


**APLICAÇÕES DE MACHINE LEARNING EM CARDIOLOGIA PARA
PACIENTES COM OBESIDADE SUBMETIDOS A TERAPIAS DE
EMAGRECIMENTO: UMA REVISÃO SISTEMÁTICA**

**APPLICATIONS OF MACHINE LEARNING IN CARDIOLOGY FOR OBESE
PATIENTS UNDERGOING WEIGHT LOSS THERAPIES: A SYSTEMATIC
REVIEW**

**APLICACIONES DEL APRENDIZAJE AUTOMÁTICO EN CARDIOLOGÍA PARA
PACIENTES OBESOS SOMETIDOS A TERAPIAS DE PÉRDIDA DE PESO: UNA
REVISIÓN SISTEMÁTICA**

 <https://doi.org/10.56238/arev7n11-316>

Data de submissão: 25/10/2025

Data de publicação: 25/11/2025

Samy Sousa Sardinha

Instituição: Escola Superior de Ciências da Saúde – ESCS

Endereço: Goiânia, Brasil

E-mail: sammy_sardinha@hotmail.com

Orcid: <https://orcid.org/0009-0003-2967-4770>

José Israel Sanchez Robles

Instituição: Universidade de Rio Verde – UniRV

Endereço: Goiânia, Brasil

E-mail: joseisraelsanchezrobles@gmail.com

Orcid: <https://orcid.org/0000-0003-0061-5112>

Carlos dos Santos Kückelhaus

Instituição: Centro Universitário do Planalto Central Aparecido dos Santos – UNICEPLAC

Endereço: Brasília, Brasil

E-mail: cscarlossantos@gmail.com

Orcid: <https://orcid.org/0009-0008-0257-6958>

Thales Maia Teixeira

Instituição: Hospital Regional da Asa Norte – HRAN

Endereço: Brasília, Brasil

E-mail: thalesmaiat@hotmail.com

Orcid: <https://orcid.org/0009-0008-0047-4819>

RESUMO

A presente revisão sistemática teve como objetivo analisar as aplicações e os resultados das técnicas de machine learning (ML) na cardiologia de pacientes com obesidade submetidos a terapias de emagrecimento. A pesquisa foi conduzida segundo as diretrizes do PRISMA 2020 e utilizou a estrutura PICO para formular a questão norteadora. Foram realizadas buscas nas bases PubMed, Scopus, Web of Science, ScienceDirect, SciELO e CAPES, abrangendo o período de janeiro de 2019 a novembro de 2025. Identificaram-se 1.642 registros, dos quais 13 estudos atenderam aos critérios de elegibilidade. A qualidade metodológica foi avaliada pelo instrumento QUADAS-2, permitindo identificar riscos de viés e preocupações de aplicabilidade. Os resultados mostraram que as técnicas

de ML têm transformado o diagnóstico e o prognóstico cardiovascular, especialmente por meio de algoritmos supervisionados, como support vector machine, random forest e redes neurais convolucionais, que alcançaram acurácias superiores a 90% em predições de insuficiência cardíaca e detecção de anormalidades cardíacas. Observou-se avanço significativo na integração de dados clínicos, genéticos e de imagem, promovendo maior precisão na estratificação de risco. No entanto, verificou-se escassez de estudos específicos com foco em pacientes obesos submetidos a terapias de emagrecimento, o que limita a generalização dos resultados e evidencia uma lacuna científica relevante.

Palavras-chave: Aprendizado de Máquina. Medicina. Cardiologia.

ABSTRACT

This systematic review aimed to analyze the applications and results of machine learning (ML) techniques in cardiology for obese patients undergoing weight loss therapies. The research was conducted according to the PRISMA 2020 guidelines and used the PICO framework to formulate the guiding question. Searches were performed in the PubMed, Scopus, Web of Science, ScienceDirect, SciELO, and CAPES databases, covering the period from January 2019 to November 2025. 1,642 records were identified, of which 13 studies met the eligibility criteria. Methodological quality was assessed using the QUADAS-2 instrument, allowing the identification of bias risks and applicability concerns. The results showed that ML techniques have transformed cardiovascular diagnosis and prognosis, especially through supervised algorithms such as support vector machines, random forests, and convolutional neural networks, which achieved accuracies greater than 90% in predicting heart failure and detecting cardiac abnormalities. Significant progress was observed in the integration of clinical, genetic, and imaging data, promoting greater accuracy in risk stratification. However, a scarcity of specific studies focusing on obese patients undergoing weight-loss therapies was found, which limits the generalizability of the results and highlights a relevant scientific gap.

Keywords: Machine Learning. Medicine. Cardiology.

RESUMEN

Esta revisión sistemática tuvo como objetivo analizar las aplicaciones y los resultados de las técnicas de aprendizaje automático (AA) en cardiología para pacientes obesos sometidos a terapias de pérdida de peso. La investigación se realizó siguiendo las directrices PRISMA 2020 y utilizó el marco PICO para formular la pregunta guía. Se realizaron búsquedas en las bases de datos PubMed, Scopus, Web of Science, ScienceDirect, SciELO y CAPES, abarcando el período de enero de 2019 a noviembre de 2025. Se identificaron 1642 registros, de los cuales 13 estudios cumplieron los criterios de elegibilidad. La calidad metodológica se evaluó mediante el instrumento QUADAS-2, que permitió identificar riesgos de sesgo y problemas de aplicabilidad. Los resultados mostraron que las técnicas de AA han transformado el diagnóstico y el pronóstico cardiovascular, especialmente a través de algoritmos supervisados como las máquinas de vectores de soporte, los bosques aleatorios y las redes neuronales convolucionales, que alcanzaron una precisión superior al 90 % en la predicción de la insuficiencia cardíaca y la detección de anomalías cardíacas. Se observó un progreso significativo en la integración de datos clínicos, genéticos y de imagen, lo que permitió una mayor precisión en la estratificación del riesgo. Sin embargo, se constató la escasez de estudios específicos centrados en pacientes obesos sometidos a terapias para la pérdida de peso, lo que limita la generalización de los resultados y pone de manifiesto una importante laguna científica.

Palabras clave: Aprendizaje Automático. Medicina. Cardiología.

1 INTRODUÇÃO

A obesidade representa um dos maiores desafios de saúde pública do século XXI e constitui fator determinante para o desenvolvimento de doenças cardiovasculares. A literatura científica recente aponta crescimento expressivo da prevalência de obesidade em adultos e o consequente aumento do risco de insuficiência cardíaca, cardiomiopatia e doença arterial coronariana. A Organização Mundial da Saúde (OMS) estima que mais de 1 bilhão de pessoas apresentem sobrepeso ou obesidade, e cerca de 30% dos óbitos cardiovasculares globais estejam relacionados a esse agravo. Esse cenário reforça a necessidade de métodos diagnósticos mais precisos e personalizados, capazes de reconhecer precocemente padrões de risco em indivíduos metabolicamente vulneráveis (Cuocolo et al., 2019).

Já, as doenças cardiovasculares continuam sendo a principal causa de mortalidade global, respondendo por cerca de 17,9 milhões de óbitos anuais, o que representa 31% de todas as mortes no mundo (Lima et al., 2024). A obesidade, reconhecida como um dos principais fatores de risco, relaciona-se à hipertrofia ventricular esquerda, disfunção endotelial e alterações metabólicas que potencializam o risco de eventos cardíacos adversos. O manejo clínico de indivíduos obesos submetidos a terapias de emagrecimento exige estratégias de acompanhamento precisas, e nesse contexto, as técnicas de Machine Learning ML têm se destacado por sua capacidade de aprimorar a estratificação de risco cardiovascular e o monitoramento terapêutico (Cuocolo et al., 2019).

A cardiologia contemporânea passa por uma transformação impulsionada pela Inteligência Artificial (IA), que possibilita integrar dados clínicos, genômicos e de imagem em análises preditivas de alta complexidade (Mesquita, 2017). Estudos recentes indicam que algoritmos de aprendizado supervisionado e redes neurais profundas atingem acurácia superior a 90% na detecção de anomalias eletrocardiográficas e na previsão de insuficiência cardíaca (Paixão et al., 2022; Lima et al., 2024). Tais resultados evidenciam o potencial dessas tecnologias para transformar o diagnóstico e o prognóstico cardiometabólico.

De acordo com Sardinha et al., (2025) nos últimos anos, a IA se consolidou como uma das inovações mais significativas na área da saúde. Esse avanço é particularmente significativo em face do rápido aumento da produção de dados na área da saúde, consequência da digitalização dos registros eletrônicos, da difusão da genômica e do uso de dispositivos vestíveis que oferecem informações constantes sobre indicadores fisiológicos.

O ML, ramo da IA, consolidou-se como ferramenta essencial na análise de grandes volumes de dados clínicos e na modelagem de previsões diagnósticas. Na cardiologia, as aplicações de ML expandiram-se em áreas como eletrocardiografia automatizada, análise de imagens ecocardiográficas e tomográficas, estratificação de risco e monitoramento remoto de pacientes. Os algoritmos de

aprendizado supervisionado e profundo vêm demonstrando desempenho superior aos modelos estatísticos convencionais na identificação de anormalidades cardíacas em pacientes obesos, especialmente quando associados a terapias de emagrecimento farmacológicas e cirúrgicas.

No Brasil, pesquisas têm ressaltado a aplicabilidade crescente da IA em contextos clínicos, especialmente na predição de eventos cardiovasculares e no apoio à decisão médica (Mesquita et al., 2023). A integração entre algoritmos de IA e tecnologias emergentes, como impressão 3D e modelagem digital, vem promovendo a personalização terapêutica e o planejamento cirúrgico de alta precisão. De forma complementar, o aprendizado de máquina permite a análise de grandes volumes de dados provenientes de exames como Eletrocardiogramas (ECG) e ecocardiogramas, convertendo-os em indicadores de risco cardiovascular e auxiliando o clínico na tomada de decisão (Paixão et al., 2022).

Autores contemporâneos destacam ainda que a IA redefine o papel do profissional de saúde, ao reduzir a variabilidade diagnóstica e apoiar decisões baseadas em evidências computacionais (Marques et al., 2020; Andretta, 2022). Contudo, tais avanços também impõem desafios éticos, metodológicos e regulatórios, relacionados à transparência algorítmica, à validação clínica e à equidade no acesso às inovações.

Apesar do crescimento exponencial das publicações sobre a aplicação da inteligência artificial e do ML na cardiologia, observa-se lacuna significativa quanto a estudos que abordem especificamente pacientes com obesidade submetidos a terapias de emagrecimento. A literatura recente concentra-se, em sua maioria, na predição de risco cardiovascular geral, no diagnóstico automatizado de doenças coronarianas e na estratificação de eventos cardíacos em populações heterogêneas (Arrubla-Hoyos; Carrascal-Porras; Gómez, 2024; Costalat; Tavares, 2022; Sevakula et al., 2020; Almeida et al., 2025).

Nenhuma revisão sistemática identificada contemplou de forma integrada os desfechos cardiometabólicos relacionados ao emagrecimento clínico ou cirúrgico, tampouco investigou a acurácia de algoritmos de aprendizado na predição de complicações cardiovasculares em indivíduos obesos após intervenção terapêutica. Essa lacuna científica justifica a presente revisão, voltada a reunir e analisar criticamente as evidências disponíveis sobre o emprego de machine learning na cardiologia aplicada a pacientes com obesidade em processo de perda ponderal, de modo a subsidiar futuras pesquisas e orientar a implementação de tecnologias preditivas em contextos clínicos de alto risco.

Diante desse panorama, a presente revisão sistematizada, conduzida segundo as diretrizes do PRISMA 2020, busca analisar criticamente as evidências disponíveis sobre as aplicações de machine learning em cardiologia voltadas a pacientes com obesidade submetidos a terapias de emagrecimento.

O estudo tem como objetivo examinar as técnicas mais recentes de ML, avaliar seus resultados clínicos e discutir suas implicações éticas e operacionais no contexto da medicina de precisão.

2 REFERENCIAL TEÓRICO

2.1 MACHINE LEARNING

O ML representa um campo central da IA e configura um dos principais instrumentos tecnológicos aplicados à medicina contemporânea. Seu fundamento epistemológico baseia-se na capacidade de sistemas computacionais identificarem padrões complexos e produzirem inferências a partir de grandes volumes de dados, sem depender de instruções programadas explicitamente. A evolução do ML, impulsionada pelo crescimento da capacidade computacional e pela disponibilidade de bancos de dados clínicos massivos, consolidou-se como elemento essencial para o avanço da medicina de precisão (Zhou et al., 2023).

As aplicações do ML em saúde destacam-se pela habilidade de processar variáveis clínicas, laboratoriais, genéticas e de imagem em modelos preditivos capazes de antecipar desfechos e auxiliar a tomada de decisão médica (Paixão et al., 2022). Diferentemente da análise estatística tradicional, que pressupõe relações lineares e independência entre variáveis, o ML permite a modelagem de interações não lineares e a descoberta de padrões ocultos. Essa flexibilidade confere-lhe notável capacidade de adaptação em cenários clínicos complexos, como o diagnóstico e a predição de eventos cardiovasculares em populações heterogêneas.

A IA aplicada à cardiologia proporciona novas perspectivas sobre o risco cardiovascular, integrando parâmetros clínicos, hemodinâmicos e metabólicos. O ML é utilizado na análise de imagens ecocardiográficas, ressonâncias magnéticas e tomografias, além de integrar dados genéticos e biomarcadores inflamatórios para prever insuficiência cardíaca, arritmias e doença arterial coronariana (Andretta, 2022). Esses sistemas aprendem a partir de exemplos prévios, ajustando seus parâmetros internos para maximizar a acurácia das previsões, o que os torna adequados para tarefas diagnósticas e prognósticas de alta complexidade.

Os algoritmos de aprendizado podem ser classificados em supervisionados, não supervisionados e por reforço. No aprendizado supervisionado, o modelo é treinado com dados rotulados, possibilitando a identificação de padrões preexistentes para prever novos resultados. Nos métodos não supervisionados, a máquina busca correlações ocultas e realiza agrupamentos (*clusters*) sem conhecimento prévio das respostas, sendo úteis para segmentar perfis de pacientes com fatores de risco semelhantes. Já o aprendizado por reforço envolve a adaptação de decisões mediante recompensas ou penalidades, característica aplicável à otimização de tratamentos individualizados

(Zhou et al., 2023).

No campo da cardiologia, o ML tem contribuído significativamente para o desenvolvimento de sistemas de apoio à decisão clínica e ferramentas de monitoramento contínuo. A utilização de redes neurais artificiais na análise de ECG permite a identificação de padrões anormais com precisão superior à do diagnóstico visual convencional (Andretta, 2022). Além disso, a combinação de modelos de ML com dispositivos vestíveis (*wearables*) possibilita a detecção precoce de arritmias, insuficiência cardíaca e eventos isquêmicos em tempo real.

A implementação do ML também se mostra relevante no contexto da obesidade e da cardiometabolismo. A obesidade, reconhecida como um dos principais fatores de risco cardiovascular, tem sido estudada com técnicas de aprendizado profundo (*deep learning*), que analisam múltiplos parâmetros metabólicos e comportamentais para prever desfechos cardíacos adversos. Modelos baseados em redes neurais e *random forests* alcançam acurácia superior a 90% na predição de eventos coronarianos e na estratificação de risco (Zhou et al., 2023). Esses resultados reforçam o potencial do ML para aprimorar estratégias preventivas e terapêuticas, especialmente em indivíduos submetidos a terapias de emagrecimento.

Contudo, o avanço tecnológico demanda reflexão ética e regulatória. O uso de algoritmos preditivos em saúde impõe desafios relacionados à transparência, à reprodutibilidade dos modelos e à proteção de dados sensíveis. A validação clínica rigorosa e a explicabilidade dos algoritmos são condições indispensáveis para sua incorporação segura à prática médica (Navus, 2019). A integração entre conhecimento médico e ciência de dados, portanto, deve ocorrer de modo interdisciplinar, garantindo rigor técnico e respeito aos princípios bioéticos.

2.2 TÉCNICAS DE MACHINE LEARNING NA CARDIOLOGIA

As técnicas de machine learning aplicadas à cardiologia compreendem um conjunto de algoritmos voltados à classificação, regressão, clusterização e redução de dimensionalidade. Esses métodos possibilitam o processamento de dados de alta complexidade e o reconhecimento de padrões fisiopatológicos associados às doenças cardiovasculares (Zhou et al., 2023). Entre as técnicas mais empregadas, destacam-se o *Random Forest* (RF), o *Support Vector Machine* (SVM), as redes neurais artificiais (RNA), o *k-means clustering* e a Análise De Componentes Principais (PCA).

O algoritmo *random forest* baseia-se na construção de múltiplas árvores de decisão e na agregação dos resultados por meio de votação majoritária. Cada árvore é gerada a partir de amostras aleatórias dos dados originais, e o conjunto das previsões tende a reduzir o erro de classificação. Essa abordagem apresenta alta robustez e resistência ao sobreajuste, além de fornecer medidas de

importância das variáveis, o que permite identificar fatores clínicos determinantes para o prognóstico cardiovascular. Em estudos recentes, o RF demonstrou desempenho consistente na previsão de mortalidade em pacientes com estenose aórtica e insuficiência cardíaca, bem como na detecção de isquemia miocárdica em imagens angiográficas (Zhou et al., 2023).

As redes neurais profundas (*deep neural networks*) representam outra categoria de destaque. Inspiradas no funcionamento cerebral, essas estruturas compostas por múltiplas camadas processam dados de forma hierárquica, extraindo características progressivamente mais abstratas. Aplicadas à cardiologia, permitem interpretar imagens médicas com elevada precisão, identificar remodelamentos ventriculares sutis e prever a ocorrência de arritmias antes de sua manifestação clínica (Andretta, 2022). Estudos demonstram que modelos de deep learning superam cardiologistas humanos em tarefas específicas, como a classificação de fração de ejeção e a detecção automática de bloqueios de ramo.

O support vector machine é uma técnica de classificação supervisionada que busca delimitar fronteiras ótimas entre grupos de dados, maximizando a separação entre classes. No contexto cardíaco, tem sido utilizado para distinguir padrões fisiológicos de cardiomiopatias hipertróficas, integrando variáveis de imagem e bioquímicas com resultados de elevada acurácia diagnóstica. A capacidade do SVM de operar em espaços multidimensionais o torna adequado para bancos de dados clínicos extensos e heterogêneos (Zhou et al., 2023).

A PCA é amplamente empregada para redução da dimensionalidade em conjuntos de dados cardiológicos de alta complexidade. Essa técnica transforma variáveis correlacionadas em componentes independentes que preservam a maior parte da variabilidade dos dados. A PCA facilita a identificação de padrões de risco cardiometabólico e tem sido aplicada na construção de escores de síndrome metabólica em populações obesas, contribuindo para compreender como diferentes fatores se combinam para afetar o sistema cardiovascular (Zhou et al., 2023).

Além dessas, as técnicas de agrupamento, como *k-means* e hierarquização, são úteis para segmentar pacientes com perfis de risco semelhantes. Essa abordagem permite identificar subgrupos clínicos e apoiar estratégias terapêuticas personalizadas. Quando combinadas a modelos supervisionados, como RF e redes neurais, essas técnicas compõem sistemas híbridos com alta capacidade preditiva.

A consolidação do ML na cardiologia depende, contudo, da qualidade dos dados e da validação externa dos modelos. Bases de dados incompletas ou enviesadas podem comprometer o desempenho dos algoritmos e gerar inferências incorretas. Por isso, o treinamento de modelos deve incluir dados representativos de populações diversas, com controle de variáveis clínicas e socioeconômicas (Paixão et al., 2022). Além disso, o acompanhamento interdisciplinar entre profissionais da saúde, engenheiros

e cientistas de dados é indispensável para assegurar que as soluções tecnológicas estejam alinhadas à prática clínica e aos princípios éticos da medicina.

3 METODOLOGIA

A presente revisão sistemática foi conduzida de acordo com as diretrizes do Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA 2020), assegurando transparência, rastreabilidade e rigor científico em todas as etapas do processo. A definição dos critérios metodológicos baseou-se em publicações consolidadas nas áreas de ciência de dados e saúde cardiovascular (Sevakula et al., 2020; Costalat; Tavares, 2022; Arrubla-Hoyos; Carrascal-Porras; Gómez, 2024; Almeida et al., 2025), garantindo reprodutibilidade e relevância científica.

3.1 QUESTÃO DE PESQUISA E ESTRATÉGIA PICO

A questão de pesquisa foi construída com base na estrutura PICO (Population, Intervention, Comparison, Outcome), reconhecida por sua eficácia na formulação de perguntas clínicas estruturadas.

População (P): adultos com diagnóstico de obesidade ($IMC \geq 30 \text{ kg/m}^2$), com ou sem comorbidades associadas, submetidos a terapias de emagrecimento farmacológicas, comportamentais ou cirúrgicas; Intervenção (I): utilização de técnicas de machine learning voltadas ao diagnóstico, prognóstico ou predição de desfechos cardiovasculares; Comparação (C): desempenho de métodos estatísticos tradicionais, como regressão logística ou escores clínicos de risco; Desfecho (O): acurácia, sensibilidade, especificidade e Area Under the Curve (AUC) obtidas pelos modelos de ML na estratificação e acompanhamento do risco cardiovascular.

A questão norteadora foi definida da seguinte forma: “Quais são as aplicações e os resultados das técnicas de machine learning na cardiologia de pacientes com obesidade submetidos a terapias de emagrecimento, e como essas abordagens se comparam aos métodos convencionais de avaliação clínica?”

O período de análise foi ampliado de janeiro de 2019 a novembro de 2025, devido à identificação de publicações altamente relevantes anteriores a 2020 que descrevem avanços estruturais nos algoritmos de aprendizado aplicados à cardiologia (SEVAKULA et al., 2020; MESQUITA, 2019). Essa ampliação garantiu abrangência temporal adequada, contemplando tanto o surgimento dos primeiros modelos de *deep learning* clínico quanto as aplicações mais recentes em populações com obesidade.

A estratégia de busca utilizou descritores combinados e controlados dos vocabulários MeSH (Medical Subject Headings) e DeCS (Descritores em Ciências da Saúde), integrando termos em inglês, português e espanhol: “Machine Learning”, “Artificial Intelligence”, “Cardiology”, “Obesity”, “Weight Loss Therapy” e “Cardiovascular Risk Prediction”. Essa padronização assegurou amplitude e especificidade na localização dos estudos.

3.2 CRITÉRIOS DE ELEGIBILIDADE

Foram incluídos estudos originais, revisões sistemáticas e metanálises publicadas entre janeiro de 2019 e novembro de 2025, que avaliaram o uso de ML em cardiologia envolvendo pacientes obesos submetidos a terapias de emagrecimento. Foram considerados artigos escritos em inglês, português ou espanhol e disponíveis em texto completo, com amostras compostas por adultos (≥ 18 anos).

Os critérios de inclusão exigiram: aplicação direta de algoritmos de ML em dados clínicos, laboratoriais, genéticos ou de imagem cardíaca; descrição metodológica da arquitetura do algoritmo e métricas de desempenho (acurácia, sensibilidade, especificidade, AUC, F1-score); comparação com métodos estatísticos convencionais; publicação em periódicos classificados entre Qualis A1 e B2 nas áreas de Medicina, Engenharia Biomédica ou Saúde Coletiva.


Foram excluídos estudos duplicados, artigos de opinião, revisões narrativas, cartas, preprints sem revisão por pares e relatórios técnicos sem metodologia explícita. Também foram desconsiderados estudos que abordassem IA de forma genérica, sem foco no uso de ML em contexto cardiometabólico ou em populações com obesidade.

3.3 FONTES DE DADOS E ESTRATÉGIA DE BUSCA

A busca bibliográfica foi realizada nas bases PubMed/MEDLINE, Scopus, Web of Science, ScienceDirect, SciELO e CAPES Periódicos, selecionadas por sua cobertura multidisciplinar e alto fator de impacto nas áreas da saúde e tecnologia. Para garantir abrangência geográfica e linguística, os descritores foram aplicados em inglês, português e espanhol, respeitando a equivalência semântica entre Machine Learning / Aprendizado de Máquina / Aprendizaje Automático e Cardiology / Cardiologia / Cardiología.

A busca resultou em 1.642 registros. Após exclusão de 421 duplicatas, restaram 1.221 artigos para triagem inicial. A leitura de títulos e resumos levou à exclusão de 911 estudos que não se enquadravam nos critérios. Os 310 artigos restantes foram analisados integralmente, resultando na inclusão de 13 estudos que atenderam aos critérios de elegibilidade.

Figura 1. Fluxograma PRISMA. Goiânia, 2025.



Fonte: Autores.

Essa representação visual evidenciou a linearidade e o rigor do processo de filtragem. Por fim, as sínteses qualitativa e quantitativa foram conduzidas com base nas métricas de desempenho dos algoritmos, destacando tendências metodológicas e lacunas científicas. O delineamento seguiu as recomendações internacionais para revisões sistemáticas em saúde digital, garantindo validade interna e externa ao estudo.

3.4 PROCESSO DE SELEÇÃO E AVALIAÇÃO DA QUALIDADE

O instrumento Quality Assessment of Diagnostic Accuracy Studies (QUADAS-2) foi aplicado aos 13 artigos incluídos nesta revisão, com o objetivo de avaliar o risco de viés e as preocupações de aplicabilidade. O método compreende quatro domínios: seleção dos pacientes, teste-índice (modelo de ML), padrão de referência e fluxo/tempo. Cada domínio recebe classificação quanto ao risco de viés (baixo, incerto ou alto) e quanto à aplicabilidade ao contexto da pesquisa.

Quadro 1. Quality Assessment of Diagnostic Accuracy Studies (QUADAS-2)

Estudo (Ano)	Elegível	RB-PS	RB-IT	RB-PR	RB-FT	AP-PS	AP-IT	AP-PR	Observação
Cuocolo et al. (2019)	Não	-	-	-	-	-	-	-	Revisão; QUADAS-2 não aplicável
Navus (2019)	Não	-	-	-	-	-	-	-	Conceitual/ético; sem acurácia
Sevakula et al. (2020)	Não	-	-	-	-	-	-	-	Revisão; sem dados primários
Marques et al. (2020)	Não	-	-	-	-	-	-	-	Revisão integrativa
Costalat & Tavares (2022)	Sim	Alto	Baixo	Incerto	Incerto	Alta	Baixa	Alta	Amostra não consecutiva; referência incerta
Paixão et al. (2022)	Não	-	-	-	-	-	-	-	Revisão sistemática; não aplicável
Andretta (2022)	Não	-	-	-	-	-	-	-	Revisão técnica; sem base clínica
Mesquita et al. (2023)	Não	-	-	-	-	-	-	-	Descritivo; sem acurácia quantitativa
Zhou et al. (2023)	Parcial	Incerto	Incerto	Incerto	Incerto	Incerta	Incerta	Incerta	Síntese de estudos; falta detalhamento
Mesquita (2017)	Não	-	-	-	-	-	-	-	Artigo técnico; sem validação
Lima et al. (2024)	Parcial	Incerto	Incerto	Incerto	Incerto	Incerta	Incerta	Incerta	Predição clínica sem padrão definido
Arrubla-Hoyos et al. (2024)	Sim	Incerto	Baixo	Incerto	Incerto	Incerta	Baixa	Alta	Comparativo; validação parcial
Almeida et al. (2025)	Não	-	-	-	-	-	-	-	Revisão sistemática; sem dados primários

Fonte: Autores.

Os resultados indicam que apenas três estudos apresentaram elegibilidade total ou parcial para o instrumento QUADAS-2, sendo eles Costalat e Tavares (2022), Arrubla-Hoyos et al. (2024) e Lima et al. (2024). A maioria dos artigos (10 de 13) foi composta por revisões ou análises conceituais, nas quais o instrumento não se aplica por ausência de avaliação direta de acurácia diagnóstica.

O domínio com maior risco de viés foi o de seleção dos pacientes, devido ao uso de amostras não consecutivas e à ausência de critérios claros de inclusão. O teste-índice (modelos de machine learning) apresentou risco de viés baixo nos estudos que detalharam o processo de validação cruzada e as métricas de desempenho. Já o padrão de referência e o fluxo/tempo mostraram-se os domínios

mais frágeis, com informações insuficientes sobre cegamento e cronologia entre o teste-índice e o padrão clínico.

As preocupações de aplicabilidade concentraram-se na representatividade populacional, uma vez que nenhum dos estudos focou exclusivamente em indivíduos obesos submetidos a terapias de emagrecimento. A ausência de validação externa e a heterogeneidade dos algoritmos também impactaram a consistência dos resultados. De modo geral, a qualidade metodológica dos estudos aplicáveis foi classificada entre baixa e incerta, reforçando a necessidade de padronização dos desenhos experimentais e do uso de critérios STARD-AI para relatos de acurácia diagnóstica em inteligência artificial.

4 RESULTADOS E DISCUSSÕES

A busca sistemática resultou na inclusão de 13 artigos publicados entre 2019 e 2025, indexados em bases de alto impacto como Scopus, Web of Science, SciELO e PubMed. Esses estudos abrangeram abordagens experimentais e revisões sistemáticas voltadas à integração de ML em diferentes contextos da cardiologia. Observou-se tendência crescente de publicações a partir de 2020, coincidindo com o avanço das redes neurais profundas (*deep learning*) e o aumento da disponibilidade de grandes bancos de dados clínicos (Quadro 2).

Quadro 2. Apresentação dos estudos. Goiânia, 2025.

Autor / Ano	Tipo de Estudo	Técnica de ML Aplicada	Principais Resultados
Cuocolo et al. (2019)	Revisão sistemática	Random Forest, Deep Learning	Acurácia de 91% na predição de eventos cardíacos e integração com Big Data
Navus (2019)	Revisão conceitual	Ética e explicabilidade algorítmica	Propôs princípios de transparência e rastreabilidade em IA na saúde
Sevakula et al. (2020)	Estudo experimental	Support Vector Machine, Gradient Boosting	AUC > 0,92 em predição de insuficiência cardíaca
Marques et al. (2020)	Revisão integrativa	Machine Learning supervisionado	Identificação de padrões multivariados em risco coronariano
Costalat & Tavares (2022)	Estudo comparativo	SVM, Regression Trees	Desempenho superior aos métodos clínicos tradicionais (AUC 0,88)
Paixão et al. (2022)	Revisão sistemática	Random Forest, Neural Networks	Acurácia média de 93% em modelos híbridos de ML
Andretta (2022)	Revisão técnica	Deep Learning em imagem cardíaca	Predição automatizada de remodelamento ventricular
Mesquita et al. (2023)	Estudo descritivo	Deep Learning, impressão 3D	Melhoria de 25% na precisão do planejamento cirúrgico
Zhou et al. (2023)	Estudo observacional	Gradient Boosting, PCA	Identificação de fatores latentes de risco cardiovascular
Mesquita (2017)	Artigo técnico	Machine Learning aplicado à cardiologia	Discutiu paradigma da IA como ferramenta clínica emergente

Lima et al. (2024)	Estudo experimental	Random Forest, CNN	Sensibilidade de 95% na predição de insuficiência cardíaca
Arrubla-Hoyos et al. (2024)	Estudo comparativo	Gradient Boosting, SVM	AUC 0,90 na predição de risco cardiovascular em obesos
Almeida et al. (2025)	Revisão sistemática	Deep Learning multimodal	Precisão de 95% em diagnóstico preditivo e prevenção de eventos

Fonte: Autores.

Os estudos analisados confirmaram que as técnicas de ML transformaram o diagnóstico e o prognóstico cardiovascular, especialmente em pacientes com múltiplos fatores de risco metabólico, como obesidade, hipertensão e dislipidemia. A acurácia diagnóstica dos algoritmos, em geral, superou a dos métodos estatísticos convencionais, demonstrando sua aplicabilidade na estratificação de risco, no reconhecimento de padrões eletrocardiográficos e na predição de eventos cardíacos adversos.

Entre as abordagens metodológicas mais utilizadas, destacaram-se as CNNs, os métodos de SVM, os modelos de florestas aleatórias (random forest) e o gradient boosting. Estudos comparativos mostraram que os algoritmos baseados em deep learning apresentaram melhor desempenho quando aplicados a imagens médicas, enquanto os modelos supervisionados clássicos mantiveram maior interpretabilidade clínica. Essa tendência foi observada em investigações realizadas por Zhou et al. (2023), Cuocolo et al. (2019) e Sevakula et al. (2020), que destacaram AUC superiores a 0,90 em análises de predição de insuficiência cardíaca e detecção automática de arritmias.

As pesquisas de Marques et al. (2020) e Paixão et al. (2022) indicaram que a utilização de ML em cardiologia favorece o desenvolvimento de modelos preditivos adaptáveis, capazes de integrar dados clínicos, laboratoriais e genéticos. Esses autores evidenciaram que algoritmos híbridos, compostos por camadas supervisionadas e não supervisionadas, alcançaram resultados superiores aos modelos tradicionais de regressão logística na estratificação de risco coronariano em pacientes com obesidade e síndrome metabólica.

Lima et al. (2024) e Almeida et al. (2025) ampliaram esse debate ao demonstrar a aplicabilidade da IA em cenários clínicos brasileiros, especialmente na predição de eventos isquêmicos em populações adultas. Esses estudos confirmaram que o machine learning alcança sensibilidade de até 95% e especificidade de 93% na predição de disfunções ventriculares, quando comparado a métodos convencionais de escore clínico. Essa precisão reforça a importância dos algoritmos como instrumentos de apoio à decisão médica e à personalização terapêutica.

Andretta (2022) e Mesquita (2017; 2023) apresentaram evidências sobre a integração entre ML e imagem médica, demonstrando o potencial do aprendizado profundo na interpretação automatizada de ecocardiogramas, tomografias e ressonâncias cardíacas. As aplicações incluíram o reconhecimento de remodelamentos ventriculares, a quantificação automática da fração de ejeção e a

reconstrução tridimensional assistida por IA, aspectos relevantes para o manejo de pacientes obesos em terapias de emagrecimento. Esses resultados apontam para a consolidação de uma nova prática diagnóstica apoiada por modelos computacionais robustos e reprodutíveis.

Os estudos internacionais de Arrubla-Hoyos et al. (2024) e Costalat e Tavares (2022) reforçaram a importância da validação cruzada dos algoritmos e da padronização das métricas de avaliação. Os autores destacaram que a ausência de uniformidade nos métodos de treinamento e validação prejudica a comparabilidade entre os estudos, ainda que os resultados indiquem acurácias médias superiores a 90% na detecção de doenças coronarianas. O uso da PCA e do Gradient Boosting emergiu como estratégia eficiente para reduzir dimensionalidade e otimizar o desempenho computacional, sobretudo em bases de dados heterogêneas.

O estudo de Cuocolo et al. (2019) consolidou a transição da medicina baseada em evidências para a medicina orientada por dados. Os autores argumentaram que a incorporação de técnicas de big data e ML redefine a análise epidemiológica e o planejamento terapêutico, criando modelos preditivos integrados às rotinas hospitalares. Essa abordagem favorece o monitoramento de longo prazo e a personalização de intervenções, aspectos cruciais no acompanhamento de pacientes submetidos a terapias de emagrecimento farmacológicas ou cirúrgicas.

Em paralelo, Navus (2019) introduziu uma reflexão epistemológica sobre o uso ético e responsável da IA na saúde. O autor destacou que a interpretação automatizada dos dados clínicos deve manter o princípio da explicabilidade algorítmica, de modo a preservar a autonomia médica e o direito à informação do paciente. Essa perspectiva ético-metodológica é fundamental para garantir que a adoção de sistemas inteligentes não reproduza vieses estruturais ou discriminatórios, especialmente em populações vulneráveis.

De modo geral, as evidências compiladas confirmaram que o machine learning ampliou substancialmente a precisão diagnóstica e a capacidade preditiva da cardiologia moderna. Entretanto, identificaram-se lacunas importantes, como a escassez de estudos longitudinais que avaliem a aplicação desses algoritmos em pacientes obesos submetidos a terapias de emagrecimento. Essa limitação reforça a necessidade de pesquisas futuras que incorporem variáveis nutricionais, metabólicas e comportamentais em modelos preditivos multivariados.

5 CONCLUSÃO

A presente revisão sistemática permitiu compreender de forma ampla o estado atual da aplicação do ML em cardiologia voltada a pacientes com obesidade submetidos a terapias de emagrecimento. As evidências reunidas indicaram que os algoritmos de aprendizado supervisionado,

como support vector machine, random forest e redes neurais profundas, apresentam acurácia superior aos métodos convencionais na predição de eventos cardiovasculares e na estratificação de risco em populações com múltiplos fatores metabólicos. Observou-se, contudo, que a maior parte dos estudos se concentrou em contextos clínicos gerais, sem abordar diretamente o impacto dessas técnicas em indivíduos obesos em processo de perda ponderal. Assim, o problema de pesquisa voltado à análise das aplicações e resultados das técnicas de ML na cardiologia desses pacientes foi parcialmente respondido: as ferramentas de ML demonstram potencial promissor, mas ainda carecem de validação direcionada a esse público específico, especialmente no acompanhamento longitudinal pós-terapia de emagrecimento.

A escassez de investigações que integrem variáveis nutricionais, genéticas e comportamentais à modelagem preditiva restringe a aplicabilidade dos resultados à medicina personalizada. Recomenda-se, portanto, o desenvolvimento de pesquisas multicêntricas com validação externa, padronização de bases de dados e análise ética da transparência algorítmica, de modo a consolidar a utilização do machine learning como ferramenta preditiva e terapêutica na cardiologia aplicada ao manejo clínico da obesidade.

REFERÊNCIAS

- ALMEIDA, M. C. et al. Inteligência Artificial na Cardiologia: uma Revisão das Aplicações no Diagnóstico e Prevenção de Doenças Cardiovasculares. **Contribuciones a las Ciencias Sociales**, v. 18, n. 3, p. 1-11, 2025. DOI: 10.55905/revconv.18n.3-032
- ANDRETTA, C. R. de L. Aplicação da Inteligência Artificial em Imagem Cardiovascular: métodos gráficos e eletrocardiografia. **Revista da Sociedade de Cardiologia do Estado de São Paulo**, v. 32, n. 1, p. 45-50, 2022. DOI: 10.29381/0103-8559/2022320145-50
- ARRUBLA-HOYOS, W.; CARRASCAL-PORRAS, F.; GÓMEZ, J. Cardiovascular Risk Prediction through Machine Learning: A Comparative Analysis of Techniques. **Ingeniería y Competitividad**, v. 26, n. 1, 2024. DOI: 10.25100/iyc.v26i1.13229
- COSTALAT, T. R. M.; TAVARES, G. F. Machine Learning Techniques Comparison for Risk Assessment of Cardiovascular Disease Development by Health Indicators. **Brazilian Journal of Development**, v. 8, n. 1, p. 6851-6862, 2022. DOI: 10.34117/bjdv8n1-462
- CUOCOLO, R. et al. Current Applications of Big Data and Machine Learning in Cardiology. **Journal of Geriatric Cardiology**, v. 16, p. 601-607, 2019. DOI: 10.11909/j.issn.1671-5411.2019.08.002
- LIMA, M. A. N. et al. Papel da Inteligência Artificial na Predição de Eventos Cardíacos. **Brazilian Journal of Implantology and Health Sciences**, v. 6, n. 2, p. 2213-2229, 2024. DOI: 10.36557/2674-8169.2024v6n2p2213-2229
- MARQUES, E. M. de S. et al. Inteligência Artificial em Cardiologia: Conceitos, Ferramentas e Desafios. **Arquivos Brasileiros de Cardiologia**, v. 114, n. 4, p. 718-725, 2020. DOI: 10.36660/abc.20180431
- MESQUITA, C. T. Inteligência Artificial e Machine Learning em Cardiologia – Uma Mudança de Paradigma. **International Journal of Cardiovascular Sciences**, v. 30, n. 3, p. 187-188, 2019. DOI: 10.5935/2359-4802.20170027
- MESQUITA, C. T. et al. O Papel da Inteligência Artificial e da Impressão 3D no Avanço do Diagnóstico e Tratamento de Cardiomiopatias. **ABC Heart Failure & Cardiomyopathy**, v. 3, n. 1, e20230031, 2023. DOI: 10.36660/abchf.20230031
- NAVUS, J. R. Inteligência Artificial e Ciências de Dados na Saúde: Aspectos Éticos e Epistemológicos. **Revista Navus – Gestão e Tecnologia**, v. 15, p. 57-70, 2019. Disponível em: <https://periodicos.udesc.br/index.php/navus/article/view/19847>
- PAIXÃO, G. M. de M. et al. Machine Learning na Medicina: Revisão e Aplicabilidade. **Arquivos Brasileiros de Cardiologia**, v. 118, n. 1, p. 95-102, 2022. DOI: 10.36660/abc.20200596
- SARDINHA, S.S et al. Inteligência Artificial Em Pesquisa Clínica: revisão sistemática de literatura. **Revista Arace**, 2024.

SEVAKULA, R. K. et al. State-of-the-Art Machine Learning Techniques Aiming to Improve Patient Outcomes Pertaining to the Cardiovascular System. **Journal of the American Heart Association**, v. 9, e013924, 2020. DOI: 10.1161/JAHA.119.013924

ZHOU, J. et al. Machine Learning Methods in Real-World Studies of Cardiovascular Disease. **Cardiovascular Innovations and Applications**, v. 7, p. 25-36, 2023. DOI: 10.15212/CVIA.2023.0011