



UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO
CENTRO MULTIDISCIPLINAR DE CARAÚBAS
CURSO DE ENGENHARIA ELÉTRICA

LETÍCIA AINOAN NUNES DE SOUSA

**PROCESSAMENTO DO SINAL DE ELETROCARDIOGRAMA PARA
CLASSIFICAÇÃO DE CARDIOPATIAS UTILIZANDO REDE NEURAL**

CARAÚBAS/RN

2021

LETÍCIA AINOAN NUNES DE SOUSA

**PROCESSAMENTO DO SINAL DE ELETROCARDIOGRAMA PARA
CLASSIFICAÇÃO DE CARDIOPATIAS UTILIZANDO REDE NEURAL**

Monografia apresentada à Universidade Federal Rural do Semi-Árido como requisito para obtenção do título de Bacharel em Engenharia Elétrica.

Orientador: D.Sc. Francisco de Assis Brito Filho

CARAÚBAS/RN

2021

© Todos os direitos estão reservados a Universidade Federal Rural do Semi-Árido. O conteúdo desta obra é de inteira responsabilidade do (a) autor (a), sendo o mesmo, passível de sanções administrativas ou penais, caso sejam infringidas as leis que regulamentam a Propriedade Intelectual, respectivamente, Patentes: Lei nº 9.279/1996 e Direitos Autorais: Lei nº 9.610/1998. O conteúdo desta obra tomar-se-á de domínio público após a data de defesa e homologação da sua respectiva ata. A mesma poderá servir de base literária para novas pesquisas, desde que a obra e seu (a) respectivo (a) autor (a) sejam devidamente citados e mencionados os seus créditos bibliográficos.

S725p Sousa, Letícia Ainoan Nunes .
PROCESSAMENTO DO SINAL DE ELETROCARDIOGRAMA
PARA CLASSIFICAÇÃO DE CARDIOPATIAS UTILIZANDO
REDE NEURAL / Letícia Ainoan Nunes Sousa. - 2021.
51 f. : il.

Orientador: Francisco de Assis Brito Filho.
Monografia (graduação) - Universidade Federal
Rural do Semi-árido, Curso de Engenharia
Elétrica, 2021.

1. Eletrocardiograma. 2. Cardiopatias. 3.
Processamento. 4. Rede Neural Artificial. I.
Brito Filho, Francisco de Assis , orient. II.
Título.

Ficha catalográfica elaborada por sistema gerador automático em conformidade
com AACR2 e os dados fornecidos pelo(a) autor(a).

Biblioteca Campus Caraúbas
Bibliotecária: Dalvanira Brito Rodrigues
CRB: 15/700

O serviço de Geração Automática de Ficha Catalográfica para Trabalhos de Conclusão de Curso (TCC's) foi desenvolvido pelo Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo (USP) e gentilmente cedido para o Sistema de Bibliotecas da Universidade Federal Rural do Semi-Árido (SISBI-UFERSA), sendo customizado pela Superintendência de Tecnologia da Informação e Comunicação (SUTIC) sob orientação dos bibliotecários da instituição para ser adaptado às necessidades dos alunos dos Cursos de Graduação e Programas de Pós-Graduação da Universidade.

LETÍCIA AINOAN NUNES DE SOUSA


**PROCESSAMENTO DO SINAL DE ELETROCARDIOGRAMA PARA
CLASSIFICAÇÃO DE CARDIOPATIAS UTILIZANDO REDE NEURAL**

Monografia apresentada à Universidade Federal Rural do Semi-Árido como requisito para obtenção do título de Bacharel em Engenharia Elétrica.


Orientador: D.Sc. Francisco de Assis Brito Filho

Defendida em: 18 de novembro de 2021

BANCA EXAMINADORA


Prof. Dr. Francisco de Assis Brito Filho
Presidente

LINCOLN
ALEXANDRE PAZ
SILVA:08221348457
Assinado digitalmente por
LINCOLN ALEXANDRE PAZ
SILVA:08221348457
Data: 2021.11.22 09:44:24-03'00'
Prof. Me. Lincoln Alexandre Paz Silva
Membro


Me. Nayana Leticia de Moraes Viana
Membro

CARAÚBAS/RN

2021

AGRADECIMENTOS

A Deus, por me manter firme nos momentos mais difíceis e não me deixar esmorecer.

Aos meus pais Geraldo Antônio de Sousa e Francisca Nunes Filha (In Memoriam), por todo esforço, amor, apoio, educação e por me ensinar que o conhecimento é minha maior riqueza. Em especial ao meu pai que acompanha e se esforça tanto para que eu possa concluir meus estudos.

A minha amada irmã Laryssa Débora, por ser a minha melhor amiga e por estar sempre comigo. Me apoiando, guiando e servindo de ‘porto seguro’ nos momentos difíceis. Ao meu amado irmão, Luiz Felipe, que mesmo ainda sendo uma criança, com sua pureza e essência me acalma nos momentos de aflição e me faz feliz.

Agradeço ao professor Dr. Francisco de Assis Brito Filho, por ser um excelente orientador, por toda paciência, assistência, todo incentivo e por acreditar no meu potencial para desenvolver esse projeto.

Ao meu grande amigo Tyrone, que foi essencial no desenvolvimento desse trabalho. Que disponibilizou seu tempo e conhecimento para me ajudar. Serei eternamente grata.

As minhas amigas, irmãs que a UFERSA me deu, Renata e Jocelia. Por dividirem comigo seus sonhos, conquistas, vidas e a casa. Em especial, Sara Joaquina, que foi um crucial para a conclusão dessa etapa. Vocês foram e são muito importantes para o meu crescimento pessoal e profissional.

Aos meus primos, Aeferson, Anderson e Arthur. Por me apresentarem a UFERSA Caraúbas, por estarem presentes nessa caminhada e por todo amparo. Agradeço também a minha, irmã e comadre Alessandra, pelos conselhos, conversas, apoio e amizade.

Aos meus tios e tias, por serem pilar na construção do meu futuro. Minha gratidão por tudo que fazem por mim é enorme.

Agradeço aos meus amigos Pepeu, Josemar, Pedro Lucas, Diego, Yuri, Gleidson, Gesley, Igor, Dayane e Lorena por estarem junto comigo nesse percurso

A todos os professores do curso de Engenharia Elétrica, que foram tão importantes na minha vida acadêmica e no desenvolvimento deste trabalho.

Enfim, a todos aqueles que me ajudaram na conclusão dessa etapa, meu muito obrigada!

RESUMO

De acordo com informações disponibilizadas pelo Portal da transparência brasileiro, no Brasil, houve um aumento de pelo menos 50% em óbitos causados por cardiopatias não diagnosticadas, desde o início da pandemia de COVID-19 no ano de 2020. Um dos principais fatores para que isso ocorra é a baixa procura por cardiologistas, dificultando assim o diagnóstico de doenças cardíacas. Uma possível solução para esta problemática seria o uso da telemedicina, já que, o distanciamento social dificulta um diagnóstico presencial. Isto posto, o presente trabalho se propõe a realizar o processamento dos dados, adquiridos no Eletrocardiograma, por meio de uma rede neural capaz de identificar cardiopatias de forma prática, cômoda e segura. Foi desenvolvido uma Rede Neural Artificial Convolucional de uma dimensão, que permite identificar anormalidades, doenças cardíacas, no sinal do Eletrocardiograma. A Rede Neural Artificial foi implementada em linguagem *Python*, utilizando a plataforma *Google Colaboraty*. A rede foi treinada com dados da PhysioNet, e testada com dados colhidos. A Rede Neural Artificial apresentou uma excelente acurácia de forma a atingir os resultados esperados.

Palavras-chave: Eletrocardiograma. Cardiopatias. Processamento. Rede Neural Artificial.

ABSTRACT

According to information provided by the Brazilian Transparency Portal, in Brazil, there has been an increase of at least 50% in deaths caused by undiagnosed heart disease since the beginning of the COVID-19 pandemic in 2020. One of the main factors for this what happens is the low demand for cardiologists, thus making the diagnosis of heart disease difficult. A possible solution to this problem would be the use of telemedicine, since social distancing makes a face-to-face diagnosis difficult. That said, the present work proposes to carry out the processing of the data, acquired in the Electrocardiogram, through a neural network capable of identifying heart diseases in a practical, comfortable and safe way. A one-dimensional Convolutional Artificial Neural Network was developed, which allows the identification of abnormalities, heart diseases, in the Electrocardiogram signal. The Artificial Neural Network was implemented in Python language, using the Google Collaboration platform. The network was trained with data from PhysioNet, and tested with collected data. The Artificial Neural Network showed excellent accuracy in order to achieve the expected results.

Keywords: Electrocardiogram. Heart diseases. Processing. Artificial Neural Network.

LISTA DE ILUSTRAÇÕES

Figura 1 – Representação do sistema de condução elétrica do coração.	12
Figura 2 – Contribuição de cada onda para a formação do ECG.	13
Figura 3 – Onda P no ECG	14
Figura 4 – Complexo QRS no ECG	14
Figura 5 – Onda T no ECG	15
Figura 6 – Eletrocardiograma Normal.	15
Figura 7 – Triângulo de Einthoven	16
Figura 8 – Derivações de Goldberger	17
Figura 9 – Derivações precordiais	18
Figura 10 – Estrutura Básica de uma Rede Neural	19
Figura 11 – Estrutura básica da Rede Perceptron	21
Figura 12 – Fronteira de separação dos neurônios com duas entradas	22
Figura 13 – Arquitetura do Perceptron de Multicamadas	23
Figura 14 – Arquitetura de uma Rede Neural Recorrente Simples	25
Figura 15 – Arquitetura de uma Rede Neural Convolucional	26
Figura 16 – Etapas Para a Aquisição do ECG	27
Figura 17 – Circuito de aquisição presente no datasheet do AD620	28
Figura 18 – Topologia do filtro passa-baixa utilizado.	28
Figura 19 – Topologia do amplificador utilizado.	29
Figura 20 – Topologia do circuito de aquisição do ECG.	30
Figura 21 – Topologia da fonte simétrica.	30
Figura 22 – Circuito de aquisição do ECG com o circuito da fonte simétrica	31
Figura 23 – Sinal do ECG obtido por SOUSA, 2018	32
Figura 24 – Etapas do treinamento da rede neural	32
Figura 25 – Etapas para reconhecimento de cardiopatias	33
Figura 26 – Google Colaboraty	34
Figura 27 – Fluxograma com a arquitetura da Rede Neural Convolucional	35
Figura 28 – Fluxograma com a arquitetura da Rede Neural Convolucional utilizada com os blocos de convolução	37
Figura 29 – Fluxograma com a Rede Neural Artificial para classificação de cardiopatias ..	38
Figura 30 – Interface do <i>Google Colaboraty</i> com o código da RNA proposta	39
Figura 31 – Matriz de confusão do 1º teste.	41
Figura 32 – Matriz de confusão do 2º teste.	42

LISTA DE TABELAS

Tabela 1 – Resultados obtidos no 1º teste da RNA	40
Tabela 2 – Resultados obtidos no 2º teste da RNA	42
Tabela 3 – Comparativo da acurácia entre o 1º teste e 2º teste da RNA	42

LISTA DE ABREVIATURAS E SIGLAS

ART	<i>Adaptive Resonance Theory</i>
AV	Atrio Ventricular
CNN	<i>Convolutional Neural Network</i>
CIFAR	<i>Canadian Institute for Advances Research</i>
ECG	Eletrocardiograma
F	Faraday
FN	<i>False Negative</i>
FP	<i>False Positive</i>
Hz	Hertz
OMS	Organização Mundial da Saúde
PTB	<i>Physikalisch-Technische Bundesanstalt</i>
ReLu	<i>Rectified Linear Activation Function</i>
RNA	Rede Neural Artificial
RNN	<i>Recurrent Neural Network</i>
SA	Sino Atrial
SBC	Sociedade Brasileira de Cardiopatias
TN	<i>True Negative</i>
TP	<i>True Positive</i>
V	Volt
Vdc	Volt em tensão contínua
1D	1 Dimensão
Ω	Ohm

SUMÁRIO

1	INTRODUÇÃO.....	10
1.1	OBJETIVOS	10
1.1.1	Objetivo geral	10
1.1.2	Objetivos específicos	10
1.2	ORGANIZAÇÃO DO TRABALHO	11
2	FUNDAMENTAÇÃO TEÓRICA.....	12
2.1	ATIVIDADE ELÉTRICA DO CORAÇÃO	12
2.2	ELETROCARDIOGRAMA	13
2.2.1	Onda P	13
2.2.2	Complexo QRS	14
2.2.3	Onda T	14
2.2.4	ECG Complexo	15
2.3	DERIVAÇÕES.....	16
2.4	CARDIOPATIAS	18
2.5	REDE NEURAL ARTIFICIAL	19
2.5.1	História da Rede Neural Artificial	19
2.5.2	Rede Perceptron Simples	21
2.5.3	Rede Perceptron de Multicamadas.....	23
2.5.4	Redes Neurais Recorrentes.....	24
2.5.5	Redes Neurais Convolucionais.....	25
3	MATERIAIS E MÉTODOS.....	27
3.1	AQUISIÇÃO DO ELETROCARDIOGRAMA	27
3.1.1	Circuito de aquisição do ECG	27
3.1.2	Sinal do ECG	31
3.2	PROCESSAMENTO DO SINAL.....	32
3.2.1	<i>PhysioNet</i>	33
3.2.2	<i>Python</i>	33
3.2.3	Rede Neural.....	34
4	RESULTADOS	39
4.1	PROCESSAMENTO DO SINAL.....	39
4.1.1	Rede Neural Proposta	39
5	CONCLUSÃO	43
	REFERÊNCIAS.....	44

1 INTRODUÇÃO

De acordo com a Organização Mundial de Saúde (OMS) em sua pesquisa mais recente, com dados do ano de 2019, uma das principais causas de morte no mundo são as doenças cardíacas e de acordo com o ano da coleta desses dados, o número apresentou 31% no número de mortes do âmbito global. Com a pandemia do novo COVID-19, pessoas com doenças crônicas como algumas cardiopatias, tornaram-se grupo de risco para o desenvolvimento da doença, além de que, por conta da quarentena, alguns cardiopatas negligenciam o acompanhamento médico agravando ainda mais a situação, já que, segundo o portal da transparência, houve um aumento de pelo menos 50% no índice de óbitos por doenças cardíacas. (SBC, 2020)

Em consequência deste contexto, o diagnóstico precoce de cardiopatias de forma prática e objetiva, pode ser posto como um fator de impacto positivo na diminuição destas estatísticas (MEDEIROS, 2020).

O Eletrocardiograma, também conhecido pela abreviatura ECG, é um exame que registra a atividade elétrica do coração, em que é possível realizar o diagnóstico de cardiopatias, através da análise morfológica do sinal gerado pelos impulsos elétricos oriundos do coração (TOMAZATI, 2010).

Diante de toda esta problemática, o uso da telemedicina tem sido uma excelente opção para diagnóstico e acompanhamento dessas doenças, além de proporcionar maior comodidade e praticidade ao paciente e ao profissional de saúde (ARRAIS JUNIOR, 2016) (SBC, 2020).

Propõe-se neste trabalho o uso de Rede Neural Artificial (RNA) convolucional, capaz de identificar cardiopatias a partir da classificação do Eletrocardiograma. A RNA será treinada com dados de ECG de indivíduos saudáveis e com cardiopatias. Essas informações serão coletadas no banco de dados da plataforma digital *PhysioNet* e será e testada com os dados colhidos por Sousa (2018) com o intuito auxiliar o diagnóstico de cardiopatias, gerando conforto e confiabilidade ao exame.

1.1 OBJETIVOS

1.1.1 Objetivo geral

O objetivo geral deste trabalho é realizar a análise dos sinais elétricos do coração e o seu processamento por meio de uma rede neural, para diagnóstico de cardiopatias no auxílio da telemedicina.

1.1.2 Objetivos específicos

- Realizar a coleta de dados no *database* utilizado

- Treinar a rede neural artificial por meio da topologia mais adequada;
- Realizar a validação da rede neural artificial para detecção de cardiopatias com os dados colhidos.

1.2 ORGANIZAÇÃO DO TRABALHO

Neste tópico é feita uma breve introdução ao tema e os objetivos do trabalho. O tópico 2 trata-se do referencial teórico a respeito da atividade elétrica do coração, o eletrocardiograma, Derivações, Cardiopatias e sobre a rede neural. No tópico 3, encontra-se a metodologia para desenvolvimento do projeto. O tópico 4 está os resultados obtidos a partir processamento do ECG a partir das redes neurais. Por fim, o tópico 5, encontra-se a conclusão do trabalho e proposta para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA


2.1 ATIVIDADE ELÉTRICA DO CORAÇÃO

O coração é um dos principais órgãos do ser humano, que tem como função, bombear sangue pelo corpo. Esse bombeamento é precedido por um estímulo elétrico, causado pela polarização, despolarização e repolarização do átrio e ventrículo, em que, as cargas elétricas estão dentro e ao redor das células cardíacas (VIER, 2008).

No momento que o músculo cardíaco se encontra em repouso, as cargas negativas estão no interior da célula e as cargas positivas em seu exterior, que é a chamada polarização. O processo contrário chama-se despolarização, que é quando há a contração do músculo cardíaco, em que, as cargas positivas estão no interior da célula e as cargas negativas em seu exterior. O retorno da célula ao seu estado inicial de repouso é a chamada repolarização. (VIER, 2008)

O processo de contração e relaxamento da fibra miocárdio, possuem caminhos específicos, denominado como o sistema de condução elétrica. Em que, o nodo sinoatrial (S-A), localizado próximo a veia cava superior, no átrio direito, onde o impulso elétrico se origina e faz com que haja a despolarização dos átrios. O nodo atrioventricular (A-V) e o feixe de His esquerdo e direito recebem o impulso elétrico através da rede de fibras de Purkinje, causando a despolarização dos ventrículos. A Figura 1 mostra a representação do sistema de condução elétrica do coração (VIER, 2008).

Figura 1 – Representação do sistema de condução elétrica do coração.




Fonte: REIS et al. 2013.

2.2 ELETROCARDIOGRAMA

Quando o estímulo elétrico atravessa o músculo cardíaco, tecidos próximos também recebem essa corrente elétrica que é propagada até a superfície da pele. Desta forma, é possível realizar o registro da diferença potencial gerada, através de eletrodos em contato com a pele. Tal registro é conhecido como Eletrocardiograma. É um exame bastante utilizado no diagnóstico de cardiopatias, pelo fato de que, é um exame rápido, pouco invasivo e economicamente viável (MORRIS, 2003).

O sinal característico do Eletrocardiograma é formado pela onda P, resultado da despolarização atrial, pelo complexo QRS, geradas pela despolarização do septo ventricular, da parede ventricular e fibras de Purkinje. E a onda T que é formado pela repolarização ventricular. A Figura 2 mostra a contribuição de cada onda na formação do ECG.(REIS, 2013)

Figura 2 – Contribuição de cada onda para a formação do ECG




Fonte: MALMIVUO E PLONSEY, 1995 (Editada pela autora 2021).

2.2.1 Onda P

Trata-se da primeira onda do ECG, representa a despolarização atrial, possui forma arredondada, uma morfologia entre 0° e $+90^\circ$, com duração igual ou inferior a 110 ms, sua tensão máxima é de 0,25 a 0,30 mV. De acordo com o sentido de ativação atrial, pode-se ter uma onda P isoelétrica, quando há taquicardia a tensão P aumenta, sem ultrapassar os limites do normal. (SBPC,2016; LENGYEL, 1974).

Na Figura 3 segue a onda P destacada no eletrocardiograma.

Figura 3 – Onda P no ECG




Fonte: NEUMAMM, 2011 (Editada pela autora, 2021).

2.2.2 Complexo QRS

O complexo QRS é a representação da despolarização ventricular, em que, possui três formas de onda distintas, a onda Q, a primeira do complexo, possui deflexão para baixo, na sequência a onda R, possui deflexão para cima e ao final do complexo, a onda S com deflexão para baixo. A variação do complexo QRS é normal nas diferentes derivações. Sua duração varia entre 0,08 e 0,11 s (BERBARI, 2000; MORRIS, 2003).

A Figura 4 ilustra a o complexo QRS.

Figura 4 – Complexo QRS no ECG




Fonte: NEUMAMM, 2011 (Editada pela autora, 2021).

2.2.3 Onda T

A onda T representa a repolarização, a diástole do ciclo cardíaco. É uma onda assimétrica, em quase todas as derivações, uma onda positiva, com amplitude equivalente entre 10 a 30%

do QRS. Em alguns indivíduos, uma pequena onda pode ocorrer ao final da onda T, conhecida como onda U, não possui origem bem definida, mas é considerada uma onda de repolarização. A Figura 5 ilustra a onda T no ECG (BERBARI, 2000; SBPC,2016).

Figura 5 – Onda T no ECG




Fonte: NEUMAMM, 2011 (Editada pela autora, 2021).

2.2.4 ECG Complexo

O sinal do ECG normal é constituído pela junção das ondas P, Q, R S e T, pelos segmentos P-R e S-T e pelos intervalos PR, ST e QT. Com amplitude entre 0,05 e 3mV. Por via de regra, trata às ondas Q, R e S, como sendo um modelo único, intitulado complexo QRS. A Figura 6 ilustra um registro de eletrocardiograma normal (DALE, 2004; SBC, 2016).

Figura 6 – Eletrocardiograma Normal



Fonte: NEUMAMM, 2011 (Editada pela autora, 2021).

2.3 DERIVAÇÕES


Derivação é o nome dado ao posicionamento de eletrodos no corpo humano para a aquisição de sinais elétricos. Existem infinitas derivações na superfície do corpo humano, sendo assim necessário, convencionar os tipos de derivações. O ECG possui 12 derivações, sendo elas classificadas entre periféricas e precordiais (SILVA, 2008; REIS, 2013).

As derivações periféricas, são aquelas em que a diferença de potencial é medida entre dois pontos de referência do corpo, ou seja, derivações bipolares ou apenas entre um ponto, que são as derivações unipolares (TOMAZATI, 2010).

As derivações DI, DII e DIII são derivações bipolares periféricas, responsáveis pela formação do triângulo de Einthoven, que recebe esse nome em homenagem ao pesquisador holandês Einthoven, que em 1913 definiu as três derivações de modo a formarem um triângulo, em que, o centro do triângulo representa o centro elétrico do coração (VIER, 2008).

O triângulo de Einthoven é disposto da seguinte maneira, na derivação DI o eletrodo positivo é conectado ao braço esquerdo e no braço direito o eletrodo negativo. Na derivação DII, conecta-se o eletrodo negativo ao braço direito e o eletrodo positivo conecta-se a perna direita. Por fim, na derivação DIII, conecta-se o eletrodo positivo a perna esquerda e o eletrodo negativo ao braço esquerdo. A perna direita é o ponto de referência para as três derivações. A Figura 7 pode-se observar a disposição de eletrodos nas derivações do triângulo de Einthoven (REIS, 2013; VIER, 2008).

Figura 7 – Triângulo de Einthoven




Fonte: ECG: manual prático de eletrocardiograma, 2013.

As derivações aVR, aVL e aVF, são também derivações periféricas, porém unipolares e são conhecidas como derivações de Goldberger. A derivação aVR representa o posicionamento do eletrodo direito no braço direito, a derivação AVL o posicionamento do eletrodo positivo no

braço esquerdo e a derivação AVF o eletrodo positivo posicionado na perna esquerda. Nas três derivações, o eletrodo negativo está posicionado em um único ponto de referência em comum. Na Figura 8 pode-se observar a disposição dos eletrodos nas derivações de Goldberger (REIS, 2013).


Figura 8 – Derivações de Goldberger



Fonte: ECG: manual prático de eletrocardiograma, 2013.

As derivações precordiais são derivações unipolares dispostas no plano horizontal na área do tórax, que são as derivações V1 a V6. Entretanto, estão situadas em planos distintos, as derivações V1 e V2 localizam-se no plano horizontal no quarto espaço intercostal. V3 encontra-se no plano horizontal intermediário entre o quarto espaço. As derivações V4, V5 e V6 localizam-se no plano horizontal no quinto espaço intercostal. Na Figura 9 pode-se observar a disposição dos eletrodos nas derivações precordiais (MORRIS, 2003).

Figura 9 – Derivações precordiais



Fonte: Cardiopapers.

2.4 CARDIOPATIAS

Segundo Bueno (2018), cardiopatias são doenças causadas por algum débito cardíaco, que seria o volume de sangue que sai dos ventrículos, por minuto. Segundo a Pfizer, 2019, é o termo usado para definir todas as doenças que acometem o coração.

As Cardiopatias podem ser congênitas, quando o indivíduo já nasce com a doença ou adquire a partir dos primeiros dias de vida, ou podem ser adquiridas ao longo do tempo. (REDE D'OR SÃO LUIZ, 2021).

Alguns dos tipos de cardiopatias mais comuns são os seguintes:

- **Cardiopatias Congênitas:** Doenças cardíacas desenvolvidas desde o nascimento, em casos mais graves, podendo ser diagnosticado no momento do nascimento em casos menos graves, o diagnóstico, normalmente, é feito com o indivíduo já adulto (PIFIZER, 2019);
- **Doenças no Miocárdio:** Ocorre quando há comprometimento no funcionamento do músculo cardíaco, afetando a atividade cardíaca (BUENO, 2018);
- **Infecção do Coração:** Doenças ocasionadas por fungos, bactérias, vírus ou parasitas que atingem o coração, danificando seu funcionamento (PIFIZER, 2019);
- **Cardiopatia Hipertensiva:** Quando o paciente é acometido com a doença da hipertensão, no qual a pressão nas artérias é muito alta e leva a sobrecarga no coração, outros órgãos também podem ser comprometidos podendo desenvolver outras patologias (SBC, 2006);
- **Cardiopatia isquêmica:** Ela ocorre quando há um desequilíbrio na oferta e demanda de oxigênio, ocasionados pelo acúmulo de gordura nas artérias do miocárdio, fatores como estresse e esforço físico também alteram a demanda e oferta de oxigênio no coração.

Trata-se de uma doença crônica, mais comum em adultos a partir dos 40 anos, pode gerar dor no peito e em casos agudos, infarto (CARVALHO E SOUSA, 2001; FUCHS, 2016).

A partir do exame eletrocardiográfico, o ECG, é possível identificar a grande maioria dessas cardiopatias, em que a análise das morfologias das ondas dá o diagnóstico de cada doença (SBC, 2016).

2.5 REDE NEURAL ARTIFICIAL


Segundo Rosa e Matta, 2004 as Redes Neurais Artificiais, também chamadas de RNAs, são padrões matemáticos que têm estruturas baseadas nos arranjos neurológicos humanos com uma capacidade computacional obtida a partir do aprendizado e generalização.

Também podendo ser definidas como, sistemas computacionais com estrutura baseada em ligações de nós ou neurônios, por isso, se dá a nomenclatura de “rede”. (FERNANDES, 2005)

Os nós ou neurônios artificiais, são unidades de processamento simples, que têm como função realizar os cálculos das funções matemáticas. Há camadas dos neurônios, em que cada um deles realiza o somatório de suas entradas e entrega a saída do neurônio como resultado. (ROSA; MATTA, 2004).

A Figura 10 mostra a estrutura básica de uma rede neural.

Figura 10 – Estrutura Básica de uma Rede Neural



Fonte: CARVALHO, 2011 (Editada pela autora, 2021)

2.5.1 História da Rede Neural Artificial

Em 1943, o neurofisiologista e psiquiatra Warren McCulloch e o matemático Walter Pitts, desenvolveram os primeiros estudos sobre a Rede Neural Artificial, modeladas a partir de

circuitos elétricos, foi desenvolvido um modelo computacional baseado no modelo matemático lógica de limiar. (FERNANDES, 2005).

Em 1949 Donald Olding Hebb publicou uma importante obra, o livro *“The Organization of Behaviour”* (A organização do Comportamento) que inspirou diversos modelos de RNAs de destaque na atualidade. Na obra, Hebb indicou que as rotas dos neurônios se fortalecem quando são utilizados, tal qual os neurônios biológicos, ao disparar dois nervos ao mesmo tempo, sua conexão é aperfeiçoada (FERNANDES, 2005).

Com os avanços computacionais nos anos de 1950, Nathaniel Rochester, tentou simular uma hipotética rede neural, infelizmente, sua tentativa foi falha. Entretanto foi dada continuidade nas pesquisas da área. E 1956, Dartmouth, desenvolveu um projeto de pesquisa em que impulsionou as Redes Neurais e Inteligência Artificial. Um de seus resultados, estimulou a pesquisa em Inteligência Artificial em processamento neural. (*Data Science Academy*, 2021).

Baseado nos estudos de McCulloch e Pitts, em 1959 Frank Rosenblatt criou a Rede Perceptron, uma rede de múltiplos neurônios discriminadores. A rede em questão é a mais antiga utilizada até hoje. Nela é feito o cálculo da soma ponderada das entradas, faz a subtração dentro de um limite e entrega como resultado um dos valores possíveis. Porém em 1969, Marvin Minsky e Seymour Papert comprovaram a limitação da rede Perceptron, com a publicação do livro *Perceptrons* (*Data Science Academy*, 2021; SANTOS; ALMEIDA, 2011).

Posteriormente foram desenvolvidas inúmeras pesquisas na área RNAs na década de 80, com os avanços tecnológicos as pesquisas tornaram-se mais contundentes. O físico John Hopfield, em 1982, desenvolveu um importante modelo de RNA, diferente dos modelos baseados no Perceptron, tratava-se de uma rede de conexões recorrentes em que havia uma competição entre os neurônios, em que, não tinha supervisão do aprendizado (SANTOS; ALMEIDA, 2011).

Nos anos 80 com o desenvolvimento da tecnologia e, conseqüentemente, a melhoria nos computadores que permitiam melhores testes das RNAs, bem como, a evolução de modelos matemáticos, houve o ressurgimento da Rede Perceptron. O modelo que permitiu tal acontecimento foi a Rede de Multiníveis em que o algoritmo de aprendizado é chamado de *Back Propagation* (Retropropagação) desenvolvido por Rumelhart, Hinton e Williams, solucionou boa parte os problemas de aprendizado existentes até então (BRAGA. CARVALHO. LUDERMIR, 2000).

Outro modelo que na década de 80, foi o modelo Kohonen, que permite um aprendizado por meio da competição auto organizáveis, criando os chamados *self organizing maps* (mapas de atributos auto organizáveis) (SANTOS; ALMEIDA, 2011).


Outro modelo de destaque é *Adaptive Resonance Theory*, ART, criado por Gail Carpenter e Stephen Grossberg. O aprendizado é não supervisionado, ou seja, cria protótipos dos padrões aprendidos. Posteriormente surgiram outras versões, como semi supervisionado e com o uso da lógica *Fuzzy* (Lógica Nebulosa) (SANTOS; ALMEIDA, 2011).

2.5.2 Rede Perceptron Simples

O Perceptron é a configuração mais simples de RNA, que tem como fundamentação, o modelo computacional baseado na retina, e um dos seus objetivos é de realizar percepção eletrônica dos sinais, tais como a identificação de padrões geométricos. (SILVA et al, 2016).

A Figura 11 mostra uma rede Perceptron formada por de n sinais de entrada, representação do problema a ser mapeado, e uma saída, á que neste tipo de rede é composto de um único nó. (SILVA et al, 2016).

Figura 11 – Estrutura básica da Rede Perceptron



Fonte: SILVA et al, 2016

Seu princípio de funcionamento é dado a partir de entradas x_n , em que estão contidas as informações do que está sendo mapeado, em que será realizado a ponderação pelos pesos sinápticos w_i que irá realizar a qualificação dos objetivos funcionais delegado a cada nó, mapeando entradas e saídas do processo em questão. Posteriormente, o valor derivado da ponderação das entradas, adicionado a limiar de ativação, é transmitido como argumento da função de ativação, em que seu resultado de retorno será a saída "y". Podendo também ser descrito como mostra a equação 2.1 (HAYKIN, 2001; SILVA et al, 2016).

$$\begin{cases} u = \sum_{i=1}^n w_i \cdot x_i - \theta \\ y = g(u) \end{cases} \quad (2.1)$$

As entradas x_i ficam em função do problema que será mapeado, podendo assumir valores numéricos variados. Com o intuito de melhorar o desempenho computacional, no processo de desenvolvimento da rede, as entradas são normalizadas, considerando os limites numéricos gerados pelas funções de ativação. (HAYKIN, 2001; SILVA et al, 2016).

As funções de ativação, devido suas características estruturais, normalmente utilizam a função degrau ou degrau bipolar. Por conseguinte, têm-se duas possibilidades de saída, independente da função de ativação. Isto significa que para função degrau a saída será 0 ou 1 e para a função bipolar -1 ou 1. Assim a função de ativação, em termos matemáticos, é dada pela equação 2.2.(SILVA et al, 2016).


$$y = \begin{cases} 1 & \text{se } \sum w_i \cdot x_i - \theta \geq 0 \iff w_1 \cdot x_1 + w_2 \cdot x_2 - \theta \geq 0 \\ -1 & \text{se } \sum w_i \cdot x_i - \theta < 0 \iff w_1 \cdot x_1 + w_2 \cdot x_2 - \theta < 0 \end{cases} \quad (2.2)$$

Em que as desigualdades são uma função de primeiro grau linear, a fronteira de decisão para o Perceptron de duas entradas será uma reta definida pela equação 2.3 (SILVA et al, 2016).

$$w_1 \cdot x_1 + w_2 \cdot x_2 - \theta = 0 \quad (2.3)$$

Deste modo, é possível concluir que o Perceptron de camada simples é um classificador de padrões em que sua função é realizar a divisão entre as classes que são linearmente separáveis. Na condição do Perceptron de duas entradas. A Figura 12 ilustra uma reta posicionada na fronteira de separabilidade. (HAYKIN, 2001; SILVA et al, 2016).

Figura 12 – Fronteira de separação dos neurônios com duas entradas




Fonte: SILVA et al, 2016

2.5.3 Rede Perceptron de Multicamadas

Para dados que não são linearmente separáveis, e por consequência, que não podem ser tratados pelo Perceptron Simples, utiliza-se o Perceptron de Multicamadas, pois são computacionalmente mais poderosas, podendo assim solucionar problemas mais complexos, com diversas aplicações lineares e não lineares. Consiste em um conjunto de nós, com os dados de entrada, camadas ocultas e camadas de saída (HAYKIN, 2001; SILVA et al, 2008).

A Figura 13 mostra a arquitetura do Perceptron de Multicamadas.

Figura 13 – Arquitetura do Perceptron de Multicamadas



Fonte: SILVA et al, 2016

O Perceptron de Multicamadas possui diversas aplicações para diferentes tipos de problemas, para as mais diversificadas áreas, além de possuir uma das mais versáteis arquiteturas. Pode-se destacar as seguintes áreas para aplicabilidade do Perceptron de Multicamadas (SILVA et al, 2016):

- Previsão de séries temporais;
- Identificação e controle de processos;
- Aproximação universal de funções;
- Otimização de sistemas;
- Reconhecimento de padrões.

Seu funcionamento trata-se de uma camada de entrada que recebe os dados e não realiza nenhum tipo de processamento, servindo para armazenar e receber as informações. Nessa camada, o número de neurônios é proporcional ao vetor de entrada. formado também por camadas ocultas,

que estão entre as camadas de entrada e saída, e permitem a não linearidade e complexidade da rede. O número de camadas ocultas, independe de algum tipo de método, bem como número de neurônios nessa camada. Por fim, a camada de saída armazena os resultados obtidos, também é capaz de proporcionar a não linearidade da rede. Número de vetores é proporcional ao número de neurônios de saída (SILVA, 2010).

O ajuste de pesos e do limiar em cada um dos nós é feito a partir do processo de treinamento supervisionado, ou seja, para cada entrada há uma resposta. No decorrer do treinamento de redes Perceptron de Multicamadas, é utilizado um algoritmo de aprendizagem chamado *Backpropagation* ou reprogramação do erro (SILVA et al, 2016).

Nesse algoritmo supervisionado, para cada entrada há uma saída desejada, utilizadas para ajuste dos pesos "w", com base na regra de delta, como pode ser observado na equação 2.4 (SILVA et al, 2008).

$$w_i(n+1) = w_i(n) + \Delta w_i(n) \quad (2.4)$$

O neurônio "i" é nó de saída e "n" é o número de interações. Assim o gradiente descendente Δw_i é dado pela equação 2.5 (SILVA et al, 2008)

$$\Delta w_i(n) = \eta \frac{\partial \varepsilon(n)}{\partial w_i(n)} \quad (2.5)$$

Desta forma, η será taxa de aprendizagem (n) será a soma instantânea dos erros quadráticos que ocorrem na interação. O treinamento da rede ocorre dentro de duas fase, que são a "forward" (pra frente), em que a saída é gerado como resultado real da rede, e "backward" (pra trás), em que os pesos sinápticos atualizam-se através da regra delta, onde o resultado da rede irá para mais próximo da resposta esperada (SILVA et al, 2008).


2.5.4 Redes Neurais Recorrentes

As Redes Neurais Recorrentes (RNN), são métodos de aprendizado de máquina que possuem neurônios recorrentes que possuem loops que podem armazenar dados e processar novas entradas e realizam o processamento a partir de séries temporais (CARVALHO, et al, 2018).

As RNNs permitem que os parâmetros da rede possam ser usados em instantes de tempo diferentes, isso por conta do efeito temporal da rede. Isso faz com que seja possível realizar a captura as relações temporais em uma sequência de dados, pois nela é possível fazer uso de

informações passadas para gerar uma predição. A Figura 14 ilustra uma RNN de instante de tempo " t " e entrada " x " gerando uma saída " h ", onde a camada " A " é recorrente (MOURA, 2018).

Figura 14 – Arquitetura de uma Rede Neural Recorrente Simples



Fonte: OLAH, 2015.


Para o treinamento de uma Rede Neural Recorrente, é utilizado algoritmo *Backpropagation*, que ajusta os pesos da rede ao longo de um determinado intervalo de tempo, realizando a soma dos gradientes da função para cada instante de tempo (MOURA, 2018).

Uma problemática encontrada no uso da função de retropropagação nas RNNs é o aumento do gradiente, que faz com que o algoritmo de descida não consiga ajustar os valores, fazendo com que, no decorrer dos passos de tempo o gradiente diminua e acabem perdendo a relevância, dificultando a convergência da rede (GOODFELLOW; et al, 2016).

2.5.5 Redes Neurais Convolucionais

A Rede Neural convolucional, CNN, é uma variação das redes Perceptron de Multicamadas, porém tem como inspiração o processamento de informações visuais biológicas. Assim como as técnicas tradicionais de computação visual, a rede CNN pode adicionar filtros de dados visuais, mantendo a relação de vizinhança entre os pixels de imagem. Na Figura 15 pode-se observar um exemplo de uma estrutura de uma rede CNN (VARGAS; et al, 2016).

Figura 15 – Arquitetura de uma Rede Neural Convolucional



Fonte: VARGAS, 2016.

Por volta do ano de 2006, pesquisadores do *Canadian Institute for Advances Research* (CIFAR), introduziram novos processos de aprendizagem não supervisionada nas RNAs que poderiam criar camadas de detecção dos atributos sem a necessidade de um pré-processamento dos dados. Sua primeira abordagem foi para reconhecimento de fala e logo quebrou recordes em um benchmark de reconhecimento de fala. Posteriormente surgiram redes convolucionais muito utilizadas pelo fato de ser baseada na visão computacional (FERREIRA, 2017).

A arquitetura de uma CNN é dividida em uma série de estágios, os primeiros são constituídos por dois tipos de camadas, as de convolução e *pooling*. A camada de convolução é um conjunto de mapas de atributos conectados a camada anterior por meio de parâmetros distribuídos por todas as unidades e possui neurônios de ativação não lineares descrita na equação 2.6 (Y. LeCun, 2015).

$$f(x) = \max(0, x) \quad (2.6)$$

As camadas *Pooling*, computam o máximo local de uma região do mapa de atributos específica, essas camadas eliminam valores não máximos, diminuindo o tamanho da representação dos dados e por consequência a carga computacional necessárias para as próximas camadas e também cria uma irrelevância nas pequenas distorções. (Y. LeCun, 2015).

As redes CNN têm ganhado bastante espaço, além de reconhecimento de imagens, as redes Convolucionais são muito utilizadas em análises de sentimentos, classificação de tipos de perguntas, classificação de filmes, na descoberta de drogas entre outras áreas. E em conjunto com redes RNN podem desenvolver novos mecanismos para o desenvolvimento da inteligência artificial (SANTOS, 2014).


3 MATERIAIS E MÉTODOS

Neste tópico são descritos os materiais e métodos utilizados para o desenvolvimento do trabalho.

3.1 AQUISIÇÃO DO ELETROCARDIOGRAMA

Para realização dos testes de comprovação do processamento do ECG, por meio da rede neural, foram utilizadas as aquisições de Sousa, 2018. Os dados utilizados são de cinco indivíduos voluntários, entre 20 e 23 anos e do sexo masculino e feminino. A Figura 16 mostra as etapas de aquisição do sinal de ECG.

Figura 16 – Etapas Para a Aquisição do ECG




Fonte: SOUSA, 2018

3.1.1 Circuito de aquisição do ECG

O circuito projetado por Sousa, 2018 teve como base o *datasheet* do amplificador de instrumentação AD620, onde consta um esquemático do circuito para aquisição do eletrocardiograma, já que, o amplificador em questão é amplamente utilizado em instrumentação médica devido a sua alta precisão. Na Figura 17 pode-se observar o circuito de aquisição presente no *datasheet* do AD620.

Figura 17 – Circuito de aquisição presente no datasheet do AD620




Fonte: Analog Devices, 2004.

Para o circuito de aquisição em questão também foram utilizados dois estágios de filtragem, um filtro passa baixa e um capacitor utilizado como filtro passa alta.

O filtro passa baixa foi utilizado para diminuir a quantidade de ruídos presentes na aquisição, já que, por se tratar de um sinal de baixa amplitude, os componentes utilizados geram uma quantidade de ruído que pode atrapalhar a identificação do sinal. O filtro utilizado é de topologia Sallen Key de segunda ordem com formato Bessel. A frequência de corte desse filtro é de 31,83 Hz, um fator de qualidade de 0,5 (Bessel) e ganho 2. Para a construção desse filtro utilizou-se o amplificador operacional LM324AN do fabricante *STMicroelectronics*, resistores de 100 k Ω (R1 e R2), e pares de capacitores de 100 nF em série. Na Figura 18 pode-se observar a topologia do filtro passa-baixa utilizado (SOUSA, 2018) (BYLESTAD, 2012).

Figura 18 – Topologia do filtro passa-baixa utilizado




Fonte: SOUSA, 2018.

Foi utilizado um capacitor, na saída do circuito de aquisição, como filtro passa alta, de forma a eliminar o *Offset*, que é uma tensão na saída do circuito, provocada por um desbalanceamento interno causado pelo casamento imperfeito dos dispositivos de entrada no estágio diferencial do AmpOp. Trata-se de um circuito R-C passivo, com um capacitor de 100nF e R é resistência equivalente do circuito, que pelo fato de possuir uma reatância muito alta seu valor tenderá ao infinito, fazendo com que a frequência de corte seja praticamente zero, eliminando apenas o *Offset* do circuito (SOUSA, 2018; BOYLESTAD, 2012).

Também foi utilizado um estágio de amplificação, para melhor identificação do sinal adquirido. Nessa etapa empregou-se um amplificador não inversor. Utilizou-se o Amp Op LM324 um resistor R1 22 k Ω e um potenciômetro de 10 K Ω , para possibilitar um ganho ajustável de até 43,29. A Figura 19 apresenta a topologia do amplificador não inversor (SOUSA, 2018; BOYLESTAD, 2012).


Figura 19 – Topologia do amplificador utilizado



Fonte: SOUSA, 2018.

Após as etapas citadas anteriormente, obteve-se o circuito de aquisição do ECG Desenvolvido por Sousa, 2018. Na Figura 20 pode-se observar o esquemático do circuito.


Figura 20 – Topologia do circuito de aquisição do ECG.



Fonte: SOUSA, 2018.

Para a alimentação do circuito foi utilizada uma fonte simétrica, empregada para a proteção contra inversão de polaridade da fonte. A fonte simétrica foi projetada com dois diodos Zener de 1,5 V polarizados, em que um fornece a tensão negativa e o outro a positiva. Foram utilizados também, dois resistores 10 Ω e dois capacitores cerâmicos de 100 nF para estabilizar a tensão. Para a alimentação utilizou-se uma bateria de 9 Vdc, onde obteve-se a alimentação simétrica de +4,5 Vdc e -4,5 Vdc. A Figura 21, mostra o esquemático da fonte. (SOUSA, 2018).


Figura 21 – Topologia da fonte simétrica.



Fonte: SOUSA, 2018.

A Figura 22, mostra o circuito de aquisição com fonte simétrica na bateria utilizado por Sousa, 2018.

Figura 22 – Circuito de aquisição do ECG com o circuito da fonte simétrica



Fonte: SOUSA, 2018.


3.1.2 Sinal do ECG

A aquisição do sinal do ECG é feita a partir de 12 derivações, porém com algumas derivações é possível identificar a morfologia do sinal em questão. A aquisição do sinal de ECG feita por Sousa, 2018 foi realizada a partir da derivação DI do triângulo de Einthoven em que é possível observar as características do sinal do ECG.

Os testes foram realizados com os indivíduos em repouso, sentados e imóveis. Foi utilizado gel condutivo, para melhorar a condutividade entre a pele e o eletrodo. Um eletrodo foi posicionado no pulso direito, representando o sinal negativo. Outro no pulso esquerdo, representando sinal positivo. E perna a esquerda, representando a referência da aquisição (SOUSA, 2018).

Os materiais utilizados para a aquisição foram, um sistema composto pelo circuito de aquisição, eletrodos, gel condutivo, cabos de conexão e a *Analog Discovery 2* da Digilent, que foi utilizada para substituir o osciloscópio e para a coleta dos dados do sinal (SOUSA, 2018). A Figura 23 ilustra o sinal do ECG obtido na saída do circuito de aquisição.

Figura 23 – Sinal do ECG obtido por SOUSA, 2018




Fonte: SOUSA, 2018.

3.2 PROCESSAMENTO DO SINAL

Para o processamento do sinal de ECG, por meio da rede neural, foram divididas as etapas para a sua realização. De início foram coletados os dados para teste de Sousa (2018), que contém informações de sinais saudáveis do eletrocardiograma. Em seguida foram coletados dados para treinamento do *Physikalisch-Technische Bundesanstalt* (PTB), presente na plataforma da *PhysioNet*, que contém cerca de 14.000 amostras de sinais de ECG saudáveis e com cardiopatias.

A Figura 24 mostra as etapas para o treinamento da rede neural.


Figura 24 – Etapas do treinamento da rede neural



Fonte: Autoria Própria, 2021.

Posteriormente foi feita a extração das características dos sinais saudáveis e com a cardiopatias, para em seguida realizar o treinamento da rede, e por fim, foram feitos os testes da rede para validação. A linguagem utilizada para a construção da RNA foi o *Python*. A Figura 25 mostra as etapas para o reconhecimento de cardiopatias.

Figura 25 – Etapas para reconhecimento de cardiopatias



Fonte: Autoria Própria, 2021.

3.2.1 *PhysioNet*

A *PhysioNet* é uma plataforma gerenciada por membros do laboratório de Fisiologia Computacional do MIT (*Massachusetts Institute of Technology*). Estabelecido no ano de 1999, *PhysioNet* é apelido dado ao *Research Resource for Complex Physiologic Signals* (do inglês, Recurso de pesquisa para sinais fisiológicos complexos). Com o objetivo de desenvolver pesquisa e educação na área da biomedicina, oferece um grande banco de dados fisiológicos, clínicos e *software* de código aberto relacionados (*PhysioNet*, 2021).

Os sinais biomédicos são coletados em parceria com NIH (*National Institutes of Health*) e em parceria com a conferência anual *Computing in Cardiology* desenvolve pesquisas em problemas ainda não resolvidos na área biomédica (*PhysioNet*, 2021).

O site da *PhysioNet* foi desenvolvido para a troca e disseminação livre e aberta de sinais biomédicos, fornecendo praticidade e cooperação no desenvolvimento de novos algoritmos, além de fornecer treinamento gratuito para novos usuários (*PhysioNet*, 2021).


3.2.2 *Python*

Python é uma linguagem de alto nível, lançado na década de 90, criada para dar ênfase no trabalho do desenvolvedor, com linguagem simples que facilita o trabalho do programador. Oferece recursos dinâmicos, poderosos em biblioteca. Seu código é aberto e sua utilização é gratuita. (PYTHON, 2021).

Possui muitas estruturas de testes integradas, com módulos voltados para realização de testes. É favorito dentro da programação, por ter uma boa interpretação de grandes volumes de dados, e é uma linguagem portátil e multiplataforma. (PYTHON, 2021).

Para Desenvolvimento deste trabalho, foi utilizada a plataforma *Google Colaboraty*, em que, o possui todos os mecanismos para efetivação deste trabalho, já que é uma plataforma de armazenamento em nuvem de *notebooks*, onde são desenvolvidos códigos na linguagem de *Python*, diretamente no navegador, que possui todas as bibliotecas, em que não há necessidade de instalar nenhum *software*. Na Figura 26 é possível observar a interface do *Google Colaboraty* (KENZIE, 2019).

Figura 26 – Google Colaboraty



Fonte: Google Colaboraty, 2021.

3.2.3 Rede Neural

Para o processamento dos dados colhidos de ECG, foi desenvolvido uma Rede Neural artificial Convolutacional usando a função de ativação ReLu (*Rectified Linear Activation Function*) e em sua saída a função de ativação Softmax.

O modelo convolutacional de uma dimensão 1D é uma topologia de apenas uma camada convolutacional, muito eficaz em sequenciamento de tempo em que possui diversas saídas. Esse modelo permite que os dados sejam utilizados em seu estado bruto, sem a necessidade de um pré-processamento. Tendo como propósito descobrir múltiplos níveis de representação para que recursos de alto nível tenham uma sequência abstrata dos dados (GUO et al., 2017).

A rede convolutacional possui uma arquitetura composta pela camada de entrada, camada convolutacional e *pooling*. O modelo sequencial utilizado é oferecido pelo Keras, que é uma biblioteca de RNA de código aberto escrita em *Python*. Nela encontra-se as funções necessárias para construir cada camada de uma CNN.

Neste trabalho utilizou-se a função de ativação ReLu, já que a função de ativação é um recurso de extrema importância na construção de uma RNA, pois a partir dela são definidas as informações que são relevantes ou não. Contribuem para a não linearidade do modelo de forma a realizar atividades mais complexas. A função de ativação ReLu é não linear e possibilita a reprodução dos erros para trás e grande número de camadas que a própria função ativa. Sua principal vantagem é não ativar todos os neurônios de uma vez, o que melhora a eficiência da rede. A função de ativação ReLu pode ser observada na Equação (2.6) (Silva et al., 2010; DAL PRÁ, 2020).


Faz-se também necessária a utilização de funções de ativação na saída da rede, neste

trabalho fez-se uso da função de ativação Softmax, que é bastante utilizada para classificação binária ou de várias classes. Essa função transforma valores em probabilidades e seu resultado é 1, gerando um vetor que representa a probabilidade de diversos tipos de resultados na saída. É uma função muito utilizada em aprendizado profundo. A equação a 3.1 mostra a função de ativação Softmax em que "j" representa o índice do neurônio de saída, "k" representa todos os neurônios de um nível e "z" indica o vetor dos neurônios da saída (DAL PRÁ,2020).

$$\sigma(z)_j = \frac{e^z_j}{\sum_{k=1}^k e^z_k} \quad (3.1)$$

A Figura 27 Mostra o fluxograma com a arquitetura da CNN com suas funções de ativação e saídas.

Figura 27 – Fluxograma com a arquitetura da Rede Neural Convolutacional



Fonte: Autoria Própria, 2021.


Para o desenvolvimento do processamento foram estabelecidas etapas para a construção da rede. De início foram coletados os dados de ECG disponíveis na *PhysioNet*, os dados foram disponibilizados pela *Physikalisch-Technische Bundesanstalt* (PTB), com a mostras de 4.046 sinais saudáveis (sinal normal) e 10.506 amostras com cardiopatias (sinal anormal). Os dados foram separados entre sinal normal e anormal e salvos em formato .csv,(amostras separadas por vírgula). Os arquivos foram importados para o *Google Drive* onde poderiam ser utilizados no *Google Colaboraty*.

Em seguida foi dada início a construção da CNN.As bibliotecas para uso da linguagem de programação em *python* foram importadas, depois os dados de treinamento, validação e teste foram separados, em que, 60% das amostras dos dados foram utilizados para o treinamento da

rede, cerca de 9.800 dados, 20% das amostras para validação, por volta de 2.200 amostras e 20% para teste, por volta de 2.200 amostras.

Em seguida foi dado início a construção da CNN 1D, em que se utilizou 5 blocos de convolução de 1 dimensão e em cada bloco uma camada *pooling* utilizada para a redução do mapa de recursos. O primeiro bloco convolucional contou com 32 neurônios, o segundo bloco contou com 84 neurônios, o terceiro 128 neurônios, o quarto com 256 e o último bloco com 513 neurônios. A definição da quantidade de blocos e neurônios é feita de forma aleatória, não possui em nenhuma literatura um parâmetro que defina essa quantidade. Ao final da rede foi utilizada a função de ativação softmax para a definição dos parâmetros de saída, que são as aquisições de ECG saudáveis ou com cardiopatias. A rede foi treinada de forma a apresentar a acurácia, precisão, *recall* e *score*, parâmetros que definem a assertividade da rede. A Figura 28 mostra o fluxograma com a arquitetura CNN utilizada e o seus blocos de convolução.


Figura 28 – Fluxograma com a arquitetura da Rede Neural Convolucional utilizada com os blocos de convolução



Fonte: Autoria Própria, 2021.

Para a validação deste trabalho foram utilizados os dados colhidos por Sousa (2018) em que contém cinco amostras de ECG de pacientes saudáveis. As amostras foram agrupadas e salvas em um arquivo no mesmo formato dos arquivos de treinamento e importados para o *Google Drive*. Os dados de treinamento, validação e teste foram separados, em que, 80% das amostras dos dados foram utilizados para o treinamento da rede, cerca de 12.000 dados, 20% das amostras para validação, e para o teste as 5 amostras já citadas. Como as amostras de teste são todas saudáveis a classe de cardiopatias foi preenchida com zeros. A Figura 29 mostra a estrutura da rede neural, em forma de fluxograma, para realização de teste e treinamento da mesma.

Figura 29 – Fluxograma com a Rede Neural Artificial para classificação de cardiopatias



Fonte: Autoria Própria, 2021.

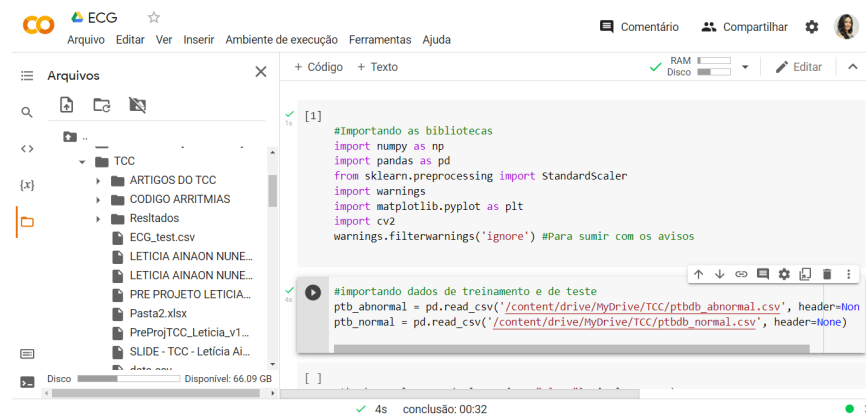
4 RESULTADOS

Neste tópico serão tratados os resultados alcançados durante a elaboração deste trabalho. Os resultados serão representados por meio de tabelas com os valores de acurácia, precisão, *recall* e *score*, e com a matriz de confusão que descreve a acurácia da rede.

4.1 PROCESSAMENTO DO SINAL

Para processamento do sinal e validação da RNN proposta, utilizou-se dados do base de dados da *PhysioNet*, que foram utilizados para treinamento e teste da rede. Os dados colhidos por Sousa (2018) também foram utilizados para teste da RNA. Os dados foram importados para a plataforma *Google Colaboraty*, para assim efetuar o processamento por meio da rede neural convolucional de 1 dimensão. A Figura 30 mostra a interface da plataforma utilizada com o código da RNA proposta.

Figura 30 – Interface do *Google Colaboraty* com o código da RNA proposta



Fonte: *Google Colaboraty*, 2021.

4.1.1 Rede Neural Proposta

Para validação da RNA proposta, foi utilizada a o modelo convolucional com arquitetura de 1 dimensão, demonstrados por meio de fluxogramas já citados na metodologia. A rede irá apresentar a precisão de acordo com seu treinamento demonstrando se os dados testados são de ECG normal ou não, ou seja, se os sinais possuem cardiopatias ou não.

Foram feitos dois testes de validação da rede. O primeiro teste com os próprios dados da *PhysioNet* e o segundo com os dados colhidos por Sousa (2018). Para o primeiro teste de validação a rede alcançou uma acurácia de 97%, de acordo com Silva, 2010 e Haykin, 2001, um excelente resultado. Na Tabela 1 podemos observar os resultados obtidos pela rede.

Tabela 1 – Resultados obtidos no 1º teste da RNA

	Precisão	Recall	Score
ECG Normal	97%	92%	95%
ECG Anormal	97%	99%	98%
Acurácia	-	-	97%
Média simples	97%	96%	96%
Média ponderada	97%	96%	96%

Fonte: Autoria Própria, 2021.

Acurácia é a razão entre o somatório dos acertos da RNA sobre todas as previsões, sejam corretas ou não. Ou seja, o quantitativo de previsões assertivas da RNA. Assim pode-se dizer rede acertou o resultado de 2.134 amostras e errou o resultado de 66 amostras, onde o valor total de amostras usadas o para teste é de 2.200. A equação 4.1 mostra como é feito o cálculo da acurácia(*Google Developers para Machine Learning*, 2021)

$$Acuracia = \frac{TP + TN}{TP + FP + TN + FN} \quad (4.1)$$

TP (*True Positive*) é quando no conjunto real foi previsto de forma correta, o FP (*False Positive*) é quando no conjunto real foi previsto de forma incorreta, o TN (*True Negative*) é quando no conjunto real, a classe que não estamos buscando prever foi prevista corretamente, já o FN (*False Negative*) é quando no conjunto real, a classe que não estamos buscando prever foi prevista incorretamente.(*Google Developers para Machine Learning*, 2021).

Recall é a proporção de previsões positivas identificadas de maneira correta, ou seja, o quão bom o modelo é para prever positivos. É definido como a razão entre verdadeiros positivos sobre a soma de verdadeiros positivos com negativos falsos. O cálculo do recall é feito como mostra a equação 4.2 (*Google Developers para Machine Learning*, 2021).

$$Recall = \frac{TP}{TP + FN} \quad (4.2)$$

A precisão, como o próprio nome já diz, demonstra o quão precisa é a RNA, isto é, a quão boa é a rede neural artificial. Calcula-se a precisão da forma que está descrito na equação 4.3 (*Google Developers para Machine Learning*, 2021).

$$Preciso = \frac{TP}{TP + FP} \quad (4.3)$$


O score é o balanço entre a precisão e o recall. Demonstrado na equação 4.4 (*Google Developers para Machine Learning*, 2021).

$$score = 2 \cdot \frac{Preciso \cdot score}{Preciso + score} \quad (4.4)$$

Outro demonstrativo da eficiência da rede é a matriz de confusão que permite a visualização do desempenho de um algoritmo de classificação. Na primeira linha e primeira coluna, apresenta os verdadeiros positivos, na primeira linha e segunda coluna estão os falsos positivos, na segunda linha e primeira coluna estão os falsos negativos e na segunda linha e segunda coluna estão os verdadeiros negativos. De forma que os valores na diagonal representam a acurácia da rede, demonstrando assim, o número de acertos. A Figura 31 apresenta a Matriz de confusão do primeiro teste.

falsos positivos , falsos negativos , verdadeiros positivos e verdadeiros negativos

Figura 31 – Matriz de confusão do 1º teste



Fonte: Autoria Própria, 2021.

Para o segundo teste de validação a rede alcançou uma acurácia de 80%, de acordo com a literatura e por conta de seu baixo valor de amostras, é um excelente resultado. Na Tabela 2 podemos observar os resultados obtidos pela rede. Como nos dados de teste em questão eram todos saudáveis a rede não teve como identificar os dados com cardiopatias tendo zeros como resultado.


A Figura 32 apresenta a Matriz de confusão do segundo teste.

Tabela 2 – Resultados obtidos no 2º teste da RNA

	Precisão	Recall	Score
ECG Normal	80%	100%	88%
ECG Anormal	0	0	0
Acurácia	-	-	80%
Média simples	80%	100%	84%
Média ponderada	80%	100%	84%

Fonte: Autoria Própria, 2021.

Figura 32 – Matriz de confusão do 2º teste



Fonte: Autoria Própria, 2021.

A Tabela 3 mostra o comparativo entre a acurácia do primeiro teste e do segundo teste da Rede Neural Artificial Proposta.

Tabela 3 – Comparativo da acurácia entre o 1º teste e 2º teste da RNA

Teste	Acurácia (%)
Dados do PTB	97%
Dados de Sousa (2018)	80%

Fonte: Autoria Própria, 2021.

A partir desses resultados demonstrados pode-se constatar a validação da Rede Neural Artificial, bem como a arquitetura proposta, fazendo com que os objetivos de deste trabalho sejam cumpridos e com resultados satisfatórios.

5 CONCLUSÃO

Com o desenvolvimento de novas tecnologias e modernização dos processos a telemedicina tem ganhado um espaço significativo, na vida do profissional de saúde e dos pacientes. E com a pandemia do COVID-19, tornou-se essencial, já que, o isolamento social fez-se necessário.

Desta forma, o presente trabalho tem como contribuição uma Rede Neural Artificial capaz de auxiliar profissionais de saúde no diagnóstico de doenças cardíacas. Houve a validação do sistema proposto com o treinamento de uma RNA Convolucional. O treinamento da rede foi feito com dados fornecidos pelo PTB disponíveis na plataforma da *PhysioNet* e testado com dados de cinco amostras colhidos por Sousa 2018.

Foram feitos dois testes para validação, o primeiro com dados do PTB e o segundo as cinco amostras já citadas. Ambos os testes apresentaram bons resultados com acurácia de 97% e 80% respectivamente. Comprovando assim a eficiência do sistema.

Além do que foi proposto no trabalho em questão, existem outras maneiras de contribuir para melhoria deste trabalho, de forma que, o mesmo é capaz de se adequar em diversos fins. Assim sugere-se como trabalhos futuros:

- Uso de RNAS em outras arquiteturas para classificação de sinais biológicos;
- Detecção de doenças de outras parte do corpo humano a partir de biosinais.
- Criação de aplicativos confiáveis no auxílio de diagnósticos de doenças;
- Construção de um banco de dados pra treinamento da RNA.

REFERÊNCIAS

ARRAIS JUNIOR, Ernano. **Sistema de Análise de Sinal Cardíaco para Aplicação em Telecardiologia**. Tese de doutorado. Universidade Federal do Rio Grande do Norte. Rio Grande do Norte, 2016.

BOYLESTAD, Robert L. **Introdução à análise de circuitos** revisão técnica Benedito Donizete Bonatto. Tradução Daniel Vieira e Jorge Ritter. – 12. ed. – São Paulo: Pearson Prentice Hall, 2012.

BRONZINO, J.D. **The Biomedical Engineering HandBook**. CRC Press, 2000.

BUENO, Nina Maria. **Classificação Automática de Cardiopatias Baseada em Eletrocardiograma**. Dissertação de Mestrado. Universidade Federal de Uberlândia. São Paulo 2007.

CARVALHO, Antônio C.C.. SOUSA, José Marconi. **Cardiopatía Isquêmica**. Rev Bras Hipertens 8: 297-305. São Paulo. 2001.

CARVALHO, Hanna V. F. de. CARVALHO Eduardo C.. ARRUDA, Helder. IMPERATRIZ-FONSECA Vera. SOUZA Paulo. PESSIN Gustavo. **Deteção de Anomalias em Comportamento de Abelhas Utilizando Redes Neurais Recorrentes**. Instituto de Ciências Exatas e Naturais Universidade Federal do Pará (UFPA) – Belém, PA, Brasil.

DAL PRÁ, Bruno Rover. **Desenvolvimento de modelos de redes neurais para avaliação nutricional da Brachiaria Brizantha**. Tese de Doutorado, Programa de Pós-Graduação em tecnologia nuclear, Instituto de Pesquisas Energéticas Nucleares, São Paulo, 2020.

DALE, D. **Interpretação rápida do ECG**. Tradução de Ismar Chaves da Silveira. Publicações científicas, 2004.

Deep Learning Book. **Uma Breve História das Redes Neurais Artificiais**. 2021. Disponível em <<https://www.deeplearningbook.com.br/uma-breve-historia-das-redes-neurais-artificiais/>> Acesso em 12 de agosto de 2021.

FUCHS, Flavio Danni. **Prevenção Primária de Cardiopatía Isquêmica: medidas não medicamentosas e medicamentosas**. Uso Racional de Medicamentos: fundamentação em

condutas terapêuticas e nos macroprocessos da Assistência Farmacêutica. Brasília. 2016.

Guo, T., Dong, J., Li, H., Gao, Y. 2017. **Simple convolutional neural network on image classification** 2nd International Conference on Big Data Analysis (ICBDA), 2017.

HAYKIN, Sünon. **Redes neurais: princípios e prática I**. Simon Haykin; trad. Paulo Martins Engel. 2.ed. -Porto Alegre: BooknMan., 2001.

KENZIE. **Google Colab: o que é, como usar e quais são as vantagens?**. 2019. Disponível em: <<https://kenzie.com.br/blog/google-colab/>>. Acesso em 13 de novembro de 2021.

LENGYEL, L. **Eletrocardiografia Clínica**. São Paulo: Sarvier, 1974.

MACHINE LEARNING CRASH COURSE. **Classification: Precision and Recall**. 2021. Disponível em <<https://developers.google.com/machine-learning/crash-course/classification/precision-and-recall>> Acesso em 10 de novembro de 2021.

MEDEIROS, Tyrone Gabriel Costa. **Aquisição de eletrocardiograma de forma não invasiva em barras de fisioterapia**. Monografia (Graduação em Engenharia Elétrica) Universidade Federal Rural do Semi- Árido. Rio Grande do Norte, 2020.

MEDTRONIC. **Sobre Valvulopatia**. 2021. Disponível em <<https://www.medtronic.com/br-pt/your-health/conditions/heart-valve-disease.html>>. Acesso em 02 de setembro de 2021.

MORRIS, F.; EDHOUSE, J.; BRADY, W.; CAMM, J. **ABC of Clinical Electrocardiography**. London: BMJ Books, 2003.

MOURA, Gustavo Bennemann de. **Redes neurais recorrentes para a classificação de estruturas retóricas**. Maringá, 2018.

Organização Mundial da Saúde (OMS). **As 10 principais causas de morte**. Disponível em: <<https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death>>. Acesso em 01 de setembro de 2021.

PFIZER. **Os diferentes tipos de cardiopatias**. 2019. Disponível em <<https://www.pfizer.com.br/noticias/ultimas-noticias/os-diferentes-tipos-de-cardiopatia>> Acesso em 1 de outubro de 2021.

PHYSIONET. **The Research Resource for Complex Physiologic Signals**. 2021. Disponível em <<https://physionet.org/>> Acesso em 10 de novembro de 2021.

REDE D'OR SÃO LUIZ. **O que é cardiopatia?**. 2021. Disponível em <<https://www.rededorsaoluiz.com.br/doencas/cardiopatia>> Acesso em 01 de setembro de 2021.

REIS, Helder José Lima; GUIMARÃES, Hélio Penna; ZAZULA, Ana Denise; VASQUE, Ronaldo Gomes; LOPES, Renato Delascio (ed.). **ECG: manual prático de eletrocardiograma**. 2013.

ROSA, Izabel Cristina Ribeiro da. MATTA, Cláudia Eliane da. **Classificação de sinais eletrocardiográficos usando redes neurais artificiais**. Centro Universitário Salesiano de São Paulo. 2004.

SANTOS, Euclides Júnior. ALMEIDA, Victor Hugo Amaral. **Aplicação da rede neural artificial na identificação de padrões em eletrocardiograma**. Universidade Vale Do Rio Doce – UNIVALE. Faculdade De Ciências Tecnológicas - FATEC. Ciência Da Computação. Governador Valadares 2011

SANTOS. C. N. dos, GATTI, M. **Deep Convolutional Neural Networks for Sentiment Analysis of Short Texts**. In Proceedings os 25th International Conference on Computational Linguistics COLING, Dublin, Ireland, 2014.

SBC (SOCIEDADE BRASILEIRA DE CARDIOLOGIA). **III Diretrizes da Sociedade Brasileira de Cardiologia Sobre Análise e Emissão de Laudos Eletrocardiográficos**. Rio de Janeiro: SBC - Tecnologia da Informação e Comunicação, 2016

SBC (SOCIEDADE BRASILEIRA DE CARDIOLOGIA). **Diretriz de Telecardiologia no Cuidado de Pacientes com Síndrome Coronariana Aguda e Outras Doenças Cardíacas**. Rio de Janeiro: SBC - Tecnologia da Informação e Comunicação. 2015.

SILVA, I. N. Da; SPATTI, D.; FLAUSINO, R. A. **Redes Neurais artificiais: Para engenharia e ciências aplicadas**. São Paulo: Artliber Editora Ltda, 2010

SILVA, Ivan Nunes da. SAPATTI, Danilo Hernane. FLAUSINO, Rogério Andrade. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.

SILVA, Marília Paula e. **Aplicação de Redes Neurais Artificiais no Diagnóstico de Falhas de Turbinas a Gás**. Rio de Janeiro: PUC, Departamento de Engenharia Mecânica, 2010.

Sociedade Brasileira de Cardiologia (SBC). **Reduzir os Óbitos por Doenças Cardiovasculares é o Maior Desafio da Cardiologia**. Disponível em: <<https://www.portal.cardiol.br/post/reduziros>>. Acesso em 01 de setembro de 2021.

SOCIEDADE BRASILEIRA DE CARDIOLOGIA (SBC). **II Diretriz de Cardiopatia Grave**. Rio de Janeiro: SBC - Tecnologia da Informação e Comunicação. 2006.

SOUSA, Letícia Ainoan Nunes. **Aquisição e Processamento do Eletrocardiograma para Auxílio ao Diagnóstico De Arritmias Cardíacas**. Monografia. Universidade Federal Rural do Semi- Árido. Rio Grande do Norte, 2018.

TOMAZATI, Alexandre Oliveira. **Detecção do complexo QRS em sinais cardíacos utilizando FPGA**. Dissertação de mestrado. Universidade Estadual de Campinas, Campinas – SP, Brasil. 2010.

VARGAS, Ana Caroline Gomes. CARVALHO, Aline Marins Paes. VASCONCELOS, e Cristina Nader. **Um estudo sobre Redes Neurais Convolucionais e sua aplicação em detecção de pedestres**. Instituto de Computação. Universidade Federal Fluminense. Niterói, Brasil. 2016.

Y. LeCun, Y.Bengio and G. Hilton. **Deep Learning**. *Nature*, 2015.

Y.L.A. LIU, E.E.N. MACAU, J.J. BARROSO, J.D.S. SILVA. R.L.A. VIANA. **Uso de Rede Neural Perceptron Multi-Camadas na Classificação de Patologias Cardíacas**. Sociedade Brasileira de Matemática Aplicada e Computacional. 2008.

APÊNDICE

A – Código da RNA Convolutacional

```
#Importando as bibliotecas
import numpy as np
import pandas as pd
from sklearn.preprocessing import StandardScaler
import warnings
import matplotlib.pyplot as plt
import cv2
warnings.filterwarnings('ignore') #Para sumir com os avisos

#importando dados de treinamento e de teste
ptb_abnormal = pd.read_csv('/content/drive/MyDrive/TCC/ptbdb_abnormal.csv',
    header=None)
ptb_normal = pd.read_csv('/content/drive/MyDrive/TCC/ptbdb_normal.csv', header=None)
ecg_teste = pd.read_csv('/content/drive/MyDrive/TCC/ECG_test.csv', header=None)

#Observando quantas classes existem no banco de dados
ptb_abnormal.rename(columns={187:"Class"}, inplace=True)
ptb_normal.rename(columns={187:"Class"}, inplace=True)

print ("\nPTB Abnormal classes: \n", ptb_abnormal["Class"].value_counts())
print ("\nPTB Normal classes: \n", ptb_normal["Class"].value_counts())

# Definição de dicionário para definir o tipo de pulsação para ambos os conjuntos de dados
PTB_Outcome = {0. : 'Normal',
                1. : 'Abnormal'}

#Plotando 10 amostras aleatórias do conjunto de dados de treinamento PTB com sua classificação

plt.figure(figsize=(25,10))
rnd = np.random.randint(0,ptb_normal.shape[0],size=(5,))
rnd1 = np.random.randint(0,ptb_abnormal.shape[0], size=(5,))
```

```

for i in range(np_time.shape[0]):
    ax = plt.subplot(2,5,i+1)
    if (i < 5):
        ax.plot(ptb_normal.iloc[rnd[i],np_time[i,:]])
        ax.set_title(PTB_Outcome[ptb_normal.loc[rnd[i],'Class']])
    else:
        ax.plot(ptb_abnormal.iloc[rnd1[i-5],np_time[i,:]])
        ax.set_title(PTB_Outcome[ptb_abnormal.loc[rnd1[i-5],'Class']])

plt.show()

# Análise de Aprendizado Profundo
# Importando as bibliotecas necessárias
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import normalize
from sklearn.metrics import classification_report, plot_confusion_matrix,
confusion_matrix

import tensorflow as tf
import tensorflow_addons as tfa
from tensorflow import keras
from tensorflow.keras.layers import Dense, Conv1D, MaxPool1D, Flatten,
Dropout, InputLayer, LSTM, GRU, BatchNormalization, Bidirectional,
Concatenate
from tensorflow.keras.models import Model
from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint
from tensorflow.keras.preprocessing import sequence
from tensorflow.keras.optimizers import SGD, RMSprop
from tensorflow.keras.utils import to_categorical

# Preparar os conjuntos de treinamento, validação e teste para o conjunto de
dados PTB e ECC colhidos.
ptb_full = pd.concat([ptb_normal, ptb_abnormal], axis=0).reset_index()
ptb_full.drop(columns='index', inplace=True)
ptb_full = ptb_full.sample(ptb_full.shape[0], random_state=42)
train_ptb, test_ptb, out_train_ptb, out_test_ptb =
train_test_split(ptb_full.iloc[:, :187], ptb_full.iloc[:, -1], test_size=0.15,
random_state=42)
train_ptb, valid_ptb, out_train_ptb, out_valid_ptb =
train_test_split(train_ptb, out_train_ptb, test_size=0.2, random_state=42 )

```

```

# Calculando o peso da classe
# Crie um dicionário de cada peso de classe para alimentar o modelo, uma #
vez que os dados são desequilibrados

normal, abnormal = np.bincount(ptb_full.loc[:, 'Class'])
norm_weight = (1/normal) * ((normal+abnormal)/2)
abnorm_weight = (1/abnormal) * ((normal+abnormal)/2)
class_weight = {0: norm_weight, 1: abnorm_weight}
print("Tamanho do conjunto de dados de treinamento: ", train_ptb.shape)
print("Tamanho do conjunto de dados de validação: ", valid_ptb.shape)
print("Tamanho do conjunto de dados de teste: ", test_ptb.shape)

#Normalizar os dados de treinamento, validação e teste
train_ptb = normalize(train_ptb, axis=0, norm='max')
valid_ptb = normalize(valid_ptb, axis=0, norm='max')
ecg_test = normalize(ecg_test, axis=0, norm='max')

# Remodelar o dataframe em uma matriz Numpy 3-D (lote, período de tempo,
valor)
x_train_ptb = train_ptb.reshape(len(train_ptb), train_ptb.shape[1], 1)
x_valid_ptb = valid_ptb.reshape(len(valid_ptb), valid_ptb.shape[1], 1)
x_ecg_test = ecg_test.reshape(len(ecg_test), ecg_test.shape[1], 1)

# Converter a saída em uma matriz categórica
y_train_ptb = to_categorical(out_train_ptb)
y_valid_ptb = to_categorical(out_valid_ptb)
y_ecg_test = to_categorical(out_ecg_test)

print("Tamanho do conjunto de dados de treinamento: ", x_train_ptb.shape , "
-- Y size: ", y_train_ptb.shape)
print("Tamanho do conjunto de dados de validação: ", x_valid_ptb.shape , " -
- Y size: ", y_valid_ptb.shape)
print("Tamanho do conjunto de dados de teste: ", x_ecg_test.shape , " -- Y
size: ", y_ecg_test.shape)

tf.keras.backend.clear_session()

# Função para construir redes convolucionais 1D
def build_conv1d_model (input_shape=(x_train_ptb.shape[1],1)):
    model = keras.models.Sequential()

```

```

model.add(Conv1D(32,7, padding='same', input_shape=input_shape))
model.add(BatchNormalization())
model.add(tf.keras.layers.ReLU())
model.add(MaxPool1D(5,padding='same'))

model.add(Conv1D(64,7, padding='same'))
model.add(BatchNormalization())
model.add(tf.keras.layers.ReLU())
model.add(MaxPool1D(5,padding='same'))

model.add(Conv1D(128,7, padding='same', input_shape=input_shape))
model.add(BatchNormalization())
model.add(tf.keras.layers.ReLU())
model.add(MaxPool1D(5,padding='same'))
model.add(Conv1D(256,7, padding='same'))
model.add(BatchNormalization())
model.add(tf.keras.layers.ReLU())
model.add(MaxPool1D(5,padding='same'))
model.add(Flatten())
model.add(Dense(512, activation='relu'))
model.add(Dropout(0.5))
model.add(Dense(256, activation='relu'))
model.add(Dropout(0.5))
model.add(Dense(128, activation='relu'))
model.add(Dense(64, activation='relu'))
model.add(Dense(32, activation='relu'))
model.add(Dense(2, activation="softmax"))
model.compile(optimizer="adam", loss="categorical_crossentropy",
metrics=[tfa.metrics.F1Score(2,"micro")])
return model

checkpoint_cb = ModelCheckpoint("conv1d_ptb.h5", save_best_only=True)

earlystop_cb = EarlyStopping(patience=5, restore_best_weights=True)

model_conv1d_ptb= build_conv1d_model(input_shape=(x_train_ptb.shape[1],
x_train_ptb.shape[2]))

```

```

model_convld_ptb.summary()

history_convld_ptb = model_convld_ptb.fit(x_train_ptb, y_train_ptb,
epochs=40, batch_size=32,
class_weight=class_weight,
validation_data=(x_valid_ptb, y_valid_ptb),
callbacks=[checkpoint_cb,
earlystop_cb])

model_convld_ptb.load_weights("convld_ptb.h5")
model_convld_ptb.evaluate(x_ecg_test,y_ecg_test)

# Calculando as previsões com base na classe de probabilidade mais alta

convld_pred_proba_ptb = model_convld_ptb.predict (x_ecg_test)
convld_pred_ptb = np.argmax(convld_pred_proba_ptb, axis=1)

print(classification_report(out_ecg_test, convld_pred_ptb > 0.5,
target_names=[PTB_Outcome[i] for i in PTB_Outcome]))

#matrix de confusão

cm = confusion_matrix(y_true= out_ecg_test, y_pred=convld_pred_ptb,
labels=list(PTB_Outcome.keys()))
plt.figure(figsize=(8,6))
plt.imshow(cm, cmap="Oranges")
plt.colorbar()
plt.xticks(list(PTB_Outcome.keys()),[PTB_Outcome[i] for i in PTB_Outcome],
rotation=90)
plt.yticks(list(PTB_Outcome.keys()),[PTB_Outcome[i] for i in PTB_Outcome])
plt.show()

#Traçando os resultados de treinamento e validação
plt.figure(figsize=(25,12))
plt.plot(history_convld_ptb.epoch, history_convld_ptb.history['loss'],
color='r', label='Train loss')
plt.plot(history_convld_ptb.epoch, history_convld_ptb.history['val_loss'],
color='b', label='Val loss' , linestyle="--")
plt.xlabel('Epoch')
plt.ylabel('Loss')
plt.plot(history_convld_ptb.epoch, history_convld_ptb.history['f1_score'],

```

```
        color='g', label='Train F1')
plt.plot(history_conv1d_ptb.epoch,
history_conv1d_ptb.history['val_f1_score'],
        color='c', label='Val F1' , linestyle="--")
plt.xlabel('Epoch')
plt.ylabel('Loss')
plt.legend()
plt.show()
```