

As Aplicações das Redes Neurais Convolucionais na Imagem Cardíaca

Convolutional Neural Network Applications In Cardiac Imaging

Luiz Henrique Cartaxo Fernandes,¹ José Lucas Formiga Dantas,¹ Marília Graziela Vieira de Macena Lima,¹ Glaudir Donato,¹ Marcelo Dantas Tavares de Melo²

Centro de Ciências Médicas, Universidade Federal da Paraíba,¹ João Pessoa, PB – Brasil

Departamento de Medicina Interna, Universidade Federal da Paraíba,² João Pessoa, PB – Brasil

Figura Central: As Aplicações das Redes Neurais Convolucionais na Imagem Cardíaca



Arq Bras Cardiol: Imagem cardiovasc. 2025;38(3):e20250058

Aplicações de Redes Neurais Convolucionais em diferentes tipos de métodos de imagem diagnóstica em cardiologia. TC: Tomografia Computadorizada; RM: Ressonância Magnética; ECO: Ecocardiografia; HAP: Hipertensão Arterial Pulmonar; CMH: Cardiomiopatia Hipertrófica; FA: Fibrilação Atrial; CIA: Comunicação Interatrial; PCA: Persistência do Canal Arterial; DAC: Doença Arterial Coronariana.

Resumo

Redes neurais são modelos computacionais que imitam o funcionamento do cérebro humano, aprendendo a partir de grandes volumes de dados para realizar tarefas cada

Palavras-chave

Redes neurais de computação; inteligência artificial; técnicas de imagem cardíaca

Correspondência: Luiz Henrique Cartaxo Fernandes •

Universidade Federal da Paraíba – Centro de Ciências Médicas. Cidade Universitária, s/n – Conj. Pres. Castelo Branco III. CEP: 58051-900. João Pessoa, PB – Brasil

E-mail: luiz.cartaxo@academico.ufpb.br

Artigo recebido em 13/08/2025; revisado em 29/08/2025; aceito em 02/08/2025

Editor responsável pela revisão: Marcelo Tavares

DOI: <https://doi.org/10.36660/abcimg.20250058>

vez mais complexas. Isso é feito por meio de neurônios artificiais interconectados que propagam informações de camadas brutas para camadas refinadas, às vezes com pesos atribuídos, permitindo a classificação ou identificação de padrões não lineares. A Rede Neural Convolucional (CNN, do inglês *Convolutional Neural Network*) é uma arquitetura especializada de aprendizado profundo (*deep learning*) projetada para extrair e analisar padrões espaciais em imagens, possibilitando aplicações em decisões diagnósticas e monitoramento clínico longitudinal. Seu uso em tomografia computadorizada e ressonância magnética, por meio da segmentação de imagens cardíacas, permite definir estruturas cardíacas de forma rápida e eficiente, desempenhando um papel importante na reconstrução de imagens tridimensionais e no suporte a procedimentos pré-operatórios. Além disso, em comparação com outras formas de análise convencional, a CNN garante interpretações objetivas e qualidade superior de imagem, com base na remoção de artefatos do

segmento estudado. Ecocardiogramas têm mostrado bons resultados na identificação de patologias como hipertensão pulmonar, amiloidose, cardiomiopatia hipertrófica e doenças congênitas, e estudos sobre a automação desses exames apontam para uma possível ampliação do acesso em áreas remotas onde operadores manuais não estão disponíveis. Consequentemente, abordagens baseadas em CNN têm o potencial de otimizar os fluxos de trabalho em imagem cardiovascular, minimizar a variabilidade entre observadores e expandir as capacidades diagnósticas para regiões carentes e remotas com acesso limitado a cuidados especializados.

Introdução

O sistema nervoso humano é uma das formas mais eficientes de captar e interpretar dados, refletindo os estímulos e experiências aos quais o corpo é submetido ao longo da vida.¹ Segundo o fenômeno da neuroplasticidade, todas essas interações provocam modificações no cérebro, permitindo sua adaptação para a tomada de decisões e possibilitando que conhecimentos pré-existentes sejam assimilados e sirvam de base para a formação de novos circuitos de informação.²

As redes neurais surgiram como modelos artificiais que buscam reproduzir esse processamento de forma rápida e eficaz, com o objetivo de solucionar os problemas propostos, tornando-se ferramentas importantes no dinâmico campo da Inteligência Artificial (IA).³ Para enfrentar esse desafio, as redes são treinadas para reconhecer padrões a partir de milhares ou até milhões de exemplos, permitindo que o sistema desenvolva sua própria capacidade de aprendizado.⁴ Isso ocorre por meio do que se chama de “input”, ou seja, qualquer novo conceito inserido na ordenação. O conjunto de entradas gera uma resposta, o “output”, que pode ser influenciado de maneira ponderada, sempre guiado por um padrão de referência que serve como base.⁵

Isso pode ser exemplificado de forma simples: na avaliação de um paciente com suspeita de Fibrilação Atrial (FA), quando um eletrocardiograma é solicitado para investigação, cada voltagem no traçado pode assumir o papel de um neurônio de entrada, que continua influenciando a cascata e serve como nova entrada para o próximo neurônio, solidificando a resposta final.⁶ Assim, se o diagnóstico for FA sem que haja traçado correspondente, os pesos que levaram a esse resultado são reduzidos. Por outro lado, se houver correspondência, eles são reforçados e reutilizados em análises subsequentes.⁷ Além disso, podem ser adicionadas informações extras, como idade, sexo e comorbidades do paciente.

A aplicação da IA na área médica tem sido amplamente explorada e, nos últimos anos, tornou-se uma tecnologia disruptiva na interpretação de imagens.⁸ Nesse contexto, a Rede Neural Convolutiva (CNN, do inglês *Convolutional Neural Network*) surgiu como uma versão desse processamento voltada para o reconhecimento e a classificação de imagens, reduzindo o esforço computacional e aumentando sua robustez.⁸ A disposição hierárquica de múltiplas camadas convolucionais permite que as CNNs transformem progressivamente características de baixo nível – como gradientes de intensidade de pixels – em representações cada vez mais abstratas e clinicamente relevantes.⁹ Durante

o período de treinamento, a CNN ajusta e individualiza seus filtros de acordo com a tarefa a ser executada. De certa forma, a classificação de imagens começa pela detecção das bordas de pixels mais grosseiros na camada inicial, utilizando essas informações para identificar formas simples na segunda camada e assim por diante, permitindo a distinção de características mais complexas. Por fim, a última camada é responsável pela leitura avançada da imagem, com base nos filtros construídos.¹⁰

A vantagem das CNNs em relação a outras redes neurais é que elas estabelecem os recursos essenciais para uma previsão bem-sucedida, reduzindo a dimensionalidade dos dados na camada anterior.¹¹

A segmentação precisa de imagens cardíacas é essencial para a tomada de decisões clínicas, e as técnicas de Deep Learning e o uso da CNN têm demonstrado resultados notáveis nessa área. No entanto, a quantificação e análise dessas imagens ainda representam um desafio contínuo, devido à complexidade das subestruturas cardíacas e à variabilidade anatômica existente. A individualização dessa análise é fundamental para consolidar evidências objetivas das mais variadas patologias investigadas, facilitando o diagnóstico, o monitoramento e o acompanhamento clínico do paciente.¹²

Nessa abordagem, o uso da segmentação de imagens por meio de CNNs permite respostas rápidas e eficientes. Isso ocorre porque, em determinadas situações, a presença de certas características é mais relevante do que outras. Às vezes, identificar a localização de uma alteração na câmara cardíaca é o único objetivo essencial, não sendo necessário visualizar essas estruturas com alta definição de pixels.¹³

O cenário de aplicação abrange uma ampla variedade de exames de imagem, desde a ecocardiografia – utilizada para calcular os volumes sistólico final e diastólico final – até a avaliação dos espaços ventriculares e atriais em múltiplos cortes, além da detecção de placas de calcificação coronariana por meio da angiotomografia coronária guiada por tomografia computadorizada (CCTA). A versatilidade das CNNs na imagem cardíaca é ilustrada na Figura Central. Na maioria dos casos, esses aspectos são apoiados por figuras e diagramas provenientes de atlas ou outros documentos incluídos no banco de dados do modelo. Outro ponto interessante é que já existem estudos que exploram o uso desses sistemas para avaliar e garantir a qualidade de ultrassonografias e outros exames diagnósticos.⁵

Aplicações de CNN na Tomografia Computadorizada (TC)

O uso de CNNs tem se destacado na automatização da segmentação de estruturas cardíacas e vasculares em imagens de Tomografia Computadorizada (TC), processo pelo qual estruturas cardíacas ou lesões patológicas são delimitadas.^{5,12,13} A segmentação de imagens cardíacas por TC possui relevância clínica na identificação de doenças valvulares, avaliação de doença arterial coronariana, diagnóstico de cardiopatias congênitas, planejamento pré-operatório e em indicações extracardíacas.¹² A aplicação de CNNs trouxe rapidez e eficiência ao processo de segmentação cardíaca, que anteriormente era realizado de forma manual e subjetiva

Artigo de Revisão

por radiologistas. Em um estudo sobre a segmentação de câmaras cardíacas e grandes vasos, Sharkey et al.¹⁴ apresentaram resultados indicando que a variabilidade da análise entre observadores é semelhante à variabilidade entre o observador e a CNN.¹⁴ Esses achados sustentam a premissa de que a segmentação baseada em CNN pode fornecer resultados reprodutíveis, objetivos e com precisão diagnóstica comparável à avaliação manual realizada por especialistas.

Com relação à identificação de estruturas anatômicas, Chen et al.¹⁵ demonstraram que a CNN se mostrou uma ferramenta precisa e eficiente para avaliar o volume e a reconstrução tridimensional do átrio esquerdo. O cálculo de volume por meio da CNN revelou-se capaz de prever o risco de recorrência de FA em pacientes após ablação por cateter. Astudillo et al.¹⁶ utilizaram uma técnica de CNN para identificar as cúspides coronarianas e os óstios coronarianos direito e esquerdo em tomografia computadorizada com múltiplos detectores. Essas estruturas são pontos de referência importantes para definir o perímetro e a área do anel aórtico e, consequentemente, as próteses valvares a serem implantadas por via transcater. O método mostrou-se reprodutível e confiável, podendo ser aplicado no planejamento pré-operatório de rotina, com o objetivo de reduzir o tempo gasto e aumentar a precisão na definição dos pontos de referência.

As CNNs também se mostraram excelentes ferramentas para a identificação de imagens patológicas na angiografia coronariana. A angiotomografia coronária por tomografia computadorizada é um método importante para avaliar a gravidade da estenose arterial, além de apresentar alta precisão na quantificação da aterosclerose quando comparada ao ultrassom intravascular. Em um estudo multicêntrico, uma rede neural foi treinada para segmentar placas coronarianas.¹⁷ O estudo demonstrou excelente concordância entre a ferramenta de *Deep Learning* e as medições realizadas por leitores experientes quanto ao volume da placa ateromatosa e ao grau de estenose arterial. Também houve concordância com as medições por ultrassom vascular, além de valor prognóstico em relação ao risco de infarto agudo do miocárdio futuro.

A quantificação do tecido adiposo epicárdico também pode ser otimizada com o uso de CNNs. O tecido adiposo epicárdico é um depósito metabolicamente ativo de gordura visceral e pode estar relacionado à obesidade visceral e à síndrome metabólica.¹⁸ A angiografia coronária é o padrão-ouro para identificar esse tecido, mas sua quantificação manual é trabalhosa e desafiadora. Nesse cenário, West et al.¹⁹ desenvolveram uma CNN para quantificar automaticamente o tecido adiposo epicárdico e identificar sua associação clínica com doenças cardíacas e não cardíacas. O método mostrou-se preciso, rápido e reprodutível para a quantificação da adiposidade epicárdica por meio da angiografia coronária. A ferramenta também demonstrou bom valor prognóstico para mortalidade geral e para eventos cardiovasculares.

Aplicações de CNN na Ressonância Magnética

Nos últimos anos, a Ressonância Magnética (RM) tornou-se uma excelente ferramenta para a investigação de doenças cardiovasculares, com alta capacidade para fornecer diagnósticos complexos.^{20,21} Trata-se de um método

não invasivo, versátil e livre de radiação ionizante, capaz de identificar estrutura, função, fluxo e caracterização do tecido cardíaco. O realce tardio com gadolínio e os mapeamentos T1/T2 adicionaram informações importantes sobre a viabilidade cardíaca e patologias como infarto tecidual e fibrose miocárdica difusa.

O desenvolvimento da RM de fluxo também trouxe avanços significativos ao fornecer informações sobre o fluxo sanguíneo em diversos planos, permitindo a identificação de *shunts* intracardíacos.²⁰ No entanto, o longo tempo de escaneamento e a produção lenta de imagens são desvantagens da RM. As imagens de RM devem considerar os movimentos cardíacos e respiratórios para evitar artefatos, que precisam ser suprimidos por algoritmos de reconstrução. Nesse cenário, os métodos de reconstrução baseados em Deep Learning têm demonstrado desempenho superior em comparação com algoritmos convencionais, oferecendo imagens de maior fidelidade, melhor supressão de artefatos e tempos de processamento substancialmente reduzidos.

Hauptmann et al.²² treinaram uma CNN residual tridimensional em arquitetura U-Net para remover artefatos espaço-temporais em dados de ressonância magnética (RM) em tempo real com subamostragem (*subsampling*), a partir de imagens de pacientes com cardiopatias congênitas. A remoção de artefatos pela CNN foi comparada à técnica convencional de compressão sensorial, uma ferramenta que exige reconstrução computacional intensa e demorada. O método baseado em CNN alcançou supressão de artefatos mais de cinco vezes mais rápida que a abordagem de compressão sensorial, além de oferecer qualidade de imagem superior e medições volumétricas ventriculares mais precisas. El-Rewaidy et al.²³ também apresentaram resultados importantes na reconstrução de imagens de RM com realce tardio por gadolínio utilizando uma rede neural convolucional.²³ Em comparação com a técnica de compressão sensorial, a reconstrução de imagens por meio da CNN foi 300 vezes mais rápida.

As CNNs influenciaram múltiplas etapas do fluxo de trabalho da RM, desde o planejamento da aquisição de imagens e reconstrução em tempo real até tarefas de pós-processamento, como análise quantitativa e modelagem prognóstica. Assim como a TC, a RM também desempenha um papel importante na segmentação e consequente identificação de estruturas cardíacas.²⁴ Nesse processo com RM, o uso de CNNs também tem sido associado à maior eficiência.²⁵ Sander et al.²⁶ utilizaram uma CNN para realizar a segmentação de estruturas cardíacas e outra CNN auxiliar para identificar automaticamente áreas com falhas de segmentação. O estudo mostrou que a segmentação de imagens cardíacas com CNNs, associada à correção manual das falhas detectadas, resultou em melhor desempenho.

No que diz respeito à identificação de doenças, muitos estudos têm utilizado índices convencionais de imagem como dados de entrada para redes neurais na tentativa de diagnosticar doenças cardíacas. Por exemplo, a presença de cicatrizes cardíacas identificadas por RM está associada a desfechos cardiovasculares desfavoráveis. Bekheet et al.²⁷ desenvolveram uma CNN chamada FibrosisNet para diagnosticar fibrose cardíaca por RM, demonstrando alta precisão e acurácia diagnóstica. Sharifrazi et al.²⁸ obtiveram

resultados importantes ao combinar uma rede neural convolucional profunda com a técnica de agrupamento K-means, formando a CNN-KCL, para diagnosticar e classificar miocardite com base em dados de imagem por RM. A técnica baseada em CNN superou outros algoritmos tradicionais de *machine learning* na classificação da miocardite em termos de precisão e acurácia.

Aplicações de CNN na ecocardiografia

A ecocardiografia é o método de imagem mais acessível e amplamente utilizado para avaliar a estrutura e a função cardíaca. Suas vantagens incluem aquisição rápida de imagens e ausência de radiação ionizante, o que a torna um método eficiente e democrático. A ecocardiografia pode ser utilizada tanto para rastrear pacientes assintomáticos quanto para diagnosticar e acompanhar condições cardíacas.^{29,30} Por ser um exame dependente do operador, exige certo grau de experiência por parte do profissional, podendo haver variações na interpretação.^{29,31}

Quando se trata da aplicação de interpretação automatizada de imagens na ecocardiografia, existem alguns desafios intrínsecos a esse método. O ecocardiograma consiste na geração de imagens estáticas, bem como vídeos e registros Doppler coletados de diferentes pontos de vista para obtenção dos parâmetros desejados. Além disso, os valores obtidos nas medições podem variar significativamente devido à variabilidade intrínseca dos batimentos cardíacos. Há também a variação existente ao extrapolar medições de imagens bidimensionais para medições de um objeto tridimensional.^{32,33}

Apesar desses impasses e considerando a complexidade do método diagnóstico em questão, uma abordagem de aprendizado automatizado traria muitos benefícios e auxiliaria na interpretação humana, ao permitir a identificação e classificação automática das imagens. De fato, o uso de *Deep Learning* (DL), e mais especificamente de CNNs, para treinar a IA na interpretação de ecocardiogramas poderia reduzir custos e, conseqüentemente, democratizar esse exame. Essa integração tecnológica permitiria a aquisição de ecocardiogramas por operadores com treinamento especializado limitado, facilitando assim o acesso à imagem cardíaca em regiões geograficamente remotas ou com poucos recursos.³²

Diversos estudos demonstraram a eficácia do uso de CNNs na ecocardiografia. Entre as aplicações observadas, a maioria está relacionada à quantificação da estrutura e função cardíaca, bem como à segmentação cardíaca.^{10,29,34-38} As CNNs também têm sido utilizadas na detecção de hipertrofia ventricular esquerda,³⁹⁻⁴¹ na estenose aórtica,^{42,43} na identificação de fases cardíacas,⁴⁴ na detecção precoce de infarto agudo do miocárdio,⁴⁵ e na classificação de visualizações cardíacas.^{46,47} O modelo utilizado por Ghorbani et al.,²⁹ além de identificar com precisão elementos da estrutura e função cardíaca, treinou uma CNN para prever fenótipos sistêmicos que modificam o risco cardiovascular, como idade, sexo, altura e peso, a partir de imagens de ecocardiograma.²⁹

Zhang et al.³² foram além e treinaram uma CNN para a interpretação totalmente automatizada de ecocardiogramas,

incluindo identificação de visualizações, segmentação de imagens, quantificação da estrutura e função cardíaca e detecção de doenças. Esse estudo demonstrou sucesso na análise automatizada do tipo de visualização e na segmentação de imagens. Em relação à estrutura e função do coração, houve alguma discrepância entre as medições manuais e automatizadas, especialmente na estrutura, com tendência à superestimação dos valores. Por fim, o modelo foi bem-sucedido na identificação de Hipertensão Arterial Pulmonar (HAP), amiloidose e cardiomiopatia hipertrófica, com base na análise das massas, estrutura e função das câmaras cardíacas.³²

Estudos recentes também avaliaram o potencial para o diagnóstico automático da HAP.⁴⁸ Segundo os achados de DuBrock et al.,⁴⁹ o algoritmo utilizado foi capaz de antecipar o diagnóstico de HAP em um período de seis a dezoito meses – um avanço extremamente relevante em uma condição na qual o diagnóstico precoce é crucial para o manejo eficaz da doença.^{48,49}

Outra patologia que pode ser identificada por meio da ecocardiografia com o uso de CNNs é a FA oculta. Yuan et al.⁵⁰ desenvolveram um modelo capaz de distinguir entre ritmo sinusal e FA, além de prever a presença concomitante de FA paroxística em indivíduos com ritmo sinusal. O modelo superou métodos tradicionais baseados em fatores de risco clínicos, medições do ecocardiograma transtorácico, tamanho do átrio esquerdo ou escore CHA₂DS₂-VASc.⁵⁰ Pesquisas utilizando técnicas de DL também têm apresentado resultados promissores na ecocardiografia fetal e neonatal, incluindo o diagnóstico pré-natal de defeito do septo atrial⁵¹ e a identificação de persistência do canal arterial em neonatos.⁵²

Aplicação de CNN em outros métodos

A TC por emissão de fóton único (SPECT) de perfusão miocárdica é um exame capaz de identificar a presença de isquemia miocárdica e, portanto, de doença arterial coronariana. Betancur et al.⁵³ analisaram a aplicação de DL nesse método diagnóstico, com o objetivo de verificar a capacidade de prever automaticamente a doença coronariana por meio de CNNs treinadas com imagens de perfusão miocárdica, em comparação com o método convencional atualmente utilizado. O resultado foi uma maior eficácia e melhor sensibilidade de detecção com o método baseado em DL.⁵³ Outros estudos também avaliaram a capacidade de classificar automaticamente imagens de perfusão miocárdica. Papadrianos et al.⁵⁴ treinaram CNNs para identificar três possíveis resultados – infarto, isquemia e perfusão normal – e todos os modelos avaliados apresentaram resultados positivos e confiáveis.⁵⁴ Su et al.⁵⁵ demonstraram a viabilidade e precisão do diagnóstico de doença arterial coronariana baseado em CNN, com um sistema já utilizado na prática, e capaz de reduzir consideravelmente o tempo necessário para interpretar as imagens.

A fluoroscopia por raios X permite a visualização em tempo real da estrutura cardíaca, o que a torna um método indispensável para a realização de procedimentos guiados por imagem, como a terapia de ressincronização cardíaca,

Artigo de Revisão

angiografia e reparo endovascular da aorta. O DL também tem sido testado com sucesso para auxiliar esses procedimentos, seja na redução de ruído em vídeos ou na fusão de dados pré-operatórios com imagens intraoperatórias de raios X, com o objetivo de guiar a intervenção e reduzir a exposição ao contraste.⁵⁶⁻⁵⁹ Estudos também demonstraram melhor sensibilidade e especificidade na caracterização de lesões coronarianas utilizando tomografia de coerência óptica quando o DL é aplicado.⁶⁰⁻⁶²

Conclusão

A aplicação de CNNs na análise de imagens cardíacas surgiu como uma ferramenta versátil, contribuindo para diagnósticos mais precisos e rápidos. Sua integração à imagem cardiovascular permite reduzir a variabilidade entre observadores, minimizar artefatos de imagem, aprimorar a automação de medições e superar barreiras geográficas ao possibilitar a avaliação remota de imagens adquiridas – democratizando, assim, o acesso ao cuidado. As direções futuras devem priorizar estudos de validação em larga escala para confirmar a generalização e a robustez clínica das abordagens baseadas em CNNs em diferentes populações de pacientes e protocolos de imagem. Além disso, a integração desses algoritmos aos fluxos de trabalho clínicos rotineiros exigirá a superação de desafios regulatórios e de interoperabilidade, a fim de garantir uma adoção segura e eficaz na prática cardiovascular real.

Contribuição dos autores

Concepção e desenho da pesquisa: Melo MDT. Obtenção de dados: Fernandes LHC, Dantas JLF, Lima MGVM. Análise

e interpretação dos dados: Fernandes LHC, Dantas JLF, Lima MGVM, Donato G. Redação do manuscrito: Fernandes LHC, Dantas JLF, Lima MGVM. Revisão crítica do manuscrito quanto ao conteúdo intelectual importante: Donato G, Melo MDT.

Potencial conflito de interesse

Declaro não haver conflito de interesses pertinentes.

Fontes de financiamento

O presente estudo não teve fontes de financiamento externas.

Vinculação acadêmica

Não há vinculação deste estudo a programas de pós-graduação.

Aprovação ética e consentimento informado

Este artigo não contém estudos com humanos ou animais realizados por nenhum dos autores.

Uso de Inteligência Artificial

Os autores não utilizaram ferramentas de inteligência artificial no desenvolvimento deste trabalho.

Disponibilidade de Dados

Os conteúdos subjacentes ao texto da pesquisa estão contidos no manuscrito.

Referências

1. Rotta NT, Ohlweiler L, Riesgo RS. Transtornos da Aprendizagem. Porto Alegre: Artmed; 2015.
2. Costa RLS. Neuroscience and Learning. Rev Bras Educ. 2023;28:e280010. doi: 10.1590/S1413-24782023280010.
3. Kriegeskorte N, Golan T. Neural Network Models and Deep Learning. Curr Biol. 2019;29(7):R231-6. doi: 10.1016/j.cub.2019.02.034.
4. Krittanawong C, Zhang H, Wang Z, Aydar M, Kitai T. Artificial Intelligence in Precision Cardiovascular Medicine. J Am Coll Cardiol. 2017;69(21):2657-64. doi: 10.1016/j.jacc.2017.03.571.
5. Litjens G, Ciompi F, Wolterink JM, de Vos BD, Leiner T, Teuwen J, et al. State-of-the-Art Deep Learning in Cardiovascular Image Analysis. JACC Cardiovasc Imaging. 2019;12(8 Pt 1):1549-65. doi: 10.1016/j.jcmg.2019.06.009.
6. Krittanawong C, Johnson KW, Rosenson RS, Wang Z, Aydar M, Baber U, et al. Deep Learning for Cardiovascular Medicine: A Practical Primer. Eur Heart J. 2019;40(25):2058-73. doi: 10.1093/eurheartj/ehz056.
7. El-Taraboulsi J, Cabrera CP, Roney C, Aung N. Deep Neural Network Architectures for Cardiac Image Segmentation. Artif Intell Life Sci. 2023;4:100083. doi: 10.1016/j.ailsci.2023.100083.
8. Johnson KW, Soto JT, Glicksberg BS, Shameer K, Miotto R, Ali M, et al. Artificial Intelligence in Cardiology. J Am Coll Cardiol. 2018;71(23):2668-79. doi: 10.1016/j.jacc.2018.03.521.
9. Bizopoulos P, Koutsouris D. Deep Learning in Cardiology. IEEE Rev Biomed Eng. 2019;12:168-93. doi: 10.1109/RBME.2018.2885714.
10. Lau ES, Di Achille P, Kopparapu K, Andrews CT, Singh P, Reeder C, et al. Deep Learning-Enabled Assessment of Left Heart Structure and Function Predicts Cardiovascular Outcomes. J Am Coll Cardiol. 2023;82(20):1936-48. doi: 10.1016/j.jacc.2023.09.800.
11. Wang P, Qiao J, Liu N. An Improved Convolutional Neural Network-Based Scene Image Recognition Method. Comput Intell Neurosci. 2022;2022:3464984. doi: 10.1155/2022/3464984.
12. Alnasser TN, Abdulaal L, Maiter A, Sharkey M, Dwivedi K, Salehi M, et al. Advancements in Cardiac Structures Segmentation: A Comprehensive Systematic Review of Deep Learning in CT Imaging. Front Cardiovasc Med. 2024;11:1323461. doi: 10.3389/fcvm.2024.1323461.
13. Lüscher TF, Wenzl FA, D'Ascenzo F, Friedman PA, Antoniadis C. Artificial Intelligence in Cardiovascular Medicine: Clinical Applications. Eur Heart J. 2024;45(40):4291-304. doi: 10.1093/eurheartj/ehae465.
14. Sharkey MJ, Taylor JC, Alabed S, Dwivedi K, Karunasaagar K, Johns CS, et al. Fully Automatic Cardiac Four Chamber and Great Vessel Segmentation on CT Pulmonary Angiography Using Deep Learning. Front Cardiovasc Med. 2022;9:983859. doi: 10.3389/fcvm.2022.983859.
15. Chen HH, Liu CM, Chang SL, Chang PY, Chen WS, Pan YM, et al. Automated Extraction of Left Atrial Volumes from Two-Dimensional Computer

- Tomography Images Using a Deep Learning Technique. *Int J Cardiol.* 2020;316:272-8. doi: 10.1016/j.ijcard.2020.03.075.
16. Astudillo P, Mortier P, Bosmans J, De Backer O, Jaegere P, Iannaccone F, et al. Automatic Detection of the Aortic Annular Plane and Coronary Ostia from Multidetector Computed Tomography. *J Interv Cardiol.* 2020;2020:9843275. doi: 10.1155/2020/9843275.
17. Lin A, Park C. HHS Public Access international multicentre study. 2022;4(4):10-1.
18. Oikonomou EK, Antoniadou C. The Role of Adipose Tissue in Cardiovascular Health and Disease. *Nat Rev Cardiol.* 2019;16(2):83-99. doi: 10.1038/s41569-018-0097-6.
19. West HW, Siddique M, Williams MC, Volpe L, Desai R, Lyasheva M, et al. Deep-Learning for Epicardial Adipose Tissue Assessment with Computed Tomography: Implications for Cardiovascular Risk Prediction. *JACC Cardiovasc Imaging.* 2023;16(6):800-16. doi: 10.1016/j.jcmg.2022.11.018.
20. Oscanoa JA, Middione MJ, Alkan C, Yurt M, Loecher M, Vasanawala SS, et al. Deep Learning-Based Reconstruction for Cardiac MRI: A Review. *Bioengineering.* 2023;10(3):334. doi: 10.3390/bioengineering10030334.
21. Argentiero A, Muscogiuri G, Rabbat MG, Martini C, Soldato N, Basile P, et al. The Applications of Artificial Intelligence in Cardiovascular Magnetic Resonance-A Comprehensive Review. *J Clin Med.* 2022;11(10):2866. doi: 10.3390/jcm11102866.
22. Hauptmann A, Arridge S, Lucka F, Muthurangu V, Steeden JA. Real-Time Cardiovascular MR with Spatio-Temporal Artifact Suppression Using Deep Learning-Proof of Concept in Congenital Heart Disease. *Magn Reson Med.* 2019;81(2):1143-56. doi: 10.1002/mrm.27480.
23. El-Rewaidy H, Neisius U, Mancio J, Kucukseymen S, Rodriguez J, Paskavitz A, et al. Deep Complex Convolutional Network for Fast Reconstruction of 3D Late Gadolinium Enhancement Cardiac MRI. *NMR Biomed.* 2020;33(7):e4312. doi: 10.1002/nbm.4312.
24. Peng P, Lekadir K, Gooya A, Shao L, Petersen SE, Frangi AF. A Review of Heart Chamber Segmentation for Structural and Functional Analysis Using Cardiac Magnetic Resonance Imaging. *MAGMA.* 2016;29(2):155-95. doi: 10.1007/s10334-015-0521-4.
25. Xiong Z, Fedorov VV, Fu X, Cheng E, Macleod R, Zhao J. Fully Automatic Left Atrium Segmentation from Late Gadolinium Enhanced Magnetic Resonance Imaging Using a Dual Fully Convolutional Neural Network. *IEEE Trans Med Imaging.* 2019;38(2):515-24. doi: 10.1109/TMI.2018.2866845.
26. Sander J, de Vos BD, Išgum I. Automatic Segmentation with Detection of Local Segmentation Failures in Cardiac MRI. *Sci Rep.* 2020;10(1):21769. doi: 10.1038/s41598-020-77733-4.
27. Bekheet M, Sallah M, Alghamdi NS, Rusu-Both R, Elgarayhi A, Elmogy M. Cardiac Fibrosis Automated Diagnosis Based on FibrosisNet Network Using CMR Ischemic Cardiomyopathy. *Diagnostics.* 2024;14(3):255. doi: 10.3390/diagnostics14030255.
28. Sharifrazi D, Alizadehsani R, Joloudari JH, Band SS, Hussain S, Sani ZA, et al. CNN-KCL: Automatic Myocarditis Diagnosis Using Convolutional Neural Network Combined with K-Means Clustering. *Math Biosci Eng.* 2022;19(3):2381-402. doi: 10.3934/mbe.2022110.
29. Ghorbani A, Ouyang D, Abid A, He B, Chen JH, Harrington RA, et al. Deep Learning Interpretation of Echocardiograms. *NPJ Digit Med.* 2020;3:10. doi: 10.1038/s41746-019-0216-8.
30. American College of Cardiology Foundation Appropriate Use Criteria Task Force; American Society of Echocardiography; American Heart Association; American Society of Nuclear Cardiology; Heart Failure Society of America; Heart Rhythm Society; et al. ACCF/AHA/ASNC/HFSA/HRS/SCAI/SCCM/SCCT/SCMR 2011 Appropriate Use Criteria for Echocardiography. A Report of the American College of Cardiology Foundation Appropriate Use Criteria Task Force, American Society of Echocardiography, American Heart Association, American Society of Nuclear Cardiology, Heart Failure Society of America, Heart Rhythm Society, Society for Cardiovascular Angiography and Interventions, Society of Critical Care Medicine, Society of Cardiovascular Computed Tomography, Society for Cardiovascular Magnetic Resonance American College of Chest Physicians. *J Am Soc Echocardiogr.* 2011;24(3):229-67. doi: 10.1016/j.echo.2010.12.008.
31. De Geer L, Oscarsson A, Engvall J. Variability in Echocardiographic Measurements of Left Ventricular Function in Septic Shock Patients. *Cardiovasc Ultrasound.* 2015;13:19. doi: 10.1186/s12947-015-0015-6.
32. Zhang J, Gajjala S, Agrawal P, Tison GH, Hallock LA, Beussink-Nelson L, et al. Fully Automated Echocardiogram Interpretation in Clinical Practice. *Circulation.* 2018;138(16):1623-35. doi: 10.1161/CIRCULATIONAHA.118.034338.
33. Madani A, Arnaout R, Mofrad M, Arnaout R. Fast and Accurate View Classification of Echocardiograms Using Deep Learning. *NPJ Digit Med.* 2018;1:6. doi: 10.1038/s41746-017-0013-1.
34. Shi S, Alimu P, Mahemut P. The Study of Echocardiography of Left Ventricle Segmentation Combining Transformer and Convolutional Neural Networks. *Int Heart J.* 2024;65(5):889-97. doi: 10.1536/ihj.23-638.
35. Jiang J, Deng H, Xue Y, Liao H, Wu S. Detection of Left Atrial Enlargement Using a Convolutional Neural Network-Enabled Electrocardiogram. *Front Cardiovasc Med.* 2020;7:609976. doi: 10.3389/fcvm.2020.609976.
36. Painchaud N, Duchateau N, Bernard O, Jodoin PM. Echocardiography Segmentation with Enforced Temporal Consistency. *IEEE Trans Med Imaging.* 2022;41(10):2867-78. doi: 10.1109/TMI.2022.3173669.
37. Lei Y, Fu Y, Roper J, Higgins K, Bradley JD, Curran WJ, et al. Echocardiographic Image Multi-Structure Segmentation Using Cardiac-SegNet. *Med Phys.* 2021;48(5):2426-37. doi: 10.1002/mp.14818.
38. Wehbe RM, Katsaggelos AK, Hammond KJ, Hong H, Ahmad FS, Ouyang D, et al. Deep Learning for Cardiovascular Imaging: A Review. *JAMA Cardiol.* 2023;8(11):1089-98. doi: 10.1001/jamacardio.2023.3142.
39. Jian Z, Wang X, Zhang J, Wang X, Deng Y. Diagnosis of Left Ventricular Hypertrophy Using Convolutional Neural Network. *BMC Med Inform Decis Mak.* 2020;20(1):243. doi: 10.1186/s12911-020-01255-2.
40. Nazar W, Nazar K, Daniłowicz-Szymanowicz L. Machine Learning and Deep Learning Methods for Fast and Accurate Assessment of Transthoracic Echocardiogram Image Quality. *Life.* 2024;14(6):761. doi: 10.3390/life14060761.
41. Duffy G, Cheng PP, Yuan N, He B, Kwan AC, Shun-Shin MJ, et al. High-Throughput Precision Phenotyping of Left Ventricular Hypertrophy with Cardiovascular Deep Learning. *JAMA Cardiol.* 2022;7(4):386-95. doi: 10.1001/jamacardio.2021.6059.
42. Holste G, Oikonomou EK, Mortazavi BJ, Coppi A, Faridi KF, Miller EJ, et al. Severe Aortic Stenosis Detection by Deep Learning Applied to Echocardiography. *Eur Heart J.* 2023;44(43):4592-604. doi: 10.1093/eurheartj/ehad456.
43. Wessler BS, Huang Z, Long GM Jr, Pacifici S, Prashar N, Karmiy S, et al. Automated Detection of Aortic Stenosis Using Machine Learning. *J Am Soc Echocardiogr.* 2023;36(4):411-20. doi: 10.1016/j.echo.2023.01.006.
44. Farhad M, Masud MM, Beg A, Ahmad A, Ahmed LA, Memon S. Cardiac Phase Detection in Echocardiography Using Convolutional Neural Networks. *Sci Rep.* 2023;13(1):8908. doi: 10.1038/s41598-023-36047-x.
45. Muraki R, Teramoto A, Sugimoto K, Sugimoto K, Yamada A, Watanabe E. Automated Detection Scheme for Acute Myocardial Infarction Using Convolutional Neural Network and Long Short-Term Memory. *PLoS One.* 2022;17(2):e0264002. doi: 10.1371/journal.pone.0264002.
46. Naser JA, Lee E, Pislaru SV, Tsaban G, Malins JG, Jackson JJ, et al. Artificial Intelligence-Based Classification of Echocardiographic Views. *Eur Heart J Digit Health.* 2024;5(3):260-9. doi: 10.1093/ehjdh/ztae015.
47. Østvik A, Smistad E, Aase SA, Haugen BO, Lovstakken L. Real-Time Standard View Classification in Transthoracic Echocardiography Using Convolutional

Artigo de Revisão

- Neural Networks. *Ultrasound Med Biol*. 2019;45(2):374-84. doi: 10.1016/j.ultrasmedbio.2018.07.024.
48. Sun D, Hu Y, Li Y, Yu X, Chen X, Shen P, et al. Chamber Attention Network (CAN): Towards Interpretable Diagnosis of Pulmonary Artery Hypertension Using Echocardiography. *J Adv Res*. 2024;63:103-15. doi: 10.1016/j.jare.2023.10.013.
49. DuBrock HM, Wagner TE, Carlson K, Carpenter CL, Awasthi S, Attia ZI, et al. An Electrocardiogram-Based AI Algorithm for Early Detection of Pulmonary Hypertension. *Eur Respir J*. 2024;64(1):2400192. doi: 10.1183/13993003.00192-2024.
50. Yuan N, Stein NR, Duffy C, Sandhu RK, Chugh SS, Chen PS, et al. Deep Learning Evaluation of Echocardiograms to Identify Occult Atrial Fibrillation. *NPJ Digit Med*. 2024;7(1):96. doi: 10.1038/s41746-024-01090-z.
51. Zhou X, Yang T, Ruan Y, Zhang Y, Liu X, Zhao Y, et al. Application of Neural Networks in Prenatal Diagnosis of Atrioventricular Septal Defect. *Transl Pediatr*. 2024;13(1):26-37. doi: 10.21037/tp-23-394.
52. Erno J, Gomes T, Baltimore C, Lineberger JP, Smith DH, Baker GH. Automated Identification of Patent Ductus Arteriosus Using a Computer Vision Model. *J Ultrasound Med*. 2023;42(12):2707-13. doi: 10.1002/jum.16305.
53. Betancur J, Commandeur F, Motlagh M, Sharir T, Einstein AJ, Bokhari S, et al. Deep Learning for Prediction of Obstructive Disease from Fast Myocardial Perfusion SPECT: A Multicenter Study. *JACC Cardiovasc Imaging*. 2018;11(11):1654-63. doi: 10.1016/j.jcmg.2018.01.020.
54. Papandrianos NI, Feleki A, Papageorgiou EI, Martini C. Deep Learning-Based Automated Diagnosis for Coronary Artery Disease Using SPECT-MPI Images. *J Clin Med*. 2022;11(13):3918. doi: 10.3390/jcm11133918.
55. Su TY, Chen JJ, Chen WS, Chang YH, Lu HH. Deep Learning for Myocardial Ischemia Auxiliary Diagnosis Using CZT SPECT Myocardial Perfusion Imaging. *J Chin Med Assoc*. 2023;86(1):122-30. doi: 10.1097/JCMA.0000000000000833.
56. Toth D, Miao S, Kurzendorfer T, Rinaldi CA, Liao R, Mansi T, et al. 3D/2D Model-to-Image Registration by Imitation Learning for Cardiac Procedures. *Int J Comput Assist Radiol Surg*. 2018;13(8):1141-9. doi: 10.1007/s11548-018-1774-y.
57. Breininger K, Albarqouni S, Kurzendorfer T, Pfister M, Kowarschik M, Maier A. Intraoperative Stent Segmentation in X-Ray Fluoroscopy for Endovascular Aortic Repair. *Int J Comput Assist Radiol Surg*. 2018;13(8):1221-31. doi: 10.1007/s11548-018-1779-6.
58. Sadda P, Qarni T. Real-Time Medical Video Denoising with Deep Learning: Application to Angiography. *Int J Appl Inf Syst*. 2018;12(13):22-8. doi: 10.5120/ijais2018451755.
59. Luo Y, Ma Y, O' Brien H, Jiang K, Kohli V, Maidelin S, et al. Edge-Enhancement Densenet for X-Ray Fluoroscopy Image Denoising in Cardiac Electrophysiology Procedures. *Med Phys*. 2022;49(2):1262-75. doi: 10.1002/mp.15426.
60. Abdolmanafi A, Duong L, Dahdah N, Adib IR, Cheriet F. Characterization of Coronary Artery Pathological Formations from OCT Imaging Using Deep Learning. *Biomed Opt Express*. 2018;9(10):4936-60. doi: 10.1364/BOE.9.004936.
61. Abdolmanafi A, Cheriet F, Duong L, Ibrahim R, Dahdah N. An Automatic Diagnostic System of Coronary Artery Lesions in Kawasaki Disease Using Intravascular Optical Coherence Tomography Imaging. *J Biophotonics*. 2020;13(1):e201900112. doi: 10.1002/jbio.201900112.
62. Gessert N, Lutz M, Heyder M, Latus S, Leistner DM, Abdelwahed YS, et al. Automatic Plaque Detection in IVOCT Pullbacks Using Convolutional Neural Networks. *IEEE Trans Med Imaging*. 2019;38(2):426-34. doi: 10.1109/TMI.2018.2865659.



Este é um artigo de acesso aberto distribuído sob os termos da licença de atribuição pelo Creative Commons