

Comparativo de Precisão Entre Algoritmos de *Machine Learning* Para Previsão de Doenças Cardiovasculares: um Mapeamento Sistemático.

Augusto Cesar dos Santos Ferreira, Maria Eduarda Silva de Almeida, Fernando Castilho

¹Instituto de Computação – Universidade Federal de Mato Grosso (UFMT)
Cuiabá – MT – Brazil

{augusto.ferreira1,maria.almeida4}@sou.ufmt.br

Abstract. *This study conducts a systematic mapping of the use of Machine Learning (ML) models in cardiovascular disease (CVD) prediction. The research analyzed various articles addressing the application of ML techniques, focusing on ensemble models, Deep Learning, and traditional algorithms such as Random Forest, Support Vector Machines, and neural networks. The results show that Hybrid models, such as stacking and the use of Deep Learning techniques, achieve high accuracy levels, reaching up to 98.86%. However, challenges such as data quality and availability, feature selection, interpretability, and validation across diverse datasets remain significant barriers to widespread clinical implementation. The research concludes that, despite promising advances, the adoption of Machine Learning in CVD prediction requires continuous efforts to overcome these challenges, along with greater integration between accuracy, interpretability, and usability in the clinical context.*

Resumo. *Este estudo realiza um mapeamento sistemático sobre o uso de modelos de Machine Learning (ML) na previsão de doenças cardiovasculares (DCV). A pesquisa analisou diversos artigos que abordam a aplicação de técnicas de ML, com foco em modelos de ensemble, Deep Learning e algoritmos tradicionais, como Random Forest, Support Vector Machines e redes neurais. Os resultados indicam que modelos híbridos, como o stacking e o uso de técnicas de Deep Learning, apresentam altos níveis de acurácia, atingindo até 98,86%. No entanto, desafios como a qualidade e a disponibilidade de dados, a seleção de características, a interpretabilidade e a validação em conjuntos de dados diversos ainda são barreiras significativas para a implementação clínica generalizada. A pesquisa conclui que, apesar dos avanços promissores, a adoção de Machine Learning na previsão de DCV requer esforços contínuos na superação desses desafios, além de uma maior integração entre precisão, interpretabilidade e usabilidade no contexto clínico.*

1. Introdução

Sabe-se que as Doenças Cardiovasculares (DCVs) são a principal causa de morte ao redor do mundo. Tal fato é corroborado pela Organização Mundial da Saúde [World Health Organization 2021], que afirma que 17,9 milhões de pessoas perdem a vida anualmente em decorrência de complicações relacionadas a DCVs, representando 32% de todas as mortes globais. Diante desse cenário desafiador, o diagnóstico precoce

dessas doenças torna-se essencial para que sejam implementados tratamentos mais eficazes e, conseqüentemente, para a redução da elevada taxa de mortalidade.

Nos últimos anos, o avanço das técnicas de *Machine Learning* tem desempenhado um papel crucial na detecção e previsão de DCVs [Paixão et al. 2020]. Diversos algoritmos vêm sendo desenvolvidos e aprimorados para aumentar a precisão diagnóstica, permitindo identificar pacientes em risco com maior assertividade. Entretanto, a variedade de abordagens disponíveis impõe a necessidade de uma análise detalhada para determinar quais técnicas se destacam em termos de eficiência, levando em conta não apenas a acurácia, mas também fatores como custo computacional e interpretabilidade. Nesse contexto, a realização de um mapeamento sistemático se revela fundamental para sintetizar o conhecimento acumulado na área, comparando as metodologias utilizadas e evidenciando as soluções mais eficazes para a previsão de DCVs.

A relevância desta pesquisa não se restringe apenas à apresentação dos dados atuais, mas também à identificação de lacunas na literatura, o que poderá orientar futuros estudos na integração de modelos de *Machine Learning* na prática clínica. Para atingir esse propósito, adotou-se uma metodologia baseada na busca sistemática e filtragem criteriosa dos estudos por meio de critérios preestabelecidos, os quais serão detalhados na Seção 2.

O restante deste artigo está organizado da seguinte forma: a Seção 2 apresenta a metodologia utilizada para a realização deste mapeamento sistemático, detalhando os critérios de inclusão e exclusão dos estudos, bem como o procedimento de coleta de dados nas diferentes fontes; a Seção 3 discute os principais achados da pesquisa, comparando os algoritmos de *Machine Learning* aplicados à previsão de DCVs, destacando os modelos mais eficientes; a Seção 4 apresenta as considerações finais, ressaltando as principais conclusões do estudo e as direções para pesquisas futuras; por fim, a Seção 5 reúne as referências bibliográficas utilizadas neste trabalho.

2. Metodologia

O Mapeamento Sistemático constitui um método de pesquisa amplamente utilizado em contextos nos quais se busca uma visão abrangente de uma determinada área do conhecimento, com o objetivo de reunir e sintetizar o máximo de informações disponíveis [Kitchenham and Charters 2007]. Para a realização deste estudo, foi elaborado um planejamento que inclui a definição das questões de pesquisa, a formulação da string de busca, a escolha das estratégias de busca e a especificação dos critérios de inclusão e exclusão.

As questões que nortearam este mapeamento sistemático foram as seguintes:

Q1: Quais os algoritmos de *Machine Learning* mais utilizados para orientar diagnósticos?

Q2: Qual a eficácia de cada um deles, e qual o mais acurado?

Q3: Quais as principais limitações desses métodos?

Base de dados	String de busca
Inglês	("machine learning algorithms") AND ("heart disease prediction") AND ("efficiency"OR "accuracy") AND ("comparison"OR "evaluation")

Tabela 1. Strings de busca utilizada para o Mapeamento Sistemático

Utilizaram-se as normas a seguir no processo de filtragem de trabalhos deste mapeamento: (i) Os estudos devem comparar a eficiência de modelos de *Machine Learning* na previsão de DCVs; (ii) Os trabalhos devem ter sido publicados em periódicos ou conferências revisados por pares; (iii) Devem estar disponíveis integralmente; (iv) Devem ter sido publicados em português ou inglês. Os trabalhos encontrados foram excluídos com base na negação dos critérios previamente estabelecidos.

2.1. Levantamento de Dados

A fim de garantir a transparência e a reprodutibilidade do presente mapeamento sistemático, esta seção apresenta o processo de levantamento de dados conduzido em três etapas sequenciais. Cada uma dessas etapas foi cuidadosamente planejada para assegurar a seleção de estudos relevantes e alinhados aos objetivos da pesquisa. A seguir, detalha-se cada passo do processo, desde a busca inicial nas bases de dados até a filtragem final dos artigos selecionados, conforme sintetizado na Tabela 2.

Base de dados	Passo 1	Passo 2	Passo 3
Scopus	74	17	11
IEE Xplore	16	3	3
Total	90	20	14

Tabela 2. Quantidade de trabalhos selecionados

Na Tabela 2, apresenta-se a totalidade dos trabalhos selecionados passo a passo, seguindo os critérios previamente estabelecidos. O Passo 1 consistiu na busca inicial, na qual foram coletados todos os artigos encontrados nas bases de dados IEEE Xplore e Scopus utilizando a string de busca definida. Essas bases foram escolhidas por fornecerem acesso a um grande volume de pesquisas relevantes na área de *Machine Learning* aplicado à previsão de DCVs, além de garantirem a disponibilidade gratuita de grande parte dos trabalhos analisados. Outras bases foram consideradas, mas apresentaram limitações, como o acesso pago à maioria dos artigos ou a predominância de publicações não diretamente relacionadas ao tema, sendo que os artigos mais relevantes dessas bases também estavam presentes no IEEE Xplore e no Scopus.

No Passo 2, foi realizada uma filtragem preliminar com base nos títulos e resumos dos artigos, considerando os critérios de inclusão e exclusão previamente definidos. Estudos que não comparavam a eficiência de modelos de *Machine Learning* para previsão de DCVs ou que não estavam disponíveis integralmente foram descartados nesta etapa.

Por fim, no Passo 3, aplicou-se a filtragem final após a leitura completa dos artigos restantes. Essa etapa permitiu identificar com precisão os estudos que realmente atendiam aos requisitos estabelecidos, resultando na seleção final dos trabalhos analisados.




Figura 1. Estudos por ano

Na Figura 1, foi realizada uma distribuição dos artigos estudados em função do tempo. Apesar da estabilidade nos anos previamente observados, nota-se um salto nos trabalhos condizentes ao eixo temático no ano de 2023, indicando uma alta de interesse dos pesquisadores naquele período específico de tempo.

3. Discussão

Esta seção analisa criticamente os achados dos estudos revisados, explorando a eficiência, a aplicabilidade e os desafios dos modelos de *Machine Learning* na previsão de doenças cardiovasculares (DCV).

3.1. Modelos de *Machine Learning* Mais Eficientes para a Previsão de DCV

Os estudos revisados destacam uma ampla variedade de modelos de *Machine Learning* que demonstram alta precisão na previsão de DCV. No entanto, a eficiência desses modelos pode ser interpretada sob diferentes prismas, incluindo acurácia, custo computacional e interpretabilidade.

Os modelos de *ensemble*, que combinam mais de um método, têm se mostrado particularmente promissores. O modelo de *stacking* apresentado por [Mohapatra et al. 2023] obteve uma impressionante acurácia de 94,67% ao utilizar *Gradient Boosting* como *meta-learner*. De forma semelhante, um modelo híbrido combinando *Machine Learning* e *Deep Learning* [Abbas et al. 2023] atingiu 94,14% de acurácia. Além disso, técnicas de votação em *ensemble* também demonstraram grande potencial [Saboor et al. 2022] [Gao et al. 2021], com destaque para o método de *bagging* com *Decision Tree*, que apresentou os melhores resultados em um dos estudos [Gao et al. 2021].

As *Deep Neural Networks* (DNNs), incluindo arquiteturas como *Convolutional Neural Networks* (CNNs) e *Long Short-Term Memory* (LSTM), além de suas versões híbridas, chamadas *Hybrid Deep Neural Networks* (HDNNs), vêm se destacando como alternativas de alto desempenho. Um modelo HDNN que combina CNN e LSTM, por exemplo, atingiu uma acurácia notável de 98,86% [Reshan et al. 2023]. Da mesma forma, uma abordagem baseada no *Coati Optimisation Algorithm* (COA) aplicada a uma *Artificial Neural Network* (ANN) obteve uma acurácia média de 98,43% [Murtaza et al. 2023].

Entre os algoritmos tradicionais de *Machine Learning*, o *Random Forest* (RF) continua sendo um dos mais citados por sua alta precisão [Saboor et al. 2022] [Ghosh et al. 2021] [Mohapatra et al. 2023] [Gao et al. 2021]. Um estudo específico mostrou que a combinação de RF com a técnica de seleção de características via *Relief* elevou a acurácia para 99,05% [Ghosh et al. 2021]. Outro algoritmo de destaque é o *Gradient Boosting*, que atingiu 94,67% de acurácia [Mohapatra et al. 2023]. Já o *Support Vector Machine* (SVM), após ajustes de hiperparâmetros, alcançou 96,72% de acurácia [Saboor et al. 2022].

Além disso, um estudo comparativo apontou que o *Multilayer Perceptron* (MLP) apresentou o melhor desempenho entre classificadores individuais quando aplicado a um conjunto de dados pré-processado [Dou et al. 2024]. A seleção de características melhorou ainda mais os resultados, permitindo que um modelo de votação suave (*soft voting*) alcançasse um AUC de 0,951 e um modelo de *stacking* atingisse um AUC de 0,952 [Dou et al. 2024]. No entanto, é importante considerar que a eficiência desses modelos pode variar dependendo do conjunto de dados utilizado, das características selecionadas e das métricas de avaliação empregadas [Saboor et al. 2022] [Ghosh et al. 2021].

3.2. Modelos de *Machine Learning* Mais Utilizados para a Previsão de DCV

Os estudos revisados evidenciam a diversidade de modelos de *Machine Learning* aplicados à previsão de DCV. Entre os algoritmos clássicos mais utilizados, destacam-se:

- ***Logistic Regression (LR)***: frequentemente usada como linha de base para comparação de desempenho [Saboor et al. 2022] [Singh et al. 2024].
- ***Decision Trees (DT)***: aplicadas individualmente ou como base para modelos de *ensemble* [Saboor et al. 2022] [Singh et al. 2024] [Gao et al. 2021].
- ***Random Forest (RF)***: amplamente empregado devido à sua robustez e precisão [Saboor et al. 2022] [Ghosh et al. 2021] [Singh et al. 2024] [Mohapatra et al. 2023] [Gao et al. 2021].
- ***Support Vector Machines (SVM)***: conhecido por sua eficiência em diferentes configurações [Saboor et al. 2022] [Ghosh et al. 2021] [Singh et al. 2024] [Gao et al. 2021].
- ***K-Nearest Neighbors (KNN)***: empregado por ser um método não paramétrico que utiliza métricas de distância para identificar os vizinhos mais próximos e realizar classificações ou regressões. [Saboor et al. 2022] [Ghosh et al. 2021] [Singh et al. 2024] [Gao et al. 2021].
- ***Naive Bayes (NB)***: utilizado tanto como classificador simples quanto combinado com outras técnicas [Saboor et al. 2022] [Ghosh et al. 2021] [Singh et al. 2024] [Mohapatra et al. 2023] [Gao et al. 2021].
- ***Métodos de Boosting (XGBoost, AdaBoost, Gradient Boosting)***: cada vez mais aplicados devido ao seu alto desempenho e capacidade de lidar com dados complexos [Saboor et al. 2022] [Singh et al. 2024] [Ghosh et al. 2021] [Mohapatra et al. 2023] [Dou et al. 2024].

Além dos modelos clássicos, o *Deep Learning* tem ganhado crescente relevância, com o uso de *Artificial Neural Networks* (ANNs), *Convolutional Neural Networks* (CNNs) e *Recurrent Neural Networks* (RNNs), como LSTM. Modelos híbridos, como CNN-LSTM, também estão sendo investigados para melhorar a previsão de DCV [Reshan et al. 2023] [Murtaza et al. 2023].

3.3. Desafios na Previsão de DCV usando *Machine Learning*

Apesar dos avanços significativos, a previsão de DCV por meio de *Machine Learning* ainda enfrenta desafios substanciais. A qualidade e a disponibilidade dos dados são fatores críticos, pois a precisão dos modelos depende fortemente da confiabilidade das informações utilizadas [Saboor et al. 2022] [Ghosh et al. 2021]. Além disso, a seleção e engenharia de características desempenham um papel crucial, já que escolhas inadequadas podem levar a problemas como overfitting ou underfitting, comprometendo o desempenho do modelo [Ghosh et al. 2021].

A variedade de conjuntos de dados também afeta os resultados [Ghosh et al. 2021]. Enquanto muitos estudos utilizam o Cleveland Heart Disease Dataset com 14 atributos clínicos [Sajja and Kalluri 2020], como idade, sexo, tipo de dor no peito, pressão arterial, colesterol e frequência cardíaca, outros mesclam diferentes bases do UCI (como Cleveland, Hungria, Suíça e VA Long Beach) [Saboor et al. 2022] ou recorrem a dados reais, como prontuários eletrônicos, sinais de ECG [Kusuma and Udayan 2020], e exames laboratoriais.

Outro aspecto relevante é a interpretabilidade dos modelos. Enquanto métodos mais simples, como regressão logística e árvores de decisão, oferecem maior transparência, abordagens mais complexas, como *Deep Neural Networks*, frequentemente são vistas como "caixas-pretas", o que pode dificultar sua adoção na prática clínica [Paul and Masood 2024]. A generalização e validação dos modelos também são desafios essenciais, pois um desempenho robusto em diferentes conjuntos de dados é indispensável para garantir aplicabilidade em cenários reais [Paul and Masood 2024].

Além disso, há diferenças na definição da condição cardiovascular prevista. Alguns estudos focam em doenças cardíacas de forma geral [Paul and Masood 2024]; outros delimitam patologias específicas, como DAC (Doença Arterial Coronariana) [Ghosh et al. 2021] ou insuficiência cardíaca [Ravulapalli et al. 2023]. Essa falta de uniformidade dificulta a comparação entre os modelos.. Por fim, mesmo que um modelo apresente alto desempenho, sua integração na prática clínica enfrenta barreiras relacionadas à usabilidade e à aceitação por parte dos profissionais de saúde, o que reforça a necessidade de soluções que equilibrem precisão e interpretabilidade [Singh et al. 2024]. Superar esses desafios é fundamental para consolidar o uso eficaz de *Machine Learning* na previsão e no tratamento de DCV.

4. Considerações Finais

Em síntese, a análise dos artigos revisados aponta para um horizonte promissor quanto à aplicação de técnicas de *Machine Learning* na previsão de doenças cardiovasculares (DCV). Observa-se uma crescente produção científica que evidencia a eficácia de diferentes modelos, especialmente aqueles baseados em *ensemble learning* e *Deep Learning*, na obtenção de alta precisão na identificação e na previsão de risco de DCV [Mohapatra et al. 2023] [Abbas et al. 2023] [Reshan et al. 2023] [Murtaza et al. 2023].

A seção de discussão destaca a diversidade de algoritmos empregados, desde abordagens clássicas como Regressão Logística, Árvores de Decisão, *Random Forest* e *Support Vector Machines*, até modelos mais sofisticados, como Redes Neurais Artificiais, *Convolutional Neural Networks* e Redes Neurais Recorrentes [Saboor et al. 2022]

[Singh et al. 2024] [Sajja and Kalluri 2020] [Kusuma and Udayan 2020]. A tendência parece apontar para uma exploração cada vez mais intensa de modelos de *ensemble* e *Deep Learning*, refletindo o grande potencial dessas técnicas em captar padrões complexos nos dados médicos [Saboor et al. 2022] [Singh et al. 2024].

Entretanto, é imperativo reconhecer os desafios substanciais que ainda precisam ser superados para viabilizar uma integração plena e eficaz dessas tecnologias na prática clínica [Saboor et al. 2022] [Ghosh et al. 2021] [Paul and Masood 2024]. Esses desafios incluem:

- Garantir a qualidade e a disponibilidade de conjuntos de dados robustos e representativos, fundamentais para o treinamento e validação de modelos confiáveis [Saboor et al. 2022] [Ghosh et al. 2021] [Paul and Masood 2024].
- A relevância da seleção e engenharia de características pertinentes, que impactam diretamente tanto a precisão quanto a interpretabilidade dos modelos [Saboor et al. 2022] [Ghosh et al. 2021] [Paul and Masood 2024] [Gao et al. 2021].
- O aprimoramento da interpretabilidade, particularmente em modelos de *Deep Learning*, para fortalecer a confiança e compreensão dos profissionais de saúde [Paul and Masood 2024] [Husain et al. 2023].
- A validação rigorosa dos modelos em conjuntos de dados externos e diversos, garantindo a generalização e robustez das previsões [Paul and Masood 2024] [Reshan et al. 2023].
- O tratamento adequado do desbalanceamento de dados, um desafio recorrente em conjuntos de dados médicos, que pode resultar em modelos enviesados [Ravulapalli et al. 2023] [Paul and Masood 2024].
- A complexidade da integração desses modelos em sistemas de saúde existentes, considerando as questões de usabilidade, ética e privacidade dos pacientes [Singh et al. 2024] [Paul and Masood 2024] [Husain et al. 2023].

Portanto, embora o campo da aplicação de *Machine Learning* na previsão de DCV tenha apresentado avanços notáveis, o caminho para uma implementação clínica ampla e confiável exige um esforço contínuo na superação dos desafios previamente mencionados. Pesquisas futuras deverão não apenas focar no desenvolvimento de modelos com maior precisão, mas também garantir a qualidade dos dados, aprimorar a interpretabilidade, realizar validações rigorosas e considerar os aspectos práticos e éticos da aplicação desses modelos no contexto da saúde cardiovascular [Singh et al. 2024] [Paul and Masood 2024].

Referências

- Abbas, S., Sampedro, G. A., Alsubai, S., Almadhor, A. S., and Kim, T.-H. (2023). An efficient stacked ensemble model for heart disease detection and classification. *Computers, Materials and Continua*.
- Dou, Y., Liu, J., Meng, W., and Zhang, Y. (2024). Comparative analysis of supervised learning algorithms for prediction of cardiovascular diseases. *Technology and Health Care*.
- Gao, X.-Y., Ali, A. A., Hassan, H. S., and Anwar, E. M. (2021). Improving the accuracy for analyzing heart diseases prediction based on the ensemble method. *Complexity*.

- Ghosh, P., Azam, S., Jonkman, M., Karim, A., Shamrat, F. M. J. M., Ignatious, E., Shultana, S., Beeravolu, A. R., and Boer, F. D. (2021). Efficient prediction of cardiovascular disease using machine learning algorithms with relief and lasso feature selection techniques. *IEEE Access*.
- Husain, M., Kumar, P., Ahmed, M. N., Ali, A., Rasool, M. A., Hussain, M. R., and Dildar, M. S. (2023). Harnessing ensemble in machine learning for accurate early prediction and prevention of heart disease. *International Journal of Advanced Computer Science and Applications*.
- Kitchenham, B. and Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering. Technical report, Keele University and Durham University.
- Kusuma, S. and Udayan, J. D. (2020). Analysis on deep learning methods for ecg based cardiovascular disease prediction. *Scalable Computing*.
- Mohapatra, S., Mishra, I., and Mohanty, S. (2023). Stacking model for heart stroke prediction using machine learning techniques. *EAI Endorsed Transactions on Pervasive Health and Technology*.
- Murtaza, A. A., Saher, A., Mohyuddin, H., Moosavi, S. K. R., Zafar, M. H., and Sanfilippo, F. (2023). Enhancing cardiovascular disease prediction via hybrid deep learning architectures: A step towards smart healthcare. *2023 2nd International Conference on Emerging Trends in Electrical, Control, and Telecommunication Engineering, ETECTE 2023 - Proceedings*.
- Paixão, G., Santos, B. C., Araújo, R., Ribeiro, H., and Moraes, J. L. A. (2020). Machine learning na medicina: Revisão e aplicabilidade. *Arquivos Brasileiros de Cardiologia*.
- Paul, V. V. and Masood, J. A. I. S. (2024). Exploring predictive methods for cardiovascular disease: A survey of methods and applications. *IEEE Access*.
- Ravulapalli, L. T., Paladugu, R. K., Likki, V. K. R., Mothukuri, R., Mukkapati, N., and Kilaru, S. (2023). Evaluative study of machine learning classifiers in predicting heart failure: A focus on imbalanced datasets. *Ingenierie des Systemes d'Information*.
- Reshan, M. S. A., Amin, S., Zeb, M. A., Sulaiman, A., Alshahrani, H., and Shaikh, A. (2023). A robust heart disease prediction system using hybrid deep neural networks. *IEEE Access*.
- Saboor, A., Usman, M., Sikandar, A., Samad, A., Abrar, M. F., and Ullah, N. (2022). A method for improving prediction of human heart disease using machine learning algorithms. *Mobile Information Systems*.
- Sajja, T. K. and Kalluri, H. K. (2020). A deep learning method for prediction of cardiovascular disease using convolutional neural network. *Revue d'Intelligence Artificielle*.
- Singh, E., Singh, V., Rai, A., Christopher, I., Mishra, R., and Arikumar, K. (2024). Early detection of cardiovascular disease with different machine learning approaches. *EAI Endorsed Transactions on Internet of Things*.
- World Health Organization (2021). Cardiovascular diseases (cvds). Accessed: 2025-03-06.