


INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA
PARAÍBA

COORDENAÇÃO DO CURSO DE ENGENHARIA ELÉTRICA



PEDRO ANTÔNIO DE ANDRADE DA SILVA

**Detecção Automática de Infarto do Miocárdio em
Eletrocardiogramas Utilizando Redes Neurais Convolucionais e
Classificação Multiclasse**

João Pessoa

2026

PEDRO ANTÔNIO DE ANDRADE DA SILVA

**Detecção Automática de Infarto do Miocárdio em
Eletrocardiogramas Utilizando Redes Neurais Convolucionais e
Classificação Multiclasse**

Trabalho de Conclusão de Curso submetido à Coordenação do Curso de Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba, como parte dos requisitos para a obtenção do grau de Engenheiro Eletricista.

Orientador: Carlos Danilo Miranda Regis

João Pessoa
2026

PEDRO ANTÔNIO DE ANDRADE DA SILVA

**DETECÇÃO AUTOMÁTICA DE INFARTO DO MIOCÁRDIO EM ELETROCARDIOGRAMAS UTILIZANDO
REDES NEURAIS CONVOLUCIONAIS E CLASSIFICAÇÃO MULTICLASSE**

TRABALHO DE CONCLUSÃO DE CURSO (TCC) submetido a
Coordenação do Curso Superior de Bacharelado em Engenharia
Elétrica, do Instituto Federal da Paraíba (IFPB), como parte dos
requisitos institucionais para a obtenção do Título de **ENGENHEIRO
ELETRICISTA**.

Aprovado em 03/07/2026 - 14:30

Membros da Banca Examinadora:

Prof. Dr. CARLOS DANILO MIRANDA REGIS

Instituto Federal da Paraíba –
Orientador Interno

Profa. Dra. SUZETE ELIDA NOBREGA CORREIA

Instituto Federal da Paraíba
Examinadora Interna

Prof. Dr. PATRIC LACOUTH DA SILVA

Instituto Federal da Paraíba
Examinador Interno

Documento assinado eletronicamente por:

- Carlos Danilo Miranda Regis, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 08/07/2026 05:49:36.
- Patric Lacouth da Silva, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 08/07/2026 19:23:08.
- Suzete Elida Nobrega Correia, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 10/07/2026 19:02:32.

Este documento foi emitido pelo SUAP em 07/07/2026. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifpb.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código 901017
Verificador: c0c4ae7b22
Código de Autenticação:



Dados Internacionais de Catalogação na Publicação – CIP
Biblioteca Nilo Peçanha – IFPB, *campus* João Pessoa

S586d Silva, Pedro Antônio de Andrade da.
Detecção automática de infarto do miocárdio em eletrocardiogramas utilizando redes neurais convolucionais e classificação multiclasse / Pedro Antônio de Andrade da Silva. – 2026.
44 f. : il.
TCC (Graduação em Engenharia Elétrica) – Instituto Federal de Educação, Ciência e Tecnologia da Paraíba – IFPB / Coordenação de Engenharia Elétrica.
Orientador: Carlos Danilo Miranda Regis.
1. Eletrocardiograma. 2. Infarto do miocárdio. 3. Redes neurais convolucionais. 4. Aprendizado profundo. 5. Classificação multiclasse. I. Título.

CDU 616.12-073.7

Agradecimentos

Primeiramente, agradeço a Deus, por me conceder saúde, sabedoria, força e perseverança ao longo desta caminhada. Sua presença foi essencial para superar os desafios encontrados e para tornar possível a conclusão desta etapa tão importante da minha formação.

Agradeço à minha família, pelo incentivo e confiança depositados em mim durante toda a minha trajetória acadêmica. Em especial, à minha mãe, que sempre esteve ao meu lado com dedicação e inúmeros sacrifícios, servindo como minha fonte de inspiração e motivação.

Expresso minha sincera gratidão aos meus colegas do Grupo de Pesquisa em Processamento Digital de Sinais (GPDS), pelo companheirismo, pelas discussões técnicas, pela troca de conhecimentos e pelo ambiente colaborativo que tanto contribuiu para o meu crescimento pessoal e profissional.

Também agradeço aos professores e orientadores que compartilharam seus conhecimentos e experiências ao longo desta jornada, contribuindo significativamente para minha formação acadêmica e para o desenvolvimento deste trabalho.

Por fim, agradeço a todos que, de alguma forma, participaram desta caminhada e contribuíram para que este sonho se tornasse realidade.

RESUMO

As doenças cardiovasculares estão entre as principais causas de mortalidade no mundo, sendo o infarto do miocárdio uma condição associada à interrupção do fluxo sanguíneo coronariano e à consequente lesão do tecido cardíaco. O eletrocardiograma de 12 derivações é uma das ferramentas mais utilizadas na triagem inicial dessa condição, por ser um exame não invasivo, de baixo custo e amplamente disponível. Entretanto, sua interpretação pode ser afetada por variabilidade entre especialistas, fadiga e pela presença de outras patologias cardíacas com manifestações eletrocardiográficas semelhantes. Nesse contexto, este trabalho propõe uma abordagem de classificação multiclasse para detecção automática de infarto do miocárdio em sinais de ECG, utilizando redes neurais convolucionais unidimensionais e a base pública PTB-XL. Diferentemente de formulações binárias, restritas às classes Normal e Infarto, a metodologia incorpora uma terceira classe, denominada Outras Patologias, com o objetivo de representar sinais eletrocardiográficos anômalos não associados diretamente ao infarto. Foram avaliados dois cenários experimentais: uma abordagem binária de referência e uma abordagem multiclasse com três classes. Os resultados indicaram que o modelo binário obteve maior acurácia global, com 95,12% na validação, mas não possui mecanismo explícito para identificar sinais patológicos fora das classes consideradas. O modelo multiclasse obteve acurácia de 82,71%, permitindo distinguir exames normais, registros associados ao infarto e outras alterações cardíacas. Os resultados sugerem que a inclusão da classe Outras Patologias reduz a simplificação do espaço diagnóstico e torna a avaliação mais próxima de cenários de triagem clínica.

Palavras-chave: Eletrocardiograma. Infarto do Miocárdio. Redes Neurais Convolucionais. Aprendizado Profundo. Classificação Multiclasse.

ABSTRACT

Cardiovascular diseases are among the leading causes of mortality worldwide, and acute myocardial infarction is associated with the interruption of coronary blood flow and consequent injury to cardiac tissue. The 12-lead electrocardiogram is one of the most widely used tools for the initial screening of this condition, since it is non-invasive, low-cost, and broadly available. However, ECG interpretation may be affected by interobserver variability, fatigue, and the presence of other cardiac diseases with similar electrocardiographic manifestations. In this context, this work proposes a multiclass classification approach for the automatic detection of myocardial infarction in ECG signals, using one-dimensional convolutional neural networks and the public PTB-XL database. Unlike binary formulations, restricted to Normal and Myocardial Infarction classes, the proposed methodology includes a third class, named Other Pathologies, to represent abnormal electrocardiographic signals not directly associated with myocardial infarction. Two experimental scenarios were evaluated: a binary reference approach and a multiclass approach with three classes. The results showed that the binary model achieved higher global accuracy, with 95.12% on validation, but it does not provide an explicit mechanism to identify pathological signals outside the considered classes. The multiclass model achieved an accuracy of 82.71%, allowing the distinction among normal exams, myocardial infarction records, and other cardiac abnormalities. The results suggest that including the Other Pathologies class reduces the simplification of the diagnostic space and makes the evaluation closer to clinical screening scenarios.

Keywords: *Electrocardiogram. Myocardial Infarction. Convolutional Neural Networks. Deep Learning. Multiclass Classification.*

LISTA DE FIGURAS

Figura 1 – Representação esquemática da doença arterial coronariana.	12
Figura 2 – Exemplo esquemático de alteração do segmento ST em sinal de ECG associado ao infarto do miocárdio. A ampliação de V5 tem finalidade didática e não indica que as demais derivações estejam normais.	14
Figura 3 – Exemplo de eletrocardiograma de 12 derivações.	15
Figura 4 – Ondas, segmentos e intervalos característicos de um ciclo eletrocardiográfico.	16
Figura 5 – Fluxo geral da metodologia empregada neste trabalho.	23
Figura 6 – Exemplos representativos das classes utilizadas no estudo: ECG normal (NORM), infarto do miocárdio inferior (IMI) e exemplos da classe <i>Outras Patologias</i> (CLBBB, LVH e ISCA). A figura ilustra a diversidade morfológica presente na Classe 2, reforçando sua relevância na formulação multiclasse.	26
Figura 7 – Arquitetura da rede convolucional utilizada neste trabalho.	28
Figura 8 – Fluxo experimental do cenário binário.	30
Figura 9 – Fluxo experimental do cenário multiclasse.	30
Figura 10 – Curvas de perda do modelo binário ao longo do treinamento, com early stopping monitorando a perda de validação.	34
Figura 11 – Matriz de confusão normalizada do modelo binário quando exposto a sinais da classe <i>Outras Patologias</i>	35
Figura 12 – Curvas de perda do modelo multiclasse ao longo do treinamento.	37
Figura 13 – Matriz de confusão normalizada do modelo multiclasse.	37

LISTA DE TABELAS

Tabela 1	–	Resumo da arquitetura do modelo multiclasse proposto.	29
Tabela 2	–	Desempenho do modelo no cenário binário Normal versus Infarto. . . .	34
Tabela 3	–	Desempenho global do modelo multiclasse proposto.	36
Tabela 4	–	Desempenho por classe do modelo multiclasse.	38
Tabela 5	–	Comparação entre os cenários binário e multiclasse.	38

SUMÁRIO

1	INTRODUÇÃO	9
2	FUNDAMENTAÇÃO TEÓRICA	12
2.1	Infarto do Miocárdio	12
2.2	Eletrocardiograma	14
2.2.1	ECG e alterações cardíacas	17
2.3	Outras Patologias Cardíacas	17
2.3.1	Distúrbios de condução	18
2.3.2	Hipertrofias cardíacas	18
2.3.3	Alterações de repolarização e alterações ST/T	19
2.3.4	Arritmias e alterações do ritmo cardíaco	19
2.3.5	Justificativa para a classe Outras Patologias	20
2.4	Aprendizado de Máquina Aplicado à Análise de ECG	20
3	METODOLOGIA	23
3.1	Visão Geral da Metodologia	23
3.2	Base de Dados	23
3.3	Definição das Classes	24
3.4	Pré-processamento dos Sinais	25
3.5	Particionamento dos Dados	27
3.6	Arquitetura da Rede Neural	27
3.7	Estratégias Experimentais	29
3.8	Configuração do Treinamento	31
3.8.1	Métricas de avaliação	31
4	RESULTADOS E DISCUSSÃO	33
4.1	Cenário Binário: Normal versus Infarto	33
4.2	Cenário Multiclasse: Normal, Infarto e Outras Patologias	36
4.3	Comparação entre as Formulações Binária e Multiclasse	38
4.4	Discussão Geral	39
5	CONCLUSÃO	41
	REFERÊNCIAS	43

1 Introdução

As doenças cardiovasculares constituem a principal causa de morte no mundo. Segundo a Organização Mundial da Saúde, essas doenças foram responsáveis por aproximadamente 19,8 milhões de mortes em 2022, correspondendo a cerca de 32% dos óbitos globais (World Health Organization, 2025). Entre essas condições, destaca-se o infarto do miocárdio (IM), definido pela presença de lesão miocárdica aguda associada a evidências clínicas de isquemia (THYGESEN et al., 2018). No Brasil, o IM permanece como uma das principais causas de internação hospitalar por doença cardiovascular: entre 2019 e 2023 foram registradas 737.213 internações por infarto agudo do miocárdio, com taxa média de incidência de 72,60 casos por 100 mil habitantes (NETO et al., 2024), o que evidencia a relevância epidemiológica da condição na população geral.

O diagnóstico precoce do IM é necessário para orientar a conduta clínica e reduzir o risco de complicações associadas à interrupção do fluxo sanguíneo coronariano. Nesse contexto, o eletrocardiograma (ECG) de 12 derivações é uma das principais ferramentas de triagem, pois permite registrar a atividade elétrica cardíaca de forma não invasiva, rápida e com ampla disponibilidade clínica (SAMESIMA et al., 2022). Alterações como supradesnivelamento do segmento ST, inversão da onda T e presença de ondas Q patológicas podem indicar lesão isquêmica e auxiliar na avaliação inicial de pacientes com suspeita de infarto (THYGESEN et al., 2018).

Apesar de sua relevância clínica, a interpretação manual do ECG apresenta limitações. O processo depende da experiência do profissional, pode sofrer influência da variabilidade interobservador e torna-se mais desafiador em ambientes de emergência, nos quais há pressão por decisões rápidas (SCHLÄPFER; WELLENS, 2017). Além disso, diferentes condições cardíacas podem produzir alterações morfológicas no ECG sem caracterizar necessariamente um evento isquêmico, dificultando o diagnóstico diferencial.

Com o avanço do aprendizado de máquina e do aprendizado profundo, modelos computacionais passaram a ser utilizados na análise automática de sinais eletrocardiográficos. Entre essas abordagens, as redes neurais convolucionais têm sido empregadas por sua capacidade de aprender características diretamente dos sinais brutos, reduzindo a dependência de etapas manuais de extração de atributos (LECUN; BENGIO; HINTON, 2015). Em aplicações com ECG, esse tipo de arquitetura tem sido explorado em tarefas como detecção de arritmias, identificação de distúrbios de condução e classificação de alterações cardiovasculares (ACHARYA et al., 2017; HANNUN et al., 2019; RIBEIRO et al., 2020).

Entretanto, parte dos estudos sobre detecção automática de infarto formula o pro-

blema como uma classificação binária, geralmente separando os registros entre sinais normais e sinais associados ao infarto. Embora essa estratégia possa produzir métricas elevadas em bases controladas, ela restringe o espaço de decisão do classificador. Em cenários de triagem, pacientes podem apresentar bloqueios de ramo, hipertrofias ventriculares, alterações de repolarização, arritmias e outras condições que modificam o ECG, mas não correspondem diretamente ao infarto do miocárdio (SAMESIMA et al., 2022; GOLDBERGER; GOLDBERGER; SHVILKIN, 2018).

Quando um modelo binário é exposto a sinais patológicos não representados durante o treinamento, a decisão tende a ser forçada para uma das classes conhecidas. Esse comportamento pode gerar interpretações inadequadas, classificando sinais anômalos como normalidade ou como infarto. Em sistemas de apoio à decisão clínica, essa limitação é relevante porque a ausência de uma classe intermediária impede que o modelo represente explicitamente padrões eletrocardiográficos patológicos fora da classe-alvo.

Diante desse problema, este trabalho propõe uma abordagem de classificação multi-classe para detecção automática de infarto do miocárdio em sinais de ECG. A metodologia utiliza a base pública PTB-XL, composta por registros clínicos de ECG de 12 derivações com anotações diagnósticas estruturadas (WAGNER et al., 2020). Foram consideradas três classes: Normal, Infarto do Miocárdio e Outras Patologias. A terceira classe agrupa sinais patológicos não associados diretamente ao infarto, permitindo avaliar o impacto de sua inclusão na robustez do classificador.

O objetivo geral deste trabalho é investigar se a formulação multiclasse torna o processo de classificação mais adequado a cenários de triagem clínica quando comparado à formulação binária. Para isso, são avaliadas abordagens baseadas em redes neurais aplicadas diretamente aos sinais de ECG, comparando-se métricas globais de desempenho e padrões de erro observados nas matrizes de confusão.

Como contribuições, este trabalho apresenta: a organização de um protocolo experimental baseado na base PTB-XL; a comparação entre formulações binária e multiclasse para detecção de infarto; e a análise do impacto da classe Outras Patologias na separação entre sinais normais, sinais associados ao infarto e demais alterações eletrocardiográficas. Dessa forma, busca-se avaliar não apenas a acurácia dos modelos, mas também sua coerência com um cenário de apoio à decisão em triagem cardiovascular.

Este trabalho está organizado em cinco capítulos. O Capítulo 2 apresenta a fundamentação teórica, abordando conceitos relacionados ao infarto do miocárdio, ao eletrocardiograma, às principais patologias cardíacas consideradas neste estudo e às técnicas de aprendizado profundo aplicadas à análise de sinais biomédicos. O Capítulo 3 apresenta a metodologia do trabalho, abordando a base de dados, o pré-processamento dos sinais, a definição das classes, a arquitetura da rede neural e o protocolo experimental utilizado. No Capítulo 4 são apresentados e discutidos os resultados obtidos para os cenários de

classificação binária e multiclasse. Por fim, o Capítulo 5 reúne as conclusões do trabalho, destacando as principais contribuições, limitações e possíveis direções para pesquisas futuras.

2 Fundamentação Teórica


2.1 Infarto do Miocárdio

De acordo com a Quarta Definição Universal de Infarto do Miocárdio, o infarto é definido pela presença de lesão miocárdica aguda associada a evidências clínicas de isquemia miocárdica (THYGESEN et al., 2018). Essa definição é importante porque diferencia a simples elevação de biomarcadores cardíacos de um evento isquêmico propriamente dito.

O Infarto do Miocárdio (IM) ocorre quando há redução significativa ou interrupção do suprimento sanguíneo para uma região do músculo cardíaco. A diminuição do aporte de oxigênio provoca isquemia miocárdica e, quando mantida por tempo suficiente, resulta em necrose irreversível das células cardíacas (THYGESEN et al., 2018).

Na maior parte dos casos, o IM está associado à ruptura ou erosão de placas ateroscleróticas presentes nas artérias coronárias. Esse processo favorece a formação de trombos, que podem obstruir parcial ou totalmente o vaso sanguíneo, reduzindo a perfusão do miocárdio (WHITE; CHEW, 2008). A extensão da lesão depende de fatores como o tempo de oclusão, a artéria acometida, a área irrigada por esse vaso e a presença de circulação colateral. A Figura 1 apresenta uma representação esquemática da doença arterial coronariana, caracterizada pelo acúmulo de placas na parede interna das artérias.

Figura 1 – Representação esquemática da doença arterial coronariana.



Fonte: Adaptada de (BLAUS, 2014).

Do ponto de vista fisiopatológico, a interrupção da perfusão coronariana compromete inicialmente o metabolismo celular. Com a redução da disponibilidade de oxigênio, as células miocárdicas passam a apresentar alterações funcionais e elétricas. Caso a reperfusão não ocorra de forma adequada, instala-se necrose miocárdica, comprometendo a função mecânica e elétrica da região afetada (THYGESEN et al., 2018).

Além da obstrução trombótica associada à aterosclerose, o infarto também pode ocorrer em situações nas quais há desequilíbrio entre oferta e demanda de oxigênio pelo miocárdio. Esse quadro pode estar relacionado, por exemplo, a espasmo coronariano, anemia, taquiarritmias ou hipotensão prolongada (THYGESEN et al., 2018).

Diversos fatores estão associados ao desenvolvimento de doença arterial coronariana e, conseqüentemente, ao aumento do risco de infarto do miocárdio. Entre os principais fatores modificáveis estão hipertensão arterial, tabagismo, diabetes mellitus, dislipidemia, obesidade, sedentarismo e dieta inadequada (GAZIANO et al., 2010). Também são relevantes fatores não modificáveis, como idade, sexo e histórico familiar de doença cardiovascular.

A presença simultânea de múltiplos fatores de risco aumenta a probabilidade de desenvolvimento de aterosclerose coronariana. Esse processo ocorre de forma progressiva e pode permanecer assintomático por longos períodos. (WHITE; CHEW, 2008).

Embora a análise dos fatores de risco seja essencial para prevenção e acompanhamento clínico, o foco deste trabalho está na identificação automática de padrões eletrocardiográficos associados ao IM. Por esse motivo, os fatores de risco são abordados como contexto clínico, enquanto a análise dos sinais de ECG é tratada com maior detalhamento nos capítulos seguintes.

O diagnóstico do IM é realizado a partir da combinação de evidências clínicas, alterações eletrocardiográficas e biomarcadores cardíacos. A Quarta Definição Universal de Infarto do Miocárdio estabelece que a identificação de lesão miocárdica aguda depende da elevação ou queda de troponina cardíaca, associada a evidências de isquemia, como sintomas, alterações no ECG, achados de imagem ou identificação de trombo coronariano (THYGESEN et al., 2018).


Entre os exames utilizados na avaliação inicial, o eletrocardiograma de 12 derivações possui papel central por ser rápido, não invasivo, de baixo custo e disponível em unidades de urgência e emergência. O ECG permite observar alterações na atividade elétrica cardíaca, auxiliando na triagem de pacientes com suspeita de síndrome coronariana aguda (SAMESIMA et al., 2022). A suspeita clínica é definida principalmente pela presença de sintomas sugestivos de isquemia miocárdica, como dor ou desconforto torácico, dispneia e sudorese, que motivam a solicitação imediata do ECG e a dosagem seriada de biomarcadores cardíacos para confirmação diagnóstica (THYGESEN et al., 2018; SAMESIMA et al., 2022).

As alterações eletrocardiográficas associadas ao IM dependem da região acometida, do tempo de evolução do evento isquêmico e da extensão da lesão miocárdica. Entre os achados mais frequentemente avaliados estão o supradesnívelamento do segmento ST, o infradesnívelamento do segmento ST, a inversão da onda T e o surgimento de ondas Q

patológicas (THYGESEN et al., 2018; SAMESIMA et al., 2022).

O supradesnivelamento do segmento ST é um dos achados mais relevantes na triagem de pacientes com suspeita de IM com supradesnivelamento do segmento ST. Esse padrão pode indicar lesão miocárdica aguda e demanda avaliação clínica imediata. A Figura 2 apresenta um exemplo esquemático de alteração do segmento ST associada ao infarto.

Figura 2 – Exemplo esquemático de alteração do segmento ST em sinal de ECG associado ao infarto do miocárdio. A ampliação de V5 tem finalidade didática e não indica que as demais derivações estejam normais.



Fonte: Autoria Própria.

2.2 Eletrocardiograma

O eletrocardiograma (ECG) é um exame utilizado para registrar, ao longo do tempo, as variações de potencial elétrico produzidas pela atividade cardíaca. Esses potenciais são captados por eletrodos posicionados na superfície corporal e representados graficamente em forma de ondas, segmentos e intervalos. Por ser um exame não invasivo, de rápida aquisição e amplamente disponível, o ECG é empregado na investigação de arritmias, distúrbios de condução, alterações de repolarização e eventos isquêmicos, incluindo o infarto do miocárdio (SAMESIMA et al., 2022; GOLDBERGER; GOLDBERGER; SHVILKIN, 2018).

A atividade elétrica cardíaca resulta da despolarização e repolarização das células do miocárdio. Esses fenômenos ocorrem de forma coordenada durante o ciclo cardíaco e produzem diferenças de potencial que se propagam pelos tecidos até a superfície corporal. O ECG registra essas variações por meio de eletrodos, permitindo observar indiretamente a

sequência de ativação elétrica do coração (GOLDBERGER; GOLDBERGER; SHVILKIN, 2018).


Em condições fisiológicas, o impulso elétrico é iniciado no nó sinoatrial, propaga-se pelos átrios, alcança o nó atrioventricular e segue pelo sistema até os ventrículos. Essa sequência gera padrões característicos no traçado eletrocardiográfico. Alterações na condução, na ativação ventricular ou na repolarização podem modificar a forma, duração ou amplitude desses padrões (SAMESIMA et al., 2022).

Dessa forma, o ECG não mede diretamente a contração mecânica do coração, mas a atividade elétrica que antecede e organiza essa contração. Essa característica torna o exame útil para detectar condições que afetam a condução elétrica cardíaca ou a integridade do tecido miocárdico.

O ECG clínico convencional utiliza 12 derivações, obtidas a partir da combinação de eletrodos posicionados nos membros e na região torácica. Essas derivações permitem observar a atividade elétrica cardíaca a partir de diferentes perspectivas espaciais, ampliando a capacidade de identificar alterações localizadas em regiões específicas do coração (SAMESIMA et al., 2022; GOLDBERGER; GOLDBERGER; SHVILKIN, 2018).

As derivações periféricas são DI, DII, DIII, aVR, aVL e aVF. Elas analisam a atividade elétrica predominantemente no plano frontal. Já as derivações precordiais, identificadas como V1, V2, V3, V4, V5 e V6, avaliam a atividade cardíaca no plano horizontal. Em conjunto, essas derivações fornecem uma representação espacial da propagação elétrica cardíaca (GOLDBERGER; GOLDBERGER; SHVILKIN, 2018). A Figura 3 apresenta um exemplo de eletrocardiograma de 12 derivações que são utilizadas conjuntamente como entrada multicanal da rede neural nesse trabalho.

Figura 3 – Exemplo de eletrocardiograma de 12 derivações.



Fonte: (HAMPTON, 2014).


O traçado eletrocardiográfico é composto por elementos que correspondem a diferentes etapas da ativação elétrica cardíaca. Entre os principais componentes estão a

onda P, o complexo QRS, a onda T, o intervalo PR, o segmento ST e o intervalo QT (SAMESIMA et al., 2022; GOLDBERGER; GOLDBERGER; SHVILKIN, 2018).

A onda P representa a despolarização atrial. Em seguida, o complexo QRS corresponde à despolarização ventricular, sendo geralmente o componente de maior amplitude do ECG. A onda T representa a repolarização ventricular. Esses elementos refletem a sequência elétrica do ciclo cardíaco e são avaliados quanto à duração, amplitude, morfologia e relação temporal entre si.

A Figura 4 apresenta os principais componentes de um ciclo eletrocardiográfico.

Figura 4 – Ondas, segmentos e intervalos característicos de um ciclo eletrocardiográfico.



Fonte: Adaptada de (VIJAYBASKAR; PUGAZENDI, 2025).

O intervalo PR representa o tempo entre o início da despolarização atrial e o início da despolarização ventricular. Alterações nesse intervalo podem indicar distúrbios de condução atrioventricular. O segmento ST corresponde ao período entre o final da despolarização ventricular e o início da repolarização ventricular, sendo um componente importante na avaliação de isquemia miocárdica. O intervalo QT, por sua vez, compreende a despolarização e a repolarização ventricular, podendo ser alterado por distúrbios eletrolíticos, medicamentos e condições cardíacas específicas (SAMESIMA et al., 2022).

No infarto do miocárdio, alterações no segmento ST, na onda T e no complexo QRS podem indicar lesão isquêmica ou necrose miocárdica. Entretanto, padrões semelhantes também podem surgir em outras condições cardíacas, o que reforça a necessidade

de interpretar o ECG considerando o contexto clínico e a possibilidade de diagnósticos diferenciais (THYGESEN et al., 2018).

2.2.1 ECG e alterações cardíacas

O ECG é utilizado na avaliação de diferentes condições cardiovasculares. Arritmias podem alterar a regularidade e a frequência do traçado; bloqueios de condução podem modificar a duração e a morfologia do complexo QRS; hipertrofias ventriculares podem produzir alterações de amplitude e repolarização; e eventos isquêmicos podem modificar o segmento ST, a onda T e a presença de ondas Q patológicas (SAMESIMA et al., 2022; GOLDBERGER; GOLDBERGER; SHVILKIN, 2018).

Essa diversidade de manifestações torna o ECG uma fonte de dados adequada para sistemas computacionais de apoio à decisão em dois sentidos principais: trata-se de um sinal digital estruturado, com formato e amostragem padronizados entre exames e existem bases de dados públicas de grande escala e anotadas clinicamente que viabilizam o treinamento supervisionado de modelos. Modelos de aprendizado profundo podem aprender padrões presentes no sinal, identificando características temporais e morfológicas associadas a diferentes classes diagnósticas (HANNUN et al., 2019; RIBEIRO et al., 2020).

2.3 Outras Patologias Cardíacas

Nas seções anteriores, foram apresentados os fundamentos do Infarto do Miocárdio e do eletrocardiograma. Entretanto, em um cenário clínico real, nem todo ECG anormal corresponde a um infarto. Diferentes alterações cardíacas podem modificar a morfologia do sinal eletrocardiográfico e produzir padrões que dificultam a separação direta entre normalidade e infarto.

Essa distinção é particularmente relevante no contexto de emergência: estima-se que uma causa isquêmica possa ser descartada em 60% a 90% dos pacientes que procuram o pronto-socorro com queixa de dor torácica (WERTLI et al., 2019), o que significa que a maior parte dos ECGs anormais avaliados nesse cenário está associada a outras condições e não ao infarto.

A formulação binária, composta apenas pelas classes Normal e Infarto do Miocárdio, assume que todo sinal analisado pertence necessariamente a uma dessas duas categorias. Em aplicações de triagem, essa hipótese é restritiva, pois pacientes podem apresentar bloqueios de condução, hipertrofias, alterações de repolarização, arritmias e outras condições capazes de alterar o ECG sem caracterizar diretamente um evento de infarto (SAMESIMA et al., 2022; GOLDBERGER; GOLDBERGER; SHVILKIN, 2018).

Por esse motivo, este trabalho incorpora uma terceira classe, denominada Outras

Patologias. Essa classe não tem como objetivo fornecer um diagnóstico específico para cada alteração cardíaca individual. Sua função metodológica é representar sinais eletrocardiográficos patológicos que não pertencem à classe de infarto, permitindo avaliar se a presença desses exemplos altera o comportamento do classificador.

A base PTB-XL organiza os diagnósticos eletrocardiográficos em diferentes níveis hierárquicos, incluindo superclasses diagnósticas como normalidade, infarto do miocárdio, alterações de ST/T, distúrbios de condução e hipertrofias (WAGNER et al., 2020). Neste trabalho, registros associados a alterações patológicas não pertencentes diretamente ao infarto foram agrupados na classe Outras Patologias.

2.3.1 Distúrbios de condução

Os distúrbios de condução ocorrem quando há alterações na propagação do impulso elétrico pelo sistema de condução cardíaco. Essas alterações podem modificar a duração, a forma e a orientação do complexo QRS, afetando diretamente a morfologia do ECG (SAMESIMA et al., 2022).

Entre os exemplos mais comuns estão os bloqueios de ramo direito e esquerdo, bloqueios fasciculares e bloqueios atrioventriculares. Nos bloqueios de ramo, a ativação ventricular ocorre de forma alterada, o que pode resultar em alargamento do complexo QRS e mudanças secundárias no segmento ST e na onda T (SAMESIMA et al., 2022).

Essa característica é relevante para a detecção automática de infarto porque alterações de condução podem interferir na interpretação de padrões isquêmicos. A própria definição universal de infarto considera alterações de ST-T, ondas Q patológicas e bloqueios de ramo no contexto da avaliação eletrocardiográfica de isquemia miocárdica (THYGESEN et al., 2018). Assim, sinais com distúrbios de condução não devem ser tratados automaticamente como normais, ainda que também não correspondam necessariamente à classe de infarto.

2.3.2 Hipertrofias cardíacas

As hipertrofias cardíacas correspondem ao aumento da massa muscular de uma ou mais câmaras cardíacas. No ECG, essas alterações podem se manifestar por aumento de amplitude dos complexos QRS, desvios do eixo elétrico e alterações secundárias de repolarização (SAMESIMA et al., 2022; GOLDBERGER; GOLDBERGER; SHVILKIN, 2018).

A hipertrofia ventricular esquerda, por exemplo, pode produzir alterações de repolarização, incluindo depressão do segmento ST e inversão da onda T em determinadas derivações. Esses achados podem dificultar a distinção entre alterações estruturais crônicas e padrões associados à isquemia miocárdica (SAMESIMA et al., 2022).

Do ponto de vista da classificação automática, a presença de hipertrofias amplia a variabilidade dos sinais patológicos. Um classificador binário treinado apenas com sinais normais e sinais de infarto pode interpretar essas alterações como pertencentes a uma das duas classes disponíveis. Isso pode resultar em falsos positivos para infarto ou em classificação indevida como normalidade.

2.3.3 Alterações de repolarização e alterações ST/T

As alterações de repolarização envolvem modificações no segmento ST e na onda T. Esses componentes são relevantes na avaliação de isquemia miocárdica, mas também podem ser modificados por outras condições cardíacas e não cardíacas (THYGESEN et al., 2018; SAMESIMA et al., 2022).

Na base PTB-XL, uma das superclasses diagnósticas corresponde às alterações ST/T, indicando que esse grupo possui representação própria na organização dos rótulos diagnósticos (WAGNER et al., 2020). Essas alterações são importantes neste trabalho porque afetam justamente regiões do ECG utilizadas na avaliação de eventos isquêmicos.

A Quarta Definição Universal de Infarto do Miocárdio descreve alterações de onda T e do segmento ST como manifestações eletrocardiográficas de isquemia miocárdica (THYGESEN et al., 2018). Entretanto, diretrizes de interpretação eletrocardiográfica também reconhecem que alterações de repolarização podem ocorrer em diferentes contextos clínicos, incluindo alterações secundárias associadas a distúrbios de condução e hipertrofias (SAMESIMA et al., 2022, 2022).

2.3.4 Arritmias e alterações do ritmo cardíaco

As arritmias correspondem a alterações na formação ou condução dos impulsos elétricos responsáveis pelo ritmo cardíaco. No ECG, essas condições podem modificar a regularidade dos intervalos, a frequência cardíaca, a presença ou morfologia da onda P e a relação entre atividade atrial e ventricular (SAMESIMA et al., 2022; GOLDBERGER; GOLDBERGER; SHVILKIN, 2018).

Embora o foco deste trabalho não seja a classificação específica de arritmias, sua presença é relevante porque alterações do ritmo podem modificar a organização temporal do ECG. Essas mudanças podem afetar a extração de características pelo modelo, principalmente quando a rede aprende padrões temporais diretamente a partir do sinal bruto. Além disso, arritmias podem coexistir com outras doenças cardíacas, aumentando a heterogeneidade dos registros clínicos.

2.3.5 Justificativa para a classe Outras Patologias

Do ponto de vista eletrocardiográfico, distúrbios de condução, hipertrofias, arritmias e alterações de repolarização podem modificar a forma, amplitude, duração e distribuição temporal dos componentes do ECG. Essas modificações tornam inadequado tratar todos os registros não pertencentes ao infarto como normais.

Do ponto de vista computacional, a ausência de uma classe intermediária força o classificador a atribuir sinais patológicos a uma das duas classes disponíveis. Como consequência, um ECG anormal pode ser classificado como normalidade, reduzindo a sensibilidade do sistema para alterações cardíacas, ou pode ser classificado como infarto, aumentando a ocorrência de falsos positivos.

A classe Outras Patologias, portanto, não foi criada para substituir o diagnóstico clínico específico dessas condições. Ela foi definida como uma categoria metodológica para representar sinais anômalos não pertencentes diretamente ao infarto do miocárdio. Essa escolha permite avaliar se a inclusão de patologias adicionais no treinamento altera a robustez diagnóstica do modelo. Da mesma forma, nem a classe Normal nem a classe Infarto do Miocárdio produzidas pelo modelo devem ser interpretadas como diagnóstico clínico definitivo: as três classes representam uma ferramenta de auxílio ao diagnóstico, cujo resultado é destinado a apoiar, e não substituir, a avaliação de um profissional de saúde qualificado.

2.4 Aprendizado de Máquina Aplicado à Análise de ECG

O uso de técnicas de aprendizado de máquina na análise de sinais de eletrocardiograma tem se intensificado nas últimas décadas, impulsionado pela disponibilidade de bases de dados clínicas digitais e pelo aumento da capacidade computacional disponível para treinamento de modelos complexos (RIBEIRO et al., 2020). Nas primeiras abordagens, a classificação automática de ECG era baseada na extração manual de características, incluindo amplitudes, intervalos temporais, medidas estatísticas e descritores morfológicos obtidos a partir do sinal eletrocardiográfico. Esses atributos eram posteriormente utilizados por classificadores tradicionais, como Máquinas de Vetores de Suporte (SVM), Árvores de Decisão e Redes Neurais Multicamadas (MLP), que em conjunto reportam acurácias tipicamente por volta de 90% na classificação de batimentos cardíacos, a depender da base de dados e do conjunto de atributos utilizado (LUZ et al., 2016).

Com o avanço do aprendizado profundo, as Redes Neurais Convolucionais (CNNs) passaram a ocupar papel central na análise automática de sinais biomédicos. Diferentemente dos métodos tradicionais, as CNNs realizam aprendizado hierárquico de representações diretamente a partir dos dados de entrada, reduzindo a dependência de atributos definidos manualmente (LECUN; BENGIO; HINTON, 2015). Essa característica favo-

rece a identificação automática de padrões morfológicos presentes em sinais de ECG e tem motivado sua ampla utilização em tarefas de detecção de arritmias, classificação de patologias cardíacas e identificação de infarto do miocárdio (HANNUN et al., 2019; RIBEIRO et al., 2020). Por outro lado, essas arquiteturas também apresentam limitações, como a necessidade de grandes volumes de dados rotulados para treinamento, maior custo computacional em relação a métodos tradicionais, e menor interpretabilidade das decisões do modelo em comparação a atributos extraídos manualmente (LECUN; BENGIO; HINTON, 2015).

A evolução recente da literatura demonstra uma transição gradual de modelos baseados exclusivamente em atributos manuais para arquiteturas capazes de realizar aprendizado fim a fim. Trabalhos mais recentes têm explorado tanto representações bidimensionais do ECG, obtidas por transformadas tempo-frequência, quanto abordagens que processam diretamente os sinais unidimensionais. Nesse contexto, Sheth et al. (SHETH et al., 2024) combinaram a Transformada Wavelet Discreta com uma CNN unidimensional para detecção de infarto do miocárdio na base PTB-XL, alcançando desempenho superior a 95% em métricas de classificação binária. Resultados semelhantes foram observados por Aghababaei et al. (AGHABABAEI et al., 2025), que empregaram uma arquitetura híbrida CNN-GRU para identificação automática de infarto, reportando acurácia superior a 99% em cenários experimentais controlados.

Embora esses resultados demonstrem o elevado potencial do aprendizado profundo para apoio ao diagnóstico cardiovascular, observa-se que grande parte dos estudos recentes formula o problema como uma tarefa binária, distinguindo apenas sinais normais de sinais associados ao infarto. Essa simplificação reduz a complexidade do espaço de decisão e tende a produzir métricas elevadas de desempenho, porém não representa adequadamente o ambiente clínico real, no qual diversas patologias cardíacas podem apresentar alterações eletrocardiográficas semelhantes às observadas em eventos isquêmicos (WERTLI et al., 2019; SAMESSIMA et al., 2022).

Nos últimos anos, alguns trabalhos passaram a investigar cenários diagnósticos mais abrangentes utilizando bases de ECG de grande escala. Sinha et al. (SINHA et al., 2023) propuseram o DASMCC, um classificador multiclasse baseado em características de séries temporais e na técnica SMOTE para balanceamento, distinguindo quatro categorias de doenças cardiovasculares (Infarto do Miocárdio, Hipertrofia, Distúrbios de Condução e Alterações ST-T) a partir de ECG de 12 derivações. Smigiel et al. (SMIGIEL; PAŁCZYŃSKI; LEDZIŃSKI, 2021) avaliaram diferentes arquiteturas profundas utilizando a base PTB-XL em cenários com 2, 5 e 20 classes diagnósticas. Os autores observaram uma redução progressiva da acurácia à medida que a complexidade da tarefa aumentava, obtendo 89,2% de acurácia para classificação binária, 76,5% para cinco classes e 69,8% para vinte classes. Esses resultados evidenciam o impacto do aumento do espaço de decisão

sobre o desempenho dos classificadores e demonstram que tarefas multiclasse representam um desafio substancialmente maior quando comparadas à formulação binária tradicional.

Apesar desses avanços, ainda é limitada a quantidade de trabalhos que investigam explicitamente o impacto da inclusão de outras patologias cardíacas no processo de detecção do infarto do miocárdio. Em muitos estudos, condições como bloqueios de ramo, hipertrofias ventriculares e alterações de repolarização são excluídas do treinamento ou agrupadas de forma secundária, reduzindo a representatividade clínica dos cenários avaliados. Dessa forma, permanece em aberto a investigação sobre como a inclusão explícita dessas condições influencia a robustez diagnóstica dos classificadores.

Neste contexto, o presente trabalho adota uma formulação multiclasse composta por três categorias diagnósticas: Normal, Infarto do Miocárdio e Outras Patologias. Essa estratégia busca aproximar o processo de classificação das condições encontradas em ambientes reais de triagem clínica, permitindo avaliar não apenas a capacidade de identificar eventos isquêmicos, mas também a habilidade do modelo em distinguir o infarto de outras alterações cardíacas potencialmente confundidoras.


3 Metodologia

Este capítulo apresenta os procedimentos adotados para construção, treinamento e avaliação dos modelos utilizados neste trabalho. Inicialmente é descrita a base de dados utilizada e o processo de definição das classes. Em seguida, são apresentadas as etapas de pré-processamento dos sinais, particionamento dos dados, arquiteturas avaliadas, estratégias experimentais e métricas empregadas na avaliação dos modelos.

3.1 Visão Geral da Metodologia

A metodologia proposta foi estruturada para investigar o impacto da inclusão de uma classe adicional de patologias cardíacas na detecção automática de infarto do miocárdio. Para isso, foram comparadas duas formulações do problema: uma abordagem binária, composta pelas classes Normal e Infarto do Miocárdio, e uma abordagem multi-classe, composta pelas classes Normal, Infarto do Miocárdio e Outras Patologias. A Figura 5 apresenta uma visão geral das etapas desenvolvidas neste trabalho.

Figura 5 – Fluxo geral da metodologia empregada neste trabalho.



Fonte: Autoria Própria.

Inicialmente, os sinais de ECG foram obtidos da base pública PTB-XL. Em seguida, foi realizada a seleção das classes de interesse e o pré-processamento dos sinais, incluindo filtragem e normalização. Após a divisão dos dados em conjuntos de treinamento e validação, os modelos foram treinados e avaliados por meio de métricas de classificação e análise das matrizes de confusão.

3.2 Base de Dados

Os experimentos foram conduzidos utilizando a base pública PTB-XL (WAGNER et al., 2020), atualmente uma das maiores bases de eletrocardiogramas de 12 derivações

disponíveis para pesquisa. A base contém 21.837 registros clínicos obtidos de 18.885 pacientes distintos, coletados pelo Hospital Universitário de Erlangen, na Alemanha, ao longo de um período de aproximadamente sete anos, entre outubro de 1989 e junho de 1996, utilizando equipamentos do fabricante Schiller AG. A população coberta pela base é equilibrada entre os sexos (52% homens e 48% mulheres) e abrange uma ampla faixa etária, de 0 a 95 anos, com idade mediana de 62 anos. Cada registro foi anotado por até dois cardiologistas.

Por se tratar de uma base coletada em um único centro clínico, na Alemanha, e em um período específico, sua distribuição demográfica e o perfil de equipamentos de aquisição não são necessariamente representativos de outras populações ou de outros contextos clínicos.

Cada exame possui duração aproximada de 10 segundos e foi adquirido utilizando as 12 derivações convencionais do ECG. Os sinais são disponibilizados pela PTB-XL em duas taxas de amostragem, 100 Hz e 500 Hz, com resolução de 16 bits. Neste trabalho foi utilizada a versão amostrada a 500 Hz, compatível com as 5000 amostras por derivação descritas. Além dos sinais, a base disponibiliza informações clínicas e diagnósticas estruturadas segundo o padrão SCP-ECG, permitindo a organização dos registros em diferentes categorias diagnósticas.

A escolha da PTB-XL deve-se à sua diversidade clínica, disponibilidade pública e ampla utilização na literatura recente de aprendizado profundo aplicado ao ECG. Essas características tornam a base adequada para investigar cenários de classificação mais próximos da prática clínica, especialmente quando se deseja avaliar a influência da presença de diferentes patologias cardíacas sobre o desempenho dos modelos.

Neste estudo foram considerados 19.610 registros rotulados, de um total de 21.837 disponíveis na base. A diferença de 2.227 registros corresponde a exames cujos rótulos diagnósticos não se enquadram em nenhuma das três classes definidas neste trabalho.

3.3 Definição das Classes

Foram definidas três classes. A Classe 0 corresponde aos registros classificados como normalidade (*NORM*) segundo a taxonomia da PTB-XL. A Classe 1 corresponde aos registros associados ao infarto do miocárdio. Foram agrupadas nessa categoria as subclasses AMI (*Anterior Myocardial Infarction*), IMI (*Inferior Myocardial Infarction*), LMI (*Lateral Myocardial Infarction*) e PMI (*Posterior Myocardial Infarction*). A Classe 2, denominada Outras Patologias, reúne registros eletrocardiográficos associados a alterações cardíacas distintas do infarto do miocárdio.

Essa formulação de três classes se diferencia da abordagem adotada por Smigiel et al. (SMIGIEL; PAŁCZYŃSKI; LEDZIŃSKI, 2021), que avaliaram cenários com 2, 5 e

20 classes diagnósticas na mesma base PTB-XL. Enquanto os cenários de 5 e 20 classes daqueles autores mantêm a granularidade original das superclasses e subclasses da PTB-XL, a formulação multiclasse deste trabalho agrupa deliberadamente condições não associadas ao infarto em uma única classe – Outras Patologias. Essa escolha simplifica o espaço de decisão em relação aos cenários de 5 e 20 classes, mas preserva, em relação ao cenário puramente binário, a distinção essencial entre normalidade, infarto e outra alteração cardíaca.

Essa categoria engloba distúrbios de condução, como bloqueios fasciculares anteriores e posteriores esquerdos (LAFB/LPFB), bloqueio incompleto de ramo direito (IRBBB), atraso inespecífico da condução intraventricular (IVCD), bloqueios completos dos ramos direito e esquerdo (CRBBB e CLBBB), síndrome de Wolff-Parkinson-White (WPW), bloqueio incompleto de ramo esquerdo (ILBBB) e bloqueios atrioventriculares (AVB). Também inclui alterações de repolarização e do segmento ST (STTC), hipertrofias ventriculares direita e esquerda (RVH e LVH), sobrecarga ou aumento atrial esquerdo (LAO/LAE), alterações isquêmicas não classificadas como infarto (ISCA) e padrões eletrocardiográficos compatíveis com hipertrofia secundária (SEHYP), conforme os rótulos diagnósticos disponíveis na base PTB-XL. A Figura 6 apresenta exemplos representativos das três classes consideradas neste estudo.

A distribuição final dos registros foi:

- Classe 0 – Normal: 9.073 registros;
- Classe 1 – Infarto do Miocárdio: 2.559 registros;
- Classe 2 – Outras Patologias: 7.978 registros.


Para lidar com o desbalanceamento entre as classes (9.073, 2.559 e 7.978 registros, respectivamente), foi utilizada ponderação de classes (*class weight*) na função de perda durante o treinamento, atribuindo maior peso a exemplos das classes minoritárias (Infarto e, em menor grau, Outras Patologias) proporcionalmente à sua frequência inversa no conjunto de treinamento.

3.4 Pré-processamento dos Sinais

Os sinais de ECG provenientes da base PTB-XL foram submetidos a uma etapa de pré-processamento antes do treinamento dos modelos. O objetivo dessa etapa foi reduzir interferências associadas ao processo de aquisição e padronizar os registros utilizados pelos classificadores.

Inicialmente, foi aplicado um filtro digital Butterworth passa-faixa de quarta ordem, com frequências de corte de 0,67 Hz e 40 Hz. A frequência inferior foi escolhida

Figura 6 – Exemplos representativos das classes utilizadas no estudo: ECG normal (NORM), infarto do miocárdio inferior (IMI) e exemplos da classe *Outras Patologias* (CLBBB, LVH e ISCA). A figura ilustra a diversidade morfológica presente na Classe 2, reforçando sua relevância na formulação multiclasse.



Fonte: Autoria Própria.

para reduzir oscilações associadas à variação da linha de base, enquanto a frequência superior foi utilizada para atenuar componentes de alta frequência relacionadas a ruídos musculares e interferências presentes durante a aquisição do sinal.

Após a filtragem, cada registro foi normalizado individualmente pela sua amplitude máxima absoluta. Esse procedimento foi adotado para reduzir diferenças de escala entre pacientes e minimizar a influência de variações de amplitude decorrentes do posicionamento dos eletrodos ou de características individuais de aquisição.

Para um sinal discreto $x(n)$, a normalização foi realizada segundo:

$$x_{norm}(n) = \frac{x(n)}{\max(|x(n)|)} \quad (3.1)$$

Como consequência, os valores de amplitude passaram a estar limitados ao intervalo $[-1, 1]$, favorecendo a estabilidade numérica durante o treinamento das redes neurais.

A normalização individual, por preservar apenas a forma relativa do sinal e não sua amplitude absoluta, pode atenuar informações de amplitude potencialmente relevantes para certas condições (como hipertrofias, que se manifestam por aumento de amplitude do QRS). Essa escolha foi feita para reduzir a variabilidade decorrente de diferenças de ganho e posicionamento de eletrodos entre exames, priorizando a padronização da escala de entrada da rede em detrimento da preservação da amplitude absoluta; uma normalização global (por exemplo, por um fator fixo comum a todos os registros) poderia preservar essa informação.

3.5 Particionamento dos Dados

Após o pré-processamento, os registros foram divididos em conjuntos de treinamento e validação. A divisão foi realizada utilizando a proporção de 80% dos registros para treinamento e 20% para validação. Para evitar vazamento de informação entre os conjuntos, a separação foi realizada em nível de paciente. Dessa forma, registros pertencentes ao mesmo indivíduo não aparecem simultaneamente nos conjuntos de treinamento e validação.

Essa estratégia é particularmente importante em aplicações biomédicas, uma vez que diferentes exames de um mesmo paciente podem compartilhar características morfológicas específicas que não necessariamente representam capacidade de generalização do modelo. Além disso, foi empregada estratificação por classe, preservando aproximadamente a distribuição original dos rótulos em ambos os conjuntos. Essa abordagem reduz o risco de viés decorrente de distribuições artificiais de classes durante o treinamento e avaliação.

3.6 Arquitetura da Rede Neural

Os experimentos realizados neste trabalho utilizam uma arquitetura baseada em Redes Neurais Convolucionais Unidimensionais (1D-CNN), desenvolvida para processamento de sinais de ECG multicanais. A mesma arquitetura foi empregada em todos os cenários experimentais, permitindo que a comparação entre os resultados reflita exclusivamente o impacto da formulação do problema de classificação.


A escolha de uma arquitetura convolucional foi motivada pela capacidade das convoluções unidimensionais de extrair automaticamente padrões morfológicos presentes nos sinais eletrocardiográficos, incluindo características associadas às ondas, segmentos e intervalos do ECG. Além disso, arquiteturas convolucionais apresentam bom desempenho em tarefas de classificação de sinais biomédicos e têm sido amplamente utilizadas em

aplicações envolvendo ECG (HANNUN et al., 2019; RIBEIRO et al., 2020). A entrada da rede consiste em sinais de ECG de 12 derivações contendo 5000 amostras temporais por derivação, correspondendo ao registro completo de 10 segundos adquirido a 500 Hz, sem segmentação adicional do sinal.

A definição da arquitetura final foi conduzida principalmente por um processo empírico de tentativa e erro, no qual o número de blocos convolucionais, a quantidade de filtros por camada e a taxa de dropout foram ajustados iterativamente a partir do desempenho observado no conjunto de validação. O ponto de partida desse processo foi a arquitetura híbrida CNN-BiLSTM proposta por Hasbullah et al. (HASBULLAH; ZAHID; MANDALA, 2023). Ao longo dos experimentos, no entanto, o componente recorrente (BiLSTM) foi removido e a profundidade e a largura dos blocos convolucionais foram substancialmente modificadas, resultando na arquitetura puramente 1D-CNN aqui descrita, que já não guarda semelhança estrutural direta com o trabalho que a inspirou inicialmente.

Os blocos convolucionais realizam uma extração hierárquica de características, permitindo que padrões locais sejam progressivamente combinados em representações mais complexas ao longo da rede. Após a etapa convolucional, é aplicada uma operação de Global Average Pooling, responsável por reduzir a dimensionalidade das características extraídas. Por fim, uma camada totalmente conectada produz a classificação final dos registros. A Figura 7 apresenta a arquitetura geral utilizada nos experimentos.

Figura 7 – Arquitetura da rede convolucional utilizada neste trabalho.



Fonte: Autoria Própria.

Na Figura 7, o parâmetro k indica o tamanho do *kernel* (janela de convolução)

utilizado em cada camada Conv1D, fixado em $k = 4$ em todos os blocos convolucionais.

A Tabela 1 apresenta a configuração detalhada das camadas empregadas na arquitetura proposta.

Tabela 1 – Resumo da arquitetura do modelo multiclasse proposto.


Camada	Shape de saída	Parâmetros
Permute	(None, 5000, 12)	0
Conv1D + BN + ReLU	(None, 4997, 16)	848
MaxPooling1D	(None, 1249, 16)	0
Conv1D + BN + ReLU	(None, 1246, 32)	2.208
MaxPooling1D	(None, 311, 32)	0
Conv1D + BN + ReLU	(None, 308, 64)	8.512
MaxPooling1D	(None, 77, 64)	0
Conv1D + BN + ReLU	(None, 74, 128)	33.408
MaxPooling1D	(None, 18, 128)	0
Conv1D + BN + ReLU	(None, 15, 256)	132.352
GlobalAveragePooling	(None, 256)	0
Dense + ReLU	(None, 64)	16.448
Dropout ($p = 0,3$)	(None, 64)	0
Dense + Softmax	(None, 3)	195
Total		193.971

Na coluna "Shape de saída", o último valor de cada linha corresponde ao número de filtros (canais) daquela camada, e não a saídas do modelo; a única exceção é a última linha, cujo valor (3) representa o número de classes de saída do classificador.

3.7 Estratégias Experimentais


A hipótese central deste trabalho é que a inclusão explícita de sinais pertencentes a outras patologias cardíacas durante o treinamento pode produzir modelos mais robustos para cenários reais de triagem clínica.

Para investigar essa hipótese foram definidos dois cenários experimentais. No primeiro cenário foi utilizada uma formulação binária composta exclusivamente pelas classes Normal e Infarto do Miocárdio. Esse cenário representa a abordagem predominante encontrada na literatura e foi utilizado como baseline experimental. A Figura 8 apresenta o fluxo do cenário binário.

Figura 8 – Fluxo experimental do cenário binário.

Fonte: Autoria Própria.

No segundo cenário foi empregada a formulação multiclasse proposta, composta pelas classes Normal, Infarto do Miocárdio e Outras Patologias. Nesse caso, o objetivo foi permitir que o modelo aprendesse explicitamente padrões patológicos que não correspondem à normalidade nem ao infarto do miocárdio. Espera-se que essa estratégia reduza a tendência do classificador de forçar sinais anômalos para uma das classes do cenário binário. A Figura 9 apresenta o fluxo do cenário multiclasse.

Figura 9 – Fluxo experimental do cenário multiclasse.

Fonte: Autoria Própria.

A comparação entre os cenários foi realizada por meio das métricas de classificação e da análise das matrizes de confusão. Particular atenção foi dada aos erros envolvendo a classe Infarto do Miocárdio, uma vez que classificações incorretas nessa categoria possuem maior impacto potencial em aplicações de apoio à decisão clínica.

3.8 Configuração do Treinamento

Os modelos foram implementados utilizando o framework PyTorch (versão 2.3.0). Durante o treinamento foi utilizada a função de perda Categorical Cross-Entropy para o cenário multiclasse e Binary Cross-Entropy para o cenário binário.

O treinamento do modelo foi realizado utilizando o otimizador Adam, com taxa de aprendizado de 0,0001, tamanho de lote de 64 e 100 épocas de treinamento com utilização de critérios de parada antecipada (*early stopping*). Os experimentos foram executados em ambiente Linux, utilizando aceleração por GPU NVIDIA RTX 3060 com suporte a CUDA 12.1.

Para reduzir o risco de sobreajuste e melhorar a capacidade de generalização do modelo, foi empregada regularização L2 nos parâmetros treináveis da rede (GOODFELLOW; BENGIO; COURVILLE, 2016). Essa técnica adiciona um termo de penalização à função de perda proporcional à magnitude dos pesos, desencorajando a formação de parâmetros excessivamente elevados e favorecendo soluções mais estáveis durante o treinamento.

3.8.1 Métricas de avaliação

O desempenho dos modelos foi avaliado por meio da acurácia global, precisão macro, sensibilidade macro e F1-score macro. As métricas macro foram adotadas devido ao desbalanceamento entre as classes, pois atribuem o mesmo peso a cada classe durante o cálculo do desempenho médio.

Para cada classe $c \in \{0, 1, 2\}$, foram considerados verdadeiros positivos (TP_c), falsos positivos (FP_c), falsos negativos (FN_c) e verdadeiros negativos (TN_c). A acurácia global foi calculada por:

$$Acc = \frac{\sum_{c=0}^2 TP_c}{N} \quad (3.2)$$

em que N representa o número total de amostras avaliadas.

A precisão e a sensibilidade por classe foram definidas, respectivamente, por:

$$Prec_c = \frac{TP_c}{TP_c + FP_c} \quad (3.3)$$

$$Recall_c = \frac{TP_c}{TP_c + FN_c} \quad (3.4)$$

As médias macro foram calculadas por:

$$Prec_{macro} = \frac{1}{3} \sum_{c=0}^2 Prec_c \quad (3.5)$$

$$Recall_{macro} = \frac{1}{3} \sum_{c=0}^2 Recall_c \quad (3.6)$$

O F1-score por classe foi calculado como a média harmônica entre precisão e sensibilidade:

$$F1_c = 2 \cdot \frac{Prec_c \cdot Recall_c}{Prec_c + Recall_c} \quad (3.7)$$

e o F1-score macro foi definido por:

$$F1_{macro} = \frac{1}{3} \sum_{c=0}^2 F1_c \quad (3.8)$$

Além das métricas quantitativas, foram analisadas as matrizes de confusão normalizadas dos modelos avaliados. Essa análise permite identificar quais classes apresentam maior taxa de confusão e fornece uma interpretação mais detalhada do comportamento dos classificadores do que métricas globais isoladas.

4 Resultados e Discussão

Este capítulo apresenta os resultados obtidos nos experimentos de classificação automática de sinais de ECG. A análise foi organizada em dois cenários: o primeiro considera a formulação binária, composta pelas classes Normal e Infarto do Miocárdio; o segundo considera a formulação multiclasse proposta, composta pelas classes Normal, Infarto do Miocárdio e Outras Patologias.


Em ambos os cenários, o objetivo principal foi avaliar o impacto da formulação do problema sobre o comportamento do classificador. Portanto, a comparação não se limita à acurácia global, mas considera também a capacidade do modelo de lidar com sinais patológicos que não pertencem diretamente à classe de infarto.

4.1 Cenário Binário: Normal versus Infarto

Inicialmente, avaliou-se a formulação binária do problema, na qual o modelo foi treinado apenas com registros das classes Normal e Infarto do Miocárdio. Essa configuração representa uma abordagem simplificada de detecção automática de infarto, pois restringe o espaço de decisão do classificador a duas saídas possíveis.

A Figura 10 apresenta as curvas de perda do modelo binário ao longo do treinamento. A perda de validação atingiu seu menor valor por volta da 19^a época; a partir desse ponto, observa-se estabilização seguida de leve tendência de aumento na perda de validação, com oscilações mais pronunciadas ao final do treinamento, enquanto a perda de treinamento continua decrescendo, padrão característico de início de sobreajuste.

Figura 10 – Curvas de perda do modelo binário ao longo do treinamento, com early stopping monitorando a perda de validação.



Fonte: Autoria Própria.

A Tabela 2 apresenta o desempenho obtido nesse cenário.

Tabela 2 – Desempenho do modelo no cenário binário Normal versus Infarto.

Métrica	Valor (%)
Acurácia de treinamento	97,44
Acurácia de validação	95,12
Precisão	90,24
Recall	94,11
F1-Score	92,13

Os resultados indicam que o modelo apresentou desempenho elevado quando avaliado no mesmo espaço de decisão utilizado durante o treinamento. A acurácia de validação de 95,12% mostra que o classificador foi capaz de separar, com baixa taxa de erro, sinais normais e sinais associados ao infarto do miocárdio.


Entretanto, essa avaliação não considera a presença de outras alterações cardíacas. Como o modelo binário possui apenas duas saídas, qualquer sinal apresentado ao classificador deve ser atribuído obrigatoriamente à classe Normal ou à classe Infarto, mesmo quando o exame contém uma patologia diferente daquelas utilizadas durante o treinamento.

Para avaliar essa limitação, o modelo binário foi exposto a sinais pertencentes à classe Outras Patologias. Esses sinais não participaram da formulação binária original e representam registros anômalos que não correspondem diretamente ao infarto do miocár-

dio. A Figura 11 apresenta o comportamento do modelo binário quando exposto a esses sinais.

Para avaliar essa limitação, o modelo binário foi exposto a sinais pertencentes à classe Outras Patologias. Esses sinais não participaram do treinamento nem da validação da formulação binária original – ou seja, não foram usados para ajustar os pesos desse modelo em nenhum momento. É importante frisar que este trabalho não constrói um conjunto de teste independente adicional para esse experimento: os sinais de Outras Patologias correspondem ao mesmo subconjunto de validação (20% dos registros, particionados por paciente) já utilizado na avaliação do cenário multiclasse, apenas reclassificados pelo modelo binário, que nunca teve acesso a exemplos dessa classe durante o treinamento.

Figura 11 – Matriz de confusão normalizada do modelo binário quando exposto a sinais da classe Outras Patologias.



Fonte: Autoria Própria.

Observa-se que os sinais pertencentes à classe Outras Patologias foram distribuídos de forma relativamente equilibrada entre as duas classes disponíveis no modelo (57% Normal, 43% Infarto). Como o treinamento binário utilizou ponderação de classes (*class weight*) para compensar o desbalanceamento entre Normal e Infarto, essa distribuição não pode ser atribuída a um viés residual de frequência das classes de treinamento; ela sugere, em vez disso, que uma parcela considerável dos sinais de Outras Patologias possui morfologia suficientemente próxima às alterações associadas ao infarto para confundir o classificador binário.

Do ponto de vista de um sistema de apoio à decisão, esse comportamento é relevante. Quando um sinal patológico é classificado como Normal, há risco de subestimar uma alteração cardíaca. Por outro lado, quando esse mesmo tipo de sinal é classificado

como Infarto, ocorre aumento de falsos positivos para a classe de maior criticidade clínica. Assim, embora o cenário binário apresente maior acurácia global, sua confiabilidade é reduzida quando sinais fora do espaço de treinamento são considerados.

4.2 Cenário Multiclasse: Normal, Infarto e Outras Patologias

No segundo experimento, avaliou-se a formulação multiclasse proposta neste trabalho. Nesse cenário, o modelo foi treinado com três classes: Normal, Infarto do Miocárdio e Outras Patologias. A inclusão da terceira classe tem como objetivo permitir que o classificador represente explicitamente sinais patológicos não associados diretamente ao infarto.


A Tabela 3 apresenta o desempenho global obtido pelo modelo multiclasse.

Tabela 3 – Desempenho global do modelo multiclasse proposto.

Métrica	Valor (%)
Acurácia de treinamento	88,70
Acurácia de validação	82,71
Precisão macro	79,83
Recall macro	82,73
F1-Score macro	80,84


A acurácia de validação do modelo multiclasse foi de 82,71%, inferior à obtida no cenário binário. Essa redução era esperada, pois a inclusão da classe Outras Patologias aumenta a complexidade do problema. Além de separar sinais normais e sinais de infarto, o modelo passa a lidar com um conjunto heterogêneo de alterações cardíacas, composto por padrões morfológicos distintos.

A Figura 12 apresenta as curvas de perda do modelo multiclasse ao longo do treinamento. As curvas indicam redução da perda nas primeiras épocas, seguida de estabilização. A proximidade entre as curvas de treinamento e validação sugere que o modelo convergiu sem evidências severas de sobreajuste, embora os resultados indiquem margem para melhoria na generalização, principalmente na separação entre Infarto do Miocárdio e Outras Patologias.

Figura 12 – Curvas de perda do modelo multiclasse ao longo do treinamento.

Fonte: Autoria Própria.

A matriz de confusão normalizada do modelo multiclasse é apresentada na Figura 13.

Figura 13 – Matriz de confusão normalizada do modelo multiclasse.

Fonte: Autoria Própria.

A análise da matriz de confusão mostra que a Classe Normal obteve a maior taxa de acerto, com recall de 90,27%. A classe Infarto do Miocárdio apresentou recall de 83,92%, resultado importante por se tratar da classe de interesse principal deste trabalho. A classe Outras Patologias apresentou recall de 74,00%, valor inferior ao das demais classes, mas que corresponde à identificação correta de aproximadamente três em cada quatro registros patológicos não associados ao infarto – valor consideravelmente superior ao de uma atribuição aleatória entre as três classes (33%), o que indica que o modelo aprendeu padrões discriminativos para essa categoria, ainda que com desempenho inferior ao das classes Normal e Infarto.

A Tabela 4 apresenta o desempenho por classe do modelo multiclasse.

Tabela 4 – Desempenho por classe do modelo multiclasse.

Classe	Registros	Precisão (%)	Recall (%)	F1-Score (%)
Normal	9073	85,80	90,27	87,98
Infarto	2559	68,47	83,92	75,41
Outras Patologias	7978	85,22	74,00	79,21
Macro	–	79,83	82,67	80,84

A classe Normal apresentou o melhor equilíbrio entre precisão, recall e F1-score. Esse comportamento indica que os sinais normais possuem padrões mais distinguíveis em relação às demais classes. A classe Infarto do Miocárdio apresentou recall de 83,92%, indicando que a maior parte dos registros de infarto foi corretamente identificada. No entanto, sua precisão de 68,47% mostra que parte dos sinais classificados como infarto pertence, na verdade, a outras classes.

Esse comportamento está associado à semelhança morfológica entre alguns padrões eletrocardiográficos de infarto e alterações pertencentes à classe Outras Patologias. Como essa terceira classe reúne diferentes condições cardíacas, há maior variabilidade interna, o que torna sua separação mais difícil. Ainda assim, o modelo obteve precisão de 85,22% para Outras Patologias, indicando que, quando atribui um registro a essa classe, a decisão tende a ser consistente.

4.3 Comparação entre as Formulações Binária e Multiclasse

A Tabela 5 apresenta a comparação entre os dois cenários avaliados.

Tabela 5 – Comparação entre os cenários binário e multiclasse.

Métrica	Binário CNN(0,1)	Multiclasse CNN(0,1,2)
Acurácia de validação	95,12	82,71
Precisão	90,24	79,83
Recall	94,11	82,73
F1-Score	92,13	80,84

A formulação binária apresentou desempenho superior em todas as métricas globais. Entretanto, essa vantagem deve ser analisada considerando que o problema binário é menos complexo. Nesse cenário, o modelo precisa distinguir apenas entre duas classes, sem representar outros padrões patológicos presentes em sinais reais de ECG.

A principal limitação do modelo binário aparece quando sinais de outras patologias são apresentados ao classificador. Como não há uma saída específica para esses casos, 57% desses sinais foram classificados como Normal e 43% como Infarto. Esse resultado mostra que a alta acurácia binária não implica, necessariamente, maior segurança diagnóstica em um cenário de triagem com maior diversidade clínica.

Por outro lado, o modelo multiclasse apresenta métricas globais menores, mas oferece uma formulação mais compatível com o problema clínico. A presença da classe Outras Patologias permite que sinais anômalos não associados diretamente ao infarto sejam representados no espaço de decisão, reduzindo a necessidade de forçar esses registros para Normal ou Infarto.

Assim, a comparação entre os cenários evidencia que a acurácia isolada não é suficiente para avaliar a robustez do classificador. O modelo binário otimiza o desempenho em um problema simplificado, enquanto o modelo multiclasse amplia o espaço diagnóstico e permite uma avaliação mais próxima da triagem clínica.

4.4 Discussão Geral

Os resultados obtidos mostram que a formulação do problema exerce influência direta sobre o comportamento do classificador. No cenário binário, o modelo alcançou acurácia de validação de 95,12%, mas apresentou limitação ao lidar com sinais patológicos não utilizados durante o treinamento. Esses sinais foram distribuídos entre as duas classes disponíveis, evidenciando que o classificador não possui mecanismo explícito para reconhecer padrões fora do espaço binário.

No cenário multiclasse, a acurácia foi reduzida para 82,71%, mas o modelo passou a distinguir três categorias diagnósticas. Essa redução não deve ser interpretada apenas como perda de desempenho, pois a tarefa avaliada é mais difícil. A inclusão da classe Outras Patologias introduz maior variabilidade morfológica e aproxima o problema de uma situação de triagem, na qual diferentes alterações cardíacas podem estar presentes.

A análise por classe mostra que o modelo multiclasse manteve recall de 83,92% para Infarto do Miocárdio, ao mesmo tempo em que identificou 74,00% dos registros pertencentes a Outras Patologias. Esse resultado indica que a terceira classe contribui para representar padrões patológicos adicionais, ainda que exista confusão entre infarto e outras alterações cardíacas.

Dessa forma, os resultados sustentam a hipótese de que a formulação multiclasse

fornece uma avaliação mais adequada da robustez diagnóstica do sistema. Embora o modelo binário apresente maior acurácia, ele opera em um espaço de decisão restrito. O modelo multiclasse, por sua vez, considera uma condição mais próxima da prática clínica, na qual o classificador deve diferenciar exames normais, registros associados ao infarto e sinais patológicos que exigem avaliação médica adicional.

5 Conclusão

Este trabalho apresentou uma abordagem baseada em redes neurais convolucionais para detecção automática de infarto do miocárdio em sinais de eletrocardiograma, investigando o impacto da inclusão de uma terceira classe diagnóstica composta por outras patologias cardíacas. Para isso, foram comparados dois cenários experimentais utilizando registros da base pública PTB-XL: uma formulação binária, composta pelas classes Normal e Infarto do Miocárdio, e uma formulação multiclasse, composta pelas classes Normal, Infarto do Miocárdio e Outras Patologias.

Os resultados obtidos mostraram que o cenário binário apresentou melhor desempenho global, alcançando acurácia de validação de 95,12%, precisão de 90,24%, recall de 94,11% e F1-score de 92,13%. Entretanto, a análise realizada com sinais pertencentes à classe Outras Patologias evidenciou uma limitação importante dessa formulação. Como o modelo foi treinado para reconhecer apenas duas categorias, registros patológicos não associados ao infarto foram obrigatoriamente classificados como Normal ou Infarto, resultando em interpretações potencialmente inadequadas para aplicações de apoio à decisão clínica.

A formulação multiclasse apresentou acurácia de validação de 82,71%, com precisão macro de 79,83%, recall macro de 82,73% e F1-score macro de 80,84%. Embora esses valores sejam inferiores aos observados no cenário binário, o modelo passou a representar explicitamente uma categoria adicional de sinais anormais, permitindo distinguir registros normais, sinais associados ao infarto e alterações cardíacas pertencentes a outras condições clínicas. A análise da matriz de confusão demonstrou que a rede foi capaz de identificar corretamente uma parcela significativa dos registros pertencentes à classe Outras Patologias, reduzindo a necessidade de forçar esses sinais para as classes Normal ou Infarto.

Os resultados obtidos indicam que a comparação entre formulações binárias e multiclasse não deve ser realizada exclusivamente com base em métricas globais de desempenho. Embora a formulação binária produza maior acurácia, ela opera em um espaço diagnóstico simplificado, no qual sinais patológicos não representados durante o treinamento não possuem uma categoria apropriada de classificação.

A inclusão da classe Outras Patologias resultou em redução das métricas globais de classificação, porém permitiu uma modelagem mais abrangente do espaço diagnóstico e uma representação mais adequada da diversidade de sinais encontrados na prática clínica. Esse comportamento sugere que a utilização de classes adicionais pode contribuir para o desenvolvimento de sistemas de apoio à decisão mais robustos e menos suscetíveis a

interpretações incorretas diante de sinais patológicos não associados diretamente ao infarto do miocárdio.

Como trabalhos futuros, recomenda-se investigar estratégias para melhorar a separação entre as classes Infarto do Miocárdio e Outras Patologias, incluindo técnicas de balanceamento de classes, mecanismos de atenção, arquiteturas mais profundas e abordagens híbridas. Também podem ser exploradas formulações hierárquicas de classificação, nas quais o sistema inicialmente diferencia sinais normais e anormais e, posteriormente, realiza a identificação específica da patologia. Além disso, a validação do modelo em outras bases de dados e em cenários clínicos mais heterogêneos pode contribuir para uma avaliação mais abrangente da capacidade de generalização da abordagem proposta.

REFERÊNCIAS

- ACHARYA, U. R. et al. Automated detection of arrhythmias using different intervals of tachycardia ecg segments with convolutional neural network. *Information Sciences*, v. 405, p. 81–90, 2017.
- AGHABABAEI, Z. et al. Optimizing myocardial infarction detection: A hybrid cnn-gru deep learning approach. *BMC Medical Informatics and Decision Making*, v. 25, p. 408, 2025.
- BLAUS, B. Medical gallery of blausen medical 2014. *Wiki J. Med*, v. 1, n. 10, 2014.
- GAZIANO, T. A. et al. Growing epidemic of coronary heart disease in low- and middle-income countries. In: *Disease Control Priorities in Developing Countries*. 2. ed. Washington, DC: The World Bank, 2010.
- GOLDBERGER, A. L.; GOLDBERGER, Z. D.; SHVILKIN, A. *Goldberger's Clinical Electrocardiography: A Simplified Approach*. 9. ed. [S.l.]: Elsevier, 2018.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016.
- HAMPTON, J. *150 ECG Casos Clínicos*. [S.l.]: Elsevier Brasil, 2014.
- HANNUN, A. Y. et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature Medicine*, v. 25, p. 65–69, 2019.
- HASBULLAH, S.; ZAHID, M. S. M.; MANDALA, S. Detection of myocardial infarction using hybrid models of convolutional neural network and recurrent neural network. *BioMedInformatics*, v. 3, n. 2, p. 478–492, 2023.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, p. 436–444, 2015.
- LUZ, E. J. d. S. et al. Ecg-based heartbeat classification for arrhythmia detection: A survey. *Computer Methods and Programs in Biomedicine*, v. 127, p. 144–164, 2016.
- NETO, M. F. de P. et al. Perfil epidemiológico das internações por infarto agudo do miocárdio entre 2019 e 2023. *Brazilian Journal of Implantology and Health Sciences*, v. 6, n. 4, p. 2287–2296, 2024.
- RIBEIRO, A. H. et al. Automatic diagnosis of the 12-lead ecg using a deep neural network. *Nature Communications*, v. 11, n. 1760, 2020.
- SAMESIMA, N. et al. Diretriz da sociedade brasileira de cardiologia sobre a análise e emissão de laudos eletrocardiográficos – 2022. *Arquivos Brasileiros de Cardiologia*, v. 119, n. 4, p. 638–680, 2022.
- SCHLÄPFER, J.; WELLENS, H. J. Computer-interpreted electrocardiograms: Benefits and limitations. *Journal of the American College of Cardiology*, v. 70, n. 9, p. 1183–1192, 2017.

- SHETH, K. A. et al. Time-frequency transformation integrated with a lightweight convolutional neural network for detection of myocardial infarction. *BMC Medical Imaging*, v. 24, n. 1, 2024.
- SINHA, N. et al. Dasmcc: Data augmented smote multi-class classifier for prediction of cardiovascular diseases using time series features. *IEEE Access*, v. 11, p. 117643–117655, 2023.
- SMIGIEL, S.; PAŁCZYŃSKI, K.; LEDZIŃSKI, D. Ecg signal classification using deep learning techniques based on the ptb-xl dataset. *Entropy*, v. 23, n. 9, p. 1121, 2021.
- THYGESEN, K. et al. Fourth universal definition of myocardial infarction (2018). *Circulation*, v. 138, n. 20, p. e618–e651, 2018.
- VIJAYBASKAR, G.; PUGAZENDI, R. Exploration of several methodologies for ecg signal processing in healthcare. *Journal of Emerging Technologies and Innovative Research (JETIR)*, v. 12, n. 11, November 2025. ISSN 2349-5162. JETIR2511707.
- WAGNER, P. et al. Ptb-xl, a large publicly available electrocardiography dataset. *Scientific Data*, v. 7, n. 154, 2020.
- WERTLI, M. M. et al. Non-cardiac chest pain patients in the emergency department: Do physicians have a plan how to diagnose and treat them? a retrospective study. *PLOS ONE*, v. 14, n. 2, p. e0211615, 2019.
- WHITE, H. D.; CHEW, D. P. Acute myocardial infarction. *The Lancet*, v. 372, n. 9638, p. 570–584, 2008.
- World Health Organization. *Cardiovascular diseases (CVDs)*. 2025. Acesso em: 08 jun. 2026. Disponível em: <[https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))>.

	INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA PARAÍBA
	Campus João Pessoa - Código INEP: 25096850
	Av. Primeiro de Maio, 720, Jaguaribe, CEP 58015-435, João Pessoa (PB)
	CNPJ: 10.783.898/0002-56 - Telefone: (83) 3612.1200

Documento Digitalizado Ostensivo (Público)

TCC com folha de aprovação e ficha catalográfica

Assunto:	TCC com folha de aprovação e ficha catalográfica
Assinado por:	Pedro Antonio
Tipo do Documento:	Anexo
Situação:	Finalizado
Nível de Acesso:	Ostensivo (Público)
Tipo do Conferência:	Cópia Simples

Documento assinado eletronicamente por:
▪ **Pedro Antonio de Andrade da Silva, DISCENTE (20211610015) DE BACHARELADO EM ENGENHARIA ELÉTRICA - JOÃO PESSOA**, em 21/07/2026 15:54:37.

Este documento foi armazenado no SUAP em 21/07/2026. Para comprovar sua integridade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifpb.edu.br/verificar-documento-externo/> e forneça os dados abaixo:

Código Verificador: 1920281
Código de Autenticação: 2b5b7b67e4

