

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO ACADÊMICO DE ELÉTRICA
CURSO DE ENGENHARIA DE CONTROLE E AUTOMAÇÃO

VINÍCIUS SUTERIO

**DETECÇÃO DE CARDIOPATIAS POR ELETROCARDIOGRAMA
UTILIZANDO REDES NEURAS ARTIFICIAIS**

TRABALHO DE CONCLUSÃO DE CURSO

CORNÉLIO PROCÓPIO

2017

VINÍCIUS SUTERIO

**DETECÇÃO DE CARDIOPATIAS POR ELETROCARDIOGRAMA
UTILIZANDO REDES NEURAS ARTIFICIAIS**

Trabalho de conclusão de curso apresentado ao Curso Superior de Engenharia de Controle e Automação da Universidade Tecnológica Federal do Paraná como requisito para obtenção do título de Engenheiro de Controle e Automação.

Orientador: Prof. Dr. Cristiano Marcos Agulhari

Co-orientador: Prof. Dr. Danilo Hernane Spatti

CORNÉLIO PROCÓPIO

2017



Universidade Tecnológica Federal do Paraná
Campus Cornélio Procópio
Departamento Acadêmico de Elétrica
Curso de Engenharia de Controle e Automação



FOLHA DE APROVAÇÃO

Vinicius Suterio

Deteção de cardiopatias por eletrocardiograma utilizando redes neurais artificiais

Trabalho de conclusão de curso apresentado às 17:30hs do dia 06/06/2017 como requisito parcial para a obtenção do título de Engenheiro de Controle e Automação no programa de Graduação em Engenharia de Controle e Automação da Universidade Tecnológica Federal do Paraná. O candidato foi arguido pela Banca Avaliadora composta pelos professores abaixo assinados. Após deliberação, a Banca Avaliadora considerou o trabalho aprovado.

Prof(a). Dr(a). Cristiano Marcos Agulhari - Presidente (Orientador)

Prof(a). Dr(a). Danilo Hernane Spatti - (Coorientador)

Prof(a). Dr(a). Bruno Catarino Bispo - (Membro)

Prof(a). Dr(a). Vander Teixeira Prado - (Membro)

AGRADECIMENTOS

Primeiramente gostaria de agradecer a Deus por mais uma etapa concluída em minha vida! Apenas eu e Ele sabemos a árdua batalha travada até então para que um dos meus maiores sonhos fosse realizado. Meu maior amigo e confidente de todos os dias.

Para essa realização, deixo meu singelo agradecimento aos meus pais Flávio e Nilza, os quais me apoiaram do começo ao fim de forma irrefutável. A maior fortaleza da minha vida! Assim como meus pais me dizem todos os dias: - Pode contar com a gente pra tudo! Eu pude sentir a presença de ambos, nos momentos em que me encontrei mais vulnerável, apesar da distância.

Não posso esquecer de forma alguma dos meus padrinhos Jorge e Solange, os quais me ajudaram e muito para que eu pudesse me manter em outro estado e continuar meus estudos. Estiveram sempre na torcida e vibrando a cada vitória/conquista.

Agradeço a minha amiga, companheira e namorada Larissa por me acompanhar nessa reta final tendo extrema paciência comigo e me ajudando em partes cruciais para a realização deste projeto, como correções e emprestando seu computador para compilar meus algoritmos.

Agradeço a Universidade Tecnológica Federal do Paraná campus Cornélio Procopio (UTFPR-CP), a qual tive o prazer de passar 5 anos da minha vida me dedicando aos estudos e fazendo exatamente o que gosto de fazer! Agradeço também pela bolsa de TCC2 fornecida para a realização deste trabalho.

Dos amigos que pude fazer no decorrer dessa jornada, com certeza levarei todos para o resto de minha vida. Prefiro não citar nomes para que não ocorra o eventual equívoco de esquecer algum! Porém em especial agradeço ao Marcelo e ao Guilherme que moraram comigo praticamente do começo ao fim. Posso dizer com todas as letras que são minha segunda família! Aguentaram minhas lamúrias, surtos e encheção de saco. Contudo, não podemos deixar de lado os momentos inesquecíveis e únicos que passamos juntos. Ficará "cravado" em minha memória para sempre.

Agradeço imensamente ao meu orientador e amigo Prof. Dr. Cristiano M. Agulhari "Quem sabe convolui ao vivo" e posso afirmar que esse convolui mesmo! Essa pessoa, que

não existe adjetivos para qualificar, me ensinou muitas coisas, das quais ultrapassam a barreira do conhecimento profissional. Tive o privilégio e o prazer de tê-lo como professor durante 5 semestres na minha graduação. Metade da graduação perturbando sua paciência e tendo que ter muita também para enfrentar a "fila da merenda" e ser atendido em sua sala. Espero poder trabalharmos juntos durante bons anos!

Agradeço também ao meu coorientador e amigo Prof. Dr. Danilo H. Spatti. Pessoa fantástica, extremamente dedicado e empenhado com seu trabalho. Infelizmente só pude conhecê-lo praticamente no término da minha graduação, 8º semestre, mas ainda espero poder trocar muitas "figurinhas" de conhecimento no decorrer de minha jornada. Posso afirmar que nesse TCC pude descobrir quantos dados são "xiblentos".

Agradeço ao Centro Integrado de Pesquisa em Controle e Automação (CIPECA), o qual contém diversos laboratórios de pesquisa, dentre eles o qual sou membro. Laboratório de Processamento de Sinais e Aplicações (LPSA). Agradeço ao professor responsável pelo laboratório Prof. Dr. Paulo R. Scalassara, o qual permitiu meu ingresso no laboratório. Agradeço a galera que esteve junto comigo, partilhando de momentos únicos dentro do "lab". Muitas risadas, muito trabalho e muita chorumela também.

Agradeço ao Prof. Dr. Alessandro Goedel, responsável pelo Laboratório de Sistemas Inteligentes (LSI - CIPECA), por ter disponibilizado os *clusters*, permitindo que meus algoritmos fossem compilados dentro dos prazos. Agradeço também a galera do laboratório, pois foram muito atenciosos e me receberam muito bem.

Agradeço à banca de TCC composta pelos professores Dr. Bruno C. Bispo e Dr. Vander T. Prado, os quais fizeram observações de extrema relevância para que o trabalho pudesse sair da melhor forma possível.

Por fim, agradeço à todos os professores, técnicos administrativos e as tias da limpeza que contribuíram com meu crescimento profissional e pessoal.

RESUMO

SUTERIO, Vinícius. DETECÇÃO DE CARDIOPATIAS POR ELETROCARDIOGRAMA UTILIZANDO REDES NEURAS ARTIFICIAIS. 34 f. Trabalho de conclusão de curso – Departamento acadêmico de Elétrica , Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2017.

Este projeto consiste em propor um auxílio para o profissional da saúde, visando facilitar a interpretação do eletrocardiograma (ECG) do paciente para a detecção de arritmias entre ECGs de pacientes saudáveis e com cardiopatia. O projeto utiliza *wavelet packet* para a extração de características dos ECGs e os dados obtidos são apresentados para uma rede neural artificial, *perceptron* multicamadas, automatizada. O projeto forneceu resultados satisfatórios com baixo grau de incerteza.

Palavras-chave: *wavelet packet*, redes neurais artificiais, extração de características, eletrocardiogramas, cardiopatias.

ABSTRACT

SUTERIO, Vinícius. DETECTION OF CARDIOPATHIES BY ELETROCARDIOGRAM USING NEURAL NETWORK. 34 f. Trabalho de conclusão de curso – Departamento acadêmico de Elétrica , Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2017.

This Project consists in proposing a process aiding health's professional, aimed to facilitate the interpretation of patient's eletrocardiograms for detection of arrhythmia between ECG's patient healthy and with cardiopathy. The project uses wavelet packet to feature extraction of ECGs and the obtained data are presented to a neural network, multilayer perceptron, automated. The project provided results satisfactory with a low degree of uncertainty.

Keywords: wavelet packet, neural networks, feature extraction, eletrocardiograms, cardiopathies.

LISTA DE FIGURAS

FIGURA 1	– Dez principais causas de morte no mundo	10
FIGURA 2	– Comparação das mortes entre o ano 2000 e 2012	11
FIGURA 3	– Dez principais causas de morte no mundo em porcentagem	11
FIGURA 4	– Arquitetura da rede neural <i>perceptron</i> multicamadas	18
FIGURA 5	– Fluxograma do desenvolvimento do projeto	20
FIGURA 6	– Exemplos ECG saudável e com arritmia.	21
FIGURA 7	– Exemplo de janelamento para ECGs saudáveis e com arritmia	22
FIGURA 8	– Configuração de uma RNA com 5 neurônios na camada escondida	24
FIGURA 9	– <i>Daubechies</i> 3 nível 4 conjunto total de amostras	26
FIGURA 10	– <i>Daubechies</i> 3 nível 4 conjunto parcial de amostras	27
FIGURA 11	– Matriz de confusão do vetor de saída - <i>Daubechies</i> 3 nível 4	28
FIGURA 12	– Eletrocardiógrafo modelo ECGV6 - HW	32

LISTA DE TABELAS

TABELA 1	– Dados fornecidos pelo MIT	21
TABELA 2	– Dados obtidos pelo janelamento	22
TABELA 3	– Famílias <i>wavelet packet</i>	23
TABELA 4	– Conjunto de ECGs no domínio do tempo	23
TABELA 5	– Conjunto de ECGs <i>wavelet packet</i> para o nível 3	24
TABELA 6	– Conjunto de ECGs <i>wavelet packet</i> para o nível 4	24
TABELA 7	– Matriz para implementação nas RNAs	25
TABELA 8	– Combinação dos parâmetros para a RNA automatizada	25
TABELA 9	– Resultados obtidos para família <i>wavelet packet</i> de nível 3	29
TABELA 10	– Resultados obtidos para família <i>wavelet packet</i> de nível 4	30

SUMÁRIO

1	INTRODUÇÃO	10
1.1	JUSTIFICATIVA	12
1.2	OBJETIVOS GERAIS	12
1.3	OBJETIVOS ESPECÍFICOS	13
2	FUNDAMENTAÇÃO TEÓRICA	14
2.1	EXTRAÇÃO DE CARACTERÍSTICAS	14
2.2	RECONHECIMENTO DE PADRÕES E SEUS TIPOS	15
2.3	INTRODUÇÃO ÀS REDES NEURAIS	16
2.4	REDES NEURAIS ARTIFICIAIS - APLICAÇÕES	17
2.4.1	<i>PERCEPTRON</i> MULTICAMADAS	18
3	MATERIAIS E MÉTODOS	19
3.1	DADOS UTILIZADOS PARA O DESENVOLVIMENTO DO PROJETO	19
3.2	MATLAB®	19
3.3	DESENVOLVIMENTO	20
3.3.1	BANCO DE DADOS - MIT	20
3.3.1.1	Reamostragem e janelamento	21
3.3.2	<i>Wavelet Packets</i>	22
3.3.3	Banco de dados final	23
3.4	DESENVOLVIMENTO DO ALGORITMO DA REDE NEURAL ARTIFICIAL	25
4	RESULTADOS E DISCUSSÕES	26
5	CONCLUSÕES	31
6	PROPOSTA DE CONTINUIDADE	32
6.1	CLASSIFICAÇÃO DAS CARDIOPATIAS	32
6.2	UTILIZAÇÃO DO ELETROCARDÍOGRAFO MODELO ECGV6 - HW	32
	REFERÊNCIAS	33

1 INTRODUÇÃO

Segundo o estudo realizado pela WHO (*World Health Organization*), efetuado no período de 2000 até 2012, a doença isquêmica cardíaca lidera a lista das dez principais causas de morte no mundo, atingindo 0,7 milhões de pessoas a mais do que o acidente vascular encefálico, segunda maior causa de morte no mundo, como pode ser visto na Figura 1 (ORGANIZATION, 2014).

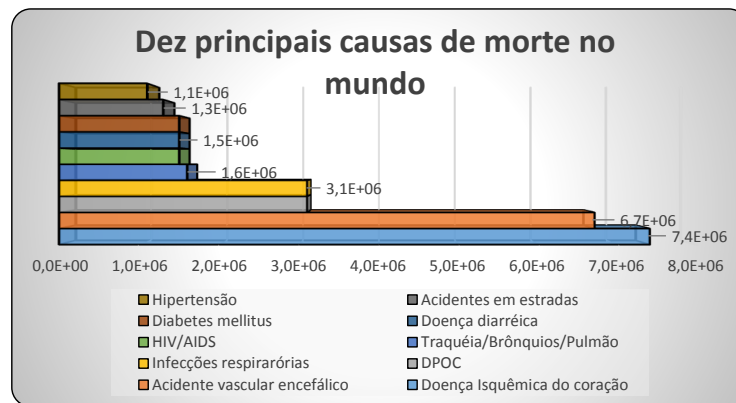


Figura 1: Dez principais causas de morte no mundo.
Fonte: Adaptado de (ORGANIZATION, 2014).

As doenças cardiovasculares mataram 17,5 milhões de pessoas, no mundo, em 2012. Sendo responsável por três em cada dez mortes. Do total das mortes em 2012, 7,4 milhões de pessoas morreram devido à doença isquêmica cardíaca, apresentado na Figura 2 (ORGANIZATION, 2014).



Figura 2: Comparação das mortes entre o ano 2000 e 2012.
Fonte: Adaptado de (ORGANIZATION, 2014).

No geral, aproximadamente 50% do total das mortes decorrem de cardiopatias, conforme Figura 3 (ORGANIZATION, 2014).




Figura 3: Dez principais causas de morte no mundo em porcentagem.
Fonte: Adaptado de (ORGANIZATION, 2014).

Apesar do avanço tecnológico no tratamento das cardiopatias, segundo informações da WHO, o número de casos de cardiopatias estão aumentando com o decorrer dos anos, havendo um acréscimo de 1,4 milhões em doze anos (ORGANIZATION, 2014).

Se a detecção desta patologia ocorrer nos estágios iniciais da doença, é possível remediar seus efeitos por meio de procedimentos mais simples e seguros ao paciente. Por outro lado, diagnósticos tardios podem ser problemáticos, exigindo tratamentos mais invasivos. Dessa forma, além das melhorias no tratamento das cardiopatias, é imprescindível que seu diagnóstico seja realizado de maneira mais rápida e eficiente. Normalmente, por senso comum, a prevenção

é efetuada por intermédio de exames *check up* que a população faz anualmente, o que pode causar demoras na detecção de cardiopatias. Este tempo pode variar dependendo se o paciente efetuou seus exames na rede pública ou privada de saúde.

1.1 JUSTIFICATIVA

Frente à exposição dos dados apresentados, pode-se afirmar que a prevenção e diagnósticos de cardiopatias são essenciais para melhorar o atual quadro mundial (ORGANIZATION, 2014). O processamento de sinais de eletrocardiogramas (ECGs) tem sido uma linha de pesquisa forte nas últimas décadas, como apresentado em (MONTEIRO; FARIAS, 1985), (HUALLPA et al., 1992), (SOUZA et al., 2006), (MELO et al., 2017), e um dos fatores que possibilitaram o fortalecimento de pesquisas nessa área foi a criação do banco de dados do MIT (*Massachusetts Institute of Technology*) no ano de 2001, o qual é composto por ECGs coletados em diversas situações e separados em várias categorias, que servem também como base de estudo (GOLDBERGER et al., 2000).

Esta monografia consiste em propor um processo de auxílio para o profissional da saúde, visando facilitar a interpretação do quadro do paciente para uma possível detecção de patologias. O projeto, intitulado "detecção de cardiopatias por eletrocardiograma utilizando redes neurais artificiais", fornece a obtenção de resultados com baixo grau de incerteza e consiste em analisar um dado sinal de eletrocardiograma, a fim de detectar se o paciente pode possuir ou não alguma cardiopatia. Para o presente projeto o escopo foi delimitado para a classificação de eletrocardiogramas entre saudáveis ou com arritmia.

O projeto foi dividido em duas etapas. Primeiramente efetuou-se os processos de extração de características dos ECGs e sua subsequente utilização para o desenvolvimento das redes neurais artificiais. Na sequência, realizou-se uma análise das vantagens obtidas pela extração de características e sua aplicação nas RNAs.

1.2 OBJETIVOS GERAIS

Implementação de um procedimento de detecção de padrões em sinais de eletrocardiograma, responsável por encontrar um determinado perfil de sinal, seguido da análise para identificar se há indícios de cardiopatia. Para facilitar o entendimento do trabalho, a partir

desta etapa, os ECGs de pacientes saudáveis serão abordados como dados saudáveis e os ECGs de pacientes com a patologia serão abordados como dados com arritmia.

1.3 OBJETIVOS ESPECÍFICOS

- Aquisitar dados saudáveis e com arritmia, do bando de dados - MIT;
- Pré-processamento dos dados;
- Aplicar e treinar as redes neurais artificiais (RNA) para classificar os ECGs em saudáveis e com arritmia;
- Analisar os resultados obtidos pelas RNAs.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão apresentadas as ferramentas computacionais utilizadas no projeto e a configuração da RNA.

2.1 EXTRAÇÃO DE CARACTERÍSTICAS

O processo de extração de características pode ser chamado de compressão, uma vez que o sinal obtido possui menos informações que o sinal original, porém conservam-se as características mais relevantes do sinal estudado (CROVATO, 2004).

Para a extração de características, será utilizada a ferramenta *wavelet* e os coeficientes serão obtidos pela sua decomposição usando as *wavelet packets*, que é uma generalização da decomposição *wavelet*. Os coeficientes da *wavelet packet* contém informações de energia dos sinais em cada banda de frequência, e isso é uma informação que auxilia na detecção dos padrões (MATHWORKS, 2017). As *wavelets* vêm sendo utilizadas em diversas aplicações, como na análise e compressão de sinais. Uma de suas principais características é que pode-se obter informações dos dados em função do tempo e da frequência. Os coeficientes obtidos por uma transformada *wavelet* de um dado sinal são os coeficientes de projeção do sinal na base formada pelas funções *wavelets* e por funções escala, que são ortogonais às funções *wavelet*. A escolha da função a ser utilizada depende da aplicação do sinal ou de propriedades que se desejam analisar. Especificamente no caso da aplicação direta das *wavelets*, é de extrema importância que a função *wavelet* utilizada seja adaptada ao sinal, pois com isso a energia do sinal estará concentrada em determinados coeficientes de representação, o que pode facilitar, por exemplo, a extração de certas características (AGULHARI, 2009).

Nas primeiras folhas de energias conservam-se as partes detentoras das altas frequências do sinal, e o sinal irá decompondo sua frequência a cada folha de energia. Maiores detalhes sobre *wavelet* e *wavelet packets* podem ser encontrados em (MALLAT, 2008).

2.2 RECONHECIMENTO DE PADRÕES E SEUS TIPOS

O reconhecimento de padrões é a ciência que atua no reconhecimento, descrição, classificação e agrupamento de padrões. Estes são problemas importantes em diversos ramos da engenharia e disciplinas científicas, como biologia, medicina, visão computacional, inteligência artificial, entre outras. Trata-se da classificação e descrição de objetos e consiste em extrair características, selecioná-las e gerar um classificador referente ao objeto de estudo (JAIN et al., 2000).

Como exemplo de padrões, podem-se citar a imagem de uma impressão digital, a escrita de forma cursiva, o rosto humano ou até mesmo um sinal de voz. Um teste de reconhecimento/classificação pode ser dividido em duas categorias: classificação supervisionada, em que o padrão a ser reconhecido é identificado como um membro de uma classe predefinida, e consiste na alocação dos dados em uma classe predefinida pelo projetista; e classificação não supervisionada (agrupamento), em que o padrão é atribuído a uma classe até então desconhecida, isto é, os dados formam grupos de similaridade dos padrões. Um sistema de reconhecimento de padrões envolve basicamente três aspectos: aquisição de dados e pré-processamento, a representação de dados e a tomada de decisão. As aplicações são inúmeras e em áreas distintas, incluindo mineração de dados, correlação ou identificação de um padrão distinto dentre milhões de padrões multidimensionais, classificação de documentos, previsão financeira, organização e recuperação de bases de dados multimídia e biometria, entre outros (JAIN et al., 2000).

Conforme o tipo de objeto a ser classificado, existem quatro tipos de abordagens para a execução de detecção de padrões (JAIN et al., 2000):

- Abordagem estatística: Os limites de decisão são estabelecidos por modelos probabilísticos, permitindo assim apenas distinguir de qual grupo o objeto estudado se enquadra;
- Abordagem sintática: descreve a estrutura de padrões usando inter-relações de características descritivas do objeto estudado. Além da classificação, esta abordagem também fornece uma descrição de como o modelo dado é construído a partir das primitivas;
- Abordagem neuronal: capacidade de aprender complexas relações não-lineares de entrada e saída. Sua principal característica é o reconhecimento de padrões de forma praticamente independente de conhecimento do domínio específico, uma vez que não há

necessidade de saber do que se tratam os dados e grupos estudados;

- Abordagem casamento de modelos: utilizado para determinar a similaridade entre duas entidades. A correspondência entre modelos é uma operação genérica dentro da classe de reconhecimento de padrões, cujo objeto a ser reconhecido é comparado com um modelo estabelecido levando em consideração todas as possíveis mudanças na qual o padrão pode sofrer.

Neste projeto será efetuada uma abordagem neuronal, isto é, apenas deseja-se executar a detecção de padrões para que os resultados possam ser estudados, o que seria uma abordagem do tipo caixa preta. Para isso, serão projetados e implementados classificadores baseados em redes neurais artificiais (RNAs).

2.3 INTRODUÇÃO ÀS REDES NEURAIIS

As RNAs são modelos computacionais inspirados no processo de aprendizagem do cérebro humano, emulando o seu funcionamento. Podem ser definidas por um conjunto de unidades de processamento, caracterizado por neurônios artificiais, interligados pelas sinapses artificiais que são representadas por vetores/matrizes de pesos sinápticos. É importante ressaltar que a capacidade de processamento das RNAs é consideravelmente inferior ao processamento do cérebro humano (SILVA et al., 2016) (KOVÁCS, 2002).

Cada vez mais as redes neurais artificiais vêm sendo aplicadas para a resolução de problemas complexos, principalmente quando se trabalha com extensas massas de dados que devem ser modeladas e analisadas. Os trabalhos a seguir podem ser citados como exemplos da aplicação de RNAs.

Seguindo a mesma linha de pesquisa deste trabalho pode-se citar (BUENO, 2006), onde a autora trabalha no reconhecimento e classificação de cardiopatias utilizando ECGs. O trabalho tem foco na extração de características do ECG por intermédio do modelo matemático auto-regressivo - (AR) e aplicação deles em uma rede neural artificial, identificando assim as cardiopatias.

Para a detecção específica de um tipo de cardiopatia utilizando técnicas de otimização pode-se citar (NETO, 2009). Neste trabalho, o autor apresenta técnicas de otimização por nu-

vem de partículas juntamente com a extração de características por intermédio de *wavelets*. Esses dados são aplicados em uma RNA para a detecção automática de arritmias cardíacas baseadas na análise de ECGs.

Uma outra linha de pesquisa, utilizando sinais de voz, também com a aplicação de *wavelets* e RNAs pode ser encontrado em (CROVATO, 2004). Neste trabalho, o autor apresenta um sistema de classificação de voz disfônica utilizando transformada *wavelet packet*, o algoritmo *Best Basis* (BBA) como redutor de dimensionalidade e RNAs.

Na área de controle de processos pode-se citar (MOURA, 2003). Neste projeto, a autora utiliza RNAs para simplificar a modelagem fenomenológica de uma coluna de destilação, sendo os dados obtidos por intermédio de um simulador.

Na área de qualidade de energia elétrica pode-se citar (POZZEBON, 2009). Neste trabalho o autor apresenta um método diferente para a classificação de distúrbios em sinais elétricos visando analisar a qualidade de energia elétrica. Para a extração de dados, utilizaram-se as transformadas *wavelet* e as classificações foram realizadas por meio de uma rede neural probabilística.

2.4 REDES NEURAIAS ARTIFICIAIS - APLICAÇÕES

Dentre as diversas aplicações das RNAs, para este projeto, sua implementação estará restrita às aplicações (SILVA et al., 2016):

- Aproximador universal de funções: consiste em mapear o relacionamento entre as variáveis de um sistema a partir de um conjunto conhecido de seus valores representativos;
- Reconhecimento/classificação de padrões: associar um padrão de entrada para uma das classes previamente definidas. Neste caso, problema a ser tratado possui um conjunto discreto e conhecido das diversas saídas desejadas;
- Agrupamento de dados (clusterização): identificação e detecção de similaridade e particularidades entre os diversos padrões de entrada, com o intuito de possibilitar um agrupamento;
- Otimização de sistemas: minimizar ou maximizar uma função, obedecendo também eventuais restrições.

Dos modelos existentes para a configuração das redes neurais, o que mais se destaca é o *perceptron*, devido à sua capacidade em reconhecer padrões (SILVA et al., 2016). Para o presente projeto, será utilizado o *perceptron* multicamadas (PMC), apresentado na Figura 4.

2.4.1 PERCEPTRON MULTICAMADAS

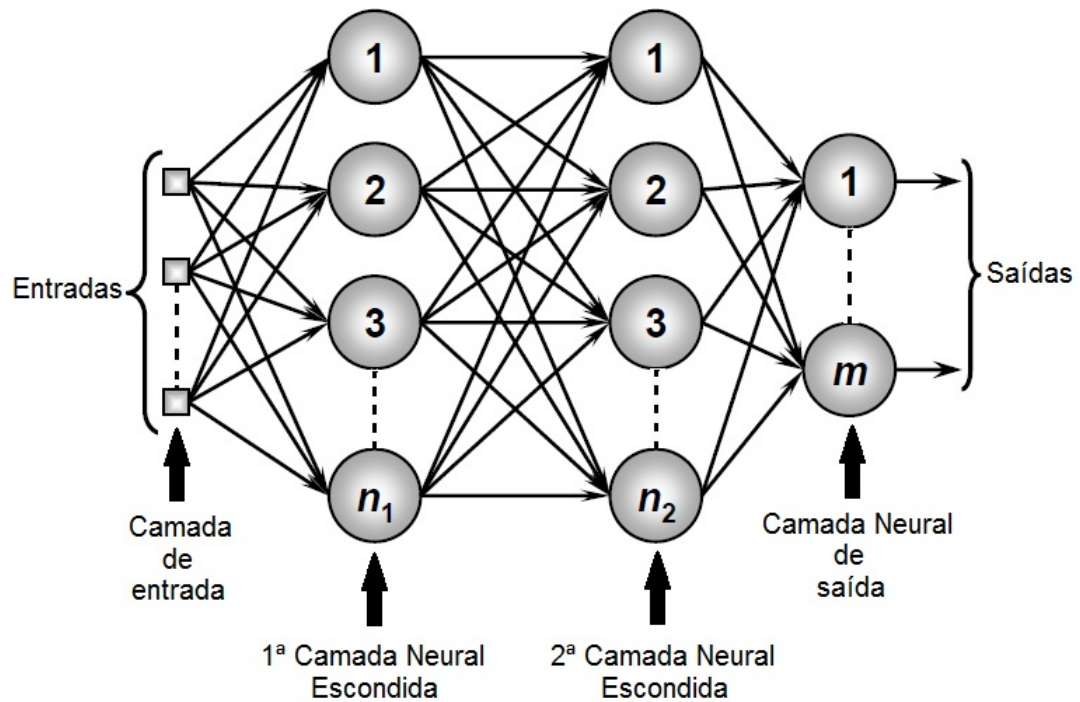


Figura 4: Arquitetura da rede neural *perceptron* multicamadas.
Fonte: Adaptado de (SILVA et al., 2016).

O PMC possui camadas múltiplas, isto é, caracterizado pela presença de pelo menos uma camada intermediária de neurônios, camada escondida para extração de características, situada entre a camada de entrada e a de saída. Esta diferença, quando comparada aos *perceptrons* de camada simples, torna sua configuração com uma maior capacidade de processamento. As redes PMC são também capazes de trabalhar com classes que não são linearmente separáveis e uma das suas principais vantagens é que uma vez pronta, não demanda tempo de processamento, apenas memória, o que a torna uma técnica melhor de implementação (SILVA et al., 2016). Maiores informações sobre RNAs podem ser encontradas em (SILVA et al., 2016) e (KOVÁCS, 2002).

3 MATERIAIS E MÉTODOS

Nesta seção serão apresentados os materiais e métodos a serem utilizados para o desenvolvimento deste trabalho.

3.1 DADOS UTILIZADOS PARA O DESENVOLVIMENTO DO PROJETO

Os dados utilizados para o projeto foram adquiridos por intermédio do banco de dados do MIT (*Massachusetts Institute of Technology*). Neste banco, podem-se encontrar dados de pessoas saudáveis e dados compostos por cardiopatias como arritmias, doenças isquêmicas do coração - infarto do miocárdio, entre outras. Assim, será possível fornecer sinais de ECG de pessoas saudáveis e com algumas cardiopatias, possibilitando o treinamento da rede para classificar dados saudáveis ou não. Vale ressaltar que cada sinal vem acompanhado de dados como o frequência de amostragem e duração total da coleta, que são importantes para o processamento (GOLDBERGER et al., 2000).

Para que o conjunto dos dados estudados fosse processado houve a necessidade de efetuar um pré-processamento. Tal processamento é chamado de normalização dos dados, e consiste em deixar os dados dentro do domínio da região dinâmica das funções de ativação, com o intuito de melhorar o desempenho do treinamento evitando a saturação na saída da RNA e problemas com o processamento dos dados. (SILVA et al., 2016) (KOVÁCS, 2002).

3.2 MATLAB®

A principal ferramenta computacional que será usada para a importação de dados, processamento e obtenção de resultados é o MATLAB® (*matrix laboratory*), que se trata de um *software* com grande capacidade de processamento aplicado diretamente no cálculo numérico. O MATLAB® é capaz de integrar análise numérica, cálculo com matrizes, processamento de sinais e construção gráfica de maneira fácil, tratando de problemas com soluções que podem ser expressas matematicamente. Para esse projeto, o MATLAB® torna-se uma ferramenta eficaz, uma vez que pode trabalhar com uma vasta massa de dados processando-os em frações de tempo. Além disso, os problemas são resolvidos com operações matemáticas elementares e

apresentadas quase que de forma idêntica, se escrita matematicamente.

3.3 DESENVOLVIMENTO

O fluxograma da Figura 5, apresenta a sequência do desenvolvimento do projeto. Cada uma das atividades apresentadas são explanadas nas seções a seguir.

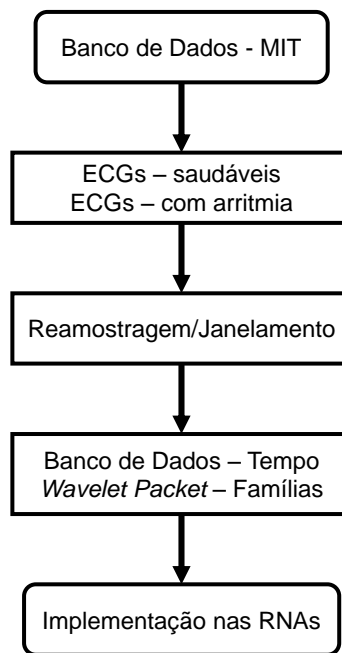


Figura 5: Fluxograma do desenvolvimento do projeto.
Fonte: Autoria própria.

3.3.1 BANCO DE DADOS - MIT

Neste projeto utilizaram-se ECGs do banco de dados de pessoas saudáveis, composto por 90 ECGs (*MIT-BIH Arrhythmia Database*), e com arritmia, composto por 48 ECGs (*The ECG-ID Database*) (GOLDBERGER et al., 2000). A Figura 6 são exemplos de ECGs saudáveis e com arritmia. Cada classe de sinal foi coletada utilizando diferentes taxas de amostragem. Assim, para um processamento adequado, é necessário analisar a frequência de amostragem de cada ECG e fazer procedimentos de reamostragem para uniformizar tal característica. É possível notar uma diferença visual entre os ECGs, porém a detecção e constatação da patologia no sinal não é trivial. A Tabela 1 apresenta o tempo de coleta e a frequência de amostragem para cada tipo de ECG.

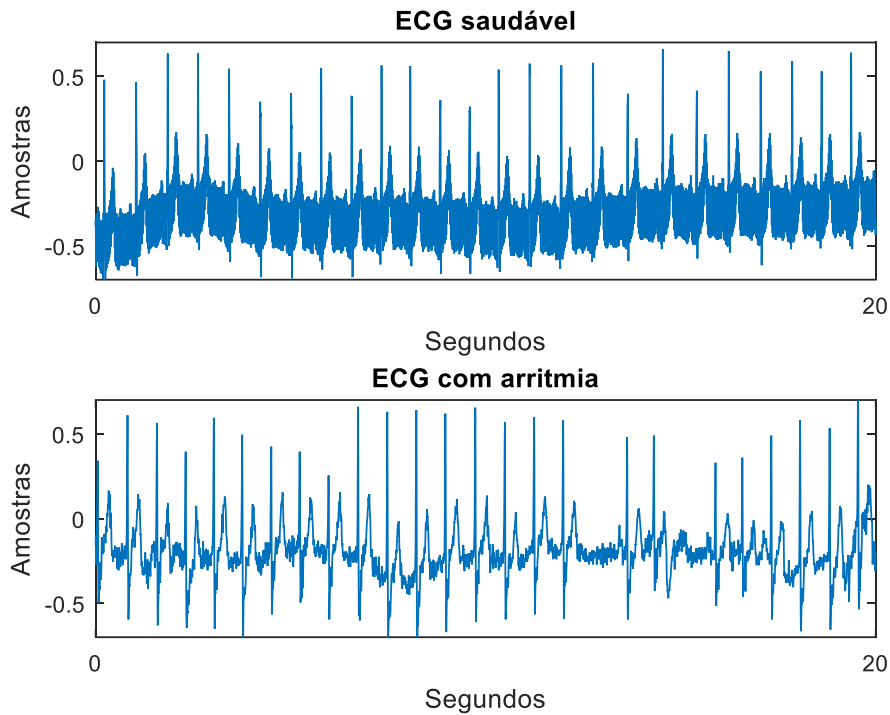


Figura 6: Exemplos ECG saudável e com arritmia.
Fonte: Autoria própria.

Tabela 1: Dados fornecidos pelo MIT

Tipo de ECG	Tempo de coleta [s]	Frequência de amostragem [amostras/s]
Saudável	20	360
Arritmia	1856	500

3.3.1.1 REAMOSTRAGEM E JANELAMENTO

Após a análise, pôde-se perceber que a frequência de amostragem dos ECGs são diferentes entre os bancos de dados considerados, o que pode ser um fator prejudicial para seu processamento e aplicações nas redes neurais. Com isso, houve a necessidade de reamostrar os ECGs com arritmia para 360 amostras/segundo. A reamostragem ocorreu respeitando a taxa de *Nyquist* (dobro da maior frequência) para não ocorrer *aliasing* - inconsistência de dados.

Efetuiu o janelamento dos ECGs com o intuito de obter uma análise mais criteriosa de tempo e frequência para cada porção do sinal (ANDRADE; SOARES, 2013). A Tabela 2 apresenta a quantidade de janelas e amostras obtidas para cada tipo de ECG. Utilizaram-se janelas de 1024 amostras, aproximadamente 3 segundos, para a montagem do banco de dados final, como mostra na Figura 7.

Tabela 2: Dados obtidos pelo janelamento

Tipo de ECG	Quantidade de janelas	Quantidade de amostras
Saudável	7	1024
Arritmia	634	

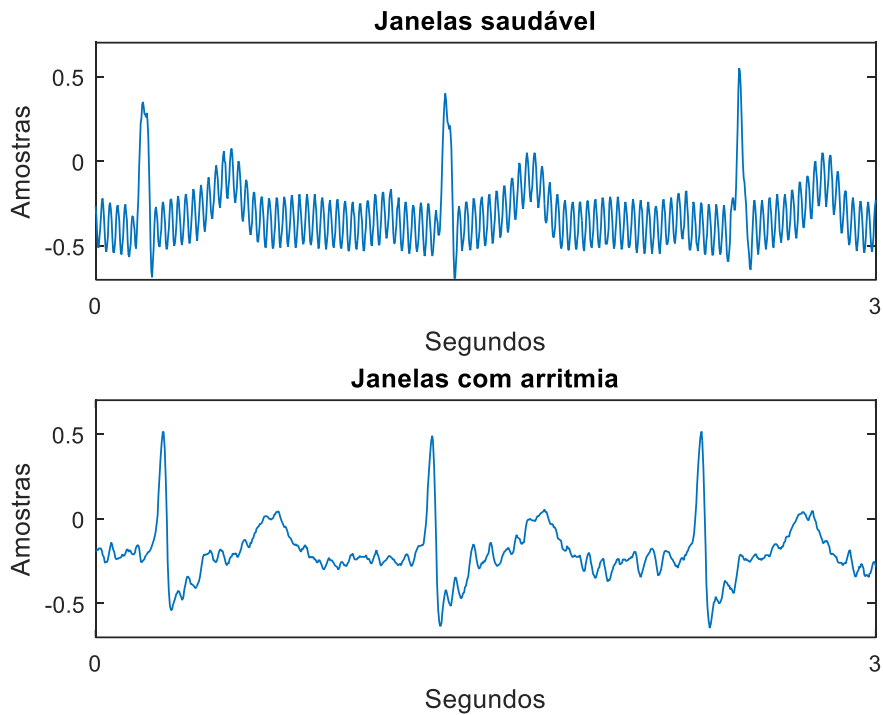


Figura 7: Exemplo de janelamento para ECGs saudáveis e com arritmia.
Fonte: Autoria própria.

3.3.2 WAVELET PACKETS

Para este projeto, os coeficientes obtidos da *wavelet packet* serão as entradas para a RNA. Foram escolhidos os níveis 3 e 4 de decomposição da árvore binária, resultando respectivamente em 8 e 16 folhas de energia. As famílias que foram escolhidas são apresentadas na Tabela 3.

Tabela 3: Famílias *wavelet packet*

Família <i>wavelet</i>	Ordem	Níveis
<i>Coiflets</i>	1 a 5	3 e 4
<i>Symlets</i>		
<i>Daubechies</i>	2 a 5	
<i>Haar</i>	-	

A família *Daubechies* foi escolhida por ser indicada como a melhor *wavelet* para comprimir sinais de ECG conforme (BESAR et al., 2000), uma vez que se utiliza para efetuar a extração de características. Em contra partida, foram escolhidas mais 3 famílias de diferentes ordens para efetuar uma comparação dentre as famílias e suas respectivas ordens.

3.3.3 BANCO DE DADOS FINAL

Criou-se o banco de dados no domínio do tempo e usando as folhas de energia (*wavelet packet*). A Tabela 4 apresenta a matriz no domínio do tempo que originou todas as famílias *wavelet packet*, a quantidade de janelas obtidas por cada ECG e a dimensão da matriz final, sendo a quantidade de janelas total pela quantidade de amostras.

As Tabelas 5 e 6 apresentam para cada família, com sua respectiva ordem, a quantidade de banco de dados juntamente com a dimensão final da matriz para cada um dos níveis. Sendo a quantidade de janelas total pela quantidade de folhas de energia.

O conjunto de arquivos de todas as famílias, juntamente com os dados no domínio do tempo que compõem o banco de dados, será guardado para que possa ser utilizado em futuras pesquisas, podendo ser executadas pelos demais membros do laboratório. Esse banco foi salvo na extensão '.mat', pois o MIT disponibiliza um *toolbox* para efetuar a leitura dos dados porém, esse *toolbox* depende de internet e do software JAVA atualizado. Sendo assim, uma vez salvo, não há necessidade de efetuar o *download* toda vez que se deseja analisar os ECGs.

Tabela 4: Conjunto de ECGs no domínio do tempo

Tipo de ECG	Quantidade de janelas	Dimensão da matriz
Saudável	630	31062x1024
Arritmia	30432	

Tabela 5: Conjunto de ECGs *wavelet packet* para o nível 3

<i>wavelet packet</i>	Quantidade de banco de dados gerados	Dimensão da matriz
<i>Coiflets</i>	5 banco de dados distintos	31062x8
<i>Symlets</i>	5 banco de dados distintos	
<i>Daubechies</i>	4 banco de dados distintos	
<i>Haar</i>	1 banco de dados	

Tabela 6: Conjunto de ECGs *wavelet packet* para o nível 4

<i>wavelet packet</i>	Quantidade de banco de dados gerados	Dimensão da matriz
<i>Coiflets</i>	5 banco de dados distintos	31062x16
<i>Symlets</i>	5 banco de dados distintos	
<i>Daubechies</i>	4 banco de dados distintos	
<i>Haar</i>	1 banco de dados	

O banco de dados final total foi composto por 30 bancos distintos obtidos de todas as famílias com suas respectivas ordens, sendo 15 bancos do nível 3 e os outros 15 do nível 4.

Os dados gerados foram aplicados em uma rede neural artificial - *perceptron* multicamadas, Figura 8, então nessa etapa, desenvolveu-se o algoritmo dessa rede com uma camada neural escondida. Utilização de 60% dos dados para treinamento e 40% para teste.




Figura 8: Configuração de uma RNA com 5 neurônios na camada escondida.
Fonte: Autoria Própria.

A RNA possui treinamento supervisionado, que consiste em apresentar à rede qual seria o resultado desejado. Assim, para cada janela de cada um dos ECGs foi acrescentada uma coluna que codifica a classificação do sinal, sendo 1 se o ECG for saudável e 0 se for um sinal com arritmia.

Tanto para o nível três como o quatro, de todas as famílias *wavelet packet*, gerou-se uma matriz composta pela concatenação das energias de cada uma das janelas obtidas acrescentando a coluna que codifica a classificação do sinal. Com isso, a matriz final obtida para cada um dos níveis apresenta as dimensões conforme a Tabela 7.

Tabela 7: Matriz para implementação nas RNAs

Nível	Dimensão da matriz final
3	31062x9
4	31062x17

3.4 DESENVOLVIMENTO DO ALGORITMO DA REDE NEURAL ARTIFICIAL

Desenvolveu-se um algoritmo automatizado para encontrar a melhor configuração da RNA para cada família, considerando todas as combinações dos parâmetros apresentados na Tabela 8.

Tabela 8: Combinação dos parâmetros para a RNA automatizada

-	Quantidade de neurônios	Erro	Taxa de aprendizagem
Mínimo e máximo	5 a 30	1.10^{-1} a 1.10^{-6}	0.1 a 0.5
Variação	5 em 5	1.10^{-1} em 1.10^{-1}	0.1 em 0.1

Após encontrar a melhor configuração de RNA para cada uma das famílias *wavelet packet*, efetuaram-se dez treinamentos para verificar a capacidade de generalização da rede e consequentemente obter o menor erro possível.

Como proposto anteriormente, efetuou-se uma comparação entre as famílias, encontrando assim, a melhor delas para a detecção de arritmias entre ECGs saudáveis e com a cardiopatia.

4 RESULTADOS E DISCUSSÕES

A melhor configuração obtida resultou em 99.9% de acertos, com 5 neurônios na camada escondida, erro 1.10^{-5} e taxa de aprendizagem de 0.1, utilizando a família *Daubechies 3*, com 4 níveis de decomposição.

As Figuras 9 e 10 mostram a quantidade de acertos e erros do conjunto total de amostras e do conjunto parcial de amostras respectivamente.




Figura 9: Classificação da resposta - RNA *Daubechies 3* nível 4 conjunto total de amostras.
Fonte: Autoria Própria.

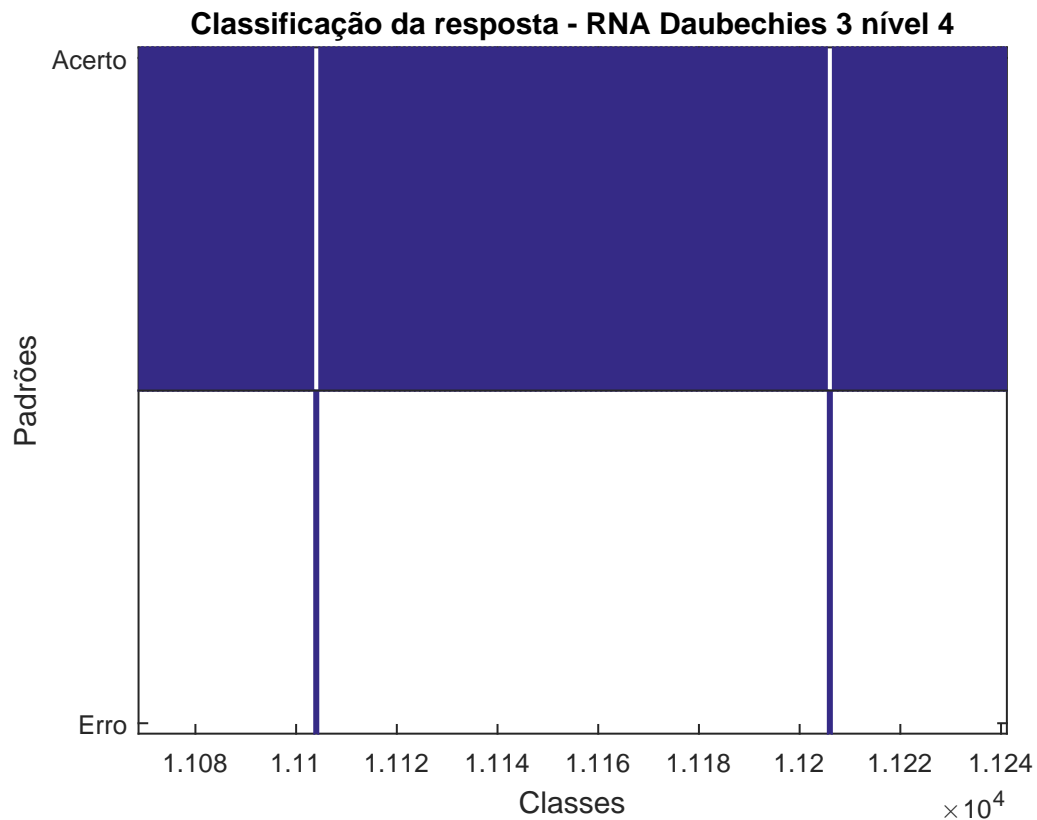


Figura 10: Classificação da resposta - RNA *Daubechies* 3 nível 4 conjunto parcial de amostras.
Fonte: Autoria Própria.

A seguir será apresentada a matriz de confusão, de dimensão 2x2, Figura 11, que foi obtida a partir da análise do vetor de saída fornecido pela rede neural artificial.

Na área da medicina, a tomada de decisão deve ser extremamente precisa e por isso, neste projeto, adotou-se uma margem de tolerância de 0.01. Com isso os dados estudados só podem ser considerados 1 apenas se forem maior ou igual à 0.99 e devem ser considerados 0 apenas se forem maior ou igual à 0.01. Então a margem de 0.01 à 0.99 é considerada como faixa de indeterminação, onde existem dados que deveriam ser 0 e foram considerados como 1 e dados que deveriam ser 1 e foram considerados como 0.

MATRIZ DE CONFUSÃO		
	0	1
0	12158	7
1	5	255

Figura 11: Matriz de confusão do vetor de saída da rede referente à *Daubechies 3* nível 4.
Fonte: Autoria Própria.

O elemento (1,1) da matriz, são os dados que deveriam ser 0 e foram considerados 0 pela RNA, o elemento (1,2) da matriz, são os dados deveriam ser 1 e foram considerados 0, o elemento (2,1) da matriz, são os dados que deveriam ser 0 e foram considerados 1 e por fim o elemento (2,2) da matriz, são os dados que deveriam ser 1 e foram considerados 1.

Quanto maior a quantidade de elementos classificados na diagonal principal da matriz de confusão, melhor é a resposta obtida. No projeto, significa que a RNA obteve grande êxito ao classificar os padrões entre 0 e 1. De todos os 12425 dados para testes, referente aos 40%, 12413 foram classificados corretamente.

As Tabelas 9 e 10 apresentam a quantidade de acertos, o menor erro, a quantidade de neurônios, o erro estipulado para a RNA e a taxa de aprendizagem para cada família *wavelet packet* nível 3 e nível 4 respectivamente. Sendo destacada a melhor família.

Tabela 9: Resultados obtidos para família *wavelet packet* de nível 3

Família <i>wavelet packet</i> nível 3	Acerto	Menor Erro	Neurônio	Erro	Taxa
dadosECoif1_3	99.0221%	370	5	1.10^{-4}	0.4
dadosECoif2_3	99.8390%	20	5	1.10^{-4}	0.4
dadosECoif3_3	98.6720%	165	5	1.10^{-6}	0.1
dadosECoif4_3	99.7746%	28	5	1.10^{-5}	0.2
dadosECoif5_3	99.8471%	19	5	1.10^{-4}	0.2
dadosESym1_3	93.9477%	752	15	1.10^{-5}	0.2
dadosESym2_3	99.2998%	87	5	1.10^{-3}	0.2
dadosESym3_3	97.3924%	324	5	1.10^{-5}	0.3
dadosESym4_3	97.3119%	334	5	1.10^{-6}	0.3
dadosESym5_3	98.3501%	205	5	1.10^{-6}	0.2
dadosEDB2_3	96.9980%	373	5	1.10^{-6}	0.3
dadosEDB3_3	95.8793%	512	5	1.10^{-4}	0.4
dadosEDB4_3	95.6781%	537	5	1.10^{-6}	0.3
dadosEDB5_3	97.8270%	270	5	1.10^{-4}	0.5
dadosEHaar_3	94.8008%	646	5	1.10^{-4}	0.1

Tabela 10: Resultados obtidos para família *wavelet packet* de nível 4

Família <i>wavelet packet</i> nível 4	Acerto	Menor Erro	Neurônio	Erro	Taxa
dadosECoif1_4	99.8390%	20	5	1.10^{-4}	0.1
dadosECoif2_4	98.4064%	198	10	1.10^{-5}	0.2
dadosECoif3_4	99.5091%	61	5	1.10^{-6}	0.1
dadosECoif4_4	99.3964%	75	5	1.10^{-4}	0.1
dadosECoif5_4	99.5976%	50	5	1.10^{-5}	0.1
dadosESym1_4	99.7666%	29	5	1.10^{-4}	0.5
dadosESym2_4	99.8712%	16	5	1.10^{-5}	0.5
dadosESym3_4	99.8149%	23	5	1.10^{-6}	0.5
dadosESym4_4	99.3400%	82	5	1.10^{-5}	0.2
dadosESym5_4	99.6217%	47	5	1.10^{-6}	0.4
dadosEDB2_4	99.8310%	21	5	1.10^{-6}	0.2
dadosEDB3_4	99.9034%	12	5	1.10^{-5}	0.1
dadosEDB4_4	99.6949%	38	5	1.10^{-4}	0.4
dadosEDB5_4	98.4628%	191	5	1.10^{-6}	0.2
dadosEHaar_4	98.4064%	198	15	1.10^{-4}	0.3

5 CONCLUSÕES

Neste trabalho, foi proposta uma técnica de auxílio para o profissional da saúde, visando facilitar a interpretação do eletrocardiograma do paciente para uma possível detecção de cardiopatias. O projeto, propôs uma técnica de detecção automática de cardiopatias a partir de sinais de eletrocardiogramas com o intuito de gerar resultados com baixo grau de incerteza.

Com isso, todo o embasamento teórico juntamente com os resultados expostos nas seções anteriores, pode-se dizer que para detectar ECGs saudáveis e com arritmia, a melhor *wavelet packet* para ser utilizada é da família *Daubechies*, mais especificamente *Daubechies 3* nível 4 - 16 folhas de energia. Com a configuração da rede neural composta por 5 neurônios na camada escondida, erro 1.10^{-5} e taxa de aprendizagem de 0.1. Resultando em 99.9% de acertos.

6 PROPOSTA DE CONTINUIDADE

6.1 CLASSIFICAÇÃO DAS CARDIOPATIAS

Para a classificação das cardiopatias, haverá o desenvolvimento de mais uma RNA, a qual será responsável pela classificação do tipo de cardiopatia detectada no paciente.

Então o processo dar-se-á da seguinte maneira, primeiramente haverá uma pré-classificação indicando se o sinal ECG estudado é saudável, esta classificação será desenvolvida pela primeira RNA. Após esta etapa, os ECGs com indícios de cardiopatias passarão pela segunda RNA, onde será efetuada uma análise para que possa ser avaliado qual o tipo de cardiopatia que o paciente possui, uma vez que o espectro do sinal do ECG comporta-se de diversas maneiras frente a cardiopatias distintas.

6.2 UTILIZAÇÃO DO ELETROCARDIÓGRAFO MODELO ECGV6 - HW

Como a RNA está fornecendo resultados satisfatórios, isto é, conseguiu distinguir dados saudáveis dos que contém cardiopatias, o projeto poderá ser aplicado em ECGs adquiridos pelo equipamento da instituição ECGV6 - HW, apresentado na Figura 12. Esse equipamento fornece sinais na extensão .dicom (*Digital Imaging and Communications in Medicine*) que é um conjunto de normas para tratamento, armazenamento e transmissão de informações médicas num formato eletrônico. Os dados nessa extensão podem ser facilmente importados para serem trabalhados no MATLAB.



Figura 12: Eletrocardiógrafo modelo ECGV6 - HW.
Fonte: <http://www.hw.ind.br/ecgv6/>.

REFERÊNCIAS

- AGULHARI, C. M. **Compressão de eletrocardiogramas usando wavelets**. [S.l.]: Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação, Área de Telemática e Telecomunicações., 2009.
- ANDRADE, A. O.; SOARES, A. B. **Técnicas de Janelamento de Sinais**. 2013. Access date: 15 abr. 2017. Disponível em: <<http://www.laps.ufpa.br/professores/valquiria/uploadsaves/ajax/1/file/2013-01-23-12:55:29.pdf>>.
- BESAR, R. et al. On the choice of the wavelets for ecg data compression. In: **2000 IEEE International Conference on Acoustics, Speech, and Signal Processing. Proceedings (Cat. No.00CH37100)**. [S.l.: s.n.], 2000. v. 6, p. 3614–3617 vol.6. ISSN 1520-6149.
- BUENO, N. M. **Classificação automática de cardiopatias baseada em eletrocardiograma**. [S.l.]: Universidade Federal de Uberlândia–Uberlândia, 2006.
- CROVATO, C. D. P. **Classificação de sinais de voz utilizando a transformada *wavelet packet* e redes neurais artificiais**. [S.l.]: Universidade Federal do Rio Grande do Sul, 2004.
- GOLDBERGER, A. L. et al. Physiobank, physiotoolkit, and physionet. **Circulation**, American Heart Association, Inc., v. 101, n. 23, p. e215–e220, 2000. ISSN 0009-7322. Disponível em: <<http://circ.ahajournals.org/content/101/23/e215>>.
- HUALLPA, B. N.; COSTA, E. T.; LOPES, A. **Obtenção e processamento de sinais de eletrocardiografia de alta resolução**. 1992. Access date: 07 jun. 2017. Disponível em: <<http://repositorio.unicamp.br/jspui/handle/REPOSIP/261371>>.
- JAIN, A. K.; DUIN, R. P. W.; MAO, J. Statistical pattern recognition: a review. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n. 1, p. 4–37, Jan 2000. ISSN 0162-8828.
- KOVÁCS, Z. L. **Redes neurais artificiais**. [S.l.]: Editora Livraria da Física, 2002.
- MALLAT, S. **A wavelet tour of signal processing: the sparse way**. [S.l.]: Academic press, 2008.
- MATHWORKS, W. P. **Wavelet Packets**. 2017. Access date: 03 mai. 2017. Disponível em: <<https://www.mathworks.com/help/wavelet/ug/wavelet-packets.html>>.
- MELO, S.; SILVA, H.; FONTES, A. **Redução de Ruídos no Sinal de ECG usando um filtro passa Alta**. 2017. Access date: 07 jun. 2017. Disponível em: <<https://periodicos.ufersa.edu.br/revistas/index.php/ecop/article/view/7079/6537>>.
- MONTEIRO, A. O.; FARIAS, M. A. C. **Monitor inteligente de arritmias cardíacas**. 1985. Access date: 07 jun. 2017. Disponível em: <<http://bibdigital.epn.edu.ec/handle/15000/9474>>.
- MOURA, L. G. **Modelagem empírica de colunas de destilação utilizando redes neurais de *wavelets* para otimização e controle de processos**. [S.l.]: Universidade Federal de Santa Catarina, 2003.

NETO, A. B. **Detecção automática de arritmia cardíaca utilizando *wavelets* e redes neurais treinadas com otimização por nuvem de partículas**. [S.l.]: Pontifícia Universidade Católica do Paraná–Curitiba, 2009.

ORGANIZATION, W. H. **The top 10 causes of death**. 2014. Access date: 5 ago. 2016. Disponível em: <<http://www.who.int/mediacentre/factsheets/fs310/en/>>.

POZZEBON, G. G. **Transformada *wavelet* e redes neurais artificiais na análise de sinais relacionados a qualidade da energia elétrica**. [S.l.]: Universidade Federal de Santa Maria, 2009.

SILVA, I. N. da et al. **Artificial Neural Networks - A practical course**. [S.l.]: Springer, 2016.

SOUZA, C. B.; ANDREÃO, R. V.; SEGATTO, M. V. **Processamento de sinais de ECG para geração automática de alarmes**. 2006. Access date: 07 jun. 2017. Disponível em: <<https://periodicos.ufersa.edu.br/revistas/index.php/ecop/article/view/7079/6537>>.