

Machine Learning na Predição do Infarto Agudo do Miocárdio: Uma Revisão Sistemática de Literatura.

Evelly Victory Vieira Pinto¹, Jose Wilker Pereira Luz¹,
Luis Fernando Maia Santos Silva¹

¹ Instituto Federal de Educação, Ciência e Tecnologia do Maranhão (IFMA)
Campus Caxias – MA – Brasil

victoryvieira@acad.ifma.edu.br

{josewilkerluz, luis.maia}@ifma.edu.br

Abstract. *Cardiovascular diseases (CVDs) are among the leading causes of death worldwide, with acute myocardial infarction (AMI) among the most fatal events. Machine Learning (ML) techniques have the potential to support early prediction and diagnosis. This study presents a Systematic Literature Review based on [Kitchenham and Charters 2007] on ML applications for AMI prediction. Searches in the IEEE and PubMed databases identified 28 primary studies. XGBoost showed the best performance (AUC 0.87–0.99; accuracy up to 98%). The results highlight the potential of ML to support AMI diagnosis, although advances in transparency and fairness are still necessary for responsible clinical adoption.*

Resumo. *As doenças cardiovasculares (DCVs) estão entre as principais causas de morte no mundo, com o infarto agudo do miocárdio (IAM) entre os eventos mais fatais. Técnicas de Machine Learning (ML) têm potencial para apoiar a predição e o diagnóstico precoce. Este estudo apresenta uma Revisão Sistemática da Literatura baseada em [Kitchenham and Charters 2007] sobre aplicações de ML na predição de IAM. As buscas nas bases IEEE e PubMed identificaram 28 estudos primários. O XGBoost apresentou o melhor desempenho (AUC 0,87–0,99; acurácia até 98%). Os resultados destacam o potencial do ML no apoio ao diagnóstico de IAM, embora avanços em transparência e equidade ainda sejam necessários para uma adoção clínica responsável.*

1. Introdução

De acordo com estimativas da Organização Mundial da Saúde [World Health Organization 2023], as doenças cardiovasculares (DCVs) representam um dos maiores desafios contemporâneos à saúde pública global, sendo responsáveis por elevados índices de mortalidade. Estima-se que cerca de 19,8 milhões de pessoas tenham morrido por DCVs em 2022, representando aproximadamente 32% de todas as mortes globais. Dentre esses óbitos, 85% ocorreram devido a ataques cardíacos e acidentes vasculares cerebrais (AVCs). [Forhad et al. 2025] apontam que dentre tais doenças, destaca-se o Infarto Agudo do Miocárdio (IAM), que constitui uma das principais causas de mortalidade em todo o mundo. Paralelamente, de acordo com [Takci 2018], a aplicação de técnicas de Machine Learning (ML) têm ganhado destaque na saúde. Algoritmos como XGBoost (conhecido pela alta acurácia em dados clínicos

heterogêneos) e Random Forest (mais interpretável e robusto ao overfitting) lideram as aplicações cardiovasculares, enquanto modelos de Deep Learning se destacam em dados não estruturados, porém com maior custo computacional e menor transparência decisória. Desse modo, a ML se caracteriza como uma ferramenta eficaz, auxiliando profissionais de saúde na tomada de decisões mais assertivas e contribuindo para intervenções precoces e personalizadas que podem reduzir a mortalidade associada ao IAM.

Para a realização desta pesquisa, utilizamos o método de Revisão Sistemática de Literatura (RSL), conforme guia descrito em [Kitchenham and Charters 2007]. Trata-se de um método estruturado e sistemático utilizado para identificar, selecionar, avaliar criticamente e interpretar todas as evidências científicas disponíveis e relevantes acerca de uma determinada questão de pesquisa, área temática ou fenômeno de interesse. A pesquisa foi guiada pelas seguintes questões: a) Quais algoritmos de Machine Learning são mais utilizados na predição de IAM e com que desempenho? b) Quais abordagens de interpretabilidade são aplicadas para compreender o processo decisório dos modelos? c) Quais considerações éticas (viés, transparência, responsabilidade médica) são relatadas nos estudos analisados? Com base nessas questões norteadoras, procedeu-se à análise de artigos selecionados a partir de palavras-chave previamente definidas, possibilitando uma investigação aprofundada das abordagens propostas em cada estudo, bem como a articulação com temas correlatos.

Diante desse contexto, o presente estudo tem como objetivo analisar como técnicas de Machine Learning têm sido aplicadas na predição e no diagnóstico do Infarto Agudo do Miocárdio, por meio de uma RSL conduzida nas bases IEEE Digital Library e PubMed, e está estruturado da seguinte forma: a Seção 2 descreve o percurso metodológico adotado na revisão; a Seção 3 apresenta e discute os resultados obtidos; e a Seção 4 expõe as considerações finais.

2. Metodologia

A metodologia adotada nesta revisão tem como base a proposta de [Kitchenham and Charters 2007], citada na seção anterior, estruturada em três etapas principais: planejamento, condução e análise dos resultados. Inicialmente, foram definidos os objetivos, as questões de pesquisa, as bases de dados consultadas e os critérios de inclusão e exclusão. Em seguida, realizou-se a busca, seleção e extração das informações dos estudos relevantes. Por fim, os dados foram organizados, analisados e interpretados, permitindo identificar tendências, lacunas e contribuições da literatura. A seção seguinte apresenta as estratégias de busca.

2.1. Estratégias de Busca

O levantamento da literatura foi realizado por meio de consultas estruturadas em repositórios acadêmicos como IEEE Digital Library e PubMed, acessadas através do site de Periódicos da CAPES, que nos permitiram identificar estudos apresentados em conferências ou publicados em periódicos vinculados aos principais repositórios da área de Ciência da Computação e da Medicina. As palavras-chave que delimitaram o escopo da RSL foram: Infarto Agudo do Miocárdio, Machine Learning e Ética em Inteligência Artificial. Assim, para contemplar os trabalhos inseridos nas interseções desses campos de pesquisa, foram elaboradas a seguinte String de busca em inglês ("machine learning

OR "deep learning"OR "artificial intelligence") AND ("acute myocardial infarction"OR "heart attack") AND ("ethics"OR "bias"OR "fairness"OR "transparency"OR "interpretability").

2.2. Critérios da Seleção

Para a inclusão na RSL, o trabalho deveria inserir estudos primários empíricos publicados nos últimos cinco anos (2020–2025) que apresentem desenvolvimento, validação ou comparação de modelos de Machine Learning aplicados à predição ou diagnóstico de Infarto Agudo do Miocárdio. Os artigos devem reportar métricas quantitativas de desempenho (sensibilidade, especificidade, AUC, precisão, recall ou F1-score) e abordar aspectos de interpretabilidade, transparência algorítmica ou discussões éticas relacionadas ao uso de inteligência artificial na prática clínica. Apenas estudos publicados em inglês e revisados por pares foram considerados.

Como critérios de exclusão, utilizamos os seguintes: Tipo de publicação: artigos secundários (systematic reviews, surveys, meta-analyses), pôsteres, short papers, editoriais ou relatórios técnicos sem revisão por pares; Irrelevância temática: estudos que não tratem de Machine Learning aplicado à predição de Infarto Agudo do Miocárdio; Ausência de resultados relevantes: publicações que não apresentem métricas quantitativas de desempenho preditivo ou que não incluam discussão sobre ética, transparência ou interpretabilidade de modelos; Indisponibilidade: trabalhos sem acesso integral ao texto completo nas bases de dados selecionadas, impossibilitando análise completa de métodos e resultados; Duplicidade: versões repetidas do mesmo estudo (mantendo-se a mais completa, geralmente a publicada em periódico). Caso se enquadrasse em pelo menos um dos critérios de exclusão, o trabalho foi classificado como excluído.

2.3. Execução da Pesquisa

A execução da pesquisa ocorreu a partir dos trabalhos identificados por meio da String de busca e das palavras-chave, limitados ao período entre 2020 e 2025 e aos tipos de documentos, "Conference Paper", "Article". Após a execução das buscas nas bases de dados, exportamos os metadados das pesquisas em formato bib para a ferramenta de gestão de revisão sistemática da literatura Parsifal. O processo de seleção dos trabalhos ocorreu em duas etapas. Na primeira, foram analisados o título, o resumo e as palavras-chave, para encontrar pesquisas que atendessem aos critérios de inclusão. Na segunda etapa, foi realizada uma leitura completa dos trabalhos selecionados, aplicando os critérios de exclusão, além de verificar novamente os critérios de inclusão, o que permitiu a seleção final das pesquisas que respeitaram os critérios estabelecidos. Para assegurar a qualidade dos estudos incluídos, foram avaliados os seguintes critérios: clareza na descrição do dataset utilizado, reporte de ao menos duas métricas quantitativas de desempenho, realização de validação cruzada ou externa, e discussão de limitações do modelo. Estudos que não atenderam a pelo menos três desses critérios foram excluídos na segunda etapa de seleção.

3. Análise dos Resultados

A String de Busca disponível no item (2.1) permitiu encontrar 100 (cem) pesquisas (Figura 1), 46 (quarenta e seis) artigos na base IEEE Digital Library e 54 (cinquenta e quatro) na base PubMed. Após a primeira etapa de seleção, baseada na leitura do título, das palavras-chave e dos resumos, aplicamos o critério de inclusão, que permitiu filtrar

a busca para selecionar os que mais se aproximavam da nossa proposta de investigação. Nesta fase, foram descartadas da base IEEE 32 (trinta) e 20 (vinte) da base PubMed, e permaneceram 48 (quarenta e oito) pesquisas pré-selecionadas. Em seguida, aplicamos os critérios de exclusão, que permitiram filtrar mais ainda a pesquisa. Nesta etapa, foram encontradas 13 (treze) pesquisas secundárias, cinco (5) pesquisas não disponíveis de forma gratuita e 2 (dois) artigos curtos (Short paper). Todas as pesquisas estavam escritas em língua inglesa. Após a aplicação dos critérios de inclusão e de exclusão, 28 (vinte e oito) estudos foram incluídos para a leitura completa, sendo todos artigos completos.

3.1. Tendências de Pesquisa em Machine Learning para predição De IAM

Para facilitar a compreensão dos objetivos gerais dos estudos analisados, as publicações foram agrupadas em quatro categorias principais, definidas com base nas questões de pesquisa desta revisão, como é descrito na Figura 1. A categoria Modelagem Preditiva reúne os estudos que tratam do desenvolvimento e avaliação de modelos de Machine Learning aplicados à predição, diagnóstico e prognóstico do IAM. A categoria Interpre-

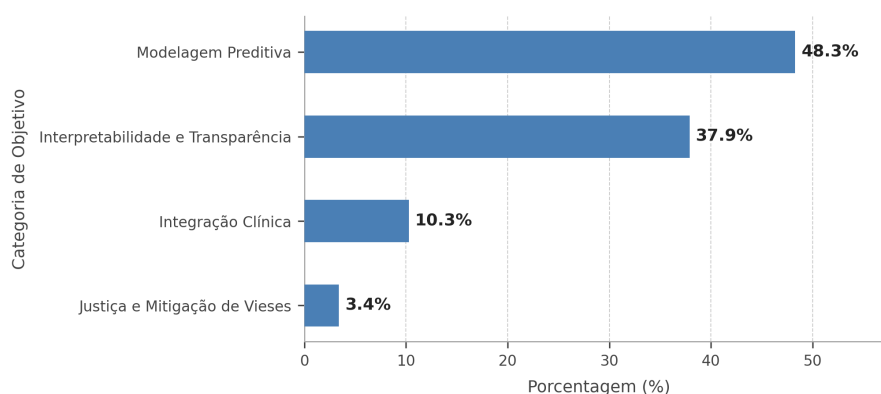


Figura 1. Categorização dos Objetivos de Pesquisa em Modelos de Machine Learning para Predição de IAM

tabilidade e Transparência abrange trabalhos que destacam estratégias de explicabilidade e análise do processo decisório dos modelos. Já as categorias Justiça e Mitigação de Vieses e Integração Clínica se conectam, respectivamente, à abordagem de considerações éticas envolvidas, como viés e equidade, e à aplicação prática dos modelos em contextos hospitalares. A Figura 1 apresenta a proporção de estudos em cada uma dessas quatro categorias, expressa em valores percentuais.

Observa-se que a maior parte dos estudos (aproximadamente 48%), [Yang et al. 2025], [Tang et al. 2025], [Forhad et al. 2025], [Wang et al. 2022], [Zhang et al. 2023], [Shen et al. 2025], [Yang et al. 2025], [Li et al. 2025], [Yu et al. 2025], [Baidya and Gupta 2024], [Chen et al. 2024] e [Salman et al. 2021], concentra-se na categoria Modelagem Preditiva, indicando que o foco predominante das pesquisas sobre Machine Learning na predição do Infarto Agudo do Miocárdio (IAM) ainda está voltado ao desenvolvimento e aprimoramento de modelos e algoritmos preditivos. Essa predominância revela o interesse contínuo da comunidade científica em alcançar maior precisão e melhor desempenho nos sistemas de diagnóstico e prognóstico automatizado.

A categoria Interpretabilidade e Transparência representa cerca de 38% dos artigos, [Kim et al. 2024], [Kucukakcali et al. 2025], [Zhu et al. 2025], [Mesinovic et al. 2025], [Ehghaghi et al. 2023], [Wang et al. 2024], [Guo et al. 2025a], [Bodini et al. 2020], [Singh et al. 2025], [Guo et al. 2025b], e [Lin et al. 2025], mostrando uma tendência significativa de tornar os modelos mais compreensíveis e auditáveis. Essa proporção demonstra o reconhecimento crescente da importância de garantir confiança clínica e aceitação por parte dos profissionais de saúde, mediante o uso de técnicas de interpretabilidade como SHAP, LIME e saliency maps. Já as categorias Integração Clínica (aproximadamente 10%), [Mekonnen et al. 2025], [Raja et al. 2024] e [Sammani et al. 2021] e Justiça e Mitigação de Vieses (cerca de 4%), [Cui and Han 2023], aparecem em menor proporção. Isso sugere que, embora o potencial de aplicação prática e a busca por equidade nos resultados sejam discutidos, ainda são temas emergentes e menos explorados nas publicações atuais. Esses resultados indicam uma lacuna importante para pesquisas futuras, voltadas à incorporação efetiva das ferramentas preditivas no ambiente hospitalar e à garantia de justiça algorítmica nos modelos aplicados à saúde.

3.2. Respostas às questões de pesquisa

3.2.1. Quais algoritmos de Machine Learning são mais utilizados na predição de IAM e com que desempenho?

Com base nos estudos analisados, o XGBoost foi o algoritmo mais recorrente na predição de IAM, com AUC entre 0,87 e 0,99 e acurácia de até 98% em diferentes contextos (predição in-hospital, 6 e 12 meses). O Random Forest, incluindo sua variação BRF, foi o segundo mais utilizado, com AUC entre 0,89 e 0,96 e acurácia de 94–96%, destacando-se pela interpretabilidade e por originar uma ferramenta web de risco. Algoritmos como SVM, LightGBM e modelos híbridos apresentaram AUC de até 0,94, enquanto modelos de Deep Learning (CNN, RNN, GNN) atingiram AUC entre 0,93 e 0,99 em análises de ECG e imagem, porém com menor frequência nos estudos. A Tabela 1 sintetiza o desempenho dos principais algoritmos, comparando AUC, acurácia e contexto de aplicação clínica.

Tabela 1. Desempenho comparativo dos principais algoritmos de ML na predição de IAM

Algoritmo	Nº estudos	AUC	Acurácia	Contexto
XGBoost	>14	0,87–0,99	até 98%	Predição in-hospital, prognóstico 6 e 12 meses
Random Forest / BRF	~8	0,89–0,96	94–96%	Risco clínico geral, ferramenta web de risco
SVM / Gradient Boosting / LightGBM	~4	até 0,94	—	Classificação com dados tabulares
Deep Learning (CNN, RNN, GNN)	~4	0,93–0,99	—	Análise de ECG e imagem médica

Fonte: elaborado pelos autores com base nos estudos analisados.

3.2.2. Quais abordagens de interpretabilidade são aplicadas para compreender o processo decisório dos modelos?

Com base nos estudos analisados, o SHAP (SHapley Additive exPlanations) destaca-se como a principal abordagem de interpretabilidade, presente na maioria dos trabalhos, permitindo visualizar o impacto global das variáveis e as contribuições individuais em cada predição de forma auditável e compreensível para médicos. O LIME foi utilizado em estudos para interpretações locais, como a influência de trechos do ECG em classificações específicas, enquanto métodos complementares (nomogramas clínicos, mapas de saliência e mecanismos de atenção) reforçam a transparência decisória. Em alguns casos, frameworks como GMCA e ferramentas web interativas foram empregados para visualizar o risco individualizado, fortalecendo a confiabilidade clínica dos modelos.

3.2.3. Quais considerações éticas (viés, transparência, responsabilidade médica) são relatadas nos estudos analisados?

Os estudos sobre predição de Infarto Agudo do Miocárdio destacam três principais eixos éticos: viés, transparência e responsabilidade médica. Há preocupação com amostras pequenas ou desbalanceadas, reforçando a necessidade de validação externa para garantir equidade e generalização. A transparência é vista como essencial para adoção clínica segura, com valorização de modelos explicáveis como SHAP, LIME e nomogramas, que permitem auditoria das decisões. Além disso, enfatiza-se que a IA deve atuar como suporte ao julgamento médico, e não substituí-lo, exigindo monitoramento contínuo, anonimização de dados e auditorias de fairness para assegurar uso ético e confiável.

4. Considerações Finais

Esta revisão sistemática evidencia o crescimento significativo das pesquisas sobre a aplicação de Machine Learning (ML) na predição do Infarto Agudo do Miocárdio. Constatou-se que algoritmos como XGBoost e Random Forest destacaram-se pelo desempenho superior (AUC acima de 0,87 e acurácia superior a 94%), especialmente por sua robustez diante de dados clínicos heterogêneos, observando-se também a consolidação de modelos ensemble e híbridos como tendência para otimizar a precisão diagnóstica. Quanto à interpretabilidade, há crescente adoção de técnicas como SHAP, LIME e nomogramas clínicos, demonstrando preocupação em tornar os modelos mais transparentes e confiáveis para uso médico. No campo ético, embora a mitigação de vieses e a justiça algorítmica sejam reconhecidas como essenciais, ainda são pouco exploradas nos estudos analisados. Apesar do desempenho promissor, a adoção clínica desses modelos enfrenta desafios concretos, como os custos de infraestrutura computacional, a heterogeneidade dos sistemas de prontuários eletrônicos e as exigências regulatórias para validação de ferramentas diagnósticas baseadas em IA. Nesse sentido, princípios de IA responsável (como auditabilidade, equidade algorítmica e transparência decisória) devem ser requisitos de projeto para que esses sistemas sejam eticamente adotados na prática médica.

Referências

Baidya, S. and Gupta, V. (2024). Predicting cardiac complications of myocardial infarction patients using machine learning. In *2024 IEEE International Conference on Big*

- Data (BigData)*, pages 7454–7462, Washington, DC, USA. IEEE.
- Bodini, M., Rivolta, M. W., and Sassi, R. (2020). Interpretability analysis of machine learning algorithms in the detection of st-elevation myocardial infarction. *Computing in Cardiology*, pages 1–4.
- Chen, Z., Zhang, L., Li, R., Wang, J., Chen, L., Jin, Y., Gao, M., Han, Z., Zhang, K., Wang, J., Li, X., and Yang, C. (2024). The development and validation of a prognostic prediction modeling study in acute myocardial infarction patients after percutaneous coronary intervention: hemorrhage and major cardiovascular adverse events. *Journal of Thoracic Disease*, 16(9):6216–6228.
- Cui, H. and Han, Y. (2023). Addressing racial bias in cardiovascular disease risk prediction with fair data augmentation. In *2023 International Conference on Artificial Intelligence in Medicine (ICAIM)*, pages 89–97. IEEE.
- Ehghaghi, M., Zhou, P.-Y., Cheng, W. Y., Rajabi, S., Kuo, C.-H., and Lee, E.-S. A. (2023). Interpretable disease prediction from clinical text by leveraging pattern disentanglement. In *2023 IEEE EMBS International Conference on Biomedical and Health Informatics (BHI)*, pages 1–7. IEEE.
- Forhad, S., Mim, T., Mosarat, Z., Taluckder, M. S., Al Masum, A., Islam, M. T., and Shuvo, M. R. K. (2025). Heart attack prediction: A comparative analysis of supervised machine learning algorithms. In *2025 International Conference on Quantum Photonics, Artificial Intelligence, and Networking (QPAIN)*, pages 1–7. IEEE.
- Guo, C. et al. (2025a). Interpretable artificial intelligence model for predicting heart failure severity after acute myocardial infarction. *BMC Cardiovascular Disorders*, 25(1):362.
- Guo, L., Wu, Y., Ma, N., and An, Y. (2025b). Kgd-gnn: A knowledge-guided graph neural network for myocardial infarction localization via 12-lead ecg. In *2025 IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*, pages 1–5.
- Kim, M. et al. (2024). Acute myocardial infarction prognosis prediction with reliable and interpretable artificial intelligence system. *JAMIA Open*, 7(2):ooae061.
- Kitchenham, B. and Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering. Technical Report EBSE-2007-01, Keele University & Durham University.
- Kucukakcali, Z., Akbulut, U. O., Basaga, S. F., and Akar, N. (2025). Beyond black boxes: Interpretable ai with explainable neural networks (enns) for acute myocardial infarction using hematological parameters. *Computers in Biology and Medicine*, 169:107659.
- Li, L., Ren, W., Lei, Y., Xu, L., and Ning, X. (2025). Hybrid cnn-transformer-woa model with xgboost-shap feature selection for arrhythmia risk prediction. *BMC Medical Informatics and Decision Making*, 25(1):291.
- Lin, Q. et al. (2025). Predicting the risk of heart failure after acute myocardial infarction using an interpretable machine learning model. *Frontiers in Cardiovascular Medicine*, 12:1444323.

- Mekonnen, D. et al. (2025). Artificial intelligence-assisted left ventricular global longitudinal strain assessment in ami patients. *International Journal of Cardiovascular Imaging*, 41(6):1225–1236.
- Mesinovic, M., Watkinson, P., and Zhu, T. (2025). Explainable machine learning for predicting icu mortality in myocardial infarction patients using pseudo-dynamic data. *Scientific Reports*, 15:27887.
- Raja, G. et al. (2024). Cardionetfusion: A deep learning and explainable ai integrated system for cardiovascular disease detection. In *2024 IEEE International Conference on Data Mining Workshops (ICDMW)*, pages 1–6.
- Salman, M. S., Shila, N., Hasan, K., Ahmed, P., Keya, M., Khushbu, S., and Noori, S. (2021). Data mining technique for prediction system of heart disease using associative classifications. pages 1–5.
- Sammani, A. et al. (2021). Automatic multilabel detection of icd10 codes in dutch cardiology discharge letters using neural networks. *NPJ Digital Medicine*, 4:32.
- Shen, C. et al. (2025). Comparison of machine learning and nomogram to predict 30-day in-hospital mortality in ami with cardiogenic shock. *BMC Cardiovascular Disorders*, 25(1):197.
- Singh, A., Alapatt, B. P., and George, J. P. (2025). An explainable ai-driven deep learning algorithm for heart disease detection in healthcare. *2025 6th International Conference on Intelligent Communication Technologies and Virtual Mobile Networks (ICICV)*, pages 471–477.
- Takci, H. (2018). Improvement of heart attack prediction by the feature selection methods. *Turkish Journal of Electrical Engineering and Computer Sciences*, 26(1):1–10.
- Tang, Z. et al. (2025). Identification of endoplasmic reticulum stress-related genes in acute myocardial infarction. *Biochemical Genetics*.
- Wang, C. et al. (2022). Predicting the prognosis of patients in the coronary care unit: A multi-category machine learning model using xgboost. *Frontiers in Cardiovascular Medicine*, 9:890067.
- Wang, Y. et al. (2024). Evaluating the effectiveness of feature selection and explainable ai in predicting acute myocardial infarction. In *2024 5th International Conference on Machine Learning and Computer Application (ICMLCA)*, pages 6–10.
- World Health Organization (2023). Cardiovascular diseases (cvds).
- Yang, R. et al. (2025). Risk factors and interpretability tool of in-hospital mortality in critically ill ami patients. *Journal of Intensive Medicine*, 4(2):103–112.
- Yu, Q., Fu, M., Hou, Z., and Wang, Z. (2025). Elucidating predictors of preoperative acute heart failure in older people with hip fractures through machine learning and shap analysis: a retrospective cohort study. *BMC Geriatrics*, 25(1):268.
- Zhang, G. et al. (2023). Atherosclerotic plaque vulnerability quantification system. *Frontiers in Cardiovascular Medicine*, 10:1245698.
- Zhu, Y. et al. (2025). Interpretable hybrid-ensemble acute myocardial infarction diagnosis with clinical transparency. *International Journal of Cardiology*, 438:133598.