Artigo Original

v. 7 n. 4 (2026)
ISSN: 2675-8008
Revista Multidisciplinar em Saúde

ACESSO ABERTO

Data de Recebimento:
03/11/2026

Data de Aceite:
03/11/2026

Data de Publicação:
18/11/2026

INTELIGÊNCIA ARTIFICIAL COMO FERRAMENTA DE APOIO À CLASSIFICAÇÃO DE RISCO EM SERVIÇOS DE URGÊNCIA E EMERGÊNCIA: CONTRIBUIÇÕES PARA A ATUAÇÃO DO ENFERMEIRO

Natália de Pádua Alves[a], Gabriel Almeida de Sousa[a], Geovanna Rafaela Ferreira de Souza[a], Júlia de Freitas Guimarães[a], Eduardo Breno Ferreira de Farias[a], Patrícia Furtado Malard[ab]

[a]Curso de Graduação em Enfermagem, Universidade Estácio de Sá (UNESA), Campus R9 Taquara. Rua André Rocha, nº 838, Taquara, Rio de Janeiro – RJ, Brasil.

***Autor correspondente:**
Cláudia Daniela Souza de Assis Messias, ensino médio completo; cursando graduação em Enfermagem (não concluída). Rua Professor Henrique Costa, nº 730, bloco 5, apartamento 405, Pechincha, Rio de Janeiro – RJ, CEP 22770-235. Telefone (21) 96560-1831, E-mail: claudia_dsals@yahoo.com.br

Citação:
MESSIAS, C.D.S,A; Inteligência artificial como ferramenta de apoio à classificação de risco em serviços de urgência e emergência: contribuições para a atuação do enfermeiro , **Revista Multidisciplinar em Saúde**, v. 7, n. 4, 2026. https://doiorg/10.51161/integrar/rems/5068

RESUMO

Introdução: A classificação de risco é atividade privativa do enfermeiro nos serviços de urgência e emergência e convive com superlotação, variação entre avaliadores e casos de subtriagem, cenário em que ferramentas de inteligência artificial vêm sendo testadas como apoio à decisão. **Metodologia:** Revisão narrativa da literatura, com busca nas bases SciELO, LILACS e PubMed por artigos publicados entre 2010 e 2025, em português ou inglês, complementada por documentos normativos brasileiros e internacionais; os textos foram lidos na íntegra e organizados em quatro eixos temáticos. **Resultados:** Os 15 artigos analisados indicam que modelos de aprendizado de máquina identificam melhor que a triagem convencional os pacientes que vão precisar de cuidados críticos ou de internação, sobretudo por reduzirem a subtriagem nos casos de gravidade intermediária. Persistem limitações importantes: predominância de estudos retrospectivos, ausência de validação em serviços brasileiros, risco de vieses algorítmicos, opacidade dos modelos e exigências de proteção de dados. **Conclusões:** A inteligência artificial pode qualificar a classificação de risco quando incorporada como suporte ao julgamento clínico do enfermeiro, e não como substituto dele, o que depende de validação com dados nacionais, de regras claras de responsabilidade e de formação específica da equipe.

Palavras-chave: Aprendizado de máquina; Triagem; Tomada de decisão clínica; Enfermagem; Segurança do paciente.

DOI: 10.51161/integrar/rems/5068
Editora Integrar© 2026. Todos os direitos reservados.

ABSTRACT

Introduction: Risk classification is an activity exclusive to nurses in urgent and emergency services and is affected by overcrowding, inter-rater variability and undertriage, a scenario in which artificial intelligence tools have been tested as decision support. **Methodology:** Narrative literature review, with searches in the SciELO, LILACS and PubMed databases for articles published between 2010 and 2025, in Portuguese or English, complemented by Brazilian and international regulatory documents; the texts were read in full and organized into four thematic axes. **Results:** The 15 articles analyzed indicate that machine learning models identify patients who will need critical care or hospital admission better than conventional triage, mainly by reducing undertriage in cases of intermediate severity. Important limitations remain: predominance of retrospective studies, lack of validation in Brazilian services, risk of algorithmic bias, model opacity and data protection requirements. **Conclusions:** Artificial intelligence can improve risk classification when incorporated as support for the nurse's clinical judgment, not as a substitute for it, which depends on validation with national data, clear rules of accountability and specific training of the team.

Keywords: Machine learning; Triage; Clinical decision-making; Nursing; Patient safety.

1 INTRODUÇÃO

Quem chega a um pronto-socorro lotado raramente é atendido por ordem de chegada. Desde que o Ministério da Saúde passou a orientar o acolhimento com classificação de risco nas portas de urgência, a prioridade é definida pela gravidade clínica, e não pelo horário em que o paciente entrou na fila (Brasil, 2009). A Portaria nº 1.600/2011, que instituiu a Rede de Atenção às Urgências no Sistema Único de Saúde (SUS), consolidou essa lógica ao incluir o acolhimento com classificação de risco entre as diretrizes de toda a rede (Brasil, 2011). O princípio é simples de enunciar e difícil de executar: em poucos minutos, com informações incompletas, alguém precisa decidir quem não pode esperar.

No Brasil, essa decisão cabe ao enfermeiro. A Lei nº 7.498/1986 reserva a ele os cuidados de maior complexidade técnica, que exigem conhecimento científico e capacidade de tomar decisões imediatas (Brasil, 1986), e o Conselho Federal de Enfermagem definiu a classificação de risco como atividade privativa do enfermeiro dentro da equipe de enfermagem (Conselho Federal de Enfermagem, 2021). Para orientar o raciocínio, os serviços adotam protocolos estruturados. O Sistema Manchester de Classificação de Risco, o mais difundido no país, distribui os pacientes em cinco categorias identificadas por cores, cada uma com um tempo máximo para o primeiro atendimento médico (Mackway-Jones; Marsden; Windle, 2014). Nos Estados Unidos, o Emergency Severity Index (ESI) combina gravidade e previsão dos recursos que o atendimento vai exigir, também em cinco níveis (Gilboy et al., 2011).

Os protocolos padronizam a decisão, mas não a tornam infalível. Uma revisão sistemática sobre o Sistema Manchester apontou boa capacidade de prever internação e óbito, ao lado de confiabilidade variável e de desempenho menos consistente em alguns grupos de pacientes (Azeredo et al., 2015). A meta-análise de Zachariasse et al. (2019), que comparou diferentes sistemas de triagem, chegou a conclusão parecida: o desempenho oscila bastante entre serviços e populações, e uma parcela relevante dos pacientes graves recebe prioridade menor que a necessária. No Brasil, Souza et al. (2011) encontraram concordância apenas moderada entre um protocolo institucional e o Manchester, o que mostra quanto a classificação depende do instrumento adotado e de quem o aplica. Some-se a isso a superlotação, a rotatividade das equipes e a pressão do tempo, e a triagem se torna um ponto frágil do atendimento.

Foi nesse ponto que a inteligência artificial (IA) entrou no debate. Modelos de aprendizado de

máquina conseguem analisar ao mesmo tempo sinais vitais, idade, queixa principal, comorbidades e histórico de atendimentos, e estimar a probabilidade de desfechos como internação em terapia intensiva ou óbito (Rajkomar; Dean; Kohane, 2019). Pesquisas feitas em serviços norte-americanos mostraram que esses modelos diferenciam melhor os pacientes quanto à gravidade do que a triagem convencional (Levin et al., 2018; Raita et al., 2019). O entusiasmo vem acompanhado de alertas: algoritmos podem reproduzir desigualdades presentes nos dados com que foram treinados (Obermeyer et al., 2019), e a Organização Mundial da Saúde recomenda que a decisão clínica permaneça sob controle humano (World Health Organization, 2021). Daí a pergunta que orienta este trabalho: de que forma a inteligência artificial pode apoiar o enfermeiro na classificação de risco, e que cuidados essa incorporação exige?

A relevância do tema está na posição que o enfermeiro ocupa nessa discussão. Se ferramentas de IA chegarem às salas de classificação, será ele quem vai operá-las, interpretar o que indicam e responder pela decisão final. Boa parte da produção sobre o assunto, contudo, vem da medicina e da ciência de dados e pouco trata do trabalho da enfermagem, lacuna que Ronquillo et al. (2021) apontam ao defender a participação dos enfermeiros no desenvolvimento e na avaliação dessas tecnologias. Há ainda um motivo prático. Os futuros enfermeiros vão encontrar essas ferramentas no mercado de trabalho, talvez antes de os serviços terem regras claras para usá-las, e precisam chegar lá sabendo o que elas fazem bem e onde falham. Reunir o que já se sabe, com o olhar da enfermagem, ajuda a preparar uma incorporação que seja segura para o paciente e dê respaldo ao profissional.

Diante disso, o objetivo geral deste estudo é analisar, a partir da literatura científica, as contribuições da inteligência artificial como ferramenta de apoio à classificação de risco em serviços de urgência e emergência e suas implicações para a atuação do enfermeiro. Os objetivos específicos são descrever os modelos de IA aplicados à triagem e seu desempenho em comparação com os protocolos convencionais; identificar os limites técnicos, éticos e legais do uso dessas ferramentas; e discutir o papel do enfermeiro na incorporação da IA ao processo de classificação de risco.

2 MATERIAL E MÉTODOS

Trata-se de revisão narrativa da literatura, modalidade adequada para discutir o estado da arte de um tema sob ponto de vista teórico e contextual, sem a exigência de um protocolo sistemático de busca (Rother, 2007). A pesquisa tem abordagem qualitativa e caráter exploratório (Gil, 2017). As buscas ocorreram nas bases SciELO, LILACS, por meio da Biblioteca Virtual em Saúde, e PubMed, com os descritores “inteligência artificial”, “aprendizado de máquina”, “triagem”, “classificação de risco” e “enfermagem em emergência” e seus equivalentes em inglês, combinados pelos operadores AND e OR. Entraram artigos originais e de revisão publicados entre 2010 e 2025, em português ou inglês, disponíveis na íntegra, que tratassem da classificação de risco em urgência e emergência ou do uso de IA nesse processo. Ficaram de fora estudos sobre triagem em desastres e incidentes com múltiplas vítimas, resumos de eventos e textos opinativos. Somaram-se ao material, independentemente do ano, as obras de referência dos protocolos de triagem, a legislação brasileira sobre o exercício da enfermagem e a proteção de dados, a norma do Conselho Federal de Enfermagem sobre classificação de risco e a orientação da Organização Mundial da Saúde sobre IA em saúde. Quinze artigos científicos atenderam a esses critérios e compuseram o corpus principal da análise, ao lado de nove documentos normativos e obras de referência. Os textos foram lidos na íntegra e submetidos a análise temática, que os distribuiu nos quatro eixos usados para organizar a seção

seguinte.

3 RESULTADOS E DISCUSSÃO

3.1 A classificação de risco entre o protocolo e o julgamento clínico

Para o Ministério da Saúde, classificar risco não é excluir ninguém do atendimento, e sim organizar a ordem em que os pacientes serão vistos, de acordo com o potencial de agravamento de cada caso (Brasil, 2009). A distinção muda o foco da triagem. O que se busca ali não é um diagnóstico, mas uma estimativa de risco feita com o que está disponível naquele momento. Mendes (2011) situa essa função na lógica das redes de atenção, em que a porta de urgência precisa se comunicar com a atenção primária e com o hospital para que o paciente chegue ao ponto certo da rede.

O Sistema Manchester trabalha com fluxogramas organizados pela queixa principal. A partir dela, o enfermeiro percorre discriminadores como dor, nível de consciência, hemorragia e temperatura até chegar a uma das cinco categorias, do vermelho, que exige atendimento imediato, ao azul, que tolera até 240 minutos de espera (Mackway-Jones; Marsden; Windle, 2014). O ESI segue outro caminho: pergunta primeiro se o paciente precisa de intervenção imediata para salvar a vida, depois se está em situação de alto risco e, por último, quantos recursos o atendimento vai consumir (Gilboy et al., 2011). Os dois dão ao enfermeiro um roteiro. Ambos, porém, deixam espaço para interpretação, e é nesse espaço que surgem as divergências.

As revisões mostram onde estão os pontos fracos. Azeredo et al. (2015) observaram que o Manchester prevê bem a necessidade de internação e o risco de morte, mas que sua confiabilidade varia conforme o serviço e o perfil dos pacientes. Zachariasse et al. (2019) encontraram grande variação de desempenho entre os sistemas e entre os locais onde foram testados, com taxas de subtriagem que, em parte dos estudos, atingiam uma fração preocupante dos casos graves. A subtriagem é o erro mais perigoso, porque mantém na sala de espera quem deveria estar em atendimento. A supertriagem parece inofensiva, mas não é: num serviço lotado, cada paciente classificado acima da gravidade real ocupa um leito ou um profissional que fará falta a outro.

Nada disso desqualifica os protocolos, que seguem sendo a base da classificação de risco no país. O que esses achados revelam é que o enfermeiro decide sob condições que favorecem o erro: volume alto, tempo curto, informação parcial. Uma ferramenta de apoio só se justifica se atuar sobre essas condições.

3.2 O que os modelos de inteligência artificial acrescentam à triagem

Quase todos os estudos sobre IA na triagem usam aprendizado de máquina supervisionado. O algoritmo recebe milhares de atendimentos anteriores, cada um com as informações coletadas na triagem e o desfecho que o paciente teve, e aprende a reconhecer as combinações associadas a internação, transferência para terapia intensiva ou óbito (Rajkomar; Dean; Kohane, 2019). Um fluxograma segue regras fixas; o modelo pondera dezenas de variáveis ao mesmo tempo e devolve uma probabilidade. Sanchez-Pinto, Luo e Churpek (2018) lembram que foi a difusão do prontuário eletrônico que tornou esse tipo de análise possível, ao transformar registros clínicos de rotina em grandes bases de dados. O Quadro 1 reúne os estudos de maior peso encontrados nesta revisão.

O estudo de Levin et al. (2018) é dos mais citados. Os autores compararam ao ESI um sistema de triagem eletrônica baseado no algoritmo de floresta aleatória, em dois serviços de emergência norte-americanos. A ferramenta separou melhor os pacientes que precisariam de cuidados críticos, procedimentos

de emergência e internação, e conseguiu redistribuir parte dos casos que o ESI concentrava no nível 3. Esse nível intermediário é onde se misturam pacientes de gravidade muito distinta, e é também onde o julgamento humano mais hesita. Um apoio objetivo ali vale mais do que nos extremos, em que o enfermeiro raramente erra.

Quadro 1 – Estudos sobre inteligência artificial aplicada à triagem em urgência e emergência

Autor (ano)	Cenário e método	Principal achado
Levin et al. (2018)	Dois serviços de emergência dos EUA; triagem eletrônica com floresta aleatória comparada ao ESI	Melhor diferenciação dos pacientes quanto a cuidados críticos, procedimentos de emergência e internação; redistribuição de parte dos casos do nível 3 do ESI
Hong, Haimovich e Taylor (2018)	Três serviços de emergência dos EUA; modelos com dados da triagem e do histórico do paciente	Previsão de internação com área sob a curva acima de 0,90 quando o histórico foi incluído
Raita et al. (2019)	Inquérito nacional dos EUA com adultos; quatro modelos de aprendizado de máquina	Melhor previsão de cuidados críticos e internação que o modelo de referência, com menos subtriagem
Goto et al. (2019)	Mesma base nacional, com crianças	Ganho de desempenho também na triagem pediátrica
Kang et al. (2020)	Atendimento préhospitalar na Coreia do Sul; aprendizado profundo	Previsão da necessidade de cuidados críticos superior à dos escores convencionais
Kareemi et al. (2021)	Revisão sistemática sobre aprendizado de máquina em emergência	Desempenho geralmente superior ao cuidado usual, mas com alto risco de viés e poucos estudos prospectivos

Fonte: elaborado pelos autores (2026).

Raita et al. (2019) chegaram a resultado semelhante com dados de um inquérito nacional dos Estados Unidos. Quatro modelos, entre eles redes neurais e combinações de árvores de decisão, previram melhor que o modelo de referência a necessidade de cuidados críticos e de internação, e reduziram o número de pacientes críticos classificados abaixo da gravidade real. Goto et al. (2019) repetiram a análise com crianças e também encontraram ganho, achado que interessa porque a triagem pediátrica costuma ser difícil para os protocolos convencionais. Hong, Haimovich e Taylor (2018) mostraram, por sua vez, que o desempenho sobe quando o modelo recebe, além dos dados da triagem, o histórico do paciente, como atendimentos anteriores e medicações em uso; com essas informações, a previsão de internação ultrapassou 0,90 de área sob a curva.

Fora do hospital, Kang et al. (2020) desenvolveram na Coreia do Sul um algoritmo capaz de estimar, ainda no atendimento pré-hospitalar, quais pacientes precisariam de cuidados críticos, com desempenho superior ao dos escores tradicionais. Se essa informação chegasse ao pronto-socorro antes da ambulância, a equipe poderia se preparar para receber o caso.

O conjunto é promissor. As revisões que reuniram esses estudos, no entanto, fazem uma ressalva que muda a leitura dos números. Fernandes et al. (2020) verificaram que a maioria dos sistemas de apoio à decisão na triagem foi avaliada de forma retrospectiva, com dados já registrados, e que poucos chegaram a funcionar na rotina de um serviço. Kareemi et al. (2021) concluíram que o aprendizado de máquina costuma superar o cuidado usual nas predições feitas em emergência, mas classificaram boa parte dos estudos como de alto risco de viés e encontraram raríssimas avaliações prospectivas. Sabe-se, portanto, que os modelos acertam bem quando analisam o passado. Sobre o que acontece quando entram na sala de classificação, ao lado de um enfermeiro e diante de um paciente real, ainda se sabe pouco.

Os estudos também deixam ver como esses sistemas costumam ser pensados para a prática. Nenhum dos estudos propõe que o algoritmo atribua a cor ao paciente no lugar do enfermeiro. O desenho mais comum é o de um alerta: o modelo calcula o risco em segundo plano e sinaliza quando sua estimativa diverge da categoria escolhida, sobretudo quando aponta gravidade maior. Fernandes et al. (2020) descrevem essas ferramentas como sistemas de apoio à decisão, e não de decisão automática. Esse formato preserva o protocolo já conhecido pela equipe e acrescenta uma segunda opinião nos casos em que ela pode evitar uma subtriagem.

Pesa também o contexto. Os modelos de melhor desempenho foram desenvolvidos com dados dos Estados Unidos e da Ásia, em serviços com prontuário eletrônico consolidado. Muitos prontos-socorros e unidades de pronto atendimento brasileiros trabalham com registros incompletos, sistemas que não se comunicam e, em alguns lugares, ficha em papel. Um modelo treinado em outra população pode perder desempenho quando aplicado aqui, e Topol (2019) insiste que ferramentas de IA em saúde só deveriam chegar à prática depois de validadas nos cenários em que serão usadas. Para o Brasil, essa validação ainda não existe.

3.3 Limites técnicos, éticos e legais

O caso mais conhecido de viés algorítmico na saúde não envolve triagem, mas ajuda a dimensionar o risco. Obermeyer et al. (2019) examinaram um algoritmo usado nos Estados Unidos para indicar quais pacientes deveriam receber acompanhamento intensivo e descobriram que ele subestimava a necessidade de pacientes negros. Nenhuma variável racial aparecia no modelo. O problema estava na escolha do gasto com saúde como medida de necessidade: como pacientes negros, por barreiras de acesso, gastavam menos com o mesmo nível de doença, pareciam mais saudáveis do que eram. Na classificação de risco, o raciocínio é o mesmo. Um modelo treinado com dados de serviços em que certos grupos chegam mais tarde ou têm sinais subnotificados pode aprender a colocá-los abaixo da gravidade real.

Outro limite é a opacidade. Muitos dos modelos com melhor desempenho, como as redes neurais profundas, não mostram por que chegaram a determinado resultado, e Rajkomar, Dean e Kohane (2019) observam que essa falta de transparência dificulta tanto a confiança dos profissionais quanto a detecção de erros. Para quem classifica, a diferença é concreta. No protocolo, é possível apontar qual discriminador levou o paciente ao laranja. Um algoritmo opaco devolve apenas um número.

Em seu guia sobre ética e governança da IA em saúde, a Organização Mundial da Saúde estabeleceu seis princípios: proteger a autonomia humana; promover o bem-estar, a segurança e o interesse público; garantir transparência, explicabilidade e inteligibilidade; promover responsabilidade e prestação de contas; assegurar inclusão e equidade; e promover uma IA responsiva e sustentável (World Health Organization, 2021). Para a classificação de risco, o primeiro pesa mais que os outros, porque estabelece que as decisões clínicas continuam nas mãos de pessoas.

No plano legal, dois pontos se destacam no Brasil. A Lei Geral de Proteção de Dados Pessoais classifica as informações referentes à saúde como dados pessoais sensíveis, sujeitos a regras mais rígidas de tratamento (Brasil, 2018), o que alcança tanto o treinamento dos modelos quanto seu uso no plantão. O segundo ponto é a responsabilidade profissional. Sendo a classificação de risco atividade privativa do enfermeiro (Conselho Federal de Enfermagem, 2021), a decisão final é dele, mesmo quando o sistema sugere outra categoria. A ferramenta pode sugerir, mas quem classifica, e responde pela classificação, é o

enfermeiro.

3.4 O enfermeiro diante da inteligência artificial na classificação de risco

Se a IA não substitui o enfermeiro, o que muda no trabalho dele? A primeira mudança está na própria decisão. Hoje, o enfermeiro classifica a partir do que observa e do que o protocolo indica. Com uma ferramenta de apoio, passa a ter uma terceira referência, a estimativa do algoritmo, que pode concordar ou não com as outras duas. Quando o enfermeiro percebe uma coisa e o sistema calcula outra, a divergência não precisa ser lida como erro de um dos lados; é um sinal para reavaliar o paciente. Um idoso com sinais vitais estáveis e queixa vaga pode receber do modelo um risco alto por causa do histórico de internações, enquanto o enfermeiro nota uma palidez ou uma confusão leve que nenhum campo do sistema registrou. As duas leituras se completam, e os estudos de Levin et al. (2018) e Raita et al. (2019) sugerem que o ganho da IA aparece justamente em casos assim, de aparência intermediária.

Existe também o risco contrário, o de confiar demais. É o chamado viés de automação, a tendência de aceitar a recomendação de um sistema sem questioná-la, que costuma crescer nos plantões mais cheios, quando o cansaço empurra para o atalho. Uma ferramenta que deveria ampliar o olhar clínico acabaria, nesse caso, por substituí-lo na prática, ainda que não no papel.

A segunda mudança está na formação. Ronquillo et al. (2021), a partir de um encontro internacional de lideranças da enfermagem e da informática em saúde, defendem que os enfermeiros compreendam o funcionamento básico dessas tecnologias e participem de seu desenvolvimento, em vez de recebê-las prontas. Ninguém espera que o enfermeiro vire programador. Espera-se que saiba perguntar com que dados o modelo foi treinado, em que população foi validado e em quais situações costuma errar. Esse tipo de conhecimento ainda aparece pouco na graduação e nas capacitações sobre classificação de risco.

A terceira mudança diz respeito ao registro. Todo modelo de IA depende da qualidade dos dados que recebe, e na triagem quem produz esses dados é a enfermagem: sinais vitais, queixa principal, escala de dor, horário de chegada. Um registro incompleto ou feito às pressas alimenta mal o algoritmo e piora a estimativa que ele devolve. O tempo que a tecnologia economizar em cálculos e conferências, por outro lado, deveria voltar para o paciente, na escuta e na reavaliação de quem está esperando, que é o que o acolhimento proposto pelo Ministério da Saúde pede (Brasil, 2009).

Há, por fim, o acompanhamento depois da implantação. Um modelo que funciona bem no primeiro ano pode perder precisão quando muda o perfil dos pacientes, como ocorre em epidemias ou na abertura de um novo serviço na região. Monitorar esse desempenho exige comparar periodicamente a classificação sugerida, a classificação feita e o desfecho de cada paciente, tarefa que se aproxima da auditoria da classificação de risco que muitos serviços já atribuem aos enfermeiros. Quem conhece o fluxo da porta de entrada está em boa posição para perceber quando a ferramenta começou a errar.

O que se desenha é um enfermeiro que continua no centro da classificação de risco, agora com mais um instrumento à mão. A IA pode reduzir a subtriagem, ajudar nos casos duvidosos e antecipar informações. Não pode responder pela decisão, perceber o que não foi registrado nem acolher quem chega com medo. Para que sua incorporação seja segura nos serviços brasileiros, faltam estudos de validação com dados nacionais, regras claras sobre a responsabilidade de cada parte e formação específica para os profissionais que vão usá-la.

4 CONCLUSÃO

A literatura analisada mostra que modelos de inteligência artificial superam a triagem convencional na identificação de pacientes graves, sobretudo ao reduzir a subtriagem nos casos de gravidade intermediária. Esse ganho, porém, vem de estudos em sua maioria retrospectivos e estrangeiros, e esbarra no risco de vieses, na opacidade dos algoritmos e nas exigências da proteção de dados.

Para a enfermagem, a inteligência artificial deve ser entendida como apoio ao julgamento clínico, e não como substituto dele. A decisão continua sendo do enfermeiro, que precisará de formação para usar essas ferramentas com senso crítico, de registros de triagem completos para que o modelo receba bons dados e de regras claras sobre quem responde por cada etapa da classificação.

A contribuição deste estudo está em reunir, sob o olhar da enfermagem, evidências que circulam sobretudo em periódicos de medicina e de ciência de dados, e em traduzi-las em pontos práticos para quem classifica: a ferramenta pensada como alerta nos casos duvidosos, a qualidade do registro como condição do desempenho e o monitoramento do modelo depois da implantação como tarefa da equipe.

Por se tratar de revisão narrativa, sem protocolo sistemático de busca nem avaliação formal da qualidade dos estudos, este trabalho não esgota o tema, e a seleção do material pode ter deixado de fora pesquisas relevantes. Como perspectivas, ficam três frentes: estudos que validem modelos com dados de serviços brasileiros, avaliações prospectivas em salas de classificação reais e pesquisas sobre a formação dos enfermeiros para trabalhar com essas ferramentas.

REFERÊNCIAS

AZEREDO, T. R. M. et al. Efficacy of the Manchester Triage System: a systematic review. International Emergency Nursing, v. 23, n. 2, p. 47-52, 2015. DOI: 10.1016/j.ienj.2014.06.001.

BRASIL. Lei nº 7.498, de 25 de junho de 1986. Dispõe sobre a regulamentação do exercício da enfermagem, e dá outras providências. Diário Oficial da União: seção 1, Brasília, DF, p. 9273, 26 jun. 1986. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/l7498.htm. Acesso em: 23 out. 2026.

BRASIL. Ministério da Saúde. Acolhimento e classificação de risco nos serviços de urgência. Brasília: Ministério da Saúde, 2009. 56 p. Disponível em: https://bvsms.saude.gov.br/bvs/publicacoes/acolhimento_classificaao_risco_servico_urgencia.pdf. Acesso em: 23 out. 2026.

BRASIL. Ministério da Saúde. Portaria nº 1.600, de 7 de julho de 2011. Reformula a Política Nacional de Atenção às Urgências e institui a Rede de Atenção às Urgências no Sistema Único de Saúde (SUS). Diário Oficial da União: seção 1, Brasília, DF, 8 jul. 2011.

BRASIL. Lei nº 13.709, de 14 de agosto de 2018. Lei Geral de Proteção de Dados Pessoais (LGPD). Diário Oficial da União: seção 1, Brasília, DF, p. 59, 15 ago. 2018. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/l13709.htm. Acesso em: 23 out. 2026.

CONSELHO FEDERAL DE ENFERMAGEM (Brasil). Resolução Cofen nº 661/2021. Atualiza e normatiza, no âmbito do Sistema Cofen/Conselhos Regionais de Enfermagem, a participação da Equipe de Enfermagem na atividade de Classificação de Risco. Brasília, DF: Cofen, 2021. Disponível em: https://www.cofen.gov.br/resolucao-cofen-no-661-2021. Acesso em: 23 out. 2026.

FERNANDES, M. et al. Clinical decision support systems for triage in the emergency department using intelligent systems: a review. Artificial Intelligence in Medicine, v. 102, 101762, 2020. DOI: 10.1016/j.artmed.2019.101762.

GIL, A. C. Como elaborar projetos de pesquisa. 6. ed. São Paulo: Atlas, 2017.

GILBOY, N. et al. Emergency Severity Index (ESI): a triage tool for emergency department care, version 4. Implementation handbook 2012 edition. Rockville, MD: Agency for Healthcare Research and Quality, 2011. (AHRQ Publication No. 12-0014).

GOTO, T. et al. Machine learning-based prediction of clinical outcomes for children during emergency department triage. JAMA Network Open, v. 2, n. 1, e186937, 2019. DOI: 10.1001/jamanetworkopen.2018.6937.

HONG, W. S.; HAIMOVICH, A. D.; TAYLOR, R. A. Predicting hospital admission at emergency department triage using machine learning. PLoS ONE, v. 13, n. 7, e0201016, 2018. DOI: 10.1371/journal.pone.0201016.

KANG, D. Y. et al. Artificial intelligence algorithm to predict the need for critical care in prehospital emergency medical services. Scandinavian Journal of Trauma, Resuscitation and Emergency Medicine, v. 28, 17, 2020. DOI: 10.1186/s13049-020-0713-4.

KAREEMI, H. et al. Machine learning versus usual care for diagnostic and prognostic prediction in the emergency department: a systematic review. Academic Emergency Medicine, v. 28, n. 2, p. 184-196, 2021. DOI: 10.1111/acem.14190.

LEVIN, S. et al. Machine-learning-based electronic triage more accurately differentiates patients with respect to clinical outcomes compared with the Emergency Severity Index. Annals of Emergency Medicine, v. 71, n. 5, p. 565-574.e2, 2018. DOI: 10.1016/j.annemergmed.2017.08.005.

MACKWAY-JONES, K.; MARSDEN, J.; WINDLE, J. (ed.). Emergency triage: Manchester Triage Group. 3. ed. Chichester: Wiley Blackwell: BMJ Books, 2014.
MENDES, E. V. As redes de atenção à saúde. 2. ed. Brasília: Organização Pan-Americana da Saúde, 2011. 549 p.

OBERMEYER, Z. et al. Dissecting racial bias in an algorithm used to manage the health of populations. Science, v. 366, n. 6464, p. 447-453, 2019. DOI: 10.1126/science.aax2342.

RAITA, Y. et al. Emergency department triage prediction of clinical outcomes using machine learning models. Critical Care, v. 23, 64, 2019. DOI: 10.1186/s13054-019-2351-7.

RAJKOMAR, A.; DEAN, J.; KOHANE, I. Machine learning in medicine. New England Journal of Medicine, v. 380, n. 14, p. 1347-1358, 2019. DOI: 10.1056/NEJMra1814259.

RONQUILLO, C. E. et al. Artificial intelligence in nursing: priorities and opportunities from an international invitational think-tank of the Nursing and Artificial Intelligence Leadership Collaborative. Journal of Advanced Nursing, v. 77, n. 9, p. 3707-3717, 2021. DOI: 10.1111/jan.14855.

ROTHER, E. T. Revisão sistemática X revisão narrativa. Acta Paulista de Enfermagem, São Paulo, v. 20, n. 2, p. v-vi, abr./jun. 2007.
SANCHEZ-PINTO, L. N.; LUO, Y.; CHURPEK, M. M. Big data and data science in critical care. Chest, v. 154, n. 5, p. 1239-1248, 2018. DOI: 10.1016/j.chest.2018.04.037.

SOUZA, C. C. et al. Classificação de risco em pronto-socorro: concordância entre um protocolo

institucional brasileiro e Manchester. Revista Latino-Americana de Enfermagem, Ribeirão Preto, v. 19, n. 1, p. 26-33, 2011. DOI: 10.1590/S0104-11692011000100005.

TOPOL, E. J. High-performance medicine: the convergence of human and artificial intelligence. Nature Medicine, v. 25, n. 1, p. 44-56, 2019. DOI: 10.1038/s41591-018-0300-7.

WORLD HEALTH ORGANIZATION. Ethics and governance of artificial intelligence for health: WHO guidance. Geneva: World Health Organization, 2021. Disponível em: https://www.who.int/publications/i/item/9789240029200. Acesso em: 23 out. 2026.

ZACHARIASSE, J. M. et al. Performance of triage systems in emergency care: a systematic review and meta-analysis. BMJ Open, v. 9, n. 5, e026471, 2019. DOI: 10.1136/bmjopen-2018-026471.