REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

O USO DA INTELIGÊNCIA ARTIFICIAL NO AUXÍLIO DA TRIAGEM DE ADULTOS EM SERVIÇOS DE EMERGÊNCIA

THE USE OF ARTIFICIAL INTELLIGENCE IN ASSISTING ADULT TRIAGE IN EMERGENCY SERVICES

EL USO DE LA INTELIGENCIA ARTIFICIAL EN EL APOYO AL TRIAJE DE ADULTOS EN SERVICIOS DE EMERGENCIA

Leônidas das Graças Mendes Júnior[1], Genilson Marcio de Lima[1], João Oliveira Tavares[1], Larissa Rebeca Antunes Mendonça[1], Thaynan Silva Narciso[1]

e6106821
https://doi.org/10.47820/recima21.v6i10.6821

PUBLICADO: 10/2025

RESUMO

Objetivo: Analisar, por meio de uma revisão bibliográfica integrativa, como a Inteligência Artificial (IA) pode auxiliar na classificação de risco de pacientes adultos em serviços de emergência, melhorando a eficiência, a precisão e os desfechos clínicos. Método: Foi realizada uma revisão integrativa da literatura nas bases MeSH, DeCs, BVS e SciELO utilizando os descritores "inteligência artificial", "triagem de emergência" e "adultos". Foram incluídos artigos publicados entre 2019 e 2025, em português ou inglês, que abordassem aplicações práticas de IA na triagem com dados quantitativos de desempenho. Resultados: oito estudos foram incluídos na análise final. Os sistemas de IA demonstraram redução significativa no tempo de classificação comparados a métodos manuais, com algoritmos como redes neurais apresentando sensibilidade superior na detecção de casos graves. O modelo KATE obteve 75,9% de acurácia *vs*. 59,8% de enfermeiros na atribuição de níveis ESI. Sistemas multimodais aumentaram a sensibilidade em 10,94% para detecção de AVC. A IA reduziu o tempo mediano desde chegada até triagem em 33%. Conclusão: A IA mostra-se promissora na otimização da triagem em emergências, potencializando a segurança do paciente e a alocação de recursos. Contudo, sua implementação requer rigor ético, transparência algorítmica e adaptação às realidades locais, sempre mantendo supervisão humana qualificada.

PALAVRAS-CHAVE: Inteligência artificial. Triagem de emergência. Medicina de emergência. Tecnologia em saúde. Machine learning. Classificação de risco.

ABSTRACT

Objective: To analyze, through an integrative bibliographic review, how Artificial Intelligence (AI) can assist in risk classification of adult patients in emergency services, improving efficiency, accuracy and clinical outcomes. Method: An integrative literature review was conducted in MeSH, DeCs, VHL and SciELO databases using the descriptors "artificial intelligence", "emergency triage" and "adults". Articles published between 2019 and 2025, in Portuguese or English, addressing practical applications of AI in triage with quantitative performance data were included. Results: Eight studies were included in the final analysis. AI systems demonstrated significant reduction in classification time compared to manual methods, with algorithms such as neural networks showing superior sensitivity in detecting severe cases. The KATE model achieved 75.9% accuracy vs. 59.8% for nurses in ESI level assignment. Multimodal systems increased sensitivity by 10.94% for stroke detection. AI reduced median time from arrival to triage by 33%. Conclusion: AI shows promise in optimizing emergency triage, enhancing patient safety and resource allocation.

[1] AESGA: Autarquia do Ensino Superior de Garanhuns.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

However, its implementation requires ethical rigor, algorithmic transparency and adaptation to local realities, always maintaining qualified human supervision.

KEYWORDS: *Artificial intelligence. Emergency triage. Emergency medicine. Health technology. Machine learning. Risk classification.*

RESUMEN
Objetivo: Analizar, a través de una revisión bibliográfica integrativa, cómo la Inteligencia Artificial (IA) puede ayudar en la clasificación de riesgo de pacientes adultos en servicios de emergencia, mejorando la eficiencia, precisión y resultados clínicos. Método: Se realizó una revisión integrativa de literatura en las bases MeSH, DeCs, BVS y SciELO utilizando los descriptores "inteligencia artificial", "triaje de emergencia" y "adultos". Se incluyeron artículos publicados entre 2019 y 2025, en portugués o inglés, que abordaran aplicaciones prácticas de IA en triaje con datos cuantitativos de desempeño. Resultados: ocho estudios fueron incluidos en el análisis final. Los sistemas de IA demostraron reducción significativa en el tiempo de clasificación comparado con métodos manuales, con algoritmos como redes neuronales presentando sensibilidad superior en la detección de casos graves. El modelo KATE obtuvo 75,9% de precisión vs. 59,8% de enfermeros en la asignación de niveles ESI. Sistemas multimodales aumentaron la sensibilidad en 10,94% para detección de ACV. La IA redujo el tiempo mediano desde llegada hasta triaje en 33%. Conclusión: La IA se muestra prometedora en la optimización del triaje en emergencias, potenciando la seguridad del paciente y la asignación de recursos. Sin embargo, su implementación requiere rigor ético, transparencia algorítmica y adaptación a las realidades locales, manteniendo siempre supervisión humana calificada.

PALABRAS CLAVE: *Inteligencia artificial. Triaje de emergência. Medicina de emergência. Tecnología en salud. Machine learning. Clasificación de riesgo.*

1. INTRODUÇÃO

A crescente demanda por serviços de emergência, impulsionada pelo envelhecimento populacional e pela complexidade dos casos clínicos, tem sobrecarregado sistemas de saúde em todo o mundo (27). Nesse contexto, a etapa de triagem (classificação de risco que define a prioridade de atendimento) tornou-se um gargalo crítico, impactando diretamente a eficiência dos serviços e os desfechos dos pacientes.

Tradicionalmente, a triagem é realizada mundialmente por profissionais de saúde utilizando protocolos manuais, como o *Manchester Triage System* (MTS) ou o *Emergency Severity Index* (ESI), que dependem da experiência clínica e estão sujeitos a variações subjetivas (29). Esses métodos, embora consolidados, enfrentam desafios como demora na avaliação, erros de classificação (particularmente a subestimação de casos graves) e sobrecarga da equipe, especialmente em cenários de alta demanda.

Diante desses obstáculos, a Inteligência Artificial (IA) emerge como uma ferramenta transformadora, capaz de otimizar a triagem por meio da automatização e da análise preditiva (6). Algoritmos de *machine learning* e processamento de linguagem natural (PLN) podem processar grandes volumes de dados (sinais vitais, histórico médico, imagens radiológicas e relatos textuais de sintomas), identificando padrões que humanos poderiam negligenciar (2).

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

A capacidade computacional atual permite que sistemas de IA analisem informações complexas em tempo real, emulando e por vezes superando a capacidade humana de interpretação de dados clínicos múltiplos (12).

Sistemas baseados em IA já demonstraram capacidade de prever sepse horas antes da deterioração clínica evidente, classificar risco de acidente vascular cerebral (AVC) com maior precisão que métodos convencionais e reduzir significativamente o tempo de triagem (16,43,10). Essas aplicações não apenas melhoram a eficiência operacional, mas elevam a segurança do paciente, garantindo que casos urgentes recebam atenção imediata.

Técnicas como redes neurais profundas e aprendizado supervisionado permitem que modelos sejam treinados com registros de milhares de pacientes, reconhecendo correlações entre variáveis clínicas e prováveis desfechos adversos. Ferramentas de visão computacional automatizam a análise de exames de imagem, enquanto *chatbots* com PLN auxiliam na coleta inicial de sintomas, direcionando casos prioritários para avaliação humana (38).

A implementação da IA na triagem não é isenta de desafios. Vieses algorítmicos (resultantes de bancos de dados desbalanceados ou sub-representação de grupos populacionais) podem levar a erros sistemáticos. Questões como privacidade de dados, transparência das decisões e integração com fluxos hospitalares também exigem atenção (45,41,1). Ainda assim, os benefícios potenciais são significativos: desde a otimização de recursos até a redução de mortalidade em condições que são mais dependentes de tempo, tal como infarto e trauma.

Esta revisão integrativa busca consolidar evidências sobre os avanços da IA na triagem de adultos em emergências, analisando criticamente estudos que aplicaram essas tecnologias na prática clínica. O foco recairá sobre resultados mensuráveis (como ganho de tempo, precisão diagnóstica e impacto clínico) além de discutir barreiras práticas e éticas para a adoção em larga escala.

2. REFERENCIAL TEÓRICO

2.1. Sistemas de triagem tradicionais em emergências

Os serviços de emergência utilizam sistemas de triagem padronizados para classificar pacientes segundo a gravidade e urgência de seus casos. O *Manchester Triage System* (MTS), amplamente adotado internacionalmente, categoriza pacientes em cinco níveis de prioridade baseados em discriminadores clínicos específicos e tempos-alvo para atendimento médico (47,3,18). Similarmente, o *Emergency Severity Index* (ESI) utiliza algoritmos de decisão que consideram estabilidade vital e necessidade de recursos (48).

Estudos recentes demonstram que ambos os sistemas apresentam desempenho adequado na predição de admissões hospitalares, com o ESI mostrando-se superior ao MTS

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

neste aspecto específico (42). A sensibilidade do MTS varia entre 47 e 87% em diferentes hospitais, com especificidade de 84 a 94% para triagem de pacientes adultos (47).

Apesar de sua eficácia comprovada, esses sistemas apresentam limitações inerentes (9). A variabilidade entre observadores, a dependência da experiência clínica do agente de triagem e a sobrecarga cognitiva em períodos de alta demanda podem comprometer a precisão das classificações (33). Estudos demonstram concordância entre enfermeiros treinados de 90% para o MTS e 73% para o ESI, com Kappa inter-observador de 76% para MTS e 46% para ESI. Uma revisão sistemática identificou alta taxa de subtriagem e baixa sensibilidade na predição de níveis de maior urgência (32).

2.2. Fundamentos da Inteligência Artificial aplicada à saúde

A inteligência artificial em saúde engloba diversas técnicas computacionais capazes de simular processos cognitivos humanos para análise, interpretação e tomada de decisão baseada em dados clínicos (2,28,25). *Machine learning*, subcampo da IA, permite que algoritmos aprendam padrões complexos a partir de grandes conjuntos de dados sem programação explícita para cada situação específica (40).

Revisões sistemáticas recentes demonstram que a IA tem potencial transformador na prática médica, melhorando eficiência, precisão diagnóstica e resultados clínicos (4,23,11). A adoção de sistemas de IA em hospitais é influenciada por fatores macroeconômicos, regulatórios, tecnológicos, organizacionais e individuais (26).

Redes neurais artificiais, inspiradas no funcionamento do cérebro humano, processam informações através de camadas interconectadas de neurônios artificiais. *Deep learning*, uma extensão das redes neurais com múltiplas camadas ocultas, demonstra capacidade excepcional para reconhecimento de padrões em dados não estruturados, como imagens médicas e texto livre (17,36).

2.3. Processamento de linguagem natural em registros médicos

O Processamento de Linguagem Natural (PLN) capacita sistemas computacionais a compreender, interpretar e gerar linguagem humana, sendo particularmente útil para extrair informações clínicas relevantes de registros médicos eletrônicos (13,39,5). Aproximadamente 80% dos dados em prontuários eletrônicos existem em formato não estruturado, consistindo em textos livres com jargão médico, abreviações e anotações clínicas (46).

Revisões sistemáticas recentes identificaram que o PLN é amplamente utilizado para classificação de notas médicas, reconhecimento de entidades clínicas, extração de informações e análise de registros eletrônicos (39). As aplicações mais comuns incluem classificação CID-9, análise de notas clínicas e reconhecimento de entidades nomeadas para descrições clínicas (16).

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

Modelos de linguagem de grande escala, como o GatorTron com mais de 90 bilhões de palavras de texto clínico, demonstram capacidade superior em tarefas de PLN clínico, incluindo extração de conceitos, relações médicas e inferência de linguagem natural (46). O PLN mostra-se promissor para análise de sentimentos em saúde pública, triagem de prontuários eletrônicos e identificação automatizada de candidatos para ensaios clínicos (16).

2.4. Aplicações emergentes de IA na Triagem Médica

Sistemas de apoio à decisão clínica baseados em IA começam a demonstrar superioridade em várias aplicações de triagem. Algoritmos de *machine learning* treinados com dados históricos de pacientes podem predizer deterioração clínica, identificar sepse precoce e estratificar risco cardiovascular com desempenho superior aos métodos convencionais (24,30,34). A integração de múltiplas modalidades de dados (sinais vitais, exames laboratoriais, imagens radiológicas e texto livre) permite análise holística do estado clínico do paciente (20). Sistemas multimodais demonstram capacidade de detectar padrões sutis que podem escapar à percepção humana, especialmente em cenários de fadiga ou sobrecarga cognitiva (7).

Ferramentas de visão computacional aplicadas à análise de imagens médicas automatizam a detecção de achados radiológicos relevantes para triagem, como pneumotórax, fraturas ou sinais de AVC agudo. Esses sistemas podem processar imagens em segundos, fornecendo alertas imediatos para condições que requerem intervenção urgente (31,44).

Estudos demonstram que sistemas de IA reduzem significativamente o tempo de triagem, melhoram a detecção de eventos adversos, predizem erros de medicação e avaliam riscos de quedas (37). Contudo, permanecem desafios relacionados a questões sociotécnicas, barreiras de implementação e necessidade de padronização (1).

3. MÉTODOS

Para esta revisão integrativa sobre aplicação de Inteligência Artificial em triagem de emergência adulta, realizou-se uma busca sistemática nas principais bases indexadoras da literatura científica em saúde. A estratégia de pesquisa foi elaborada utilizando os sistemas de vocabulário controlado MeSH *(Medical Subject Headings)* para buscas no PubMed/MEDLINE e DeCs (Descritores em Ciências da Saúde) para as bases regionais.

3.1. Estratégia de busca

A pesquisa abrangeu quatro plataformas. (1) PubMed: utilizando descritores MeSH para recuperação precisa da literatura internacional. (2) Biblioteca Virtual em Saúde (BVS): integrando fontes de informação científica da América Latina. (3) SciELO: representando a produção

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

científica de qualidade da região. E (4) LILACS: através da BVS, para garantir ampla cobertura da literatura latino-americana.

3.2. Termos de busca

PubMed: ("*Artificial Intelligence*"[Mesh] *OR* "*Machine Learning*"[Mesh]) *AND* ("Triage"[Mesh]) *AND* ("*Emergency Medical Services*"[Mesh]) *AND* ("*Adult*"[Mesh]).

BVS/SciELO/LILACS: "Inteligência Artificial" OU "Aprendizado de Máquina" E "Triagem" E "Serviços Médicos de Emergência" E "Adulto".

3.3. Critérios de inclusão e exclusão

Critérios de inclusão: artigos publicados entre 2019-2025; idiomas: português ou inglês; aplicações práticas de IA em sistemas de triagem; dados quantitativos de desempenho; e estudos com amostras ≥ 100 pacientes.

Critérios de exclusão: estudos meramente teóricos; relatos de caso isolados; pesquisas com amostras < 100 pacientes; e artigos sem dados de desempenho mensuráveis.

3.4. Processo de Seleção

O processo seguiu três etapas: triagem inicial por título e resumo; leitura na íntegra dos artigos potencialmente relevantes; e avaliação crítica da qualidade metodológica. Os dados extraídos incluíram características dos algoritmos, métricas de desempenho e contexto de implementação.

4. RESULTADOS E DISCUSSÃO

4.1. Análise bibliométrica descritiva dos principais achados

A busca sistemática resultou na identificação inicial de 847 artigos, dos quais 134 foram selecionados para leitura completa após triagem por título e resumo. Aplicando-se os critérios de inclusão e exclusão estabelecidos, 8 estudos foram incluídos na análise final, abrangendo o período de 2019 a 2025.

Distribuição temporal e geográfica: Os estudos concentram-se no período de 2020-2022, representando 57% das publicações analisadas, com clara predominância de pesquisas conduzidas na América do Norte (57%) e Europa (29%). Esta concentração geográfica indica uma lacuna significativa na representação de países em desenvolvimento, limitando a generalização dos achados para contextos de recursos limitados.

Características metodológicas: A maioria dos estudos (71%) utilizou delineamento retrospectivo, baseando-se em análise de prontuários eletrônicos históricos. O tamanho das amostras variou consideravelmente, desde 1.247 até 284.470 pacientes, com mediana de

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

aproximadamente 15.000 casos, demonstrando robustez estatística adequada na maior parte das investigações.

Tecnologias e aplicações: As redes neurais emergiram como a tecnologia mais frequentemente empregada (43% dos estudos), seguidas por sistemas de *machine learning* como o modelo KATE (29%). Observa-se uma evolução temporal clara: estudos iniciais focavam em algoritmos básicos, enquanto pesquisas mais recentes exploram abordagens multimodais e sistemas híbridos mais sofisticados.

Resultados de desempenho: Os achados demonstram consistência nos benefícios da IA, com reduções temporais variando de 33% a 50% no tempo de triagem, e sensibilidade diagnóstica alcançando até 93,3% para detecção de sepse. Particularmente notável é o ganho de precisão de 16,1 pontos percentuais (75,9% *vs.* 59,8%) do modelo KATE em relação aos enfermeiros na atribuição de níveis ESI.

Lacunas identificadas: A análise revela ausência completa de estudos originários da América Latina, África ou Oceania, além de predominância de estudos observacionais em detrimento de ensaios clínicos prospectivos. Esta limitação metodológica e geográfica compromete a aplicabilidade dos achados em cenários clínicos diversos e em sistemas de saúde com diferentes recursos e características organizacionais.

4.2. Principais Achados dos Estudos

Quadro 1. Principais estudos sobre IA na triagem de emergência adulta

Autor/Ano	Tipo de estudo	Principais Achados
Taylor *et al*. – 2025 (37)	Estudo prospectivo	IA reduziu o tempo mediano desde chegada até triagem (-33%; 12 para 8 min), tempo até decisão de destino (-4,2%; 190 para 182 min) e tempo até saída do ED (-6,1%; 311 para 292 min).
Sun *et al*. – 2024 (35)	Simulação computacional	Sistema IA reduziu o tempo médio de espera no pronto-socorro de 4h para 2h (-50%) em simulação com base no MIMIC-ED.
Ivanov *et al*. – 2021 (15)	Estudo retrospectivo	Modelo KATE obteve maior precisão na atribuição de níveis ESI (75,9% *vs*. 59,8% de enfermeiros).
Helguera-Repetto *et al*. – 2020 (14)	Estudo retrospectivo	Rede neural para diagnóstico de sepse neonatal alcançou sensibilidade de 93,3% e especificidade de 80%.
Lin *et al*. – 2021 (21)	Estudo retrospectivo	Modelo de *machine learning* para identificar pacientes com sepse apresentou sensibilidade superior aos critérios

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

		SIRS, principalmente em casos críticos.
Lauritsen *et al*. – 2020 (19)	Estudo retrospectivo	CNN+LSTM detectou sepse com AUC 0,856 (3h antes) e 0,756 (24h antes).
Cai *et al*. – 2022 (8)	Estudo experimental	Sistema multimodal (vídeo + áudio) aumentou sensibilidade em 10,94% para AVC, com avaliação < 6 min.
Lynn (2019) (22)	Revisão narrativa	Sistemas de IA para tomada de decisão complexa em medicina de emergência requerem supervisão humana qualificada.

4.3. Impacto da IA na eficiência temporal da triagem

A integração de sistemas de inteligência artificial na triagem de emergências adultas apresenta potencial expressivo para otimizar fluxos e reduzir tempos críticos de atendimento. Evidências como as de Taylor *et al*. (2025) (37) mostram reduções consistentes no tempo até a triagem e na alta hospitalar, refletindo ganhos diretos na eficiência operacional.

O estudo ED-Copilot (Sun *et al*., 2024) (35) demonstrou que em ambiente simulado, reduções de 50% no tempo de espera. Do ponto de vista da precisão diagnóstica, Ivanov *et al*. (2021) (15) sugerem que melhorias no desempenho da classificação pelo ESI podem acelerar decisões e minimizar gargalos.

4.4. Desempenho diagnóstico de algoritmos de IA

Algoritmos de redes neurais e arquiteturas híbridas de *deep learning* têm demonstrado sensibilidade superior na detecção de condições graves. Helguera-Repetto *et al*. (2020) (14) obtiveram sensibilidade de 93,3% para sepse neonatal, superando protocolos convencionais.

Lin *et al*. (2021) (21) relataram que o modelo de *machine learning* para identificar pacientes com sepse apresentou sensibilidade superior aos critérios SIRS, principalmente em casos críticos. Lauritsen *et al*. (2020) (19) mostraram que combinações de CNN e LSTM conseguem prever sepse até 24 horas antes do início clínico, enquanto Cai *et al*. (2022) (8) usaram dados multimodais para rastrear AVC com sensibilidade quase 11% maior que a triagem padrão, em menos de seis minutos.

4.5. Desafios de implementação e integração clínica

A integração da IA aos fluxos hospitalares, conforme discutido por Lynn (2019) (22) e Van der Meijden *et al*. (2023) (41), só é segura e eficaz quando acompanhada por supervisão humana qualificada. Médicos e enfermeiros devem interpretar as recomendações da IA garantindo que limitações técnicas e contextuais não comprometam a segurança.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

As principais barreiras identificadas incluem: necessidade de grandes volumes de dados de qualidade para treinamento; resistência de profissionais à adoção de novas tecnologias; questões regulatórias e de responsabilidade médico-legal; custos elevados de implementação e manutenção; e necessidade de adaptação às especificidades locais de cada serviço.

4.6. Impacto da IA na equidade do atendimento em contextos de vulnerabilidade

A implementação de sistemas de IA na triagem de emergências apresenta implicações críticas para a equidade em saúde, particularmente no atendimento de populações vulneráveis. Embora a tecnologia prometa reduzir variabilidade nas decisões clínicas, evidências demonstram que algoritmos podem perpetuar ou amplificar disparidades existentes quando não desenvolvidos com atenção específica à justiça social (10,49).

Sistemas de IA são tão equitativos quanto os dados utilizados em seu treinamento. Algoritmos desenvolvidos predominantemente com dados de populações de alta renda ou etnicamente homogêneas apresentam desempenho inferior quando aplicados a grupos sub-representados (10,50). Um exemplo documentado envolve algoritmos de predição de risco que utilizavam gastos históricos com saúde como proxy para necessidade de cuidados, resultando em subestimação sistemática da gravidade clínica de pacientes negros (50). Similarmente, modelos de detecção de sepse desenvolvidos em contextos de países de alta renda demonstraram precisão significativamente reduzida em pacientes hispânicos devido a dados de treinamento desbalanceados (10,49).

Iniciativas de saúde digital que dependem de *smartphones* ou conectividade à internet excluem automaticamente segmentos significativos da população, incluindo idosos, mulheres em regiões rurais e comunidades de baixa renda (10). Em países em desenvolvimento, onde a infraestrutura de saúde já é deficiente, a implementação de IA sem adaptação local pode ampliar, ao invés de reduzir, as lacunas existentes no acesso ao cuidado (49).

Estudos recentes demonstram que vieses demográficos influenciam significativamente as classificações de gravidade na triagem. Pacientes do sexo feminino recebem sistematicamente níveis de prioridade mais baixos que pacientes masculinos apresentando condições clínicas idênticas (10). Fatores como etnia e *status* socioeconômico também influenciam decisões de triagem, mesmo quando clinicamente irrelevantes. Embora a IA tenha potencial para reduzir vieses humanos implícitos, algoritmos treinados em dados históricos tendenciosos simplesmente codificarão e escalarão essas discriminações (10,50).

Para que a IA contribua efetivamente para reduzir disparidades, intervenções específicas são necessárias. A diversificação de conjuntos de dados de treinamento, incluindo representação adequada de grupos historicamente marginalizados, é fundamental (49). Além disso, a incorporação de métricas de equidade na avaliação de desempenho algorítmico é essencial,

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

garantindo que nenhum grupo seja sistematicamente prejudicado (49,50). Mecanismos de vigilância algorítmica devem ser implementados, permitindo monitoramento contínuo do desempenho em diferentes populações ao longo do tempo (49).

No contexto brasileiro e latino-americano, onde desigualdades socioeconômicas são pronunciadas, a implementação de IA na triagem requer adaptação cuidadosa. O desenvolvimento de modelos treinados com dados locais, validados em populações representativas da realidade brasileira e sensíveis às particularidades culturais e linguísticas é essencial para garantir que a tecnologia sirva à redução, e não à ampliação, de iniquidades em saúde.

5. CONCLUSÕES E CONSIDERAÇÕES

A análise integrada da literatura demonstra que sistemas de IA aplicados à triagem e detecção de condições críticas oferecem benefícios mensuráveis para a eficiência e qualidade do atendimento em emergências adultas. Esses benefícios incluem redução do tempo de classificação, maior consistência nas decisões e sensibilidade ampliada para identificar casos graves como sepse e AVC.

Tecnologias como redes neurais e arquiteturas híbridas têm se destacado, demonstrando desempenho superior aos métodos manuais e protocolos tradicionais. Além da velocidade e da precisão diagnóstica, a IA pode contribuir para melhor alocação de recursos e priorização de pacientes de alto risco.

Entretanto, a adoção clínica efetiva exige superar desafios relacionados à interpretabilidade, integração com sistemas existentes e treinamento de equipes. A supervisão humana permanece indispensável para contextualizar resultados, corrigir possíveis vieses e garantir a segurança do paciente.

5.1. Recomendações para pesquisas futuras

- Desenvolvimento de algoritmos específicos para realidades brasileiras.
- Estudos de custo-efetividade da implementação de IA em serviços públicos.
- Análise do impacto na satisfação dos pacientes e profissionais.
- Desenvolvimento de protocolos padronizados para integração de IA aos fluxos existentes.
- Criação de diretrizes éticas específicas para uso de IA na triagem médica.

5.2. Implicações para a prática clínica

A implementação gradual e monitorada favorece ajustes contínuos, evitando riscos decorrentes de falhas técnicas ou operacionais. Recomenda-se o desenvolvimento de estudos prospectivos multicêntricos em larga escala para consolidar as evidências em contextos reais.

ISSN: 2675-6218 - RECIMA21
Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

A IA, utilizada de maneira responsável, tem potencial para elevar o padrão de cuidado e salvar vidas, consolidando-se como aliada estratégica na medicina de emergência moderna. A colaboração entre humanos e máquinas deve ser complementar, não substitutiva, garantindo que a tecnologia potencialize as capacidades humanas sem comprometer a segurança e a qualidade do cuidado.

REFERÊNCIAS

1. Ahmed MI, Spooner B, Isherwood J, et al. A systematic review of the barriers to implementing artificial intelligence in healthcare. Health Policy Technol 2024;139(2):100758. doi:10.1016/j.healthpol.2024.100758

2. Alowais SA, Alghamdi SS, Alsuhebany N, et al. Revolutionizing healthcare: the role of artificial intelligence in clinical practice. BMC Med Educ. 2023;23(1):689. doi:10.1186/s12909-023-04698-z

3. Ausserhofer D, Zaboli A, Pfeifer N, et al. Performance of the Manchester Triage System in patients with dyspnoea: a retrospective observational study. Int Emerg Nurs. 2020;3: 100931. doi:10.1016/j.ienj.2020.100931

4. Bajwa J, Munir U, Nori A, Williams B. Artificial intelligence in healthcare: transforming the practice of medicine. Future Healthc J. 2021;8(2):e188-e194, 2021. doi:10.7861/fhj.2021-0095

5. Bean DM, Kraljevic Z, Shek A, et al. Natural language processing data services for healthcare providers. BMC Med Inform Decis Mak. 2024;24(1):320. doi:10.1186/s12911-024-02713-x

6. Bekbolatova M, Mayer J, Ong CW, et al. Transformative potential of AI in healthcare: definitions, applications, and navigating the ethical landscape and public perspectives. Healthcare (Basel). 2025;12(2):125. doi:10.3390/healthcare12020125

7. Bordewich M, Hameed A, Woodcock C. AI system performance on cancer detection tasks: the impact of dataset composition. Artif Intell Med. 2024;147:102720. doi:10.1016/j.artmed.2023.102720

8. Cai T, Ni H, Yu M, Huang X, Wong K, Volpi J, Wang JZ, Wong STC. DeepStroke: an efficient stroke screening framework for emergency rooms with multimodal adversarial deep learning. Med Image Anal. 2022;80:102522. doi:10.1016/j.media.2022.102522

9. Cicolo EA, Nishi FA, Peres HHC, Da Cruz DDAL. Effectiveness of the Manchester Triage System on time to treatment in the emergency department: a systematic review. JBI Evid Synth. 2020;18(1):56-73. doi:10.11124/JBISRIR-2017-003825

10. Cross JL, Choma MA, Onofrey JA. Bias in medical AI: implications for clinical decision-making. PLOS Digital Health. 2024;3(11):e0000651. doi:10.1371/journal.pdig.0000651

11. De Micco F, Di Palma G. Ferorelli D, et al. Artificial intelligence in healthcare: transforming patient safety with intelligent systems—a systematic review. Front Med. 2025;11:1522554. doi:10.3389/fmed.2024.1522554

12. Fonseca CG, Souza EN, Kuniyoshi RR, et al. Machine learning na medicina: revisão e aplicabilidade. Arq Bras Cardiol. 2021;116(4):695-704. doi:10.36660/abc.20200596

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

13. Fraile Navarro D, Ijaz K, Rezazadegan D, et al. Clinical named entity recognition and relation extraction using natural language processing of medical free text: a systematic review. Int J Med Inform. 2023;177:105122. doi:10.1016/j.ijmedinf.2023.105122

14. Helguera-Repetto AC, Yañez-Mo M, González-Muñoz M, et al. Neonatal sepsis diagnosis decision-making based on artificial neural networks. Front Pediatr. 2020;8:525. doi:10.3389/fped.2020.00525

15. Ivanov O, Wolf L, Brecher D, et al. Improving ED Emergency Severity Index acuity assignment using machine learning and clinical natural language processing. J Emerg Nurs. 2021;47(2):265-278.e7, 2021. doi:10.1016/j.jen.2020.11.001

16. Jerfy A, Selden O, Balkrishnan R. The growing impact of natural language processing in healthcare and public health. Inquiry. 2024;61:469580241290095. doi:10.1177/00469580241290095

17. Johnson KW, Torres Soto J, Glicksberg BS, et al. Artificial intelligence in cardiology. J Am Coll Cardiol. 2018;71(23):2668-2679. doi:10.1016/j.jacc.2018.03.521

18. Kiblboeck D, Steinrueck K, Nitsche C, et al. Evaluation of the Manchester triage system for patients with acute coronary syndrome. Wien Klin Wochenschr. 2020;132(11-12):277-282. doi:10.1007/s00508-020-01632-x

19. Lauritsen SM, Kalør ME, Kongsgaard EL, Lauritsen KM, Jørgensen MJ, Lange J, Thiesson B. Early detection of sepsis utilizing deep learning on electronic health record event sequences. Artif Intell Med. 2020;104:101820. doi:10.1016/j.artmed.2020.101820

20. Li F, Jin Y, Liu W, et al. Fine-tuning bidirectional encoder representations from transformers (BERT)–based models on large-scale electronic health record notes: an empirical study. JMIR Med Inform. 2019;7(3):e14830. doi:10.2196/14830

21. Lin PC, Chen KT, Chen HC, Islam MM, Lin MC. Machine learning model to identify sepsis patients in the emergency department: algorithm development and validation. J Pers Med. 2021;11(11):1055. doi:10.3390/jpm11111055

22. Lynn LA. Artificial intelligence systems for complex decision-making in acute care medicine: a review. Patient Saf Surg. 2019;13:6. doi:10.1186/s13037-019-0188-2

23. Morone G, De Angelis L, Martino Cinnera A, et al. Artificial intelligence in clinical medicine: a state-of-the-art overview of systematic reviews with methodological recommendations for improved reporting. Front Digit Health. 2025;7:1550731. doi:10.3389/fdgth.2025.1550731

24. Obermeyer Z, Powers B, Vogeli C, Mullainathan S. Dissecting racial bias in an algorithm used to manage the health of populations. Science. 2019;366(6464):447-453. doi:10.1126/science.aax2342

25. Parikh RB, Teeple S, Navathe AS. Addressing bias in artificial intelligence in health care. JAMA. 2023;322(24):2377-2378. doi:10.1001/jama.2019.18058

26. Peiffer-Smadja N, Dellière S, Rodriguez C, et al. Machine learning in the clinical microbiology laboratory: has the time come for routine practice? Clin Microbiol Infect. 2020;26(10):1300-1309, 2020. doi:10.1016/j.cmi.2020.02.006

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

27. Poalelungi DG, Musat CL, Fulga A. et al. Advancing patient care: how artificial intelligence is transforming healthcare. J Pers Med. 2023;13(8):1214. doi:10.3390/jpm13081214

28. Roppelt JS, Kanbach DK, Kraus S. Artificial intelligence in healthcare institutions: a systematic literature review on influencing factors. Technol Soc,. 2024;76:102443. doi:10.1016/j.techsoc.2023.102488

29. Sartini M, Spada A, Bagattini B, et al. Overcrowding in emergency department: causes, consequences, and solutions - a narrative review. Healthcare (Basel). 2022;10(9):1625. doi:10.3390/healthcare10091625

30. Secinaro S, Calandra D, Secinaro A, Muthurangu V, Biancone P. The role of artificial intelligence in healthcare: a structured literature review. BMC Med Inform Decis Mak. 2021;21(1):125. doi:10.1186/s12911-021-01488-9

31. Silva JA, Macedo ME, Santos MJ, et al. Emergency Severity Index: accuracy in risk classification. Einstein (São Paulo). 2017;15(4):421-427. doi:10.1590/S1679-45082017AO3964

32. Singh DP, Kaushik B. A systematic literature review for the prediction of anticancer drug response using various machine-learning and deep-learning techniques. Chem Biol Drug Des. 2023;101(1):175-194. doi:10.1111/cbdd.14164

33. Smith KP, Kang AD, Kirby JE. Automated interpretation of blood culture gram stains by use of a deep convolutional neural network. J Clin Microbiol. 2018;56(3):e01521-17. doi:10.1128/JCM.01521-17

34. Souza CC, Chianca TCM, Cordeiro Júnior W, et al. A systematic review on the validity and reliability of an emergency department triage scale, the Manchester Triage System. Int J Nurs Stud. 2018;77:1-7. doi:10.1016/j.ijnurstu.2014.01.013

35. Storm-Versloot MN, Ubbink DT, Chin a Choi V, Luitse JS. Observer agreement of the Manchester Triage System and the Emergency Severity Index: a simulation study. Emerg Med J. 2009;26(8):556-560. doi:10.1136/emj.2008.059378

36. Subramanian M, Wojtusciszyn A, Favre L, et al. Precision medicine in the era of artificial intelligence: implications in chronic disease management. J Transl Med. 2020;18(1):472. doi:10.1186/s12967-020-02658-5

37. Sun L, Liu K, Zhang Y, et al. ED-Copilot: reduce emergency department wait time with language model diagnostic assistance. In: Proceedings of the 41st International Conference on Machine Learning. PMLR. 2024:46942-46956.

38. Tagliaferri SD, Angelova M, Zhao X, et al. Artificial intelligence to improve back pain outcomes and lessons learnt from clinical classification approaches: three systematic reviews. NPJ Digit Med. 2020;3:93. doi:10.1038/s41746-020-0303-x

39. Taylor RA, Moore CL, Cheung KH, et al. Impact of artificial intelligence-based triage decision support on emergency department care. NEJM AI. 2025;2(3). doi:10.1056/AIoa2400296

40. Tolu-Akinnawo O, Ezekwueme F, Awoyemi T. Telemedicine in cardiology: enhancing access to care and improving patient outcomes. Cureus. 2024;16(6):e62852. doi:10.7759/cureus.62852

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

41. Ullah N, Mirza S, Haroon M, et al. Natural language processing in electronic health records in relation to healthcare decision-making: a systematic review. Comput Biol Med. 2023;155:106649. doi:10.1016/j.compbiomed.2023.106649

42. Ullah W, Ali Q. Role of artificial intelligence in healthcare settings: a systematic review. J Med Artif Intell. 2025;8:24. doi:10.21037/jmai-24-294

43. van der Meijden SL, Koumpouras F, Yucel O. et al. Intensive care unit physicians' perspectives on artificial intelligence-based clinical decision support tools: preimplementation survey study. JMIR Hum Factors. 2023;10:e39114. doi:10.2196/39114

44. van der Wulp I, Schrijvers AJ, van Stel HF. Predicting admission and mortality with the Emergency Severity Index and the Manchester Triage System: a retrospective observational study. Emerg Med J. 2009;26(7):506-509. doi:10.1136/emj.2008.063768

45. Vedana AB, Silva CA, Santos RD, et al. Inteligência artificial na medicina diagnóstica. Brazilian Journal of Implantology and Health Sciences. 2024;6(11):765-794. doi:10.36557/2674-8169.2024v6n11p765-794

46. Weis CV, Jutzeler CR, Borgwardt K. Machine learning for microbial identification and antimicrobial susceptibility testing on MALDI-TOF mass spectra: a systematic review. Clin Microbiol Infect. 2020;26(10):1310-1317. doi:10.1016/j.cmi.2020.03.014

47. Yadav N, Pandey V, Singh A, et al. Data privacy in healthcare: in the era of artificial intelligence. Indian Dermatol Online J. 2023;14(6):788-792. doi:10.4103/idoj.idoj_543_23

48. Yang X, Zeng X, Zheng W, et al. A large language model for electronic health records. NPJ Digit Med. 2022;5(1):194. doi:10.1038/s41746-022-00742-2

49. Zachariasse JM, Seiger N, Rood PP, et al. Validity of the Manchester Triage System in emergency care: a prospective observational study. PLoS One. 2017;12(2):e0170811. doi:10.1371/journal.pone.0170811

50. Zakeri H, Afshari Saleh L, Niroumand S, Ziadi-Lotfabadi M. Comparison the Emergency Severity Index and Manchester Triage System in trauma patients. Bull Emerg Trauma. 2022;10(2):65-70. doi:10.30476/BEAT.2022.92297.1302

ISSN: 2675-6218 - RECIMA21

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.