



XXIX ENFERMAIO E VI SIEPS

Inteligência artificial, Enfermagem e saúde:
aplicabilidades, impactos e perspectivas futuras

REALIZAÇÃO



APOIO









































































































































































































































































































































INTRODUÇÃO

A hipertensão arterial sistêmica (HAS) configura-se como uma das principais condições crônicas não transmissíveis no mundo, estando associada à elevada morbimortalidade cardiovascular e a um expressivo ônus econômico em saúde. Sua alta prevalência em diferentes regiões, alcançando 46,7% entre adultos na América do Norte, entre 20% e 40% na América Latina e Caribe, e variando de 22,58% a 33,54% no Brasil, evidencia a magnitude do problema e reforça a necessidade de estratégias mais eficazes de cuidado (Jones et al., 2025; Abreu, 2025; Migowski; Costa, 2024).

Apesar da existência de diretrizes clínicas consolidadas, o manejo adequado da HAS ainda representa um desafio significativo, especialmente em cenários marcados por alta demanda assistencial e por dificuldades no acompanhamento contínuo dos pacientes (Parati et al., 2021). Nesse contexto, torna-se essencial avançar em abordagens que qualifiquem o monitoramento clínico, a individualização do tratamento e a tomada de decisão terapêutica.

Com o avanço das tecnologias digitais e a crescente disponibilidade de dados em saúde, o uso de Machine Learning (ML) tem emergido como estratégia promissora na área cardiovascular, permitindo a análise de grandes volumes de dados e a identificação de padrões complexos (Mroz et al., 2024; Tsoi et al., 2021).

Embora amplamente explorados na predição de risco, os algoritmos de ML têm demonstrado potencial crescente no manejo da HAS, ao possibilitar o monitoramento mais preciso da pressão arterial, da avaliação da resposta ao tratamento e do suporte à tomada de decisão clínica baseada em dados. A integração de informações heterogêneas, incluindo sinais fisiológicos em tempo real, amplia as possibilidades de um cuidado mais personalizado, proativo e eficiente (Guimarães et al., 2024).

Diante desse cenário, o uso de Machine Learning no manejo da HAS desponta como uma abordagem inovadora e relevante, com potencial para qualificar a assistência e melhorar os desfechos cardiovasculares. O estudo, então, tem como objetivo mapear as evidências disponíveis sobre o uso de Machine Learning no manejo da hipertensão arterial sistêmica.

MÉTODO

Trata-se de uma revisão de escopo conduzida de acordo com as diretrizes do manual do *JBIM Manual for Evidence Synthesis* para síntese de evidências e reportada conforme a extensão do Preferred Reporting Items for Systematic Reviews and Meta-Analyses para revisões de escopo (PRISMA-ScR) (Peters et al., 2022). A revisão foi conduzida em nove etapas: (1) definição dos objetivos e da questão de pesquisa; (2) estabelecimento dos critérios

de inclusão; (3) descrição da abordagem planejada para busca, seleção, extração, análise e apresentação das evidências; (4) processo de busca; (5) seleção dos estudos; (6) extração dos dados; (7) análise dos resultados; (8) apresentação dos resultados; e (9) síntese das evidências em relação ao objetivo da revisão e às implicações dos achados (Araújo, 2020).

Para a estruturação da questão de pesquisa, utilizou-se o mnemônico PCC (População, Conceito, Contexto): P — indivíduos com hipertensão arterial sistêmica; C — tecnologias baseadas em Machine Learning; C — manejo clínico da hipertensão, incluindo monitoramento, controle pressórico, resposta ao tratamento e tomada de decisão em diferentes níveis de atenção à saúde (primária, secundária e terciária), que culminou na pergunta norteadora: Quais tecnologias baseadas em Machine Learning têm sido utilizadas no manejo da hipertensão arterial sistêmica em diferentes níveis de atenção à saúde?

Foram incluídos estudos que abordassem tecnologias baseadas em inteligência artificial, com ênfase em técnicas de Machine Learning, como algoritmos preditivos, redes neurais e métodos de aprendizado supervisionado ou não supervisionado, aplicadas ao manejo clínico da hipertensão arterial sistêmica, incluindo monitoramento, controle pressórico e suporte à tomada de decisão em saúde. Foram considerados estudos publicados em qualquer idioma e período. Quanto ao delineamento, foram elegíveis pesquisas primárias e secundárias, de caráter descritivo ou analítico, com abordagem quantitativa ou qualitativa. Foram excluídas cartas ao editor, resumos de congressos, artigos incompletos e protocolos de estudo, por não apresentarem resultados conclusivos sobre a aplicação dos sistemas na prática clínica ou na gestão em saúde.

A busca foi realizada em novembro de 2025 nas seguintes bases de dados: Medical Literature Analysis and Retrieval System Online (MEDLINE), via PubMed, Scientific Electronic Library Online (SciELO), Literatura Latino-Americana e do Caribe em Ciências da Saúde (LILACS), Web of Science, Scopus, Cumulative Index to Nursing and Allied Health Literature (CINAHL), Cochrane Library, e Embase. A recuperação de documentos no Google Acadêmico foi realizada a partir das dez primeiras páginas de resultados. A literatura cinzenta foi pesquisada na Biblioteca Digital Brasileira de Teses e Dissertações (BDTD), no Catálogo de Teses e Dissertações da CAPES e na base Open Access Theses and Dissertations (OATD).

A estratégia de busca foi elaborada com base nos Descritores em Ciências da Saúde (DeCS) e no Medical Subject Headings (MeSH), combinados por meio dos operadores booleanos AND e OR, conforme o modelo Extraction, Conversion, Combination, Construction, and Use (ECUs), presentes na Tabela 1.

Tabela 1: Construção da estratégia de busca - Fortaleza, Ceará, Brasil, 2026.

	P	C	C
Extração	People with hypertension	Machine Learning Artificial Intelligence Clinical decision-support systems	Hypertension management Clinical management Patient monitoring
Conversão	Hypertension Hypertension, Essential	Decision Support Systems, Clinical Expert Systems Artificial Intelligence	Disease Management Patient Care Management Monitoring
Combinação	High Blood Pressure Systemic Arterial Hypertension Arterial Hypertension Hypertensive Patients Hypertensive Disease	Clinical Decision Support Systems Decision Support Tool Intelligent System Knowledge-Based System Expert System Machine Learning Model Predictive Model AI in Healthcare Algorithm for Clinical Decision-Making	Hypertension Management Blood Pressure Control Patient Monitoring Remote Monitoring Treatment Response Therapeutic Decision Clinical Decision-Making Treatment Optimization Care Management Chronic Disease Management
Construção	(Hypertension OR “Hypertension, Essential” OR “High Blood Pressure” OR “Systemic Arterial Hypertension” OR “Arterial Hypertension” OR “Hypertensive Patients” OR “Hypertensive Disease”)	(“Decision Support Systems, Clinical” OR “Expert Systems” OR “Artificial Intelligence” OR “Clinical Decision Support Systems” OR “Decision Support Tool” OR “Intelligent System” OR “Knowledge-Based System” OR “Expert System” OR “Machine Learning Model” OR “Predictive Model” OR “AI in Healthcare” OR “Algorithm For Clinical Decision-Making”)	(Management OR “Disease Management” OR “Clinical Management” OR “Patient Management” OR “Hypertension Management” OR “Blood Pressure Control” OR Monitoring OR “Remote Monitoring” OR “Patient Monitoring” OR “Treatment Response” OR “Therapeutic Decision” OR “Clinical Decision-Making” OR “Treatment Optimization” OR “Care Management” OR “Chronic Disease Management”)
Uso	((Hypertension OR “Hypertension, Essential” OR “High Blood Pressure” OR “Systemic Arterial Hypertension” OR “Arterial Hypertension” OR “Hypertensive Patients” OR “Hypertensive Disease”) AND (“Decision Support Systems, Clinical” OR “Expert Systems” OR “Artificial Intelligence” OR “Clinical Decision Support Systems” OR “Decision Support Tool” OR “Intelligent System” OR “Knowledge-Based System” OR “Expert System” OR “Machine Learning Model” OR “Predictive Model” OR “AI in Healthcare” OR “Algorithm For Clinical Decision-Making”) AND (Management OR “Disease Management” OR “Clinical Management” OR “Patient Management” OR “Hypertension Management” OR “Blood Pressure Control” OR Monitoring OR “Remote Monitoring” OR “Patient Monitoring” OR “Treatment Response” OR “Therapeutic Decision” OR “Clinical Decision-Making” OR “Treatment Optimization” OR “Care Management” OR “Chronic Disease Management”))		

Fonte: elaborada pelos autores.

Após a busca, os resultados recuperados nas bases de dados foram importados para o gerenciador de referências Rayyan®, desenvolvido pelo Qatar Computing Research Institute

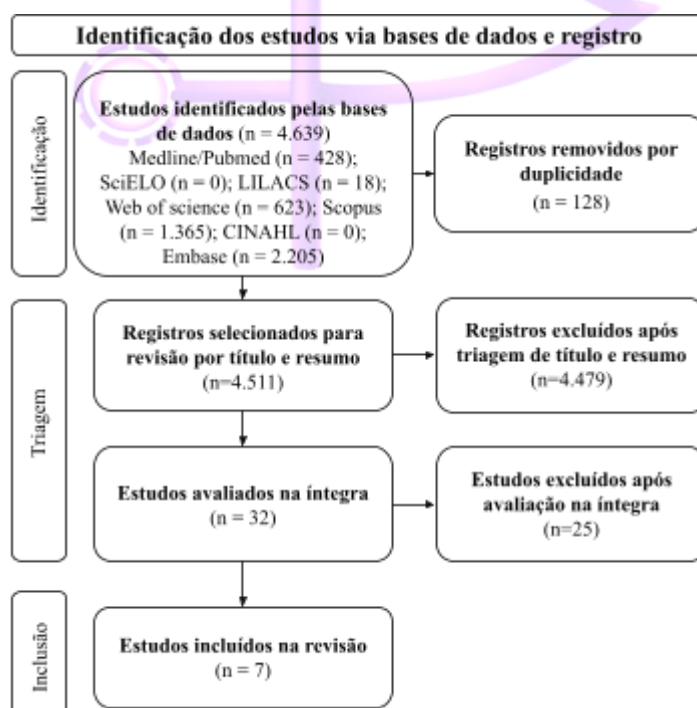
(QCRI). Nessa etapa, foram removidos os registros duplicados, seguidos da triagem independente dos estudos por dois revisores. Divergências foram resolvidas por meio da mediação de um terceiro revisor com experiência na temática. Após a remoção das duplicatas, procedeu-se à seleção dos estudos por meio da leitura de títulos e resumos, conforme os critérios previamente estabelecidos. Os estudos potencialmente elegíveis foram avaliados na íntegra para confirmação da inclusão. Aqueles que não atenderam aos critérios foram excluídos com justificativas explícitas. Adicionalmente, as listas de referências dos estudos incluídos foram examinadas para identificação de outras publicações relevantes.

Foi definida uma estratégia de extração de dados, adaptada conforme as diretrizes do manual do JBI, com o objetivo de coletar informações relevantes dos estudos incluídos. Os dados extraídos contemplaram: 1) Características gerais dos estudos: autor, país, periódico, tema, ano de publicação, título, objetivos e delineamento; 2) Aplicabilidade clínica do ML; 3) principais resultados e limitações identificadas. As informações foram organizadas em tabelas narrativas no Microsoft Excel®.

RESULTADOS E DISCUSSÃO

Foram identificados 4.639 estudos nas bases de dados, dos quais 128 foram removidos por duplicidade. Após a triagem de títulos e resumos (n = 4.511), 32 artigos foram avaliados na íntegra, resultando em uma amostra final de 7 estudos publicados entre 2020 e 2025 (Figura 1).

Figura 1: Fluxograma de seleção dos estudos - Fortaleza, Ceará, Brasil, 2026.



Fonte: elaborada pelos autores.

Os achados evidenciam a crescente incorporação de técnicas de ML no manejo da HAS, destacando seu potencial para qualificar o cuidado clínico e otimizar o controle pressórico. De modo geral, os estudos demonstram que os modelos de ML ampliam a capacidade de análise ao integrar múltiplas variáveis clínicas, demográficas e biológicas, favorecendo uma avaliação mais precisa e dinâmica do estado de saúde dos indivíduos (Kanegae et al., 2020). Nesse contexto, diferentes abordagens têm sido empregadas, incluindo algoritmos supervisionados, como regressão logística, Random Forest, Support Vector Machine e redes neurais artificiais, amplamente utilizados para predição de risco, classificação de pacientes e estimativa de desfechos clínicos.

No contexto do manejo, essas tecnologias têm se mostrado particularmente relevantes no monitoramento contínuo da pressão arterial, na avaliação da resposta terapêutica e no suporte à tomada de decisão clínica. Modelos preditivos baseados em Random Forest e Gradient Boosting, por exemplo, têm sido aplicados para estimar o tempo necessário para o controle pressórico e identificar pacientes com maior risco de não adesão ou resposta terapêutica inadequada, contribuindo para intervenções mais oportunas e com potencial impacto na redução da morbimortalidade cardiovascular (Mroz et al., 2024). Além disso, modelos baseados em redes neurais profundas (deep learning) vêm sendo utilizados para análise de séries temporais de pressão arterial e sinais fisiológicos, permitindo monitoramento contínuo e detecção precoce de padrões anormais.

A utilização de dados provenientes de prontuários eletrônicos e da atenção primária tem possibilitado a construção de ferramentas aplicáveis à prática real, favorecendo o acompanhamento longitudinal e a personalização do cuidado. Nesses cenários, algoritmos de aprendizado supervisionado e não supervisionado, como clustering (k-means, hierarchical clustering), têm sido empregados para estratificação de perfis de pacientes e identificação de subgrupos com diferentes padrões de risco e resposta ao tratamento (Norrman et al., 2024).

Outro avanço relevante refere-se à capacidade dos algoritmos de ML em lidar com dados complexos e interdependentes, superando limitações de modelos tradicionais e possibilitando a identificação de padrões clínicos mais sutis, inclusive em condições de difícil detecção, como a hipertensão mascarada. Modelos como Support Vector Machine e redes neurais têm demonstrado bom desempenho na classificação desses casos, especialmente quando integrados a dados ambulatoriais e domiciliares (Tsoi et al., 2021). A incorporação de biomarcadores, dados de dispositivos vestíveis e sinais fisiológicos amplia ainda mais o

potencial dessas abordagens no monitoramento e ajuste terapêutico, permitindo estratégias mais individualizadas de manejo (Jusic et al., 2024).

Além disso, algoritmos de ML vêm sendo explorados em aplicações específicas do cuidado, como sistemas de apoio à decisão clínica (Clinical Decision Support Systems – CDSS), recomendação de terapias anti-hipertensivas personalizadas e previsão de eventos adversos relacionados ao tratamento. Técnicas como aprendizado por reforço (reinforcement learning), embora ainda incipientes, apresentam potencial para otimizar esquemas terapêuticos ao longo do tempo, ajustando intervenções com base na resposta individual do paciente.

Apesar desses avanços, persistem desafios importantes para a implementação clínica. Destacam-se a heterogeneidade dos modelos desenvolvidos, a ausência de padronização metodológica e limitações relacionadas à interpretabilidade dos algoritmos, especialmente em modelos mais complexos como redes neurais profundas, fatores que dificultam sua aplicação em larga escala (Koshimizu; Kojima; Okuno, 2020; Tsoi et al., 2021). Além disso, a escassez de estudos com validação em cenários reais e de delineamentos robustos, como coortes prospectivas e ensaios clínicos, limita a consolidação das evidências (Mroz et al., 2024).

Nesse sentido, embora o ML se apresente como uma ferramenta promissora para o manejo da hipertensão arterial, ao possibilitar monitoramento contínuo, suporte à decisão clínica e cuidado mais individualizado, sua incorporação efetiva à prática assistencial depende de avanços na padronização dos modelos, na validação externa, na transparência algorítmica e na integração com os sistemas de saúde.

CONCLUSÃO

Diante dos achados, técnicas de ML apresentam elevado potencial no manejo da HAS, ao possibilitar monitoramento contínuo, predição de risco e suporte à decisão clínica por meio da integração de múltiplas variáveis. Diferentes abordagens, como modelos supervisionados e redes neurais, demonstram aplicabilidade na estratificação de pacientes e na personalização terapêutica, contribuindo para um cuidado mais preditivo e individualizado.

Entretanto, a heterogeneidade dos estudos, a limitada interpretabilidade dos modelos e a escassez de validação em cenários reais ainda restringem sua aplicação prática. Assim, sua incorporação efetiva depende de maior padronização metodológica, validação externa e integração com os sistemas de saúde.

REFERÊNCIAS

ABREU, A. P. Hipertensão na América Latina e no Caribe: uma análise do recente progresso e dos desafios remanescentes. **Brazilian Journal of Nephrology**, [S.l.], v. 47, n. 3, e20240245, 2025. DOI: <http://dx.doi.org/10.1590/2175-8239-JBN-2024-0245pt>.

ARAÚJO, W. C. O. Recuperação da informação em saúde: construção, modelos e estratégias. **ConCI: Convergências em Ciência da Informação**, v. 3, n. 2, p. 100–134, 2020. DOI: [10.33467/conci.v3i2.13447](https://doi.org/10.33467/conci.v3i2.13447).

GUIMARÃES, P. et al. Artificial intelligence–derived risk prediction: a novel risk calculator using office and ambulatory blood pressure. **Hypertension**, v. 82, n. 1, 2025. DOI: <https://doi.org/10.1161/HYPERTENSIONAHA.123.22529>.

JONES, D. W. et al. 2025

AHA/ACC/AANP/AAPA/ABC/ACCP/ACPM/AGS/AMA/ASPC/NMA/PCNA/SGIM guideline for the prevention, detection, evaluation and management of high blood pressure in adults: a report of the American College of Cardiology/American Heart Association Joint Committee on Clinical Practice Guidelines. **Circulation**, [S.l.], v. 152, p. e1–e105, 2025. DOI: [10.1161/CIR.0000000000001356](https://doi.org/10.1161/CIR.0000000000001356).

JUSIC, A. et al. A machine learning model based on microRNAs for the diagnosis of essential hypertension. **Non-Coding RNA**, v. 9, n. 6, p. 64, 2023. DOI: <https://doi.org/10.3390/ncrna9060064>.

KANEGAE, H. et al. Highly precise risk prediction model for new-onset hypertension using artificial intelligence techniques. **Journal of Clinical Hypertension**, v. 22, n. 3, p. 445–450, 2020. DOI: <https://doi.org/10.1111/jch.13759>.

KOSHIMIZU, H.; KOJIMA, R.; OKUNO, Y. Future possibilities for artificial intelligence in the practical management of hypertension. **Hypertension Research**, v. 43, p. 1327–1337, 2020. DOI: <https://doi.org/10.1038/s41440-020-0498-x>.

MIGOWSKI, A.; COSTA, G. T. L. Análise temporal da prevalência de hipertensão arterial no Brasil entre 2006 e 2023: evidências a partir dos dados dos Vigitel. **OnSci**, [S.l.], v. 2, n. 2, e00027, 2024. DOI: <https://doi.org/10.33634/2764-0736.2024.0027>.

MROZ, T. et al. Predicting hypertension control using machine learning. **PLOS One**, 2024. DOI: <https://doi.org/10.1371/journal.pone.0299932>.

NORRMAN, A. et al. Predicting new cases of hypertension in Swedish primary care with a machine learning tool. **Preventive Medicine Reports**, v. 44, 2024. DOI: <https://doi.org/10.1016/j.pmedr.2024.10280646>.

PARATI, G.; LOMBARDI, C.; PENGO, M.; BILO, G.; OCHOA, J. E. Current challenges for hypertension management: from better hypertension diagnosis to improved patients' adherence and blood pressure control. **International Journal of Cardiology**, v. 331, p. 262–269, 2021. DOI: [10.1016/j.ijcard.2021.01.070](https://doi.org/10.1016/j.ijcard.2021.01.070).

PETERS, M. D. J. et al. Orientações de melhores práticas e itens de relatórios para o desenvolvimento dos protocolos de revisão de escopo. **Síntese de Evidências do JBI**, v. 20, n. 4, p. 953–968, 2022.

TSOI, K. et al. Applications of artificial intelligence for hypertension management. **Journal of Clinical Hypertension**, v. 23, n. 3, p. 568–574, 2021. DOI: <https://doi.org/10.1111/jch.14180>.