones incluyeron la predicción e identificación de sepsis neonatal, enterocolitis necrosante, retinopatía del prematuro, displasia broncopulmonar y crisis epilépticas, además de la evaluación nutricional, interpretación de ultrasonografía pulmonar y estimación de supervivencia y mortalidad. Predominaron técnicas de machine learning y deep learning, con resultados relevantes en la identificación precoz de alteraciones clínicas, estratificación del riesgo y evaluación pronóstica. Sin embargo, se observaron limitaciones relacionadas con el tamaño de las muestras, estudios unicéntricos, uso de datos retrospectivos y ausencia de validación externa o prospectiva en algunos modelos. Se concluye que la IA presenta potencial para complementar la

CC BY

REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

atención neonatal, contribuyendo a la identificación precoz de riesgos y al apoyo a la toma de decisiones clínicas. No obstante, se requieren estudios multicéntricos y prospectivos para ampliar la validación de estas herramientas antes de su incorporación a la práctica asistencial, preservando la supervisión y el juicio profesional.

Palabras clave: Aprendizaje automático; Recién nacido; Diagnóstico precoz; Pronóstico; Sistemas de apoyo a decisiones clínicas.

1. Introdução

A incorporação da Inteligência Artificial (IA) à prática médica tem sido acompanhada pela necessidade de estabelecer parâmetros para sua utilização segura, ética e responsável. O Conselho Federal de Medicina (CFM), por meio da Resolução nº 2.454/2026, normatizou o uso da IA na medicina, reconhecendo essas tecnologias como ferramentas de apoio à prática e à tomada de decisão clínica, sem substituir a autonomia e o julgamento profissional. A normativa estabelece que o médico permanece responsável pelas decisões clínicas, diagnósticas, terapêuticas e prognósticas, devendo avaliar criticamente as recomendações geradas pela IA e registrar em prontuário sua utilização como suporte à decisão. Também assegura ao paciente o direito de ser informado sobre o emprego dessas ferramentas em seu cuidado e determina que diagnósticos, prognósticos ou decisões terapêuticas não sejam comunicados por sistemas automatizados sem mediação humana. Além disso, a resolução estabelece diferentes categorias de risco para as aplicações de IA e prevê requisitos de governança, transparência, auditoria e monitoramento proporcionais ao seu potencial impacto. Dessa forma, a incorporação dessas tecnologias à assistência médica deve ocorrer sob supervisão humana, preservando a centralidade do cuidado, a segurança do paciente e a autonomia profissional (Conselho Federal de Medicina, 2026).

Nesse contexto, a aplicação da IA torna-se particularmente relevante em áreas de elevada complexidade assistencial, como a neonatologia. A assistência neonatal apresenta elevada complexidade, especialmente no cuidado de recém-nascidos prematuros e de baixo peso, mais vulneráveis a complicações e desfechos adversos. A prematuridade permanece entre os principais desafios para a saúde neonatal, estando associada a elevada morbidade e mortalidade e a

CC BY

REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

possíveis repercussões no desenvolvimento infantil (Ward et al., 2024; Liang et al., 2024). A identificação precoce de alterações clínicas e a avaliação individualizada do risco são fundamentais para direcionar intervenções oportunas e favorecer melhores desfechos.

Nas unidades de terapia intensiva neonatal (UTIN), a assistência envolve a avaliação contínua de informações provenientes de sinais vitais, exames laboratoriais, registros clínicos, imagens e monitoramento fisiológico. Alterações iniciais de algumas condições podem ser sutis ou pouco específicas, tornando seu reconhecimento precoce um desafio. O grande volume e a diversidade de dados clínicos e fisiológicos gerados durante o acompanhamento dos recém-nascidos podem ser utilizados na predição de desfechos e no desenvolvimento de ferramentas capazes de auxiliar a tomada de decisão clínica e o monitoramento neonatal (McAdams et al., 2022; Keles; Bagci, 2023).

Nesse cenário, a Inteligência Artificial (IA) destaca-se pela capacidade de processar grandes volumes de dados e identificar padrões relevantes para a avaliação clínica. Entre seus principais subcampos, está o machine learning, o qual utiliza algoritmos capazes de aprender a partir dos dados para realizar tarefas de classificação ou predição. O deep learning, por sua vez, constitui uma subárea do machine learning e emprega redes neurais com múltiplas camadas, permitindo reconhecer padrões complexos em dados clínicos, sinais fisiológicos e exames de imagem (Keles; Bagci, 2023).

Na neonatologia, a IA tem sido investigada no diagnóstico precoce, monitoramento clínico, predição de complicações e avaliação prognóstica, podendo auxiliar na identificação de recém-nascidos com maior risco de deterioração (Sullivan et al., 2024). Suas aplicações incluem condições como sepse, retinopatia da prematuridade e displasia broncopulmonar, além da análise de imagens e parâmetros fisiológicos (Husain et al., 2025). Dessa forma, seu potencial se estende à estratificação de risco, estimativa de desfechos e suporte à tomada de decisão clínica (Sullivan et al., 2024).

Apesar dos avanços, a incorporação da IA à assistência neonatal ainda enfrenta desafios relacionados à heterogeneidade dos modelos, à qualidade dos dados e à necessidade de validação em diferentes populações. Schouten et al.

CC BY

REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

(2024) destacam que muitos modelos permanecem em fases de desenvolvimento e validação, indicando uma lacuna entre o desempenho experimental e sua aplicação clínica. Diante disso, o presente estudo teve como objetivo analisar as aplicações da IA na neonatologia, com ênfase em seu potencial para o diagnóstico precoce e o apoio à tomada de decisão clínica.

2. Metodologia

2.1 Delineamento

O presente estudo caracteriza-se como uma revisão integrativa da literatura, desenvolvida com o propósito de reunir e sintetizar as evidências científicas disponíveis sobre as aplicações da IA na neonatologia, com ênfase em seu potencial para o diagnóstico precoce e o apoio à tomada de decisão clínica. Para sua realização, foram adotadas as seguintes etapas sistematizadas: a elaboração da pergunta norteadora, a definição dos critérios de elegibilidade, a busca nas bases de dados, a identificação e seleção dos estudos, a avaliação metodológica das publicações incluídas, a extração e organização das informações e, a análise e a síntese dos principais achados.

2.2 Questão norteadora

Para a elaboração da questão norteadora, utilizou-se a estratégia PCC, composta pelos elementos População, Conceito e Contexto, considerada adequada para estruturar perguntas amplas em revisões de literatura. Nessa estratégia, definiu-se como população (P) os recém-nascidos; como conceito (C), a aplicação da IA no diagnóstico precoce e no apoio à tomada de decisão clínica; e como contexto (C), a assistência neonatal nos diferentes níveis de atenção à saúde, incluindo as unidades de terapia intensiva neonatal. A partir dessa estrutura, formulou-se a seguinte pergunta norteadora: “Quais são as aplicações da IA no diagnóstico precoce e no apoio à tomada de decisão clínica em neonatologia?”.

2.3 Fontes de informação e período de busca

As buscas bibliográficas foram realizadas no período de junho a agosto de 2026, nas bases de dados PubMed/MEDLINE; Biblioteca Virtual em Saúde (BVS); Scopus; Web of Science; e SciELO. A seleção dessas fontes de informação teve como finalidade proporcionar ampla cobertura da produção científica nacional e

CC BY

REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

internacional relacionada às aplicações da IA na neonatologia, especialmente no diagnóstico precoce e no apoio à tomada de decisão clínica.

2.4 Estratégia de busca

A estratégia de busca foi elaborada exclusivamente com termos indexados, selecionados nos vocabulários DeCS e MeSH, nos idiomas português e inglês. Foram empregados os descritores: “Inteligência Artificial” / “Artificial Intelligence”, “Aprendizado de Máquina” / “Machine Learning”, “Aprendizado Profundo” / “Deep Learning”, “Recém-Nascido” / “Infant, Newborn”, “Neonatologia” / “Neonatology”, “Diagnóstico Precoce” / “Early Diagnosis”, “Tomada de Decisão Clínica” / “Clinical Decision-Making” e “Sistemas de Apoio a Decisões Clínicas” / “Decision Support Systems, Clinical”. Os descritores referentes a um mesmo componente temático foram combinados pelo operador booleano OR, enquanto os diferentes componentes foram relacionados pelo operador AND.

2.5 Critérios de elegibilidade

Foram incluídos artigos originais, disponíveis na íntegra e publicados entre 2021 e 2026, nos idiomas português, inglês ou espanhol, que abordassem recém-nascidos ou a assistência neonatal e investigassem aplicações clínicas da IA no diagnóstico precoce, prognóstico, monitoramento ou apoio à tomada de decisão. Foram excluídos artigos duplicados, revisões da literatura, editoriais, cartas ao editor, protocolos, capítulos de livros e resumos publicados em eventos, bem como estudos exclusivamente pediátricos que não apresentassem dados neonatais individualizados, pesquisas sobre IA sem aplicação clínica ou relação direta com a neonatologia e trabalhos cujo texto completo não estivesse disponível.

2.6 Extração e organização dos dados

Para a extração e organização dos dados, foi elaborada uma planilha padronizada no Google Planilhas, na qual foram registradas as seguintes informações dos estudos incluídos: autoria, ano de publicação, objetivo, população, tipo de IA, aplicação clínica, principais resultados e limitações. Posteriormente, os dados foram organizados e comparados para sintetizar as evidências sobre o potencial da IA no diagnóstico precoce e no apoio à tomada de decisão clínica em neonatologia.

2.7 Apresentação do processo de seleção dos estudos

CC BY

REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

O processo de identificação, triagem, avaliação da elegibilidade e inclusão dos estudos foi apresentado por meio de um fluxograma elaborado com base nas recomendações do PRISMA, no qual foram registrados os números de publicações identificadas nas bases de dados, duplicatas removidas, estudos excluídos após a leitura dos títulos e resumos, textos completos avaliados e artigos incluídos na síntese final.

3. Resultados

A busca nas bases de dados resultou na identificação de 406 artigos potencialmente elegíveis para esta revisão (PubMed = 306; BVS = 7; Scopus = 15; Web of Science = 64; e SciELO = 14). Em seguida, 138 estudos foram excluídos por estarem duplicados, resultando em 268 artigos encaminhados para a leitura dos títulos e resumos. Destes, 157 foram excluídos por se tratar de revisões de literatura e 74 por não estarem disponíveis por completo. Assim, 37 artigos foram lidos na integra, e destes foram excluídos 12 estudos por inadequação aos critérios metodológicos estabelecidos, 5 por não abordarem diretamente a temática investigada e 8 por não contemplarem os desfechos de interesse desta revisão. Ao término do processo de seleção, doze artigos científicos foram incluídos na síntese final. As etapas de identificação, triagem, elegibilidade e inclusão dos estudos encontram-se representadas no fluxograma da Figura 1. Já o Quadro 1 reúne os dados referentes aos estudos selecionados para esta revisão.

CC BY

REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

Figura 1 – Fluxograma PRISMA

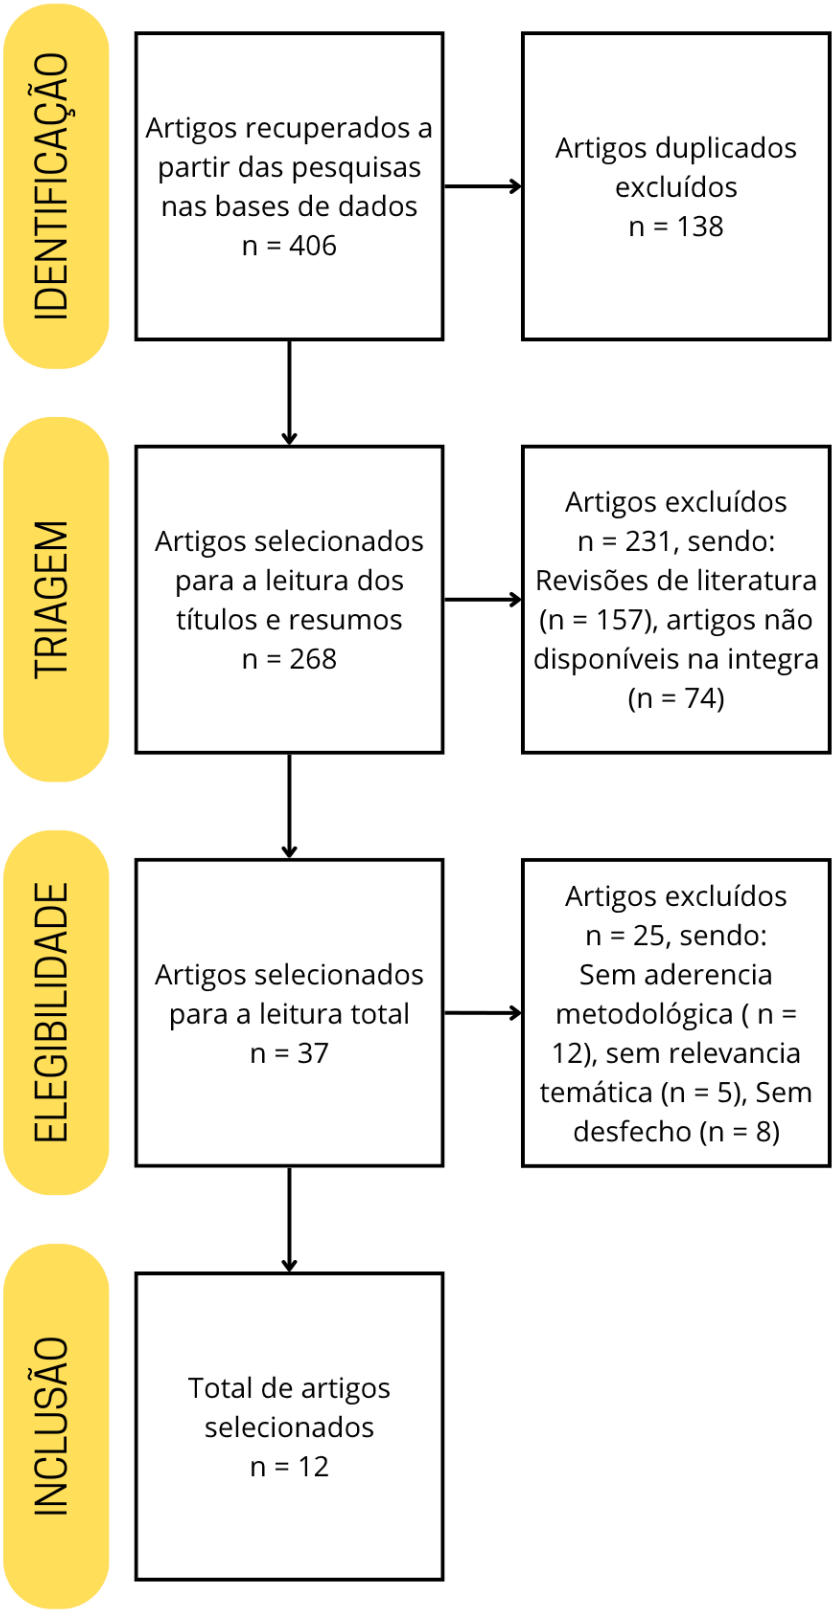

Fonte: Adaptado de Page et al. (2022)

CC BY

REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

Quadro 1 – Principais características e resultados dos estudos selecionados

Autoria (ano)	Objetivo	População	Tipo de IA	Aplicação clínica	Principais resultados	Limitações
Stocker et al. (2022)	Comparar a acurácia de fatores de risco, sinais clínicos e biomarcadores e desenvolver modelo preditivo para sepse neonatal de início precoce.	1.685 neonatos ≥34 semanas tratados com antibióticos por suspeita de sepse precoce.	*Machine learning* – Random Forest.	Predição e auxílio ao diagnóstico da sepse neonatal precoce.	O modelo completo apresentou AUROC de 0,834. Proteína C-reativa e contagem de leucócitos estiveram entre as variáveis de maior importância preditiva.	Pequeno número de casos de sepse confirmada em relação ao total da amostra e população previamente selecionada por suspeita de infecção, podendo limitar a generalização.
Honoré et al. (2023)	Avaliar a capacidade de dados de monitorização fisiológica contínua e características demográficas para detectar precocemente sepse neonatal.	325 neonatos, correspondendo a 2.866 dias de hospitalização.	*Machine learning* aplicado a sinais vitais, com modelo probabilístico Naïve Bayes.	Detecção precoce de sepse neonatal por sinais vitais.	O modelo alcançou AUC de aproximadamente 0,82 e identificou alterações compatíveis com sepse até 24 horas antes da suspeita clínica.	Estudo unicêntrico, amostra relativamente pequena e número reduzido de episódios de sepse; requer validação externa.
Meeus et al. (2024)	Desenvolver modelo de aprendizado de máquina para predizer sepse tardia e enterocolite necrosante em prematuros.	865 prematuros <32 semanas no desenvolvimento e 148 pacientes em conjunto independente de validação interna.	*Machine learning* – XGBoost.	Predição de sepse neonatal tardia e enterocolite necrosante (NEC).	O modelo produziu previsões horárias de risco. Apresentou 69% de sensibilidade para todos os episódios de LOS/NEC e 81% para episódios graves, possibilitando antecipação do reconhecimento clínico.	Coorte retrospectiva, proveniente de um único centro e sem validação externa independente; necessita avaliação prospectiva do impacto clínico.
Lin et al. (2022)	Desenvolver escores individualizados e dinâmicos de risco para enterocolite necrosante	261 prematuros de risco, provenientes de duas coortes,	*Machine learning* – Multiple Instance Learning, rede	Predição precoce da enterocolite necrosante.	O modelo alcançou aproximadamente 86% de sensibilidade e 90% de especificidade,	Uso de dados históricos de microbiota e diferenças entre os conjuntos de dados;

REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

Autoria (ano)	Objetivo	População	Tipo de IA	Aplicação clínica	Principais resultados	Limitações
	utilizando dados da microbiota intestinal.	com 3.595 amostras fecais.	neural com mecanismo de atenção.		podendo identificar risco de NEC vários dias antes do diagnóstico clínico.	necessita validação prospectiva antes da utilização clínica.
Wu et al. (2022)	Desenvolver e validar modelo para predizer ocorrência e gravidade da retinopatia da prematuridade utilizando imagens da retina e características clínicas.	815 prematuros submetidos à triagem de ROP; 725 no desenvolvimento/validação interna e 90 na validação externa.	Deep learning, utilizando redes neurais profundas.	Predição da ocorrência e da gravidade da retinopatia da prematuridade (ROP).	Na validação externa, apresentou AUC de 0,94 para ocorrência e 0,88 para gravidade da ROP, alcançando sensibilidade de 100% nos limiares estabelecidos.	A especificidade na validação externa foi baixa nos limiares escolhidos para alcançar sensibilidade máxima, aumentando a possibilidade de falsos positivos.
Yalçın et al. (2023)	Desenvolver e validar ferramenta de suporte à decisão clínica baseada em ML para identificação de risco nutricional e restrição do crescimento extrauterino.	512 pacientes de UTIN, incluídos prospectivamente.	*Machine learning* – Random Forest para ganho de peso e Elastic Net Regression para peso na alta.	Avaliação nutricional e predição do crescimento neonatal.	O Random Forest apresentou AUROC de 0,847 para presença de ganho de peso na alta. Para predição do peso na alta, a regressão Elastic Net alcançou $R^2 = 0,748$.	Realizado em um único centro; o desempenho da ferramenta necessita ser avaliado externamente antes de sua implementação generalizada em diferentes UTINs.
Raeisi et al. (2023)	Desenvolver abordagem automatizada, explicável e capaz de lidar com desequilíbrio entre classes para detectar crises epilépticas neonatais em sinais de EEG.	Registros de EEG neonatal multicanal utilizados para treinamento e avaliação do modelo.	*Deep learning* – Convolutional Neural Networks (CNN) + Graph Attention Networks (GAT), formando uma rede espaço-temporal (ST-GAT).	Detecção automatizada de crises neonatais por EEG.	O modelo apresentou AUC média de 96,6% e coeficiente Kappa de 0,88, superando métodos de referência avaliados no estudo.	Dependência de bases de EEG anotadas por especialistas e necessidade de validação prospectiva e em diferentes populações antes da utilização clínica ampla.
Fatima et al. (2024)	Desenvolver métodos automatizados de *deep*	34 neonatos, correspondendo a	*Deep learning* para	Interpretação automatizada de	A melhor estratégia *frame-to-video*	Amostra pequena, com apenas 34 pacientes;

REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

Autoria (ano)	Objetivo	População	Tipo de IA	Aplicação clínica	Principais resultados	Limitações
	learning para classificação de padrões em ultrassonografia pulmonar neonatal e avaliar a concordância entre IA e especialistas.	70 exames de ultrassonografia pulmonar, avaliados por três especialistas.	classificação de imagens/vídeos; estratégias frame-to-video e classificação direta de vídeo.	ultrassonografia pulmonar neonatal.	alcançou 77% de acurácia e concordância moderada com especialistas; a classificação direta dos vídeos apresentou acurácia de 72%.	subjetividade inerente às anotações dos especialistas e necessidade de conjuntos maiores e validação externa.
Leigh et al. (2022)	Desenvolver modelos de ML para predizer sobrevida livre de displasia broncopulmonar em prematuros extremos/muito prematuros.	Prematuros com idade gestacional <32 semanas internados em UTIN, avaliados a partir de dados clínicos neonatais.	*Machine learning*, com comparação de diferentes algoritmos preditivos.	Predição de displasia broncopulmonar (DBP) e sobrevida livre de DBP.	Os modelos demonstraram capacidade de estratificar precocemente o risco de DBP ou morte, mostrando potencial para apoiar prognóstico e decisões terapêuticas em prematuros.	Natureza retrospectiva e dependência das características da população utilizada para treinamento; requer validação em populações externas e avaliação prospectiva.
Shu et al. (2025)	Desenvolver modelos de ML utilizando variáveis maternas e neonatais precoces para predizer mortalidade e principais morbidades em prematuros de muito baixo peso.	3.341 prematuros de muito baixo peso na coorte de desenvolvimento/validação e 447 em uma coorte separada de teste.	Sete algoritmos de *machine learning*; melhor desempenho principalmente com Random Forest e XGBoost.	Predição de mortalidade, DBP, sepse, NEC, hemorragia intraventricular, leucomalácia periventricular e ROP.	Os melhores modelos apresentaram AUROC de 0,74 para mortalidade, 0,73 para sepse, 0,73 para NEC e 0,71 para DBP, permitindo estratificação individualizada do risco neonatal.	Desempenho discriminativo moderado para alguns desfechos e necessidade de avaliar a generalização e o benefício clínico dos modelos antes da implementação na prática.
Li et al. (2024)	Desenvolver e avaliar modelos de machine learning para predizer a sobrevida de recém-	459 prematuros, nascidos entre 23 e 29 semanas de gestação,	Machine learning, incluindo Random Forest e	Predição de sobrevida em prematuros extremos,	O modelo Random Forest apresentou desempenho preditivo superior ao SNAPPE-II	Número relativamente pequeno de óbitos; utilização de dados retrospectivos de uma

REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

Autoria (ano)	Objetivo	População	Tipo de IA	Aplicação clínica	Principais resultados	Limitações
	nascidos extremamente prematuros no momento da admissão à UTIN.	provenientes da base MIMIC-III; 37 (8,1%) evoluíram para óbito.	outros algoritmos preditivos.	auxiliando a estratificação de risco e a tomada de decisão clínica na UTIN.	para prematuros extremos de muito baixo peso. Os modelos permitiram incorporar múltiplas características maternas e neonatais para estimar a probabilidade de sobrevida.	base clínica e necessidade de validação externa antes da aplicação em diferentes populações neonatais.
Sullivan et al. (2025)	Comparar diferentes técnicas de machine learning para predizer mortalidade em pacientes internados em UTIN utilizando informações clínicas, demográficas e fisiológicas.	Mais de 6.000 admissões em UTIN, utilizando dados demográficos, clínicos e medidas de frequência cardíaca e saturação de oxigênio.	Machine learning: regressão logística, CatBoost, redes neurais, Random Forest e XGBoost.	Predição de mortalidade neonatal e estratificação precoce do risco na UTIN.	Cinco equipes desenvolveram modelos para estimar o risco de mortalidade na admissão e nos 7 dias subsequentes, demonstrando a aplicabilidade de diferentes técnicas de ML à estratificação de risco neonatal a partir de dados clínicos e fisiológicos.	O estudo foi estruturado como uma competição de modelagem, com diferenças metodológicas entre as abordagens; a aplicação dos modelos na prática clínica ainda requer avaliação prospectiva e validação em diferentes cenários assistenciais.

Fonte: A autora (2026)

REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

Em relação às populações investigadas, observou-se expressiva heterogeneidade entre os estudos. As pesquisas incluíram tanto populações selecionadas segundo características neonatais específicas, como prematuridade, idade gestacional e muito baixo peso ao nascer, quanto grupos de pacientes internados em UTIN avaliados a partir de diferentes características clínicas, demográficas e fisiológicas. Entre os estudos que informaram quantitativamente o número de participantes, as amostras variaram de 34 neonatos (na investigação envolvendo ultrassonografia pulmonar) a mais de 6.000 admissões em UTIN no estudo voltado a predição de mortalidade. Também foram avaliados grupos de 325, 459, 512, 815, 1.685 e 3.341 recém-nascidos, além de estudos baseados em registros fisiológicos, amostras biológicas e exames complementares. Parte relevante das pesquisas concentrou-se em prematuros, incluindo recém-nascidos com idade gestacional inferior a 32 semanas, prematuros extremos e neonatos de muito baixo peso, demonstrando especial interesse pela aplicação da IA em populações com maior vulnerabilidade clínica.

Quanto às tecnologias empregadas, predominou o uso de técnicas de *machine learning*, com aplicação de diferentes algoritmos de classificação e predição. Entre os métodos utilizados destacaram-se *Random Forest, XGBoost, Naïve Bayes, Elastic Net Regression e Multiple Instance Learning*. Alguns estudos compararam simultaneamente diferentes algoritmos para identificar aquele com melhor capacidade preditiva, enquanto outros desenvolveram modelos específicos a partir das características dos dados analisados. Técnicas de *deep learning* também estiveram presentes, principalmente nas aplicações relacionadas ao processamento de imagens, vídeos e sinais fisiológicos. Foram utilizadas redes neurais convolucionais, *Graph Attention Networks* e arquiteturas espaço-temporais, além de redes profundas destinadas à interpretação de imagens da retina e de ultrassonografia pulmonar. Essa variedade metodológica demonstra que a escolha da abordagem computacional esteve diretamente relacionada à natureza dos dados clínicos utilizados e ao desfecho neonatal investigado.

As aplicações clínicas identificadas abrangeram diferentes áreas da neonatologia. A sepse constituiu um dos principais focos de investigação, com modelos direcionados à identificação da sepse neonatal de início precoce e tardio

CC BY

REMUNOM
ISSN 2178-6925
Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

por meio de fatores clínicos, biomarcadores e monitoramento contínuo dos sinais vitais. Outras ferramentas foram desenvolvidas para estimar o risco de enterocolite necrosante, inclusive a partir de características da microbiota intestinal, enquanto modelos baseados em imagens foram empregados na predição da ocorrência e da gravidade da retinopatia da prematuridade. Também foram identificadas aplicações voltadas à avaliação nutricional e ao crescimento neonatal, detecção automatizada de crises epilépticas por eletroencefalografia, interpretação de ultrassonografia pulmonar e predição de displasia broncopulmonar. Adicionalmente, alguns estudos utilizaram IA para estimar sobrevida, mortalidade e múltiplas morbidades em recém-nascidos prematuros, ampliando sua utilização para a estratificação prognóstica e o suporte às decisões clínicas na UTIN.

Na avaliação do desempenho dos modelos, a área sob a curva AUC ou AUROC foi uma das métricas utilizadas, variando de 0,5, o que corresponde a uma discriminação não superior ao acaso, a 1,0, que representa discriminação perfeita. Assim, quanto mais próximo de 1, maior a capacidade do modelo de distinguir indivíduos com e sem o desfecho investigado. Nos estudos voltados à predição da sepse neonatal, foram observados valores de AUC/AUROC entre aproximadamente 0,82 e 0,834, indicando boa capacidade discriminativa dos modelos, sendo que, em um deles, alterações associadas à sepse foram identificadas até 24 horas antes da suspeita clínica. Para a predição de sepse tardia e enterocolite necrosante, foram registradas sensibilidades de 69% para o conjunto dos episódios e de 81% para os episódios graves. O modelo baseado na microbiota intestinal para predição de enterocolite necrosante apresentou sensibilidade de aproximadamente 86% e especificidade de 90%. Na retinopatia da prematuridade, foram observadas AUC de 0,94 para ocorrência e de 0,88 para gravidade da doença na validação externa. Na detecção automatizada de crises neonatais, o modelo apresentou AUC média de 0,966 e coeficiente Kappa de 0,88. Para a classificação automatizada da ultrassonografia pulmonar, a maior acurácia registrada foi de 77%.

Em relação às limitações relatadas nos estudos, foram identificados tamanho amostral reduzido ou baixo número de eventos clínicos, realização de pesquisas em centro único, utilização retrospectiva de bases de dados e emprego de

CC BY

REMUNOM
ISSN 2178-6925
Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

populações específicas no desenvolvimento e treinamento dos modelos. Também foi registrada ausência de validação externa ou prospectiva em parte dos estudos. Nos modelos que utilizaram imagens e sinais fisiológicos, foram descritas limitações relacionadas à necessidade de dados previamente classificados por especialistas e às características dos conjuntos de dados empregados no treinamento. Adicionalmente, alguns modelos apresentaram desempenho discriminativo moderado para determinados desfechos, enquanto, na predição da retinopatia da prematuridade, foi observada redução da especificidade nos limiares estabelecidos para obtenção de sensibilidade de 100%.

4. Discussão

Os achados desta revisão evidenciam a diversidade de aplicações da IA no campo da neonatologia, abrangendo diferentes condições e necessidades relacionadas à assistência ao recém-nascido. Os estudos analisados empregaram ferramentas de IA na identificação e predição de sepse neonatal, enterocolite necrosante, retinopatia da prematuridade, crises epilépticas e displasia broncopulmonar, além de aplicações direcionadas a avaliação nutricional, interpretação de ultrassonografia pulmonar e estimativa de mortalidade e sobrevida. Esse conjunto de aplicações demonstra que o uso da IA na assistência neonatal não se concentra exclusivamente na identificação de doenças específicas, mas se estende ao monitoramento clínico, à avaliação prognóstica e à estratificação de risco.

Entre as aplicações identificadas, a predição da sepse neonatal e da enterocolite necrosante (NEC) destacou-se pela utilização de diferentes fontes de dados. Stocker et al. (2022) integraram fatores de risco, sinais clínicos e biomarcadores para estimar o risco de sepse neonatal precoce, enquanto Honoré et al. (2023) utilizaram o monitoramento contínuo de sinais vitais, identificando alterações associadas à sepse antes da suspeita clínica. Meeus et al. (2024) ampliaram essa abordagem ao estimar, de forma horária, o risco de sepse tardia e NEC, enquanto Lin et al. (2022) incorporaram dados da microbiota intestinal para predizer individualmente o risco de NEC. Esses achados estão de acordo com McAdams et al. (2022), que identificaram sepse e NEC entre as principais

CC BY

REMUNOM
ISSN 2178-6925
Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

condições investigadas por modelos de IA na neonatologia. Entretanto, o predomínio de estudos retrospectivos, a heterogeneidade das populações e as diferenças nas variáveis e estratégias de validação dificultam a comparação entre os modelos e sua aplicação em diferentes cenários assistenciais (Stocker et al., 2022; Honoré et al., 2023; Meeus et al., 2024; Lin et al., 2022; McAdams et al., 2022).

A aplicação da IA na interpretação de imagens e sinais fisiológicos também apresentou resultados relevantes nos estudos analisados. Wu et al. (2022) demonstraram a utilização do *deep learning* na predição da ocorrência e gravidade da retinopatia da prematuridade a partir de imagens da retina associadas a características clínicas, enquanto Raeisi et al. (2023) empregaram redes neurais na análise de sinais de EEG para a detecção automatizada de crises neonatais. Em outra abordagem, Fatima et al. (2024) utilizaram *deep learning* para classificação de padrões em ultrassonografia pulmonar, embora com desempenho inferior ao observado nas demais aplicações. Essas diferenças devem ser interpretadas considerando a diversidade dos dados, desfechos e populações avaliadas, não permitindo uma comparação direta entre os modelos. De forma semelhante, Keles e Bagci (2023) identificaram a análise de imagens, biossinais e retinopatia da prematuridade entre importantes aplicações da IA na neonatologia, destacando, contudo, desafios relacionados à disponibilidade e qualidade dos dados e à implementação dessas ferramentas na prática clínica (Wu et al., 2022; Raeisi et al., 2023; Fatima et al., 2024; Keles; Bagci, 2023).

A IA também se destacou na predição de morbidades, mortalidade e prognóstico neonatal. Leigh et al. (2022) utilizaram modelos de machine learning para estimar a sobrevida livre de displasia broncopulmonar, enquanto Shu et al. (2025), Li et al. (2024) e Sullivan et al. (2025) desenvolveram modelos para predizer mortalidade e diferentes morbidades em prematuros. Embora tenham utilizado diferentes algoritmos, populações e variáveis clínicas, esses estudos demonstram que a IA vem avançando na integração de informações disponíveis desde a admissão e ao longo da internação, visando à estimativa individualizada de riscos e à identificação de recém-nascidos mais vulneráveis. Esses achados indicam o potencial da IA para a estratificação individualizada do risco e a avaliação

CC BY

REMUNOM
ISSN 2178-6925
Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

prognóstica, conforme também observado por McAdams et al. (2022), que identificaram a mortalidade e as principais morbidades neonatais entre os desfechos mais frequentemente investigados por modelos preditivos. Entretanto, a validação externa e prospectiva ainda é necessária para avaliar a generalização dos resultados, a segurança das previsões e a utilidade desses modelos na tomada de decisão clínica, especialmente em diferentes contextos assistenciais (Leigh et al., 2022; McAdams et al., 2022; Li et al., 2024; Shu et al., 2025; Sullivan et al., 2025).

Além das aplicações voltadas ao diagnóstico e ao prognóstico, a IA também apresentou potencial como ferramenta de apoio à tomada de decisão clínica. Yalçın et al. (2023) utilizaram modelos de machine learning para avaliar o estado nutricional e predizer o ganho de peso e o peso na alta de recém-nascidos internados em unidade de terapia intensiva neonatal, demonstrando uma aplicação direcionada ao acompanhamento clínico e não apenas à identificação de doenças. Nesse sentido, a integração de diferentes dados neonatais pode auxiliar na estratificação de riscos e na identificação de pacientes que necessitam de maior vigilância ou intervenções individualizadas. Entretanto, Schouten et al. (2024) observaram que, apesar do crescente desenvolvimento de ferramentas de IA destinadas ao suporte à decisão em cuidados intensivos neonatais e pediátricos, a maioria dos modelos ainda permanece nas fases de desenvolvimento e validação, com limitada incorporação à prática clínica. Assim, essas tecnologias devem ser compreendidas como ferramentas auxiliares ao processo decisório, cuja utilização requer validação adequada e avaliação de sua aplicabilidade em cenários clínicos reais (Yalçın et al., 2023; Schouten et al., 2024).

Entre as abordagens de IA identificadas, observou-se predomínio de técnicas de aprendizado de máquina, com utilização de algoritmos como *Random Forest, XGBoost, Naïve Bayes, Elastic Net Regression e Multiple Instance Learning* em diferentes aplicações clínicas (Stocker et al., 2022; Honoré et al., 2023; Lin et al., 2022; Yalçın et al., 2023; Meeus et al., 2024; Li et al., 2024). Por outro lado, técnicas de aprendizado profundo, incluindo redes neurais convolucionais e redes com mecanismos de atenção, foram empregadas principalmente na análise de dados mais complexos, como imagens da retina, ultrassonografia e sinais de EEG (Wu et

CC BY

REMUNOM
ISSN 2178-6925
Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

al., 2022; Raeisi et al., 2023; Fatima et al., 2024). Essa diversidade sugere que a escolha do algoritmo está relacionada às características e à complexidade dos dados disponíveis para cada finalidade clínica. De forma semelhante, Keles e Bagci (2023) identificaram ampla diversidade de técnicas de aprendizado de máquina e aprendizado profundo na neonatologia, com aplicações envolvendo parâmetros vitais, biossinais, neuroimagem, retinopatia da prematuridade e análise de sobrevida. Assim, a heterogeneidade dos métodos reflete a variedade de informações produzidas durante a assistência neonatal e as diferentes possibilidades de aplicação da IA nesse contexto.

Apesar dos resultados promissores, os estudos analisados apresentam limitações que devem ser consideradas na interpretação das aplicações da IA em neonatologia. Entre as principais fragilidades estão a realização de estudos unicêntricos, o tamanho amostral reduzido, o baixo número de determinados eventos clínicos, o uso de bases retrospectivas e a ausência de validação externa ou prospectiva em parte dos modelos. Além disso, algumas aplicações dependeram de dados previamente anotados por especialistas, enquanto determinados modelos apresentaram desempenho moderado ou redução da especificidade em alguns limiares de classificação. Essas limitações são semelhantes às descritas por Keles e Bagci (2023), que destacaram amostras pequenas, estudos unicêntricos, escassez de avaliações prospectivas e dificuldades relacionadas à disponibilidade e anotação dos dados. Schouten et al. (2024) também identificaram elevado risco de viés em grande parte das pesquisas e limitada progressão dos modelos para a prática clínica. Dessa forma, a heterogeneidade metodológica e a limitada validação externa dificultam a generalização dos resultados para diferentes populações e UTINs, reforçando a necessidade de estudos multicêntricos e prospectivos antes da incorporação ampla dessas ferramentas à assistência neonatal (Keles; Bagci, 2023; Schouten et al., 2024).

5. Considerações Finais

As evidências analisadas demonstram que a IA apresenta potencial para ampliar as possibilidades de diagnóstico precoce e apoio à tomada de decisão clínica em neonatologia. Suas aplicações abrangem a identificação e predição de

CC BY

REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

diferentes condições neonatais, o processamento de imagens e sinais fisiológicos, a avaliação prognóstica, a estratificação de risco e o acompanhamento de parâmetros clínicos, contribuindo para uma assistência mais individualizada ao recém-nascido. Entretanto, apesar dos resultados promissores, a incorporação dessas ferramentas à prática assistencial ainda requer cautela, principalmente diante da heterogeneidade metodológica e da necessidade de maior validação em diferentes populações e contextos clínicos. Nesse sentido, estudos multicêntricos, prospectivos e direcionados à avaliação da aplicabilidade clínica são necessários para consolidar a utilização da IA na assistência neonatal. Dessa forma, conclui-se que essas tecnologias apresentam perspectivas relevantes para complementar a atuação dos profissionais de saúde, especialmente na identificação precoce de riscos e no suporte às decisões clínicas, sem substituir a avaliação e o julgamento profissional.

Referências

Conselho Federal de Medicina. “Resolução CFM nº 2.454, de 11 de fevereiro de 2026.” *Conselho Federal de Medicina*, 2026.

Fatima, Noreen, et al. “Deep Learning Approaches for Automated Classification of Neonatal Lung Ultrasound with Assessment of Human-to-AI Interrater Agreement.” *Computers in Biology and Medicine*, vol. 183, 2024, article 109315. https://doi.org/10.1016/j.compbiomed.2024.109315.

Honoré, Antoine, et al. “Vital Sign-Based Detection of Sepsis in Neonates Using Machine Learning.” *Acta Paediatrica*, vol. 112, no. 4, 2023, pp. 686–696. https://doi.org/10.1111/apa.16660.

Husain, Ameena, et al. “AI Models in Clinical Neonatology: A Review of Modeling Approaches and a Consensus Proposal for Standardized Reporting of Model Performance.” *Pediatric Research*, vol. 98, no. 2, 2025, pp. 412–422. https://doi.org/10.1038/s41390-024-03774-4.

Keles, Elif, and Ulas Bagci. “The Past, Current, and Future of Neonatal Intensive Care Units with Artificial Intelligence: A Systematic Review.” *npj Digital Medicine*, vol. 6, 2023, article 220. https://doi.org/10.1038/s41746-023-00941-5.

Leigh, Rebekah M., et al. “Machine Learning for Prediction of Bronchopulmonary Dysplasia-Free Survival among Very Preterm Infants.” *BMC Pediatrics*, vol. 22, 2022, article 542. https://doi.org/10.1186/s12887-022-03602-w.

Li, Angie, Sarah Mullin, and Peter L. Elkin. “Improving Prediction of Survival for

CC BY

REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

Extremely Premature Infants Born at 23 to 29 Weeks Gestational Age in the Neonatal Intensive Care Unit: Development and Evaluation of Machine Learning Models." *JMIR Medical Informatics*, vol. 12, 2024, e42271. https://doi.org/10.2196/42271.

Liang, Xifeng, et al. "Global, Regional, and National Burden of Preterm Birth, 1990–2021: A Systematic Analysis from the Global Burden of Disease Study 2021." *EClinicalMedicine*, vol. 76, 2024, article 102840. https://doi.org/10.1016/j.eclinm.2024.102840.

Lin, Yun Chao, Ansaf Salleb-Aouissi, and Thomas A. Hooven. "Interpretable Prediction of Necrotizing Enterocolitis from Machine Learning Analysis of Premature Infant Stool Microbiota." *BMC Bioinformatics*, vol. 23, 2022, article 104. https://doi.org/10.1186/s12859-022-04618-w.

McAdams, Ryan M., et al. "Predicting Clinical Outcomes Using Artificial Intelligence and Machine Learning in Neonatal Intensive Care Units: A Systematic Review." *Journal of Perinatology*, vol. 42, no. 12, 2022, pp. 1561–1575. https://doi.org/10.1038/s41372-022-01392-8.

Meeus, Marisse, et al. "Clinical Decision Support for Improved Neonatal Care: The Development of a Machine Learning Model for the Prediction of Late-Onset Sepsis and Necrotizing Enterocolitis." *The Journal of Pediatrics*, vol. 266, 2024, article 113869. https://doi.org/10.1016/j.jpeds.2023.113869.

Page, Matthew J., et al. "A Declaração PRISMA 2020: Diretriz Atualizada para Relatar Revisões Sistemáticas." *Revista Panamericana de Salud Pública*, vol. 46, 2022, e112. https://doi.org/10.26633/RPSP.2022.112.

Raeisi, Khadijeh, et al. "A Class-Imbalance Aware and Explainable Spatio-Temporal Graph Attention Network for Neonatal Seizure Detection." *International Journal of Neural Systems*, vol. 33, no. 9, 2023, article 2350046. https://doi.org/10.1142/S0129065723500466.

Schouten, Janno S., et al. "From Bytes to Bedside: A Systematic Review on the Use and Readiness of Artificial Intelligence in the Neonatal and Pediatric Intensive Care Unit." *Intensive Care Medicine*, vol. 50, no. 11, 2024, pp. 1767–1777. https://doi.org/10.1007/s00134-024-07629-8.

Shu, Chi-Hung, et al. "Early Prediction of Mortality and Morbidities in VLBW Preterm Neonates Using Machine Learning." *Pediatric Research*, vol. 97, no. 6, 2025, pp. 2056–2064. https://doi.org/10.1038/s41390-024-03604-7.

Stocker, Martin, et al. "Machine Learning Used to Compare the Diagnostic Accuracy of Risk Factors, Clinical Signs and Biomarkers and to Develop a New Prediction Model for Neonatal Early-Onset Sepsis." *The Pediatric Infectious Disease Journal*, vol. 41, no. 3, 2022, pp. 248–254. https://doi.org/10.1097/INF.0000000000003344.

CC BY

REMUNOM
ISSN 2178-6925

Received: 28/08/2026 - **Accepted:** 27/09/2026
Vol: 13.20
DOI: 10.66104/pamtv631
Pages: 1-21

Sullivan, Brynne A., et al. “Comparing Machine Learning Techniques for Neonatal Mortality Prediction: Insights from a Modeling Competition.” *Pediatric Research*, vol. 98, no. 2, 2025, pp. 405–411. https://doi.org/10.1038/s41390-024-03773-5.

Sullivan, Brynne A., et al. “Transforming Neonatal Care with Artificial Intelligence: Challenges, Ethical Consideration, and Opportunities.” *Journal of Perinatology*, vol. 44, no. 1, 2024, pp. 1–11. https://doi.org/10.1038/s41372-023-01848-5.

Ward, Victoria C., et al. “Overview of the Global and US Burden of Preterm Birth.” *Clinics in Perinatology*, vol. 51, no. 2, 2024, pp. 301–311. https://doi.org/10.1016/j.clp.2024.02.015.

Wu, Qiaowei, et al. “Development and Validation of a Deep Learning Model to Predict the Occurrence and Severity of Retinopathy of Prematurity.” *JAMA Network Open*, vol. 5, no. 6, 2022, e2217447. https://doi.org/10.1001/jamanetworkopen.2022.17447.

Yalçın, Nadir, et al. “Development and Validation of Machine Learning-Based Clinical Decision Support Tool for Identifying Malnutrition in NICU Patients.” *Scientific Reports*, vol. 13, 2023, article 5227. https://doi.org/10.1038/s41598-023-32570-z.

CC BY