



**José Raimundo Barbosa**

**Classificação da Área Infartada do  
Coração Utilizando *Deep Learning* e  
Parâmetros Extraídos do Espaço de Fases  
e Planos da Representação  
Vectorcardiográfica do ECG**

**João Pessoa – PB**

**Março de 2022**



**José Raimundo Barbosa**

# **Classificação da Área Infartada do Coração Utilizando *Deep Learning* e Parâmetros Extraídos do Espaço de Fases e Planos da Representação Vectorcardiográfica do ECG**

Versão apresentada à banca examinadora para o Exame de Dissertação de Mestrado do Programa de Pós-Graduação em Engenharia Elétrica do Instituto Federal da Paraíba, como requisito parcial necessário à obtenção do grau de Mestre em Ciências no Domínio da Engenharia Elétrica.

Área de Concentração: Processamento de Sinais.

Prof. Dr. Carlos Danilo Miranda Regis

Orientador

João Pessoa - PB, Março de 2022

© José Raimundo Barbosa – jsraimundob@gmail.com


Instituto Federal de Educação, Ciência e Tecnologia da Paraíba  
Programa de Pós Graduação em Engenharia Elétrica

**Classificação da Área Infartada do Coração Utilizando Deep Learning e  
Parâmetros Extraídos do Espaço de Fases e Planos da Representação  
Vectorcardiográfica do ECG**

José Raimundo Barbosa


Dissertação de Mestrado defendida e aprovada em 28/03/2022

Banca examinadora:

Documento assinado digitalmente  
 Carlos Danilo Miranda Regis  
Data: 28/03/2022 08:06:50-0300  
Verifique em <https://verificador.iti.br>


---

Prof. Carlos Danilo Miranda Regis, D. Sc.  
Orientador (IFPB)

Documento assinado digitalmente  
 Luciana Ribeiro Veloso  
Data: 29/03/2022 15:33:48-0300  
Verifique em <https://verificador.iti.br>

---

Profa. Luciana Ribeiro Veloso, D. Sc.  
Membro da banca (UFCEG)

Documento assinado digitalmente  
 Ruan Delgado Gomes  
Data: 29/03/2022 09:15:49-0300  
Verifique em <https://verificador.iti.br>

---

Prof. Ruan Delgado Gomes, D. Sc.  
Membro da banca (IFPB)

João Pessoa, Paraíba, Brasil  
28 de Março de 2022  
 José Raimundo Barbosa

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

B238c      Barbosa, José Raimundo.

Classificação da área infartada do coração utilizando *Deep learning* e parâmetros extraídos do espaço de fases e planos da representação vectorcardiográfica do ECG / José Raimundo Barbosa. – 2022.

80 f. : il.

Dissertação (Mestrado-Engenharia Elétrica) - Instituto Federal de Educação da Paraíba / Programa de Pós-Graduação em Engenharia Elétrica (PPGEE), 2022.

Orientação : Prof<sup>o</sup>. D.r Carlos Danilo Miranda Regis.

1. Patologia cardíaca - estudo. 2. Redes neurais profundas.  
3. Sinais de ECG. 4. Infarto agudo do miocárdio. 5. Eletrocardiograma. I. Título.

CDU 616.12:004.032.26(043)

## Agradecimentos

- ▣ Agradeço a Deus pelas várias oportunidades me concedidas e dificuldades superadas. Principalmente pela saúde e pela minha vida e de meus conhecidos neste momento delicado de pandemia.
- ▣ Agradeço a minha família, em especial à minha mãe, Maria Nazaré, por me ajudar diante das dificuldades e me motivar sempre, apoiar e ensinar com sua grandiosa e valiosa sabedoria de mãe.
- ▣ Agradeço à minha amada esposa Jocélia pela compreensão, dedicação e companheirismo em todos os momentos durante essa jornada, sempre motivando e amparando nos momentos mais difíceis.
- ▣ Ao meu professor e orientador Carlos Danilo Miranda Régis, por toda orientação, apoio e experiência compartilhada durante todos os projetos e pesquisas realizados durante o curso.
- ▣ Agradeço aos integrantes da banca, professor Ruan Gomes, por toda ajuda e conselhos, no meio acadêmico e no meio profissional. E agradeço a professora Luciana Veloso pelos comentários e observações que agregaram conhecimento e oportunidades de melhoras para o trabalho.
- ▣ Agradeço aos meus amigos e colegas de laboratório, excelentes profissionais a quem tenho muito respeito e felicidade em conhecer: Itallo, Wallison, Taína, Ruan Castro, Paloma, Diego, e em especial meu amigo Rafael Duarte, pelo companheirismo e ajuda durante a pesquisa.
- ▣ E finalmente, agradeço ao Instituto Federal da Paraíba, e ao Grupo de Processamento de Sinais Digitais. Estes foram como um segundo lar durante minha graduação e mestrado. Lugar de muito aprendizado e oportunidades para construir grandes amizades que irei carregar por toda a vida.

## Lista de Siglas e Abreviaturas

ACC – Acurácia

AM – Aprendizado de Máquina

AMI – *Anterior Myocardial Infarction*

CNN - *Convolutional Neural Networks*

DNN – *Deep Neural Network*

ECG – Eletrocardiograma

ECO – Ecocardiograma

EF – Espaço de Fases

ESP – Especificidade

FN – Falso Negativo

FP – Falso Positivo

IM – Infarto do Miocárdio

IMI – *Inferior Myocardial Infarction*

LMI – *Lateral Myocardial Infarction*

MLP – *Multilayer perceptron*

OMS – Organização Mundial da Saúde

PDI – Processamento Digital de Imagens

PTB – *Physikalisch-Technische Bundesanstalt*

REF – Reconstrução do Espaço de Fases

RNA – Rede Neural Artificial

ROC – *Receiver Operating Characteristic Curve*

SEN – Sensibilidade

VCG – Vetorcardiograma

VN – Verdadeiro Negativo

VP – Verdadeiro Positivo

XZ – Perspectiva do plano cartesiano XZ

XY – Perspectiva do plano cartesiano XY

YZ – Perspectiva do plano cartesiano YZ

## Lista de Figuras

2.1	Estrutura muscular do coração. . . . .	9
2.2	Funcionamento do coração. . . . .	10
2.3	Sistema de condução do coração. . . . .	11
2.4	Observação dos eventos do ciclo cardíaco a partir diversas técnicas. . . . .	12
2.5	Artérias coronárias. . . . .	13
2.6	Artérias coronárias obstruída. . . . .	14
2.7	Variação de IAM de acordo com a área do miocárdio afetada. . . . .	14
2.8	(a) Disposição dos eletrodos pelo corpo; (b) Perspectivas de observação do músculo cardíaco a partir das derivações. . . . .	15
2.9	(a) Derivações eletrocardiográfica; (b) Forma padrão de uma onda eletrocardiográfica. . . . .	16
2.10	Impacto das fases do IAM na derivação do ECG: (a) Situação normal; (b) Início do IAM; (c) Fase aguda, com lesão transmural; (d) Fase subaguda horas e dias; (e) Fase subaguda semanas; (f) Fase crônica, meses/anos após ocorrência do IAM	17
2.11	Disposição dos eletrodos pelo corpo. . . . .	20
2.12	Representação do vetocardiograma. . . . .	21
3.1	Estrutura de camadas de uma RNA. (a) Camada de entrada. (b) Camadas ocultas. (c) Camada de saída. (d) Neurônio artificial. (e) Função de ativação. . .	24
3.2	Abordagens de DNN investigadas: (a) DNN com dados numéricos resultante dos métodos de análise dos estados caóticos; (b) DNN do com imagens dos planos do VCG. . . . .	27
3.3	Exemplo de matriz de confusão. . . . .	28
4.1	Fluxograma de execução das atividades. . . . .	31



---

4.2	Reconstrução do Espaço de Fases. . . . .	35
4.3	Métodos de extração de parâmetros a partir do REF. . . . .	36
4.4	Exemplo de dilatação morfológica em um plano XZ do VCG. . . . .	38
5.1	Correlação de <i>Pearson</i> dos parâmetros utilizadas. . . . .	40
5.2	Arquitetura da DNN utilizada. . . . .	42
6.1	Métricas de treino e validação para classificação multiclasse. . . . .	44
6.2	Métricas de treino e validação: Normal e AMI. . . . .	46
6.3	Matriz de confusão: Normal e AMI. . . . .	47
6.4	Métricas de treino e validação: Normal e IMI. . . . .	48
6.5	Matriz de confusão: Normal e IMI. . . . .	49
6.6	Métricas de treino e validação: Normal e LMI. . . . .	50
6.7	Matriz de confusão: Normal e LMI. . . . .	51
A.1	Curva ROC: Normal e AMI. . . . .	67
A.2	Curva ROC: Normal e IMI. . . . .	68
A.3	Curva ROC: Normal e LMI. . . . .	68

## Lista de Tabelas

2.1	Tabela com os coeficientes para a matriz de reconstrução Cortez <i>et al.</i> (2014). . . . .	23
4.1	Tabela contendo a relação do número de ECGs por superclasses e subclasses. (*).Acrônimos baseados no nomes das superclasses/subclasses em língua inglesa. . . . .	32
4.2	Parâmetros extraídos a partir dos métodos apresentados por Roopaei <i>et al.</i> (2010). . . . .	38
5.1	Balanceamento das classes. . . . .	41
6.1	Resultados da classificação com todas as classes. . . . .	43
6.2	Resultados da classificação para sinais das classes Normal e AMI. . . . .	45
6.3	Resultados da classificação para sinais das classes Normal e IMI. . . . .	48
6.4	Resultados da classificação para sinais das classes Normal e LMI. . . . .	49
6.5	Métricas de teste para cada classe considerando o plano XY sem aplicação da técnica de PDI. . . . .	52
6.6	Métricas de teste para cada classe considerando o plano XY. . . . .	53
6.7	Métricas de teste para cada classe considerando o plano XZ sem aplicação de técnica de PDI. . . . .	53
6.8	Métricas de teste para cada classe considerando o plano XZ. . . . .	54
6.9	Métricas de teste para cada classe considerando o plano YZ sem aplicação de técnica de PDI. . . . .	54
6.10	Métricas de teste para cada classe considerando o plano YZ. . . . .	55

# Sumário

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Motivação . . . . .	3
1.2	Objetivo Geral . . . . .	4
1.2.1	Objetivos Específicos . . . . .	4
1.3	Estado da Arte . . . . .	4
1.4	Estrutura do Texto . . . . .	5
<b>2</b>	<b>Estudo Cardiovascular</b>	<b>7</b>
2.1	O Coração . . . . .	7
2.1.1	Ciclo Cardíaco . . . . .	10
2.1.2	Infarto Agudo do Miocárdio . . . . .	12
2.2	Eletrocardiograma . . . . .	15
2.3	Vetocardiograma . . . . .	19
2.4	Reconstrução do vetocardiograma a partir do eletrocardiograma . . . . .	21
<b>3</b>	<b>Redes Neurais Profundas</b>	<b>24</b>
3.1	Métricas de Avaliação do Modelo . . . . .	28
<b>4</b>	<b>Metodologia</b>	<b>30</b>
4.1	Aquisição dos Dados . . . . .	31
4.2	Pré-processamento . . . . .	33
4.3	Estratégias de Extração de Parâmetros . . . . .	34
4.3.1	Extração de Parâmetros a partir da Reconstrução do Espaço de Fases . . . . .	34
4.3.2	Planos do VCG . . . . .	37

---

<b>5</b>	<b>Configuração e execução dos experimentos</b>	<b>39</b>
5.1	Configuração do conjunto de dados . . . . .	39
<b>6</b>	<b>Análise dos Resultados</b>	<b>43</b>
6.1	Classificação multiclasse . . . . .	43
6.2	Classificações binárias . . . . .	45
6.2.1	Classificação em Normais e Infarto na Parede Anterior . . . . .	45
6.2.2	Classificação em Normais e Infarto na Parede Inferior . . . . .	47
6.2.3	Classificação em Normais e Infarto na Parede Lateral . . . . .	49
6.3	<i>Convolutional Neural Network</i> com imagens realçadas de planos de VCG . . .	51
6.3.1	Plano XY . . . . .	52
6.3.2	Plano XZ . . . . .	53
6.3.3	Plano YZ . . . . .	54
<b>7</b>	<b>Considerações Finais</b>	<b>56</b>
	<b>Referências Bibliográficas</b>	<b>65</b>
	<b>APÊNDICES</b>	<b>65</b>
<b>A</b>	<b>Curva ROC dos experimentos realizados</b>	<b>67</b>
<b>B</b>	<b>Artigos Publicados</b>	<b>69</b>

Segundo a Organização Mundial da Saúde (OMS), no ano de 2019 as doenças cardiovasculares representaram 32% das mortes no mundo, sendo a maior causa de mortes. Dentre essas doenças, o Infarto do Miocárdio (IM), conhecido também como ataque cardíaco, junto com o Acidente Vascular Cerebral, representou 85% dessas mortes, estando elas concentradas em países subdesenvolvidos ou em desenvolvimento (OMS, 2021).

O IM é caracterizado pela ausência ou diminuição da circulação sanguínea no coração, causando a perda de oxigênio e levando à morte dos tecidos cardíacos conforme o evento ocorre, o que causa danos normalmente irreversíveis ao coração e, conseqüentemente, causando a morte do paciente (Segers & Lee, 2008). Logo, o diagnóstico rápido e preciso desta doença nos momentos iniciais pode auxiliar no processo de tomada de decisões, aumentando as possibilidades de parar ou retardar os efeitos do IM (Moon *et al.*, 2020).

A observação dos sintomas como dor aguda no peito, dormência em partes do corpo, sudorese etc. é normalmente a primeira abordagem para caracterizar a ocorrência do IM. Porém, estes sintomas podem ser facilmente oriundos de outras doenças ou situações, o que dificulta um diagnóstico preciso. Neste contexto, exames mais específicos como o Eletrocardiograma (ECG) ou Ecocardiograma, tornam possível observar e entender melhor o comportamento do coração, auxiliando no diagnóstico de situações anormais (Shortt *et al.*, 2017; Bax *et al.*, 2012).

O Eletrocardiograma é um dos principais exames para análise do funcionamento do coração e diagnóstico de doenças relacionadas, amplamente utilizado por apresentar uma abordagem não invasiva, acessível e normalmente eficaz (Bax *et al.*, 2012). A partir do ECG é possível observar a variação dos potenciais elétricos gerados pela atividade do músculo cardíaco, que são capturadas por meio de eletrodos distribuídos em pontos específicos do corpo. Estes potenciais elétricos são altamente sensíveis às alterações causadas pelo funcionamento anormal do coração, possibilitando a identificação de padrões relacionados a patologias.

---

Semelhante ao ECG, o Vectorcardiograma (VCG) é outro exame utilizado para observar o funcionamento do coração a partir dos potenciais elétricos, porém em uma perspectiva tridimensional, este exame pode ser obtido por meio de eletrodos distribuídos em pontos específicos do corpo, ou a partir de uma representação dos vetores eletrocardiográficos no sistema de eixos cartesianos (Kors *et al.*, 1990). A partir do VCG é possível obter novas perspectivas e possibilidades para auxiliar na identificação de patologias, o que amplia ainda mais o potencial de utilização de ambos exames, ECG e VCG (Dehnavi *et al.*, 2011).

As representações gráficas dos sinais de ECG e do VCG oferecem informações úteis para identificação de patologias. Porém, para ampliar as possibilidades de aplicações e usabilidade destes exames, outros parâmetros podem ser extraídos a partir de técnicas de processamento de sinais, o que proporciona um cenário cada vez mais explorado por pesquisas envolvendo técnicas de Aprendizado de Máquina (AM) (Costa *et al.*, 2018; Dehnavi *et al.*, 2011). Logo, é possível o desenvolvimento de aplicações que auxiliam na identificação de padrões relacionados a doenças de forma precisa e automatizada.

Com os avanços tecnológicos na área da computação e com o aumento dos recursos computacionais, o uso de técnicas de AM passou a se tornar cada vez mais comum em diversas áreas, incluindo a indústria, saúde, educação etc (Singh *et al.*, 2017; Jiang *et al.*, 2017). A possibilidade de automatizar processos ou auxiliar na tomada de decisões em situações que demandam precisão e esforço humano faz com que o uso destas técnicas seja uma alternativa altamente explorada para os mais variados propósitos. Redes Neurais Artificiais (RNA), por exemplo, que antes eram inviáveis devido aos altos custos de processamento e de dados, atualmente são o estado-da-arte em termos de inteligência artificial, graças aos recursos como computadores com placas de vídeos de alta capacidade, serviços de processamento na nuvem, além da disponibilidade de dados por meio da Internet (Singh *et al.*, 2017).

As RNA são algoritmos que funcionam de forma análoga ao cérebro humano, utilizando conjuntos de neurônios artificiais organizados em camadas conectadas, capazes de modelar padrões a partir do ajuste de pesos em suas conexões (Haykin, 2004). Esta abordagem possibilita a utilização de diversas arquiteturas de organização dos neurônios e das camadas, e também proporciona às RNA a capacidade de abstração de tipos de dados diferentes, tornando possível o desenvolvimento de aplicações com imagens, textos, áudios, séries temporais, etc. Atualmente, Redes Neurais Profundas ou *Deep Neural Networks* (DNN), são o estado-da-arte na área de inteligência artificial, associadas a um ramo de estudo denominado aprendizado

---

profundo, ou *deep learning*, estas redes apresentam uma abordagem semelhante às RNA, porém com maior quantidade de camadas e neurônios, o que amplia a capacidade de abstração e ajuste do modelo aumentando, entretanto, a demanda de recursos computacionais (Jiang *et al.*, 2017).

Na literatura, constantemente são apresentados resultados de estudos envolvendo DNN em cardiologia, em aplicações voltadas para desenvolvimento de modelos preditivos, capazes de classificar sinais patológicos e saudáveis com precisão normalmente superior, quando comparado com modelos estatísticos ou algoritmos de aprendizado de máquina convencionais (LeCun *et al.*, 2015; Jiang *et al.*, 2017). Porém, a obtenção de parâmetros concisos e eficientes ainda é um dos principais desafios, a ponto concentrar a maior parte da atenção e esforços nas etapas de pré-processamento e extração de dados a partir dos sinais (Costa *et al.*, 2018). Neste contexto, surge a necessidade de investigar alternativas para extração de parâmetros e seus respectivos impactos no funcionamento de modelos preditivos.

## 1.1 – Motivação

O uso de técnicas de aprendizado de máquina está sendo cada vez mais explorado em aplicações voltadas para auxiliar no diagnóstico de patologias cardíacas. Por meio de recursos como Redes Neurais Artificiais, é possível identificar padrões que podem ser imperceptíveis para o ser humano ou reduzir consideravelmente o tempo na tomada de decisões (Sethi *et al.*, 2006; Arrieta *et al.*, 2019; Jiang *et al.*, 2017; Zhang *et al.*, 2017).

Os diversos parâmetros extraídos do ECG proporcionam um cenário convidativo para o desenvolvimento de estratégias que utilizam Rede Neurais Artificiais convencionais ou variações como Redes Neurais Profundas (Jiang *et al.*, 2017; Parvaneh *et al.*, 2019). Porém as aplicações presentes na literatura, em sua maioria, se limitam ao uso de conjuntos isolados de parâmetros, ignorando a possibilidade de correlação entre parâmetros extraídos de fontes diferentes, o que abriria a oportunidade para explorar arquiteturas de redes que abrangem mais entradas e mais possibilidades de classificações.

O desenvolvimento de uma abordagem que avalia técnicas distintas de extração de parâmetros de ECG como entrada de uma *Deep Neural Network*, possibilitara o desenvolvimento de um modelo capaz de auxiliar na etapa de diagnóstico, além de verificar o potencial entre os parâmetros para a identificação de patologias cardíacas.

---

## 1.2 – Objetivo Geral

O objetivo geral deste trabalho visa o desenvolvimento de uma aplicação de classificação das áreas infartadas do coração utilizando parâmetros extraídos a partir de sinais de ECG para alimentação de uma Rede Neural Artificial Profunda. Por meio de avaliação de duas abordagens de entrada da rede, nas quais parâmetros são obtidos a partir da reconstrução do espaço de fases e pelas imagens dos planos da representação vectorcardiográfica do sinal de ECG.

### 1.2.1 – Objetivos Específicos

- ▣ Implementação de algoritmos de extração de parâmetros de análise dos estados caóticos do sinal de VCG;
- ▣ Implementação de algoritmos de Processamento Digital de Imagens para aplicação de dilatação nos planos do VCG;
- ▣ Desenvolvimento de Redes Neurais Artificiais Profundas utilizando a biblioteca *TensorFlow* para classificação a partir dos dados numéricos dos estados caóticos;
- ▣ Desenvolvimento de Redes Neurais Artificiais Profundas do tipo Convolutacional utilizando a biblioteca *Tensorflow* para classificação a partir dos planos do VCG;
- ▣ Avaliação das técnicas de extração de parâmetros de forma individual para classificação de entre sinais saudáveis (NORM), infarto na parede anterior (AMI), infarto na parede inferior (IMI) e infarto na parede lateral (LMI);
- ▣ Testes e validação dos algoritmos avaliados.

## 1.3 – Estado da Arte

Atualmente é possível identificar na literatura diversas pesquisas que utilizam técnicas de Aprendizado de Máquina em Eletrocardiogramas ou em Vectorcardiogramas para detecção de patologias cardíacas (Parvaneh *et al.*, 2019). Conseqüentemente, estas pesquisas intensificam os esforços no desenvolvimento e análise de abordagens de extração de parâmetros a partir de sinais de ECG (Wu *et al.*, 2013).



Em Raghunath *et al.* (2020), foi utilizada uma rede neural profunda (*deep neural network*) para analisar as 12 derivações dos sinais de ECG de um banco de dados com mais de 1.200.000 pacientes. Além dos sinais, também foram utilizados os metadados dos pacientes. O objetivo do trabalho foi desenvolver um modelo preditivo capaz de identificar riscos. Nesta proposta, é possível observar a preocupação dos autores na organização correta entre os sinais e metadados.

Uma das formas mais comuns de aplicações envolvendo RNA em análise de patologias cardíacas é por meio da utilização do sinal de ECG como entrada para a rede, normalmente nestas aplicações são adicionadas etapas de pré-processamento na qual a qualidade do conjunto de entrada é melhorada. Por exemplo, em Makimoto *et al.* (2020), 289 sinais de ECG são convertidos em imagens de baixa taxa de compressão, que são processadas por uma rede neural profunda, do tipo convolucional, a abordagem proposta apresenta uma acurácia de 70% para a identificação da presença de infarto do miocárdio no ECG.

O potencial dos parâmetros extraídos de ECG podem ser expandidos para patologias e situações indiretamente relacionadas ao coração, como é apresentado em Xu & Liu (2009), no qual é realizado um classificação de emoções a partir do formato da onda eletrocardiográfica. Em Ramya *et al.* (2019), são utilizados parâmetros extraídos a partir dos pontos característicos da onda, tais como ângulos e aspectos morfológicos, a abordagem possibilita a classificação de sinais saudáveis e patológicos acometidos de arritmia cardíaca. Ambas abordagens utilizadas nos trabalhos dependem dos aspectos morfológicos do sinal.

## 1.4 – Estrutura do Texto

Esta dissertação está organizada em sete capítulos, incluindo este capítulo introdutório no qual são apresentados os conceitos motivacionais para a elaboração deste trabalho. No Capítulo 2, são apresentados os conceitos teóricos utilizados para entendimento e elaboração da proposta, tais como os componentes e funcionamento do músculo cardíaco nas Seções 2.1 e 2.1.1, e as doenças alvos da investigação deste trabalho na Seção 2.1.2. Ainda no Capítulo 2, na Seção 2.2, são apresentadas as características do sinal do Eletrocardiograma, e a representação em forma de vetocardiograma na Seção 2.3. No Capítulo 3, são contextualizadas as estruturas de redes neurais artificiais e suas aplicabilidades no cenário abordado. No Capítulo 4, são apresentados os passos metodológicos e recursos utilizados para o desenvolvimento e realização

dos experimentos. No Capítulo 5 são descritas as configurações dos experimentos realizados. E no Capítulo 6, são apresentados resultados obtidos. No último Capítulo 7, são apresentadas as considerações do autor além de estimativas das próximas etapas a serem realizadas.

## Estudo Cardiovascular

Neste Capítulo, são apresentados os principais conceitos relacionados ao funcionamento do coração e ao Eletrocardiograma, método utilizado para obtenção de informações a partir da análise das atividades elétricas do músculo cardíaco. Também são contextualizados a importância e a obtenção do vetocardiograma.

### 2.1 – O Coração

O sistema cardiovascular é responsável por manter o fluxo sanguíneo por todo o corpo, o que leva oxigênio indispensável para a vida das células e funcionamento dos tecidos. Este sistema é composto por três componentes: O sangue, que carrega o oxigênio e os nutrientes necessários para o funcionamento do corpo, os vasos sanguíneos que funcionam como vias, possibilitando que o sangue chegue a todas as partes do corpo, e o coração responsável por impulsionar a circulação do sangue pelos vasos (Drake *et al.*, 2015; Gleason *et al.*, 2012; Hall, 2015). Apesar da vital importância destes três componentes, neste trabalho o coração será abordado com maior profundidade, devido ao foco de interesse da pesquisa.

O sangue é o recipiente responsável por transportar o oxigênio e nutrientes pelo corpo. O sangue é constituído, em sua maior parcela, por uma parte líquida de cor amarelada, também conhecida como plasma, composta principalmente de água contendo proteínas, sais minerais, gases e resíduos celulares. Flutuando no plasma, se encontram os glóbulos vermelhos (hemácias), as células mais numerosas do sangue, de formato bicôncavo e cor avermelhada devido ao ferro presente na proteína hemoglobina, esta célula tem a função de transportar o oxigênio e nutrientes para os tecidos e coletar o dióxido de carbono. Ainda no plasma, se encontram os glóbulos brancos (leucócitos), em menor número que os glóbulos vermelhos e com tamanho maior e formatos diferentes, possuem a função de proteger o organismo contra microrganismos e agentes estranhos. Além destes, também há as plaquetas, contendo cerca

---

de um quarto do tamanho dos glóbulos vermelhos, são responsáveis intervir no processo de coagulação do sangue, que ocorre sempre que os vasos sanguíneos ou um tecido for danificado (Gleason *et al.*, 2012).


Para que o sangue transite, os vasos sanguíneos compõem um emaranhado de canais que se espalham por todo o corpo, semelhante a raízes ocas, com origem mais grossa e concentradas no coração, e extremidades mais finas e dispersas nos membros. Estes vasos podem ser classificados em dois grupos principais, as artérias que são os vasos sanguíneos nos quais o fluxo sai do coração, levando o sangue oxigenado, compostas por paredes espessas e dilatáveis. E as veias, que levam o sangue venoso vindo do corpo para o coração, formadas por paredes mais finas quando comparadas com as artérias. Além destes, também há os vasos finos chamados de capilares, responsáveis por entregar o oxigênio oriundo das artérias principais e coletar o gás carbônico diretamente nos tecidos em direção às veias principais (Drake *et al.*, 2015).

O coração é o órgão localizado na caixa torácica, responsável por manter o fluxo sanguíneo por todo o corpo, o que leva oxigênio indispensável para a vida das células e funcionamento dos demais órgãos (Hall, 2015). Para isso, o coração utiliza contração muscular para movimentar aproximadamente 9 mil litros de sangue por dia, considerando um ser humano adulto saudável e de estatura mediana. Este sangue é enriquecido com oxigênio captado nos pulmões durante a respiração, sendo então distribuído pelo corpo por meio do sistema circulatório que se assemelham a raízes com origem no coração.

Em sua maior parte, o coração é um órgão muscular revestido por três camadas de tecido principais como ilustra a Figura 2.1. A camada mais interna é chamada de endocárdio; a intermediária, de miocárdio; e a mais externa, de epicárdio. Elas formam uma estrutura oca composta por duas câmaras superiores, chamadas de átrios, e duas câmaras inferiores, chamadas de ventrículos, sendo estas responsáveis pelo bombeamento do sangue. Ao analisar o coração, é possível dividi-lo em duas partes, sendo a direita, normalmente representada pela cor azul, responsável pelo recebimento e encaminhamento de sangue venoso e a esquerda, representada pela cor vermelha, pelo sangue arterial. Existem também camadas do grupo pericárdico, sendo elas não exploradas no presente trabalho.

A camada endocárdia apresenta uma superfície fina e lisa que possibilita que o sangue transite facilmente. A do miocárdio tem uma espessura média e mais espessa composto de músculo estriado cardíaco, ela apresenta vital importância pois permite que o coração se

**Figura 2.1** – Estrutura muscular do coração.



Fonte: Adaptado de Drake *et al.* (2015).


contraia e impulsiona o sangue. Por fim, a camada do epicárdio é uma lâmina fina de tecido que contém soro. Além das camadas, também há um pequeno espaço conhecido como espaço pericárdio ou cavidade pericárdica.

Em um processo chamado ciclo cardíaco, as quatro câmaras do coração relaxam e se contraem normalmente em sincronia, inicialmente pelos átrios e em seguida pelos ventrículos, possibilitando que o sangue circule. Observando a Figura 2.2, é possível acompanhar o funcionamento do coração, na qual as setas indicam o fluxo sanguíneo. O sangue venoso, pobre de oxigênio e rico em gás carbônico ( $CO_2$ ) e metabolitos celulares, chega do corpo ao coração por meio das veias cavas superior e inferior em direção ao átrio direito, que se encontra em estado de relaxamento, este relaxamento também é chamado de diástole. Uma vez cheio, os átrios se contraem e o sangue que está no átrio direito é empurrado para o ventrículo direito passando pela válvula tricúspide que se fecha e impede que o sangue volte. Neste momento os átrios relaxam e os ventrículos se contraem, ato chamado de sístole, empurrando o sangue que está no ventrículo direito para o pulmão pelo tronco pulmonar.

No pulmão, durante a respiração, o  $CO_2$  do sangue é substituído por oxigênio por meio de minúsculos sacos aéreos chamados de alvéolos pulmonares, este processo é chamado de hematose. O sangue, agora rico em oxigênio, volta para o coração pelas veias pulmonares, chegando ao átrio esquerdo, neste momento, os átrios se contraem novamente e o sangue que está no átrio esquerdo é empurrado para o ventrículo esquerdo, os ventrículos se contraem e o

sangue é enviado para o corpo por meio da artéria aorta. Finalmente o sangue é distribuído pelo corpo por meio de um sistema de vias semelhantes a raízes chamadas sistema circulatório.

**Figura 2.2** – Funcionamento do coração.




Fonte: Adaptado de Gleason *et al.* (2012).

Um conjunto de fatores possibilita que o fluxo sanguíneo aconteça de forma fluída e eficiente, tais como densidade do sangue, passagem livre de obstruções nos vasos sanguíneos, funcionamento sincronizado dos componentes do coração, e a capacidade elétrica e muscular dos tecidos do coração, necessários para contrair e relaxar o órgão, e possibilitar o bombeamento do sangue (Herlihy, 2002).

### 2.1.1 – Ciclo Cardíaco

O músculo cardíaco, assim como os demais músculos do nosso corpo, demanda de um estímulo para realizar alguma ação. No caso dos outros músculos, este estímulo é realizado pelo sistema nervoso, porém no coração é realizado por um conjunto de células especializadas que compõe um sistema intrínseco, capaz de gerar e controlar descargas elétricas que determinam uma sequência de eventos chamada de ciclo cardíaco (Hall, 2015). Este sistema é apresentado na Figura 2.3.

O conjunto de eventos do ciclo cardíaco é iniciado quando o nódulo sinusal (também chamado de nodo sinoatrial ou nodo S-A), localizado no canto superior do átrio esquerdo, gera uma onda de despolarização que pode ativar as demais células cardíacas. Esta onda


**Figura 2.3** – Sistema de condução do coração.

Fonte: Adaptado de Hall (2015).

causa a contração dos átrios, e segue para a parte superior dos ventrículos por meio das vias internodais, chegando até o nódulo atrioventricular (ou nodo A-V), localizado entre o átrio e o ventrículo esquerdo, que é responsável por gerar um atraso na corrente elétrica antes que esta se propague para os ventrículos. Este atraso é necessário para que átrios e ventrículos não se contraíam simultaneamente, o que forçaria o fluxo de sangue para todas as direções. A onda então segue pelo feixe A-V, que o conduz para ventrículos pelos ramos direito e esquerdo. O impulso finalmente é distribuído pelo miocárdio dos ventrículos por meio das fibras de Purkinje, e neste momento a onda causa a contração dos ventrículos (Gleason *et al.*, 2012). As atividades ocorridas durante o ciclo cardíaco geram um conjunto de eventos que podem ser capturados de diversas maneiras, como ilustra a Figura 2.4.

As alterações causadas por eventos anormais no músculo cardíaco como quando ocorre um infarto do coração, resultam em alterações na forma como a impulso se propaga. Estas alterações podem ser observadas por meio de exames como o Eletrocardiograma, o que permite agilizar a tomada de decisões e provê contramedidas para parar ou reduzir os danos.

**Figura 2.4** – Observação dos eventos do ciclo cardíaco a partir diversas técnicas.



Fonte: Adaptado de Sukienik (2015).

### 2.1.2 – Infarto Agudo do Miocárdio

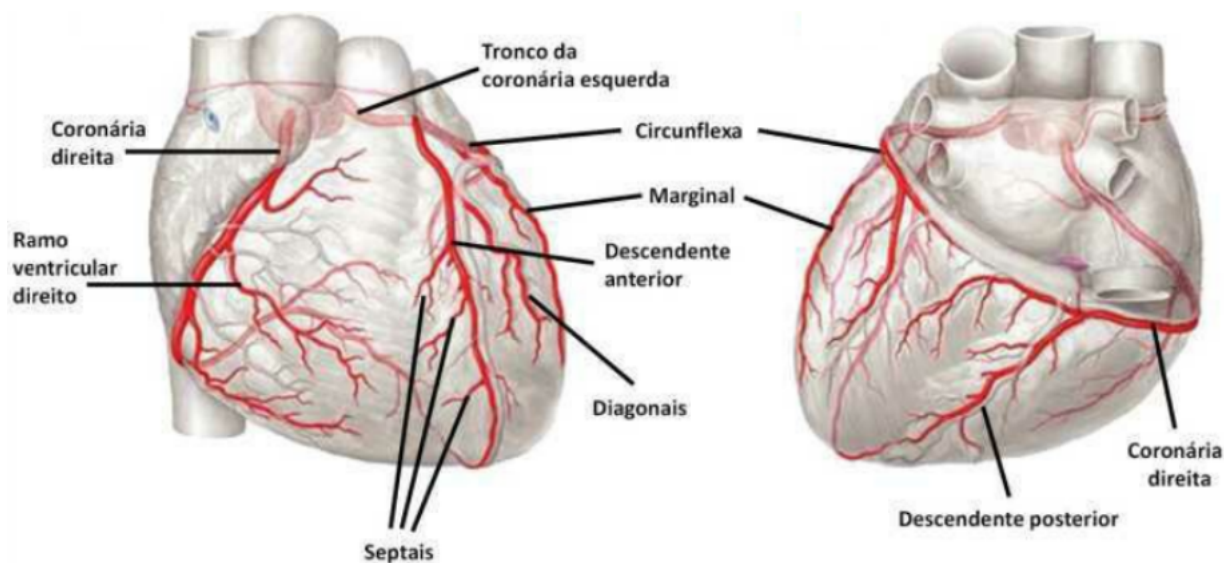
Conhecido popularmente como ataque cardíaco, o Infarto Agudo do Miocárdio (IAM) se caracteriza pela ausência ou pela diminuição da circulação sanguínea no coração, privando o músculo cardíaco (miocárdio), no local acometido, de oxigênio e de nutrientes, causando lesões importantes que podem levar até a morte de suas células, conforme o tempo de duração do evento. Com isso, o funcionamento do coração, que trabalha como uma bomba mecânica, pode ser seriamente afetado (Sukienik, 2015).

Assim como os demais órgãos do corpo humano, o coração também precisa de oxigênio e nutrientes para funcionar corretamente, ainda mais por se tratar de um órgão muscular e que se encontra em constante atividade. Esse suprimento interno de sangue é realizado por meio das artérias coronárias, que são localizadas ao redor do coração como ilustra a Figura 2.5.

As artérias coronárias fornecem o sangue para o músculo do cardíaco, em especial para o miocárdio, que por sua vez é o principal responsável pela contração muscular realizada pelo coração. A artéria coronária direita abastece de sangue o átrio direito, o ventrículo direito, a



Figura 2.5 – Artérias coronárias.



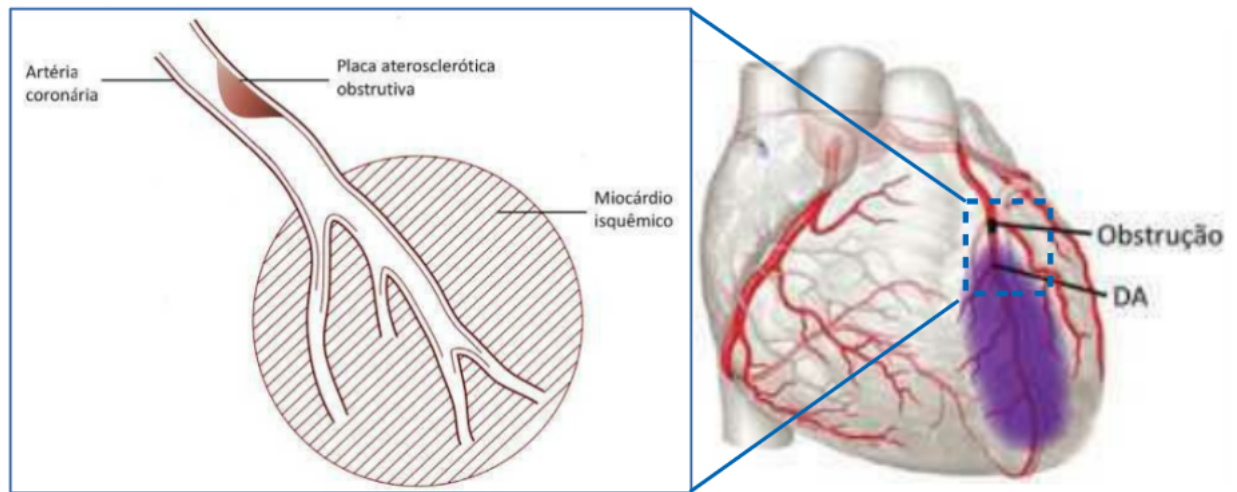
Fonte: Adaptado de Sukienik (2015).

parte posterior do coração e uma pequena parte do septo interventricular. Enquanto a artéria coronária esquerda envolve o lado esquerdo do coração e se encontra com a artéria coronária direita ao final de suas ramificações, fornecendo sangue para o átrio e ventrículo esquerdos, e para a maior parte do septo interventricular. Ainda no lado esquerdo, há a artéria coronária interventricular anterior, ou artéria descendente anterior, que seguem pelo tronco pulmonar e se entrelaçam com os ramos da artéria interventricular posterior conforme ela fica mais fina, este processo dá origem a uma área chamada de anastomose, onde os vasos se unem, possibilitando a circulação do sangue (Hall, 2015; Sukienik, 2015).

O trabalho das artérias coronárias é crucial para o funcionamento do coração, uma vez que o bloqueio do fluxo resulta na morte do tecido do miocárdio, causando o Infarto Agudo do Miocárdio, também chamado de ataque do coração. Este bloqueio é normalmente causado por um processo inflamatório chamado de aterosclerose, que é associado à presença de placas de colesterol nas paredes da artéria, o que causa o entupimento da artéria devido o desprendimento destas placas ou pela formação de coágulos na própria artéria devido à inflamação (Sukienik, 2015). A obstrução da artéria pode comprometer toda uma área do miocárdio, como ilustra a Figura 2.6, na qual a artéria Descendente Anterior (DA) está obstruída.


Logo, o IAM pode ser caracterizado de acordo com a área do coração onde ocorre o evento, como ilustra a Figura 2.7. Na Figura, é ilustrado a ocorrência de IAM do tipo ventricular, anteroseptal ou anterior, lateral alta ou superior, na parede inferior e posterior.

**Figura 2.6** – Artérias coronárias obstruída.



Fonte: Adaptado de Sukienik (2015).

**Figura 2.7** – Variação de IAM de acordo com a área do miocárdio afetada.



Fonte: Adaptado de Sukienik (2015).

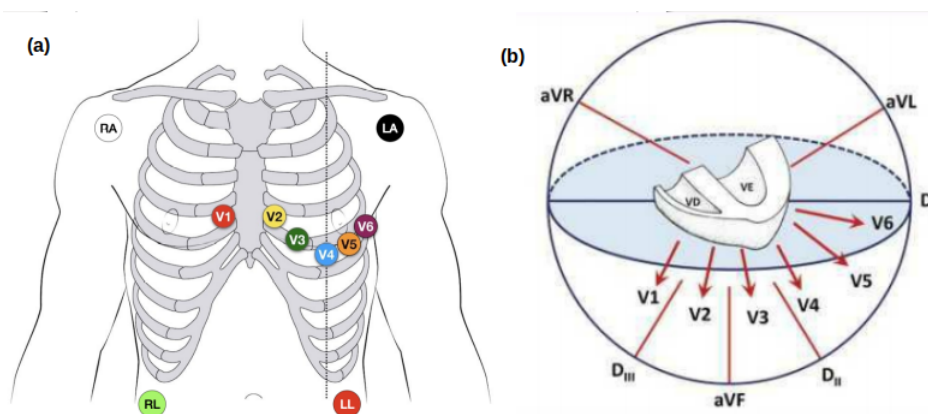
A ocorrência do IAM é normalmente seguida por sintomas como dor referida no tórax (ou peito) contínua, de forte intensidade; e sensação de compressão, aperto ou queimação no peito; ardor bastante semelhante à azia; dor peitoral irradiada para a mandíbula, ombros e braços, mais frequentemente do lado esquerdo do corpo e, por vezes, palpitações prolongadas. E em alguns casos, suor excessivo, náuseas, vômitos, tontura e desfalecimento, assim como ansiedade e agitação. Em diabéticos é possível observar menos sintomas ou nada sentem ao infartar, este é o chamado infarto silencioso (Zimmerman *et al.*, 2003).

## 2.2 – Eletrocardiograma

Como foi apresentado na Seção 2.1.1, uma sequência de eventos elétricos ocorre durante o ciclo cardíaco. Estes eventos podem ser observados por meio de um exame chamado Eletrocardiograma (ECG), que mesmo depois de mais de 100 anos em uso, continua sendo um dos principais exames utilizados para observar o funcionamento do coração, uma vez que é uma alternativa não invasiva, de baixo custo, que apresenta uma abordagem eficiente para análise do músculo cardíaco e que é realizado com um equipamento de fácil transporte e manuseio. Estas características tornam o ECG uma das primeiras abordagens utilizadas em clínicas e consultórios para detectar problemas cardíacos (Nicolau *et al.*, 2003).

O ECG é o registro das atividades elétricas do coração, que é realizado por meio de um aparelho chamado eletrocardiógrafo, que mede pequenas intensidades de corrente, geralmente a partir de dez eletrodos dispostos em determinados pontos do corpo humano, como apresenta a Figura 2.8 (a). Além destas, outros 3 são posicionados no pulso esquerdo e direito, e no tornozelo esquerdo. A partir da disposição dos eletrodos é possível obter derivações, que são perspectivas diferentes para observar os eventos do ciclo cardíaco, Figura 2.8 (b).

**Figura 2.8** – (a) Disposição dos eletrodos pelo corpo; (b) Perspectivas de observação do músculo cardíaco a partir das derivações.



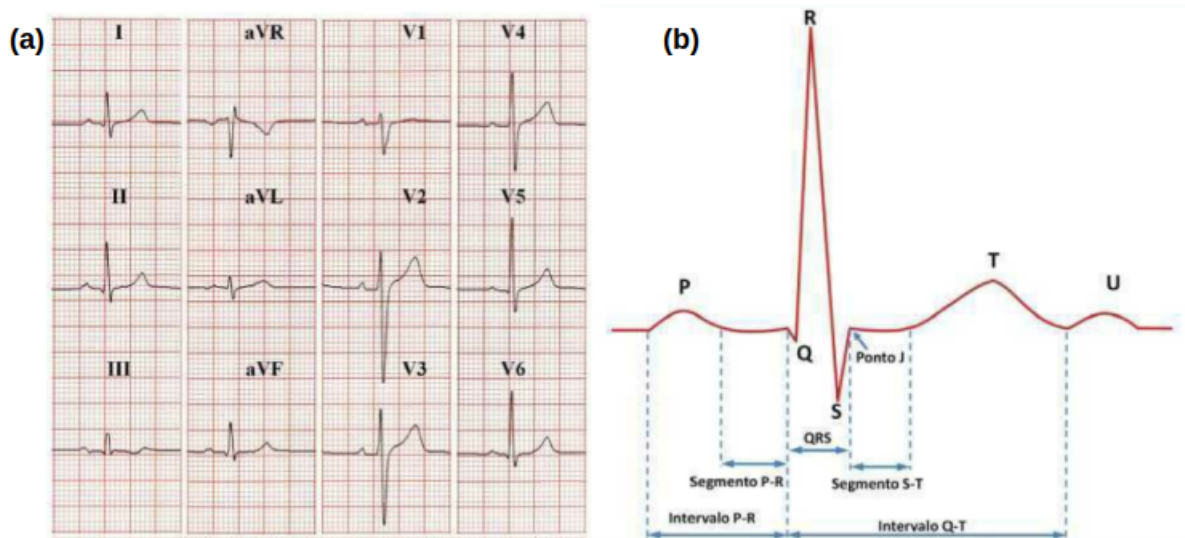
Fonte: Adaptado de Hall (2015).

Um ECG convencional possui 12 derivações, sendo seis dessas chamadas de periféricas (DI, DII, DIII, aVR, AVL e aVF), que correspondem ao deslocamento vetorial da diferença de potencial entre os eletrodos a partir do plano frontal do coração, captando o deslocamento para cima, para baixo, para direita ou para esquerda. Enquanto as outras seis (V1, V2, V3, V4, V5 e V6), chamadas de precordiais, que mostram a profundidade, permitindo uma ideia de

deslocamento para frente ou para trás (Tranchesi *et al.*, 2001). Cada derivação resulta em um registro gráfico como é apresentado na Figura 2.9 (a), cada um deles representa uma perspectiva diferente dos mesmos eventos.

Cada ciclo cardíaco é mapeado em uma onda eletrocardiográfica, que possui formas elementares (onda P, complexo QRS e onda T), mostradas na Figura 2.9 (b). O ciclo cardíaco inicia-se com a onda P, que representa um reflexo da ativação da musculatura atrial, resultante da onda de despolarização. O complexo QRS está relacionado com a despolarização ventricular, enquanto a repolarização ventricular é representada pela onda T. A análise das características das formas de onda e dos intervalos entre elas permite auxiliar no diagnóstico de alterações estruturais e funcionais do coração. Também é possível encontrar na literatura a onda U, localizada logo após a onda T.

**Figura 2.9** – (a) Derivações eletrocardiográfica; (b) Forma padrão de uma onda eletrocardiográfica.

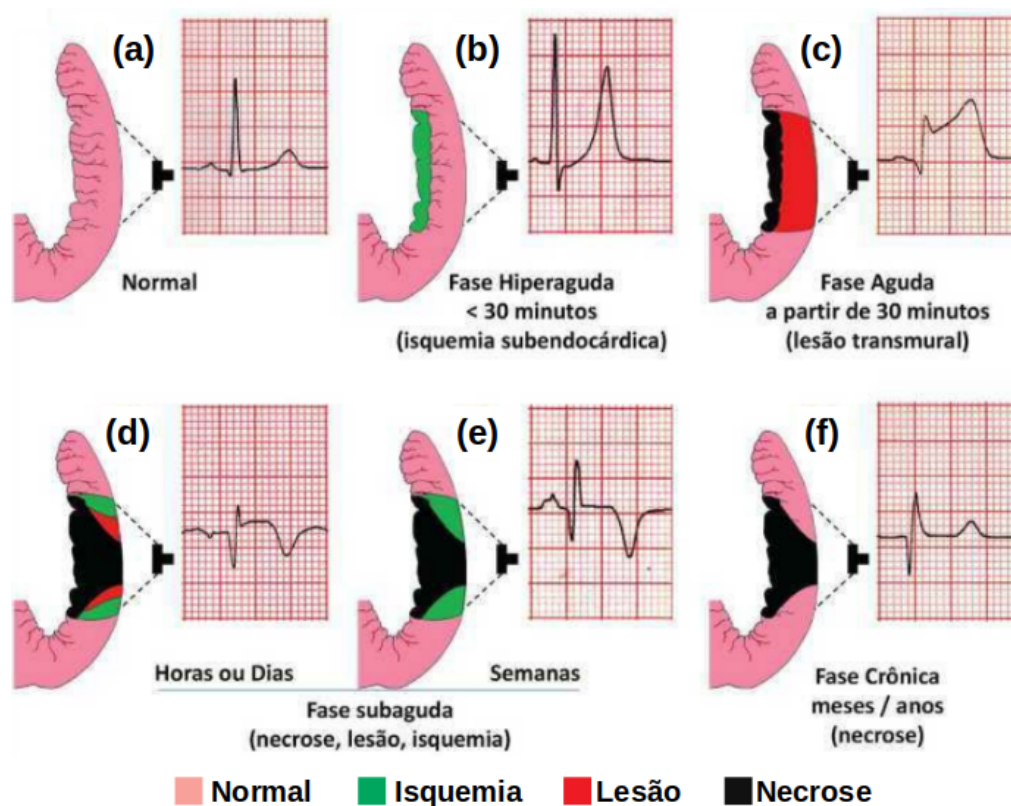


Fonte: Adaptado de (Sukienik, 2015).

A sensibilidade do ECG às mudanças dos eventos elétricos do ciclo cardíaco é um dos principais fatores da preferência deste exame como uma das primeiras medidas em caso de suspeita de IAM, uma vez que as lesões no músculo cardíaco afetam a forma como o impulso elétrico se propaga pelo miocárdio. Na Figura 2.10, é associado o estágio do IAM ao respectivo formato esperado da onda do ECG.



**Figura 2.10** – Impacto das fases do IAM na derivação do ECG: (a) Situação normal; (b) Início do IAM; (c) Fase aguda, com lesão transmural; (d) Fase subaguda horas e dias; (e) Fase subaguda semanas; (f) Fase crônica, meses/anos após ocorrência do IAM



Fonte: Adaptado de (Sukienik, 2015).

O IAM apresenta uma sequência de alterações no funcionamento e na forma como os impulsos elétricos se propagam. Essas alterações são mais nítidas com o passar do tempo, à medida que a lesão se prolonga. Segundo o tempo de evolução, o IAM pode ser dividido em quatro fases (Sukienik, 2015):

- Fase Hiperaguda (Figura 2.10 (b)): Esta fase dura em torno de 15 a 30 minutos após o início do IAM, o formato da onda T apresenta uma elevação e simétrica, decorrente da isquemia da região subendocárdica, uma das camadas do miocárdio ventricular. Por ser nos momentos iniciais, e em um tão breve intervalo de tempo, raramente esta alteração é observada em um cenário real;
- Fase Aguda (Figura 2.10 (c)): Como resultado da persistência da isquemia, é gerado uma lesão grave de toda a parede ventricular (lesão transmural). Nesta situação, é possível identificar um padrão de elevação do seguimento ST enquanto o vale Q apresenta um maior declínio à medida que a lesão se propaga do endocárdio ao epicárdio;

- ▣ Fase Subaguda ou Recente (Figura 2.10 (d & e)): Esta etapa ocorre em horas ou até mesmo dias após o início do IAM, e é caracterizada pelo aparecimento das ondas T negativas e elevação do segmento ST, além da nitidez do vale Q;
- ▣ Fase Crônica ou Antiga (Figura 2.10 (f)): Neste momento, uma área do miocárdio apresenta lesões normalmente irreversíveis, decorrente da necrose do músculo. No ECG é observado que a onda Q apresenta um formato anormal enquanto o segmento ST se mantém na linha de base e a onda T tende a se normalizar.

Um fator importante a ser considerado, e também motivador deste trabalho, é que apesar da riqueza de detalhes que o ECG pode favorecer para a identificação de patologias como o IAM, o diagnóstico da doença é constantemente descartado mesmo quando presente, isso se deve a diversos fatores como erro de interpretação do exame, ou até mesmo falso-negativos, situação em que um sinal patológico pode apresentar características extremamente semelhantes a um sinal saudável (Zimmerman *et al.*, 2003; Andrade *et al.*, 2013).

A partir do ECG é possível extrair diversos parâmetros que são amplamente utilizados na área da saúde (Biel *et al.*, 2001), além de novos parâmetros que são constantemente apresentados na literatura (Silva *et al.*, 2020). Com estes parâmetros é possível desenvolver técnicas para obter informações úteis a partir do sinal bruto (sem filtros ou qualquer tipo de pré processamento) (Xu *et al.*, 2018); de sinais pré processados nos quais os parâmetros são extraídos de um sinal filtrado ou modificado de alguma forma; na conversão de ECG em Vectorcardiograma, que viabiliza um outro cenário para extração de parâmetros (Pastore *et al.*, 2019); ou até mesmo na marcação de pontos de interesse na onda (Biel *et al.*, 2001). Na seção a seguir são apresentados alguns dos principais conceitos relacionados a eletrocardiogramas, incluindo algumas das principais formas de extração dos parâmetros mais comuns na literatura.

## 2.3 – Vetocardiograma


O Vetocardiograma (VCG) é uma representação tridimensional das atividades elétricas cardíacas baseada no registro de vetores que correspondem às variações dos potenciais elétricos captados do coração. Com este método, é possível observar em três dimensões as ondas de polarização e repolarização cardíacas, onde características anormais nessas ondas estão relacionadas às possíveis condições cardíacas como um IAM, dilatação atrial, hipertrofia ventricular ou falhas na repolarização, por exemplo. Tendo esse método, em certos casos, maior sensibilidade em relação a um ECG (Chou, 1986).

Em razão do potencial deste exame, diversos sistemas de obtenção do VCG foram propostos, como o sistema de derivação baseado em eixos retangulares (Wilson & Johnston, 1938) e o sistema de derivação VCG de *Akulnichev* (Akulinichev, 1960), todos com o intuito de proporcionar melhor visualização do VCG, mas pouco utilizados por oferecer distorções nas alças vetocardiográficas devido à posição excêntrica do coração no tórax.

O sistema vetocardiográfico mais adotado atualmente, no entanto, é o ortogonal corrigido de Frank (Frank, 1956), que se baseia na disposição de sete eletrodos pelo corpo do paciente, a fim de diminuir o erro devido à variação interindividual na localização do coração e forma do corpo.

Sua forma de obtenção mais aceita na literatura foi introduzida por Frank (Frank, 1956) em 1956, na qual consiste na utilização de 7 eletrodos dispostos no corpo, como ilustra a Figura 2.11. Cinco desses eletrodos (A, C, E, I e M) correspondem aos pontos da esquerda, da frente, da direita e da parte superior do tórax e estão localizados no mesmo nível. O eletrodo H está situado no corte do pescoço, enquanto o F se encontra na posição padrão da perna esquerda. As saídas dessa configuração são as diferenças de potencial  $V_x$ ,  $V_y$  e  $V_z$  e correspondem às derivações ortogonais do VCG de Frank.

Figura 2.11 – Disposição dos eletrodos pelo corpo.




Fonte: Frank (1956).

A partir desses eletrodos é possível determinar três vetores que caracterizam três eixos ortogonais, simbolizados por  $V_x, V_y$  e  $V_z$ . Tais vetores, também conhecidos como derivações bipolares, formam três planos do espaço-tempo equivalentes aos três planos anatômicos do corpo humano (sagital, frontal e transversal) (Yang *et al.*, 2013). As derivações bipolares ortogonais permitem a representação espacial ilustrada na Figura 2.12, a qual descreve o comportamento particular de cada estágio do ciclo cardíaco, se assemelhando, nesse sentido, ao ECG.



Figura 2.12 – Representação do vetocardiograma.



Fonte: Adaptado de Yang *et al.* (2012).

Dessa forma, o VCG é caracterizado por três *loops* fundamentais: o *loop* P, o *loop* QRS e o *loop* T, os quais correspondem às três principais ondas (onda P, complexo QRS e onda T) do eletrocardiograma convencional. Assim, por meio da análise de sua curva, o vetocardiograma possibilita a identificação de patologias associadas a alterações nessas trajetórias, bem como a localização do início e do fim da ocorrência (Ginefra *et al.*, 2006). Além disso, é possível a extração de parâmetros quantitativos, como ângulos, áreas e formas, dessas representações, os quais fornecem informações que podem ser utilizadas em análises automatizadas (Cortez & Schlegel, 2010; Arnaud *et al.*, 1989; Sedaghat *et al.*, 2016).

Inicialmente, o uso desse método teve sua utilidade reconhecida na prática clínica mas não foi adotado amplamente devido à necessidade de eletrodos específicos em arranjos não convencionais e clinicamente não práticos, além de treinamento especializado para sua realização pelo método de Frank (Frank, 1956). Posteriormente, no entanto, foram propostos algoritmos para a sua reconstrução a partir de uma eletrocardiografia de 12 derivações comum (Kors *et al.*, 1990).

## 2.4 – Reconstrução do vetocardiograma a partir do eletrocardiograma

A reconstrução das derivações de um VCG ( $V_x$ ,  $V_y$  e  $V_z$ ) pode ser realizada a partir da combinação linear de derivações de um ECG onde os coeficientes dessa combinação são armazenados em uma matriz de reconstrução, de forma que o vetocardiograma pode ser

reconstruído com essa matriz pela fórmula apresentada na Equação 2.1, onde a matriz à esquerda da igualdade corresponde às três derivações ortogonais do vetocardiograma, a matriz imediatamente após a igualdade é a matriz de reconstrução, a qual é multiplicada por uma matriz contendo as 12 derivações do ECG, à sua direita, na qual  $V_x$ ,  $V_y$  e  $V_z$  correspondem às três derivações ortogonais do VCG reconstruído. A matriz central corresponde à matriz de regressão do método utilizado, cujos coeficientes são apresentados na Tabela 2.1. Por fim, a matriz da direita refere-se as seis derivações de ECG. Em seu estudo acerca dos métodos de reconstrução apresentados, foi determinado por Cortez & Schlegel (2010) que os parâmetros descritos anteriormente no VCG gerado a partir do método da regressão de Kors possuíam os valores mais próximos em relação ao método de Frank.

$$\begin{bmatrix} V_x \\ V_y \\ V_z \end{bmatrix} = \begin{bmatrix} a_{11} & \dots & a_{112} \\ a_{21} & \dots & a_{212} \\ a_{31} & \dots & a_{312} \end{bmatrix} \cdot \begin{bmatrix} VI \\ \vdots \\ V6 \end{bmatrix} \quad (2.1)$$

Três formas para a determinação desses coeficientes, os quais são apresentados na Tabela 2.1, foram descritas por Kors *et al.* (1990). São elas:

- **A partir de uma única derivação ou Método Quasi-Ortogonal:** Nesse método cada uma das derivações do VCG é representada pela derivação do ECG com que ela mais se assemelha, com ou sem escalonamento. Assim, com exceção dos coeficientes relacionados às derivações selecionadas, todos os coeficientes serão zero;
- **A partir de um modelo:** Em Dower (1968) foi desenvolvido um modelo para obter o ECG de 12 derivações a partir de um VCG de Frank o qual foi representado por uma matriz. O processo inverso pode ser realizado com base na inversa dessa matriz. Assim, para a obtenção do VCG a partir das 12 derivações foi computada a matriz inversa da matriz original obtida por Dower Dower *et al.* (1980);
- **A partir de técnicas de regressão:** A partir de um conjunto de ECGs e VCGs obtidos simultaneamente em diferentes pacientes, os coeficientes da matriz foram obtidos a partir da minimização da soma do quadrado das diferenças entre uma certa derivação vetocardiográfica e sua reconstrução. Esses coeficientes foram obtidos considerando diferentes segmentos do período envolvendo o complexo P-QRS-T, sendo o resultado

da reconstrução avaliado visualmente e utilizados os coeficientes obtidos pela regressão com base apenas no complexo QRS aplicados a todo o sinal.

**Tabela 2.1** – Tabela com os coeficientes para a matriz de reconstrução Cortez *et al.* (2014).

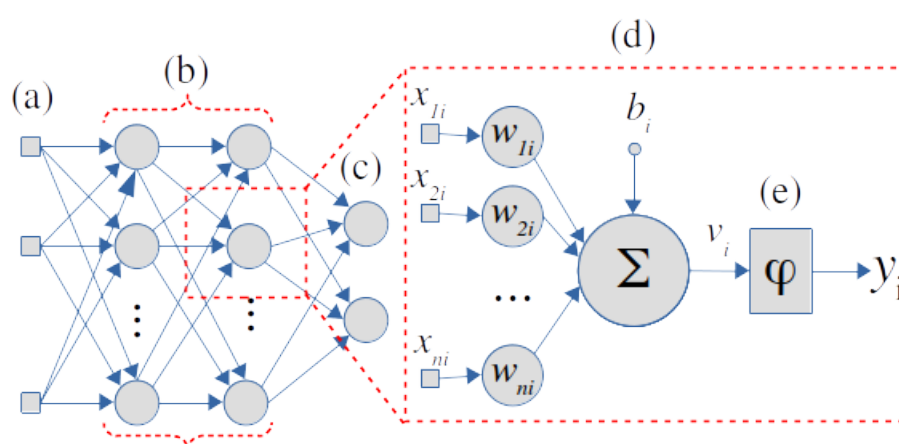
Método	Derivação do VCG	I	II	III	aVR	aVL	aVF	V1	V2	V3	V4	V5	V6
Regressão Linear de Kors	X	0.380	-0.070	0.000	0.000	0.000	0.000	-0.130	0.050	-0.010	0.140	0.060	0.540
	Y	-0.070	0.930	0.000	0.000	0.000	0.000	0.060	-0.020	-0.050	0.060	-0.170	0.130
	Z	0.110	-0.230	0.000	0.000	0.000	0.000	-0.430	-0.060	-0.140	-0.200	-0.110	0.310
Kors Quasi-Ortogonal	X	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	1.000
	Y	0.000	1.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
	Z	0.000	0.000	0.000	0.000	0.000	0.000	-0.500	0.000	0.000	0.000	0.000	0.000
Matriz Inversa de Dower	X	0.632	0.235	-0.397	-0.434	0.515	-0.081	-0.515	0.044	0.882	1.212	1.125	0.831
	Y	-0.235	1.066	1.301	-0.415	-0.768	1.184	0.157	0.164	0.098	0.127	0.127	0.076
	Z	0.059	-0.132	-0.191	0.037	0.125	-0.162	-0.917	-0.139	-1.277	-0.601	-0.086	0.230

## Redes Neurais Profundas

Inerente aos avanços computacionais nas últimas décadas, conceitos como aprendizado de máquina e Redes Neurais Artificiais (RNA), passaram a ser cada vez mais explorados, isto ocorre principalmente devido ao aumento e disponibilidade de recursos computacionais como processamento e memória. Atualmente é possível encontrar aplicações envolvendo técnicas de aprendizado de máquina ou RNA nas mais diversas áreas como indústria, educação, setor imobiliário, saúde, etc (Singh *et al.*, 2017).

Redes Neurais Artificiais são estruturas inspiradas na organização e funcionamento do cérebro humano, que são compostas por neurônios artificiais, agrupados em camadas conectadas, para prover modelos preditivos capazes de identificar padrões a partir de um conjunto de dados de entradas, como ilustra a Figura 3.1.

**Figura 3.1** – Estrutura de camadas de uma RNA. (a) Camada de entrada. (b) Camadas ocultas. (c) Camada de saída. (d) Neurônio artificial. (e) Função de ativação.



Fonte: Elaborado pelo autor.

Na Figura 3.1 é apresentado um exemplo de arquitetura de RNA sequencial padrão, no qual temos uma camada de entrada, duas camadas ocultas e uma camada de saída. Estas camadas são compostas por neurônios artificiais semelhante ao ilustrado na Figura 3.1 (d), esta

estrutura abriga uma função de somatório dos pesos ( $W$ ) oriundos das conexões com os demais neurônios, além de um valor de nivelamento ajustável chamado de *bias* ou viés ( $b$ ).

Além disto, no neurônio também há uma função de transformação não linear, chamada de função de ativação, Figura 3.1 (e), que opera sobre o sinal de saída antes de o enviar para a próxima camada como entrada. Atualmente há diversas funções de ativações, porém para limitar o escopo dos experimentos, neste trabalho são exploradas as funções Sigmoid e *Rectified Linear Unit* (ReLU).

A Sigmoid é uma função de continuidade diferenciável não linear, com variação entre 0 e 1, estruturada conforme a Eq. 3.1. De forma geral, a Sigmoid busca aproximar os valores do sinal de entrada para os extremos. A estratégia utilizada neste trabalho emprega a função Sigmoid nos neurônios da última camada, provendo um retorno probabilístico aproximado da classe alvo.

$$f(x) = \frac{1}{(1 + e^{-x})} \quad (3.1)$$

A ReLU, representada pela Eq. 3.2, apresenta uma lógica com derivada igual a 1, na qual o retorno é 0 quando o valor do sinal é negativo ou o próprio sinal quando o valor é positivo. Normalmente a função ReLU é utilizada nas camadas ocultas de redes neurais profundas, por apresentar uma abordagem simples e, conseqüentemente, mais rápida quando comparada com outras funções de ativação.

$$f(x) = \max(0, x) \quad (3.2)$$

Uma das abordagens mais comuns para o treinamento de um modelo de RNA, consiste no ajuste dos pesos a partir do erro. Inicialmente as entradas são processadas sequencialmente no sentido entrada/saída, camada por camada, processo chamado de *forward propagation*, e na última camada é calculado o gradiente da função de perda. O resultado é utilizado para atualizar recursivamente os pesos, camada por camada, no sentido saída/entrada, processo chamado de *backpropagation*. Esta descrição se aplica à versão simples do algoritmo de retro-propagação, ou seja, sem otimizações, porém comumente utilizado na maioria dos algoritmos de RNA em uso atualmente (Yamashita *et al.*, 2018).

Atualmente há diversas variações de RNA, cada uma com sua respectiva particularidade, porém com o mesmo conceito apresentado anteriormente, variando em organização e

---

distribuição de camadas e neurônios, níveis de conexão entre as camadas, forma como é realizado o treinamento, forma de manipulação de dados, etc (Schmidhuber, 2015). As RNA do tipo profunda ou *Deep Neural Networks* (DNN), são o estado-da-arte em termos de inteligência artificial, devido principalmente à alta capacidade de abstração de dados e de prover uma abordagem maleável de acordo com o problema abordado (Schmidhuber, 2015).

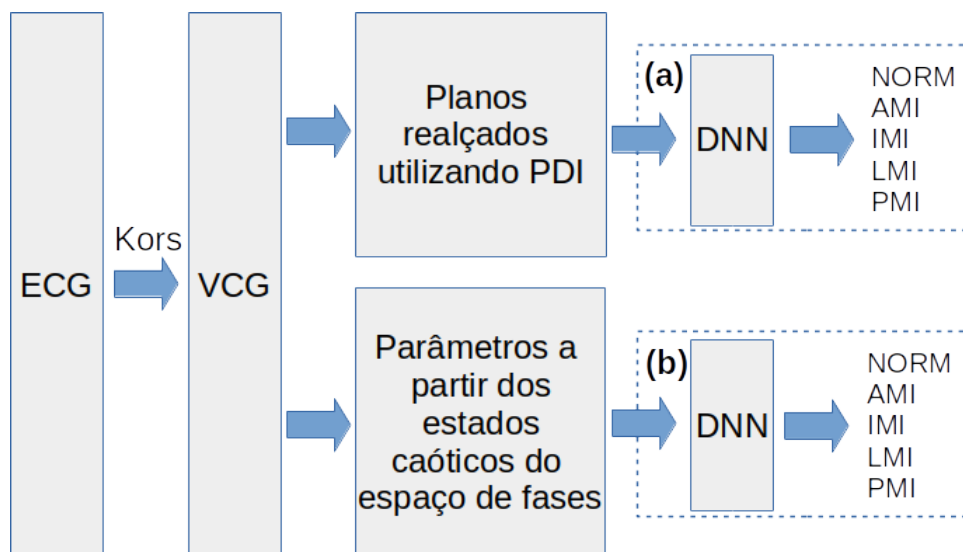
As redes do tipo DNN incluem em suas estruturas conjuntos de camadas adaptadas para o tipo de dado respectivo ao problema abordado, estas camadas atuam na segmentação seletiva dos dados, fornecendo entradas mais concisas para as camadas seguintes. Em um problema comum no qual o conjunto de entrada é composto por dados numéricos e categóricos, a entrada da rede é realizada de forma normal a uma rede MLP, em que cada neurônio assume a tarefa de abstrair um parâmetro. Porém, para lidar com imagens, normalmente são utilizadas redes neurais do tipo convolucionais, este tipo de rede utiliza operação de convolução para abstração das informações para as camadas seguintes (Schmidhuber, 2015). Essa abordagem apresenta vantagens em relação a uma rede convencional, pois considera a informação espacial da imagem como fator determinante para atribuição e ajuste dos pesos.

A versatilidade presente na construção das DNN, possibilita a exploração de inúmeras configurações e topologias, incluindo a junção de camadas auxiliares para lidar com tipos diferentes de dados em uma mesma aplicação, diferentemente das demais técnicas de aprendizado de máquinas convencionais, com características mais estáticas e limitadas (LeCun *et al.*, 2015).

DNNs do tipo Convolucionais, também conhecidas como *Convolutional Neural Networks* (CNN), utilizam camadas de convoluções para abstrair imagens como entrada e propagar o sinal devidamente apropriado para as camadas subsequentes, logo a própria imagem se torna um conjunto de parâmetros, no qual cada pixel é tratado como um elemento de entrada individual que se correlaciona com outros pixels conforme as operações de convolução ocorrem enquanto o sinal se propaga entre as camadas da rede (Schmidhuber, 2015). Logo, a própria CNN realiza a extração de parâmetros internamente.

Neste trabalho serão investigadas duas abordagens de utilização de DNN, conforme ilustra a Figura 3.2. O uso destas abordagens consiste no tipo de dado explorado no problema.

**Figura 3.2** – Abordagens de DNN investigadas: (a) DNN com dados numericos resultante dos métodos de análise dos estados caóticos; (b) DNN do com imagens dos planos do VCG.



Fonte: Elaborado pelo autor.

Para definição da DNN como algoritmo a ser utilizado, foi realizada uma análise comparativa inicial, no qual foram avaliados diversos algoritmos de aprendizado de máquina com configurações semelhantes para a resolução de um mesmo problema de classificação. Entre eles foram avaliados: O *Gradient Boosting* (GB), representando o conjunto de algoritmos baseados em árvores de decisões residuais, em que modelos de aprendizado fracos são aninhados para resolução de um problema maior, utilizando a função de erro como parâmetro para ajuste dos modelos (Friedman, 2001). *K-Nearest Neighbors* (KNN), representando o conjunto de algoritmos baseados em aproximação, no qual cada amostra do banco é abstraído para um plano, utilizando os valores de seus atributos para determinam a posição, em seguida é definida a classe da amostra a partir da observação dos k-vizinhos mais próximos os quais as classes já são conhecidas (Prasath *et al.*, 2017). *Support Vector Machine* (SVM), representando o conjunto de algoritmos que utilizam regressão para definir delimitadores, neste caso o SVM define vetores que representam uma limitação de áreas correspondentes às classes. Estas limitações são chamadas de *hyperplanes*, que se ajustam à medida que novas amostras acrescentam informações na forma de como as áreas devem ser organizadas (Smola & Schölkopf, 2004). Além dos algoritmos mencionados, também foi avaliada uma rede do tipo *Multi-Layer Perceptron* (MLP), representando uma RNA simples, como destacado nesta seção.

### 3.1 – Métricas de Avaliação do Modelo

Uma das maneiras mais utilizadas de avaliação de modelos de aprendizado de máquina consiste na análise da contingência da classificação das amostras, que pode ser observada na matriz de confusão. Este método é comumente utilizado em classificações binárias, e apresenta a taxa de acertos e erros que o modelo obtém entre a classe obtida e a esperada. Para isso, são observadas as seguintes situações: tomando como exemplo duas classes A e B, temos Verdadeiro Positivo (VP), quando o modelo classifica uma amostra A como pertencente a sua respectiva classe esperada A; Verdadeiro Negativo (VN), quando o modelo classifica a amostra A com B; Falso positivo (FP), quando o modelo classifica B como B e falso negativo (FN), quando o modelo classifica B como A. Este exemplo é ilustrado na Figura 3.3.

Figura 3.3 – Exemplo de matriz de confusão.

		Classes obtida	
		A	B
Classes esperadas	A	VP	FP
	B	FN	VN

Fonte: Elaborado pelo autor.

A partir das informações presentes na matriz de confusão, também é possível calcular métricas como a acurácia, sensibilidade, especificidade e a área abaixo da Curva Característica de Operação do Receptor, também conhecida por Curva *Receiver Operating Characteristic Curve* (ROC).

A primeira métrica a ser descrita, a acurácia, consiste na proporção entre classificações corretas em uma população. Isso é, a razão entre classificações corretas feitas pelo modelo ( $VP + VN$ ) e o número total de classificações ( $VP + FP + VN + FN$ ), ou ainda, considerando o cenário do trabalho, a soma entre de sinais classificados como normais ou infartados corretamente dividida pelo total de sinais (Zhu *et al.*, 2010).



---

A sensibilidade indica a capacidade do classificador de retornar um verdadeiro positivo, isso é a capacidade de detecção de infarto em um sinal que de fato corresponde à um infarto, ou seja, é dado pela razão entre  $VP$  e  $VP + FN$  (Zhu *et al.*, 2010).

Enquanto a sensibilidade é utilizada para avaliar a capacidade de retornar verdadeiros positivos, a especificidade é utilizada de forma similar para os verdadeiros negativos. Para o presente trabalho, ela indica a proporção de sinais classificados como normais dentre todo o conjunto de normais. Assim, a especificidade é dada pela razão entre  $VN$  e  $VN + FP$  (Zhu *et al.*, 2010).

Uma forma de analisar um modelo é com base na relação entre sua taxa de verdadeiros positivos ( $TVP =$  sensibilidade) e sua taxa de falsos positivos ( $TFP = 1 -$ especificidade). Considerando todo o conjunto de combinações entre esses valores, onde cada combinação determina um ponto, é possível definir um espaço chamado de espaço ROC, onde o ponto ideal, com sensibilidade e especificidade iguais a 1, é determinado por  $(TFP, TVP) = (0, 1)$ , os quais podem ser representados, de maneira respectiva, com base nos eixos cartesianos. Com base nisso, é possível se obter uma curva que relaciona essas duas variáveis, de forma que um modelo é considerado mais robusto caso essa curva se aproxime do caso ideal de forma mais rápida. Assim, uma forma de sumarizar a informação dessa curva é por meio da área abaixo dela, onde uma área com valores próximos a 1 indicam uma maior acurácia do teste, já que isso indica que a curva se aproxima do ponto ideal com maior rapidez Zhu *et al.* (2010).

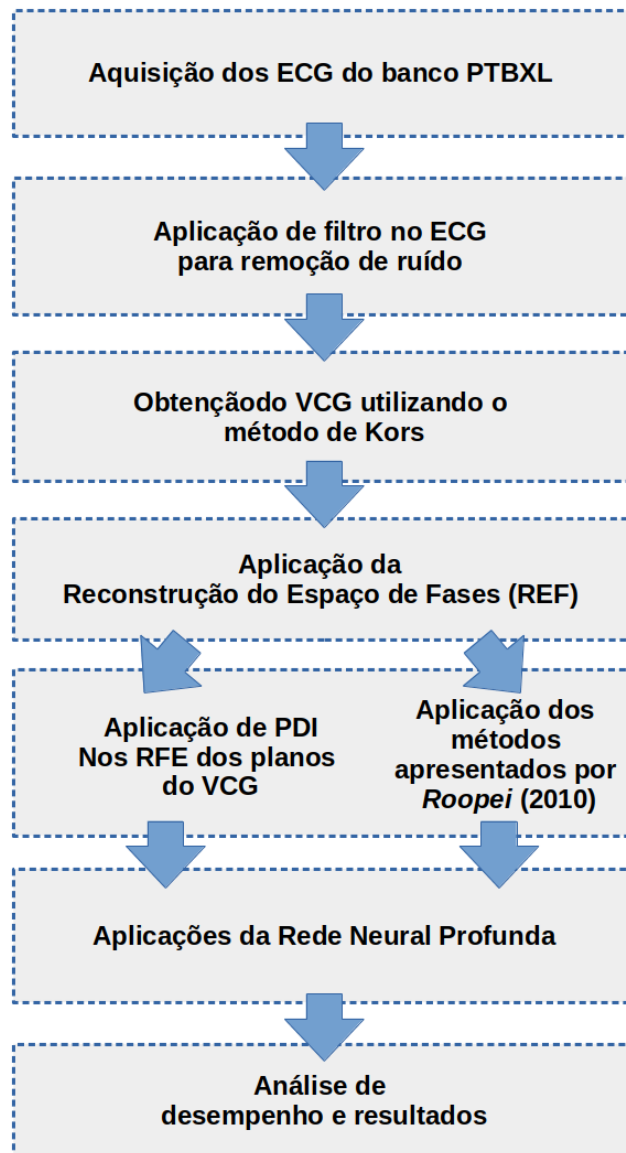
Diversas abordagens exploram técnicas de identificação de infarto do miocárdio a partir da aplicação de aprendizado de máquina (Jiang *et al.*, 2017). Porém, o desafio atual consta na etapa de pré-processamento, ou seja, antes da aplicação de técnicas como Redes Neurais Artificiais ou algoritmos de aprendizado de máquina convencionais (Jen *et al.*, 2008). A utilização de técnicas de pré-processamento pode melhorar consideravelmente o desempenho da abordagem utilizada, isto porque reduz problemas como excesso de dados nulos ou ruidosos, além de direcionar a seleção dos parâmetros mais influentes na construção do modelo (Jen *et al.*, 2008; Wu *et al.*, 2013).

Neste trabalho, a utilização da DNN (*Deep Neural Network*) para identificação do IM compõe uma das etapas investigadas, em conjunto com análise de técnicas de extração e seleção de parâmetros a partir do ECG. Para contextualizar as investigações, neste capítulo são descritos os principais recursos que serão utilizados na elaboração da proposta, além da forma esperada de utilização de cada um deles, conforme ilustrado na Figura 4.1.

A abordagem pode ser dividida em três principais etapas, inicialmente com a manipulação dos dados de ECG oriundos da base de dados alemã PTB-XL Wagner *et al.* (2020), incluindo aqui a organização, filtragem e conversão dos sinais, em seguida serão aplicadas técnicas de extração e avaliação de parâmetros, por fim será realizado a análise de arquitetura de DNN utilizando a biblioteca Tensorflow (Abadi *et al.*, 2015).

Todas as etapas presentes neste trabalho podem ser consideradas dentro do escopo de uma aplicação de mineração de dados, desde a aquisição dos dados até a identificação de padrões utilizando técnicas de aprendizado de máquina. Porém, para melhorar a organização do texto, as etapas de pré-processamento e aplicação de redes neurais são abordadas de forma individual.

Figura 4.1 – Fluxograma de execução das atividades.



Fonte: Elaborado pelo autor.

## 4.1 – Aquisição dos Dados

Em uma aplicação envolvendo RNAs ou em outras técnicas de aprendizado de máquina convencionais, a base de dados é um dos principais pontos decisivos para o sucesso da aplicação, uma vez que a qualidade e quantidade dos dados podem impactar consideravelmente o desempenho e precisão do modelo. Por este motivo, neste trabalho, foi utilizada a base de dados do Instituto Nacional de Metrologia da Alemanha, *Physikalisch-Technische Bundesanstalt* (PTB-XL) Wagner *et al.* (2020), uma das mais utilizadas para o desenvolvimento e testes de

algoritmos para processamento de sinais de ECG, devido à qualidade e organização dos dados disponíveis (Strodthoff *et al.*, 2020).

O PTB-XL contém 21837 registros de ECGs coletados entre outubro de 1989 e junho de 1996, cada um com 12 derivações e duração de 10 segundos de 18885 pacientes (9820 homens e 9065 mulheres) com idades entre 0 e 95 anos, sendo a mediana de idade de 62 anos. Associados cada registro existem diagnósticos feitos em 5 superclasses (normal, infarto do miocárdio, distúrbio de condução, hipertrofia e alteração no segmento ST/T) e 24 subclasses, podendo estar em mais de uma subclasse, e anotações padronizadas feitas por até dois cardiologistas em relação à morfologia, ritmo e diagnóstico.

A relação dos números de registros e seu agrupamento em suas superclasses e subclasses pode ser visto na Tabela 4.1.

**Tabela 4.1** – Tabela contendo a relação do número de ECGs por superclasses e subclasses. (\*) Acrônimos baseados no nomes das superclasses/subclasses em língua inglesa.

		Acrônimo (*)	Descrição	Número de ECGs
Superclasse		NORM	ECG Normal	9528
		CD	Distúrbio de condução	5772
		MI	Infarto do Miocárdio	6866
		HYP	Hipertrofia	2819
		STTC	Mudança ST/T	5788
Subclasse	NORM	NORM	ECG Normal	9528
	CD	LAFB/LPFB	Bloqueio Fascicular Anterior/Posterior Esquerdo	1803
		IRBBB	Bloqueio de Ramo Direito Incompleto	1118
		ILBBB	Bloqueio de Ramo Esquerdo Incompleto	77
		CLBBB	Bloqueio de Ramo Esquerdo Completo	536
		CRBBB	Bloqueio de Ramo Direito Completo	542
		_AVB	Bloqueio Atrioventricular	827
		IVCB	Bloqueio Intraventricular Não Específico	789
		WPW	Síndrome de Wolff-Parkinson-White	80
	HYP	LVH	Hipertrofia do Ventrículo Esquerdo	2137
		RHV	Hipertrofia do Ventrículo Direito	126
		LAO/LAE	Sobrecarga/Aumento do Átrio Esquerdo	427
		RAO/RAE	Sobrecarga/Aumento do Átrio Direito	99
		SEHYP	Hipertrofia Septal	30
	MI	AMI	Infarto do Miocárdio Anterior	3387
		IMI	Infarto do Miocárdio Inferior	3281
		LMI	Infarto do Miocárdio Lateral	201
		PMI	Infarto do Miocárdio Posterior	17
	STTC	ISCA	Isquemia em Derivações Anteriores	1016
		ISCI	Isquemia em Derivações Inferiores	398
		ISC_	Isquemia Não Específica	1275
		STTC	Mudanças ST-T	2329
		NST_	Mudanças ST Não Específicas	770

O processo de obtenção dos ECG consiste na aquisição da forma de onda para as 12 derivações, com frequência de amostragem de 400 Hz e com o eletrodo de referência no braço direito. Sendo então obtidos apenas 10 segundos dessa forma de onda. Os sinais são então

inseridos em um banco de dados junto com os metadados associados como identificador do exame, paciente ou arquivo, idade, sexo, altura, peso, locais de infarto, presença de marcapasso, etc, além de passarem por uma avaliação inicial automatizada ou por um cardiologista.

Para auxiliar na utilização, cada registro de ECG disponível para download na base de dados conta com três arquivos de extensões diferentes: arquivos de anotações de referência com extensão *.atr*; arquivo de sinal com extensão *.dat*; e arquivo de cabeçalho (metadados) com extensão *.hea*. Além disso, os metadados relacionados à identificação do paciente são alterados para garantir seu anonimato, mas de forma que não haja alteração em dados clínicos.

Neste trabalho, inicialmente foram utilizados no total 16.397 sinais, correspondentes a soma dos sinais das classes NORM e MI, com exceção da subclasse MI/PMI, devido a pouca quantidade de sinais. Porém para reduzir os efeitos da discrepância da quantidade de amostras diferentes entre as classes, algo que pode prejudicar o desempenho da DNN, para contornar este problema, foi utilizado uma técnica de balanceamento de carga, em que o número de amostras das classes majoritárias foi reduzido para valores mais próximos das classes minoritárias.

## 4.2 – Pré-processamento

Os dados em sua forma bruta, ou seja, da forma como são obtidos na base de dados, normalmente apresentam falhas como ruídos no caso dos sinais ou dados nulos no caso dos metadados, o que pode prejudicar o desempenho dos algoritmos de aprendizado de máquina. Neste contexto, é possível aplicar diversas técnicas que eliminam ou diminuem essas falhas.

Neste trabalho, a ausência dos metadados relacionados a um sinal implica na eliminação da amostra, uma vez que inviabiliza a classificação do sinal. No caso de sinais de ECG, devido ao ruído, a alternativa adotada consiste na aplicação de um filtro passa-baixas *Butterworth* de quarta ordem com frequência de corte de 500 Hz e dois filtros *Notch Butterworth*, ambos de segunda ordem, com frequências de corte de 50 Hz e 60 Hz a fim de reduzir ruídos musculares e devido à interferência elétrica, gerados durante a obtenção do ECG. A aplicação de filtros implica na alteração do sinal original, o que pode alterar informações referentes a patologias, por isso os filtros adotados foram selecionados com base em trabalhos anteriores nos quais os impactos das filtragens não infligiram grandes alterações (Silva *et al.*, 2019; Costa *et al.*, 2018).

Ainda na etapa de pré-processamento, foi obtido o Vetocardiograma a partir da Matriz de Regressão de Kors, descrito na Seção 2.4. Este método recebe como entrada as oito derivações convencionais de ECG e resulta nas três derivações ortogonais.

## 4.3 – Estratégias de Extração de Parâmetros

Atualmente é possível identificar na literatura diversas abordagens de extração de parâmetros a partir de sinais de ECG. Essa diversidade aumenta quando é considerado o advento das aplicações envolvendo Aprendizado de Máquina, uma vez que novas abordagens são exploradas de forma automatizada, possibilitando a identificação de padrões parcialmente ou totalmente imperceptíveis para o ser humano (Wu *et al.*, 2013). Neste trabalho foram empregadas duas técnicas, a primeira consiste na extração a partir da abordagem apresentada por (Roopaei *et al.*, 2010), na qual é realizada a análise dos estados caóticos de um sinal, e a segunda consiste no uso direto dos planos do VCG, em que a imagem ajustada de cada plano é apresentada como entrada para uma rede do tipo CNN. Nesta seção, estes métodos serão explicados com maior aprofundamento.

### 4.3.1 – Extração de Parâmetros a partir da Reconstrução do Espaço de Fases

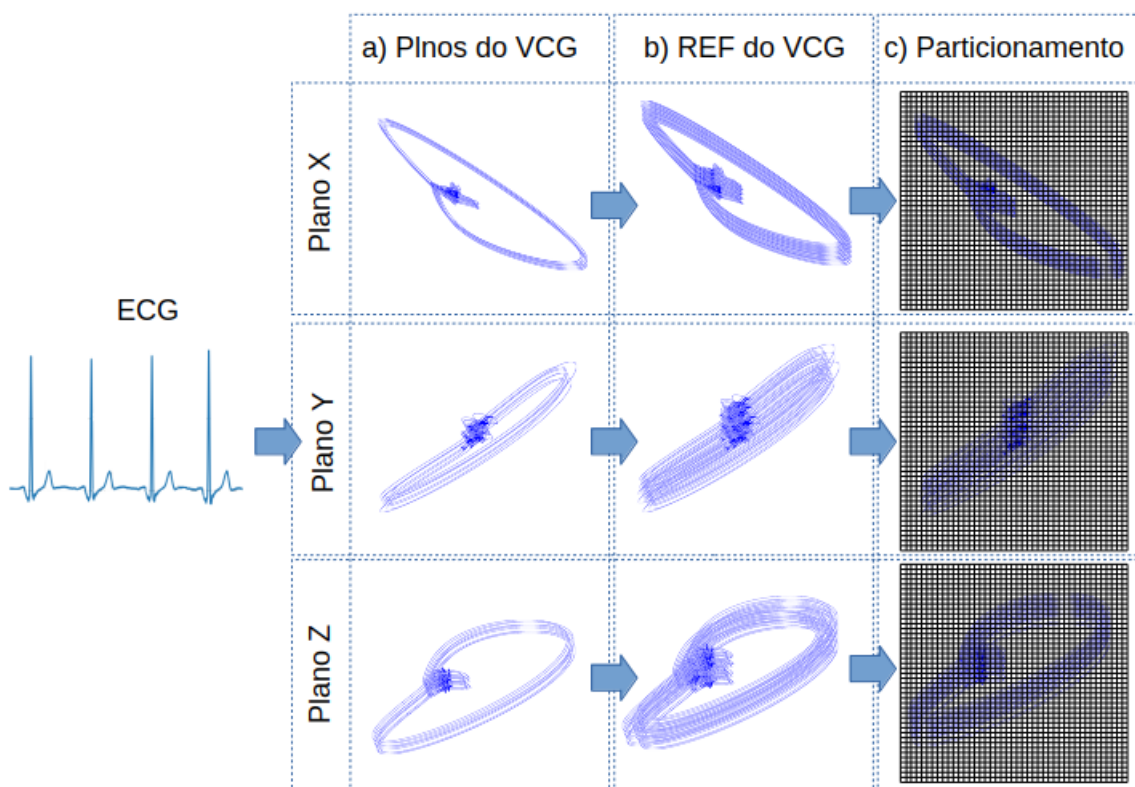
O Espaço de Fases (EF) representa o conjunto de todos os estados possíveis em um sistema dinâmico em um intervalo de tempo, no qual as características do sinal podem ser combinadas em uma representação bidimensional denominada plano de fases, a partir desta representação é possível extrair diversos parâmetros e características imperceptíveis na representação convencional do sinal (Abraham *et al.*, 1990).

A Reconstrução do Espaço de Fases (REF) a partir do método baseado no Teorema da Imersão é uma das formas mais utilizadas para a obtenção do EF (Takens, 1981). Este método consiste em um série temporal ( $x[n_i]$ ), como um ECG ou as derivações ortogonais do VCG, do qual um espaço bidimensional é representado a partir de sua versão atrasada por um tempo ( $\tau$ ) pré-definido, como é apresentado na Eq. 4.1, na qual para  $i = 1, 2, \dots, N - (m - 1)$ , em que  $N$  representa o número total de amostras do sinal,  $m$  representa a dimensão da imersão,  $\tau$  é o tempo de atraso, conhecido como passo de reconstrução (Costa *et al.*, 2018).

$$X[n] = x[n], x[n - \tau], \dots, x[N - (m - 1) * \tau] \quad (4.1)$$

Esta abordagem é amplamente utilizada na literatura para a análise do sinal eletrocardiográfico (Roberts *et al.*, 2001; Costa *et al.*, 2018; Al-Fahoum & Qasaimeh, 2006). Por esse motivo, uma das técnicas de extração de parâmetros utilizadas neste trabalho consiste na análise da REF das derivações ortogonais do VCG a partir dos métodos propostos por Roopaei *et al.* (2010). Nesta abordagem o VCG é obtido do ECG a partir do método de Kors, e a partir cada derivação do VCG são gerados os REF com  $\tau = 0,01$  (Roopaei *et al.*, 2010; Kliková & Raidl, 2011), como é apresentado na Figura 4.2 a) e 4.2 b).

**Figura 4.2** – Reconstrução do Espaço de Fases.



Fonte: Elaborado pelo autor.

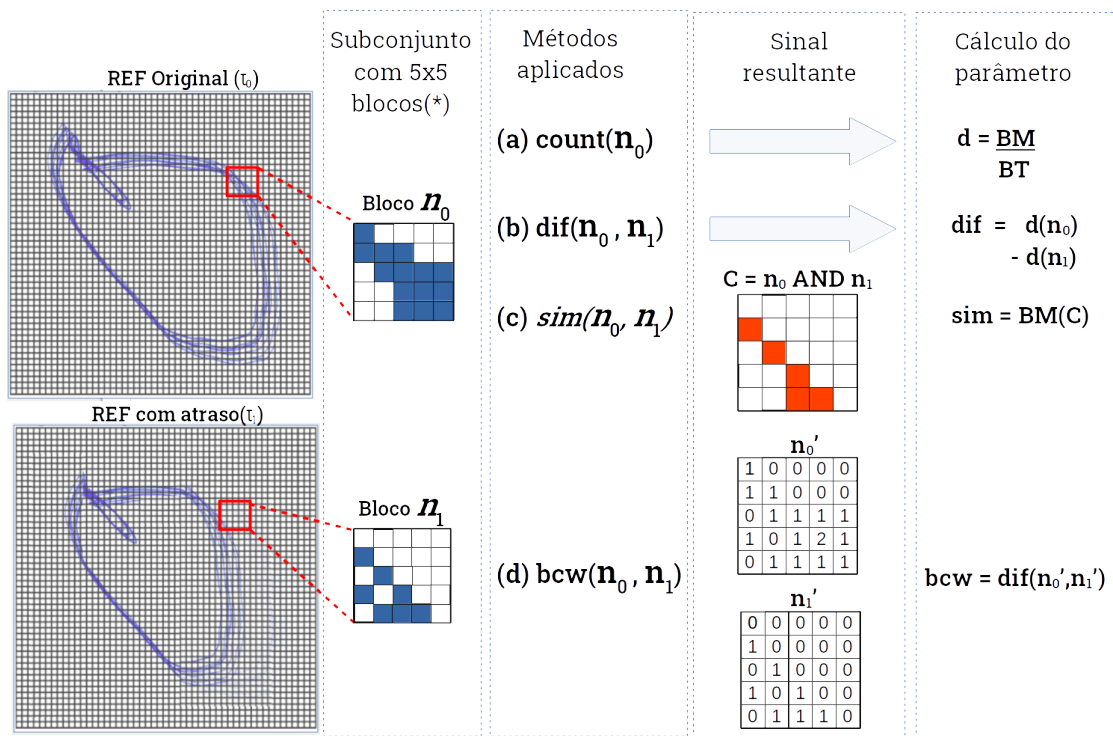
Para obtenção de parâmetros a partir do ECG usando REF, é possível encontrar na literatura diversas abordagens, como a observação dos critérios caóticos como a dimensão de correlação (Zhu *et al.*, 2008), o maior expoente de Lyapunov (Arrobo *et al.*, 2014), a entropia aproximada (Castiglioni & Di Rienzo, 2008), ou por meio dos métodos da diferença, similaridade e contagem de caixas ponderadas propostos por Roopaei *et al.* (2010).

Com base nos resultados prévios obtidos em Costa *et al.* (2018), neste trabalho serão utilizados os métodos da contagem de caixas, diferença, similaridade e contagem de caixas ponderadas, visto que, esses parâmetros foram aplicados em sinais de ECG para identificação e

classificação de arritmias (Roopaei *et al.*, 2010; Amann *et al.*, 2006). Outro fator motivador para o uso deste método é a ausência de trabalhos na literatura relacionados à reconstrução do espaço de fases como ferramenta de análise em sinais com IM, o que proporciona mais oportunidades para investigações.

A abordagem utilizada recebe como entrada uma imagem quadrada resultante da reconstrução da trajetória do espaço de fases, esta imagem é percorrida em blocos de pixels, de determinados tamanhos, a partir destes blocos é realizada a aplicação dos métodos conforme apresentado na Figura 4.3.

**Figura 4.3** – Métodos de extração de parâmetros a partir do REF.



Fonte: Elaborado pelo autor.

- **Método da contagem de caixas:** Estima a dimensão caótica da trajetória da REF, dada pelo índice  $d$ . Esse índice é definido a partir da divisão da quantidade de blocos que contêm partes dessa trajetória (blocos marcados *BM* Figura 4.3) pelo número total de blocos em que a imagem foi segmentada *BT* (Amann *et al.*, 2006);
- **Método da diferença:** Indica a auto-similaridade da REF, consistindo na geração de duas imagens do espaços de fases reconstruídos de um mesmo sinal, mas com atrasos



diferentes ( $n_0$  e  $n_1$ ), de forma que o índice  $d$  é calculado para as duas imagens  $d(n_0)$  e  $d(n_1)$ , sendo então calculada a diferença entre eles;

▣ **Método da similaridade:** Utilizando dois espaços de fases reconstruídos de mesmo sinal com atrasos diferentes ( $n_0$  e  $n_1$ ), uma nova imagem é gerada a partir da operação lógica  $E$  entre os pixels correspondentes delas, no qual os pixels preenchidos equivalem a 1 e os pixels vazios equivalem a 0. É feita então a soma dos valores dos pixels da nova imagem, sendo retornado um número inteiro, de modo que quanto maior seu valor, maior a similaridade entre as duas REF (Roopaei *et al.*, 2010);

▣ **Método da contagem de caixas ponderadas:** São atribuídos os seguintes valores para os blocos:

- 0, se o bloco não é marcado;
- 1, se o bloco é marcado, mas nem todos ao seu redor são marcados;
- 2, se o bloco e os demais blocos ao seu redor são marcados.

Esse procedimento é realizado para duas imagens do espaço de fases reconstruído com atrasos diferentes, sendo então calculado o índice  $d$  para cada uma delas e, em seguida, a diferença entre os dois índices, de forma similar ao método da diferença.

A partir da aplicação dos métodos explicados anteriormente, foram extraídos no total de 15 parâmetros numéricos a partir dos planos do VCG, cada um deles corresponde a uma entrada de uma RNA. O parâmetros foram rotulados conforme apresenta a Tabela 4.2.

#### 4.3.2 – Planos do VCG

Os planos das perspectivas tridimensionais do VCG ( $xy$ ,  $xz$  e  $yz$ ) apresentam formas distintas que possibilitam a observação de informações a partir dos padrões. Porém, as formas são caracterizadas por linhas finas que se propagam em uma área com tamanho igual ou maior, reduzindo a qualidade da informação quando as imagens são utilizadas em estruturas como Redes Neurais Artificiais. Neste contexto, uma das alternativas para ampliar o potência destas formas consiste em aplicar técnicas de Processamento de Imagens (PDI) para remoção de ruídos ou melhoramento da qualidade da imagem.

Para melhorar a qualidade das imagens de entrada utilizadas neste trabalho, foram aplicadas operações morfológicas no sinal. Estas técnicas são baseadas na teoria dos conjuntos,

**Tabela 4.2** – Parâmetros extraídos a partir dos métodos apresentados por Roopaei *et al.* (2010).

Parâmetros	Descrição
d1_x	Contagem de blocos 1 para a derivação Vx
d2_x	Contagem de blocos 2 para a derivação Vx
d1_y	Contagem de blocos 1 para a derivação Vy
d2_y	Contagem de blocos 2 para a derivação Vy
d1_z	Contagem de blocos 1 para a derivação Vz
d2_z	Contagem de blocos 2 para a derivação Vz
d_dif_x	Método da diferença para a derivação Vx
d_dif_y	Método da diferença para a derivação Vy
d_dif_z	Método da diferença para a derivação Vz
sim_x	Método da similaridade para a derivação Vx
sim_y	Método da similaridade para a derivação Vy
sim_z	Método da similaridade para a derivação Vz
d_pond_x	Contagem de blocos ponderados para a derivação Vx
d_pond_y	Contagem de blocos ponderados para a derivação Vy
d_pond_x	Contagem de blocos ponderados para a derivação Vz

Fonte: Elaborado pelo autor.

e normalmente são utilizadas para remover ruídos ou prover informações relacionadas às formas estruturais da imagem.

Mais especificamente, a abordagem utilizada consiste na dilatação da imagem, na qual o operador lógico *OU* é utilizado enquanto uma janela deslizante (*kernel*) de tamanho 5x5, percorre a imagem binarizada, sendo o *pixel* central da janela realçado caso algum *pixel* da janela sobreponha um *pixel* da estrutura da imagem. O resultado desta operação em um plano do VCG pode ser observado na Figura 4.4.

**Figura 4.4** – Exemplo de dilatação morfológica em um plano XZ do VCG.



Fonte: Elaborado pelo autor.

## Configuração e execução dos experimentos

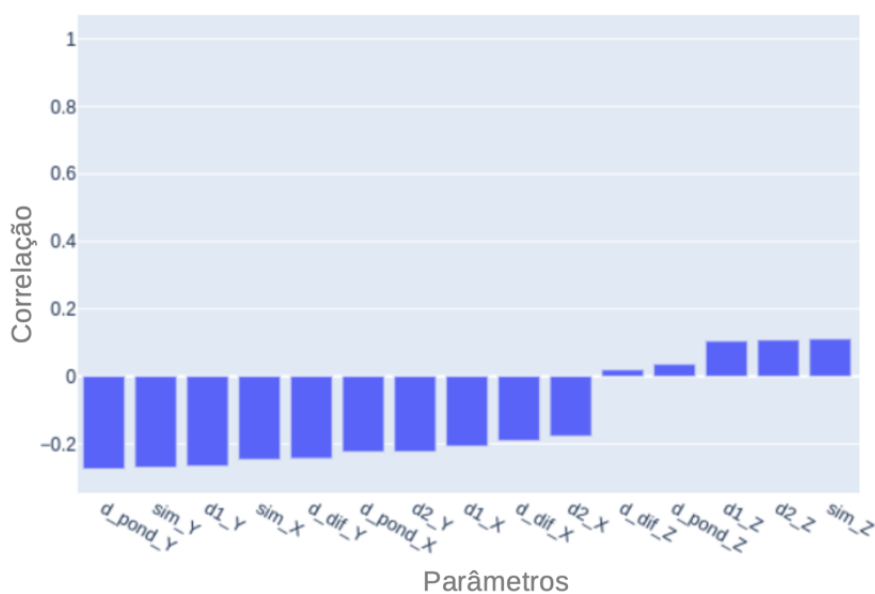
Neste Capítulo, serão apresentadas as configurações utilizadas para aplicar os métodos apresentados no Capítulo 4. Também será realizado uma breve análise dos parâmetros extraídos por meio da técnica REF.

### 5.1 – Configuração do conjunto de dados

Inicialmente, o método de Kors foi utilizado para a reconstrução do VCG a partir do ECG e, em seguida, foi realizada a extração dos parâmetros utilizando o método da análise dos estados caóticos da reconstrução do espaço de fases dos planos desse VCG reconstruído, conforme apresentado na Sessão 4.3. Além disto, também foi realizada uma análise da qualidade dos parâmetros. Neste contexto, a qualidade corresponde a influência que cada parâmetro exerce para a predominância de uma classe, ou seja, a categoria. Esta influência pode ser mensurada de diversas formas, uma alternativa para isso é a correlação de *Pearson*, que avalia o grau de correlação, positiva ou negativa, entre duas variáveis, o que indica o quanto ambas são simultaneamente afetadas pelas mesmas condições (Benesty *et al.*, 2009).

Na Figura 5.1, ao analisar a correlação obtida entre os parâmetros apresentados na Tabela 4.2 e as classes patológicos e saudáveis, é possível observar que os parâmetros obtidos a partir dos planos *X* e *Y* apresentam as correlações mais promissoras para um bom desempenho do modelo, com valores negativos em torno de até  $-0.3$ , enquanto o plano *Z* apresenta uma correlação mais neutra, com valores positivos com inferior aos outros planos, de até  $0.02$ . Esta análise é comumente utilizada em etapa de seleção de parâmetros, porém ao trabalhar com redes neurais profundas, este processo é realizado indiretamente pelas camadas iniciais das redes, durante o processo de ajuste de pesos, em que os neurônios acabam reduzindo significativamente o peso dos parâmetros menos influentes.

**Figura 5.1** – Correlação de *Pearson* dos parâmetros utilizadas.



Fonte: Elaborado pelo autor.

A diferença na quantidade de amostras de cada classe foi um dos desafios encontrados durante a elaboração dos experimentos. Esta diferença pode interferir na qualidade do modelo e resultar na ocorrência de *overfitting*, situação na qual o modelo se ajusta perfeitamente a um conjunto de dados durante o treinamento, e se torna ineficiente para um novo conjunto desconhecido. Para contornar este problema e promover conjuntos de dados balanceados, amostras aleatórias das classes majoritárias foram removidas até igualar à quantidade das classes minoritárias, este processo é conhecido como subamostragem, ou *undersampling*. Outra alternativa comumente utilizada, consiste em aumentar as amostras minoritárias acrescentando leves ruídos às amostras, esta técnica é bastante utilizada em banco de dados de imagens, porém no problema investigado, essa abordagem pode resultar em falsos-positivos para doenças e reduzir a especificidade da rede.

Para ampliar os cenários explorados, foram executados experimentos com combinações binárias de classes, utilizando os sinais normais como variável de controle e os sinais patológicos como variantes. As configurações de conjuntos de dados por experimento são apresentados na Tabela 5.1.

Tabela 5.1 – Balanceamento das classes.

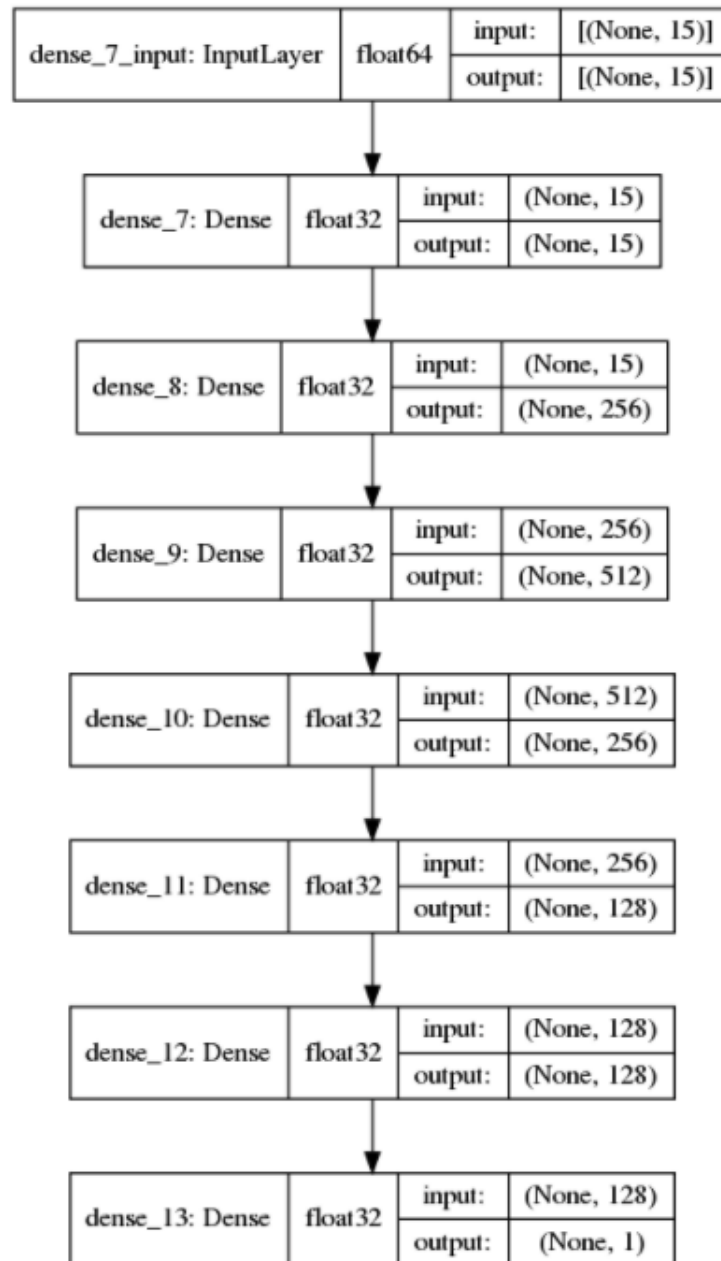
Sem balanceamento		Conjunto de dados por experimentos			
Classes	Sem cortes	Multiclasse	Binário: NORM & AMI	Binário: NORM & IMI	Binário: NORM & LMI
NORM	73917	1000	10000	8800	630
AMI	12779	1000	10000	–	–
IMI	8879	1000	–	8800	–
LMI	631	630	–	–	630

Fonte: Elaborado pelo autor.

Cada conjunto de dados por experimento foi particionado em 70% para treino, 15% para validação e 15% para teste. As especificações do modelo e do teste foram configuradas igualmente para todos os experimentos com: *batch size* 32, 1000 épocas de treinamento, e função de ajuste estocástico, Adam, com taxa de aprendizado de 0.001. Estas configurações foram baseadas nas orientações presentes em Kingma & Ba (2014) para valores padrões a serem utilizados em experimentos utilizando redes neurais artificiais.

Atualmente, é possível reutilizar diversas arquiteturas e modelos consolidados ou promissores de DNN, tais como U-Net (Ronneberger *et al.*, 2015; Huang *et al.*, 2020), ResNet (Li *et al.*, 2016), I-Net (Weng & Zhu, 2021), etc. Porém, neste trabalho foi utilizada uma arquitetura personalizada, estruturada a partir de um conjunto de camadas sequenciais. Com esta arquitetura foi possível a realização dos experimentos com menor complexidade e resultados viáveis. A arquitetura utilizada pode ser visualizada na Figura 5.2, variando 2 neurônios na camada de saída para classificação binária, 4 neurônios na camada de saída para classificação multiclasse, e a camada de entrada alterada para uma camada convolucional com formato  $255 \times 255$ , para o cenário com as imagens dos planos. Esta estrutura foi escolhida com base no melhor resultado de classificação obtido em um processo empírico de tentativa-erro no qual várias combinações de camadas e neurônios foram avaliadas.

Figura 5.2 – Arquitetura da DNN utilizada.



Fonte: Elaborado pelo autor.

## Análise dos Resultados

Este Capítulo apresenta os resultados do experimento no qual foi utilizado uma DNN para classificação de variação de infartos a partir de parâmetros extraídos de sinais de ECG. Também são apresentadas variações do experimento na qual a mesma rede realiza classificações binárias entre sinais de pacientes saudáveis como grupo de controle e sinais com diagnóstico de infarto como variantes. Além da análise dos planos de VCG utilizando redes neurais convolucionais. Os resultados estão representados em tabelas e gráficos que serão discutidos no decorrer do capítulo.

### 6.1 – Classificação multiclasse

Para este experimento, foi utilizado um banco de dados contendo 3.630 amostras, sendo 1000 para sinais de ECG normais, 1000 para AMI, 1000 para IMI e 630 para LMI. Estes limites foram estabelecidos para reduzir os efeitos do desbalanceamento das classes. A classificação apresentou valores entre 97% e 98,9% para as métricas Acurácia (Acc), Sensibilidade (Sen), Especificidade (Esp) e AUC na validação e no teste, como pode ser observado na Tabela 6.1. Este resultado é levemente inferior quando comparado com os demais experimentos realizados neste trabalho, porém é importante destacar o corte na quantidade de amostras por classes e também o aumento das classes podem influenciar diretamente no desempenho do modelo. Na Tabela, também é apresentado o valor médio da taxa de erro (Los).

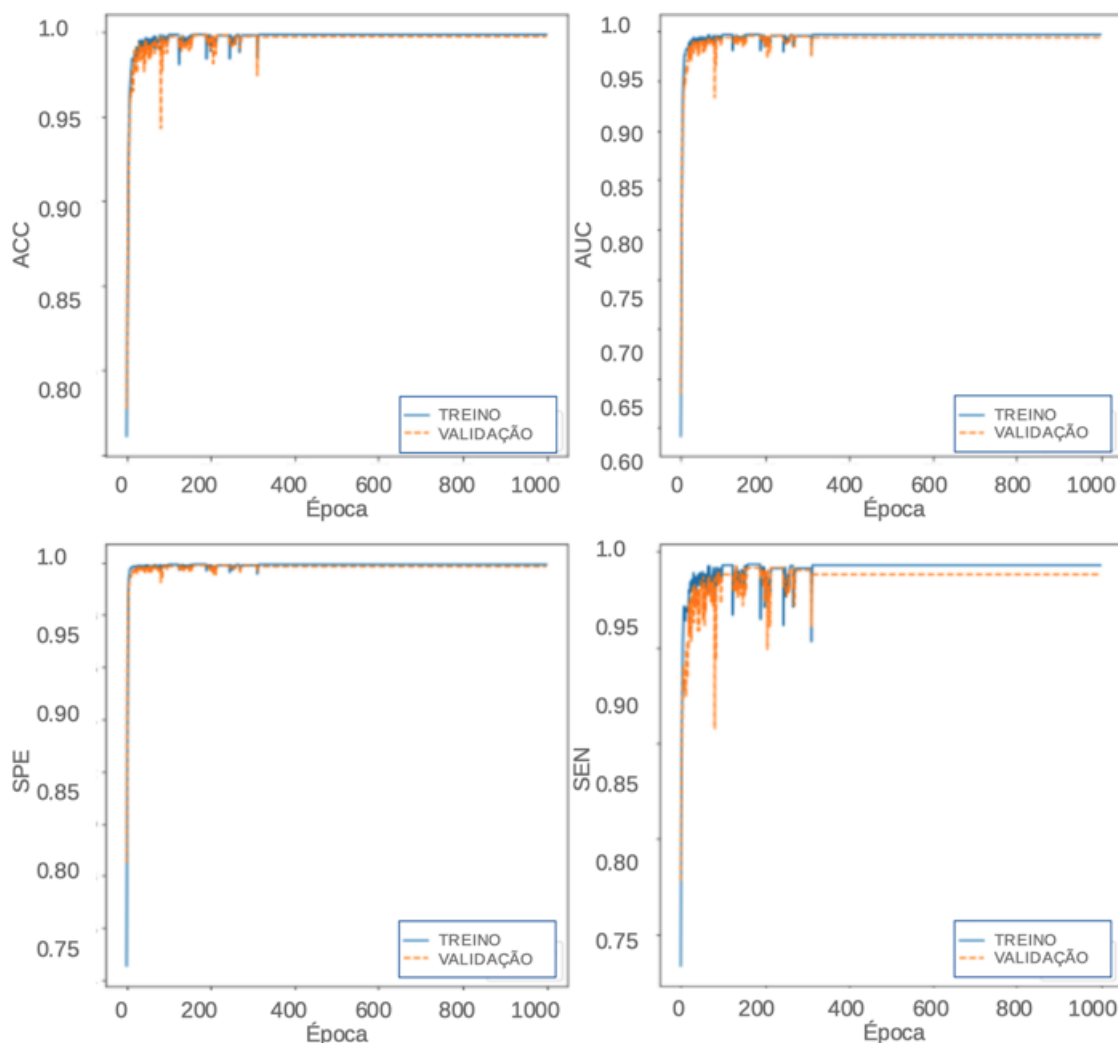
**Tabela 6.1** – Resultados da classificação com todas as classes.

	<b>Los</b>	<b>Acc</b>	<b>Sen</b>	<b>Spe</b>	<b>AUC</b>
<b>Treino</b>	0.0012	0.9973	0.9855	0.9993	0.9983
<b>Validação</b>	0.0071	0.9861	0.9734	0.9754	0.9865
<b>Teste</b>	0.0048	0.9833	0.9712	0.9899	0.9819

Fonte: Elaborado pelo autor.

As métricas apresentadas na Figura 6.1 indicam o ajuste inicial dos pesos da rede, sendo necessária uma quantidade de até 400 épocas para a convergência e estabilização. A sensibilidade apresenta uma validação inferior quando comparada às demais métricas, e também aos demais experimentos. Esse comportamento é resultante do aumento de classes que impacta no aumento de casos classificados como falso negativo.

**Figura 6.1** – Métricas de treino e validação para classificação multiclasse.



Fonte: Elaborado pelo autor.

Os resultados apresentados na Tabela 6.1 e na Figura 6.1, indicam que o método utilizado para extração de parâmetros possibilitou um conjunto de dados consistente que resultou na definição clara das classes. Em (Costa *et al.*, 2018), uma abordagem semelhante foi utilizada para a extração de parâmetros, porém a classificação foi configurada como binária entre o grupo de controle composto por sinais de ECG normais e o grupo variante composto por uma mescla de sinais de diversas patologias, esta abordagem apresenta um objetivo bem



definido, porém ao mesclar as classes é atribuído ruído devido a variação dos parâmetros de cada classe em um mesmo conjunto, o que pode resultar em um resultado inferior ao obtido neste trabalho.

## 6.2 – Classificações binárias

Nesta Seção, são apresentados os resultados dos experimentos para classificações binárias, utilizando sinais de ECG normais como grupo de controle e sinais de ECG patológicos como grupo variante. Este tipo de classificação possibilita observar a efetividade dos parâmetros de uma classe de forma individual e, conseqüentemente, identificar possíveis interferências ocasionadas por outras quando considerado a classificação com multiplicas classes.

### 6.2.1 – Classificação em Normais e Infarto na Parede Anterior

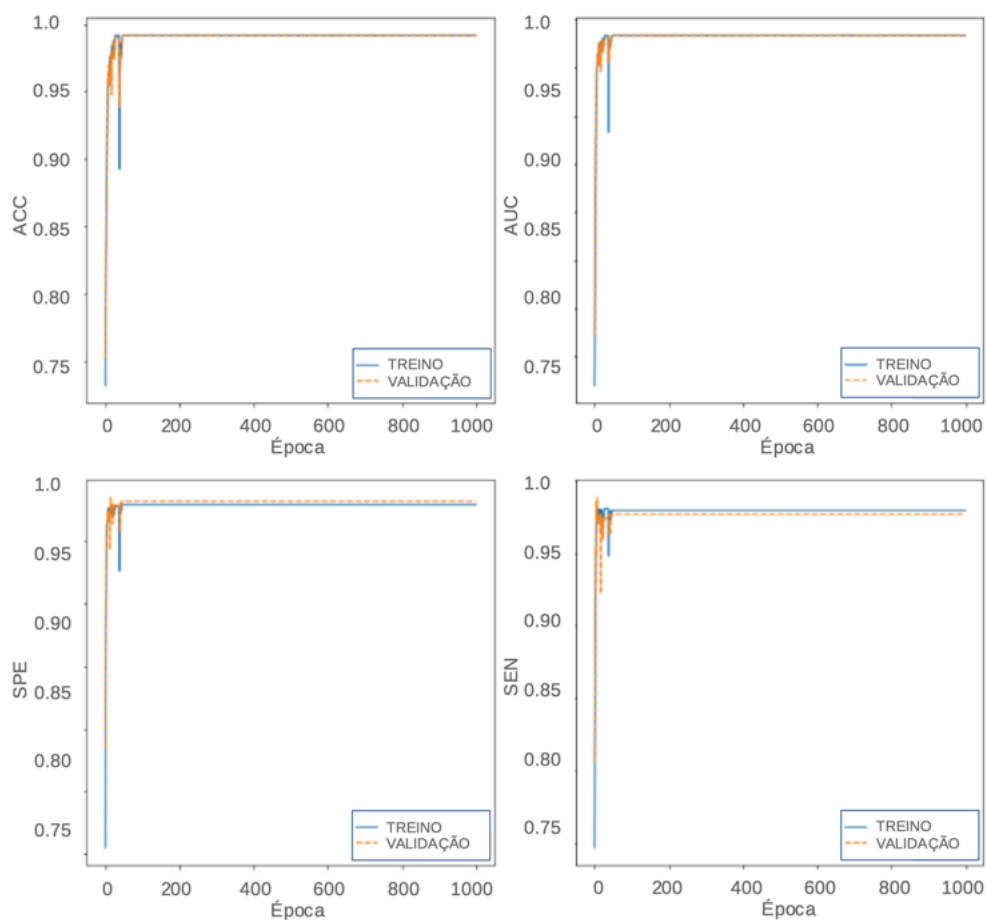
Para a classificação entre as classes Normal e AMI, os valores das métricas podem ser observados na Tabela 6.2. Os resultados mais expressivos foram observados na classificação dos sinais entre casos Normais e AMI, que resultaram em valores em torno de 99% para todas as métricas utilizadas, em todas as etapas (treino, validação e teste).

**Tabela 6.2** – Resultados da classificação para sinais das classes Normal e AMI.

	<b>Los</b>	<b>Acc</b>	<b>Sen</b>	<b>Spe</b>	<b>AUC</b>
<b>Treino</b>	0.0095	0.9905	0.9904	0.9907	0.9905
<b>Validação</b>	0.0082	0.9901	0.9907	0.9928	0.9918
<b>Teste</b>	0.0083	0.9901	0.9932	0.9902	0.9917

Fonte: Elaborado pelo autor.

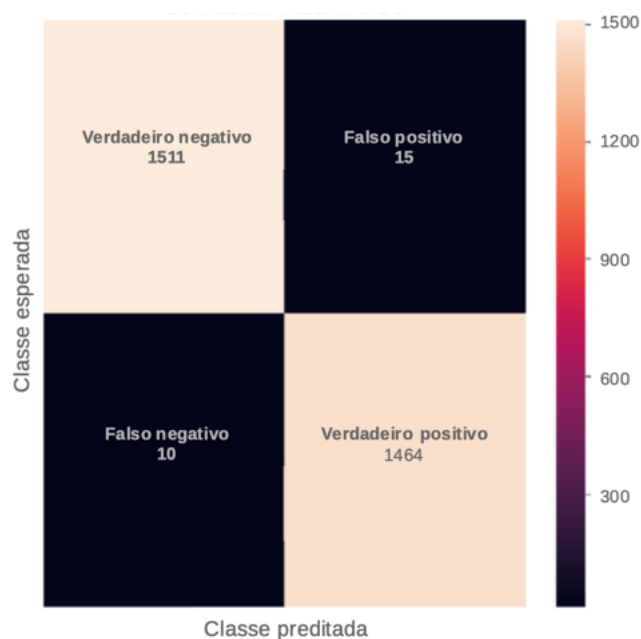
A progressão dos valores dessas quatro métricas de acordo com as épocas, onde cada época de treinamento, considerando os conjuntos de treinamento e validação, é apresentada na Figura 6.2. Para o treinamento, cada época consiste em um ciclo em que novas amostras são apresentadas para o modelo, possibilitando o ajuste do erro resultante do ciclo de treinamento anterior.

**Figura 6.2** – Métricas de treino e validação: Normal e AMI.

Fonte: Elaborado pelo autor.

A variação inicial nas métricas na Figura 6.2 indicam o ajuste inicial dos pesos da rede, sendo necessário uma quantidade entre 50 e 200 épocas para a convergência e estabilização, a partir deste ponto é possível observar uma constante na taxa de acerto da classificação, sendo justificada pelo ajuste conciso e eficiente dos pesos.

A Matriz de confusão da classificação entre sinais Normais e com AMI, é apresentada na Figura 6.3. Essa matriz é composta pelos casos presentes no conjunto de teste, o que representa 15%, do total das amostras utilizadas no experimento, conforme foi explicado no Capítulo 5. No caso da classificação entre sinais Normais e AMI, foram utilizados para teste um total de 3000 amostras.

**Figura 6.3** – Matriz de confusão: Normal e AMI.

Fonte: Elaborado pelo autor.

Já os resultados apresentados na Figura 6.3 indicam que o modelo distinguiu adequadamente as amostras das respectivas classes, Normal e AMI. Os fatores para justificar este resultado consistem na quantidade de amostras suficiente para o ajuste adequado do modelo, e também pelas variações distintas que o infarto na parede anterior do músculo cardíaco causa nas correntes elétricas que são registradas no ECG. Essas variações possibilitam a extração de parâmetros influentes na classificação, ou seja, que diferenciam significativamente os sinais Normais.

### 6.2.2 – Classificação em Normais e Infarto na Parede Inferior


Os resultados do experimento realizado utilizando amostras do grupo Normais e com IMI são apresentados na Tabela 6.3. Assim como na classificação entre Normais e AMI, os valores da Tabela 6.3 possuem valores aproximados de 99% para todas as métricas, com uma leve baixa na especificidade, algo normalmente decorrente de uma similaridade dos dados, o que reduz a capacidade do modelo de distinguir novas amostras das amostras conhecidas.

**Tabela 6.3** – Resultados da classificação para sinais das classes Normal e IMI.

	<b>Los</b>	<b>Acc</b>	<b>Sen</b>	<b>Spe</b>	<b>AUC</b>
<b>Treino</b>	0.0073	0.9927	0.9946	0.9908	0.9927
<b>Validação</b>	0.0094	0.9906	0.9922	0.9889	0.9906
<b>Teste</b>	0.0080	0.9920	0.9948	0.9892	0.9920

Fonte: Elaborado pelo autor.


A Figura 6.4 mostra que, assim como no experimento anterior, os valores das métricas para a classificação entre Normais e IMI são rapidamente ajustados e se estabilizam por volta da ducentésima época. Novamente, a qualidade dos dados e a quantidade são suficientes para um bom desempenho do modelo. Além disso, é possível observar três valores nas curvas das métricas, decorrentes da inserção de novos conjuntos de amostras contendo situações anormais para o modelo em sua atual etapa. Em seguida é possível observar a estabilização das métricas, e variando a partir da terceira casa decimal.

**Figura 6.4** – Métricas de treino e validação: Normal e IMI.

Fonte: Elaborado pelo autor.

Considerando a matriz de confusão para esse experimento, exposta na Figura 6.5, novamente, a baixa taxa de falsos positivos e falsos negativos indica a alta capacidade do modelo em generalizar e especificar a classificação diante de um conjunto de dados desconhecido.

**Figura 6.5** – Matriz de confusão: Normal e IMI.



Fonte: Elaborado pelo autor.

### 6.2.3 – Classificação em Normais e Infarto na Parede Lateral

O último experimento consistiu na classificação entre sinais Normais e LMI, cujos resultados podem ser observados na Tabela 6.4. Ao considerar o conjunto de dados contendo amostras das classes Normal e LMI, percebe-se que esse conjunto apresentou resultados inferiores aos demais, porém é importante realçar que a quantidade de amostras é menor, sendo 630 amostras da classe Normal e 630 de amostras de LMI, o que pode impactar diretamente no ajuste do modelo.

**Tabela 6.4** – Resultados da classificação para sinais das classes Normal e LMI.

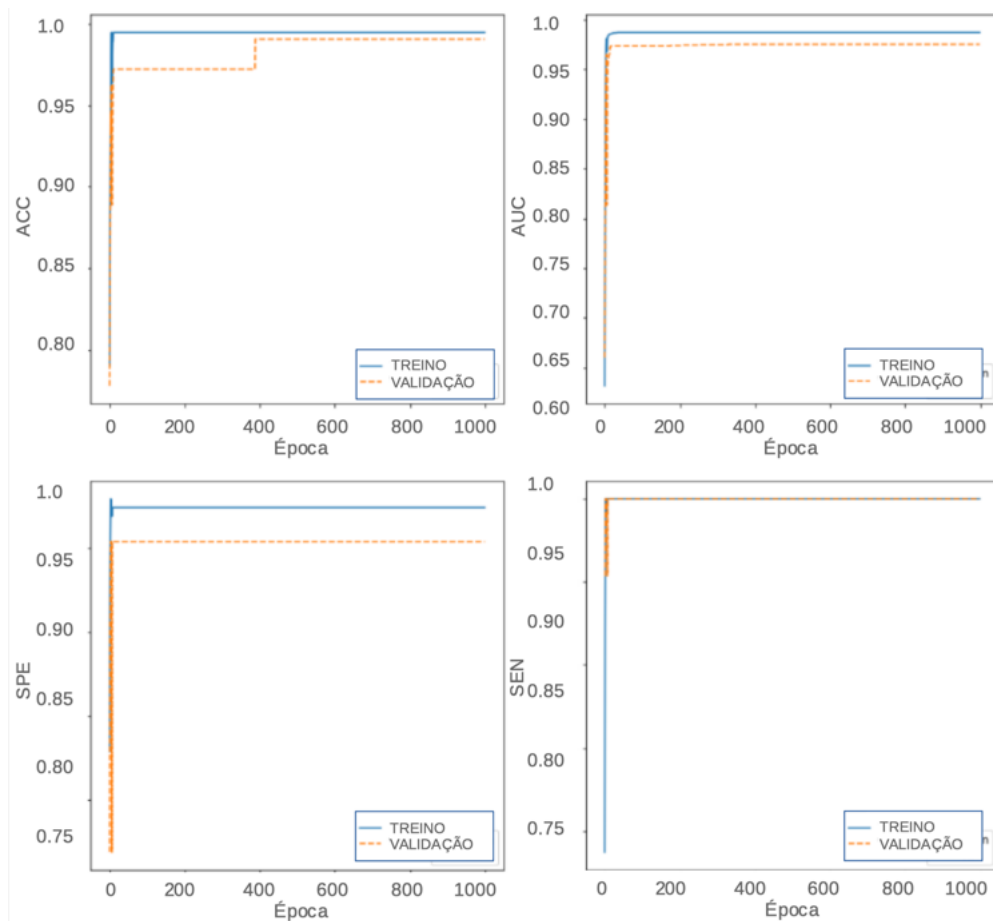
	Los	Acc	Sen	Spe	AUC
<b>Treino</b>	0.0036	0.9964	0.9990	0.9929	0.9964
<b>Validação</b>	0.0098	0.9907	0.9990	0.9815	0.9901
<b>Teste</b>	0.0207	0.9788	0.9880	0.9789	0.9889

Fonte: Elaborado pelo autor.

É possível observar na Tabela 6.4 que a taxa de erro do teste apresenta maior valor, isso é impacto direto da quantidade de amostras, o que impede um ajuste maior do modelo com o passar das épocas. Essa quantidade de dados também impede que mais épocas sejam adicionadas, uma vez que o resultado pode ser uma rede viciada, por reaproveitar amostras de um conjunto tão pequeno, algo que para o experimento feito não chegou a ocorrer, já que não houve uma queda nos valores das métricas ao fim das 1000 épocas, como evidenciado na Figura 6.6.

Assim como para os experimentos anteriores, os valores das métricas em função do número de épocas e a matriz de confusão obtidas podem ser vistas, respectivamente, na Figura 6.6 e na Figura 6.7.

**Figura 6.6** – Métricas de treino e validação: Normal e LMI.

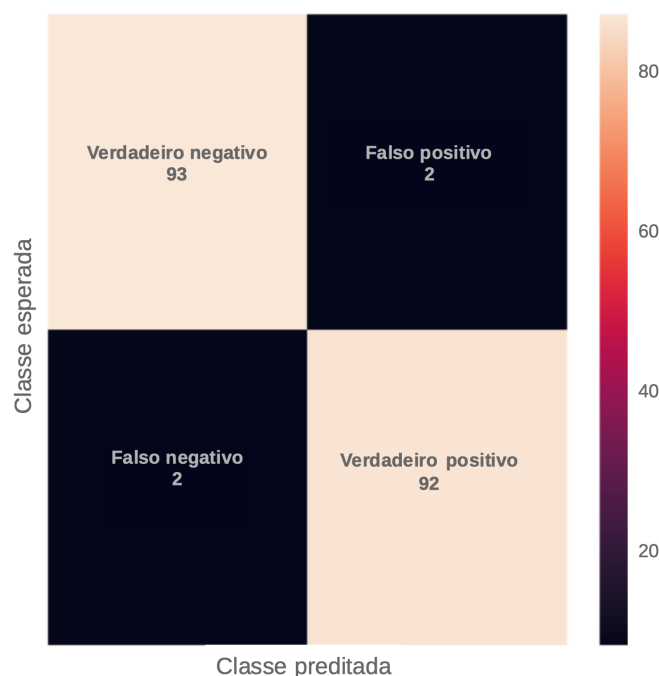


Fonte: Elaborado pelo autor.

Esses resultados inferiores podem também ser observados a partir da matriz de confusão apresentada na Figura 6.7, onde, percentualmente um aumento na quantidade de falsos positivos e falsos negativos no conjunto de teste, que representaram aproximadamente 2% do total de

dados, mais que o dobro da percentagem de falsos positivos e falsos negativos que ocorreu para os outros experimentos.

**Figura 6.7** – Matriz de confusão: Normal e LMI.



Fonte: Elaborado pelo autor.

Para análise dos resultados, também foram elaborados os gráficos contendo a Curva ROC, porém ao considerar valores de AUC próximos de 100%, a ROC apresenta pouca variação, o que torna a análise do gráfico redundante. Em razão disso, os gráficos não foram acrescentados aos resultados, podendo ser visualizados, entretanto, no Apêndice A.

### **6.3 – *Convolutional Neural Network* com imagens realçadas de planos de VCG**

Utilizando uma camada convolucional como camada de entrada, foi possível reutilizar a arquitetura de rede para realizar a classificação multiclasse das paredes infartadas a partir de imagens de planos vetocardiográficos. Foram avaliados dois cenários nos quais foram utilizadas as imagens originais como entrada e, no outro cenário, as imagens após a aplicação da dilatação morfológica, o que possibilitou o aumento dos contornos.

Assim como na classificação multiclasse, foi utilizado o mesmo limite de corte para balancear os conjuntos de dados por classe, foi utilizado um banco contendo 3.630 amostras,

sendo 1000 para sinais de ECG normais, 1000 para AMI, 1000 para IMI e 630 para LMI. Cada amostra resultou em três imagens correspondente à uma das perspectivas XY, XZ e YZ do VCG. Cada perspectiva foi trabalhada nos experimentos descritos nessa seção. Serão apresentados nas subseções a seguir os resultados obtidos para as métricas de acurácia, especificidade, sensibilidade e AUC nas etapas de teste para cada uma das classes em de acordo com o plano de VCG em questão.

Adianta-se que devido ao resultados não serem tão promissores quanto os obtidos para a DNN com parâmetros da REF, as explicações não apresentarão a mesma profundidade que a seção anterior, também não serão apresentados gráficos de métricas ou matrizes de confusão. Além disto, diferentemente dos experimentos utilizando os parâmetros de REF, a classificação de cada classe apresenta valores muito distintos, por esse motivo serão apresentados nas tabelas os valores das métricas para a classificação individual, além da média e do desvio padrão.

### 6.3.1 – Plano XY

A Tabela 6.5 apresenta o resultado para o conjunto de dados correspondente classificação multiclasse utilizando as imagens na perspectiva XY do VCG. Para esta execução, não foi aplicado a técnica de dilatação morfológica dos contornos, ou seja, as imagens utilizadas apresentam os contornos originais.

**Tabela 6.5** – Métricas de teste para cada classe considerando o plano XY sem aplicação da técnica de PDI.

	<b>Acc</b>	<b>Sen</b>	<b>Spe</b>	<b>AUC</b>
<b>NORM</b>	0.6611	0.5426	0.6616	0.6312
<b>LMI</b>	0.4356	0.4087	0.4062	0.3775
<b>IMI</b>	0.6372	0.5085	0.6031	0.4844
<b>AMI</b>	0.7333	0.6136	0.6646	0.5970
<b>Média</b>	0.6491	0.5256	0.6323	0.5407
<b>Desvio Padrão</b>	0.1275	0.852	0.1218	0.1152

Fonte: Elaborado pelo autor.

Utilizando as imagens dos plano XY com a aplicação da técnica de PDI, foi possível obter os valores mostrados na Tabela 6.6. Em média, todas as métricas abaixo de 0,8, uma performance inferior à obtida quando utilizados os parâmetros da REF. O desvio padrão em algumas métricas, de acordo com a classe, superior a 10% é outro indicador da necessidade de melhorias do atual modelo ou do conjunto de dados. Este resultado pode ser justificado pelo aumento de informações presente em uma abordagem convolucionais, o que demanda



arquitecturas de redes mais complexas e, conseqüentemente, que demanda conjuntos de dados maiores.

**Tabela 6.6** – Métricas de teste para cada classe considerando o plano XY.

	<b>Acc</b>	<b>Sen</b>	<b>Spe</b>	<b>AUC</b>
<b>NORM</b>	0.8455	0.7989	0.6118	0.7568
<b>LMI</b>	0.6113	0.6363	0.5731	0.4999
<b>IMI</b>	0.7470	0.6542	0.6159	0.5699
<b>AMI</b>	0.8159	0.7968	0.7454	0.7356
<b>Média</b>	0.7549	0.7216	0.6366	0.6406
<b>Desvio Padrão</b>	0.1043	0.0884	0.0751	0.1256

Fonte: Elaborado pelo autor.

### 6.3.2 – Plano XZ

É possível observar uma alternância entre as classes com melhores valores de métricas quando comparados os resultados obtidos para os planos XY e XZ, como pode ser observado na Tabela 6.7 e na Tabela 6.5. Isso aponta que uma determinada perspectiva do sinal de ECG exerce mais influência do que outra na identificação de uma patologia. Por exemplo, para os planos XZ o infarto do tipo LMI são mais evidentes do que para o plano XY.

**Tabela 6.7** – Métricas de teste para cada classe considerando o plano XZ sem aplicação de técnica de PDI.

	<b>Acc</b>	<b>Sen</b>	<b>Spe</b>	<b>AUC</b>
<b>NORM</b>	0.6112	0.5964	0.6189	0.6136
<b>LMI</b>	0.3531	0.2766	0.4013	0.3463
<b>IMI</b>	0.2511	0.3556	0.3045	0.2511
<b>AMI</b>	0.6185	0.6099	0.6599	0.6000
<b>Média</b>	0.4822	0.4760	0.5101	0.4731
<b>Desvio Padrão</b>	0.1853	0.1689	0.1709	0.1822

Fonte: Elaborado pelo autor.

Os dados na Tabela 6.8 mostram que, de maneira ainda mais intensa ao que ocorreu para o plano XY, ouve uma melhora na qualidade dos dados. Porém, o desempenho para o plano XZ também foi baixo, havendo quedas de em torno de 10% para as médias e um aumento em todos os desvios padrão.

**Tabela 6.8** – Métricas de teste para cada classe considerando o plano XZ.

	<b>Acc</b>	<b>Sen</b>	<b>Spe</b>	<b>AUC</b>
<b>NORM</b>	0.7656	0.6687	0.6055	0.6520
<b>LMI</b>	0.4184	0.4813	0.3256	0.4000
<b>IMI</b>	0.4715	0.4969	0.5123	0.4714
<b>AMI</b>	0.6992	0.7889	0.7658	0.7156
<b>Média</b>	0.5887	0.6089	0.5523	0.5597
<b>Desvio Padrão</b>	0.1695	0.1470	0.1839	0.1485

Fonte: Elaborado pelo autor.

### 6.3.3 – Plano YZ

Por fim, foi realizado a execução do experimento para os plano YZ, na Tabela 6.9, são apresentados os resultados, com valor médio de métricas em torno de 41% e 46%, sendo o experimento com o pior resultado médio realizado, porém ao analisar a Tabela 6.10, é possível ver um impacto positivo da aplicação da técnica de PDI.

**Tabela 6.9** – Métricas de teste para cada classe considerando o plano YZ sem aplicação de técnica de PDI.

	<b>Acc</b>	<b>Sen</b>	<b>Spe</b>	<b>AUC</b>
<b>NORM</b>	0.5515	0.4746	0.5567	0.5545
<b>LMI</b>	0.4266	0.4095	0.4199	0.4186
<b>IMI</b>	0.4032	0.3865	0.2511	0.3711
<b>AMI</b>	0.5034	0.4162	0.4372	0.4344
<b>Média</b>	0.4650	0.4128	0.4285	0.4265
<b>Desvio Padrão</b>	0.0685	0.0375	0.1257	0.0779

Fonte: Elaborado pelo autor.

Os resultados apresentados na Tabela 6.10, estiveram em média abaixo de 70%, com os desvios padrão atingindo até 15%, reforçando ainda mais a ideia da necessidade de aprimoramentos para o modelo obtido. Esse plano teve o melhor evolução após a aplicação da técnica de PDI. Aumentando a acurácia média em torno de 25%.

**Tabela 6.10** – Métricas de teste para cada classe considerando o plano YZ.

	<b>Acc</b>	<b>Sen</b>	<b>Spe</b>	<b>AUC</b>
<b>NORM</b>	0.8178	0.6912	0.7689	0.7118
<b>LMI</b>	0.6916	0.6655	0.6567	0.6191
<b>IMI</b>	0.6175	0.5171	0.4756	0.5565
<b>AMI</b>	0.6607	0.8345	0.8134	0.6622
<b>Média</b>	0.6969	0.6771	0.6786	0.6374
<b>Desvio Padrão</b>	0.0861	0.1300	0.1506	0.0659

Fonte: Elaborado pelo autor.

## Considerações Finais

O uso de inteligência artificial vem se provando viável em diversas áreas do conhecimento, este cenário se consolida com o aumento da disponibilidade de dados e recursos computacionais. Na cardiologia, e em diversas áreas da medicina (Lobo, 2017), pesquisas envolvendo recursos como redes neurais artificiais, mineração de dados, análises estatísticas, etc; vêm auxiliando no entendimento e combate a diversas doenças por meio de diagnósticos mais rápidos e precisos, possibilitando melhorar a qualidade de vida das pessoas.

Neste trabalho, é abordado uma alternativa que visa auxiliar no entendimento e diagnóstico do infarto do miocárdio, uma patologia cardíaca responsável por milhares de mortes anualmente. Para isso, foram utilizados eletrocardiogramas de diversos pacientes, organizados e disponibilizados publicamente pelo Instituto Nacional de Metrologia da Alemanha. Com base na literatura disponível, foi utilizada uma abordagem metodológica exploratória e experimental, na qual foi realizado um levantamento teórico sobre formas consolidadas de extração de informações a partir de ECG e também de trabalhos com aplicabilidades semelhantes à abordagem proposta, para serem utilizados como referências de métodos e práticas a serem seguidas.

Essa abordagem consistiu, então, em classificar esses sinais cardíacos em categorias correspondentes à existência de um infarto em uma certa parede cardíaca ou não. Onde a classificação foi feita paralelamente por uma rede neural convolucional que avaliou imagens de planos de VCG e uma rede neural profunda MLP avaliou dados numéricos provenientes da reconstrução do espaço de fases desses sinais de VCG, havendo também uma avaliação dos classificadores com base na parede cardíaca afetada pelo infarto e dos tipos de redes neurais utilizados.

Com isso, os objetivos do trabalho foram alcançados, dado que foi possível classificar os sinais e avaliar a capacidade de cada classificador na identificação da patologia. Ao se utilizar a rede neural profunda MLP foi possível se obter sensibilidades, acurácias, especificidades e

---

AUC com valores acima de 97% para todas as regiões de infarto. Esses resultados reforçam ainda mais a aplicabilidade da reconstrução do espaço de fases de sinais cardíacos como um método para auxiliar no diagnóstico de infartos.

Apesar disso, a classificação utilizando a DNN do tipo convolucional não teve resultados iniciais promissores, já que para todas as métricas as médias estiveram, para todos os planos avaliados, entre 55,23% e 75,49% e seu desvio padrão chegou a ser de até 18,39%; o que indica a necessidade de outras formas de pré-processamento das imagens dos planos de VCG além da dilatação.

Visando uma melhoria nessas métricas é sugerido que, em trabalhos futuros, outras arquiteturas de redes neurais convolucionais sejam testadas. Além disso, visando se aproximar de um cenário de diagnóstico hospitalar, é interessante que seja feita uma classificação multiclasse dos sinais, a fim de detectar a existência ou não da doença e em qual parede ela está presente.

Por fim, para se aproximar ainda mais desse cenário de diagnóstico, também é possível combinar essa classificação multiclasse com a adição de classes de sinais que possuem anormalidades, mas não correspondem à infartos, para se avaliar o desempenho desses modelos e se há aplicabilidade para esses cenários como um método auxiliar, de forma que se aumente a rapidez e confiabilidade do diagnóstico, o que pode contribuir para um melhor prognóstico, reduzindo assim o número de mortes.

## Referências Bibliográficas

- Abadi, Martín, Agarwal, Ashish, & et al, Paul Barham. 2015. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. Software available from tensorflow.org.
- Abraham, Frederick David, Abraham, Ralph H, & Shaw, Christopher D. 1990. *A visual introduction to dynamical systems theory for psychology*. Aerial Press.
- Akulinichev, IT. 1960. Practical questions of vectorcardioscopy. *M.: Medgiz*.
- Al-Fahoum, AS, & Qasaimeh, AM. 2006. ECG arrhythmia classification using simple reconstructed phase space approach. *Pages 757–760 of: 2006 Computers in Cardiology*. IEEE.
- Amann, Anton, Tratnig, Robert, & Unterkofler, Karl. 2006. Detecting ventricular fibrillation by time-delay methods. *IEEE Transactions on Biomedical Engineering*, **54**(1), 174–177.
- Andrade, Jadelson Pinheiro de, Mattos, Luiz Alberto Piva, Carvalho, Antonio Carlos, Machado, Carlos Alberto, & Oliveira, Glauca Maria Moraes de. 2013. Programa nacional de qualificação de médicos na prevenção e atenção integral às doenças cardiovasculares. *Arquivos Brasileiros de Cardiologia*, **100**(3), 203–211.
- Arnaud, Pierre, Morlet, Dominique, & Rubel, Paul. 1989. Planarity of the spatial QRS loop: Comparative analysis in normals, infarcts, ventricular hypertrophies, and intraventricular conduction defects. *Journal of electrocardiology*, **22**(2), 143–152.
- Arrieta, Alejandro Barredo, Díaz-Rodríguez, Natalia, Del Ser, Javier, Bennetot, Adrien, Tabik, Siham, Barbado, Alberto, García, Salvador, Gil-López, Sergio, Molina, Daniel, Benjamins, Richard, *et al*. 2019. Explainable Artificial Intelligence (XAI): Concepts, Taxonomies, Opportunities and Challenges toward Responsible AI. *arXiv preprint arXiv:1910.10045*.

- 
- Arrobo, Gabriel E, Perumalla, Calvin A, Liu, Yang, Ketterl, Thomas P, Gitlin, Richard D, & Fabri, Peter J. 2014. A novel vectorcardiogram system. *Pages 243–247 of: 2014 IEEE 16th International Conference on e-Health Networking, Applications and Services (Healthcom)*. IEEE.
- Bax, Jeroen J, Baumgartner, Helmut, Ceconi, Claudio, Dean, Veronica, Fagard, Robert, Funck-Brentano, Christian, Hasdai, David, Hoes, Arno, Kirchhof, Paulus, Knuuti, Juhani, *et al.* 2012. Third universal definition of myocardial infarction. *Journal of the American College of Cardiology*, **60**(16), 1581–1598.
- Benesty, Jacob, Chen, Jingdong, Huang, Yiteng, & Cohen, Israel. 2009. Pearson correlation coefficient. *Pages 1–4 of: Noise reduction in speech processing*. Springer.
- Biel, Lena, Pettersson, Ola, Philipson, Lennart, & Wide, Peter. 2001. ECG analysis: a new approach in human identification. *IEEE Transactions on Instrumentation and Measurement*, **50**(3), 808–812.
- Castiglioni, P, & Di Rienzo, M. 2008. How the threshold “r” influences approximate entropy analysis of heart-rate variability. *Pages 561–564 of: 2008 Computers in Cardiology*. IEEE.
- Chou, Te-Chuan. 1986. When is the vectorcardiogram superior to the scalar electrocardiogram? *Journal of the American College of Cardiology*, **8**(4), 791–799.
- Cortez, Daniel, Sharma, Nandita, Devers, Christopher, Devers, Erin, & Schlegel, Todd T. 2014. Visual transform applications for estimating the spatial QRS–T angle from the conventional 12-lead ECG: Kors is still most Frank. *Journal of electrocardiology*, **47**(1), 12–19.
- Cortez, Daniel L, & Schlegel, Todd T. 2010. When deriving the spatial QRS-T angle from the 12-lead electrocardiogram, which transform is more Frank: regression or inverse Dower? *Journal of Electrocardiology*, **43**(4), 302–309.
- Costa, Cecília M, Silva, Ittalo S, de Sousa, Rafael D, Hortegal, Renato A, & Regis, Carlos Danilo M. 2018. The association between reconstructed phase space and Artificial Neural Networks for vectorcardiographic recognition of myocardial infarction. *Journal of electrocardiology*, **51**(3), 443–449.
- Dehnavi, Ali Reza Mehri, Farahabadi, Iman, Rabbani, Hossain, Farahabadi, Amin, Mahjoob, Mohamad Parsa, & Dehnavi, Nasser Rajabi. 2011. Detection and classification of cardiac

- 
- ischemia using vectorcardiogram signal via neural network. *Journal of research in medical sciences: the official journal of Isfahan University of Medical Sciences*, **16**(2), 136.
- Dower, Gordon E. 1968. A lead synthesizer for the Frank system to simulate the standard 12-lead electrocardiogram. *Journal of electrocardiology*, **1**(1), 101–116.
- Dower, Gordon E, Machado, H Bastos, & Osborne, JA. 1980. On deriving the electrocardiogram from vectorcardiographic leads. *Clinical cardiology*, **3**(2), 87–95.
- Drake, Richard, Vogl, A Wayne, & Mitchell, Adam WM. 2015. *Gray's Anatomy for Students E-Book*. Elsevier Health Sciences.
- Frank, Ernest. 1956. An accurate, clinically practical system for spatial vectorcardiography. *circulation*, **13**(5), 737–749.
- Friedman, Jerome H. 2001. Greedy function approximation: a gradient boosting machine. *Annals of statistics*, 1189–1232.
- Ginefra, Paulo, Barbosa, Eduardo Correa, Ribeiro, Ricardo, Bomfim, Alfredo, Boghossian, Silvia Helena Cardoso, Barbosa, Paulo Roberto Benchimol, & Veloso, Henrique. 2006. Infarto do miocárdio da parede inferior associado ao hemibloqueio esquerdo anterior: um dilema na clínica cardiológica. *Revista da SOCERJ*.
- Gleason, Marie Murphy, Shaddy, Robert E, & Rychik, Jack. 2012. *Pediatric practice: cardiology*. McGraw-Hill Medical New York.
- Hall, John E. 2015. *Guyton & Hall Physiology Review E-Book*. Elsevier Health Sciences.
- Haykin, Simon. 2004. *Kalman filtering and neural networks*. Vol. 47. John Wiley & Sons.
- Herlihy, Barbara. 2002. *Anatomia e fisiologia do corpo humano saudável e enfermo: Barbara Herlihy, Naney K. Maebius*. Manole.
- Huang, Huimin, Lin, Lanfen, Tong, Ruofeng, Hu, Hongjie, Zhang, Qiaowei, Iwamoto, Yutaro, Han, Xianhua, Chen, Yen-Wei, & Wu, Jian. 2020. Unet 3+: A full-scale connected unet for medical image segmentation. *Pages 1055–1059 of: ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE.



- 
- Jen, K, Hwang, Y, *et al.* 2008. ECG feature extraction and classification using cepstrum and neural networks. *Journal of Medical and Biological Engineering*, **28**(1), 31.
- Jiang, Fei, Jiang, Yong, Zhi, Hui, Dong, Yi, Li, Hao, Ma, Sufeng, Wang, Yilong, Dong, Qiang, Shen, Haipeng, & Wang, Yongjun. 2017. Artificial intelligence in healthcare: past, present and future. *Stroke and vascular neurology*, **2**(4), 230–243.
- Kingma, Diederik P, & Ba, Jimmy. 2014. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Kliková, B, & Raidl, Aleš. 2011. Reconstruction of phase space of dynamical systems using method of time delay. *Pages 83–87 of: Proceedings of WDS*, vol. 11.
- Kors, JA, Van Herpen, G, Sittig, AC, & Van Bommel, JH. 1990. Reconstruction of the Frank vectorcardiogram from standard electrocardiographic leads: diagnostic comparison of different methods. *European heart journal*, **11**(12), 1083–1092.
- LeCun, Yann, Bengio, Yoshua, & Hinton, Geoffrey. 2015. Deep learning. *nature*, **521**(7553), 436–444.
- Li, Sihan, Jiao, Jiantao, Han, Yanjun, & Weissman, Tsachy. 2016. Demystifying resnet. *arXiv preprint arXiv:1611.01186*.
- Lobo, Luiz Carlos. 2017. Inteligência artificial e medicina. *Revista Brasileira de Educação Médica*, **41**, 185–193.
- Makimoto, Hisaki, Höckmann, Moritz, Lin, Tina, Glöckner, David, Gerguri, Shqipe, Clasen, Lukas, Schmidt, Jan, Assadi-Schmidt, Athena, Bejinariu, Alexandru, Müller, Patrick, *et al.* 2020. performance of a convolutional neural network derived from an ecG database in recognizing myocardial infarction. *Scientific Reports*, **10**(1), 1–9.
- Moon, Brianna F, Iyer, Srikant Kamesh, Hwuang, Eileen, Solomon, Michael P, Hall, Anya T, Kumar, Rishabh, Josselyn, Nicholas J, Higbee-Dempsey, Elizabeth M, Tsourkas, Andrew, Imai, Akito, *et al.* 2020. Iron imaging in myocardial infarction reperfusion injury. *Nature communications*, **11**(1), 1–14.
- Nicolau, José Carlos, Polanczyk, Carisi A, Pinho, José Alves, Bacellar, Mario Sérgio de Carvalho, Ribeiro, Demostenes G Lima, Darwich, Rubens Nassar, Ribeiro, Antonio

- Luiz Pinho, Dunda, Marcelo Marcos Eloy, Germiniani, Hélio, França, Francisco Faustino, *et al.* 2003. Diretriz de interpretação de eletrocardiograma de repouso. *Arquivos Brasileiros de Cardiologia*, **80**, 1–18.
- OMS, World Health Organization. 2021. *Cardiovascular diseases (CVDs)*s. Disponível em: [https://www.who.int/en/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/en/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)). Acesso em: Agosto de 2021.
- Parvaneh, Saman, Rubin, Jonathan, Babaeizadeh, Saeed, & Xu-Wilson, Minnan. 2019. Cardiac arrhythmia detection using deep learning: A review. *Journal of electrocardiology*, **57**, S70–S74.
- Pastore, Carlos Alberto, Samesima, Nelson, Pereira Filho, Horacio Gomes, Tobias, Nancy Maria Martins de Oliveira, Madaloso, Bruna Affonso, & Facin, Mirella Esmanhotto. 2019. Aplicabilidade do Eletrovetorcardiograma na Atual Prática Clínica-Um Retrato Preciso da Ativação Elétrica Cardíaca. *Arquivos Brasileiros de Cardiologia*, **113**(1), 87–99.
- Prasath, VB, Alfeilat, Haneen Arafat Abu, Hassanat, Ahmad, Lasassmeh, Omar, Tarawneh, Ahmad S, Alhasanat, Mahmoud Bashir, & Salman, Hamzeh S Eyal. 2017. Distance and Similarity Measures Effect on the Performance of K-Nearest Neighbor Classifier—A Review. *arXiv preprint arXiv:1708.04321*.
- Raghunath, Sushravya, Cerna, Alvaro E Ulloa, Jing, Linyuan, Stough, Joshua, Hartzel, Dustin N, Leader, Joseph B, Kirchner, H Lester, Stumpe, Martin C, Hafez, Ashraf, Nemani, Arun, *et al.* 2020. Prediction of mortality from 12-lead electrocardiogram voltage data using a deep neural network. *Nature Medicine*, 1–6.
- Ramya, E, Prabha, R, Jayageetha, J, Keerthana, M, Swetha, S, & Lakshmi, N. 2019. Envisaging Ventricular Arrhythmia from an ECG by Using Machine learning algorithm. *Pages 991–994 of: 2019 5th International Conference on Advanced Computing & Communication Systems (ICACCS)*. IEEE.
- Roberts, Felice M, Povinelli, Richard J, & Ropella, Kristina M. 2001. Identification of ECG arrhythmias using phase space reconstruction. *Pages 411–423 of: European Conference on Principles of Data Mining and Knowledge Discovery*. Springer.

- 
- Ronneberger, Olaf, Fischer, Philipp, & Brox, Thomas. 2015. U-net: Convolutional networks for biomedical image segmentation. *Pages 234–241 of: International Conference on Medical image computing and computer-assisted intervention*. Springer.
- Roopaei, Mehdi, Boostani, Reza, Sarvestani, R Rohani, Taghavi, Mohammad Ali, & Azimifar, Zohreh. 2010. Chaotic based reconstructed phase space features for detecting ventricular fibrillation. *Biomedical Signal Processing and Control*, **5**(4), 318–327.
- Schmidhuber, Jürgen. 2015. Deep learning in neural networks: An overview. *Neural networks*, **61**, 85–117.
- Sedaghat, Golriz, Ghafoori, Elyar, Waks, Jonathan W, Kabir, Muammar M, Shvilkin, Alexei, Josephson, Mark E, & Tereshchenko, Larisa G. 2016. Quantitative assessment of vectorcardiographic loop morphology. *Journal of electrocardiology*, **49**(2), 154–163.
- Segers, Vincent FM, & Lee, Richard T. 2008. Stem-cell therapy for cardiac disease. *Nature*, **451**(7181), 937–942.
- Sethi, Atul, Arora, Siddharth, & Ballaney, Abhishek. 2006. Frequency domain analysis of ECG signals using auto-associative neural networks. *Pages 531–536 of: 2006 International Conference on Biomedical and Pharmaceutical Engineering*. IEEE.
- Shortt, Colleen, Ma, Jinhui, Clayton, Natasha, Sherbino, Jonathan, Whitlock, Richard, Pare, Guillaume, Hill, Stephen A, McQueen, Matthew, Mehta, Shamir R, Devereaux, PJ, *et al.* 2017. Rule-in and rule-out of myocardial infarction using cardiac troponin and glycemic biomarkers in patients with symptoms suggestive of acute coronary syndrome. *Clinical Chemistry*, **63**(1), 403–414.
- Silva, Ittalo dos Santos, Barbosa, José Raimundo, de Sousa, Rafael Duarte, de Souza, IgorFranklin Brito, de Aguiar Hortegal, Renato, & Regis, Carlos Danilo Miranda. 2020. Comparison of spatial temporal representations of the vectorcardiogram using digital image processing. *Journal of Electrocardiology*.
- Silva, Ittalo S, Costa, Cecília M, de Sousa, Rafael D, Hortegal, Renato A, & Regis, Carlos Danilo M. 2019. Assessment of the Similarity Between Vectorcardiogram Curves of Both Methods Frank Standard and Kors Regression Matrix Using Digital Image Processing. *Pages 65–68 of: XXVI Brazilian Congress on Biomedical Engineering*. Springer.


- 
- Singh, Shashi Pal, Kumar, Ajai, Darbari, Hemant, Singh, Lenali, Rastogi, Anshika, & Jain, Shikha. 2017. Machine translation using deep learning: An overview. *Pages 162–167 of: 2017 International Conference on Computer, Communications and Electronics (Comptelix)*. IEEE.
- Smola, Alex J, & Schölkopf, Bernhard. 2004. A tutorial on support vector regression. *Statistics and computing*, **14**(3), 199–222.
- Strodthoff, Nils, Wagner, Patrick, Schaeffter, Tobias, & Samek, Wojciech. 2020. Deep Learning for ECG Analysis: Benchmarks and Insights from PTB-XL. *arXiv preprint arXiv:2004.13701*.
- Sukienik, Bernardo. 2015. *Atlas de eletrocardiografia*. first edn. Elsevier.
- Takens, Floris. 1981. Detecting strange attractors in turbulence. *Pages 366–381 of: Dynamical systems and turbulence, Warwick 1980*. Springer.
- Tranchesí, João, Moffa, Paulo Jorge, Sanches, Paulo César R, Ramires, José Antônio F, & de Oliveira, Sérgio Almeida. 2001. *Eletrocardiograma: normal e patológico*. Roca.
- Wagner, Patrick, Strodthoff, Nils, Bousseljot, Ralf-Dieter, Kreiseler, Dieter, Lunze, Fatima I, Samek, Wojciech, & Schaeffter, Tobias. 2020. PTB-XL, a large publicly available electrocardiography dataset. *Scientific Data*, **7**(1), 1–15.
- Weng, Weihao, & Zhu, Xin. 2021. INet: Convolutional Networks for Biomedical Image Segmentation. *IEEE Access*, **9**, 16591–16603.
- Wilson, Frank N, & Johnston, Franklin D. 1938. The vectorcardiogram. *American Heart Journal*, **16**(1), 14–28.
- Wu, Xindong, Zhu, Xingquan, Wu, Gong-Qing, & Ding, Wei. 2013. Data mining with big data. *IEEE transactions on knowledge and data engineering*, **26**(1), 97–107.
- Xu, Sean Shensheng, Mak, Man-Wai, & Cheung, Chi-Chung. 2018. Towards end-to-end ECG classification with raw signal extraction and deep neural networks. *IEEE journal of biomedical and health informatics*, **23**(4), 1574–1584.

- 
- Xu, Ya, & Liu, Guang-Yuan. 2009. A method of emotion recognition based on ECG signal. *Pages 202–205 of: 2009 International Conference on Computational Intelligence and Natural Computing*, vol. 1. IEEE.
- Yamashita, Rikiya, Nishio, Mizuho, Do, Richard Kinh Gian, & Togashi, Kaori. 2018. Convolutional neural networks: an overview and application in radiology. *Insights into imaging*, **9**(4), 611–629.
- Yang, Hui, Bukkapatnam, Satish TS, & Komanduri, Ranga. 2012. Spatiotemporal representation of cardiac vectorcardiogram (VCG) signals. *Biomedical engineering online*, **11**(1), 16.
- Yang, Hui, Chen, Yun, Kan, Chen, & Liu, Gang. 2013. Spatiotemporal differentiation of myocardial infarctions. *IEEE Transactions on Automation Science and Engineering*, **10**(4), 10.
- Zhang, Qingxue, Zhou, Dian, & Zeng, Xuan. 2017. Hear the heart: Daily cardiac health monitoring using Ear-ECG and machine learning. *Pages 448–451 of: 2017 IEEE 8th Annual Ubiquitous Computing, Electronics and Mobile Communication Conference (UEMCON)*. IEEE.
- Zhu, Jiafu, He, Wei, & Yang, Hao. 2008. Comparative analysis of heart rate variability between healthy and morbid group based on correlation dimension. *Pages 2252–2255 of: 2008 2nd International Conference on Bioinformatics and Biomedical Engineering*. IEEE.
- Zhu, Wen, Zeng, Nancy, Wang, Ning, *et al.* 2010. Sensitivity, specificity, accuracy, associated confidence interval and ROC analysis with practical SAS implementations. *NESUG proceedings: health care and life sciences, Baltimore, Maryland*, **19**, 67.
- Zimmerman, Michael W, Povinelli, Richard J, Johnson, Michael T, & Ropella, Kristina M. 2003. A reconstructed phase space approach for distinguishing ischemic from non-ischemic ST changes using Holter ECG data. *Pages 243–246 of: Computers in Cardiology, 2003*. IEEE.
-


# APÊNDICES

## Curva ROC dos experimentos realizados


**Figura A.1** – Curva ROC: Normal e AMI.



Fonte: Elaborado pelo autor.

**Figura A.2** – Curva ROC: Normal e IMI.

Fonte: Elaborado pelo autor.

**Figura A.3** – Curva ROC: Normal e LMI.

Fonte: Elaborado pelo autor.



**Artigos Publicados**

- ▣ dos Santos Silva, I., Barbosa, J. R., de Sousa, R. D., de Souza, I. F. B., de Aguiar Hortegal, R., e Regis, C. D. M. (2020). *Comparison of spatial temporal representations of the vectorcardiogram using digital image processing*. *Journal of electrocardiology*, 59, 164-170.
- ▣ Tavares de Melo, M. D., Araujo-Filho, J. D. A. B., Barbosa, J. R., Rocon, C., Miranda Regis, C. D., dos Santos Felix, A., e Salemi, V. M. C. (2021). *A machine learning framework for the evaluation of myocardial rotation in patients with noncompaction cardiomyopathy*. *Plos one*, 16(11), e0260195.