

COMPARAÇÃO ENTRE REDES NEURAIS E SISTEMAS IMUNOLÓGICOS ARTIFICIAIS PARA IDENTIFICAR DOENÇAS CARDIOVASCULARES.

CAIO HENRIQUE DO NASCIMENTO SOARES¹
IGOR FERNANDES DE MATOS²
LUCAS ATHIÉ³
LUCIANO GONÇALVES DE CARVALHO⁴

RESUMO

As doenças cardiovasculares representam uma das principais causas de mortalidade global, exigindo métodos eficazes de diagnóstico precoce. Este estudo propõe uma comparação entre dois modelos computacionais aplicados à predição de doenças cardíacas: Redes Neurais Multicamadas (MLP), baseadas em aprendizado profundo, e Sistemas Imunológicos Artificiais (AIS), inspirados em mecanismos adaptativos do sistema imunológico humano. Para isso, foram utilizados dois conjuntos de dados públicos: o Cleveland Heart Disease Dataset, composto por 303 registros, e o Cardiovascular Disease Dataset (Kaggle), com 70.000 amostras. Os modelos foram avaliados com base em três métricas principais: acurácia, tempo de processamento e eficiência (acertos por segundo). Os resultados mostraram que o modelo MLP obteve melhor desempenho geral, especialmente em grandes volumes de dados. Por outro lado, o AIS demonstrou maior leveza computacional em bases menores, com destaque para sua eficiência no dataset Cleveland. Conclui-se que a escolha do modelo mais adequado deve considerar o contexto de aplicação, equilibrando precisão diagnóstica e disponibilidade de recursos computacionais.

Palavras-chave: Diagnóstico precoce; Doenças cardiovasculares; Redes neurais; Sistema imunológico artificial.

ABSTRACT

Cardiovascular diseases are among the leading causes of global mortality, demanding effective methods for early diagnosis. This study presents a comparison between two computational models applied to the prediction of heart disease: Multilayer Perceptrons (MLP), based on deep learning, and Artificial Immune Systems (AIS), inspired by adaptive mechanisms of the human immune system. Two public datasets were used: the Cleveland Heart Disease Dataset, comprising 303 records, and the Cardiovascular Disease Dataset (Kaggle), with 70,000 samples. The models were evaluated using three main metrics:

¹Graduando, Tecnologia em Análise e Desenvolvimento de Sistemas, Faculdade de Tecnologia de Mogi das Cruzes – FATEC-MC. Mogi das Cruzes-SP. E-mail: caio.soares10@fatec.sp.gov.br

²Graduando, Tecnologia em Análise e Desenvolvimento de Sistemas, Faculdade de Tecnologia de Mogi das Cruzes – FATEC-MC. Mogi das Cruzes-SP.

³Graduando, Tecnologia em Análise e Desenvolvimento de Sistemas, Faculdade de Tecnologia de Mogi das Cruzes – FATEC-MC. Mogi das Cruzes-SP.

⁴Docente, Faculdade de Tecnologia de Mogi das Cruzes – FATEC-MC. Mogi das Cruzes-SP.

accuracy, processing time, and efficiency (correct predictions per second). The results showed that the MLP model achieved superior overall performance, particularly with large datasets. In contrast, the AIS model exhibited greater computational lightness in smaller datasets, standing out in efficiency with the Cleveland dataset. It is concluded that the most suitable model depends on the application context, balancing diagnostic precision and available computational resources.

Key words: Artificial immune system; Cardiovascular diseases; Early diagnosis; Neural networks.

INTRODUÇÃO

A previsão de ocorrências de doenças cardiovasculares representa um dos maiores desafios contemporâneos na área da saúde, tendo em vista sua alta prevalência e os custos sociais e econômicos associados. A necessidade de diagnósticos precoces tem impulsionado a busca por métodos inovadores de reconhecimento de padrões, que consigam lidar com a complexidade e heterogeneidade dos dados clínicos.

Nesse cenário, a inteligência artificial (IA) tem demonstrado um potencial crescente na predição de riscos cardiovasculares, como apontam revisões sistemáticas. Técnicas computacionais, especialmente as de aprendizado profundo, emergem como ferramentas promissoras para auxiliar na tomada de decisão médica, visando diagnósticos mais precisos.

Este estudo foca na comparação de duas abordagens computacionais distintas: as redes neurais multicamadas (MLP), baseadas em aprendizado profundo, e os sistemas imunológicos artificiais (AIS), inspirados na dinâmica adaptativa do sistema imunológico natural. Ambas as técnicas oferecem caminhos diferentes para a detecção de padrões, justificando uma análise comparativa de suas vantagens e limitações específicas.

Este artigo apresenta uma comparação entre os métodos de redes neurais multicamadas e os sistemas imunológicos artificiais, utilizando como referência o conjunto de dados Cleveland, amplamente reconhecido na comunidade científica. A comparação será realizada a partir das seguintes métricas: acurácia, eficiência e

tempo de processamento, que permitem identificar, de forma sistemática, como os fundamentos conceituais de cada abordagem se traduzem em desempenho prático.

MATERIAL E MÉTODOS

Neste trabalho, foram utilizados os seguintes conjuntos de dados relacionados a doenças cardiovasculares para a realização do treinamento e testes de ambas as formas de identificação de doenças cardiovasculares:

- Heart Disease Dataset | Cleveland (UCI ID 45): composto por 303 amostras e originalmente 76 atributos, sendo que apenas 14 atributos são relevantes para a predição de doenças cardíacas;
- Cardiovascular Disease Dataset (Kaggle): contém 70.000 amostras e 11 atributos clínicos que permite testar a escalabilidade e a generalização dos modelos em virtude do grande volume de dados.

Ambos os conjuntos de dados passaram por pré-processamento para garantir consistência, remoção de valores ausentes, e normalização dos atributos contínuos, quando necessário.

Todos os testes foram realizados em um ambiente computacional configurado da seguinte forma:

- Sistema Operacional: Windows 11 (x64);
- Processador: AMD Ryzen 5 5500 @ 3.60 GHz;
- Memória RAM: 32 GB DDR4 @ 3200 MHz;
- Placa de Vídeo: NVIDIA GeForce RTX 4060 (8 GB);
- Armazenamento: SSD NVMe ADATA LEGEND 800 – 932 GB.

O desenvolvimento e a execução dos experimentos foram realizados utilizando a linguagem de programação Python, na versão 3.11, em conjunto com o ambiente de desenvolvimento Visual Studio Code, versão 1.98.

Todos os dados, códigos e resultados estão disponíveis no repositório do projeto no GitHub.

REFERENCIAL TEÓRICO

A elevada prevalência das doenças cardiovasculares e seu impacto socioeconômico motivam a aplicação de técnicas de inteligência artificial para diagnósticos precoces. Hossain et al. (2023) destacam que, diante da heterogeneidade dos dados clínicos, métodos capazes de extrair padrões sutis e não lineares são essenciais para antecipar eventos adversos. Onishchenko et al. (2022), em revisão sistemática, corroboram o crescente potencial da IA na predição de riscos cardiovasculares, apontando tanto redes neurais quanto outros modelos como promissores. Santos (2023) demonstra aplicações de deep learning que alcançam alta acurácia em diagnósticos, reforçando a viabilidade clínica dessas abordagens.

As redes neurais multicamadas (MLPs) se fundamentam no algoritmo de retropropagação, inicialmente formalizado por Rumelhart, Hinton e Williams (1986), permitindo o ajuste de pesos em múltiplas camadas ocultas para aprender representações internas. LeCun et al. (1998) aplicaram variantes convolucionais (LeNet-5) ao reconhecimento de padrões visuais, evidenciando a eficiência de arquiteturas profundas em grandes volumes de dados. Bengio (2009) consolidou a teoria das “Deep Architectures”, explicando como múltiplas camadas hierárquicas capturam abstrações de alto nível em problemas complexos. Viana e Godoy (2008) fornecem fundamentos matemáticos das MLPs, detalhando o papel de funções de ativação não lineares e regularização no aprendizado de representações robustas.

Inspirados na resposta adaptativa do sistema imunológico natural, os Sistemas Imunológicos Artificiais (AIS) exploram conceitos de seleção clonal, tolerância e memória para detecção de padrões. Dasgupta (2002) apresenta os algoritmos básicos de AIS, destacando sua capacidade de aprendizado distribuído e detecção de anomalias. Timmis et al. (2002) aprofundam a seleção negativa, diferenciando elementos “self” e “non-self” em cenários de segurança computacional, e mostram como tais mecanismos se adaptam a variações inesperadas nos dados. Lima (2021)

revisita inovações biotecnológicas que inspiram melhorias em AIS para aplicações médicas, sugerindo potencial para sistemas híbridos.

Nesse contexto de comparação entre abordagens computacionais, tanto as redes neurais multicamadas quanto os sistemas imunológicos artificiais têm sido avaliados em benchmarks padronizados, sendo o Cleveland Heart Disease Dataset um dos mais utilizados para esse fim. Disponível no UCI Machine Learning Repository, o conjunto contém 14 atributos clínicos e demográficos amplamente usados em estudos de predição cardiovascular. Polat e Günes (2007) empregaram seleção de atributos e algoritmos AIS neste conjunto, alcançando elevada acurácia e ressaltando sua relevância como padrão de comparação. Dua e Graff (2019) documentam a consolidação e atualização contínua deste repositório, garantindo sua representatividade e qualidade para experimentos científicos.

Para comparar de forma sistemática o desempenho dos modelos, utilizam-se as seguintes métricas consagradas em predição clínica:

- Acurácia: proporção de previsões corretas sobre o total de casos;
- Eficiência: medida de recursos computacionais e latência de inferência;
- Tempo de Processamento: relevante em cenários de suporte à decisão em tempo real.

Patel (2018), Yu (2019) e Zhang (2021) aplicam as métricas citadas ao conjunto Cleveland, permitindo avaliar trade-offs entre desempenho e viabilidade prática.

RESULTADOS E DISCUSSÃO

Após a realização de experimentos com os algoritmos de AIS e MLP utilizando os conjuntos de dados Cleveland e Cardiovascular Disease, os resultados, dispostos nos Quadro 1 e 2, são apresentados individualmente para cada abordagem, seguidos de uma análise comparativa.

Quadro 1. Experimento com o Algoritmo AIS.

Comparação entre redes neurais e sistemas imunológicos artificiais para identificar doenças cardiovasculares.	Caio H. do N. Soares; Igor F. de Matos; Lucas Athié; Luciano G. de Carvalho.
---	--

CONJUNTO DE DADOS	ACURÁCIA (%)	TEMPO DE PROCESSAMENTO(S)	EFICÁCIA (ACERTOS/S)
Cleveland	53,85	4,56	10,7
Cardiovascular Disease	60,96	830,85	15,4

Fonte: Elaborado pelos autores, (2025).

Apesar da acurácia relativamente baixa, o algoritmo AIS demonstrou excelente desempenho em termos de velocidade, o que indica boa eficiência computacional em bases reduzidas. No segundo experimento houve um ganho significativo em acurácia, porém com um tempo de execução extremamente elevado. Isso indica que o AIS possui limitações de escalabilidade em contextos com grandes volumes de dados.

Quadro 2. Experimento com o Algoritmo MLP.

CONJUNTO DE DADOS	ACURÁCIA (%)	TEMPO DE PROCESSAMENTO (S)	EFICÁCIA (ACERTOS/S)
Cleveland	52,75	11,01	4,36
Cardiovascular Disease	73,95	193,52	80,25

Fonte: Elaborado pelos autores, (2025).

No caso do conjunto de dados Cleveland, a acurácia foi muito próxima à obtida pelo AIS, porém com uma eficiência computacional inferior. Já o desempenho no conjunto de dados Cardiovascular Disease, ele foi significativamente superior ao do AIS, tanto em termos de acurácia quanto de eficiência, apesar do tempo de execução mais elevado em relação ao conjunto de dados Cleveland.

Esses resultados apontam que o AIS é mais leve e rápido em conjunto de dados menores, característica do Cleveland, mas não lida bem com o aumento da complexidade dos dados, especialmente no que diz respeito ao tempo de execução. Já o modelo MLP demonstrou escalabilidade superior, mantendo boa acurácia e

aumentando sua eficiência proporcionalmente no conjunto de maior porte, característica do Cardiovascular Disease.

Essa comparação reforça que a escolha do algoritmo ideal depende diretamente do contexto de aplicação. Para sistemas embarcados ou com limitação de hardware, o AIS pode ser mais apropriado. Em contrapartida, para ambientes com maior capacidade computacional e foco em precisão diagnóstica, o uso de redes neurais multicamadas tende a ser mais eficaz.

CONCLUSÃO

A crescente demanda por diagnósticos cardiovasculares precisos e precoces motiva a busca por soluções computacionais equilibradas entre desempenho e viabilidade prática. Neste estudo, comparou-se o modelo AIS, inspirado em processos biológicos, com a MLP, baseada em redes neurais profundas, em dois conjuntos clínicos distintos. A MLP destacou-se em dados volumosos (Cardiovascular Disease), com acurácia de 73,95% e eficiência de 80,25 acertos por segundo, revelando robustez e escalabilidade; já o AIS mostrou-se mais leve e rápido no conjunto menor (Cleveland), com 10,75 acertos por segundo e menor tempo de execução, adequando-se a ambientes com restrições de hardware. Não há um modelo universalmente superior: a escolha depende do volume de dados, recursos computacionais e exigência de confiabilidade. Como perspectiva futura, sugere-se explorar abordagens híbridas e testar esses métodos em dados clínicos reais e não estruturados para ampliar sua aplicabilidade hospitalar.

REFERÊNCIAS BIBLIOGRÁFICAS

BENGIO, Y. Learning deep architectures for AI. **Foundations and Trends in Machine Learning**. Hanover, MA, EUA. p.1-127. 2009. DASGUPTA, D. An overview of artificial immune systems and their applications. In: **Artificial Immune Systems and Their Applications**. Springer, Berlin, Alemanha. p.3–21. 2002.

DUA, D.; GRAFF, C. UCI Machine Learning Repository. **University of California, Irvine, School of Information and Computer Sciences**. Irvine, CA, EUA. 2019. Disponível em: <https://archive.ics.uci.edu/ml/datasets/heart+Disease>. Acesso em: 10 abr. 2025.

HINTON, G. E. Learning distributed representations of concepts. In: **Proceedings of the Eighth Annual Conference of the Cognitive Science Society**. Amherst, MA, EUA. p.1-12. 1986.

HOSSAIN, M. I. et al. Predictive modeling of cardiovascular diseases: trends, challenges and future prospects. **Journal of Biomedical Informatics**. Amsterdam, Países Baixos. v.138, p.104304. 2023.

LECUN, Y. et al. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**. Piscataway, NJ, EUA. v.86, n.11, p.2278-2324. 1998.

LIMA, M. L. Biotecnologia aplicada à saúde: perspectivas e desafios. **Revista Brasileira de Biotecnologia**. São Paulo, SP, Brasil. v.25, n.2, p.89-101. 2021.

ONISHCHENKO, A. et al. Artificial intelligence in cardiovascular risk prediction: a systematic review. **Computers in Biology and Medicine**. Amsterdam, Países Baixos. v.147, p.105751. 2022.

PATEL, J. Predicting heart disease using machine learning algorithms. **International Journal of Computer Applications**. New York, NY, EUA. v.170, n.5, p.1-5. 2018.
POLAT, K.; GUNES, S. A novel hybrid intelligent method based on C4.5 decision tree classifier and one-against-all approach for multi-class classification problems. **Expert Systems with Applications**. Amsterdam, Países Baixos. v.36, n.2, p.1587–1592. 2007.

SANTOS, R. P. Redes neurais aplicadas à predição médica: um enfoque em doenças cardiovasculares. **Revista de Inteligência Artificial na Saúde**. Belo Horizonte, MG, Brasil. v.3, n.1, p.33-44. 2023.

SOCIEDADE DE CARDIOLOGIA DO ESTADO DE SÃO PAULO. Diretrizes para prevenção e diagnóstico precoce de doenças cardiovasculares. **Sociedade de Cardiologia do Estado de São Paulo**. São Paulo, SP, Brasil. 2020.

TIMMIS, J. Artificial immune systems: a novel paradigm to pattern recognition. In: **Artificial Neural Networks and Genetic Algorithms**. Vienna, Áustria. p.221–226. 2002.

Comparação entre redes neurais e sistemas imunológicos artificiais para identificar doenças cardiovasculares.

Caio H. do N. Soares; Igor F. de Matos; Lucas Athié; Luciano G. de Carvalho.
--

VIANA, A. C.; GODOY, R. S. Introdução às redes neurais artificiais: fundamentos e aplicações. **Revista de Engenharia e Tecnologia**. Porto Alegre, RS, Brasil. v.1, n.1, p.45-56. 2008.

YU, W. Deep learning for cardiovascular disease prediction. **Journal of Healthcare Informatics Research**. Cham, Suíça. v.3, n.2, p.113–127. 2019.

ZHANG, Y. Machine learning approaches for early diagnosis of cardiovascular diseases. **IEEE Access**. Piscataway, NJ, EUA. v.9, p.19012–19022. 2021.