



ISSN: 2595-1661

ARTIGO

Listas de conteúdos disponíveis em [Portal de Periódicos CAPES](#)

Revista JRG de Estudos Acadêmicos

Página da revista:

<https://revistajrg.com/index.php/jrg>

ISSN: 2595-1661

Revista JRG de
Estudos Acadêmicos

Uso de inteligência artificial para análise da VFC como ferramenta de predição de risco cardiovascular, uma revisão integrativa

Use of artificial intelligence for heart rate variability analysis as a tool for cardiovascular risk prediction: an integrative review

DOI: 10.55892/jrg.v9i20.3406

ARK: 57118/JRG.v9i20.3406

Recebido: 23/05/2026 | Aceito: 25/05/2026 | Publicado on-line: 26/05/2026

João Emanuel Souza Prado

<https://orcid.org/0009-0005-3130-7587>

<https://lattes.cnpq.br/6259164858919856>

Universidade Tiradentes, SE, Brasil

E-mail: joao.esouza@souunit.com.br

Luana Godinho Maynard

<https://orcid.org/0000-0003-0950-4742>

<http://lattes.cnpq.br/6070042290431615>

Universidade Tiradentes, SE, Brasil

E-mail: lgmayfisio@gmail.com



Resumo

A variabilidade da frequência cardíaca (VFC) representa um importante marcador da modulação autonômica cardíaca e tem sido amplamente utilizada na avaliação do risco cardiovascular. Com o avanço da inteligência artificial (IA), diferentes algoritmos de machine learning e deep learning passaram a ser aplicados na análise de sinais fisiológicos, permitindo a identificação de padrões complexos associados a eventos cardiovasculares. Nesse contexto, o presente estudo teve como objetivo compreender o uso da inteligência artificial aplicada à análise da VFC como ferramenta de predição do risco cardiovascular. Trata-se de uma revisão integrativa da literatura, conduzida a partir de buscas nas bases de dados PubMed/MEDLINE, Scopus, Web of Science, Embase e Google Scholar. Foram incluídos estudos publicados que abordassem a aplicação de modelos de inteligência artificial associados à VFC na predição, classificação ou monitorização de desfechos cardiovasculares. Após as etapas de triagem, leitura completa e aplicação dos critérios de elegibilidade, 21 estudos foram incluídos na revisão. Os resultados demonstraram que os modelos baseados em machine learning apresentaram desempenho promissor na predição de eventos cardiovasculares, com valores de AUC variando entre 0,75 e 0,98, além de elevadas taxas de acurácia diagnóstica. Os principais algoritmos utilizados incluíram support vector machine (SVM), redes neurais artificiais, boosting e modelos de deep learning. Entre os desfechos avaliados destacaram-se infarto agudo do miocárdio, insuficiência cardíaca, mortalidade cardiovascular e parada cardíaca intra-hospitalar. Entretanto, observou-se significativa heterogeneidade metodológica entre os estudos, especialmente quanto ao tamanho amostral, parâmetros de VFC analisados e estratégias de treinamento dos algoritmos. Conclui-se que a inteligência artificial aplicada à análise da variabilidade da frequência cardíaca apresenta potencial relevante para auxiliar na predição de risco cardiovascular e na estratificação clínica de



pacientes. Contudo, ainda são necessários estudos multicêntricos, com validação externa robusta e maior padronização metodológica, a fim de ampliar a aplicabilidade clínica dessas ferramentas.

Palavras-chave: variabilidade da frequência cardíaca; inteligência artificial; machine learning; risco cardiovascular; predição cardiovascular.

Abstract

Heart rate variability (HRV) is an important marker of cardiac autonomic modulation and has been widely used in cardiovascular risk assessment. With the advancement of artificial intelligence (AI), different machine learning and deep learning algorithms have been applied to physiological signal analysis, enabling the identification of complex patterns associated with cardiovascular events. In this context, the present study aimed to understand the use of artificial intelligence applied to HRV analysis as a tool for cardiovascular risk prediction. This study is an integrative literature review conducted through searches in the PubMed/MEDLINE, Scopus, Web of Science, Embase, and Google Scholar databases. Studies addressing the application of artificial intelligence models associated with HRV in the prediction, classification, or monitoring of cardiovascular outcomes were included. After screening, full-text reading, and eligibility assessment, 21 studies were included in the review. The results demonstrated that machine learning-based models showed promising performance in predicting cardiovascular events, with AUC values ranging from 0.75 to 0.98, in addition to high diagnostic accuracy rates. The main algorithms used included support vector machine (SVM), artificial neural networks, boosting methods, and deep learning models. The evaluated outcomes included acute myocardial infarction, heart failure, cardiovascular mortality, and in-hospital cardiac arrest. However, significant methodological heterogeneity was observed among the studies, especially regarding sample size, HRV parameters analyzed, and algorithm training strategies. It is concluded that artificial intelligence applied to heart rate variability analysis presents relevant potential to assist in cardiovascular risk prediction and clinical patient stratification. However, multicenter studies with robust external validation and greater methodological standardization are still necessary to improve the clinical applicability of these tools.

Keywords: heart rate variability; artificial intelligence; machine learning; cardiovascular risk; cardiovascular prediction.

1. Introdução

As doenças cardiovasculares constituem o principal desafio para os sistemas de saúde, o impacto decorre de representar a maior causa de morbimortalidade no mundo, sendo responsáveis por elevados números de óbitos anuais. Nesse contexto, a identificação precoce de indivíduos com maior risco de eventos cardiovasculares torna-se imprescindível para a implementação de estratégias preventivas eficazes e redução da mortalidade (JARCZOK et al., 2022; KHAN et al., 2025).

Ademais, a variabilidade da frequência cardíaca (VFC) tem se destacado como um importante marcador fisiológico na avaliação do sistema nervoso autônomo, refletindo a interação entre os sistemas simpático e parassimpático na regulação cardíaca. A VFC é obtida a partir das variações dos intervalos entre batimentos cardíacos consecutivos, calculado a medida pelos intervalos entre os picos do eletrocardiograma (intervalos R-R), sendo utilizada na prática clínica como indicador indireto das variações da homeostase



cardíaca. Estudos demonstram que a redução da VFC está associada a maior risco de eventos adversos, incluindo infarto agudo do miocárdio prematuro e morte súbita (MELILLO et al., 2015; JARCZOK et al., 2022). Além disso, o VFC, também, representa um marcador não invasivo e de fácil execução na prática clínica para avaliação do tônus autonômico, assim quanto maior o VFC reflete em maior adaptabilidade do do SNA (KHAN et al., 2025).

Apesar de sua relevância clínica, os métodos tradicionais de análise da VFC, baseados em estatística clássica, apresentam limitações na identificação de padrões complexos e não lineares presentes nos sinais fisiológicos. Essa limitação pode comprometer a precisão na estratificação de risco cardiovascular, especialmente em cenários clínicos que envolvem grande variabilidade de dados e múltiplos fatores associados (FAUST et al., 2022; NAYAK et al., 2023).

Com o avanço da tecnologia, a inteligência artificial (IA) tem demonstrado amplamente útil para a área da saúde, destacando-se como uma ferramenta proeminente na análise de dados grandes e complexos. Técnicas como machine learning e deep learning permitem a identificação de padrões ocultos em larga escala de informações, contribuindo para o aprimoramento de modelos preditivos e garantia de uma decisão clínica assertiva (ZHANG et al., 2023; SANJANA et al., 2020).

Nesse contexto, o machine learning é definido como um subcampo da inteligência artificial que possibilita aos sistemas computacionais o aprendizado de padrões a partir de dados e, com base nesses padrões, realizar previsões ou classificações. Dessa forma, o deep learning representa uma abordagem mais elaborada dentro do machine learning, caracterizada pelo uso de deep neural networks, compostas por múltiplas camadas de processamento. Essas estruturas caracterizam-se pela identificação automatizada de dados relevantes, tornando os modelos mais eficientes na análise de problemas complexos.

Dessa maneira, diferentes modelos de machine learning têm sido empregados na análise da variabilidade da frequência cardíaca, destacando-se algoritmos como support vector machine (SVM) e random forest. Essas abordagens possibilitam o reconhecimento de padrões complexos em sinais fisiológicos, contribuindo para o aprimoramento da predição de eventos cardiovasculares e para o suporte à tomada de decisão clínica. Também, modelos baseados em deep learning têm demonstrado potencial na integração de múltiplas variáveis fisiológicas e eletrocardiográficas, favorecendo análises mais abrangentes e automatizadas.

Além disso, a IA aplicada na análise da VFC tem demonstrado resultados prósperos na predição de risco cardiovascular. Desse modo, estudos atuais indicam que modelos baseados em machine learning apresentam elevada acurácia na identificação de cardiopatias e na previsão de eventos adversos, superando, em alguns casos, os métodos tradicionais de análise (AGLIARI et al., 2020; CHUMACHENKO et al., 2022). Além disso, a utilização de diversos modelos de algoritmos, como deep neural networks, support vector machine (SVM) e modelos híbridos, sendo observado com sucesso padrões associados ao infarto do miocárdio, insuficiência cardíaca e morte súbita (SONG et al., 2014; MARTINEZ-ALANIS et al., 2020; LEE et al., 2023., LIU et al., 2016).

A aplicabilidade da IA associada a VFC tem sido pesquisa em diversos contextos clínicos, incluindo a predição de risco em pacientes com doença arterial coronariana, insuficiência cardíaca e em ambientes de terapia intensiva. Esses avanços demonstram o potencial dessa abordagem na melhoria da avaliação clínica e no tratamento individualizado dos pacientes (KUMAR et al., 2022., VAN ES et al., 2024., LEE et al., 2023).



Portanto, torna-se fundamental a análise crítica das evidências disponíveis acerca da aplicação da inteligência artificial na avaliação da variabilidade da frequência cardíaca. Embora a literatura disponível possua uma divergência metodológica, o presente estudo tem como objetivo compreender o uso da inteligência artificial na análise da VFC como ferramenta de predição do risco cardiovascular, considerando sua acurácia diagnóstica, aplicabilidade clínica e limitações.

2. Justificativa

Destaca-se que o fácil acesso ao monitoramento cardíaco permitiu a obtenção em maior escala de sinais fisiológicos, podendo ser observado por monitores hospitalares, eletrocardiogramas ou smartwatches, como a variabilidade da frequência cardíaca (VFC), demonstra-se promissora na avaliação do risco cardiovascular. No entanto, a utilização desses dados na prática clínica ainda enfrenta limitações relacionadas à capacidade de interpretação e integração das informações geradas, o que pode reduzir seu potencial aplicado na tomada de decisão.

Tendo em vista disso, o uso de técnicas de inteligência artificial constituem um artifício relevante para lidar com a complexidade desses dados. Estudos incluídos nesta revisão demonstram que modelos baseados em machine learning são capazes de analisar a VFC de forma mais minuciosa, identificando padrões que não são facilmente detectados por métodos tradicionais (LEE et al., 2023). Além disso, abordagens recentes sugerem que a combinação de diferentes variáveis fisiológicas pode aumentar ainda mais a capacidade preditiva desses modelos (GONZÁLEZ et al., 2024).

Contudo, embora tenham sido observados avanços, há heterogeneidade na metodologia dos artigos já disponíveis, variando quanto aos algoritmos utilizados, características das populações estudadas e métodos de extração da VFC. Nesse sentido, a pluralidade metodológica interfere na padronização e acurácia dos resultados e limita a aplicação ampla dessas tecnologias na prática clínica (ZHANG et al., 2023; NAYAK et al., 2023).

Somado a isso, diversos estudos não focam na aplicação clínica, custo-efetividade e aceitação por profissionais de saúde, mas no desempenho técnico dos modelos e algoritmos propostos. Dessa maneira, evidencia-se a necessidade de uma abordagem mais abrangente, que não apenas avalie a acurácia dos modelos, mas também sua viabilidade de implementação no contexto real da assistência à saúde.

Dessarte, esta revisão justifica-se pela necessidade de sistematizar o conhecimento disponível sobre o uso da inteligência artificial na análise da VFC para predição do risco cardiovascular. Ao reunir e comparar os achados da literatura, o estudo tem o intuito de esclarecer a função dessas tecnologias, identificar limitações existentes e orientar futuras pesquisas, favorecendo sua aplicação mais consistente na prática clínica.

3. Metodologia

Esta revisão integrativa da literatura analisa o uso da inteligência artificial para avaliar a variabilidade da frequência cardíaca (VFC) como ferramenta de predição do risco cardiovascular. A pergunta de pesquisa foi feita usando a estratégia PICO. Ela considera: a população (adultos que têm monitoramento da frequência cardíaca), a intervenção (algoritmos de inteligência artificial aplicados à VFC), a comparação (métodos tradicionais de análise estatística da VFC) e os desfechos (acurácia diagnóstica, risco cardiovascular e mortalidade).

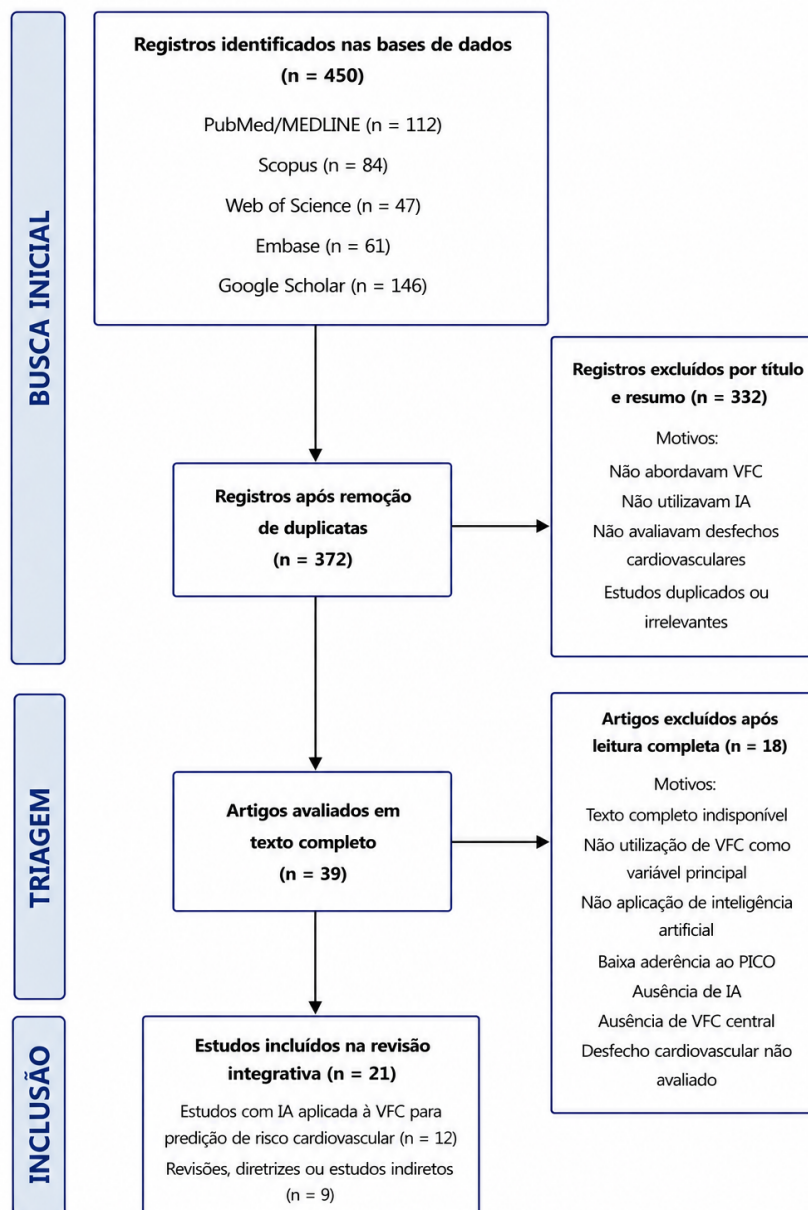
Além disso, a pesquisa foi feita usando bases de dados PubMed/MEDLINE, Scopus, Web of Science, Embase e Google Scholar no mês de abril de 2026. Utilizando os



descritores “Heart Rate Variability”, “Artificial Intelligence”, “Machine Learning”, “Risk Assessment” e “Cardiovascular Diseases” e combinando o descritor “Heart Rate Variability” com o descritor “Artificial Intelligence”, com o descritor “Machine Learning”, com o descritor “Risk Assessment” e com o descritor “Cardiovascular Diseases” usando os operadores booleanos AND e OR. Também, usando termos livres e as variações semânticas.

Nesse sentido, foram identificados, inicialmente, 450 registros nas bases de dados. Removemos as duplicidades e ficaram 372 artigos para serem considerados a inclusão. Sendo assim, foram selecionados os estudos em duas etapas, conforme método PRISMA, analisando os títulos e os resumos, depois o texto completo dos artigos que eram elegíveis.

Figura 1 – Fluxograma do processo de seleção dos estudos incluídos na revisão integrativa.



Fonte: Elaborado pelo autor (2026).



Ademais, para definir os critérios de inclusão, foram considerados os estudos que usaram inteligência artificial para analisar a variabilidade da frequência cardíaca e que tinham como objetivo prever risco cardiovascular. Somado a isso, diferentes tipos de estudo foram ponderados, como estudos observacionais, estudos experimentais e revisões relevantes. Desse modo, os artigos que estavam em inglês, que tinham o texto completo disponível e que mostravam uma relação direta com o tema proposto, foram incluídos.

Posteriormente, os estudos duplicados e os artigos que não tratam diretamente da aplicação de inteligência artificial na VFC foram desconsiderados. Também, os estudos sem desfechos cardiovasculares relevantes, dados incompletos ou que não permitem uma conclusão adequada foram excluídos. Por fim, foram removidas as revisões com escopo semelhante ao nosso estudo, para evitar redundância.

Ao final do processo de triagem, sobraram 39 artigos para leitura completa. Destes 39 artigos, 21 atenderam aos critérios de elegibilidade e 17 comporão a tabela de resultado.

Vale destacar que a extração dos dados foi feita de forma padrão. Dessa forma, na extração dos dados incluem informações como o autor, o ano de publicação, o tipo de estudo, os detalhes da amostra, o algoritmo de IA usado, as variáveis de VFC analisadas e os resultados principais. Em seguida, os dados obtidos foram organizados em uma planilha para facilitar a análise e a comparação entre os estudos.

A avaliação da qualidade metodológica dos estudos foi feita de forma descritiva, considerando o delineamento do estudo, para a clareza metodológica, para o tamanho da amostra e para a relevância dos desfechos. Como os estudos incluídos eram muito diferentes entre si, não seria possível realizar uma metanálise. Em vez disso, usamos uma síntese qualitativa dos resultados.

4. Resultados

A busca nas bases de dados resultou em 450 registros, dos quais 372 permaneceram após a remoção de duplicatas. Após a etapa de triagem e leitura dos textos completos, 21 estudos foram incluídos na revisão, sendo 11 classificados como principais, 5 complementares e 5 utilizados para fundamentação teórica. Nesse sentido, os estudos principais abordaram diretamente a aplicação de inteligência artificial associada à variabilidade da frequência cardíaca (VFC) para predição de risco cardiovascular, diagnóstico ou estratificação clínica.

A Tabela 1 apresenta a síntese dos estudos principais e complementares incluídos na análise, contemplando os modelos de inteligência artificial utilizados, desfechos avaliados, amostras e principais resultados numéricos encontrados.



Tabela 1 – Características metodológicas e principais resultados dos estudos incluídos sobre inteligência artificial aplicada à variabilidade da frequência cardíaca na predição do risco cardiovascular.

Nº	Autor/Ano	Modelo IA	Desfecho	Resultado Principal	Amostra	Resultado Numérico	Status no TCC
1	Agliari et al., 2020	ML / Neural network	Detecção de cardiopatias	Alta acurácia na classificação de patologias cardíacas	2829 pacientes	≈80-85%	Principal
2	Chumachenko et al., 2022	Diferentes modelos de ML	IAM	Classificação de pacientes com alta precisão	13.480 registros	≈71,105% - 97,774%	Principal
3	Brinza et al., 2024	Não utiliza IA	Mortalidade/MACE	Evidência clínica robusta da VFC como preditor	104 pacientes	AUC 0,853 e 0,901	Fundamentação teórica
4	Song et al., 2014	SVM	Mortalidade pós-IAM	Modelo superior aos métodos tradicionais	208 pacientes	AUC: 0,8902 / Sens: 91,67%	Principal
6	Silva-Filho et al., 2021	SVM / ML	IAM	Predição altamente precisa com VFC	218 pacientes	AUC: 0,97 / Acurácia: 96%	Principal
7	Zhang et al., 2023	ML + Signal Processing	Inferência VFC	Modelo com alta precisão	1 participante (estudo longitudinal)	Erro: 3,5%-25,7%	Principal
8	Shah et al., 2022	Machine Learning	Disautonomia pós-COVID	Classificação de pacientes	212 pacientes	AUC: 89,3% / Acurácia: 89%	Principal
9	van Es et al., 2024	ML	Insuficiência cardíaca	Predição com VFC	20 pacientes	R: 0,86 (HR) / RMSE: 10,1	Complementar
10	Melillo et al., 2015	ML/ SVM	Eventos CV	Predição de risco em hipertensos	139 pacientes	AUC: 0,888 / Acurácia: 85,7%	Principal
11	Lee et al., 2023	Machine learning	Parada cardíaca intra-hospitalar	Predição com VFC	4821pacientes	AUC: 0,881 / Acurácia: ~80%	Principal



12	Martinez-Alanis et al., 2020	SVM	Morte súbita / arritmia	Predição com VFC + heartprint	78 pacientes (treino) + 13 pacientes (teste)	AUC: 0,80–0,86 (treino) / 0,68 (teste)	Complementar
13	Kumar et al., 2022	ML/SVM	DAC/IAM	Classificação com VFC	70 pacientes	Acurácia: 99–100%	Complementar
14	Liu et al., 2016	ML	Mortalidade CV	Predição com VFC (beatquency)	2302 pacientes	AUC: 0,753 / HR: 2,91	Principal
15	Wang et al., 2024	ML	Classificação de doenças cardíacas	Classificação de doenças cardíacas com alta acurácia	18885 pacientes	Acurácia: 95,1% (binário) / 84,8% (5 classes)	Complementar
16	González et al., 2024	Deep learning/ ML	Risco de insuficiência cardíaca	Predição de risco	21891 pacientes	C-index: 0,8537 / AUC: 0,8688	Principal
17	Tasmurzeyev et al., 2025	ML	Diagnóstico de cardiopatia isquêmica	Diagnóstico com alta acurácia	350 pacientes	AUC: 0,98 / Acc: 90,82% / Sens: 88% / Esp: 100% n=500 (com dados sintéticos)	Principal

Conforme apresentado na Tabela 1, os estudos demonstraram desempenho variável entre os modelos de inteligência artificial, com destaque para algoritmos baseados em machine learning aplicados à análise da VFC.

Os estudos analisados apresentaram ampla heterogeneidade metodológica, tanto em relação aos algoritmos empregados quanto às populações avaliadas e desfechos clínicos investigados. Observou-se predomínio de modelos baseados em machine learning tradicional, especialmente support vector machine (SVM), random forest e classificadores híbridos, enquanto estudos mais recentes incorporaram arquiteturas de deep learning e integração multimodal de sinais fisiológicos.

Entre os estudos incluídos, Agliari et al. (2020) avaliaram 2829 pacientes e demonstraram acurácia aproximada entre 80% e 85% na classificação de patologias cardíacas utilizando modelos de machine learning associados à VFC. De forma semelhante, Silva-Filho et al. (2021), em uma amostra de 218 pacientes, obtiveram AUC de 0,97 e acurácia de 96% na predição de infarto agudo do miocárdio, evidenciando elevado desempenho no diagnóstico dos modelos aplicados.

Resultados relevantes também foram observados por Song et al. (2014), que utilizaram SVM para avaliação de mortalidade pós-infarto agudo do miocárdio, alcançando AUC de 0,8902 e sensibilidade de 91,67%, desempenho superior aos métodos estatísticos tradicionais utilizados como comparação. Esses achados reforçam a capacidade da inteligência artificial em identificar padrões complexos nos sinais de VFC associados à disfunção autonômica cardiovascular.

No estudo de Melillo et al. (2015), modelos híbridos de machine learning e SVM apresentaram AUC de 0,888 na predição de eventos cardiovasculares, com acurácia de 85,7%, corroborando o potencial da VFC como marcador não invasivo de risco



cardiovascular. De maneira semelhante, Lee et al. (2023), em uma das maiores amostras incluídas nesta revisão (4821 pacientes), obtiveram AUC de 0,881 na predição de parada cardíaca intra-hospitalar utilizando algoritmos de machine learning em tempo real.

Liu et al. (2016), utilizando 2302 pacientes, observaram AUC de 0,753 e hazard ratio de 2,91 para mortalidade cardiovascular, demonstrando associação significativa entre alterações da VFC e aumento do risco de eventos adversos. Embora o desempenho tenha sido inferior aos modelos mais recentes, o estudo apresentou importante robustez clínica devido ao delineamento multicêntrico e à validação externa.

Somado a isso, o estudo de maior dimensão amostral, González et al. (2024) avaliaram 21.891 indivíduos e identificaram C-index de 0,8537 associado à predição de insuficiência cardíaca, demonstrando elevada capacidade discriminativa dos modelos multimodais integrando ECG, VFC e deep learning. Esse achado sugere que a combinação de múltiplas variáveis fisiológicas pode aumentar significativamente a capacidade preditiva dos algoritmos.

Por outro lado, alguns estudos apresentaram limitações metodológicas importantes. Zhang et al. (2023), apesar de demonstrarem baixa taxa de erro na inferência de VFC (3,5%–25,7%), utilizaram apenas um participante em modelo experimental longitudinal, limitando a generalização clínica dos resultados. De maneira semelhante, Tasmurzayev et al. (2025) apresentaram elevada acurácia diagnóstica (90,82%) e AUC de 0,98 na detecção de cardiopatia isquêmica, porém parte da amostra foi composta por dados sintéticos, o que reduz a robustez externa dos achados.

Além disso, observou-se importante heterogeneidade entre os estudos quanto aos métodos de extração da VFC, duração dos registros fisiológicos, variáveis analisadas e estratégias de treinamento dos algoritmos. Essa variabilidade metodológica dificulta comparações diretas entre os resultados e limita a padronização clínica das ferramentas propostas.

Outro aspecto relevante identificado foi a predominância de estudos focados no desempenho técnico dos modelos, com menor ênfase em fatores relacionados à aplicabilidade clínica, custo-efetividade e implementação em cenários reais de assistência. Embora diversos estudos tenham apresentado métricas elevadas de acurácia e AUC, poucos avaliaram validação multicêntrica, reprodutibilidade externa ou impacto clínico longitudinal.

De forma geral, os achados desta revisão indicam que a inteligência artificial aplicada à análise da variabilidade da frequência cardíaca apresenta potencial promissor para predição de risco cardiovascular, especialmente na identificação precoce de indivíduos com maior probabilidade de eventos adversos. Entretanto, a consolidação dessas ferramentas na prática clínica ainda depende da realização de estudos com maior padronização metodológica, validação externa robusta e avaliação da aplicabilidade em populações heterogêneas.

5. Discussão

Os achados desta revisão demonstram que a aplicação da inteligência artificial associada à variabilidade da frequência cardíaca (VFC) apresenta resultados promissores na predição de risco cardiovascular, especialmente em cenários relacionados à identificação precoce de eventos adversos, estratificação prognóstica e suporte diagnóstico. De modo geral, os estudos analisados evidenciaram desempenho superior ou comparável aos métodos estatísticos tradicionais, principalmente quando utilizados algoritmos de machine learning capazes de processar grande volume de variáveis fisiológicas simultaneamente.



Entre os principais resultados observados, destacam-se os estudos que apresentaram elevados valores de AUC e acurácia diagnóstica. Silva-Filho et al. (2021) obtiveram AUC de 0,97 e acurácia de 96% na identificação de infarto agudo do miocárdio, enquanto Tasmurzayev et al. (2025) alcançaram AUC de 0,98 na detecção de cardiopatia isquêmica utilizando modelos de aprendizado de máquina associados à VFC. Resultados semelhantes também foram observados por Song et al. (2014), que demonstraram sensibilidade de 91,67% na predição de mortalidade pós-infarto utilizando support vector machine (SVM). Esses achados sugerem elevada capacidade discriminativa dos algoritmos na identificação de padrões autonômicos associados à disfunção cardiovascular.

Além disso, estudos com amostras maiores reforçaram a aplicabilidade clínica dessas ferramentas. González et al. (2024), em uma coorte com 21.891 indivíduos, identificaram C-index de 0,8537 para predição de insuficiência cardíaca por meio de modelos multimodal integrando VFC e sinais eletrocardiográficos. De forma semelhante, Lee et al. (2023), avaliando 4821 pacientes, observaram AUC de 0,881 na predição de parada cardíaca intra-hospitalar. A presença de grandes amostras e acompanhamento longitudinal nesses estudos aumenta a robustez metodológica e fortalece o potencial de generalização clínica dos modelos propostos.

Outro aspecto relevante identificado nesta revisão refere-se à diversidade dos algoritmos empregados. Modelos baseados em SVM, redes neurais artificiais, boosting, classificadores híbridos e deep learning apresentaram desempenho satisfatório em diferentes contextos clínicos. Entretanto, observou-se que não existe consenso sobre qual algoritmo apresenta melhor desempenho universal, uma vez que os resultados variaram conforme o tipo de população, qualidade dos sinais fisiológicos e desfechos avaliados.

Observou-se predominância de modelos baseados em support vector machine (SVM), random forest e redes neurais artificiais entre os estudos incluídos. De modo geral, esses algoritmos apresentaram desempenho satisfatório na identificação de padrões relacionados à variabilidade da frequência cardíaca e na predição de eventos cardiovasculares. Entretanto, não foi identificado consenso sobre superioridade absoluta entre os modelos, uma vez que o desempenho variou conforme o tamanho amostral, tipo de população estudada e parâmetros fisiológicos analisados.

Apesar dos resultados promissores, os estudos analisados apresentaram importante heterogeneidade metodológica. Houve variação significativa na forma de obtenção da VFC, duração dos registros fisiológicos, parâmetros analisados e critérios de treinamento dos modelos. Alguns estudos utilizaram registros curtos de ECG, enquanto outros empregaram monitorização contínua por Holter de 24 horas. Além disso, diferentes métricas de VFC foram utilizadas, incluindo SDNN, RMSSD, SD1, SD2 e parâmetros espectrais, dificultando comparações diretas entre os achados.

Outro ponto importante refere-se à qualidade e representatividade das amostras. Embora alguns estudos tenham incluído milhares de participantes, outros apresentaram amostras reduzidas ou desenhos experimentais limitados. Zhang et al. (2023), por exemplo, utilizaram apenas um participante em modelo experimental longitudinal, o que reduz significativamente a validade externa dos resultados. De forma semelhante, Tasmurzayev et al. (2025) utilizaram ampliação de dados sintéticos para treinamento do modelo, estratégia que, embora útil computacionalmente, pode comprometer a representatividade clínica dos achados.

Também foi observado que muitos estudos priorizaram métricas de desempenho técnico, como acurácia e AUC, sem avaliação aprofundada da aplicabilidade clínica real dos modelos. Aspectos relacionados à implementação hospitalar, integração com



sistemas de monitorização, custo computacional e interpretação clínica dos algoritmos ainda são pouco explorados. Essa limitação demonstra que, apesar do avanço tecnológico, a incorporação dessas ferramentas na prática clínica permanece em fase inicial.

Além disso, a ausência de padronização metodológica entre os estudos dificulta a consolidação de evidências consistentes para utilização clínica ampla. A falta de validação externa multicêntrica em parte dos estudos representa uma limitação importante, especialmente considerando que modelos treinados em populações específicas podem apresentar redução de desempenho quando aplicados em cenários diferentes.

Mesmo diante dessas limitações, os resultados encontrados nesta revisão indicam que a inteligência artificial aplicada à VFC possui potencial relevante para auxiliar na predição de risco cardiovascular, principalmente pela capacidade de identificar padrões complexos dificilmente detectados por métodos convencionais. A integração entre análise fisiológica e algoritmos computacionais pode contribuir para monitorização contínua, identificação precoce de descompensações clínicas e personalização do cuidado cardiovascular.

Dessa forma, futuros estudos devem priorizar amostras multicêntricas, validação externa robusta e padronização dos métodos de extração da VFC, além de investigar a aplicabilidade clínica e custo-efetividade dessas tecnologias em ambientes reais de assistência à saúde.

6. Conclusão

A presente revisão evidenciou que a aplicação da inteligência artificial associada à variabilidade da frequência cardíaca apresenta potencial relevante na predição de risco cardiovascular, especialmente na identificação precoce de eventos adversos, estratificação prognóstica e suporte ao diagnóstico clínico. Os estudos analisados demonstraram que modelos baseados em machine learning e deep learning são capazes de reconhecer padrões complexos nos sinais fisiológicos da VFC, alcançando elevados índices de acurácia e capacidade discriminativa em diferentes contextos cardiovasculares.

Os principais achados mostraram desempenho satisfatório dos algoritmos aplicados à detecção de infarto agudo do miocárdio, insuficiência cardíaca, parada cardíaca intra-hospitalar e mortalidade cardiovascular. Em diversos estudos, os modelos apresentaram AUC superiores a 0,85, além de elevada sensibilidade e acurácia diagnóstica, sugerindo potencial superior ou complementar aos métodos tradicionais de análise estatística da VFC.

Além disso, observou-se que a integração entre inteligência artificial, monitorização fisiológica e análise de sinais cardiovasculares pode contribuir para abordagens mais individualizadas e contínuas de avaliação clínica. O uso de tecnologias como machine learning, redes neurais artificiais e modelos multimodais amplia a capacidade de processamento de grandes volumes de dados, favorecendo estratégias de medicina preditiva e monitorização remota.

Entretanto, os estudos disponíveis ainda apresentam importante heterogeneidade metodológica, especialmente em relação aos algoritmos utilizados, métodos de extração da VFC, tamanho amostral e desfechos analisados. Também foram identificadas limitações relacionadas à validação externa, utilização de amostras reduzidas e emprego de dados sintéticos em parte dos modelos, fatores que dificultam a padronização e ampla implementação clínica dessas tecnologias.

Outro aspecto relevante refere-se ao fato de que muitos estudos priorizam métricas de desempenho técnico, como acurácia e AUC, com menor enfoque na



aplicabilidade clínica prática, custo-efetividade e integração aos sistemas de saúde. Dessa forma, apesar dos resultados promissores, a utilização ampla da inteligência artificial aplicada à VFC ainda requer maior consolidação científica e validação em cenários clínicos reais.

Conclui-se, portanto, que a inteligência artificial aplicada à análise da variabilidade da frequência cardíaca representa uma ferramenta promissora para predição do risco cardiovascular, podendo contribuir para a identificação precoce de pacientes de maior risco e auxiliar na tomada de decisão clínica. Contudo, futuros estudos multicêntricos, com metodologias padronizadas e validação externa robusta, são necessários para ampliar a confiabilidade e viabilidade da implementação dessas ferramentas na prática clínica.

Referências

- AGLIARI, E. et al. **Detecting cardiac pathologies via machine learning on heart-rate variability time series and related markers**. Scientific Reports, Londres, v. 10, n. 1, 2020. DOI:10.1038/s41598-020-64083-4
- BRINZA, C. et al. **Heart Rate Variability in Acute Myocardial Infarction: Results of the HeaRt-V-AMI Single-Center Cohort Study**. Journal of Clinical Medicine, Basileia, v. 13, n. 4, 2024. DOI: 10.3390/jcdd11080254.
- CHUMACHENKO, V. et al. **Machine Learning Methods in Predicting Patients with Suspected Myocardial Infarction Based on Short-Time HRV Data**. Sensors, Basileia, v. 22, n. 18, 2022. DOI:10.3390/s22187033.
- FAUST, O. et al. **Heart rate variability for healthcare applications using artificial intelligence techniques: a review**. Computer Methods and Programs in Biomedicine, Amsterdã, v. 223, 2022. DOI: 10.1016/j.cmpb.2022.106991.
- GONZÁLEZ, A. et al. **Multimodal deep learning for heart failure prediction using ECG and heart rate variability**. arXiv, Ithaca, 2024. Disponível em: <https://arxiv.org/abs/2403.15408>. Acesso em: 6 maio 2026.
- KUMAR, R.; AGGARWAL, Y.; NIGAM, V. K. **Heart rate dynamics in the prediction of coronary artery disease and myocardial infarction using artificial neural network and support vector machine**. Journal of Applied Biomedicine, České Budějovice, v. 20, n. 2, p. 70-79, 2022. DOI: 10.32725/jab.2022.008.
- LEE, H. et al. **Real-time machine learning model to predict in-hospital cardiac arrest using heart rate variability in ICU**. npj Digital Medicine, Londres, v. 6, n. 1, 2023. DOI: 10.1038/s41746-023-00960-2
- LIU, N. et al. **Beatquency domain and machine learning improve prediction of cardiovascular death after acute coronary syndrome**. Scientific Reports, Londres, v. 6, 2016. DOI: 10.1038/srep34545.
- MARTINEZ-ALANIS, J. et al. **Prediction of Sudden Cardiac Death Risk with a Support Vector Machine Based on Heart Rate Variability and Heartprint Indices**. Sensors, Basileia, v. 20, n. 19, 2020. DOI: 10.3390/s20195483.
- MELILLO, P. et al. **Automatic prediction of cardiovascular and cerebrovascular events using heart rate variability analysis**. PLoS ONE, San Francisco, v. 10, n. 3, 2015. DOI: 10.1371/journal.pone.0118504.
- NAYAK, A. et al. **A Review of Methods and Applications for a Heart Rate Variability Analysis**. Algorithms, Basileia, v. 16, n. 9, 2023. DOI: 10.3390/a16090433.
- SHAFFER, F.; GINSBERG, J. P. **An Overview of Heart Rate Variability Metrics and Norms**. Frontiers in Public Health, Lausanne, v. 5, 2017. DOI: 10.3389/fpubh.2017.00258.



- SHAH, S. et al. **Heart rate variability as a marker of cardiovascular dysautonomia in post-COVID-19 syndrome using artificial intelligence.** International Journal of Psychophysiology, Amsterdã, v. 175, 2022. DOI: 10.1016/j.ijpej.2022.01.004.
- SILVA-FILHO, A. G. et al. **A Machine Learning model of the combination of normalized SD1 and SD2 indexes from 24h-Heart Rate Variability as a predictor of myocardial infarction.** arXiv, Ithaca, 2021. Disponível em: <https://arxiv.org/abs/2102.09410>. Acesso em: 6 maio 2026.
- SONG, M. H. et al. **Usefulness of the heart-rate variability complex for predicting cardiac mortality after acute myocardial infarction.** BMC Cardiovascular Disorders, Londres, v. 14, 2014. DOI: 10.1186/1471-2261-14-59.
- TASMURZAYEV, N. et al. **A wearable IoT-based measurement system for real-time cardiovascular risk prediction using heart rate variability.** Eng, Basileia, v. 6, n. 10, 2025. DOI: 10.3390/eng6100259.
- VAN ES, R. et al. **Effect of urban environment on cardiovascular health: a feasibility pilot study using machine learning to predict heart rate variability in patients with heart failure.** European Heart Journal Digital Health, Oxford, v. 5, n. 5, 2024. DOI:10.1093/ehjdh/ztae050.
- WANG, L. et al. **Heart diseases recognition model based on HRV feature extraction over 12-lead ECG signals.** Sensors, Basileia, v. 24, n. 16, 2024. DOI: 10.3390/s24165296.
- YADAV, I. et al. **Heart rate variability as a predictor of mortality in heart failure: a systematic review and meta-analysis.** Cureus, Palo Alto, v. 17, n. 12, 2025. DOI: 10.7759/cureus.99120.
- ZHANG, Y. et al. **Efficient and Direct Inference of Heart Rate Variability using Both Signal Processing and Machine Learning.** arXiv, Ithaca, 2023. Disponível em: <https://arxiv.org/abs/2303.13637>. Acesso em: 1 maio 2026.
- ACCARDO, A. et al. **Detection of subjects with ischemic heart disease by using machine learning technique based on heart rate total variability parameters.** Physiological Measurement, Bristol, v. 41, n. 11, 2020. DOI: 10.1088/1361-6579/abc321.
- BRINZA, C. et al. **Measuring heart rate variability in patients admitted with ST-elevation myocardial infarction for the prediction of subsequent cardiovascular events: a systematic review.** Medicina, Basileia, v. 57, n. 10, 2021. DOI: 10.3390/medicina57101021.