

UNIVERSIDADE CESUMAR UNICESUMAR
CENTRO DE CIÊNCIAS BIOLÓGICAS E DA SAÚDE
CURSO DE GRADUAÇÃO EM MEDICINA

**INTELIGÊNCIA ARTIFICIAL NO DIAGNÓSTICO DE ARRITMIAS CARDÍACAS –
UMA REVISÃO SISTEMÁTICA**

INÁCIO DE SOUZA NETO
MARIA ISABEL FANTAUCCI DE SOUZA

MARINGÁ – PR

2024

INÁCIO DE SOUZA NETO
MARIA ISABEL FANTAUCCI DE SOUZA

**INTELIGÊNCIA ARTIFICIAL NO DIAGNÓSTICO DE ARRITMIAS CARDÍACAS –
UMA REVISÃO SISTEMÁTICA**

Artigo apresentado ao Curso de Graduação em Medicina da Universidade Cesumar – UNICESUMAR como requisito parcial para a obtenção do título de Bacharel(a) em Medicina, sob a orientação da Prof.^a Dra. Bianca Altrão Ratti Paglia.

MARINGÁ – PR
2024

FOLHA DE APROVAÇÃO

INÁCIO DE SOUZA NETO
MARIA ISABEL FANTAUCCI DE SOUZA

INTELIGÊNCIA ARTIFICIAL NO DIAGNÓSTICO DE ARRITMIAS CARDÍACAS – UMA REVISÃO SISTEMÁTICA

Artigo apresentado ao Curso de Graduação em Medicina da Universidade Cesumar – UNICESUMAR como requisito parcial para a obtenção do título de Bacharel(a) em Medicina, sob a orientação da Prof.^a Dra. Bianca Altrão Ratti Paglia.

Aprovado em: ____ de _____ de ____.

BANCA EXAMINADORA

Prof.^a M.^a Lígia Maria Molinari Capel – Unicesumar

INTELIGÊNCIA ARTIFICIAL NO DIAGNÓSTICO DE ARRITMIAS CARDÍACAS – UMA REVISÃO SISTEMÁTICA

Inácio de Souza Neto

Maria Isabel Fantaucchi de Souza

RESUMO

A Inteligência Artificial (IA) tem transformado a medicina, sendo amplamente aplicada em análises de dados e robôs cirúrgicos, especialmente na cardiologia, onde demonstrou potencial em exames como eletrocardiogramas, resultando em diagnósticos mais precisos. No entanto, sua aplicabilidade ainda é limitada em casos com poucos dados. Com o aumento previsto de doenças cardiovasculares até 2030, a aliança entre tecnologias como dispositivos vestíveis e IA podem ser cruciais para reduzir a mortalidade destas doenças, embora sua integração na prática médica ainda não esteja consolidada. Por isso, essa revisão visa avaliar a aplicabilidade clínica destes métodos para a predição, detecção ou diagnósticos de arritmias cardíacas. Esta revisão sistemática com meta-análise, conduzida segundo os *guidelines* PRISMA 2020, avaliou estudos publicados entre 2014 e 2024 nas bases PubMed, Embase e Cochrane, focando no uso da IA para predição, detecção ou diagnóstico de arritmias cardíacas. Dos 11 artigos incluídos, 9 apresentaram dados suficientes para comparação direta através de meta-análise, resultando em uma sensibilidade média de 85,99% e especificidade de 81,21%. A pesquisa revelou que algoritmos como *convolutional neural network* e *random forest* superaram métodos tradicionais em precisão diagnóstica. Entretanto, limitações foram identificadas, como variações entre métodos e bancos de dados, falta de padronização e a necessidade de validação em populações maiores. Em conclusão, a revisão destacou a eficácia da IA em diagnósticos cardiovasculares, mas enfatizou a necessidade de desenvolver algoritmos mais robustos e a importância de dados públicos para futuras comparações e avaliações.

Palavras-chave: Inteligência de Máquina. Técnicas de Diagnóstico Cardiovascular. Aprendizado de Máquina.

ARTIFICIAL INTELLIGENCE IN THE DIAGNOSIS OF CARDIAC ARRHYTHMIAS – A SYSTEMATIC REVIEW

ABSTRACT

Artificial Intelligence (AI) has been transforming medicine, being widely applied in data analysis and surgical robots, especially in cardiology, where it has shown potential in exams such as electrocardiograms, resulting in more accurate diagnoses. However, its applicability is still

limited in cases with sparse data. With the expected increase in cardiovascular diseases by 2030, the alliance between technologies like wearable devices and AI could be crucial in reducing the mortality of these diseases, although its integration into medical practice is not yet established. Therefore, this review aims to evaluate the clinical applicability of these methods for the prediction, detection, or diagnosis of cardiac arrhythmias. This systematic review with meta-analysis, conducted according to the PRISMA 2020 guidelines, assessed studies published between 2014 and 2024 in PubMed, Embase, and Cochrane databases, focusing on the use of AI for the prediction, detection, or diagnosis of cardiac arrhythmias. Of the 11 included articles, 9 provided sufficient data for direct comparison through meta-analysis, resulting in an average sensitivity of 85.99% and specificity of 81.21%. The research revealed that algorithms such as convolutional neural networks and random forests outperformed traditional methods in diagnostic accuracy. However, limitations were identified, such as variations between methods and databases, lack of standardization, and the need for validation in larger populations. In conclusion, the review highlighted the effectiveness of AI in cardiovascular diagnostics but emphasized the need to develop more robust algorithms and the importance of public data for future comparisons and evaluations.

Keywords: Artificial Intelligence. Cardiovascular Diagnostic Techniques. Machine Learning.

1 INTRODUÇÃO

O termo Inteligência Artificial (IA) pode ser definido como a área de estudo dedicada à automação de tarefas complexas geralmente realizadas por humanos. Dentro dessa área de estudo destaca-se o aprendizado de máquina como um dos métodos utilizados para esse propósito, onde algoritmos permitem que através da coleta e análise de dados, sistemas computacionais possam aprender e aprimorar sua performance sem intervenção humana direta (CHOI et al, 2020).

Segundo Hamet e Tremblay (2017) o uso de IA em áreas da medicina já é realidade atualmente, através da aplicação de algoritmos matemáticos que, por meio de análises de padrões, conseguem avaliar dados e interpretá-los. As aplicações da IA podem ser divididas em duas categorias: virtuais e físicas. As aplicações virtuais na medicina são diversas, desde seu uso em pesquisas científicas, como nas áreas de genética médica e medicina molecular, até o seu uso no manejo de prontuários eletrônicos, permitindo tomadas de decisões mais rápidas e precisas. Hamet e Tremblay ainda afirmam em seu estudo de 2017 que dentro das aplicações físicas, aquelas que envolvem objetos materiais, pode-se destacar a utilização de robôs para cuidados médicos de pacientes idosos ou que possuam um déficit cognitivo, bem como o uso de robôs para a realização de cirurgias.

É nesse contexto que avanços na aplicação de IA vêm ocorrendo em diversas áreas da medicina, sendo que na cardiologia o emprego dessas tecnologias tem se mostrado particularmente promissor. Seu uso em exames como eletrocardiografia e ecocardiografia proporcionam resultados mais precisos e objetivos, mas ao mesmo tempo, ainda apresentam limitações de aplicabilidade, onde em condições mais raras, quando não há dados suficientes para a aplicação de técnicas como aprendizado de máquinas, o uso de IA ainda é extremamente restrito (ITCHHAPORIA, 2020).

Nagarajan et al. (2021) questiona qual será a aplicação da IA em áreas mais restritas da cardiologia e como esta impactará a interpretação e disponibilidade de exames coletados. Nagarajan et al. defendem o importante papel que a aprendizagem de máquinas poderá desenvolver desde o diagnóstico até o tratamento de arritmias cardíacas no futuro, mas tal afirmação parece esbarrar no número ainda limitado de dados disponíveis. Há, então, a necessidade de indagarmos quais as vantagens do uso de IA frente as técnicas atuais, quais serão os seus impactos no prognóstico dos pacientes e se tais hipóteses serão confirmadas com estudos futuros.

Estima-se que até 2030 haverá um aumento de 40% de mortes por doenças cardiovasculares, fazendo-se necessário a criação de estratégias de médio e longo prazo na tentativa de mitigar o aumento da mortalidade. Deste modo, é possível tentar refrear a escalada no número de mortes através do desenvolvimento de tecnologias, como a IA, para diagnóstico de arritmias, o uso cada vez mais frequente de dispositivos vestíveis que permitem a monitorização de sinais vitais como frequência cardíaca e saturação de oxigênio sanguíneo e o investimento em campanhas de informação e conscientização para que os pacientes estejam cada vez mais envolvidos e conscientes de suas doenças e tratamentos (PIOT et al, 2022).

Topol (2019) aponta o aparente inevitável entrelaçamento de duas vertentes da medicina: a primeira onde há investimentos cada vez maiores em mão de obra e infraestrutura no setor de saúde, mas que, no entanto, não tem retornos expressivos do ponto de vista epidemiológico. Por outro lado, há um crescimento vertiginoso nas tecnologias empregadas pelo setor, onde a necessidade de interpretação de dados e análises de imagens computadorizadas aumentam a todo momento, onde a análise humana não pode ser substituída.

Em uma análise realizada por Lee et al. (2022) percebe-se o grande potencial destes métodos quando aplicados em conjunto com novas tecnologias como dispositivos vestíveis, onde o desenvolvimento de algoritmos que necessitem de menores espaços de armazenamento, porém sem diminuïrem sua precisão, poderão ser grandes aliados da medicina em um futuro próximo, providenciando diagnósticos aos pacientes em tempo real.

Percebemos que, apesar dos avanços nas últimas décadas, a integração de IA nos meios de saúde ainda não está totalmente solidificada, deixando margem para que novas tecnologias sejam criadas e possam revolucionar sua integração com a prática médica. Desta forma, esta revisão visa avaliar a aplicabilidade clínica destes métodos para a predição, detecção ou diagnósticos de arritmias cardíacas.

2 METODOLOGIA

A pesquisa realizada se trata de uma revisão sistemática com meta-análise, a qual foi realizada de acordo com as diretrizes dos Principais Itens para Relatar Revisões Sistemáticas e

Meta-análises (PRISMA) 2020. Foram selecionados artigos entre 2014 e 2024 disponíveis na íntegra para leitura, utilizando as bases de pesquisa Pubmed, Embase e Cochrane.

Foram incluídos artigos nas línguas inglesa, portuguesa e espanhola, que correspondam aos descritores utilizados e dentro da faixa temporal estabelecida.

As palavras-chave utilizadas foram *Artificial Intelligence*, *Deep Learning*, *Neural Network*, *Machine Learning*, *Arrhythmia* e *Atrial Fibrillation*. A pesquisa dos artigos foi realizada em 7 de julho de 2024, por um autor (I.S.N.) e todas as publicações desde 1 de janeiro de 2014 até a data da pesquisa foram avaliadas sem restrições. Os títulos e resumos de cada artigo foram avaliados por ambos os autores (I.S.N e M.I.F.S.) de forma independente. Os critérios de inclusão utilizados na triagem foram:

- Estudos cujo objetivo principal fora o uso de Inteligência Artificial para a predição, detecção ou diagnóstico de arritmias cardíacas;
- Estudos que utilizaram métodos diagnósticos de imagem e/ou ECG;
- Estudos que desenvolveram ou testaram modelos de IA através de Machine Learning ou Deep Learning.

Os critérios de exclusão utilizados na triagem foram:

- Estudos que não reportaram a performance quantitativa do modelo utilizado ou com dados insuficientes;
- Estudos realizados pelos mesmos autores e/ou grupos de pesquisa.

Foram excluídos também artigos que não estavam dentro do prazo estabelecido ou que não se relacionavam com o tema proposto desta revisão.

Todos os artigos que não puderam ser avaliados através apenas dos títulos e resumos, foram incluídos na avaliação do texto completo. Artigos em que houve discordância entre os autores, sua elegibilidade foi decidida através de discussão com a orientadora deste trabalho (B. A. R. P.).

As principais variáveis foram agrupadas através de uma tabela de dados dos estudos inclusos na seleção final. Os dados analisados de cada estudo foram a data de publicação, autores, doença estudada/objetivo, banco de dados utilizado, tipo do algoritmo e a performance de cada modelo.

Para os estudos selecionados foram extraídos os valores de verdadeiro positivos (VP), verdadeiro negativos (VN), falso positivos (FP) e falso negativos (FN). Nos estudos em que esses valores não foram diretamente expressos, estes foram estimados através do número de participantes (com arritmia e sem arritmia) e através de outras métricas como sensibilidade,

especificidade, acurácia, precisão e F1-score. Os valores de verdadeiros positivos, verdadeiro negativo, falso positivo e falso negativo foram utilizados para calcular a sensibilidade e especificidade na meta-análise. Estudos em que os dados disponíveis não permitiram o cálculo desses valores, foram incluídos apenas na análise qualitativa. Da mesma maneira, os artigos que não apresentaram de forma direta os valores do intervalo de confiança, tiveram os mesmos calculados através dos dados disponíveis.

3 RESULTADOS

O fluxograma PRISMA 2020 é mostrado na Fig. 1. Após a revisão completa, 11 artigos foram incluídos na revisão, sendo que desses, 9 artigos apresentaram dados suficientes para que fosse possível uma comparação direta entre as performances de cada algoritmo e foram, portanto, incluídos na meta-análise. Outros 2 artigos que não apresentaram dados suficientes para a meta-análise foram incluídos na análise qualitativa do estudo.

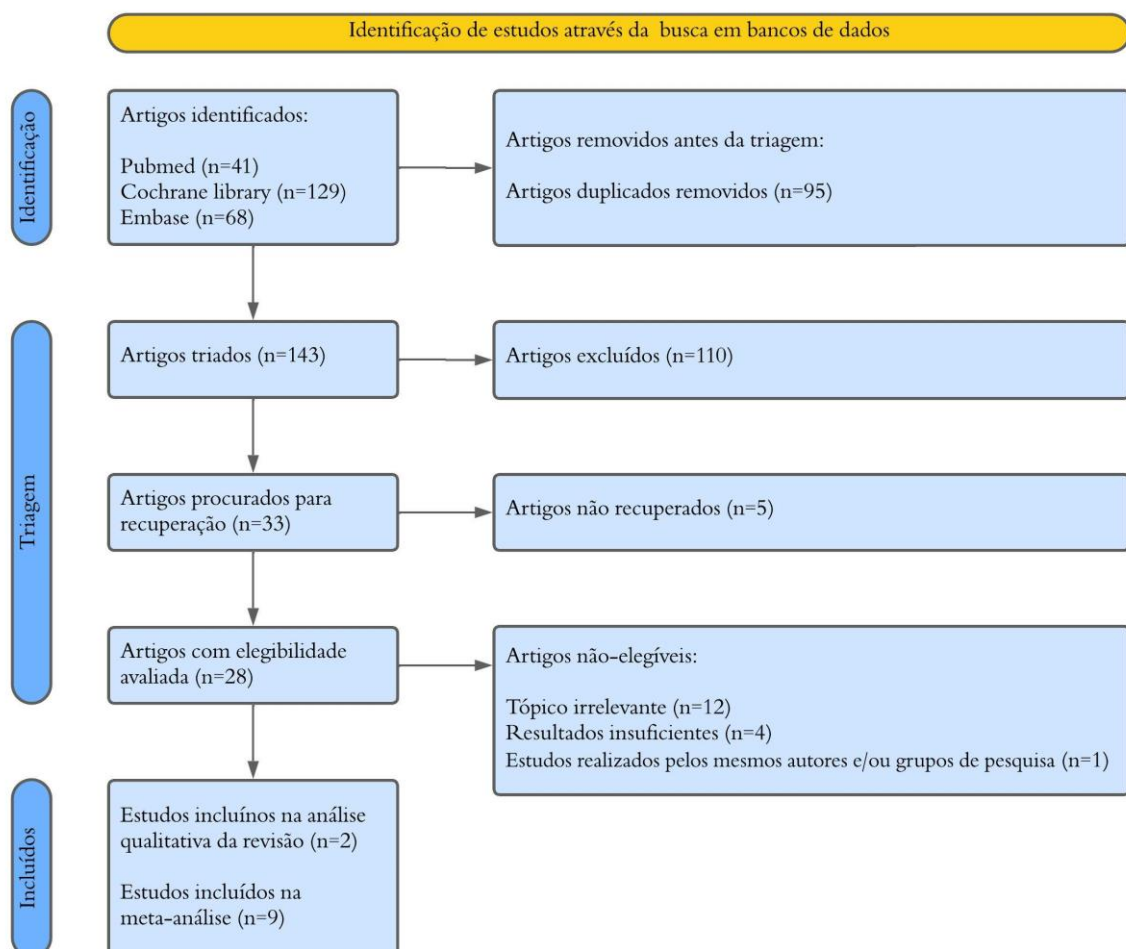


Fig.1 – Fluxograma para seleção de estudos da Principais Itens para Relatar Revisões Sistemáticas e Meta-análises (PRISMA) 2020.

Nos 11 estudos analisados, métodos de aprendizado de máquinas, como *convolutional neural networks* e *random forest* foram utilizados sozinhos ou em conjunto com outros algoritmos para o diagnóstico, predição ou detecção de arritmias cardíacas. Dentre estes, apenas 1 artigo não especificou qual o algoritmo utilizado para a análise dos dados, sendo os dados coletados através de aparelhos vestíveis com algoritmo de AI integrado ao mesmo. Um total de 9 artigos utilizou banco de dados proprietário, sendo a maioria para análise de arritmias cardíacas, o que impossibilitou uma comparação direta entre as metodologias utilizadas. A Tab. 1 apresenta uma descrição dos 11 estudos incluídos nessa revisão. O método utilizado em cada artigo para a análise do desfecho foi variável, sendo que cada artigo utilizou métodos, algoritmos e objetos de estudo distintos, porém todos tinham como objetivo final a detecção de arritmias cardíacas.

A Fig. 2 apresenta a meta-análise da sensibilidade e especificidade dos artigos analisados. Como vários dos artigos utilizaram mais de um algoritmo para seus testes, considerou-se para os parâmetros da meta-análise aqueles que geraram os melhores resultados em relação a acurácia, sensibilidade e especificidade.




Fig. 2 – Meta-análise da sensibilidade e especificidade para detecção, predição ou diagnóstico de arritmias cardíacas com o uso de inteligência artificial.

Os resultados da meta-análise mostram uma excelente performance dos algoritmos, com uma sensibilidade de 85,99% (IC 95%, 76,28%-95,70%) e uma especificidade de

Estudo	Objetivo	Dataset	Método	Resultados
AU-YEUNG, Wan-Tai M. et al	Arritmia	BD proprietário	RF e SVM	Predição 10-seg: Sensibilidade, 79,00% (IC 95%, 78,68%-79,31%); Especificidade, 80,00% (IC 95%, 79,66%-80,33%); AUC, 0,88 Predição 5-min: Sensibilidade, 75,0%; Especificidade, 75,0%; AUC, 0,81
ELTRASS, Ahmed S.; TAYEL, Mazhar B.; AMMAR, Abeer I.	Arritmia e Insuficiência Cardíaca Congestiva	MIT-BIH ARR, MIT-BIH NSR e BIDMC CHF	CNN, Alexnet, CQ-NSGT	Acurácia, 98,82%; Precisão, 99,20%; Sensibilidade, 97,30% (IC 95%, 97,08%-97,42%); Especificidade, 99,70% (IC 95%, 99,61%-99,80%)
FU, Wenxia; LI, Ruogu	Arritmia	BD proprietário		Acurácia, 96,49%; Sensibilidade, 92,45% (IC 95%, 81,64%-97,52%); Especificidade, 100% (IC 95%, 92,91%-100,00%); VPP, 100%; VPN 93,85%
HUANG, Songqun et al	Arritmia	BD proprietário	CNN-BiLSTM	Sensibilidade, 94,40% (IC 95%, 93,50%-95,10%); Especificidade, 98,50% (IC 95%, 98,30%-98,60%)
KIM, Min et al	Arritmia	BD AF-Pacemaker	LR, RF, SVM e XGB	Acurácia, 81,8%; Sensibilidade, 88,90% (IC 95%, 82,30%-93,60%); Especificidade, 31,60% (IC 95%, 12,60%-56,60%); F1-Score, 0,896; VPP, 28,6%; VPN, 90,2%
MA, Yibo et al	Arritmia	BD proprietário	RF	Acurácia, 80,3%; Precisão, 92,9%; F1-Score, 0,482
NOSEWORTHY, Peter A. et al	Arritmia	BD proprietário	CNN	≥30-seg: Sensibilidade, 89,00% (IC 95%, 81,00%-97,00%); Especificidade, 38,0% (IC 95%, 35,00%-41,00%); VPP, 8%; VPN, 98% ≥6-min: Sensibilidade, 87,0%; Especificidade, 38,0%; VPP, 6%; VPN, 98% ≥24h: Sensibilidade, 91,0%; Especificidade, 37,0%; VPP, 2%; VPN, 100%
SHIMOJO, Masafumi et al	Arritmia	BD proprietário	Decision Tree	Acurácia, 90,6%; Precisão, 90,0%; Sensibilidade, 94,70% (IC 95%, 93,40%-

				95,99%); Especificidade, 84,60% (IC 95%, 81,58%-87,61%); F1-Score, 0,92; AUC, 0,925
WANG, Lei et al	Ramos acessórios e Arritmia	BD proprietário	Alexnet, VGG19, Resnet26, SEResnet50, MobilenetV3_large e Densenet169	Acurácia, 97,3%; Precisão, 97,6%; Sensibilidade, 89,10% (IC 95%, 84,14%-94,05%); Especificidade, 99,40% (IC 95%, 98,19%-100,00%); F1-Score, 0,932
WANG, Qi et al	Arritmia	BD Anhui HF	Lasso-logistics model 1, Lasso-logistics model 2, MARS, CART, RF e XGB	AUC, 0,867
WANG, Suhuai et al	Arritmia	BD proprietário	Decision Tree, RF e ANN	Acurácia, 66,8%; Sensibilidade, 49,90% (IC 95%, 49,06%-50,73%); Especificidade, 92,20% (IC 95%, 91,69%-92,70%); AUC, 0,654; FN, 75,5%; FP, 7,8%

Tab. 1 – Algoritmos de inteligência artificial desenvolvidos e/ou testados nos estudos, com seus respectivos objetivos e performances. AUC, área sob a curva; ANN, artificial neural network; CNN, convolutional neural network; SVM, suport vector machine; RF, random forest; LR, logistic regression; XGB, extreme gradient boosting; MARS, multivariate adaptive regression splines; CART, classification and regression tree.

81,21% (IC 95%, 64,36%-98,05%). No entanto, viu-se uma grande diferença de performance entre alguns estudos, onde aqueles que utilizaram um maior número de amostras e uma *cross-validation* mais robusta, permitindo uma melhor seleção de parâmetros pelo algoritmo, resultaram em valores de sensibilidade e especificidade mais elevados e intervalos de confiança mais estreitos.

4 DISCUSSÃO

A presente revisão sistemática e meta-análise resumiu as performances de alguns algoritmos, como *convolutional neural network*, *support vector machine*, *random forest*, *logistic regression*, e outros, desenvolvidos ou testados para a predição, detecção ou diagnóstico de arritmias cardíacas. A Fig. 3 resume o processo de desenvolvimento e aplicação de um modelo de IA.

O desenvolvimento de algoritmos de *deep learning* e *machine learning* envolve várias etapas fundamentais. O processo se inicia com a captação de dados, que pode ser realizada através de dispositivos vestíveis, como monitores de atividade física ou exames intra-hospitalares como eletrocardiogramas (ECG), cardiografias e outros exames de imagem. Esses dados são então armazenados em grandes bancos de dados, que podem ser públicos ou privados, como bases de dados estruturadas (e.g., tabelas com atributos específicos) ou não estruturadas (e.g., imagens ou textos de prontuários médicos).

Após a definição do escopo do trabalho, os dados são selecionados e passam por um processo de pré-processamento, que inclui a remoção de ruído, normalização e transformação para garantir uma leitura mais precisa e uma interpretação adequada pelo algoritmo. Uma vez que os dados estão prontos, eles são divididos em conjuntos de treinamento, validação e teste. O conjunto de treinamento é usado para ensinar o algoritmo a partir de exemplos onde o algoritmo aprende a identificar associações entre as características dos dados (como padrões específicos em um ECG) e os resultados esperados (por exemplo, presença ou ausência de uma condição cardíaca), enquanto o conjunto de validação permite ajustar os parâmetros do modelo.

Após múltiplos ciclos de treinamento e ajustes, o modelo é testado em um conjunto de dados que ele nunca viu antes, permitindo uma avaliação objetiva de sua capacidade de

generalizar. Nesse ponto, métricas como acurácia, sensibilidade, especificidade e a área sob a curva ROC são usadas para determinar a eficácia do modelo em identificar corretamente as doenças cardiovasculares. Uma vez que o algoritmo tenha atingido um desempenho satisfatório nos testes, ele pode ser aplicado em cenários clínicos reais para a detecção de doenças.

Quando comparamos os resultados obtidos em nossa meta-análise com outros métodos diagnósticos de fibrilação atrial, como no estudo realizado por Gladstone et al. (2021), onde não foram utilizados algoritmos de aprendizado de máquinas para a análise dos resultados, percebemos resultados significativamente melhores quando há o uso de IA's. Essa diferença se dá principalmente pela capacidade do algoritmo em reconhecer padrões de forma adaptativa, permitindo que diagnósticos que não seriam detectados por outros métodos de análise possam ser reconhecidos através de pequenas similaridades apresentadas em outros pacientes, vantagem essa que escala com o tamanho do banco de dados utilizados para o desenvolvimento dos algoritmos. Dessa maneira, a importância da disponibilidade de bancos de dados públicos torna-se cada dia mais evidente, pois é através de um grande volume de dados analisados e da possibilidade do uso do mesmo *data set* para desenvolvimento de vários algoritmos que podemos ter uma comparação direta entre as performances de cada método.

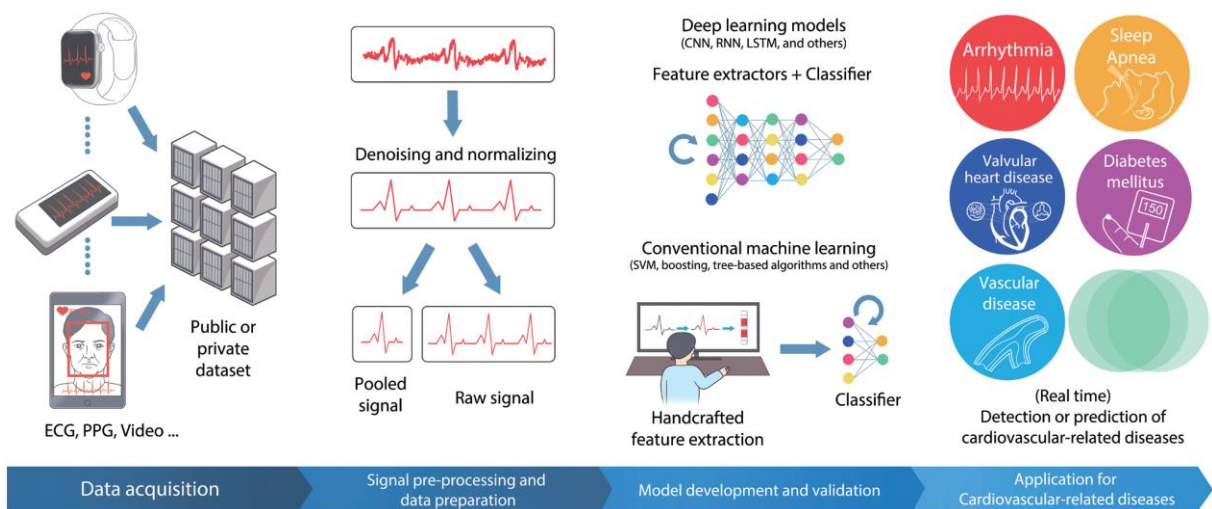


Fig. 3 – Ilustração esquemática do desenvolvimento de algoritmos de IA para predição, detecção ou diagnóstico de doenças cardiovasculares. Fonte: LEE, Solam et al. (2022).

De qualquer maneira, uma das principais desvantagens apresentadas pelos métodos é que, mesmo utilizando-se bases de dados similares, diferentes algoritmos podem apresentar discrepâncias significativas em seus resultados. Tais achados vão ao encontro daqueles feitos por Barzilai et al. (2024), onde a heterogeneidade da população estudada e a arquitetura dos algoritmos utilizados e variabilidade da aplicação da tecnologia dificultaram uma comparação direta entre os estudos analisados. Um dos principais motivos para essas disparidades é que o método de interpretação dos dados analisados pode variar muito durante o desenvolvimento de cada algoritmo, efeito esse que temos pouco ou nenhum controle, mas que ainda assim influenciará de forma significativa os resultados, efeitos também observados por Smith et al. (2023) onde os autores afirmam que aleatoriedades nos parâmetros de inicialização do modelo utilizado podem afetar diretamente a convergência do algoritmo e, conseqüentemente, sua performance. Além disso há também o fato que, apesar da alta precisão dos métodos desenvolvidos, ainda não é possível que profissionais da área da saúde aceitem tais resultados sem que haja uma revisão minuciosa por um profissional capacitado. Talvez com o desenvolvimento de métodos onde a intervenção do avaliador ocorra em estágios mais iniciais da aplicação do algoritmo possa aumentar significativamente a confiabilidade dos resultados, proporcionando que a utilização do aprendizado de máquinas trabalhe em conjunto com os profissionais aumentando a eficiência e precisão diagnósticas.

Devemos também destacar a importância da aplicação destes algoritmos em dispositivos vestíveis, onde constata-se um acompanhamento mais prolongado de cada paciente, aumentando a capacidade de diagnósticos mais precisos, além de possibilitar que o usuário seja avisado em tempo real caso ocorram alterações fisiológicas importantes nas medições. Apesar disso, há limitações para esses dispositivos, como a dificuldade para o desenvolvimento de algoritmos que sejam suficientemente eficazes para serem processados diretamente nos dispositivos e medições realizadas que ocorrem em um ambiente pouco ou nada controlado, já que os pacientes realizam o uso destes dispositivos durante suas vidas diárias, onde não há garantia de condições ideais para que ocorram as medições. Outra limitação importante apontada por Ahmed et al. (2023) é a diferença na construção dos dispositivos em si e a comparação entre performance de aparelhos de marcas distintas, já que os componentes utilizados para a construção não são padronizados na indústria. Caso ocorram muitos alarmes por falsos positivos, por falha do devido processamento dos dados ou pela detecção excessiva de ruído pelo aparelho, os usuários podem querer deixar de utilizar os dispositivos. Dessa forma, algoritmos que processam os dados de forma adequada,

considerando as falhas de aquisição adequada dos sinais, são fundamentais para a aplicação desse tipo de tecnologia no sistema de saúde.

Uma limitação desta revisão sistemática é a heterogeneidade dos artigos analisados, onde apesar de apresentarem os mesmos objetivos, foram utilizados métodos de análise, bancos de dados e algoritmos diferentes em cada artigo. Como exemplo podemos citar a aquisição de ECG, onde em alguns artigos foram utilizadas medidas obtidas em meio intra-hospitalar, enquanto outros realizaram a medição através de dispositivos com apenas uma ou duas derivações e em ambientes não controlados, dificultando que uma comparação direta entre eles possa ser realizada. Wang et al. (2023) apresenta as mesmas preocupações com a aquisição, tratamento e segurança dos dados, apontando para desafios atuais do desenvolvimento da tecnologia. Tais discrepâncias podem ter resultado na produção de estimativas estatísticas inapropriadas durante a síntese quantitativa dos estudos que foram realizados utilizando diferentes métodos de aquisição de dados. Outra limitação que se destaca é o número ainda reduzido de estudos disponíveis, sendo necessário que seus dados ainda sejam testados em outras populações para a validação adequada dos métodos utilizados e a análise da reprodutibilidade das performances dos algoritmos. Destacamos também a falta de padronização nas métricas utilizadas para a aferição da performance, dificultando a comparação entre os trabalhos.

5 CONCLUSÃO

Em conclusão, essa revisão sistemática com meta-análise revelou que diversos modelos e algoritmos de aprendizado de máquinas estão sendo desenvolvidos para a predição, detecção e diagnósticos de doenças cardiovasculares. Diversos estudos demonstram que a utilização de IA possibilita testes com alta performance, como sensibilidade e especificidade elevados, quando utilizados algoritmos apropriados como *convolutional neural network*, principalmente quando comparados com outros métodos diagnósticos já existentes que utilizam a visualização humana para a interpretação ou extração de dados.

No entanto ainda há a necessidade de desenvolvimento de algoritmos mais eficazes, que possuam bases de dados públicas e que suas performances sejam testadas em diversas populações, e possam ser avaliadas de maneira fidedigna. Concluimos também que há a necessidade de que outras características como o processo de aquisição dos dados, princípio

de funcionamento e a interpretabilidade dos modelos sejam minuciosamente avaliadas para uma aplicação prática da IA em práticas diárias da medicina.

REFERÊNCIAS

AHMED, A. et al. The effectiveness of Wearable Devices Using Artificial Intelligence for Blood Glucose Level Forecasting or Prediction: Systematic Review. **Journal of Medical Internet Research**, v. 25, 2023. DOI 10.2196/40259. Disponível em: <https://doi.org/10.2196/40259>. Acesso em: 12 out. 2024.

AU-YEUNG, Wan-Tai M. et al. Development and validation of warning system of ventricular tachyarrhythmia in patients with heart failure with heart rate variability data. **PLoS ONE**, v. 13, 2018. DOI 10.1371/journal.pone.0207215. Disponível em: <https://doi.org/10.1371/journal.pone.0207215>. Acesso em: 7 jul. 2024.

BARZILAI, D. H. et al. Machine learning in cardiac stress test interpretation: a systematic review. **European Heart Journal**, v. 5, p. 401-408, 2024. DOI 10.1093/ehjdh/ztae027. Disponível em: <https://doi.org/10.1093/ehjdh/ztae027>. Acesso em: 10 out. 2024.

CHOI, R. Y. et al. Introduction to Machine Learning, Neural Networks, and Deep Learning. **Trans. Vis. Sci. Tech, Portland**, v. 9, p. 1-12, 2020. DOI 10.1167/tvst.9.2.14. Disponível em: <https://doi.org/10.1167/tvst.9.2.14>. Acesso em: 18 set. 2023.

ELTRASS, Ahmed S.; TAYEL, Mazhar B.; AMMAR, Abeer I. A new automated CNN deep learning approach for identification of ECG congestive heart failure and arrhythmia using constant-Q non-stationary Gabor transform. **Biomedical Signal Processing and Control**, v.65, 2021. DOI 10.1016/j.bspc.2020.102326. Disponível em: <https://doi.org/10.1016/j.bspc.2020.102326>. Acesso em: 7 jul. 2024.

FU, Wenxia; LI, Ruogu. Diagnostic performance of a wearing dynamic ECG recorder for atrial fibrillation screening: the HUAMI heart study. **BCM Cardiovascular Disorders**, v. 21, 2021. DOI 10.1186/s12872-021-02363-1. Disponível em: <https://doi.org/10.1186/s12872-021-02363-1>. Acesso em: 7 jul. 2024.

GLADSTONE, David J. et al. Screening for Atrial Fibrillation in Older Population: A Randomized Clinical Trial. **JAMA Cardiology**, v. 6, p. 558-567, 2021. DOI

10.1001/jamacardio.2021.0038. Disponível em:
<https://doi.org/10.1001%2Fjamacardio.2021.0038>. Acesso em: 20 set. 2024.

HAMET, P.; TREMBLAY, J. Artificial intelligence in medicine. **Metabolism: Clinical and Experimental**, Québec, v. 69, p. 36S-40S, 2017. DOI 10.1016/j.metabol.2017.01.011. Disponível em: <https://doi.org/10.1016/j.metabol.2017.01.011>. Acesso em: 10 set. 2023.

HUANG, Songqun et al. Portable Device Improves the Detection of Atrial Fibrillation After Ablation. **International Heart Journal**, v. 62, p. 786-791, 2021. DOI 10.1536/ihj.21-067. Disponível em: <https://doi.org/10.1536/ihj.21-067>. Acesso em: 7 jul. 2024.

ITCHHAPORIA, D. Artificial Intelligence in Cardiology. **Trends in Cardiovascular Medicine, Irvine**, v. 32, p. 34-41, 2020. DOI 10.1016/j.tcm.2020.11.007. Disponível em: <https://doi.org/10.1016/j.tcm.2020.11.007>. Acesso em: 25 set. 2023.

KIM, Min et al. Artificial intelligence predicts clinically relevant atrial high-rate episodes in patients with cardiac implantable electronic devices. **Scientific Reports**, v. 12, 2022. DOI 10.1038/s41598-021-03914-4. Disponível em: <https://doi.org/10.1038/s41598-021-03914-4>. Acesso em: 7 jul. 2024.

LEE, Solam et al. Artificial Intelligence for Detection of Cardiovascular-Related Diseases from Wearable Devices: A Systematic Review and Meta-Analysis. **Yonsei Medical Journal**, v. 63, 2022. DOI 10.3349/ymj.2022.63.S93. Disponível em: <https://doi.org/10.3349/ymj.2022.63.S93>. Acesso em: 13 abr. 2024.

MA, Yibo et al. Explainable machine learning model reveals its decision-making process in identifying patients with paroxysmal atrial fibrillation at high risk for recurrence after catheter ablation. **BCM Cardiovascular Disorders**, v. 23, 2023. DOI 10.1186/s12872-023-03087-0. Disponível em: <https://doi.org/10.1186/s12872-023-03087-0>. Acesso em: 7 jul. 2024.

NAGARAJAN, V. D. et al. Artificial intelligence in the diagnosis and management of arrhythmias. **European Heart Journal, Londres**, v. 42, p. 3904-3914, 2021. DOI 10.1093/eurheartj/ehab544. Disponível em: <http://doi.org/10.1093/eurheartj/ehab544>. Acesso em: 1 out. 2023.

NOSEWORTHY, Peter A. et al. Artificial intelligence-guided screening for atrial fibrillation using electrocardiogram during sinus rhythm: a prospective non-randomised interventional trial. **The Lancet**, v. 400, p. 1206-1212, 2022. DOI 10.1016/ S0140-6736(22)01637-3. Disponível em: [https://doi.org/10.1016/S0140-6736\(22\)01637-3](https://doi.org/10.1016/S0140-6736(22)01637-3). Acesso em: 7 jul. 2024.

PIOT, O. et al. Prospective evolution of cardiac arrhythmia care: 2030 vision. **Archives of Cardiovascular Disease**, Saint-Denis, v. 115, p. 179-189, 2022. DOI 10.1016/j.acvd.2022.02.008. Disponível em: <https://doi.org/10.1016/j.acvd.2022.02.008>. Acesso em: 8 out. 2023.

SHIMOJO, Masafumi et al. A novel practical algorithm using machine learning to differentiate outflow tract ventricular arrhythmia origins. **Journal of Cardiovascular Electro physiology**, v. 34, p. 627-637, 2023. DOI 10.1111/jce.15823. Disponível em: <https://doi.org/10.1111/jce.15823>. Acesso em: 7 jul. 2024.

SMITH, Luke A. et al. Machine Learning and deep learning predictive models for long-term prognosis in patients with chronic obstructive pulmonary disease: a systematic review and meta-analysis. **Lancet Digit Health**, v. 5, p. 872-881, 2023. DOI 10.1016/S2589-7500(23)00177-2. Disponível em: [https://doi.org/10.1016/S2589-7500\(23\)00177-2](https://doi.org/10.1016/S2589-7500(23)00177-2). Acesso em: 18 out. 2024.

TOPOL, E. J. High-performance medicine: the convergence of human and artificial intelligence. **Nature Medicine**, v. 25, p. 44-56, 2019. DOI 10.1038/s41591-018-0300-7. Disponível em: <https://doi.org/10.1038/s41591-018-0300-7>. Acesso em: 26 out. 2023.

WANG, Lei et al. Deep learning-mediated prediction of concealed accessory pathway based on sinus rhythmic electrocardiograms. **Annals of Noninvasive Electrocardiology**, v. 28, 2023. DOI 10.1111/anec.13072. Disponível em: <https://doi.org/10.1111/anec.13072>. Acesso em: 7 jul. 2024.

WANG, Qi et al. Machine learning-based risk prediction of malignant arrhythmia in hospitalized patients with heart failure. **ESC Heart Failure**, v. 8, p. 5363-5371, 2021. DOI 10.1002/ehf2.13627. Disponível em: <https://doi.org/10.1002/ehf2.13627>. Acesso em: 7 jul. 2024.

WANG, Suhuai et al. Application of machine learning to predict the occurrence of arrhythmia after acute myocardial infarction. **BCM Medical Informatics and Decision Making**, v. 21, 2021. DOI 10.1186/s12911-021-01667-8. Disponível em: <https://doi.org/10.1186/s12911-021-01667-8>. Acesso em: 7 jul. 2024.

WANG, Ying et al. Guidelines, Consensus Statements, and Standards for the Use of Artificial Intelligence in Medicine: Systematic Review. **Journal of Medical Internet Research**, v. 25,

2023. DOI 10.2196/46089. Disponível em: <https://doi.org/10.2196/46089>. Acesso em: 13 out. 2024.