REVISÃO DE LITERATURA IDENTIFICADO

INTELIGÊNCIA ARTIFICIAL E *MACHINE LEARNING* NA EMBOLIA PULMONAR: UMA REVISÃO INTEGRATIVA

ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING IN PULMONARY EMBOLISM: AN INTEGRATIVE REVIEW

Sabrina Gomes de Oliveira[2], Pietra Marques Pereira Lima[1], Lusiana Barros de Sousa[1], Yasmim Gabrielle Rodrigues Amorim[1], Maria Clara Camboim Câmara de Souza[1], Karine do Carmo Leandro Correia[1]

[1] Acadêmicas de Medicina – Afya Centro Universitário UNIMA - Afya UNIMA, Maceió, AL, Brasil. Email: karine.leandromed.unima@gmail.com

[2] Docente do curso de Medicina – Afya Centro Universitário UNIMA - Afya UNIMA, Maceió, AL, Brasil. E-mail: sabrina.gomes@afya.com.br

RESUMO **Eixo Temático: 03**

Introdução: A embolia pulmonar (EP) é uma emergência cardiovascular de alta morbimortalidade, cuja estratificação precoce é fundamental para guiar o tratamento. Os escores tradicionais (Wells, Geneva, PESI, Caprini) apresentam limitações significativas, como baixa acurácia (AUC ~0,71) e subjetividade. **Objetivo:** Esta revisão integrativa sintetiza as principais aplicações da inteligência artificial (IA) e do *machine learning* (ML) na EP, abordando predição de risco, diagnóstico por imagem, prognóstico e desafios de implementação. **Método:** Revisão integrativa conduzida nas bases PubMed, SciELO e Google Scholar, utilizando descritores relacionados à EP, IA e ML. Foram incluídos estudos publicados entre 2020 e 2026, nos idiomas inglês e português, com dados quantitativos de desempenho dos modelos. **Resultados:** Modelos como Random Forest e LightGBM superam os escores tradicionais, alcançando AUC de até 0,956. Na imagem, a radiômica combinada a dados clínicos atingiu AUC de 0,935, e algoritmos aprovados pelo FDA apresentaram sensibilidade de 93% e especificidade de 98%. Ferramentas como o Viz.ai reduziram o tempo de consulta de 240 para 6,7 minutos. Para o prognóstico, modelos de ML superam PESI e sPESI (AUC 0,84 vs 0,79). Desafios como explicabilidade (SHAP), viés de dados, privacidade (*Federated Learning*) e validação externa ainda limitam a implementação. **Conclusão:** A IA tem potencial transformador na EP, mas requer estudos prospectivos e padronização para consolidação na prática clínica.
Palavras-chave: Embolia Pulmonar; Inteligência Artificial; *Machine Learning*; Radiômica; *Deep Learning*.

ABSTRACT
Introduction: Pulmonary embolism (PE) is a cardiovascular emergency with high morbidity and mortality, for which early risk stratification is essential to guide treatment. Traditional scores (Wells, Geneva, PESI, Caprini) have significant limitations, such as low accuracy (AUC ~0.71) and subjectivity. **Objective:** This integrative review synthesizes the main applications of artificial intelligence (AI) and machine learning (ML) in PE, addressing risk prediction, imaging diagnosis, prognosis, and implementation challenges. **Method:** An integrative review was conducted in PubMed, SciELO, and Google Scholar databases, using descriptors related to PE, AI, and ML. Studies published between 2020 and 2026 in English and/or Portuguese, with quantitative performance data of the models, were included. **Results:** Models such as Random Forest and LightGBM outperform traditional scores, achieving AUC up to 0.956. In imaging, radiomics combined with clinical data achieved an AUC of 0.935, and FDA-approved algorithms demonstrated sensitivity of 93% and specificity of 98%. Tools such as Viz.ai reduced consultation time from 240 to 6.7 minutes. For prognosis, ML models outperform PESI and sPESI (AUC 0.84 vs 0.79). Challenges such as explainability (SHAP), data bias, privacy (Federated Learning), and external validation still limit implementation. **Conclusion:** AI has transformative potential in PE, but requires prospective studies and standardization for consolidation in clinical practice.
Keywords: Pulmonary Embolism; Artificial Intelligence; Machine Learning; Radiomics; Deep Learning.

INTRODUÇÃO

A embolia pulmonar (EP) é a terceira causa mais comum de morte cardiovascular no mundo, com apresentação clínica inespecífica e alta morbimortalidade[1]. Sem tratamento imediato, a mortalidade pode chegar a 30%, reduzindo-se para cerca de 8% com intervenção precoce[2]. A *Computed Tomography Pulmonary Angiography* (CTPA) é o exame padrão-ouro para o diagnóstico, mas apresenta taxas de subdiagnóstico (quando o exame não identifica um trombo que está presente) de 14% e sobrediagnóstico (quando o exame aponta um trombo que não existe) de 10%, evidenciando a necessidade de ferramentas mais precisas[1]. Nesse contexto, a inteligência artificial (IA) surge como uma ferramenta capaz de auxiliar na interpretação das imagens da CTPA, reduzindo erros diagnósticos e otimizando a estratificação de risco. A estratificação precoce do risco é fundamental para orientar decisões como anticoagulação, trombólise ou intervenção mecânica[3].

Atualmente, os escores clínicos mais utilizados --- Wells, Geneva, PESI (*Pulmonary Embolism Severity Index*) e Caprini --- são ferramentas que combinam variáveis clínicas e laboratoriais para estimar a probabilidade de EP ou o risco de desfechos adversos. O escore de Wells é amplamente utilizado no diagnóstico de EP em serviços de emergência; o Geneva, em sua versão revisada, dispensa a subjetividade do julgamento clínico; o PESI é um preditor prognóstico de mortalidade em 30 dias; e o Caprini é empregado na avaliação de risco de trombose venosa profunda em pacientes cirúrgicos e clínicos. No entanto, esses escores apresentam limitações: são lineares, subjetivos e restritos a populações específicas, com áreas sob a curva ROC (do inglês *Receiver Operating Characteristic*), também chamada de AUC, modestas. A AUC é um valor que varia de 0 a 1 e indica a capacidade de um teste ou escore de distinguir corretamente entre pacientes com e sem a doença: quanto mais próximo de 1, melhor a precisão; 0,5 equivale ao acaso. O escore Caprini, por exemplo, atinge AUC de 0,714[4], evidenciando a limitação dos escores tradicionais e a margem para erros diagnósticos.

O *machine learning* (ML) é um subcampo da inteligência artificial (IA) que permite que computadores aprendam padrões a partir de dados sem programação explícita --- surge como uma alternativa robusta, capaz de processar grandes volumes de dados, identificar relações não lineares e gerar predições individualizadas[1,5]. Dentro do ML, algoritmos como *Random Forest* e *LightGBM*, modelos de aprendizado baseados em árvores de decisão que combinam múltiplos preditores para melhorar a acurácia, têm se destacado na predição de risco e prognóstico. Além da predição baseada em dados clínicos, a análise de imagens médicas também tem sido beneficiada pelo ML. Paralelamente, a radiômica, técnica que extrai características invisíveis ao olho humano, como textura, forma e heterogeneidade, de imagens

médicas, tem sido combinada a algoritmos de ML para aprimorar o diagnóstico e a estratificação de risco[7], alcançando AUC de 0,935 para estratificação de risco. Na prática clínica, algoritmos aprovados pelo FDA (*Food and Drug Administration*), agência reguladora dos Estados Unidos, já alcançam sensibilidade de 93% e especificidade de 98% na detecção de EP em CTPA[8], e ferramentas como o *Viz.ai*, software de triagem que integra comunicação em tempo real entre equipes, reduziram o tempo médio para consulta especializada de 240 para 7 minutos[9].

Diante desse cenário, o objetivo do presente estudo é analisar o papel da IA e do *machine learning* na embolia pulmonar, sintetizando as evidências disponíveis sobre predição de risco, diagnóstico por imagem, prognóstico e aplicação prática, bem como discutir os desafios para implementação clínica.

MÉTODO

Trata-se de uma revisão integrativa da literatura, conduzida em agosto de 2026 nas bases PubMed, SciELO e Google Scholar, utilizando os descritores "pulmonary embolism", "venous thromboembolism", "machine learning", "artificial intelligence", "deep learning" e "radiomics", combinados pelos operadores booleanos AND e OR. Foram incluídos estudos primários (artigos originais) e sínteses de evidência (revisões e metanálises) publicados entre 2020 e 2026, nos idiomas inglês e/ou português, que apresentassem dados quantitativos de desempenho dos modelos (AUC, sensibilidade, especificidade). Excluíram-se estudos com amostras inferiores a 50 pacientes, sem dados numéricos, resumos de congresso, cartas ao editor e estudos não focados em EP ou sem uso de IA/ML. A seleção ocorreu em duas etapas: leitura de títulos e resumos, seguida da análise do texto completo dos estudos elegíveis. Os dados foram extraídos com formulário padronizado e sintetizados em quatro categorias temáticas: predição de risco, diagnóstico por imagem, aplicação prática e prognóstico. Estudos sobre tromboembolismo venoso (TEV) foram incluídos por sua relação direta com a EP, uma vez que a EP é uma manifestação clínica do TEV, compartilhando fatores de risco, mecanismos fisiopatológicos e estratégias de manejo.

RESULTADOS

Chen *et al.*[5] desenvolveram um modelo LightGBM com 91 variáveis em 159.001 pacientes, alcançando AUC de 0,83 na validação interna e 0,80 no UK Biobank, coorte de dados de saúde do Reino Unido, superando o escore Padua, utilizado para predizer TEV em

pacientes clínicos internados, que apresentou AUC de 0,63. Sheng *et al.*[4], utilizando Random Forest baseado nas variáveis do Caprini, obtiveram AUC de 0,804 versus 0,714 do Caprini ($p < 0,001$) em 3.078 pacientes hospitalizados. Zhang *et al.*[2], em pacientes sépticos, população com risco de TEV até 10 vezes maior, alcançaram AUC de 0,956 na validação interna e 0,786 na validação externa com LightGBM, identificando cateter venoso central (CVC), cloreto, bicarbonato e tempo de tromboplastina parcial (PTT) prolongado como preditores, com relação não linear para este último, com risco acentuado acima de 45 segundos.

Song *et al.*[7] combinaram radiômica, com 12 características, com dados clínicos como dispneia, troponina e PESI, além da relação ventrículo direito/ventrículo esquerdo (RV/LV), alcançando AUC de 0,935 para estratificação de risco, superior ao modelo clínico (0,805), ao modelo de imagem convencional (0,788) e à radiômica isolada (0,860). Algoritmos aprovados pelo FDA, conforme metanálise de DePry *et al.*[8] com 9.102 exames, apresentaram sensibilidade de 93% e especificidade de 98% na detecção de EP em CTPA, reduzindo a taxa de omissão diagnóstica de 15,6% para 3,8%.

Em um estudo retrospectivo não controlado, Shapiro *et al.*[9] observaram associação entre o uso do Viz.ai e a redução do tempo de consulta de 240,45 para 6,72 minutos ($p < 0,001$) em 29 pacientes. O tempo para anticoagulação com o PERT ativado foi de 83,17 minutos, contra 164,96 minutos sem PERT ($p = 0,005$), e a mortalidade intra-hospitalar foi de 2,2% no período pós-implantação, ante 8,4% no período pré-implantação.

Zhou *et al.*[6], com *Federated Learning* em 3.997 pacientes de 12 hospitais, alcançaram AUC de 0,842 para mortalidade em 30 dias, superando o PESI (0,791) e sua versão simplificada, o sPESI (0,786). O SHapley Additive exPlanations (SHAP) identificou idade, frequência cardíaca, saturação de oxigênio, pressão arterial sistólica, câncer, insuficiência cardíaca e doença pulmonar crônica como preditores.

CONCLUSÃO

O *machine learning* e a IA têm papel transformador na embolia pulmonar, com evidências robustas em predição de risco, diagnóstico por imagem e prognóstico. Modelos como *Random Forest* e *LightGBM* superam os escores tradicionais com ganhos de AUC de aproximadamente 0,09 a 0,20 nos estudos comparativos apresentados[1,2,4]. Na imagem, a radiômica combinada a dados clínicos atinge AUC de 0,935[7], e algoritmos aprovados pelo FDA alcançam sensibilidade de 93% e especificidade de 98%[8]. Na prática, o Viz.ai foi associado à redução do tempo de consulta de 240 para 6,7 minutos e da mortalidade de 8,4% para 2,2% em

estudo retrospectivo não controlado[9]. No prognóstico, modelos de ML superam PESI e sPESI, com AUC de 0,842[6].

Apesar dos avanços, a implementação clínica enfrenta desafios como falta de transparência dos algoritmos, viés de dados, privacidade e necessidade de integração com fluxos de trabalho. Direções futuras incluem modelos multimodais, expansão do *Federated Learning* e ensaios clínicos randomizados. A IA já se consolida como ferramenta promissora, mas a colaboração entre pesquisadores e clínicos será essencial para sua aplicação segura e eficaz.

REFERÊNCIAS BIBLIOGRÁFICAS

1. Li Y, Zhang L, Liu H, Li Y, Liu Z. Research progress of artificial intelligence and machine learning in pulmonary embolism. Front Med. 2025;12:1577559.

2. Zhang Y, Ren X, Liu L, Zha J, Gu Y, Ye H. Machine learning algorithms to predict venous thromboembolism in patients with sepsis in the intensive care unit: a multicenter retrospective study. JMIR Med Inform. 2026;14:e80969.

3. Stadlbauer A, Verbelen T, Binzenhöfer L, *et al.* Management of high-risk acute pulmonary embolism: an emulated target trial analysis. Intensive Care Med. 2025. doi:10.1007/s00134-025-07805-4.

4. Sheng W, Wang X, Xu W, Hao Z, Ma H, Zhang S. Development and validation of machine learning models for venous thromboembolism risk assessment at admission: a retrospective study. Front Cardiovasc Med. 2023;10:1198526.

5. Chen R, Petrazzini BO, Malick WA, Rosenson RS, Do R. Prediction of venous thromboembolism in diverse populations using machine learning and structured electronic health records. Arterioscler Thromb Vasc Biol. 2024;44(2):491-504.

6. Zhou J, Wang X, Li Y, Yang Y, Shi J. Federated-learning-based prognosis assessment model for acute pulmonary thromboembolism. BMC Med Inform Decis Mak. 2024;24(1):141.

7. Song J, Yu Y, Wang M, Chen R, Lu Y, Wang D, Wang F, Yang F. Prediction of risk stratification in acute pulmonary embolism using a combined CTPA radiomics and machine learning model. Medicine. 2026;105(24):e49227.

8. DePry EX, Parmar V, Rajendran S, *et al.* Performance of FDA-approved AI algorithms in detecting acute pulmonary embolism on computed tomographic pulmonary angiography (CTPA): a systematic review and meta-analysis. Cureus. 2025;17(10):e94391.

9. Shapiro J, Reichard A, Muck PE. New diagnostic tools for pulmonary embolism detection. Methodist DeBakey Cardiovasc J. 2024;20(3):5-12.