

## CAPÍTULO 12

# *DEEP LEARNING* EM DIAGNÓSTICOS DE ELETROCARDIOGRAMAS: REVISÃO INTEGRATIVA

LUDMILLA PINTO GUIOTTI CINTRA ABREU<sup>1</sup>  
ANDERSON CARLOS GOMES MARTINS<sup>2</sup>  
ASAFE GUIMARÃES DANTAS CONRADO<sup>2</sup>  
ANDRÉ GUISSONI FIUSA<sup>2</sup>  
DAVI SILVEIRA GAMA BRAGA<sup>2</sup>  
JESIEL DIAS ALVES<sup>2</sup>  
VITOR DIAS SOUSA<sup>2</sup>  
MATEUS SANTOS DE AVELAR<sup>2</sup>  
HULLY CHRISTIANY GONÇALVES LEITE<sup>2</sup>  
FLÁVIO MORAES DE MIRANDA<sup>3</sup>

1. Discente – Mestranda em Engenharia Biomédica pela Universidade de Brasília (UnB).
2. Discente – Instituto Federal de Goiás (IFG).
3. Docente – Probabilidade e Estatística do Instituto Federal de Goiás (IFG).

*Palavras-chave:*  
*Deep learning; Diagnóstico; Eletrocardiograma.*

## INTRODUÇÃO

O eletrocardiograma (ECG) é um método não invasivo que ajuda a identificar sintomas de doenças do coração que podem levar à morte. É um gráfico que registra as flutuações da atividade elétrica (SARSHAR & MIRZAEI, 2022). Os algoritmos de aprendizagem profunda de máquinas ou *Deep Learning* (DL) são domínios da inteligência artificial (IA) supervisionada que requerem grandes treinamentos até um modelo ideal. O trabalho de organizar dados é atualmente uma barreira ao desenvolvimento de sistemas de DL (PHILBRICK *et al.*, 2019).

O DL é um método de aprendizagem de representação onde uma arquitetura complexa de rede neural multicamadas aprende representações de dados automaticamente, transformando as informações de entrada em vários níveis de abstrações, sendo as mais usuais as redes neurais convolucionais profundas (DCNN). As DCNN devem ser treinadas e não requerem recursos projetados manualmente como entrada, pois possuem alta seletividade e invariância (CHAN *et al.*, 2020).

As informações de imagem são essenciais na tomada de decisão em muitas etapas do processo de atendimento ao paciente, desde detecção, caracterização, estadiamento, avaliação da resposta ao tratamento, monitoramento da recorrência da doença, até a orientação sobre as intervenções. A abordagem convencional de Aprendizado de Máquina, em inglês *Machine Learning* (ML), tem algumas limitações devido ao desenvolvedor humano não ser capaz de traduzir os padrões complexos da doença em um número finito de descritores de características, mesmo que tenha analisado um grande número de casos de pacientes. É importante ressaltar que o processo de aprendizagem automatizado, como as DCNN, facilmente analisa milhares de casos que os

especialistas humanos podem não ser capazes de ver e memorizar durante a vida. O requisitos básicos para desenvolver um algoritmo robusto de ML é um conjunto de amostras grande com verdades de referência verificadas, representativas das características da população de interesse, para o treinamento da máquina (CHAN *et al.*, 2020).

A síntese de imagens médicas de última geração geralmente usam as redes neurais convolucionais (CNN), sendo que a mais popular é a *Unet*. Atualmente, uma série de redes adversárias generativas (GAN) baseadas em CNN melhoram ainda mais os resultados destas sínteses, por emparelhar imagem a imagem. O modelo *CycleGAN*, com segmentadores sem definição específica para o conjunto de dados, e o *CicloGAN*, com conjunto de dados, são desenvolvimento de DL para imagens cardíacas baseados em CNN e GAN, que surgiram a partir de 2017 (YU *et al.*, 2021).

As CNN são ferramentas poderosas para análise de imagens, que podem ser treinadas com alta precisão para os três respectivos conjuntos de dados: objetos-alvo, fundo e qualidade de imagem variados com tempo de anotação maior que duas horas. As CNN são uma classe que representa o estado da arte em análises de imagens e estão atualmente entre os métodos mais populares em pesquisa de visão computacional. Constituem um sistema neural multicamadas em rede que usa convolução em pelo menos uma camada, e são projetadas para processar dados semelhantes a grades, sendo excelentes em tarefas como segmentação e classificação (SMITH *et al.*, 2022).

As CNN são amplamente utilizadas para análise e classificação de sinais de ECG e podem aprender automaticamente recursos complexos representativos diretamente dos próprios dados, eliminando assim a necessidade de recursos artesanais, extraindo recursos

hierárquicos do simples ao complexo e aplicando filtros de alta dimensão nos dados de entrada. Têm sido utilizadas com sucesso em problemas envolvendo imagens bidimensionais e em dados unidimensionais de séries temporais, como os ECG. Os modelos CNN usados para detecção de fibrilação atrial (FA) podem realizar extração e classificação de recursos, sem necessidade de introdução manual. Para melhor precisão das CNN as camadas de convolucionais são importantes e estudos propõe que: dois fluxos de CNN com 13 camadas poderiam capturar recursos de ECG em diferentes escalas; uma CNN profunda de 8 camadas para análise de FA, flutter atrial (AFL), uma arritmia relacionada à FA; CNN com uma única camada de convolução para detectar FA; CNN para rastrear automaticamente segmentos de FA de sinais de ECG móveis; CNN com duas camadas de convolução e duas camadas de *pooling* (subamostragem) para detectar FA; CNN denso de 18 camadas para detecção de FA; CNN combinada a uma rede neural Elman aprimorada produzindo melhor desempenho para detecção de FA; e CNN unidimensional de 13 camadas de convolução com 5 camadas de *pooling* apresentou uma boa precisão. Todas estas simulações são tentativas de melhor precisão e diagnóstico das imagens de ECG (MURAT *et al.*, 2021).

Um grupo de autores propuseram um reconhecimento da contração ventricular prematura (PVC) através do DL. A pesquisa consistiu em um *pipeline* de DL que utilizava a CNN para extrair características relevantes dos sinais de ECG e classificar os complexos PVC. O *pipeline* utilizava um conjunto de 10 características distintas, sendo três morfológicas das ondas do ECG e sete estatísticas. Essas características são capazes de destacar as diferenças entre as partes dos sinais de ECG.

Além disso, a estrutura da CNN é projetada para identificar características únicas que permitem alcançar um desempenho de classificação mais alto. Avaliando a eficácia desta abordagem, compararam resultados obtidos com outras estratégias de referência, incluindo abordagens baseadas em ML tradicional, e outras técnicas de DL. Os resultados mostraram que a abordagem proposta alcançou maior precisão em comparação às estratégias de referência e reduziu o tempo de computação. Os autores utilizaram uma rede neural artificial (ANN) como classificador, embora não forneçam detalhes específicos sobre a arquitetura da ANN utilizada (SARSHAR & MIRZAEI, 2022).

As redes neurais recorrentes (RNN) são um tipo de rede neural artificial desenvolvido para resolução de problemas temporais com entradas sequenciais, como sinais de ECG. Um ciclo único, ou segmentos curtos de ECG, é adequado para aplicações de monitoramento remoto de dispositivos em tempo real, experimentado para FA. As RNN bidirecionais (BiRNN) aumentam o número de mecanismos de atenção. Foram criados quatro modelos distintos para análise da precisão: RNN sem o mecanismo de atenção, e RNN de rede hierárquica (HAN)-ECG com um, dois e três mecanismos de atenção. Melhores desempenho e precisão foram obtidos com mais mecanismos de atenção, ou seja, continham atenção de onda, batida e janela impressadas entre camadas BiRNN (MURAT *et al.*, 2021).

Modelos de memória de longo prazo (LSTM) são amplamente utilizados em DL para resolver deficiências na arquitetura RNN que incluem problemas de explosão e desaparecimento de gradiente, que limitam a capacidade de aprender dependências de longos períodos de tempo. Os LSTMs bidirecionais aprendem e extraem efetivamente recursos de

dados de entrada do intervalo compostos de segmentos de 100 batimentos e atingiram 98,51 e 99,77% de precisão para detecção de FA com validação cruzada de dez vezes e validação às cegas, respectivamente. O LSTM foi capaz de aprender recursos na presença ou ausência de FA, passando para modelos superiores totalmente conectados para classificação, eliminando a necessidade de redução de informações por extração de recursos. Existem sinergias teóricas entre as CNN e os LSTM que podem ser combinados para produzir modelos DL poderosos onde os recursos obtidos das camadas CNN são alimentados nas camadas LSTM em sequência, classificando FA ou ritmos sinusais (SR), extraindo características de alto nível. Vários modelos utilizando essas junções foram propostos, observando uma versão melhorada da perda de entropia cruzada, e relataram sucesso na detecção de FA em quatro ritmos diferentes. Ao incorporarem métodos de otimização os modelos, apresentaram bons resultados quando testado com três bancos de dados de ECG separados (MURAT *et al.*, 2021).

O algoritmo *K-Nearest Neighbours* (KNN) é um modelo não paramétrico, onde os elementos de uma mesma classe possuem características semelhantes estando mais próximos no espaço de dados, baseado na distância entre os pontos em relação a cada dado no hiperespaço, e como pontos, pode-se calcular geometricamente a distância entre eles. Quando um novo dado é apresentado ao sistema, a distância entre eles influencia na classificação, e a previsão é dada como a classificação dos vizinhos mais próximos. É extremamente simples no formato computacional e muito rápido, podendo essa distância ser medida de variadas formas: Euclidiana, Manhattan, Minkowski, entre outras. O fator importante na qualidade do algoritmo é o número de vizinhos ( $K$ ) considerados, poucos erros de vizinhos nos dados de

treinamento (GOMES-JÚNIOR *et al.*, 2022; SANTIAGO & DIAS, 2022).

Outra ferramenta é a *Logistic Regression*, Regressão Logística (LR), que é uma generalização da regressão linear permitindo a classificação em três funções: predição, custo e otimização da predição. Inicialmente, a LR se comporta como uma regressão linear tentando calcular uma linha no hiperespaço que produza a melhor resposta para qualquer dado de entrada (SANTIAGO & DIAS, 2022). É um método simples e poderoso que infere a probabilidade de ocorrência de um evento, com base na modelagem do logaritmo de sua razão de chances como uma combinação linear de algum conjunto de variáveis explicativas assumidas como independentes (GOMES-JÚNIOR *et al.*, 2022).

O algoritmo *Support Vector Machine*, Máquinas de Vetores de Suporte (SVM), utiliza o cálculo vetorial para separar as distintas classes através de hiperplanos equidistantes e paralelos ao principal, estando o mais próximo possível dos dados para classificação binária. Teoricamente, este método é semelhante à regressão linear, mas o cálculo é diferente. Um vetor ortogonal ao hiperplano é obtido, chamados vetores de suporte, todas as entradas são um componente. A classificação é baseada na projeção do vetor correspondente à entrada no hiperplano, sendo o módulo maior que um determinado valor pertence a uma classe, se menor, a outra. O método utilizado para a otimização é o multiplicador de Lagrange (GOMES-JÚNIOR *et al.*, 2022; SANTIAGO & DIAS, 2022). O SVM pode endereçar conjuntos de dados não linearmente separáveis, utilizando o truque do *Kernel*, segundo o qual a entrada é intrinsecamente mapeada em um espaço de alta dimensão com o objetivo de tornar as classes de dados linearmente separáveis. O SVM apresenta alto desempenho, mas possui treinamento

complexo e exigente (GOMES-JÚNIOR *et al.*, 2022).

Outro algoritmo é o *Extra Trees* que não utiliza o gradiente descendente para sua otimização, e são ajustados pela *Decision Trees*, árvores de decisão (DT), que separa os dados de acordo com alguma característica onde o ganho de informação é máximo (considera maior aleatoriedade em sua parametrização), tornando-o mais robusto que os demais, em determinados casos. Ao separar os dados em grupos, a classificação é feita de forma muito mais rápida e com a possibilidade de utilizar menos dados do que outros algoritmos. É uma aplicação mais sofisticada do DT, onde se constroem vários modelos de DT mais simples e ao final a decisão é tomada por maioria de votos. Este tipo de modelo é mais robusto do que os vistos anteriormente, pois reduz drasticamente o *overfitting*, e é muito eficiente. Os algoritmos DT são modelos simples não paramétricos baseados em uma sequência de partições binárias do conjunto de dados, considerando um conjunto de variáveis identificadas como as mais relevantes para a previsão de classes. São instáveis e propensos a superajustar os classificadores, uma vez que uma pequena alteração no conjunto de treinamento pode modificar significativamente a estrutura da árvore (SANTIAGO & DIAS, 2022).

O algoritmo *AdaBoost* é um modelo conjunto que combina muitos classificadores simples, implementados por árvores rasas, com classificação altamente discriminativa, sendo aditivo e, portanto, para cada iteração do algoritmo uma nova árvore é adicionada ao conjunto. Uma desvantagem do *AdaBoost* é sua sensibilidade a dados ruidosos e valores discrepantes. Há também o algoritmo *Random Forests*, Florestas Aleatórias (RF), que representa uma técnica de conjunto em que

múltiplas DT são geradas sobre amostras de *bootstrap* do conjunto de dados, considerando apenas um subconjunto pequeno e aleatório dos recursos originais. Uma vantagem significativa do RF é conjugar um bom desempenho em muitos problemas práticos com uma seleção de características intrínsecas. Uma inconveniência reside em uma interpretação do modelo mais desafiador do que a DT padrão (GOMES-JÚNIOR *et al.*, 2022).

O algoritmo *Gradient Boosting*, Aumento de gradiente (GB), semelhante ao *Adaboost*, explora a abordagem de *boosting*, mas utiliza um critério para fundir os modelos que integram o conjunto com base no gradiente de uma função de perda definida pelo usuário, embora possuam o DT como classificador base mais comum adotado. O GB dispõe de uma seleção de características intrínsecas e tem como desvantagem o custo computacional maior que o RF. Já o algoritmo *Perceptron* multicamadas (MLP) é uma rede *feedforward* totalmente conectada composta por uma ou mais camadas de *perceptrons*, de aproximação universal, é uma abordagem útil ao lidar com problemas não lineares complexos. A desvantagem do MLP é o elevado número de hiperparâmetros do modelo e as dificuldades na interpretação da regra de decisão implementada pela rede (GOMES-JÚNIOR *et al.*, 2022).

Alguns autores sugerem o *software RIL-Contour* para acelerar o DL de imagens médicas como ECG, pois suporta a automatização, os métodos semiautomáticos e os métodos manuais para anotação de *voxel* e/ou texto, além de promover a padronização de conjunto de dados. Isso pode melhorar a eficiência e a precisão dos diagnósticos, auxiliando os médicos no tratamento de doenças cardíacas (PHILBRICK *et al.*, 2019).

Em um estudo onde foram analisados 24 artigos sobre métodos de DL desenvolvidos

para detecção automática de FA em sinais baseados em ECG, os autores discorrem sobre a eficácia de mais de 90% de precisão dos modelos de DL (MURAT *et al.*, 2021).

Autores sugerem, através do desenvolvimento de seus estudos, que é necessário um conhecimento médico especializado para interpretação de exames, o que torna o ML uma alternativa eficiente, importante e com alta precisão para esses diagnósticos (FENLON *et al.*, 2023).

Para realizar diagnósticos médicos através de exames de imagem, uma camada de complexidade perigosa é destinada ao profissional médico que precisa interpretar os exames. A subjetividade e os erros humanos devem ser considerados, inclusive no diagnóstico. Sendo assim, é importante padronizar a interpretação

médica de exames por imagens e a IA é uma resposta para isso (HAFIZOVIC *et al.*, 2021).

Com base neste contexto, o objetivo deste estudo foi analisar por meio de uma revisão integrativa a eficácia do DL em diagnósticos de ECG.

## MÉTODO

Trata-se de uma revisão integrativa, elaborada segundo as diretrizes metodológicas para revisões (BRASIL, 2021), e acrônimo PICo (ARAÚJO, 2020), para pesquisas não clínicas. Os critérios de elegibilidade foram: de inclusão - estudos disponibilizados na íntegra, publicados nos últimos 5 anos, que abordassem a temática; e de exclusão - referências duplicadas, e cópia completa indisponível. O diagrama da metodologia utilizada neste estudo segue conforme a **Figura 12.1**.

**Figura 12.1** Diagrama da metodologia deste estudo



Após a metodologia aplicada para revisões, foi realizada a análise bibliométrica em gráfico de rede através do *software VOSviewer 1.6.18.*, para verificação da coocorrência, citações e cocitações e acoplamento bibliográfico dos

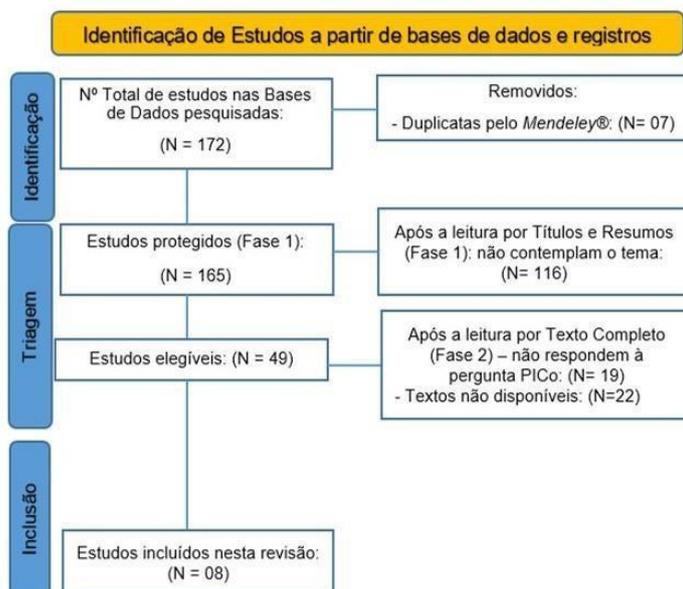
autores e das palavras-chave utilizadas nos estudos.

## RESULTADOS E DISCUSSÃO

Foram encontrados 172 estudos nas bases de dados. Após serem submetidos aos critérios

de elegibilidade, restaram oito trabalhos para extração de dados, conforme **Figura 12.2**.

**Figura 12.2** Fluxograma PRISMA



Observou-se que 100% das pesquisas (n = 08) apontavam para desfechos favoráveis à eficácia do uso do DL em diagnósticos de ECG. Verificou-se, também, que o ano que contou com mais publicações foi 2022 (n = 04, 50%), seguido de 2021 (n = 03; 37,5%) e 2023 (n = 01; 12,5%), o que enfatiza a atualidade e a relevância da temática para a comunidade científica.

O modelo que apresentou maior precisão foi o *Método de Otimização de Mud Ring com um Algoritmo de Classificação de Sinal de ECG baseado em DL (MROA-DLECGSC)*. E o

método mais usual, menos oneroso e popular de DL para ECG são as CNN, porém, apresentam como desvantagem os ajustes de parâmetros. Foi observado que a precisão de cada tipo de DL depende da técnica usada para esta avaliação, motivo pelo qual os percentuais são distintos em cada estudo analisado. Ao utilizarem uma mesma técnica avaliativa em um estudo individual verificaram a precisão comparada às outras DL. Também foi possível observar que o Brasil foi o país com mais estudos que responderam à questão de pesquisa desta revisão, conforme **Quadro 12.1**.

**Quadro 12.1** Características e desfechos dos artigos elegíveis para esta revisão

Autor e ano/País	Delineamento/ Amostra	Tipo de DL em ECG	Financiamento	Objetivo	Resultados
Alluhaidan et al. (2023) Suíça	Experimental (simulações) 3.000 ECG	MROA-DLECG SC	Universidade King Khalid e Príncipe Sattam bin Abdulaziz (Arábia Saudita), e Future University in Egypt (Egito)	Apresentar uma técnica de otimização de Mud Ring com uma técnica de classificação de ECG baseada em DL	Melhor desempenho (88,97% precisão) comparado as metodologias recentes (DLECG-CVD 88,24%; DL-ECGA 84,70%; GBT 84,98%; RF 79,83%; 1-DCNN 73%; LR 37,28%; DT 27,9%; e KNC 66,89%).

Brites <i>et al.</i> (2022) Brasil	Revisão 58 estudos	CNN	N/A	Analisar métodos e técnicas de DL	Aumento quantitativo de artigos após 2017 devido aumento da oferta de sensores e <i>wearables</i> . Evidenciou o foco em descrever modelos diagnósticos de disfunções cardiovasculares através do DL nos trabalhos mais recentes.
Gomes-Júnior <i>et al.</i> (2022) Brasil	Experimental (simulações) 105 amostras	DT AdaBoost RF SVM KNN GB LR MLP	N/A	Discutir sobre um detector automático de arritmia em pacientes em diálise, visando operar dispositivos portáteis em tempo real, de resposta rápida aos profissionais de saúde	Classificador <u>RF</u> treinado com sobreamostragem de classe minoritária, é econômico em termos de complexidade e custo computacional, alcançando uma precisão de 98,7% para tamanhos de janelas pequenas.
Isabel <i>et al.</i> (2021) Espanha	Experimental (simulações) 7027 ECG	Modelo ResNet CNN LSTM bidirecional	N/A	Apresentar um algoritmo para digitalização de ECG e classificação baseada em DL e, posteriormente, é introduzida uma rede neural residual, pré-treinada	Bem-sucedido em 100% em que o ângulo de declinação da imagem não ultrapassou 20°, 100% precisa em que a imagem foi digitalizada, modelo <u>ResNet</u> acurácia de 88%, 43% na <u>CNN</u> e 59% no <u>LSTM bidirecional</u> .
Murat <i>et al.</i> (2021) Turquia	Revisão 24 estudos	DN CNN LSTM Híbrido(CNN+LSTM)	N/A	Discutir modelos DL baseados em rede neural profunda, rede neural recorrente, memória de longo prazo, CNN, e estruturas híbridas	<u>CNN</u> : maior desempenho de detecção usando ECG e sinais de variabilidade da frequência cardíaca. É carente em análise de projetos e ajustes de parâmetros. <u>DNN</u> : em velocidade e memória é mais vantajoso, pobre na representação de sequências. <u>LSTM</u> : útil para representações de sequências, porém, lento e consome muitos recursos. <u>Híbrido</u> : vantajoso na representação de sequências, mas exige mais tempo e custo.
Santiago & Dias (2022) Brasil	Experimental (simulações) 1000 sinais de ECG	KNN LR SVM <i>Extra Trees</i>	N/A	Desenvolver um algoritmo para detecção e classificação de arritmia cardíaca em ECG	<u>Extra Trees</u> apresentou os melhores resultados para diagnosticar o ritmo cardíaco alterado (98,9% de acurácia e 98,8% de sensibilidade), mais robusta em técnicas de processamento de sinal, com resultados semelhantes para as 3 modelagens. <u>KNN</u> bons resultados, porém, um pouco inferiores.

Sarshar & Mirzaei (2022) Irã	Experimental (simulações) 48 ECG	CNN	N/A	Propor um reconhecimento de PVC baseado em uma DL usando o banco de dados de arritmia (MIT-BIH)	Melhora o desempenho do diagnóstico de forma mais eficaz; leva à diminuição da taxa de falsos positivos e ao aumento da taxa de verdadeiros positivos.
Yu <i>et al.</i> (2021) Suíça	Revisão 4 estudos	CNN GAN	N/A	Discutir dois tipos típicos de modelos de DL para síntese de imagens médicas (CNN e GAN) e apresentar quatro trabalhos recentes	<u>GAN</u> alcança melhor desempenho de síntese de imagens que os modelos convencionais em <u>CNN</u> , devido à arquitetura 3D que preserva informações contextuais contínuas melhorando os resultados. Os detalhes das imagens são essenciais para a clínica.

**Legenda:** Não se aplica ao estudo (N/A). *Método de Otimização de Mud Ring com um Algoritmo de Classificação de Sinal de ECG baseado em DL* (MROA-DLECGSC). Análise de sinal de ECG baseada em DL (DL-ECGA). DL para diagnóstico de ECG de doenças cardiovasculares (DLECG-CVD). *Gradient-boosting Tree* (GBT). *Random Forests* (RF). Rede Neural Convolutiva Profunda Unidimensional (1-DCNN). *K Neighbors Classifier* (KNC). *Decision Trees* (DT). *Support Vector Machine* (SVM). *K-Nearest Neighbors* (KNN). *Gradient Boosting* (GB). *Logistic Regression* (LR). *Multilayer Perceptron* (MLP). Redes Adversárias Generativas (GAN).

Para a verificação de coocorrência, citações e cocitações e o acoplamento bibliográfico dos autores e das palavras-chave utilizadas nos estudos, foi identificada a força total dos *links* entre elas. São autores que possuem acoplamento bibliográfico com termos DL, *neural networks* e ML. Essa análise garante a confiabilidade, a qualidade técnica e científica do estudo proposto em uma abordagem quantitativa no mapeamento do campo da pesquisa. Observou-se o grau de colaboração entre os autores e a exploração de referências científicas sobre este assunto, auxiliando a compreensão da tendência de novos estudos com esta temática, justificando futuras pesquisas sobre DL e sua eficácia nos diagnósticos da ECG em virtude das recentes publicações na área. Identificou-se os autores com maior número de publicações, citações e cocitações neste assunto, proporcionando embasamento teórico consolidado para a análise da atuação do grupo de pesquisa.

Para interpretação e melhor visualização dos dados, foi escolhido o formato em rede,

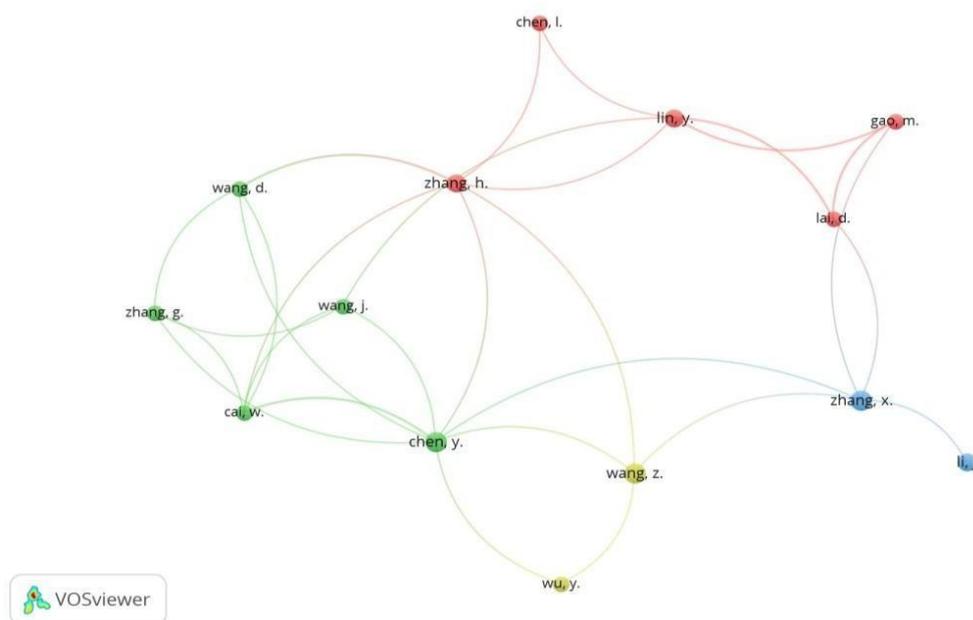
conforme a **Figura 12.3**. A figura corrobora o estudo de Brites *et al.* (2022), que mapeou os mesmos termos e observou maior frequência nos artigos publicados no ano de 2020, evidenciando foco em descrever modelos para auxiliar nos diagnósticos de disfunções cardiovasculares por DL em estudos mais recentes, ratificando a relevância atual desta temática.

Alguns autores citaram a existência de duas abordagens gerais para desenvolver ferramentas automáticas de diagnóstico de arritmias cardíacas, sendo a divisão dos sinais de ECG em unidades de batimento cardíaco ou ciclos das formas de onda, o que gera uma grande quantidade de dados para treinar modelos de ML. Enfatizam que extrair características morfológicas do ECG é desafiador devido à imprecisão, embora a previsão tenha obtido precisões tão altas quanto 99% em estudos baseados em batimentos (CHEN *et al.*, 2020). Outros estudos sobre a aplicação de inteligência artificial para detectar e classificar arritmias, como a detecção de FA ou classificando o

infarto do miocárdio usando bancos de dados de ECG de 12 eletrodos, são realizados regularmente e os resultados demonstram uma

eficácia tão ou superior a de um cardiologista humano (YOON *et al.*, 2020).

**Figura 12.3** Rede de coocorrência, citação, cocitação e acoplamento bibliográfico das palavras-chave deste estudo



Devido ao crescente número de pacientes com doenças cardiovasculares, o resultado da classificação dos ECG em virtude das grandes mudanças nos padrões de sinal necessita de ferramentas de diagnóstico automático assistidas por computador. Portanto, autores sugerem a técnica MROA-DLECGSC. Esta abordagem reconhece a presença de doença cardíaca, pré-processando os sinais de ECG para transformá-los em um formato uniforme, e otimiza hiperparâmetros, o que auxiliou na obtenção de melhor desempenho. Os resultados experimentais do algoritmo MROA-DLECGSC foram testados e demonstram melhor desempenho se comparados com outros algoritmos recentes (ALLUHAIDAN *et al.*, 2023).

## CONCLUSÃO

O DL se mostrou preciso e eficaz no diagnóstico das ECG em todos os trabalhos

analisados, e foi enfatizada a eficácia superior à de um cardiologista humano. Foi possível observar que, neste contexto, o uso da CNN alcançou um desempenho alto de classificação se comparado às outras estratégias tradicionais e de DL. Mais recentemente, o algoritmo de otimização de *Mud Ring* (MROA-DLECGSC) mostrou melhor desempenho se comparado aos algoritmos atuais analisados.

Esta revisão integrativa é parte inicial de um projeto onde, inicialmente, levantou-se a leitura para extração de dados para entendimento do tema seguida por análise bibliográfica, garantindo confiabilidade e qualidade técnica e científica do estudo proposto em uma abordagem quantitativa no mapeamento do campo da pesquisa. Observou-se as recentes publicações com esta temática, explorando as referências, o que auxiliou a compreensão da tendência de novos estudos, justificando futuras pesquisas sobre DL e sua eficácia nos

diagnósticos da ECG.

Esta revisão é importante como recurso para os pesquisadores interessados em desenvolver abordagens inovadoras de DL baseadas em ECG. Outros estudos experimentais de grande precisão, com maior amostragem e mais robustos são necessários para o aprimoramento desta medição, sendo uma proposta importante para trabalhos futuros. Outra proposta seria

desenvolver um algoritmo mais completo de DL que agregasse todos os exames cardiológicos e proporcionasse uma análise completa destes sinais e sintomas para o diagnóstico mais eficaz possível e com menor margem de erro. Sugere-se o método de Monte Carlo para esse desenvolvimento, além de pesquisas futuras.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ALLUHAIKAN, A.S. *et al.* Mud ring optimization algorithm with deep learning model for disease diagnosis on ECG monitoring system. *Sensors*, v. 23, p. 6675, 2023. doi: 10.3390/s23156675.
- ARAÚJO, W.C.O. Recuperação da informação em saúde: construção, modelos e estratégias. *Convergências em Ciência da Informação*, v. 3, p. 100, 2020.
- BRASIL. Ministério da Saúde. Secretaria de Ciência, Tecnologia, Inovação e Insumos Estratégicos em Saúde. Diretrizes metodológicas: elaboração de revisão sistemática e meta-análise de ensaios clínicos randomizados. Brasília: Ministério da Saúde, 2021.
- BRITES, I.S.G. *et al.* Aplicação da internet das coisas e aprendizado de máquina na identificação de doenças cardíacas pelas bulhas: um mapeamento sistemático. *Revista Brasileira de Computação Aplicada*, v. 14, p. 16, 2022. doi: 10.5335/rbca.v14i1.12913.
- CHAN, H.P. *et al.* Deep learning in medical image analysis. *Deep Learning in Medical Image Analysis*, v. 1213, p. 3, 2020. doi: 10.1007/978-3-030-33128-3\_1.
- CHEN, T.M. *et al.* Detection and classification of cardiac arrhythmias by a challenge-best deep learning neural network model. *IScience*, v. 23, p. 100886, 2020. doi: 10.1016/j.isci.2020.100886.
- FENLON, J.B. *et al.* A dosimetric correlation between radiation dose to bone and reduction of hemoglobin levels after radiation therapy for prostate cancer. *International Journal of Radiation Oncology, Biology, Physics*, v. 4, S0360, 2023. doi: 10.1016/j.ijrobp.2023.07.036.
- GOMES-JÚNIOR, S.P. *et al.* Intelligent detection of arrhythmia episodes in dialysis patients. *Journal of the Brazilian Society on Computational Intelligence*, v. 20, p. 34, 2022.
- HAFIZOVIC, L. *et al.* The use of artificial intelligence in diagnostic medical imaging: systematic literature review. *IEEE 21st International Conference on Bioinformatics and Bioengineering (BIBE)*, p.1-6, 2021. doi: 10.1109/BIBE52308.2021.9635307.
- ISABEL, A. *et al.* Mobile app for the digitization and deep-learning-based classification of electrocardiogram printed records. *Computing in Cardiology*, v. 48, 2021.
- MURAT, F. *et al.* Review of deep learning-based atrial fibrillation detection studies. *International Journal of Environmental Research and Public Health*, v. 18, 2021. doi: 10.3390/ijerph182111302.
- PHILBRICK, K.A. *et al.* RIL-contour: a medical imaging dataset annotation tool for and with deep learning. *Journal of Digital Imaging*, v. 32, p. 571, 2019. doi: 10.1007/s10278-019-00232-0.
- SANTIAGO, H. & DIAS, M. Automated detection of anomalies in electrocardiograms using empirical mode decomposition. *Revista Gestão & Tecnologia*, v. 22, p. 51, 2022.
- SARSHAR, N.T. & MIRZAEI, M. Premature ventricular contraction recognition based on a deep learning approach. *Journal of Healthcare Engineering*, 2022. doi: 10.1155/2022/1450723.
- SMITH, A.G. *et al.* RootPainter: deep learning segmentation of biological images with corrective annotation. *New Phytologist*, v. 236, p. 774, 2022. doi: 10.1111/nph.18387.
- YOON, D. *et al.* Discovering hidden information in biosignals from patients using artificial intelligence. *Korean J Anesthesiol*, v. 73, p. 275, 2020. doi: 10.4097/kja.19475.
- YU, B. *et al.* Medical image synthesis via deep learning. *Deep Learning in Medical Image Analysis*, v. 1213, p. 23, 2021. doi: 10.1007/978-3-030-33128-3\_2.