

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO DE ELETRÔNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
MESTRADO EM ENGENHARIA ELÉTRICA

SAULO FAVORETTO

MÁQUINAS DE APRENDIZADO EXTREMO APLICADAS À
IDENTIFICAÇÃO DE PESSOAS ATRAVÉS DE
ELETROCARDIOGRAMA (ECG)

DISSERTAÇÃO

PONTA GROSSA

2016

SAULO FAVORETTO

**MÁQUINAS DE APRENDIZADO EXTREMO APLICADAS À
IDENTIFICAÇÃO DE PESSOAS ATRAVÉS DE
ELETROCARDIOGRAMA (ECG)**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre em Engenharia Elétrica do Programa de Pós-Graduação em Engenharia Elétrica, da Universidade Tecnológica Federal do Paraná - Campus Ponta Grossa. Área de Concentração: Instrumentação e Controle.

Orientador: Prof. Dr. Sérgio Okida

Co-orientador: Prof. Dr. Hugo Valadares Siqueira

PONTA GROSSA

2016

Ficha catalográfica elaborada pelo Departamento de Biblioteca
da Universidade Tecnológica Federal do Paraná, Campus Ponta Grossa
n.01/17

F275 Favoretto, Saulo

Máquinas de aprendizado extremo aplicadas à identificação de pessoas
através de eletrocardiograma (ECG) / Saulo Favoretto. -- Ponta Grossa, 2017.
116 f. : il. ; 30 cm.

Orientador: Prof. Dr. Sérgio Okida
Coorientador: Prof. Dr. Hugo Valadares Siqueira

Dissertação (Mestrado em Engenharia Elétrica) - Programa de Pós-
Graduação em Engenharia Elétrica. Universidade Tecnológica Federal do
Paraná. Ponta Grossa, 2017.

1. Identificação biométrica. 2. Eletrocardiografia. 3. Engenharia elétrica. I.
Okida, Sérgio. II. Siqueira, Hugo Valadares. III. Universidade Tecnológica
Federal do Paraná. IV. Título.

CDD 621.3



Ministério da Educação
Universidade Tecnológica Federal do Paraná
Campus Ponta Grossa
Diretoria de Pesquisa e Pós-Graduação Programa de Pós-
Graduação em Engenharia Elétrica
Mestrado em Engenharia Elétrica



TERMO DE APROVAÇÃO

MÁQUINAS DE APRENDIZADO EXTREMO APLICADAS À IDENTIFICAÇÃO DE PESSOAS ATRAVÉS DE ELETROCARGIOGRAMA (ECG) por

Saulo Favoretto

Esta Dissertação foi apresentada em 04 de novembro de 2016 como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Prof. Dr. Raimes Moraes – (UFSC)

Prof^a. Dr^a. Kathya Silvia Collazos Linares – (UTFPR)

Prof^a. Dr^a. Fernanda Cristina Corrêa – (UTFPR)

Prof. Dr. Sérgio Okida – (UTFPR)
Orientador

Prof. Dr. Hugo Valadares Siqueira – (UTFPR)
Co-orientador

Prof. Dr. Claudinor Bitencourt Nascimento – (UTFPR)
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica

Dedico este trabalho à minha esposa
Lilian Jaqueline de Melo Schons, à minha
família e amigos.

AGRADECIMENTOS

Agradeço a Deus pelos dons que me deu e que tornaram possível finalizar mais essa tão importante etapa da minha vida e por tudo que conquistei até o momento.

À minha família, que sempre me apoiou e estive ao meu lado nos momentos alegres, tristes, nervosos, ansiosos e esperançosos, e também pela paciência durante essa minha trajetória.

Ao meu orientador Professor Doutor Sergio Okida e ao co-orientador Professor Doutor Hugo Valadares Siqueira, pelo conhecimento e experiência que dividiram comigo e que me guiaram durante o desenvolvimento deste trabalho.

À minha amiga Petra, pelo apoio e dedicação. Aos meus amigos David, Luiz Farias, Remei, Gabriel Assunção, José Jair, Ismael, Jeferson, Ricardo Lucas e os demais colegas de sala, que de alguma forma contribuíram com este trabalho, seja pelos momentos de descontração e pelas horas dedicadas ao trabalho.

À Selma Maria Schons e Padre Roque pelo apoio e pelas dicas referentes ao meu trabalho.

À CAPES pelo auxílio financeiro prestado.

Enfim, a todos os que de alguma forma contribuíram para a realização deste trabalho.

Eu tentei 99 vezes e falhei, mas na centésima tentativa eu consegui, nunca desista de seus objetivos mesmo que esses pareçam impossíveis, a próxima tentativa pode ser a vitoriosa.

(EINSTEIN, Albert, 1955)

RESUMO

FAVORETTO, Saulo. Máquinas de aprendizado extremo aplicadas à identificação de pessoas através de eletrocardiograma (ECG). 118 f. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2016.

Esta pesquisa estuda a utilização da rede neural Máquina de Aprendizado Extremo (ELM) para identificação de pessoas (biometria) através do eletrocardiograma (ECG). Os dados biométricos oferecem um nível elevado de segurança para a identificação de pessoas, e o ECG é uma técnica emergente e em crescente desenvolvimento. A ELM foi pouco empregada em sistemas de reconhecimento de padrões que utilizam o sinal de ECG. Desta forma, foram estudadas as técnicas de processamento de sinal: a Transformada *Wavelet* e a Análise dos Componentes Principais (PCA), com o objetivo de tratar e reduzir a dimensionalidade dos dados de entrada, bem como, fazer um estudo comparativo entre a ELM e a *Perceptron* Múltiplas Camadas (*Multilayer Perceptron* – MLP). Os testes foram realizados com 90 pessoas, o sinal de ECG utilizado é referente à derivação I contendo 500 amostras/s e 12-bits de resolução dentro de uma faixa nominal de $\pm 10\text{mV}$ de variação, o número de registros variou de 2 a 20 para cada pessoa. O tamanho de cada ciclo completo de ECG para o processo de formação do espaço amostral foi definido de duas formas: 167 amostras contendo as ondas P+QRS e 280 amostras contendo as ondas P+QRS+T, dos quais foram utilizados os 10 ciclos que possuíam o mais elevado nível de similaridade. Com a Transformada *Wavelet*, o sinal de ECG foi decomposto em 3 níveis, onde para as ondas P+QRS as reduções foram de 86, 45 e 25 amostras, e para as ondas P+QRS+T foram de 142, 73 e 39 amostras. Já para o PCA o sinal foi reduzido de 10 ciclos cardíacos para apenas 1. Estes foram apresentadas a rede formando os conjuntos de treinamento e teste. Foram utilizadas as Redes Neurais Artificiais ELM e MLP para classificação do ECG. Os resultados obtidos comprovaram que a ELM pode ser utilizada para identificação de pessoas.

Palavras-chave: Identificação biométrica. ECG. ELM. *Wavelet*. PCA.

ABSTRACT

FAVORETTO, Saulo. Extreme learning machine applied to the identification of people through electrocardiogram (ECG). 118 f. Dissertation (Master in Electrical Engineering) - Graduate Program in Electrical Engineering, Federal Technological University of Paraná. Ponta Grossa, 2016.

This research studies the use of neural network Extreme Learning Machine (ELM) to identify individuals (biometrics) by electrocardiogram (ECG). Biometric data offer a high level of security for identifying people, and ECG is an emerging technique and increasing development. ELM was little used in pattern recognition systems that use the ECG signal. In this way, the signal processing techniques were studied: Wavelet Transform and Principal Component Analysis (PCA), with the objective of treating and reducing the dimensionality of the input data, as was as, to make a comparative study between the ELM and Multilayer Perceptron (MLP). The tests were performed with 90 people, the ECG signal used is related to the lead I containing 500 samples/s and 12-bit resolution within a nominal range of ± 10 mV of variation, the number of records ranged from 2 to 20 for each people. The size of each ECG cycle to complete the process of forming the sample space defined in two ways: 167 samples containing the P+QRS waves and 280 samples containing the P+QRS+T waves, of which 10 cycles were used to had the highest level of similarity. With the Wavelet Transform, the ECG signal was decomposed into 3 levels, where for the P+QRS waves the reductions were 86, 45 and 25 samples, and for the P+QRS+T waves were 142, 73 and 39 samples. For PCA, the signal for reduced from 10 cardiac cycles to only 1. These were presented to network forming the joint training and testing. The Artificial Neural Networks ELM and MLP were used for ECG classification. The results obtained proved that the ELM may be used to identify individuals.

Keywords: Biometric identification. ECG. ELM. Wavelet. PCA.

LISTA DE ILUSTRAÇÕES

Figura 1 – Estrutura do coração e fluxo do sangue pelas câmaras e valvas cardíacas.....	21
Figura 2 – Ilustração dos Sistemas excitatório e condutor do coração (a) e morfologia típica dos PA's em cada tipo de estrutura (b).....	22
Figura 3 – O ECG típico e a denominação de suas características.	23
Figura 4 – Disposição das derivações I, II e III. O triângulo de Einthoven está sobreposto ao tórax.....	25
Figura 5 – Exemplo de registro do eletrocardiograma nas derivações I, II e III.....	26
Figura 6 – Derivações dos membros aumentada.....	27
Figura 7 – Derivações no peito.....	27
Figura 8 – Exemplo de dilatação e compressão da wavelet (w_0 - frequência do sinal).	38
Figura 9 – Translação de uma wavelet em b unidades.	38
Figura 10 – Família wavelet de Daubechies.....	40
Figura 11 - Família wavelet Biorthogonal.	41
Figura 12 – Decomposição do $c_0(n)$ em 2 escalas.	43
Figura 13 – Diagrama esquemático da decomposição wavelet do sinal c_0	44
Figura 14 – Diagrama esquemático da Reconstrução wavelet do sinal c_0	45
Figura 15 – O neurônio biológico.	49
Figura 16 – Modelo de um neurônio artificial.....	51
Figura 17 – Função logística e sua derivada.....	53
Figura 18 – Função tangente hiperbólica e sua derivada.....	53
Figura 19 – Modelo de uma rede MLP.	55
Figura 20 – Exemplo de MLP com 3 camadas intermediárias.	57
Figura 21 – Exemplo de instante de parada no treinamento de uma rede neural via validação cruzada.	60
Figura 22 – Notação de uma Máquina de Aprendizado Extremo.....	62
Figura 23 – Fluxograma das etapas de processamento do sinal de ECG.	66
Figura 24 – Sinal bruto de ECG.	67
Figura 25 – Sinal de ECG e aproximação nível 9 que representa a flutuação da linha de base.	69
Figura 26 – Sinal de ECG com correção da linha de base.....	69
Figura 27 – Espectro de frequência do sinal de ECG sem filtragem.	70
Figura 28 – Resposta em frequência do filtro Butterworth Passa-Baixa.	71
Figura 29 – Espectro de frequência do sinal de ECG filtrado.....	71
Figura 30 – (a) Sinal de ECG bruto e (b) Sinal de ECG filtrado com filtro Passa-Baixa.	72
Figura 31 – Aplicação da técnica do limiar adaptativo wavelet para detectar os picos R.....	73
Figura 32 – Detecção usando wavelet 'db3' e escala 1 para o coeficiente de corte.	74

Figura 33 – 22 ciclos de ECG com 167 amostras/ciclo.	75
Figura 34 – 22 ciclos de ECG com 280 amostras/ciclo.	75
Figura 35–Ciclos cardíacos com 167 amostras/ciclo ajustados subtraindo a média.	76
Figura 36 – Ciclos cardíacos com 280 amostras/ciclo ajustados subtraindo a média.	76
Figura 37 – Os 10 ciclos cardíacos com 167 amostras/ciclo estimados pela correlação.....	77
Figura 38 – Os 10 ciclos cardíacos com 280 amostras/ciclo estimados pela correlação.....	77
Figura 39 – Coeficientes de aproximação da decomposição wavelet “db3” nível 1 para janela contendo as ondas P+QRS.	78
Figura 40 – Coeficientes de aproximação da decomposição wavelet “db3” nível 2 para janela contendo as ondas P+QRS.	79
Figura 41 – Coeficientes de aproximação da decomposição wavelet “db3” nível 3 para janela contendo as ondas P+QRS.	79
Figura 42 – Resultado da soma vetorial dos 10 ciclos cardíacos contendo as ondas P+QRS com a wavelet “db3” nível 1.	80
Figura 43 – Resultado da soma vetorial dos 10 ciclos cardíacos contendo as ondas P+QRS com a wavelet “db3” nível 2.	80
Figura 44 – Resultado da soma vetorial dos 10 ciclos cardíacos contendo as ondas P+QRS com a wavelet “db3” nível 3.	81
Figura 45 – Coeficientes de aproximação da wavelet “db3” nível 1 dos 10 ciclos cardíacos para a janela contendo as ondas P+QRS+T.	81
Figura 46 – Coeficientes de aproximação da wavelet “db3” nível 2 dos 10 ciclos cardíacos para a janela contendo as ondas P+QRS+T.	82
Figura 47 – Coeficientes de aproximação da wavelet “db3” nível 3 dos 10 ciclos cardíacos para a janela contendo as ondas P+QRS+T.	82
Figura 48 – Resultado da soma vetorial dos 10 ciclos cardíacos contendo as ondas P+QRS+T com a wavelet “db3” nível 1.	83
Figura 49 – Resultado da soma vetorial dos 10 ciclos cardíacos contendo as ondas P+QRS+T com a wavelet “db3” nível 2.	83
Figura 50 – Resultado da soma vetorial dos 10 ciclos cardíacos contendo as ondas P+QRS+T com a wavelet “db3” nível 3.	84
Figura 51 – Redução do sinal de ECG com a técnica PCA utilizando a janela P+QRS.	85
Figura 52 – Redução do sinal de ECG com a técnica PCA utilizando a janela P+QRS+T.....	86
Figura 53 – Gráfico da Média e Desvio Padrão dos testes para as janelas P+QRS e P+QRS+T com wavelet “db3” e PCA (ELM). Onde N corresponde ao número de amostras do sinal de entrada.	90
Figura 54 – Gráfico com os melhores resultados obtidos com a ELM. Onde N corresponde ao número de amostras do sinal de entrada.	91
Figura 55 – Gráfico das médias e desvios padrão dos treinamentos da rede neural artificial MLP para a janela P+QRS. Onde N corresponde ao número de amostras do sinal de entrada.....	95

Figura 56 – Gráfico das médias e desvios padrão dos treinamentos da rede neural artificial MLP para a janela P+QRS+T. Onde N corresponde ao número de amostras do sinal de entrada.	96
Figura 57 – Gráfico da média e desvio padrão dos testes para as janelas P+QRS (MLP). Onde N corresponde ao número de amostras do sinal de entrada.	97
Figura 58 – Gráfico da média e desvio padrão dos testes para as janelas P+QRS+T (MLP). Onde N corresponde ao número de amostras do sinal de entrada.	98
Figura 59 – Gráfico com os melhores resultados obtidos com a MLP. Onde N corresponde ao número de amostras do sinal de entrada.	99
Figura 60 – Gráfico comparativo dos resultados com a wavelet “db3” nível 3 e o resultado de Lugovaya (2005). Onde N corresponde ao número de amostras do sinal de entrada.	101
Figura 61 – Gráfico comparativo dos resultados com a PCA e o resultado de Lugovaya (2005). Onde N corresponde ao número de amostras do sinal de entrada.	102

LISTA DE QUADROS

Quadro 1 – Trabalhos que utilizaram o ECG para identificação de pessoas.	35
Quadro 2 – Famílias wavelet.....	40

LISTA DE TABELAS

Tabela 1 – Frequências de corte da transformada wavelet para o sinal de 500 amostras/s.....	68
Tabela 2 – Redução das amostras para os dois grupos de amostras de ciclos de ECG.	84
Tabela 3 – Média dos 30 testes com 90 pessoas utilizando a ELM sem coeficiente de regularização.....	88
Tabela 4 – Média dos 30 testes com 90 pessoas utilizando a ELM com coeficiente de regularização.....	89
Tabela 5 – Melhores resultados utilizando a ELM para a janela contendo as ondas P+QRS.....	90
Tabela 6 – Melhores resultados utilizando a ELM para a janela contendo as ondas P+QRS+T.....	91
Tabela 7 – Média dos 30 testes com 90 pessoas utilizando a MLP.	93
Tabela 8 – Melhores resultados obtidos com a Rede Neural Artificial MLP.	98
Tabela 9 – Pessoas erroneamente identificadas considerando a quantidade de registros utilizados para teste com wavelet “db3” nível 1 janela P+QRS (ELM).....	100
Tabela 10 – Pessoas erroneamente identificadas considerando a quantidade de registros utilizados para teste com PCA janela P+QRS (ELM).	100
Tabela 11 – Pessoas erroneamente identificadas considerando a quantidade de registros utilizados para teste com wavelet janela P+QRS (MLP).	103
Tabela 12 – Pessoas erroneamente identificadas considerando a quantidade de registros utilizados para teste com PCA janela P+QRS (MLP).	104
Tabela 13 – Comparação dos resultados obtidos em trabalhos que utilizaram as Redes Neurais Artificiais.	105

LISTA DE SIGLAS

A/D	Analógico/Digital (<i>analog-digital</i>)
AC	Autocorrelação (<i>autocorrelation</i>)
AM	Modelagem Autoregressiva (<i>Autoregressive Modelling</i>)
ANN	Método do Vizinho Mais Próximo (<i>nearest neighbor method</i>)
AV	Nodo Atrioventricular
aVF	Aumentada, Voltagem, Pé Esquerdo
aVL	Aumentada, Voltagem. Braço Esquerdo
aVR	Aumentada, Voltagem, Braço Direito
CCORR	Coeficiente de Correlação (<i>Correlation Coefficient</i>)
CWT	Transformada <i>Wavelet</i> Cotínua (<i>Continuous Wavelet Transform</i>)
DAELE	Departamento de Eletrônica
dB	Decibel
DBNN	Rede Neural Baseada em Decisão (<i>Decision- based neural network</i>)
DCT	Transformada do Cosseno Discreto (<i>Discrete cosine transform</i>)
DNA	Ácido Desoxirribonucleico
DWT	Transformada <i>Wavelet</i> Discreta (<i>Discrete Wavelet Transform</i>)
ECG	Eletrocardiograma
ELM	Máquinas de Aprendizado Extremo (<i>Extreme Learning Machine</i>)
FT	Transformada de <i>Fourier</i> (<i>Fourier transform</i>)
FTT	Transformada Rápida de <i>Fourier</i> (<i>Fast Fourier Transform</i>)
HTTP	Protocolo de Transferência de Hipertexto (<i>Hypertext Transfer Protocol</i>)
Hz	<i>Hertz</i>
LDA	Análise Discriminante Linear (<i>Linear Discriminant Analysis</i>)
mA	<i>Mille Ampere</i>
MLP	<i>Perceptron</i> de Múltiplas Camadas (<i>Multilayer Perceptron</i>)
mV	<i>Mille Volts</i>
MVC	Classificador do Voto Majoritário (<i>Majority Vote Classifier</i>)
NED	Distância Euclidiana Normalizada (<i>Normalized euclidean distance</i>)
NGLL	Probabilidade do Registro Gaussiano Normalizado (<i>Normalized gaussian log likelihood</i>)
NMC	Classificador da Média Mais Próxima (<i>Nearest Mean Classifier</i>)
PA	Potencial de Ação
PCA	Análise de Componentes Principais (<i>Principal Component Analysis</i>)

PPGEE	Programa de Pós-Graduação em Engenharia Elétrica
RBF	Função de Base Radial (<i>Radial Basis Function</i>)
RNA	Rede Neural Artificial (<i>Artificial Neural Network</i>)
SA	Nodo Sinoatrial
SIMCA	Modelagem Independente Flexível por Analogia de Classe (<i>Soft Independent Modelling of Class Analogy</i>)
SLFN	Rede Neural Alimentada Adiante de Camada Única (<i>Single Layer Feedforward Network</i>)
SPSS	Método Passo a Passo (<i>Stepwise method</i>)
SVM	Máquina de Vetores Suporte (<i>Support Vector Machine</i>)
TAV	Tempo de Ativação Ventricular
TM	Casamento de Modelo (<i>Template Matching</i>)
UTFPR	Universidade Tecnológica Federal do Paraná
WDIST	Medida da Distância <i>Wavelet</i> (<i>Wavelet Distance Measure</i>)
WNMC	Classificador da Média Ponderada Mais Próxima (<i>Weighted Nearest Mean Classifier</i>)
WT	Transformada <i>Wavelet</i> (<i>Wavelet Transform</i>)
WWW	Rede de Alcance Mundial (<i>World Wide Web</i>)

SUMÁRIO

1 INTRODUÇÃO	16
1.1 OBJETIVOS	18
1.1.1 Objetivo Principal	18
1.1.2 Objetivos Específicos.....	18
1.2 JUSTIFICATIVAS	18
1.3 ORGANIZAÇÃO DO TRABALHO	19
2 O ELETROCARDIOGRAMA (ECG) E SUA APLICAÇÃO EM BIOMETRIA	20
2.1 O CORAÇÃO HUMANO	20
2.2 O ELETROCARDIOGRAMA (ECG).....	23
2.3 AS DERIVAÇÕES ELETROCARDIOGRÁFICAS	24
2.4 DADOS BIOMÉTRICOS COMUMENTE UTILIZADOS.....	27
2.5 O USO DO ECG NA BIOMETRIA.....	30
3 MÉTODOS DE PROCESSAMENTO E EXTRAÇÃO DE CARACTERÍSTICAS DE SINAIS DE ECG	36
3.1 TRANSFORMADA WAVELET	36
3.1.1 Transformada Wavelet Discreta (DWT)	41
3.2 ANÁLISE DOS COMPONENTES PRINCIPAIS (PCA)	45
4 REDES NEURAIS ARTIFICIAIS	49
4.1 MODELOS DE NEURONIOS ARTIFICIAIS.....	51
4.2 TREINAMENTO DE UMA REDE NEURAL.....	53
4.2.1 Perceptron Múltiplas Camadas (MLP)	55
4.2.2 Máquinas de Aprendizado Extremo (ELM)	60
5 MATERIAIS E MÉTODOS	66
5.1 BASE DE DADOS DO ECG.....	67
5.2 PRÉ-PROCESSAMENTO DO SINAL DE ECG	68
5.2.1 Correção da Linha de Base	68
5.2.2 Filtragem.....	70
5.3 EXTRAÇÃO DE CARACTERÍSTICAS.....	72
5.3.1 Detecção da Onda R	72
5.3.2 Segmentação do Sinal.....	74
5.3.3 Redução da Dimensão do Espaço de Características do Sinal	78
5.4 REDES ELM E MLP PARA A IDENTIFICAÇÃO DE PESSOAS	86
6 RESULTADOS	88
7 DISCUSSÃO	100
8 CONCLUSÃO	107
9 TRABALHOS FUTUROS	108
REFERÊNCIAS	109

1 INTRODUÇÃO

A identificação biométrica é uma tecnologia que permite a identificação das pessoas através de seu fenótipo. As características do fenótipo são ditadas pelas proteínas que o genótipo codifica.

Este conjunto de genes de um organismo são pedaços ou segmentos do DNA (Ácido Desoxirribonucleico) formado basicamente por proteínas. São elas que comandam as atividades dos genes e determinam uma ou mais características, como por exemplo, cor de pele, cor do cabelo, cor dos olhos, estatura, peso, forma do corpo, funcionamento dos órgãos (LEHNINGER et al., 2002).

Todavia, não se pode demonstrar ser esta herança verdadeira para todas as individualidades biométricas, especialmente para o caso de gêmeos idênticos nos quais os DNA's são idênticos. Porém, a maioria dos dados biométricos obtidos de gêmeos monozigóticos têm demonstrado tal singularidade (SUFU; KHALIL; HU, 2010).

Um sistema biométrico é essencialmente um sistema de reconhecimento de padrões que, através da aquisição dos dados biométricos de um indivíduo, extrai um conjunto de características e as compara com o modelo definido no banco de dados. Dependendo do contexto da aplicação, um sistema biométrico irá operar no modo de controle de acesso ou apenas para identificação (JAIN; ROSS; PRABHAKAR, 2004).

Atualmente, os dados biométricos são de grande interesse em áreas onde é realmente importante verificar a identidade de um indivíduo. Inicialmente estas técnicas eram empregadas em aplicações especializadas de alta segurança. Entretanto, observa-se agora, sua utilização e proposta de uso em uma grande e crescente área em utilizações públicas no nosso dia a dia, como em programas de fidelidade de mercados e acesso em academias.

Nos sistemas de segurança, por exemplo, a abertura de uma porta pode ser realizada de diferentes maneiras. A técnica mais simples seria o uso de um código de bloqueio, porém, para um sistema com maior nível de segurança são necessários sistemas mais complexos. A partir disso, parte-se para sistemas que realizam a identificação do rosto humano. Este método necessita de sistemas de visão computacional de alta resolução que coletam características faciais, geralmente estruturas faciais antropométricas. Outros métodos utilizados nesta área incluem reconhecimento por voz, o reconhecimento de palma da mão, e o mais comum, a

impressão digital. O olho humano também contém características específicas tanto na retina como na íris (BIEL et al., 1999; BIEL et al., 2001).

Para que um dado biométrico possa ser utilizado para identificação humana, ele deve ser: universal, cada pessoa deve ter essa característica; distinta, duas pessoas quaisquer devem ser suficientemente diferentes em termos de característica; permanente, a característica deve ser suficientemente invariante, com relação ao critério correspondente; e coletável, a característica pode ser medida quantitativamente (JAIN; ROSS; PRABHAKAR, 2004). Satisfazendo estes requisitos pode-se supor que ele possa ser utilizado para identificação de pessoas.

Uma das técnicas também usadas para a identificação biométrica é o eletrocardiograma (ECG) que corresponde às atividades elétricas do coração, contendo informações singulares herdadas do DNA (SUFİ; KHALIL; HU, 2010). Em função disso, o eletrocardiograma (ECG) foi proposto por Biel et al. (1999) para identificação de pessoas.

Desde então, diversos trabalhos vêm sendo realizados. Para esta finalidade, diferentes métodos foram propostos como: o método de Modelagem Independente Flexível por Analogia de Classe (SIMCA), Análise dos Componentes Principais (PCA), Casamento de Modelos (TM), Análise Discriminante Linear (LDA), Medida de Distância *Wavelet* (WDIST), Redes Neurais Artificiais (RNA), dentre outros. Contudo, há poucos trabalhos que utilizam as redes neurais artificiais. Entre eles destacam-se: os trabalhos de Shen et al. (2002), Güler e Übeyli (2005), Wan et al. (2008) e Wu e Zhang (2014) os quais fizeram uso de redes neurais artificiais baseadas em arquiteturas das *Perceptron* Múltiplas Camadas (MLP). Já os trabalhos de Boumbarov et al. (2009) e Chen et al. (2012) apresentam redes neurais artificiais baseadas nas Funções de Bases Radiais (RBF).

Neste trabalho, é avaliada a aplicação da rede neural “Máquina de Aprendizado Extremo” (ELM) para identificação de pessoas através do eletrocardiograma. Até o presente momento, não há trabalhos que avaliem a ELM para esta finalidade.

Os estudos foram baseados no trabalho de Lugovaya (2005) que realizou um comparativo com as diferentes ondas do sinal de eletrocardiograma (ECG) e também, com as técnicas de redução de dimensão do sinal.

1.1 OBJETIVOS

1.1.1 Objetivo Principal

O objetivo deste trabalho é investigar o potencial da rede neural baseada em Máquina de Aprendizado Extremo (ELM – *Extreme Learning Machine*) na identificação de pessoas (biometria) a partir do eletrocardiograma.

1.1.2 Objetivos Específicos

- Avaliar técnicas de pré-processamento dos sinais de ECG necessárias para tratar, reduzir a dimensionalidade e extrair as características dos dados de entrada;
- Fazer um estudo comparativo do desempenho da ELM com outra arquitetura de rede neural artificial usada na biometria com ECG, como por exemplo a *Perceptron Multicamadas (MLP, Multilayer Perceptron)*.

1.2 JUSTIFICATIVAS

Tendo em vista que as técnicas de reconhecimento de pessoas são cada vez mais requeridas e, devido ao fato de que os dados biométricos oferecem um nível de segurança elevado, optou-se em investigar neste trabalho uma nova técnica para identificação de pessoas a partir do eletrocardiograma.

Essa técnica está emergindo e em crescente desenvolvimento. Assim, diversos métodos para sua utilização foram propostos; dentre eles, as redes neurais artificiais. Uma das principais desvantagens das redes neurais tradicionais é o tempo que necessitam para aprendizagem, sendo geralmente lentos.

Já a rede Máquina de Aprendizado Extremo (ELM) possui um rápido tempo de treinamento. Sua utilização vem crescendo nos últimos anos, sendo aplicadas em várias áreas, tais como: biometria, bioinformática, processamento de imagem, processamento de sinais, seleção de características. É uma rede que possui um

algoritmo simples onde apenas os parâmetros dos neurônios da camada oculta são ajustados.

1.3 ORGANIZAÇÃO DO TRABALHO

Depois desta breve introdução que descreve o problema, os objetivos e a justificativa deste trabalho, os tópicos relacionados ao desenvolvimento do trabalho são detalhados.

Nos três capítulos seguintes, é apresentada a fundamentação teórica essencial para a compreensão do trabalho desenvolvido. No Capítulo 2, descreve-se o sistema excitatório e condutor do coração (que geram o eletrocardiograma), com um breve resumo dos diversos dados biométricos comumente utilizados para identificação de pessoas e o uso do eletrocardiograma na biometria.

Apresenta-se no Capítulo 3, conceitos sobre as duas técnicas de pré-processamento dos sinais de eletrocardiograma: a Transformada *Wavelet* e a Análise dos Componentes Principais (PCA).

No Capítulo 4, introduz-se as arquiteturas de redes neurais artificiais tipo *Perceptron* de Múltiplas Camadas (MLP) e Máquina de Aprendizado Extremo (ELM).

O Capítulo 5 descreve e explica as etapas que foram realizadas para atender os objetivos propostos.

O Capítulo 6 apresenta e comenta os resultados obtidos após a realização dos processamentos.;

O Capítulo 7 discute os resultados obtidos com este trabalho. O Capítulo 8 expõe as conclusões e o Capítulo 9, propostas para trabalhos futuros.

Por fim, são listadas as referências bibliográficas utilizadas neste trabalho de pesquisa.

2 O ELETROCARDIOGRAMA (ECG) E SUA APLICAÇÃO EM BIOMETRIA

A eletrocardiografia surgiu e desenvolveu-se graças a pesquisadores ilustres que souberam captar o desenvolvimento da eletrofisiologia e de novas tecnologias na elaboração de uma ferramenta de diagnóstico sem precedentes (GIFFONI; TORRES, 2010).

Einthoven pode ser considerado o pai da eletrocardiografia, já que seu galvanômetro de corda permitiu registros fidedignos e com a padronização empregada até hoje. O sucessor de Einthoven foi o grande estudioso das arritmias, Thomas Lewis, que também foi professor de Frank N. Wilson.

As derivações unipolares desenvolvidas por Wilson permitiram o registro dos potenciais elétricos em qualquer parte do corpo. A eletrocardiografia também proporcionou o estabelecimento da teoria coronariana das síndromes anginosas e, mais recentemente, novas aplicações clínicas, tais como os testes ergométricos, eletrofisiológicos, Holter e a eletrocardiografia de alta resolução (GIFFONI; TORRES, 2010).

Neste capítulo, faz-se um breve relato sobre o coração humano, bem como as técnicas comumente utilizadas para coletar seus sinais elétricos que são registrados no eletrocardiograma.

2.1 O CORAÇÃO HUMANO

O coração humano fica localizado na caixa torácica, com sua parte inferior inclinada para o lado esquerdo e a parte superior, para o direito. Seu tamanho e peso variam de um indivíduo para outro. Em muitas pessoas, o coração é aproximadamente do tamanho da mão fechada e o peso médio é de cerca de 300g (CARR; BROWN, 2001).

O coração (Figura 1) é formado por duas bombas separadas: o *coração direito* (em azul, que bombeia o sangue para os pulmões) e o *coração esquerdo* (em vermelho, que bombeia o sangue para os órgãos periféricos). Cada uma dessas bombas é composta por um *átrio* (câmara superior) que se comporta como uma fraca

bomba de escorva¹ para o ventrículo, ajudando a propelir o sangue para seu interior. O *ventrículo* (câmara inferior) fornece as altas pressões que propelem o sangue através da circulação pulmonar (coração direito) e demais órgãos (coração esquerdo) (HALL; GUYTON, 2011).




Figura 1 – Estrutura do coração e fluxo do sangue pelas câmaras e valvas cardíacas.
Fonte: Hall e Guyton (2011).

Como ilustrado na Figura 1, existem quatro valvas (ou também conhecidas como válvulas) no coração humano. As valvas situadas entre os átrios e ventrículos são denominadas de valvas atrioventriculares. Sendo a valva entre o átrio e o ventrículo direito conhecida como a *valva tricúspide*. A *valva atrioventricular* entre o átrio esquerdo e o ventrículo esquerdo é chamada de *valva bicúspide* (ou *valva mitral*). A função dessas valvas é garantir a circulação do sangue no coração em um único sentido, sempre do átrio para o ventrículo (TORTORA; DERRICKSON, 2012).

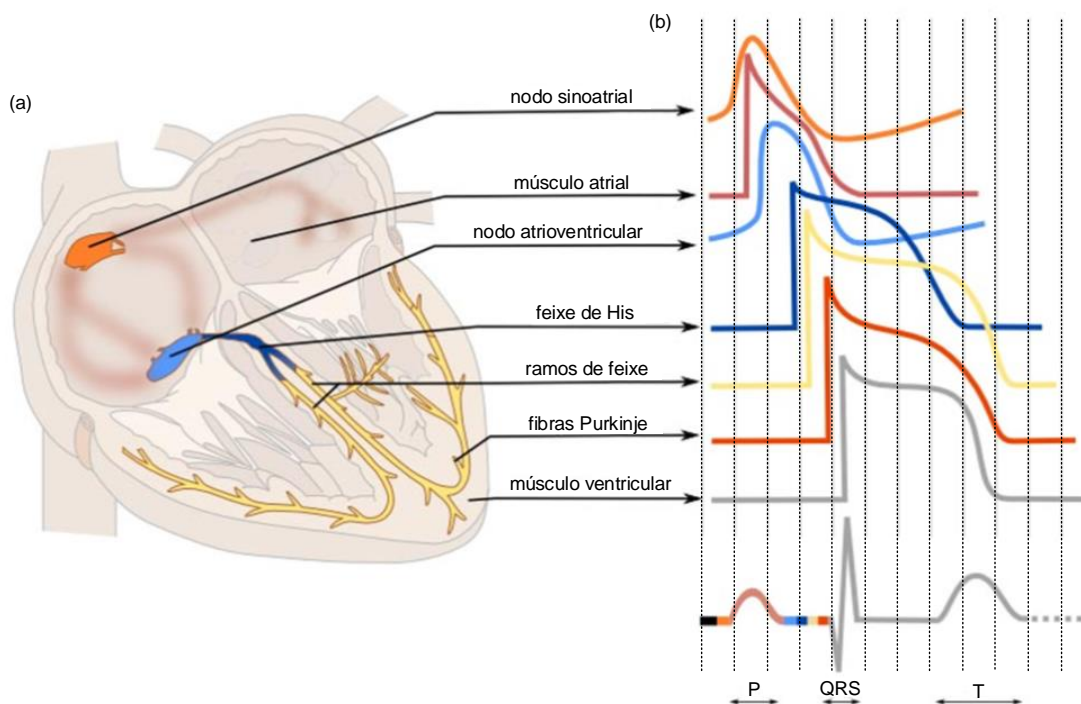
A *valva pulmonar* impede o refluxo de sangue da artéria pulmonar para o ventrículo direito. A *valva aórtica* que, devido às suas formas de meia-lua, recebe o nome de *valva semilunar*, impede o refluxo de sangue da aorta para o ventrículo esquerdo (CARR; BROWN, 2001).

¹ O sangue flui de forma contínua, vindo das grandes veias para os átrios; cerca de 80% do sangue fluem diretamente dos átrios para os ventrículos, mesmo antes da contração atrial. Então, essa contração representa os 20% adicionais para acabar de encher os ventrículos. Deste modo, os átrios funcionam simplesmente como bomba de escorva, que melhora a eficácia do bombeamento ventricular por no máximo 20% (HALL; GUYTON, 2011).

O conjunto dos eventos cardíacos que ocorrem entre dois batimentos é denominado ciclo cardíaco, consistindo em um período de relaxamento (diástole), no qual o coração se enche de sangue, e pelo período de contração (sístole).

O ciclo cardíaco inicia-se pela geração espontânea de um potencial de ação (PA) que é uma inversão do potencial de membrana de uma célula excitável como músculos esquelético, cardíaco e liso ou tecido nervoso no nodo sinoatrial (SA) (HALL; GUYTON, 2011).

O gráfico representado na Figura 2 mostra o sistema de condução e excitação do coração e os potenciais de ação de suas fibras cardíacas. O potencial de ação tem origem no nodo sinoatrial que rapidamente se espalha pelas vias internodais através dos átrios direito e esquerdo, contraindo-os. O PA ao atingir o nodo atrioventricular (AV) sofre um retardo, para que os átrios esvaziem seus conteúdos antes da contração ventricular. Após o PA propagar-se pelo feixe de His, pelos ramos direito e esquerdo e pelas fibras de Purkinje, tem-se a contração ventricular (HALL; GUYTON, 2011).



**Figura 2 – Ilustração dos Sistemas excitatório e condutor do coração (a) e morfologia típica dos PA's em cada tipo de estrutura (b).
Fonte: OME (2014).**

2.2 O ELETROCARDIOGRAMA (ECG)

O termo eletrocardiograma (ECG) é uma combinação de três palavras: *ele*to, pertencente ao sinal elétrico; *cardio*, que se traduz em coração; e *grama*, do grego que significa o que é desenhado, caráter, letra, sendo o método mais comum de diagnóstico clínico de arritmia cardíaca (NAJARIAN; SPLINTER, 2012).

O ECG é o registro das atividades elétricas produzidas pelo coração, medidas por meio de eletrodos colocados sobre a superfície corporal. Representa a soma das atividades elétricas (Figura 2) que ocorrem a cada instante do ciclo cardíaco. A Figura 3 ilustra as formas de onda que constituem o ECG em um ciclo cardíaco (CALIL; GOMIDE, 2002). As diferentes partes da forma de onda do ECG são designados por letras. A onda P indica contração atrial; sístole ventricular ocorre imediatamente após o QRS e a repolarização gera a onda T (CARR; BROWN, 2001).




Figura 3 – O ECG típico e a denominação de suas características.
Fonte: Calil e Gomide (2002).

Segundo Hall e Guyton (2011) e Carr e Brown (2001), a onda P é gerada pelos potenciais elétricos devido à despolarização dos átrios, produzindo a contração atrial. As ondas Q, R e S são conjuntamente chamadas de complexo QRS geradas quando os ventrículos se despolarizam antes de sua contração, ou seja, enquanto a onda de despolarização se propaga pelos ventrículos. A onda P e o complexo QRS são ondas de despolarização.

A onda T, conhecida como onda de repolarização, é produzida pelos potenciais gerados, enquanto os ventrículos se restabelecem do estado de despolarização.

O intervalo P-Q ou P-R, medido do início da onda P até o início do complexo QRS, corresponde ao intervalo entre o começo da estimulação elétrica dos átrios e o começo da estimulação dos ventrículos. O intervalo P-Q normal é de cerca de 0,16 segundo. Com frequência, esse intervalo é chamado intervalo P-R porque é comum a onda Q estar ausente.

O tempo de ativação ventricular (TAV) representa a medida do tempo de aparecimento da deflexão intrínseca, ou seja, a medida em tese do tempo gasto para que o impulso despolarizante percorra toda a espessura do ventrículo esquerdo; estendendo-se do início do complexo QRS até o pico da onda R (PASTORE et al., 2009).

O intervalo Q-T corresponde ao espaço compreendido entre o início da onda Q (ou da onda R, quando a onda Q está ausente) até o final da onda T. Esse período tem normalmente cerca de 0,35 segundo (HALL; GUYTON, 2011). O segmento ST começa no exato momento em que termina o complexo QRS e finaliza de forma imperceptível no início da inclinação da onda T. A onda T normal é assimétrica, apresentando o inclinação ascendente lenta e uma inclinação descendente rápido, sendo essa a característica mais importante (SUFI; KHALIL; HU, 2010).

2.3 AS DERIVAÇÕES ELETROCARDIOGRÁFICAS

A derivação é uma unidade vetorial que define a direção que um vetor cardíaco com magnitude constante deve ter para gerar a tensão máxima em um par de eletrodos (WEBSTER; CLARK, 2010).

Existem três modalidades de derivações convencionais: derivações dos membros ou bipolares; derivações dos membros aumentada e derivações precordiais no peito (MOND; GARCIA; VISAGATHILAGAR, 2015).

As derivações bipolares ou de membros (Figura 4) são conhecidas como “bipolares” que quer dizer que o eletrocardiograma é registrado por dois eletrodos posicionados nos membros. São três as derivações bipolares padrão dos membros: derivação I, II e III (HALL; GUYTON, 2011).

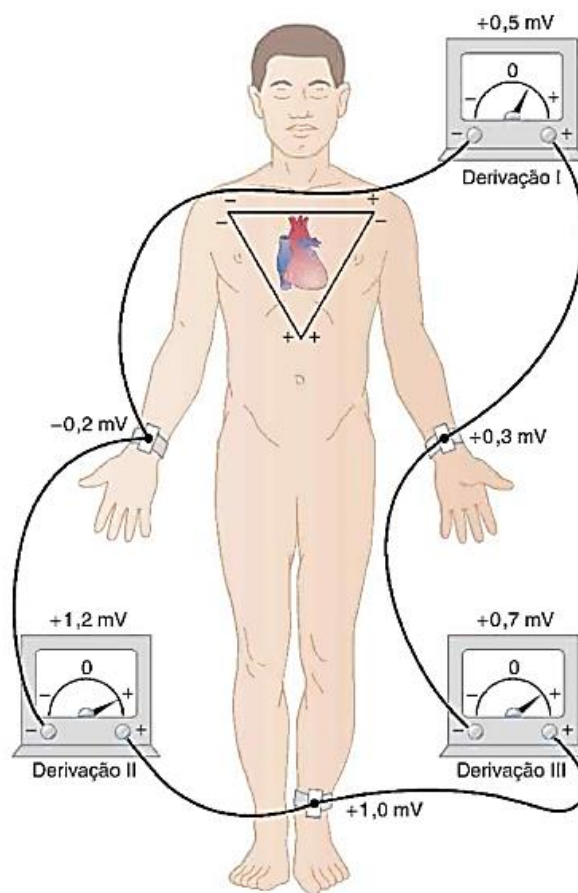


Figura 4 – Disposição das derivações I, II e III. O triângulo de Einthoven está sobreposto ao tórax.

Fonte: Hall e Guyton (2011).

A derivação I corresponde ao terminal negativo do eletrocardiógrafo conectado ao braço direito, e o terminal positivo, ao braço esquerdo. Esta disposição faz com que o eletrocardiógrafo registre valor positivo (valor acima da linha de voltagem zero do eletrocardiograma) quando o potencial elétrico do braço direito for eletronegativo em relação ao braço esquerdo. Quando ocorre o oposto, o eletrocardiógrafo registra valor situado abaixo da linha.

Na derivação II, o terminal negativo do eletrocardiógrafo é conectado ao braço direito, e o terminal positivo, à perna esquerda. Portanto, quando o braço direito está em um potencial elétrico menor em relação à perna esquerda, o eletrocardiógrafo exibe registro positivo.

Para registrar a derivação III, o terminal negativo do eletrocardiógrafo é conectado ao braço esquerdo, e o terminal positivo, à perna esquerda. Isso significa que o eletrocardiógrafo apresentará registro positivo quando o braço esquerdo estiver com potencial elétrico menor que a perna esquerda (AGRAFIOTI; HATZINAKOS, 2008b).

A combinação das derivações I, II e III compõe o triângulo de Einthoven (MOND; GARCIA; VISAGATHILAGAR, 2015).

A lei de Einthoven diz que, se os potenciais elétricos de duas derivações eletrocardiográficas bipolares dos membros são conhecidos, o potencial elétrico da terceira derivação poderá ser determinado pela soma vetorial dos dois primeiros. Na Figura 5, são mostrados os registros dos eletrocardiogramas normais nas derivações bipolares padrão dos membros I, II e III (HALL; GUYTON, 2011).



**Figura 5 – Exemplo de registro do eletrocardiograma nas derivações I, II e III.
Fonte: Hall e Guyton (2011).**

O registro do eletrocardiograma para as derivações I, II e III são semelhantes entre si, pois ambas registram as ondas P, T e a parte principal do complexo QRS positivas. Outra análise com relação a estas três derivações que pode ser realizada por meio de medidas cuidadosas e da observação adequada das polaridades é a soma dos potenciais nas derivações I e III, sendo igual ao potencial na derivação II, como descrito na lei de Einthoven (HALL; GUYTON, 2011).

As derivações unipolares dos membros aumentada (Figura 6), aVR (aumentada, tensão, braço direito), aVL (aumentada, tensão, braço esquerdo) e aVF (aumentada, tensão, pé esquerdo) são medidas em relação ao Terminal Central de Wilson. Cada derivação mede o potencial elétrico de um ponto comum criado unindo as outras duas ligações. Para aVR, a seta de referência agora aponta para o braço

direito é uma deflexão negativa, enquanto que para aVL e aVF os desvios são geralmente positivos.




Figura 6 – Derivações dos membros aumentada.
Fonte: Jbatt (2009).

As derivações no peito, denominadas de precordiais, são unipolares e os registros são obtidos a partir de seis posições no peito padronizados, V1 a V6 (Figura 7). O potencial elétrico de referência pelo ponto comum formado pela junção das três derivações dos membros (MOND; GARCIA; VISAGATHILAGAR, 2015).

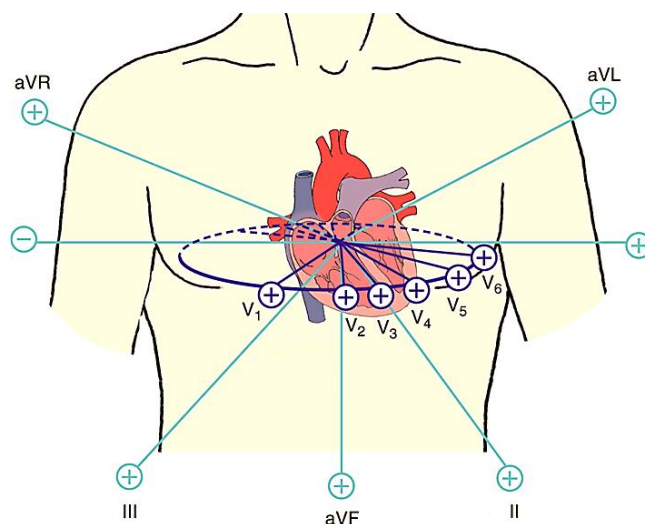


Figura 7 – Derivações no peito.
Fonte: Morton et al. (2005).

2.4 DADOS BIOMÉTRICOS COMUMENTE UTILIZADOS

Hoje são utilizadas, em várias aplicações, diversas características biométricas, tendo cada biometria seus pontos fortes e fracos, sendo sua escolha

dependente da aplicação. Não existe uma biometria “ideal” capaz de atender com eficácia as necessidades de todas as aplicações, pois cada uma apresenta diferentes modos de funcionamento, propriedades e características biométricas (JAIN; ROSS; PRABHAKAR, 2004). Os dados biométricos mais comumente utilizados são:

- **ÁCIDO DESOXIRRIBONUCLEICO (DNA):** é o material genético das células vivas que determinam as características hereditárias que são transmitidas (LEHNINGER et al., 2002). Composto por DNA, o genoma de cada ser humano é único e diferente dos demais, com exceção de gêmeos univitelinos. Atualmente, é utilizado principalmente em aplicações forenses para reconhecimento de pessoas (MATTANA et al., 2012).
- **FACE:** Reconhecimento facial é um método não intrusivo. Imagens faciais são provavelmente as características biométricas mais comuns usadas pelos seres humanos para fazer o reconhecimento de uma pessoa. As abordagens mais populares para o reconhecimento facial são baseadas ou na localização e a forma de atributos faciais, tais como os olhos, sobrancelhas, nariz, lábios e queixo e suas relações espaciais, ou na análise total (global) da imagem do rosto. Porém, existem problemas com as variações de padrões que, devido a diferenças na aparência facial (tais como o uso de óculos, barba, bigode e iluminação) dificultam, significativamente o reconhecimento facial (SUNG; POGGIO, 1998).
- **TERMOGRAMA DE INFRAVERMELHO FACIAL, MÃO E VEIA DA MÃO:** O padrão de calor irradiado pelo corpo humano é uma característica do indivíduo e pode ser capturada por uma câmera de infravermelho de forma discreta, bem como uma fotografia regular (espectro visível). Um sistema baseado em termograma não exige contato e é não-invasivo (JAIN; ROSS; NANDAKUMAR, 2011).
- **IMPRESSÃO DIGITAL:** É o padrão de cumes e vales na superfície da ponta dos dedos das mãos e dos pés, sendo sua formação determinada durante os sete primeiros meses do desenvolvimento fetal. Utilizada há séculos, sua correspondente precisão tem-se mostrado muito elevada (MAZI; DAL PINO JÚNIOR, 2008). Impressão digital de gêmeos idênticos são diferentes, assim como as impressões em cada dedo de uma mesma pessoa (JAIN; ROSS; PRABHAKAR, 2004).

- **IMPRESSÃO DA PALMA DA MÃO:** As palmas das mãos humanas contêm padrões de cumes e vales muito parecidos com as impressões digitais. Possuem características distintas adicionais, tais como linhas e rugas principais que podem ser capturadas até mesmo com um *scanner* de baixa resolução, sendo distintas inclusive entre gêmeos idênticos e permanecendo estáveis desde o nascimento (KONG; ZHANG; KAMEL, 2009).
- **ÍRIS:** A íris é uma região anelar do olho delimitada pelas pupilas e as escleras (parte branca do olho) em ambos os lados. A textura visual da íris é formada durante o desenvolvimento fetal e se estabiliza durante os dois primeiros anos de vida. A complexa textura da íris traz informações muito distintas e úteis para reconhecimento de pessoas. Cada íris é distinta, mesmo em gêmeos idênticos. A íris pode sofrer efeitos do envelhecimento, tais como: perda da pigmentação, surgimento de degrau e alguns problemas clínicos que distorcem sua superfície (GARCIA, 2009).
- **ESCANEAMENTO DE RETINA:** A vasculatura da retina é rica em estrutura e característica de cada indivíduo e cada olho. Alega-se ser a característica biométrica mais segura, uma vez que não é fácil de alterar ou replicar a vasculatura da retina, pois suas ramificações são as mais variadas possíveis. O aspecto dessa vascularização permanece constante ao longo da vida o que permite sua utilização como método de identificação biométrica (GARCIA, 2009).
- **ASSINATURA:** A forma como uma pessoa assina seu nome é conhecido por ser uma característica daquele indivíduo. Embora as assinaturas exijam contato com o instrumento de escrita e um esforço por parte do usuário, eles foram aceitos pelo governo, jurídico e transações comerciais como um método de verificação. É um dado biométrico que muda ao longo de um período de tempo e é influenciada pelas condições física e emocional do signatário, sendo as impressões sucessivas de sua assinatura significativamente diferentes. Além disso, falsificadores profissionais podem ser capazes de reproduzir as assinaturas que enganam o sistema (JAIN; ROSS; NANDAKUMAR, 2011).
- **VOZ:** A voz é uma combinação de dados biométricos, fisiológicos e comportamentais. Os recursos de voz de um indivíduo são baseados na forma

e tamanho dos apêndices (por exemplo, intervalos vocais, boca, das cavidades nasais, e lábios) que são utilizados na síntese do som. Estas características fisiológicas da fala humana são invariantes para um indivíduo, mas a parte comportamental da fala de uma pessoa muda ao longo do tempo devido à idade, condições médicas (como um resfriado comum), e estado emocional e outros. A voz também não é muito distinta e pode não ser apropriada para a identificação em grande escala (NUNES, 2015).

2.5 O USO DO ECG NA BIOMETRIA

O sinal do eletrocardiograma (ECG) é um dado biométrico em ascensão, contendo informações suficientemente distintas para a identificação de pessoas.

Os primeiros trabalhos envolvendo os dados do eletrocardiograma como nova forma para identificação de pessoas foram realizados por Biel et al. (1999 e 2001). Para isso, os autores utilizaram um equipamento da empresa *SIEMENS* para aquisição das 12 derivações do ECG em 20 pessoas (entre 20 e 55 anos de idade), tendo como método para classificação a modelagem independente flexível por analogia de classe (SIMCA). Foram utilizadas 85 amostras para montagem do conjunto de treinamento e 50 amostras para teste, obtendo 98% de classificação. Concluiu-se que apenas uma derivação é suficiente para identificar uma pessoa (BIEL et al., 2001).

Shen et al. (2002) investigaram a viabilidade do uso do eletrocardiograma (ECG) como um novo método de biometria para verificação da identidade humana utilizando apenas a derivação I e um conjunto de 20 pessoas. Neste trabalho, foi usado o casamento de modelos (*template matching*) e uma rede neural baseada em decisão. Para treinamento foram selecionadas 20 registros e 1 registro para teste, obtendo como resultado 95% com o método de casamento de modelos e 80% com a rede neural.

No trabalho de Lugovaya (2005), além das técnicas para identificação de pessoas, é apresentada uma sequência de filtros para tratar o sinal de ECG. Duas técnicas de redução de características são propostas, o PCA (Análise dos Componentes Principais) e a Transformada *Wavelet*. Para classificação do ECG, um comparativo entre três métodos: o classificador da média mais próxima (*Nearest Mean*

Classifier), o classificador da média ponderada mais próxima (*Weighted Nearest Mean Classifier*) e a análise do discriminante linear (LDA - *Linear Discriminant Analysis*) foi analisado. Lugovaya (2005) utilizou 90 pessoas (entre 13 e 75 anos) e um total de 310 registros de ECG com a derivação I. Para treinamento, foram utilizados 195 registros contendo entre 6 a 10 batimentos cardíacos e 115 reservados para teste. Com a análise do discriminante linear e o classificador do voto majoritário, obteve-se o resultado de 96% de classificação.

O coração humano, como dito anteriormente, é considerado um sistema único de cada pessoa. O registro de corrente elétrica gerada pelo batimento cardíaco é potencialmente uma característica humana distintiva, uma vez que as formas de onda de ECG dependem das características anatômicas do coração e do corpo humano (LUGOVAYA, 2005).

Sua importância é também discutida por Saechia et al. (2005), tendo em vista que as preocupações de segurança aumentam à medida em que a tecnologia avança para a falsificação. Existem fortes evidências indicando que é difícil falsificar os dados biométricos (PLATANIOTIS; HATZINAKOS; LEE, 2006).

Por décadas, o ECG foi utilizado em diagnósticos clínicos. Wang et al. (2006) investigaram as características analíticas e a aparência para descobrir atributos significativos a serem utilizados para identificação humana pelo ECG. Os que são utilizados mais intensamente, quando se trata de autenticação de acesso, são a impressão digital e a íris (CHAN et al., 2008).

Um comparativo entre dois métodos de redução de características: PCA e LDA foi apresentado por Boumbarov et al. (2009). Para classificação, foi utilizada uma rede neural de função base radial. Para treinamento da rede neural, foram usados os dados de ECG de 9 pessoas com 20 ciclos cardíacos e, para teste, outros 20 ciclos cardíacos das mesmas pessoas, obtendo-se 94% de classificação.

A comprovação de que é possível realizar a identificação de uma pessoa a partir de ECG captado nos dedos da mão foi dada por Chan et al. (2006). O reforço do quanto esta técnica é poderosa, sendo uma parte da autenticação multimodal, veio com Shen et al. (2011) que adquiriram os sinais de ECG a partir das palmas das mãos.

O Quadro 1 apresenta alguns trabalhos desenvolvidos para identificação de pessoas pelo ECG. Nele, são organizados os trabalhos por ano, sendo os mais importantes aqueles que utilizaram um maior número de pessoas e obtiveram

resultados acima de 90% como o trabalho de Lugovaya (2005), Chan et al. (2006), Zhang e Wei (2006) e Shen et al. (2011).

Ano	Estudo	Nº de Indivíduos	Nº de derivações	Nº de gravações de ECG	Recurso	Método de redução	Classificador	Desempenho
2001	Biel et al.	20 (20-55 anos)	12	135 (dias diferentes)	Amplitude das ondas dos batimentos cardíacos e intervalo de duração (N=30)		Modelagem independente flexível por analogia de classe (SIMCA) (Análise multivariada) + PCA (Análise dos componentes principais)	98%
2002	Shen et al.	20	1	20	QRS e amplitude da onda T e intervalo de duração (N=7)		Casamento de modelos (TM) + Rede neural baseada em decisão (DBNN)	TM: 95% DBNN: 80% Ambas: 100%
2003	Yi	9 (22-28 anos)	Wireless, 30 minutos de duração	18(dias diferentes)	Coefficientes da decomposição Wavelet de fragmentos do ECG sucessivos com 10s	Análise dos componentes principais (PCA)	Rede neural probabilística	95%
2005	Lugovaya	90 (13-75 anos)	1	210 (diferentes dias durante 6 meses)	Complexo QRS, ondas P e T (N=250)	(PCA) e Transformada Wavelet	Análise discriminante linear (LDA) e Classificador do voto majoritário	96%
2005	Saechia et al.	2	1 período (80vezes/min)	2	Complexo QRS, ondas P e T	Transformada de Fourier (todo o período normalizado e subsequências da normalização)	Rede neural	Melhor resultado subsequência da normalização
2005	Qibin Zhao e Liqing Zhang	6	1	6	Complexo QRS, ondas P e T (N=300)	Transformada de Wavelet e Modelagem	Support Vector Machine	99.68%
2006	C. Chan et al.	60	1 (2 eletrodos um em cada polegar)	60	Complexo QRS, ondas P e T	Transformada Wavelet	Coefficiente de correlação e medida da distância wavelet	90.8%
2006	Plataniotis et al.	14	12	14 (118 dias)	Autocorrelação (normalização com 5 segundos)	Transformada de cosseno discreta	Normalized euclidean distance e Normalized gaussian log likelihood	NED: 92.86% NGLL: 100%

Ano	Estudo	Nº de Indivíduos	Nº de derivações	Nº de gravações de ECG	Recurso	Método de redução	Classificador	Desempenho
2006	Wang et al.	13	12	13	Complexo QRS, ondas P e T	Método passo a passo (SPSS)	Análise discriminante linear (LDA)	100%
2006	Zhang e Wei	60	12	502	Complexo QRS e amplitude da onda T e intervalo de duração (N=14)	Análise dos componentes principais (PCA) N=9	Teorema de Bayes	97.4%
2008	Agrafioti e Hatzinakos	27	1	27	Normalização usando autocorrelação (AC). Janela de 5 segundos (506 janelas)	DCT (Transformada de cosseno discreto) e LDA (Análise discriminante linear)	AC/DCT com e Template matching (TM) e AC/LDA com e Template matching (TM)	AC/DCT: 88.9 e 96.3% AC/LDA: 96.6% e 100%
2008	Chan et al.	50	2 eletrodos (dedos da mão)	150 (dias diferentes)	Complexo PQRST		Diferença percentual residual (PRD), coeficiente de correlação (CCORR) e Medida de distância wavelet (WDIST)	PRD: 75% CCORR: 82% WDIST: 95%
2008	Chiu et al.	45 (35 ECG normal e 10 ECG com arritmia)	Lead II e Lead V1	45 (2 minutos, 1 para treinamento e outro para	QRS, Sinal de síntese e Cálculo dos coeficientes wavelet pela Transformada wavelet discreta		Medição da distância euclidiana	100% ECG normal e 81% ECG com arritmia
2008	Gahi et al.	16		16 (2 minutos)	24 características (P, PQ, QRS, QT, T e RR) amplitudes das ondas P, R e T	Classificador baseado na distância de Mahalanobis (N=9)	Classificador baseado na distância de Mahalanobis	100%
2011	Shen et al.	168 (19-52 anos)	1	168	Complexo QRS e amplitude da onda T e intervalo de duração (N=17)		Classificação de distância LDA+ Casamento de modelos (TM)	95.3%

Ano	Estudo	Nº de Indivíduos	Nº de derivações	Nº de gravações de ECG	Recurso	Método de redução	Classificação	Desempenho
2012	Pal e Mitra	20	1	20	Complexo QRS, ondas P e T (N=16)	Análise dos componentes principais (PCA) e Transformada Wavelet	Método do vizinho mais próximo (ANN) + Algoritmo de ajuste da curva quadrática	95%
2012	Chen et al.	47	2	48	Complexo QRS, ondas P e T (N=256)	Máquinas de vetores de suporte estatístico	Rede Neural	75-90%
2013	Pathoumvanh et al.	10	1	10	Transformada Wavelet contínua	Análise do discriminante linear (LDA)	Distância euclidiana normalizada	97%
2014	Wu e Zhang	33	1	33	Complexo QRS (N=7)	Análise dos componentes principais (PCA)	Rede neural por retro propagação	99.64%

Quadro 1 – Trabalhos que utilizaram o ECG para identificação de pessoas.
Fonte: Autoria própria.

3 MÉTODOS DE PROCESSAMENTO E EXTRAÇÃO DE CARACTERÍSTICAS DE SINAIS DE ECG

Os dados coletados de eletrocardiogramas (ECG), na maioria das vezes, contêm ruídos que incluem principalmente componentes de baixa frequência, como flutuações na linha de base, e componentes de alta frequência, como a interferência da contração muscular. Geralmente a presença de ruído compromete o sinal, fazendo com que a extração de características e a classificação sejam menos precisas (WANG; PLATANIOTIS; HATZINAKOS, 2006).

Além disso, o sinal original de ECG é uma matriz unidirecional, longa e redundante sendo necessário extrair as características relevantes (CHIU; CHUANG; HSU, 2008). Com a extração das características é possível reduzir a dimensão do sinal e salientar as diferenças entre as amostras, que facilita a identificação quando empregado em um sistema de classificação de padrões (como na utilização das redes neurais artificiais).

A seguir, são apresentados alguns métodos usados no pré-processamento, processamento e extração de características.

3.1 TRANSFORMADA WAVELET

A Transformada *Wavelet* (WT – *Wavelet Transform*) é uma ferramenta que fragmenta dados ou funções ou operadores em diferentes componentes de frequência e, em seguida, analisa cada componente com uma resolução associada à sua escala (DAUBECHIES, 1992).

A Transformada *wavelet* tem sido empregada em diversas áreas, tais como: análise de imagem, sistemas de comunicação, imagens biométricas, radar, acústica, matemática teórica, sistemas de controle e outras áreas de processamento de sinal (YOUNG, 1993).

A análise temporal é realizada pela contração e a análise de frequência pela dilatação da mesma função de análise que consiste na adoção de uma função *wavelet*, também chamada *wavelet* mãe. Portanto, o sinal original ou função pode ser representada em termos de uma expansão (usando coeficientes em uma combinação linear de funções *wavelet*), pode-se executar as operações de dados com base nos

coeficientes correspondentes. É importante encontrar funções base *wavelets* apropriadas que tenham correlação com o sinal a ser analisado. Em seguida, os índices de correlação serão os coeficientes compactos do sinal (RIOUL; VETTERLI, 1991).

Existem duas formas da transformada: a contínua e a discreta. A transformada *wavelet* contínua é de grande interesse teórico, principalmente para a derivação e compreensão das propriedades matemáticas das funções *wavelets*. Entretanto, a sua discretização é necessária para aplicações práticas, como por exemplo, quando se pretende descrever um sinal unidimensional em uma representação bidimensional ou quando se tem a necessidade de se inverter uma operação (SILVA, 2008).

Considerando-se uma função $f(t)$, pode ser realizada a generalização para sinais ou imagens bidimensionais $f(x, y)$. Quando uma função $f(t)$ é escalonada:

$$f(t) \rightarrow f(at), \text{ onde } a > 0, \quad (3.1)$$

sendo a fator de escala. Então, se $a > 1$ $f(at)$ é uma versão comprimida (reduzida) do sinal $f(t)$ e se $0 < a < 1$, $f(at)$ é uma versão dilatada (ampliada) do sinal. A Transformada *Wavelet* Contínua (CWT – *Continuous Wavelet Transform*) pode ser escrita como (RIOUL; VETTERLI, 1991):

$$CWT(b, a) = \frac{1}{\sqrt{a}} \int x(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (3.2)$$

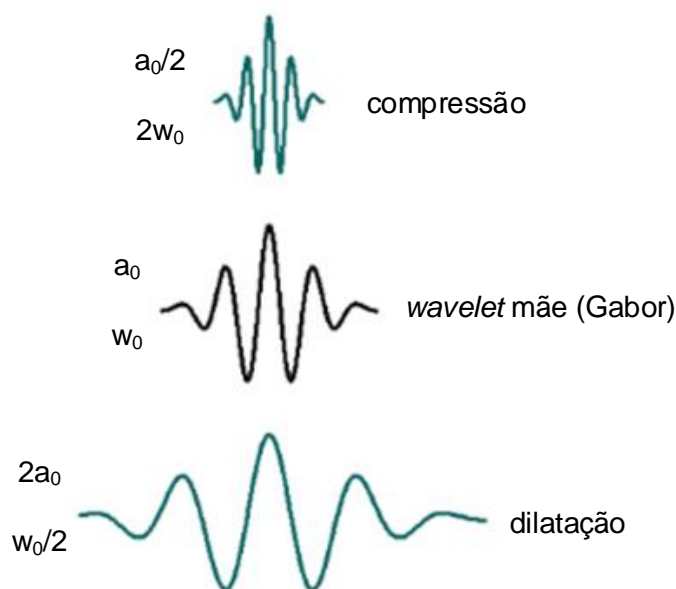
em que $*$ indica o conjugado complexo, $x(t)$ refere-se ao sinal, $a, b \in \mathbb{R}$, $a \neq 0$, o parâmetro b representa o deslocamento no tempo, a o fator de escala ($a > 1$ corresponde a dilatação e $0 < a < 1$ para contração de $\psi(t)$). Na Equação (3.2), com

o aumento da escala, $\psi \left(\frac{t-b}{a} \right)$ torna-se escalonada no tempo, e leva apenas em consideração o comportamento de tempo prolongado. O fator de multiplicação $1/\sqrt{a}$ é para normalização da energia através das diferentes escalas. A CWT também pode ser representada pela troca de variável, como

$$CWT(b, a) = \sqrt{a} \int x(at) \psi^* \left(t - \frac{b}{a} \right) dt \quad (3.3)$$

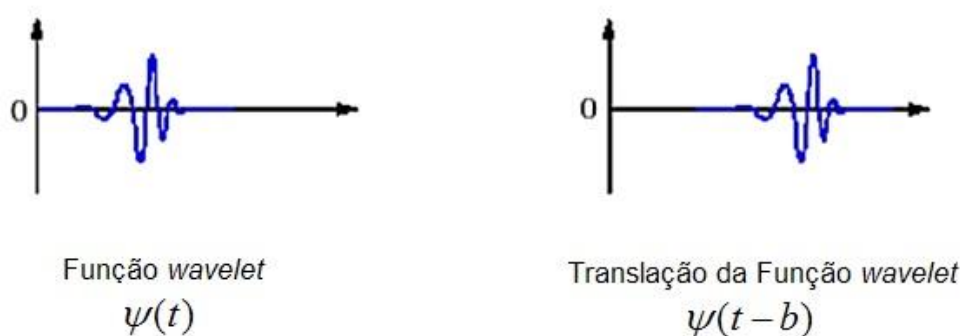
De forma equivalente, a Equação (3.3) indica que, à medida que a escala cresce, uma versão contraída do sinal é vista através de um filtro de comprimento constante. Isto é, o fator de escala a tem a interpretação da escala em mapas.

Escalas muito grandes significam visões globais, enquanto escalas muito pequenas significam visões locais. Na Figura 8, é ilustrado um exemplo de dilatação e compressão de uma *wavelet* (RIOUL; VETTERLI, 1991). Nota-se que o fator de escala a_0 é responsável pela alteração do sinal.



**Figura 8 – Exemplo de dilatação e compressão da *wavelet* (w_0 - frequência do sinal).
Fonte: Malegori e Ferrini (2010).**

Na Figura 9, ilustra-se a translação “ b ”.



**Figura 9 – Translação de uma *wavelet* em b unidades.
Fonte: Gutierrez (2002).**

Os coeficientes da Transformada *Wavelet* Contínua (*CWT*) servem para medir a semelhança entre o sinal (x) e uma função *wavelet* em diferentes escalas (a) e translação temporal (b). Sendo assim, esta função deve satisfazer várias exigências como a similaridade entre $\psi(t)$ e o sinal $x(t)$. É também desejável que $\psi(t)$ seja simétrico (resposta de fase linear dos filtros) (MALLAT, 2009).

Para que uma função seja considerada uma *wavelet* é preciso satisfazer as seguintes condições básicas:

1. Que $\psi(t) \in L^2(\mathfrak{R})$, ou seja, a função pertença ao espaço das funções de quadrado integrável ou, ainda, o espaço das funções de energia finita, no sentido que:

$$\int_{-\infty}^{+\infty} |\psi(t)|^2 dt < \infty. \quad (3.4)$$

Que sua Transformada de Fourier $\hat{\psi}(\omega)$ satisfaça a condição de admissibilidade, mantendo a conservação de energia de acordo com o teorema provado pelo matemático Calderón; este define uma transformação *wavelet* como um operador de convolução que decompõe a identidade (MALLAT, 2009):

$$C_\psi = \int_{-\infty}^{\infty} \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < \infty. \quad (3.5)$$

Segue da condição de admissibilidade que:

$$\lim_{\omega \rightarrow 0} \hat{\psi}(\omega) = 0. \quad (3.6)$$

Assim, se $\hat{\psi}(\omega)$ é contínua então, $\hat{\psi}(0) = 0$, ou seja,

$$\int_{-\infty}^{\infty} \psi(t) dt = 0. \quad (3.7)$$

O sinal reconstruído pela Transformada *wavelet* inversa será:

$$x(t) = \frac{1}{C_\psi} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} CWT(b, a) \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) db \frac{da}{a^2} \quad (3.8)$$

A Equação (3.5) estabelece que o gráfico de $\psi(t)$ deve oscilar de modo a anular a integral Equação (3.7) (DAUBECHIES, 1992).

Desde que $\psi(t)$ esteja bem localizada no tempo, este decaimento será muito rápido, formando uma onda de curta duração.

Atualmente, existem inúmeras funções *wavelets* que geralmente recebem o nome de seus proponentes (Quadro 2).

Neste trabalho foi utilizado a família *wavelet* de Daubechies (db) que é a escolha mais adequada para a análise do sinal de Eletrocardiograma (ECG) devido a sua similaridade (MAHMOODABADI et al., 2005).

Nome da família <i>wavelet</i>	Abreviação
Haar	haar
Daubechies	db
Symlets	sym
Coiflets	coif
BiorSplines	bior
ReverseBior	rbio
Meyer	meyr
DMeyer	dmey
Gaussian	gaus
Mexican_hat	mexh
Morlet	morl
Complex Gaussian	cgau
Shannon	shan
Frequency B-Spline	fbsp
Complex Morlet	cmor
Fejer-Korovkin wavelets	fk

Quadro 2 – Famílias *wavelet*.
Fonte: MathWorks (2016).

As famílias *wavelets* comumente utilizadas para os sinais do eletrocardiograma (ECG) são apresentadas nas Figura 10 e Figura 11.




Figura 10 – Família *wavelet* de Daubechies.
Fonte: MathWorks (2016b).




Figura 11 - Família *wavelet* Biorthogonal.
Fonte: MathWorks (2016b).

3.1.1 Transformada Wavelet Discreta (DWT)

A Transformada *Wavelet* Discreta (DWT – *Discrete Wavelet Transform*) aceita sinais contínuos e aplica somente mudanças discretas e escaladas para realizar a transformação. Portanto, se o sinal original é amostrado com um conjunto apropriado de escalas e deslocamentos, todo o sinal contínuo pode ser reconstruído a partir da DWT (NAJARIAN; SPLINTER, 2012). Inicia-se a análise com o fornecimento das equações para a DWT (DAUBECHIES, 1992):

$$\begin{aligned} a &= a_0^j, & j &= 1, 2, 3, \dots \\ b &= kb_0 a_0^j & k &= 1, 2, 3, \dots \text{estabelecido } j. \end{aligned} \quad (3.9)$$

Onde:

b_0 é o intervalo de amostragem (diferente de zero);

a_0 é uma constante positiva diferente de zero;

j são os passos na escala discreta;

k são os passos das translações discretas.

A família de *wavelets* de interesse, para $j, k \in \mathbb{Z}$, torna-se então:

$$\psi_{jk}(t) = \frac{1}{\sqrt{a_0^j}} \psi\left(\frac{t - kb_0 a_0^j}{a_0^j}\right) = a_0^{-j/2} \psi(a_0^{-j} t - kb_0) \quad (3.10)$$

onde $\psi(t)$ é *wavelet* mãe contínua. Para a Transformada *wavelet* discreta, os valores de escalas são definidos positivo $a_0 > 0$, a_0 é fixo e j corresponde às diferentes larguras das *wavelets*. O passo da translação é proporcional à escala $b = kb_0 a_0^j$, b_0 é fixo e k corresponde as translações das *wavelets* através do tempo. Então, os coeficientes da DWT são calculados como:

$$DWT_{jk} = \int_{-\infty}^{+\infty} x(t) \psi_{jk}^*(t) dt \quad (3.11)$$

A Equação (3.11) proporciona um conjunto finito de coeficientes discretos diretamente a partir de um sinal contínuo (NAJARIAN; SPLINTER, 2012).

Através da seleção cuidadosa de a_0 e b_0 , a família *wavelets* mãe dilatada constitui uma base ortonormal de $L^2(\mathbb{R})$. A escolha mais simples de a_0 e b_0 são $a_0 = 2$ e $b_0 = 1$. Com isso, a transformada *wavelet* é chamada de transformada *wavelet* diádica ortonormal (SANTOSO et al., 1996) e a Equação (3.10) torna-se:

$$\psi_{jk}(t) = 2^{-j/2} \psi(2^{-j} t - k) \quad (3.12)$$

Existem várias implicações da adoção da base ortonormal. A primeira é que não haverá nenhuma redundância de informação entre os sinais decompostos devido as propriedades ortonormais. A segunda é a possibilidade de decomposição do sinal em escalas com diferentes resoluções no tempo e na frequência (DAUBECHIES, 1992).

A técnica de decomposição do sinal em multiresolução decompõe um determinado sinal $x(t)$ em suas versões de detalhes e aproximações, ilustrada pela Figura 12.

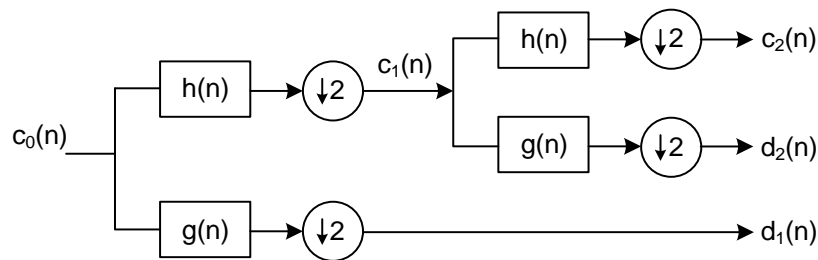


Figura 12 – Decomposição do $c_0(n)$ em 2 escalas.
Fonte: MathWorks (2016)².

A Figura 12 mostra a decomposição do sinal $c_0(n)$ em aproximações e detalhes usando-se filtros $h(n)$ e $g(n)$, respectivamente. Estes filtros determinam a *wavelet* usada para analisar o sinal de $c_0(n)$. A escolha de $h(n)$ e $g(n)$ resulta em uma família de funções escala $\phi(t)$ e *wavelet* $\psi(t)$, de modo que

$$\phi(t) = \sqrt{2} \sum_n h(n) \phi(2t - n) \quad (3.13)$$

$$\psi(t) = \sqrt{2} \sum_n g(n) \phi(2t - n) \quad (3.14)$$

A partir da técnica de decomposição do sinal em multiresolução, os sinais decompostos para escala 1 são definidos como:

$$c_1(n) = \sum_k h(k - 2n) c_0(k) \quad (3.15)$$

$$d_1(n) = \sum_k g(k - 2n) c_0(k) \quad (3.16)$$

Onde:

$c_1(n)$ - coeficiente da DWT que representa a versão aproximada do sinal original;

$d_1(n)$ - coeficiente da DWT que representa a versão detalhada do sinal original $c_0(n)$;

$h(n)$ - são os coeficientes do filtro passa-baixa associado que decompõe $c_0(n)$ em $c_1(n)$;

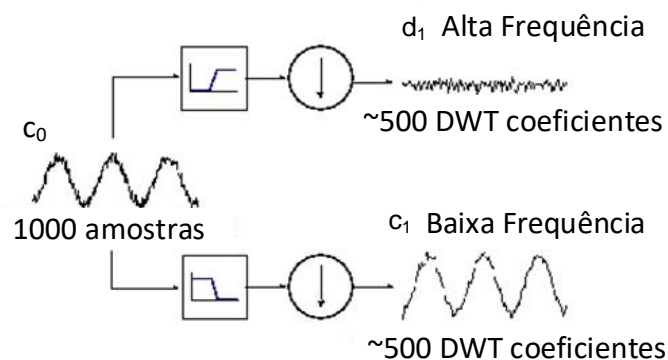
$g(n)$ - são os coeficientes do filtro passa-alta associado que decompõe $c_0(n)$ em $d_1(n)$.

Após o sinal $c_0(n)$ ser filtrado por $h(n)$ e $g(n)$, é então decimado por um fator de 2 (reamostragem com metade da taxa) conforme as Equações (3.15) e (3.16),

² Imagem obtida com base na documentação do *Matlab*® disponível em: <http://www.mathworks.com/help/wavelet/ref/wavedec.html>.

respectivamente. O sinal resultante $c_1(n)$ é uma versão aproximada do sinal original $c_0(n)$, pois o filtro $h(n)$ tem uma resposta de frequência passa-baixa. O sinal $d_1(n)$, pode ser obtido através da diferença entre o sinal original $c_0(n)$ e o sinal aproximado $c_1(n)$. Portanto $c_1(n)$ contém os detalhes removidos do sinal aproximado (SANTOSO et al., 1996).

Para ilustrar o processo de decomposição, é apresentado um estágio da transformada *wavelet* discreta do sinal c_0 . O sinal é composto de uma senoide pura adicionada a um ruído de alta frequência, como mostra a Figura 13.



**Figura 13 – Diagrama esquemático da decomposição *wavelet* do sinal c_0 .
Fonte: MathWorks (2016d).**

Note que os coeficientes do detalhe d_1 são compostos principalmente por ruídos de altas frequências, enquanto que os coeficientes de aproximação c_1 contém menos ruído se comparados ao sinal original.

As resoluções temporais de $c_1(n)$ e $d_1(n)$, devido à decimação por um fator de 2, são metade do $c_0(n)$. Portanto, se $c_0(n)$ tem N amostras para o tempo de observação, então os sinais $c_1(n)$ e $d_1(n)$ terão $N/2$ amostras para o mesmo período.

A próxima ordem da escala de decomposição é agora baseada no sinal $c_1(n)$. A decomposição do sinal para escala 2 é dada por:

$$c_2(n) = \sum_k h(k-2n)c_1(k) \quad (3.17)$$

$$d_2(n) = \sum_k g(k-2n)c_1(k) \quad (3.18)$$

É também possível realizar a união dos sinais decompostos para formar o sinal original sem perdas de informação. Este processo é chamado de “reconstrução ou síntese”.

A reconstrução consiste em interpolar o sinal por um fator de 2 colocando zeros entre cada amostra. Depois, o sinal é filtrado utilizando os filtros passa baixa e passa alta inversos (RIOUL; VETTERLI, 1991), como ilustrado na Figura 14.

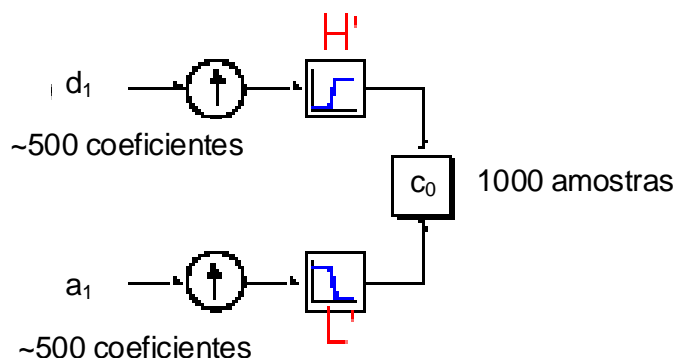


Figura 14 – Diagrama esquemático da Reconstrução wavelet do sinal c_0 .
Fonte: MathWorks (2016e).

O símbolo \uparrow indica *upsampling*, processo de alongamento dos componentes do sinal por inserção de zeros entre os coeficientes *wavelets* obtidos na decomposição (DAUBECHIES, 1992).

3.2 ANÁLISE DOS COMPONENTES PRINCIPAIS (PCA)

Análise de componentes principais (PCA - *Principal Component Analysis*) é uma técnica estatística cujo objetivo é comprimir os dados de um grande conjunto de variáveis correlacionadas em algumas variáveis ("componentes principais"), sem descartar a variabilidade presente neste conjunto (JOLLIFFE, 2006).

Os componentes principais são derivados de uma combinação linear das variáveis do conjunto de dados, com pesos escolhidos de modo que os componentes principais são mutuamente não correlacionados (CASTELLS et al., 2007).

A variância em um pequeno número de componentes principais, proporciona uma razoável caracterização do conjunto de dados completo. Ou seja, reduz a dimensão do sinal sem grandes perdas na informação disponível (SMITH, 2002).

O objetivo da análise do componente principal é identificar a base mais significativa para efetuar a projeção do conjunto de dados. A esperança é que esta

nova base filtre o ruído e revele a estrutura oculta. Determinar este fato permite para um experimentador discernir quais dinâmicas são importantes, redundantes ou ruídos (SHLENS, 2014).

O PCA é uma das técnicas mais antigas e amplamente utilizada para transformação de dados para análise multivariada, é definido matematicamente como uma transformação linear ortogonal que transforma os dados em um novo sistema de coordenadas, de modo que a maior variância, através de qualquer projeção dos dados, trata de posicionar sobre a primeira coordenada (chamado de primeiro componente principal) a segunda maior variância na segunda coordenada, e assim por diante (PAL; MITRA, 2012).

Seja \mathbf{X} uma matriz de dados contendo N observações e M amostras, onde cada x_{ij} tem $1 \leq i \leq N$ e $1 \leq j \leq M$, como mostra a Equação (3.19), onde cada linha possui um conjunto de dados.

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1M} \\ x_{21} & x_{22} & \cdots & x_{2M} \\ \vdots & \vdots & \cdots & \vdots \\ x_{N1} & x_{N2} & \cdots & x_{NM} \end{bmatrix} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_N \end{bmatrix} \quad (3.19)$$

onde:

$$x_i = [x_{i1} \quad x_{i2} \quad \cdots \quad x_{im}], \quad i = 1, \dots, N \quad (3.20)$$

É essencial que os componentes do PCA sejam mutuamente correlacionados, e exista alguma redundância em \mathbf{X} , tornando possível sua compressão. Se os componentes são independentes, nada pode ser conseguido pelo PCA (HYVÄRINEN; KARHUNEN; OJA, 2004).

Antes de aplicar a técnica é necessário subtrair a média de cada um dos conjunto de dados (SMITH, 2002). Desta forma, a média é obtida pela equação a seguir:

$$e_i = \frac{1}{M} \sum_{j=1}^M x_{ij}, \quad i = 1, \dots, N \quad (3.21)$$

$$\mathbf{e} = [e_1 \quad e_2 \quad \cdots \quad e_N]$$

onde N refere-se à quantidade de observações, e_i é média para cada observação e \mathbf{e} o vetor de médias das observações.

Para cálculo da média, o resultado obtido na Equação (3.21) é replicado para cada amostra do conjunto de dados de comprimento M , tornando possível a subtração, que é dada por:

$$\mathbf{Xm} = \mathbf{X} - \mathbf{E} \quad (3.22)$$

sendo:

$$\mathbf{E} = \mathbf{e} \cdot \begin{bmatrix} 1 & \cdots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \cdots & 1 \end{bmatrix}_{NxM}$$

na qual \mathbf{Xm} é a nova matriz de dados com média igual a zero.

Após realizar a subtração da média, parte-se para a obtenção da matriz de covariância, calculada a partir da Equação (3.23):

$$\mathbf{C}_x = \frac{1}{M-1} \mathbf{XmXm}^T \quad (3.23)$$

Pode-se sumarizar várias propriedades de \mathbf{C}_x :

- \mathbf{C}_x é uma matriz quadrada simétrica $N \times N$.
- \mathbf{C}_x capta a covariância entre todos os possíveis pares de medições. Os valores de covariância refletem o ruído e redundância nessas medições.
- Nos termos fora da diagonal, grandes magnitudes correspondem a redundâncias elevadas (SHLENS, 2014).

A matriz de dados \mathbf{Xm} é formada por $N \times M$ elementos, na qual cada linha é uma única amostra (ou momento no tempo) do conjunto de dados e seja \mathbf{Y} outra matriz $N \times M$ relacionada por uma transformação linear \mathbf{P} . A matriz \mathbf{Xm} representa os dados originais e \mathbf{Y} é uma nova projeção do referido conjunto de dados, de acordo com a Equação (3.24):

$$\mathbf{Y} = \mathbf{P}^T \mathbf{Xm} \quad (3.24)$$

A Equação (3.24) representa uma mudança de base e, portanto, pode-se dizer que \mathbf{P} é uma matriz que transforma \mathbf{Xm} em \mathbf{Y} .

Com a matriz diagonal de \mathbf{P} e com a matriz de covariância \mathbf{C}_x , obtemos a matriz diagonal dos autovalores:

$$\mathbf{P}^T \mathbf{C}_x \mathbf{P} = \mathbf{\Lambda} \quad (3.25)$$

A decomposição dos autovalores e autovetores é expressa como:

$$\mathbf{C}_x \mathbf{P} = \mathbf{P} \mathbf{\Lambda} \quad (3.26)$$

A matriz \mathbf{C}_x é simétrica; então \mathbf{P} é uma matriz ortonormal e os autovalores de \mathbf{C}_x são números reais.

O objetivo de diagonalizar a matriz de covariância é minimizar a redundância entre as diferentes características dos dados, de modo que não haja covariância entre os vetores da base do espaço de características. A matriz de covariância dos dados de saída é apresentada na expressão (3.27).

$$\mathbf{C}_y = \text{diag}\{\lambda_1, \lambda_2, \dots, \lambda_N\} \quad (3.27)$$

onde *diag* é a função que realiza a diagonalização da matriz, λ_1 corresponde ao autovalor que possui a maior energia do sinal.

Para \mathbf{C}_y , a seguinte expressão também é válida:

$$\mathbf{C}_y = \frac{1}{M-1} \mathbf{Y}\mathbf{Y}^T \quad (3.28)$$

As colunas de \mathbf{P} consistem nos autovetores de \mathbf{C}_x .

Os autovalores são soluções de um polinômio com grau N . O passo final é encontrar os autovetores correspondentes aos autovalores e classificá-los em ordem decrescente em termos energéticos. A base original possui dimensão $N \times N$. Enquanto que, a nova base possui dimensão reduzida $N \times L$ ($L \ll N$). Os componentes com energia insignificante, normalmente, são omitidos. Assim, o PCA é um método que oferece a possibilidade de realizar retroprojeção dos dados em direções ortogonais de modo a minimizar o Erro Quadrado Médio (EQM) entre a projeção e o sinal original (BOUMBAROV; VELCHEV; SOKOLOV, 2009).

4 REDES NEURAIS ARTIFICIAIS

O cérebro é considerado o mais fascinante e complexo órgão do corpo humano, responsável em propiciar os mais diversos tipos de sentimentos, sensações, reações e ações corporais. Ele está no centro de uma vasta e complexa rede de comunicação que constantemente busca e colhe informações provenientes do restante do corpo e do mundo externo (CARTER et al., 2012). À medida que o cérebro interpreta essas informações, ele gera experiências como visões e sons, emoções e pensamentos.

O cérebro é formado por bilhões de neurônios que processam informações de forma contínua e paralelamente. Sua rede de neurônios, que se comunicam entre si, tem a capacidade de reconhecer padrões e relacioná-los, usar e armazenar conhecimento (BRAGA, 2000).

Os neurônios estão conectados uns aos outros por meio das sinapses, e juntos formam uma grande rede, chamada rede neural. Embora as informações, ou potenciais de ação sejam elétricos, o modo de transmissão entre as células é químico – os sinais são passados adiante por substâncias chamadas de neurotransmissores (CARTER et al., 2012). Na Figura 15, é apresentado o modelo de um neurônio biológico e suas partes componentes.




Figura 15 – O neurônio biológico.
Fonte: Martins (2012).

Conforme a Figura 15, em geral, os dendritos recebem sinais nervosos e os axônios os enviam adiante. O potencial de ação recebido pelo dendrito é conduzido até o corpo celular, que em seguida passa pelo axônio que é polarizado em repouso. O potencial se propaga enquanto ele se despolariza até chegar à sinapse com o

próximo neurônio (CARTER et al., 2012). As diversas ligações sinápticas do corpo celular de um neurônio para outro formam uma rede disposta em camadas.

A estrutura individual dos neurônios, sua topologia de conexões e o comportamento conjunto serviram de alicerce para inspiração das Redes Neurais Artificiais.

As redes neurais artificiais ou RNAs, também conhecidas como redes conexionistas são sistemas de processamento paralelo e distribuído, os quais tentam reproduzir de forma simplificada as funções das redes biológicas, buscando implementar seu comportamento básico e sua dinâmica. Tanto as redes neurais biológicas quanto as redes neurais artificiais são baseadas em unidades de processamento que se comunicam por meio de conexões sinápticas e possuem detectores de características, redundância e modularização das conexões (HAYKIN; ENGEL, 2001).

As RNAs são formadas por uma ou mais camadas e são interligadas por um grande número de conexões, normalmente unidirecionais. Na grande maioria dos modelos, estas conexões estão associadas a pesos, os quais armazenam o conhecimento e ponderam as entradas recebidas de cada neurônio da rede. A forma como os seus diversos neurônios são arranjados ou distribuídos, uns em relação aos outros, é denominado de arquitetura de rede. Esta possui um papel muito importante, pois é o fator preponderante que limita o tipo de problema que pode ser tratado pela mesma (BRAGA, 2000). Já a topologia de uma RNA é definida como sendo as diferentes formas de composição estruturais que a arquitetura de rede pode assumir (SILVA; SPATTI; FLAUZINO, 2010).

Segundo Haykin e Engel (2001), o procedimento usual para aplicação de uma RNA na solução de problemas passa inicialmente por uma fase de aprendizagem, por meio de um algoritmo de treinamento, cuja função é modificar os pesos sinápticos da rede para alcançar um objetivo de projeto.

Para Braga (2000), o que faz da RNA um atrativo para solução de problemas é sua capacidade de aprender através de exemplos e de generalizar a informação recebida, ou seja, aprender com um conjunto reduzido de exemplos e, posteriormente, dar respostas adequadas para dados desconhecidos. Esta é uma demonstração de que a capacidade das RNAs vai muito além de simplesmente mapear relações de entrada e saída.

E ainda, segundo Cybenko (1989), as RNAs alimentadas adiante de apenas uma camada oculta, com um número suficiente de neurônios, são capazes de atuar como aproximadores universais de funções multivariáveis, com custo computacional que cresce apenas linearmente com o número de variáveis. Outra característica importante é a capacidade de auto-organização e de processamento temporal, que faz das RNAs uma ferramenta computacional extremamente poderosa e atrativa para a solução de problemas complexos.

4.1 MODELOS DE NEURONIOS ARTIFICIAIS

O primeiro modelo de neurônio artificial foi proposto pelo psiquiatra e neuroanatomista McCulloch e o matemático Pitts em 1943. Por mais que seja um modelo de neurônio simples, a rede composta por este tipo de unidade processadora engloba as principais características de uma rede neural biológica, ou seja, paralelismo e alta conectividade (SILVA; SPATTI; FLAUZINO, 2010).

Com base nos conceitos propostos por McCulloch e Pitts, um modelo de neurônio artificial genérico é apresentado na Figura 16. Este é também um dos modelos mais utilizados nas diferentes arquiteturas (estruturas) de redes neurais artificiais.

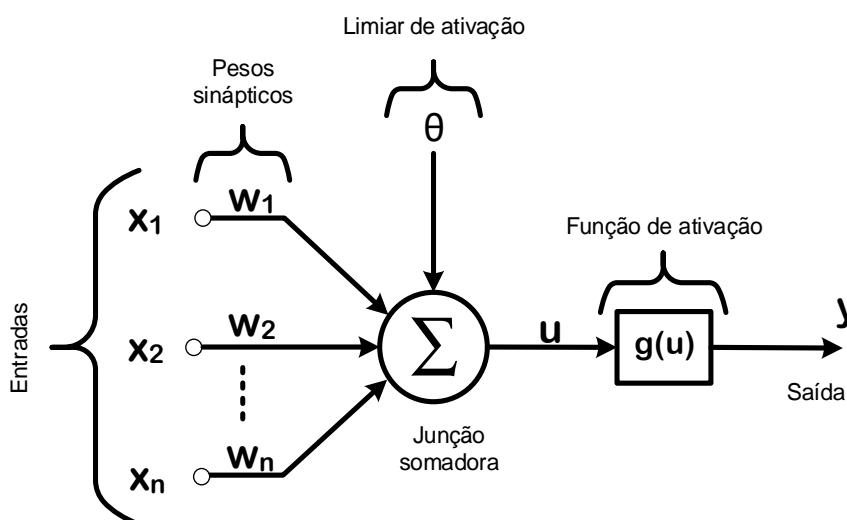


Figura 16 – Modelo de um neurônio artificial.
Fonte: Autoria própria³.

³ Modelo baseado no livro “Redes neurais: princípios e prática / Simon Haykin; trad. Paulo Martins Engel. – 2.ed. – Porto Alegre: Bookman, 2001”.

De acordo com a Figura 16, a descrição matemática é apresentada em um modelo com n terminais de entrada x_1, x_2, \dots, x_n (que representam os dendritos) e apenas um terminal de saída y (representando o axônio). As ponderações exercidas pelas junções sinápticas do modelo biológico, são representadas no neurônio artificial pelos pesos sinápticos w_1, w_2, \dots, w_n . O neurônio é então multiplicado por seu respectivo peso sináptico w_i , que pondera todas as informações externas que chegam ao mesmo (HAYKIN; ENGEL, 2001).

A junção somadora, como o próprio nome sugere, irá somar os sinais de entrada, ponderados pelos respectivos pesos do neurônio artificial. A junção de todos os sinais de entrada produz um valor de potencial de ativação, denotado por u , o qual é um combinador linear. O limiar de ativação θ , também conhecido como *bias*, é uma variável, positiva ou negativa, que irá produzir um resultado apropriado em direção à saída do neurônio. O potencial de ativação u é o resultado, da diferença ou da soma, entre o valor produzido pelo combinador linear e o limiar de ativação, de forma que, a depender do resultado, ele pode ser excitatório ou inibitório (SILVA; SPATTI; FLAUZINO, 2010).

A função de ativação $g(\cdot)$ é responsável em restringir a amplitude da saída do neurônio e, às vezes, introduzir não-linearidade ao modelo, de forma a permitir aproximações em alta dimensionalidade (SÁNCHEZ, 2011).

Matematicamente, a saída do neurônio artificial é representada através da Equação (4.1):

$$y = g(\cdot) = g\left(\sum_{i=1}^n w_i x_i + \theta\right) \quad (4.1)$$

Existem diversos tipos de funções de ativação na literatura. Em se tratando das arquiteturas de rede *Perceptron* de Múltiplas Camadas (MLP), a qual será apresentada na sequência, é necessário que ela seja não-linear e diferenciável em todos os pontos. Uma classe de funções que atende a essas características são as sigmoidais. As duas mais usuais para as MLPs são a *logística* e a *tangente hiperbólica*. A seguir são apresentadas tais funções e suas respectivas derivadas.

- 1) Função *logística*: O resultado produzido pela saída é sempre positivo, compreendido entre 0 e 1 (Figura 17). A expressão matemática é dada por:

$$g(u) = \frac{e^{au}}{e^{au} + 1} = \frac{1}{1 + e^{-au}} \quad (4.2)$$

onde a é uma constante.

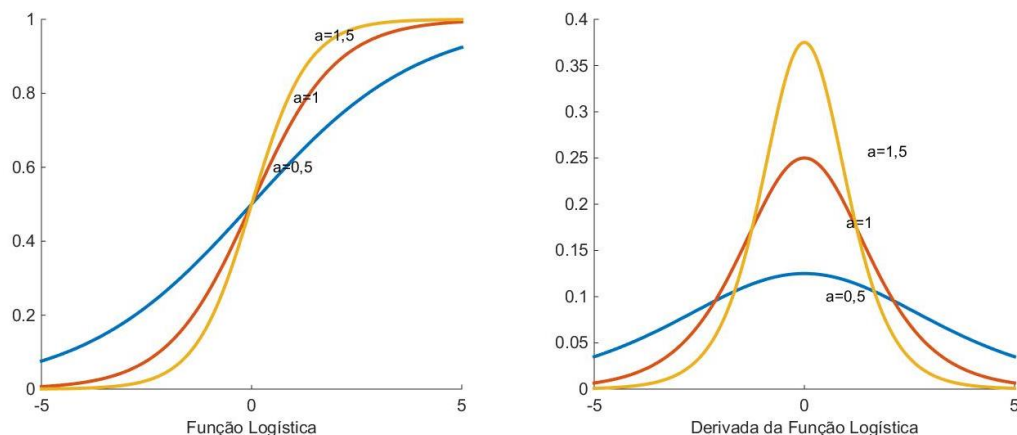


Figura 17 – Função logística e sua derivada.
Fonte: Autoria própria⁴.

2) Função tangente hiperbólica: Difere da função logística por produzir valores de saída compreendidos entre -1 e 1 (Figura 18). Representado pela equação:

$$g(u) = \tanh(u) = \frac{e^{au} - e^{-au}}{e^{au} + e^{-au}} = \frac{1 - e^{-au}}{1 + e^{-au}} \quad (4.3)$$

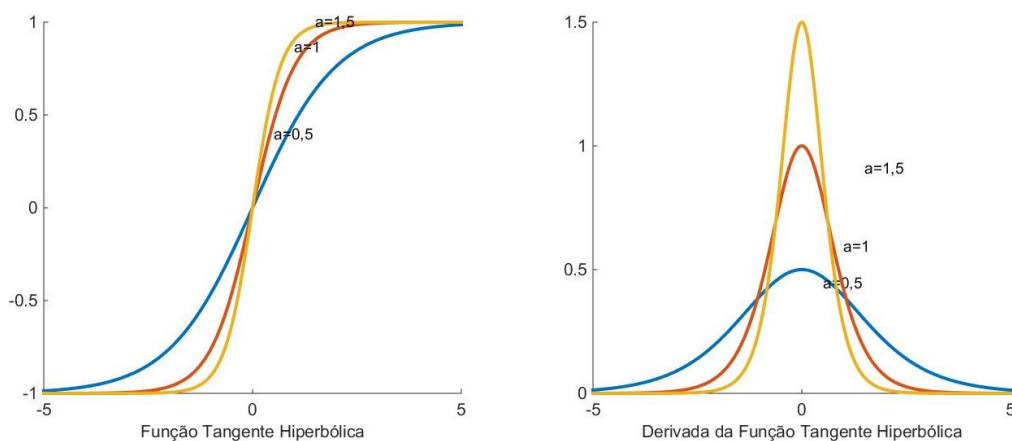


Figura 18 – Função tangente hiperbólica e sua derivada.
Fonte: Autoria própria.

4.2 TREINAMENTO DE UMA REDE NEURAL

O processo de treinamento consiste em apresentar à rede amostras que exprimem o comportamento do sistema para que este seja capaz de generalizar

⁴ Figuras 15 e 16 geradas a partir do *software Matlab®*

soluções e produzir uma saída próxima daquela esperada a partir de dados diferentes daqueles apresentados inicialmente. Ou seja, o processo de treinamento de uma rede neural consiste em alterar de forma sistemática os pesos sinápticos e limiares de seus neurônios (SILVA; SPATTI; FLAUZINO, 2010). Esse processo de adaptação dos pesos dos neurônios artificiais se assemelha aos neurônios biológicos, no qual a plasticidade sináptica permite que o sistema nervoso em desenvolvimento se adapte ao ambiente (HAYKIN; ENGEL, 2001).

Neste sentido, as redes neurais artificiais obtêm conhecimento através de um processo de aprendizagem. O conjunto preestabelecido de regras bem-definidas para a solução de um problema de aprendizagem é chamado de algoritmo de aprendizado (BRAGA, 2000).

Existem diversos métodos para treinamento de redes, que podem ser agrupados em dois paradigmas principais: aprendizado supervisionado e não-supervisionado (BRAGA, 2000).

No aprendizado supervisionado, as entradas e saídas desejadas para a rede são fornecidas. Assim, a mesma irá se ajustar de forma a encontrar uma similaridade entre a entrada e saída fornecida. É como se houvesse um “professor” ensinando qual a resposta correta para cada amostra apresentada (SILVA; SPATTI; FLAUZINO, 2010). Dessa maneira, ocorre uma comparação entre o valor que a rede produz como resposta na saída e o valor da saída desejada. Se estas forem diferentes, a RNA gera um sinal de erro, o qual culmina na determinação de uma função de custo, usada para calcular os pesos sinápticos. O objetivo do treinamento é minimizar a função custo ou reduzir o erro com base no sinal de saída.

Todavia, a forma mais usual de aprendizado foge da inspiração biológica (AZEVEDO; BRASIL; OLIVEIRA, 2000), já que se deve lançar mão de ferramentas matemáticas derivadas de técnicas de otimização irrestritas, como o método do gradiente de 1ª ordem e o método de Newton de 2ª ordem (HAYKIN; ENGEL, 2001). A soma dos erros quadráticos de todas as saídas é normalmente utilizada como medida de desempenho e, também, como função de custo a ser minimizada pelo algoritmo de treinamento (BRAGA, 2000).

Já no aprendizado não-supervisionado não existe um “professor” para orientar qual é a saída desejada para cada amostra de entrada. Muitos dos sistemas biológicos ocorrem através deste aprendizado. A rede precisa interpretar os dados através das

semelhanças entre as amostras e com isso encontrar uma relação entre elas criando grupos ou classes automaticamente (BRAGA, 2000).

A rede recebe em sua entrada excitações muito diferentes ou padrões de entrada e organiza arbitrariamente os mesmos em categorias. Quando uma informação é apresentada à rede, a mesma fornece uma resposta de saída indicando a classe à qual ela pertence. Se uma classe não pode ser encontrada para o padrão de entrada, uma nova classe é gerada (AZEVEDO; BRASIL; OLIVEIRA, 2000). Este tipo de aprendizado só se torna possível quando existe redundância nos dados, pois sem isso seria impossível encontrar quaisquer semelhanças (BRAGA, 2000).

4.2.1 Perceptron Múltiplas Camadas (MLP)

A rede *Perceptron Múltiplas Camadas* () é definida como uma rede que possui uma camada de entrada, uma ou mais camadas intermediárias (ocultas) e uma camada de saída, as quais são uma generalização do *Perceptron* de camada única (forma mais simples de uma Rede Neural Artificial, utilizada para classificação de padrões linearmente separáveis) (HAYKIN; ENGEL, 2001).

As MLPs possuem um poder computacional muito maior do que aquele apresentado por redes sem a camada intermediária. Ao contrário destas redes, as MLPs podem resolver problemas que não são linearmente separáveis. Redes com mais de duas camadas intermediárias têm a capacidade de resolver qualquer problema de mapeamento, seja ele linearmente separável ou não, desde que devidamente ajustada (BRAGA, 2000).

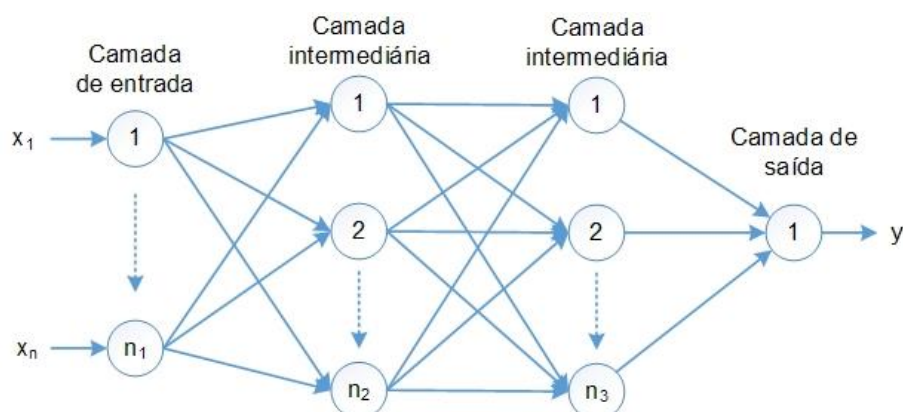


Figura 19 – Modelo de uma rede MLP.
Fonte: Silva et al. (2010).

As redes *MLPs* são ainda caracterizadas pelas elevadas possibilidades de aplicações em diversos tipos de problemas relacionados à diferentes áreas de conhecimento, entre elas: aproximação universal de funções, reconhecimento de padrões, identificação e controle de processos, previsão de séries temporais, otimização de sistemas, dentre outros (SILVA; SPATTI; FLAUZINO, 2010).

O algoritmo mais conhecido para treinamento destas redes é o método do gradiente descendente, com cálculo da derivada da função custo por meio do *back-propagation*. A maioria dos métodos de aprendizado para redes neurais artificiais do tipo MLP utiliza variações deste algoritmo, o qual usa o aprendizado supervisionado para ajustar os pesos da rede (BRAGA, 2000).

O treinamento ocorre em duas fases. A primeira fase chamada de *forward* ou “propagação adiante” é utilizada para definir a saída da rede para um dado padrão de entrada (BRAGA, 2000). Ou seja, os dados são inseridos na entrada e propagados camada a camada até a produção das respectivas saídas. Esta fase visa apenas obter as respostas da rede, os pesos e limiares de seus neurônios permanecerão inalterados durante cada execução desta etapa (SILVA; SPATTI; FLAUZINO, 2010).

A segunda fase chamada de *backward* “propagação reversa” utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões (BRAGA, 2000). Desta forma, realiza alterações nos pesos sinápticos e limiares de todos os neurônios em função dos valores de erros gerados na primeira etapa (*forward*) (SILVA; SPATTI; FLAUZINO, 2010).

O processo de treinamento das MLPs utilizando o algoritmo do gradiente descendente com o *back-propagation* é baseado na regra delta proposta por Widrow e Hoff, a qual também é conhecida como regra delta generalizada. Trata-se de um método computacional eficiente para otimização da rede (HAYKIN; ENGEL, 2001) que objetiva definir a função representativa do erro de aproximação. Este mede o desvio entre as respostas produzidas pelos neurônios de saída da rede e seus respectivos valores desejados (SILVA; SPATTI; FLAUZINO, 2010).

O sinal de erro na saída do neurônio j , na iteração k , é expresso como:

$$e_j(k) = d_j(k) - y_j(k) \quad (4.4)$$

onde d é a saída desejada e y é a saída obtida pela rede.

O erro quadrático é obtido somando-se os termos de todos os neurônios da camada de saída pela Equação (4.5):

$$E(k) = \frac{1}{2} \sum_{j \in n} e_j^2(k) \quad (4.5)$$

onde o conjunto n inclui todos os neurônios da camada de saída da rede. O erro quadrático médio (EQM) é obtido somando-se os $E(k)$ para todos os k 's e ponderando-o em relação ao tamanho do conjunto N , que representa o número total de padrões contidos no conjunto de treinamento, definido pela Equação (4.6):

$$E_m = \frac{1}{N} \sum_{j=1}^N E(k) \quad (4.6)$$

O E_m é normalmente utilizado como uma medida de desempenho da aprendizagem e também como *função de custo* a ser minimizada. O objetivo do processo é ajustar os parâmetros livres para minimizar E_m função dos pesos w .

A Figura 20 apresenta um esquema de funcionamento da MLP. A saída de cada camada da MLP é dada, em forma matricial, por:

$$\mathbf{y}^{c+1} = \mathbf{g}^{c+1}(\mathbf{w}^{c+1} \mathbf{y}^c + \boldsymbol{\theta}^{c+1}), \text{ com } c = 0, 1, \dots, C-1 \quad (4.7)$$

na qual C é o número de camadas da rede, c refere-se a camada atual. \mathbf{y}^{c+1} à saída da próxima camada. \mathbf{g}^{c+1} , \mathbf{w}^{c+1} e $\boldsymbol{\theta}^{c+1}$ são a função de ativação, matriz de pesos e vetor do limiar, respectivamente.

A Figura 20, apresenta uma MLP com 3 camadas intermediárias com suas respectivas expressões de saída em cada etapa, na qual para \mathbf{y}^1 , temos o vetor de entrada \mathbf{x} e, para \mathbf{y}^3 , a saída da rede (DE CASTRO, 2006).




Figura 20 – Exemplo de MLP com 3 camadas intermediárias.

Fonte: de Castro (2006).

O ajuste dos pesos para cada neurônio da rede, a fim de minimizar o erro quadrático médio, é alcançado empregando a definição de gradiente e explorando a regra de diferenciação em cadeia. Desta forma, tem-se:

$$\Delta E = \frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial y} \frac{\partial y}{\partial w_{ji}} \quad (4.8)$$

A derivada parcial $\frac{\partial E}{\partial w_{ji}}$ representa um *fator de sensibilidade*, determinando a direção de busca no espaço de pesos para o peso sináptico w_{ji} (HAYKIN; ENGEL, 2001).

A regra delta sugere que a atualização dos pesos para um algoritmo de primeira ordem como o gradiente seja:

$$w_{ji}^c(k+1) = w_{ji}^c(k) - \eta \frac{\partial E(k)}{\partial w_{ji}^c} \quad (4.9)$$

onde $w_{ji}^c(k+1)$ é peso do neurônio atual e $w_{ji}^c(k)$ é o peso do neurônio anterior.

A Equação (4.9) ajusta os pesos dos neurônios da camada de saída da rede através da diferença observada entre as respostas produzidas por suas saídas em relação aos seus respectivos valores desejados (SILVA; SPATTI; FLAUZINO, 2010).

A obtenção de derivadas da função $E(k)$ para cada camada é feita pela regra da cadeia, da camada mais externa até a de entrada, e η é o *parâmetro da taxa de aprendizagem* do algoritmo de retropropagação (*back-propagation*). Os índices i e j são referentes aos neurônios da rede. O uso do sinal negativo indica a descida do gradiente no espaço de pesos. A equação (4.9) pode ser reescrita como:

$$w_{ji}^c(k+1) = w_{ji}^c(k) - \eta \delta_j(k) y_i(k) \quad (4.10)$$

onde δ_j é definido como o gradiente local em relação ao j -ésimo neurônio da camada de saída é igual ao produto do sinal de erro $e_j(k)$ correspondente para aquele neurônio pela derivada da função $g'(\cdot)$ de primeira ordem com a função de ativação considerada, sendo o mesmo dado por:

$$\delta_j = e_j(k) g'(y_j) \quad (4.11)$$

As funções de ativação mais usualmente empregadas nas MLPs, como mencionado, são as do tipo sigmoidais, sendo, a tangente hiperbólica a mais utilizada. Os neurônios da camada oculta têm um papel muito importante para mapeamento de sistemas complexos, extraindo progressivamente as características mais significativas dos padrões de entrada (HAYKIN; ENGEL, 2001).

O número de neurônios na camada oculta é geralmente definido empiricamente, porém é preciso observar que um número muito elevado de neurônios pode causar o chamado *overfitting*, memorização excessiva. Neste caso, a rede se ajusta muito bem na fase de treinamento, mas, não tem capacidade de generalização frente a dados desconhecidos. Por outro lado, um número muito baixo de neurônios pode causar o chamado *underfitting* (a rede não converge durante o seu treinamento) (BRAGA, 2000).

Segundo Braga (2000), uma forma de se evitar o *overfitting* é estimar o erro de generalização durante o processo de treinamento. Para isto, o conjunto de dados é dividido em conjunto de treinamento e conjunto de validação. O primeiro é utilizado na modificação dos pesos, e o segundo para estimar a capacidade de generalização da rede durante o processo de aprendizagem.

Para Haykin e Engel (2001), a rede precisa ser bem-treinada de modo que aprenda o suficiente sobre o passado para generalizar o futuro. Neste contexto, o processo de aprendizagem se torna uma escolha, dentre um conjunto de estruturas de modelo candidatas, de parametrização da rede para determinado conjunto de dados.

O objetivo de validar o modelo com um conjunto de dados diferente daquele usado para estimar os parâmetros é evitar que a rede possa acabar ajustando excessivamente o subconjunto de treinamento. Por isso, o desempenho de generalização do modelo selecionado é medido sobre o conjunto de teste, sendo diferente dos subconjuntos de treinamento e validação (HAYKIN; ENGEL, 2001).

Um dos métodos associados à validação cruzada é o treinamento com parada antecipada. Na MLP, o treinamento com o algoritmo de retropropagação tende sempre a reduzir o erro quadrático médio com o aumento do número de iterações da rede, ou seja, ele começa com um valor relativamente grande, decresce rapidamente e então continua diminuindo lentamente conforme a rede segue seu caminho em direção a um mínimo local na superfície de erro. O objetivo, com isso é obter uma boa generalização, porém é muito difícil saber qual é o melhor momento para encerrar o treinamento apenas observando-se a curva de aprendizagem (HAYKIN; ENGEL, 2001).

Para identificar o ponto exato de parada da rede que representa a melhor capacidade de generalização, utiliza-se a validação cruzada com parada antecipada. O subconjunto de exemplos de estimação é usado para treinar a rede normalmente e

a sessão de treinamento é interrompida periodicamente para teste com o subconjunto de validação após cada período de treinamento (HAYKIN; ENGEL, 2001).

A Figura 21 mostra o comportamento do Erro Quadrático Médio (EQM) dos subconjuntos de treinamento e de validação. Nota-se que o erro de treinamento tende a diminuir com o aumento do número de iterações. Já o subconjunto de validação decresce monotonamente para um mínimo e então, começa a crescer conforme o processo continua, indicando que a rede está perdendo a capacidade de generalização por sobre ajuste ou *overfitting* (HAYKIN; ENGEL, 2001).




Figura 21 – Exemplo de instante de parada no treinamento de uma rede neural via validação cruzada.

Fonte: Autoria própria⁵.

4.2.2 Máquinas de Aprendizado Extremo (ELM)

Máquinas de aprendizado extremo (*Extreme Learning Machine* - ELM) são arquiteturas de redes *feedforward* propostas por Huang et al. (2006), que contorna os problemas encontrados por algoritmos baseados no gradiente descendente. Tal rede foi desenvolvida com somente uma camada escondida, denominada *Single Layer Feedforward Network* (SLFN) (HUANG; ZHU; SIEW, 2004).

Esta arquitetura pertence ao grupo de Rede Neural Artificial conhecido atualmente como Máquinas Desorganizadas, devido ao fato de não ajustarem a

⁵ Figura baseada no livro “Redes Neurais Artificiais para engenharia e ciências aplicadas / Ivan Nunes da Silva; Danilo Hernane Spatti; Rogério Andrade Flauzino. – São Paulo: Artliber, 2010”.

camada intermediária e, mesmo assim, tornar possível atingir bons resultados (BOCCATO et al., 2011)

Os algoritmos tradicionais de aprendizagem são geralmente lentos, podendo demorar horas ou dias para treinar a rede neural, dependendo do tamanho do conjunto de treinamento. A ELM se destaca devido ao seu custo computacional extremamente reduzido e sua essência está no uso de pesos sinápticos aleatórios na camada oculta (HUANG; ZHU; SIEW, 2004, 2006).

Na ELM, os pesos entre as camadas de entrada e intermediária (oculta) e os *bias* (limiares), são atribuídos aleatoriamente e não são ajustados no decorrer do treinamento sendo treinada apenas a camada de saída. Esta configuração resulta em um modelo linear para os pesos sinápticos da última camada (pesos de saída), os quais são analiticamente calculados por meio de uma solução de mínimos quadrados (HUANG; WANG; LAN, 2011).

Ademais, os autores provaram por meio de uma abordagem construtiva que inserção de um neurônio na camada intermediária sempre leva à redução do erro de aproximação. Dessa maneira, caso o número de amostras e de neurônios sejam iguais, o erro de saída pode ser zero. Esta prova coloca as ELMs como aproximadores universais, tal qual as MLPs e RBFs.

O problema de treinamento passa a ser linear nos parâmetros ajustáveis, o que representa uma enorme economia de recursos computacionais na realização do treinamento supervisionado, o qual resume-se em encontrar os pesos da camada de saída.

O operador generalizado de *Moore-Penrose* é sugerido para solucionar este problema, pois minimiza o erro quadrático médio entre o sinal que chega da camada intermediária e o desejado. Este é um candidato natural para cálculo dos pesos da camada de saída de uma ELM, pois não só atinge o menor erro nos conjuntos de treinamento, como também obtém menor norma dos pesos, tendendo a ter um desempenho de melhor generalização. Bartlett (1998) aponta que em redes semelhantes com o mesmo número de neurônios na camada oculta, aquela que possui menor norma dos pesos terá melhor capacidade de generalização.

É importante ressaltar que pode ser difícil para os algoritmos de aprendizagem, baseados em gradiente como *backpropagation*, alcançar o melhor desempenho de generalização, pois baseiam-se em obter os menores erros durante o treinamento sem considerar a magnitude dos pesos (HUANG; ZHU; SIEW, 2004).

Na Figura 22, é apresentada a arquitetura de uma ELM genérica com suas camadas. Embora a figura mostre apenas uma saída, esta rede admite múltiplas saídas. Esta arquitetura é semelhante à da MLP, porém não se treina a camada escondida.

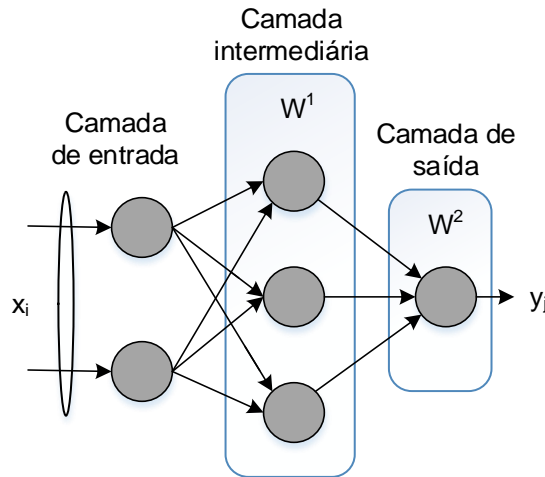


Figura 22 – Notação de uma Máquina de Aprendizado Extremo.
Fonte: Autoria própria⁶.

Para N amostras distintas (x_i, d_i) , onde $x_i = [x_{i1}, x_{i2}, x_{i3}, \dots, x_{im}]^T \in \mathbb{R}^n$ e $d_i = [d_{i1}, d_{i2}, d_{i3}, \dots, d_{im}]^T \in \mathbb{R}^m$, as redes neurais *feedforward* de única camada escondida (SLFN) com n neurônios na camada intermediária e função de ativação $g(x)$ nesses neurônios são modelados como:

$$\sum_{i=1}^n w_i^2 g_i(x_j) = \sum_{i=1}^n w_i^2 g(w_i^1 x_i + \theta_i) = y_j, \quad j = 1, 2, 3, \dots, N \quad (4.12)$$

no qual i corresponde ao índice do neurônio da camada escondida, $\mathbf{W}_i^1 = [w_{i1}^1, w_{i2}^1, \dots, w_{im}^1]^T$ os pesos gerados de forma aleatória conectando esse neurônio ao neurônio da camada de entrada, $\mathbf{W}_i^2 = [w_{i1}^2, w_{i2}^2, \dots, w_{im}^2]^T$ os pesos conectando esse mesmo neurônio para a camada de saída, θ_i o limiar desse neurônio.

As redes neurais *feedforward* de única camada escondida (SLFN) com n neurônios na camada intermediária e função de ativação $g(x)$ podem aproximar esses N exemplos com erro zero, $\sum_{j=1}^N \|y_j - d_j\| = 0$. Ou seja, existe \mathbf{W}_i^2 , \mathbf{W}_i^1 e θ_i tal que:

⁶ Figura baseada no tutorial de Guang-Bin HUANG disponível no site: <http://www.ntu.edu.sg/home/egbhuang/pdf/ELM-Tutorial.pdf>.

$$\sum_{i=1}^n w_i^2 g(w_i^1 x_i + \theta_i) = d_j, \quad j = 1, 2, 3, \dots, N \quad (4.13)$$

Essas equações podem ser escritas de forma matricial como:

$$\mathbf{H}\mathbf{W}^2 = \mathbf{d} \quad (4.14)$$

Onde:

$$\mathbf{H} = \begin{bmatrix} g(w_1^1 x_1 + \theta_1) & \cdots & g(w_n^1 x_1 + \theta_n) \\ \vdots & \ddots & \vdots \\ g(w_1^1 x_N + \theta_1) & \cdots & g(w_n^1 x_N + \theta_n) \end{bmatrix} \quad (4.15)$$

$$\mathbf{W}^2 = \begin{bmatrix} w_1^{2T} \\ \vdots \\ w_i^{2T} \end{bmatrix}_{n \times m} \quad (4.16)$$

$$\mathbf{d} = \begin{bmatrix} d_1^T \\ \vdots \\ d_N^T \end{bmatrix}_{N \times m} \quad (4.17)$$

na qual \mathbf{H} é a matriz de saída da camada oculta; \mathbf{W}^2 é a matriz de pesos da camada de saída e \mathbf{d} contém as saídas desejadas.

Treinar a ELM é equivalente a resolver o seguinte problema de otimização para cada uma das saídas da rede neural:

$$\mathbf{w}_i^* = \arg \min_{\mathbf{w}_i \in \mathcal{R}^{n+1}} \|\mathbf{w}_i\|^2 + C_i \times J(\mathbf{w}_i) \quad (4.18)$$

na qual i é o índice da saída, n é o número de neurônios na camada oculta, $\|\cdot\|^2$ é a norma euclidiana, C_i é um coeficiente de ponderação, a ser determinado.

Na ELM, os pesos que ligam camada de entrada à camada de saída são gerados aleatoriamente e permanecem inalterados. Assim, seu treinamento resume-se em encontrar \mathbf{W}^2 por meio de uma solução de mínimos quadrados que satisfaça a Equação(4.18). Se o número de neurônios escondidos for igual ao número de amostras utilizadas no treinamento, $n = N$, a matriz \mathbf{H} é quadrada e pode ser invertida por métodos clássicos e a ELM pode aproximar essas amostras de treino com erro zero.

Apesar disso, na maior parte dos casos, o valor de n é muito menor que N . Isso faz com que a matriz \mathbf{H} não seja quadrada, impossibilitando assim, calcular a sua inversa. Nesses casos, a solução pelo operador de Moore-Penrose, que garante

a norma mínima dos pesos para a solução de mínimos quadrados (BARTLETT, 1998), visto que a equação (4.14) é dada por:

$$\mathbf{W}^2 = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{d} \quad (4.19)$$

onde $\mathbf{H}^\dagger = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T$ é a pseudo-inversa de Moore-Penrose da matriz \mathbf{H} . A seguir é apresentado o pseudocódigo da ELM.

Algoritmo 1: Pseudocódigo da ELM

1. Dado um conjunto de treinamento $\mathbf{X} = \{(x_i, d_i) \mid x_i \in R^n, d_i \in R^m, i = 1, 2, \dots, N\}$, a função de ativação $g(x)$, e número de neurônios na camada escondida n .
 2. Atribua aleatoriamente valores para \mathbf{W}_i^1 e θ_i .
 3. Calcule a matriz de saída da camada escondida, \mathbf{H} .
 4. Calcule a matriz de pesos de saída \mathbf{W}^2 , onde $\mathbf{W}^2 = \mathbf{H}^\dagger \mathbf{d}$.
-

A maximização da capacidade de generalização é obtida inserindo o coeficiente de ponderação ou regularização C . Huang et al. (2012) propõem um conjunto de validação, definindo $C = 2^\lambda$ com valores para λ compreendidos entre -25 a 26, ou seja, um vetor contendo 52 elementos $C = \{2^{-25}, 2^{-24}, \dots, 2^0, \dots, 2^{26}\}$. Com isso, cada valor do coeficiente é apresentado às entradas de validação da rede, gerando uma medida de erro quadrático médio. O valor ótimo de C é aquele que minimiza o erro junto ao conjunto de validação, considerado aquele que permite a melhor generalização da rede. A correção dos pesos passa a ser:

$$\mathbf{W}^2 = \left(\frac{\mathbf{I}}{C} + \mathbf{H}\mathbf{H}^T \right)^T \mathbf{H}\mathbf{d}^T \quad (4.20)$$

na qual \mathbf{I} é a matriz identidade.

Ainda que esta rede ofereça uma boa capacidade de generalização, a escolha aleatória dos pesos sinápticos da camada oculta (pesos de entrada) pode gerar um conjunto não-ótimo de pesos e limiares, ocasionando o efeito de sobreajuste. Outro problema enfrentado é a escolha do número de neurônios ocultos e a possibilidade de diminuí-los sem afetar a eficácia do aprendizado, acarretando em diversos testes por tentativa e erro (LOUZADA; SIRAVENHA; PELAES, 2015).

Na maioria dos problemas, a aprendizagem a partir de dados usando métodos tradicionais de treinamento para a MLP (tais como *backpropagation*) envolve custo

computacional excessivo, exige também, tentativa e erro ou procedimentos de validação cruzada para a concepção da arquitetura (BUENO-CRESPO; GARCÍA-LAENCINA; SANCHO-GÓMEZ, 2013). A ELM, apesar de não existir uma metodologia para definição do número de neurônios na camada oculta, possui uma arquitetura de rede simples e velocidade de treinamento maior que a MLP (VERGARA et al., 2015).

5 MATERIAIS E MÉTODOS

O presente capítulo descreve o banco de dados de eletrocardiograma (ECG) e os métodos utilizados no processamento de sinais e reconhecimento de padrões com a finalidade de identificação de pessoas.

Para isso foi realizado o pré-processamento dos sinais e a posterior aplicação de Rede Neural Artificial Máquina de Aprendizado Extremo (ELM). Em seguida, o desempenho foi comparado ao Rede *Perceptron* Múltiplas Camadas (MLP), descrita no Capítulo 4.

Inicialmente, de posse do banco de dados de ECG, foi realizado o processo de tratamento do sinal por meio das técnicas: *Wavelet*, para correção da linha de base, e filtro *Butterworth* passa-baixa para eliminação dos ruídos (LUGOVAYA, 2005).

Após a filtragem do sinal, foi realizada a detecção das ondas R do sinal de ECG com o propósito da segmentação do sinal em ciclos cardíacos.

Foram escolhidos os dois tipos de segmentação do sinal de ECG (ondas P+QRS e P+QRS+T) com base nos dados obtidos por Lugovaya (2005), os quais possuem os resultados mais expressivos quanto à capacidade de classificação.

A partir dos ciclos identificados, foram empregadas as técnicas de: correlação para estimar os 10 ciclos mais próximos e as técnicas descritas no Capítulo 3 para redução da dimensão do sinal e o posterior emprego das redes neurais para classificação.

A Figura 23 apresenta o fluxograma das etapas que foram executadas.

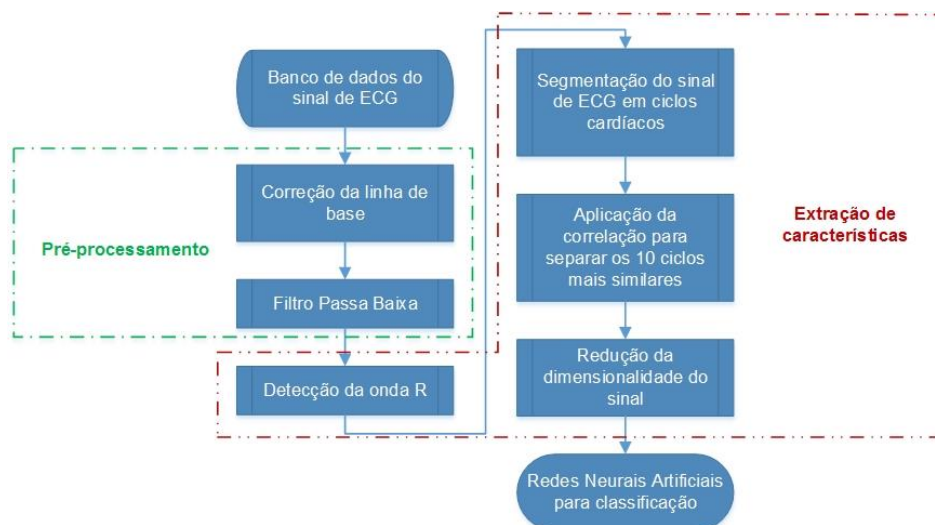


Figura 23 – Fluxograma das etapas de processamento do sinal de ECG.
Fonte: Autoria própria.

Nas próximas seções serão detalhadas todas as etapas apresentadas no fluxograma da Figura 23.

5.1 BASE DE DADOS DO ECG

Neste trabalho, utilizou-se o banco de dados ECG-ID (disponível no *site Physionet* - GOLDBERGER et al., 2000) criado por Lugovaya (2005) com o objetivo de desenvolver um sistema de identificação baseado no ECG. Este banco de dados é composto por 310 registros, obtidos de 90 pessoas (44 homens e 46 mulheres com idades entre 13 e 75 anos). O número de registros efetuados para cada pessoa foi de 2 (coletados durante um dia) a 20 (coletados periodicamente ao longo de 6 meses). A duração de cada registro é de 20 segundos, contendo uma quantidade significativa de batimentos.

Os sinais de ECG foram adquiridos através da derivação I, com frequência de amostragem de 500 amostras/s e 12-bits de resolução dentro de uma faixa nominal de $\pm 10\text{mV}$ de variação.

Cada registro inclui os sinais bruto e filtrado da seguinte maneira:

- Sinal 0: ECG I (sinal bruto, nenhum tipo de filtragem)
- Sinal 1: ECG I (sinal filtrado).

Na Figura 24, é apresentado um sinal bruto de ECG do banco de dados.

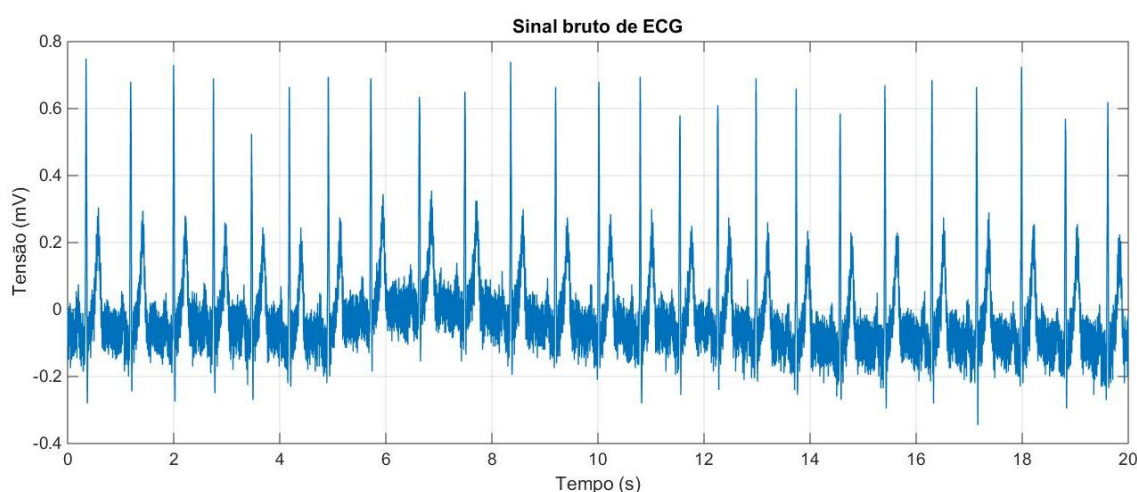


Figura 24 – Sinal bruto de ECG.
Fonte: Autoria própria⁷.

⁷ Todas as figuras dos Capítulos 5 e 6 são resultados obtidos pelas simulações realizadas em um notebook core i7 2,20GHz 16Gb de memória RAM, com o software Matlab® R2014b.

5.2 PRÉ-PROCESSAMENTO DO SINAL DE ECG

O sinal de ECG sem filtragem possui diferentes interferências, como por exemplo, causadas por contrações musculares, desvios da linha de base, modulação de amplitude devido à respiração, interferência da rede elétrica e ruído do eletrodo (CHIU; CHUANG; HSU, 2008).

Segundo Lugovaya (2005), *softwares* de eletrocardiógrafos suprimem características essenciais para a identificação. Portanto, faz-se necessário utilizar o sinal bruto de ECG e especificar adequadamente os filtros de modo a preservar tais características.

5.2.1 Correção da Linha de Base

Conforme o Fluxograma apresentado na Figura 23, o primeiro passo realizado é a correção de linha de base. Para isso, foi utilizada a decomposição *wavelet* (Daubechies 'db8', nível 9, Tabela 1) (LUGOVAYA, 2005).

Tabela 1 – Frequências de corte da transformada wavelet para o sinal de 500 amostras/s.

Fonte: Autoria própria.

Nível	Frequência de corte (Hz)
1	125
2	62,5
3	31,25
4	15,625
5	7,8125
6	3,9063
7	1,9531
8	0,9766
9	0,4883

Segundo Fatemian e Hatzinakos (2009), a flutuação da linha de base está limitada a componentes abaixo de 1Hz. Já os artefatos de movimento, situam-se na faixa de 1-10Hz que se sobrepõem consideravelmente o conteúdo espectral do complexo PQRST.

Para Sahambi et al. (1997), as variações de linha de base e artefatos de movimento situam-se na faixa de 0,5-7Hz enquanto o espectro de potência das ondas P e T está compreendido no intervalo de 0,5-10Hz.

Chiu et al. (2008) faz uso de um filtro passa alta com frequência de corte de 0,5Hz para eliminar a flutuação da linha de base.

O sinal e flutuação da linha de base do ECG (Figura 25, em vermelho) foi obtido a partir da reconstrução dos coeficientes de aproximação (baixas frequências) resultantes da decomposição *wavelet* no nível 9. Subtraindo o sinal de flutuação da linha de base do sinal bruto, obtêm-se o sinal corrigido (Figura 26).

A Figura 25 ilustra o sinal bruto de ECG (azul) com o sinal de reconstrução da aproximação nível 9 (vermelho).

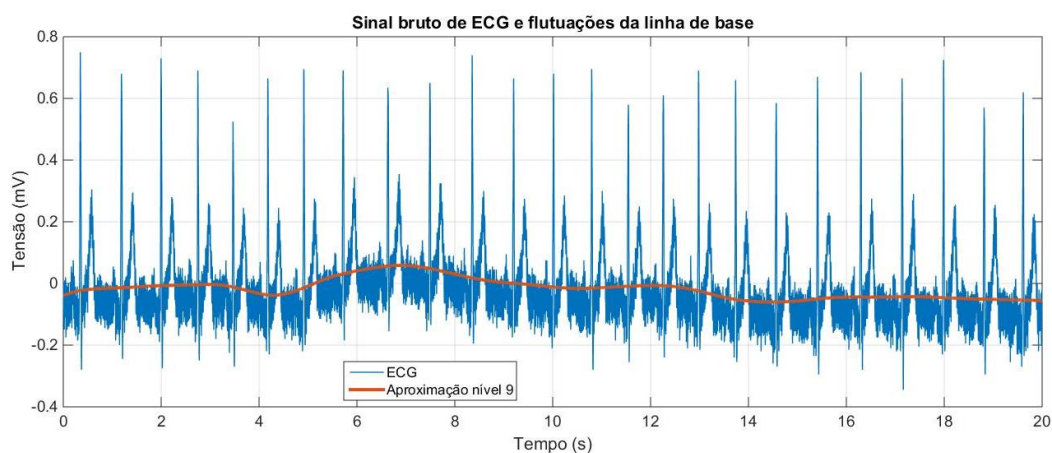


Figura 25 – Sinal de ECG e aproximação nível 9 que representa a flutuação da linha de base.
Fonte: Autoria própria.

Após a subtração da aproximação nível 9, a correção da linha de base é obtida conforme ilustra a Figura 26.

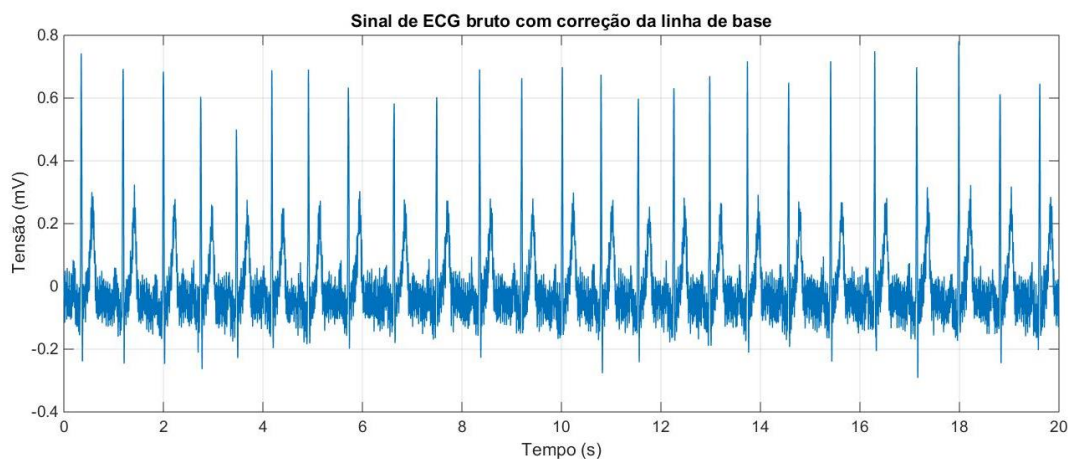


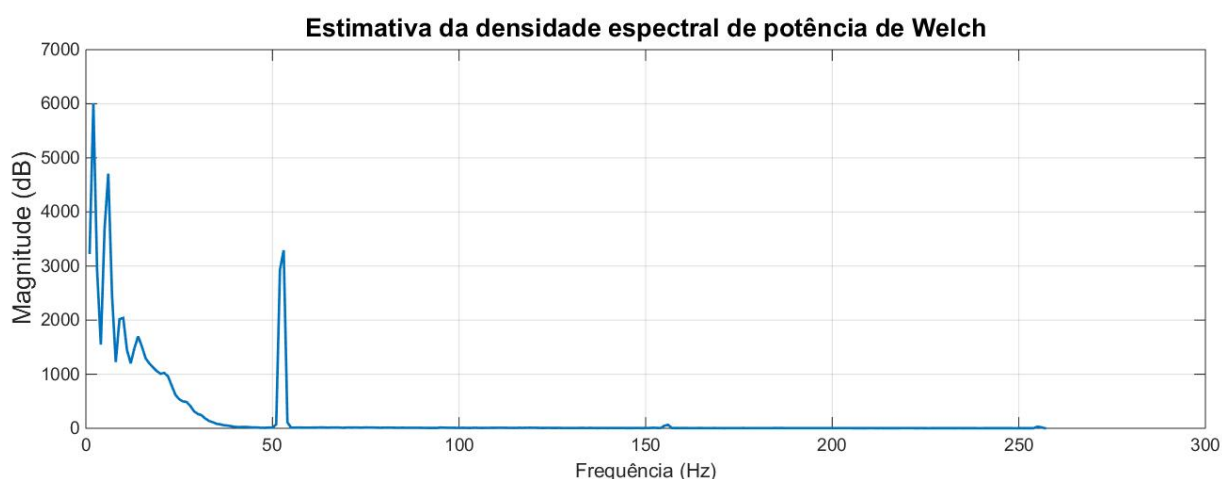
Figura 26 – Sinal de ECG com correção da linha de base.
Fonte: Autoria própria.

5.2.2 Filtragem

Para fins de monitoramento cardíaco a faixa de frequência de ECG deve possuir componentes no intervalo de 0,5-40Hz (CALIL; GOMIDE, 2002). O monitor deve selecionar, principalmente, o complexo QRS, que estão contidos nesta faixa de frequência.

Tipicamente, as componentes de frequência que compõem o complexo QRS situam-se dentro da faixa de 10-25Hz (SAHAMBI; TANDON; BHATT, 1997).

A Figura 27 ilustra o espectro de frequência do sinal de ECG não filtrado usando o periodograma de *Welch* (GUPTA; MEHRA; BATAN, 2013). Podemos visualizar as diversas faixas de frequências do sinal e identificar quais frequências que devem ser filtradas.



**Figura 27 – Espectro de frequência do sinal de ECG sem filtragem.
Fonte: Autoria própria.**

Com base nos trabalhos de Lugovaya (2005), Agrafioti e Hatzinakos (2008), Fattah et al. (2012), Naraghi et al. (2012) e no espectro de frequência do sinal ilustrado na Figura 27, foi utilizado o filtro *Butterworth* Passa-Baixa com frequência de corte de 40Hz e ordem 18 (Figura 28).

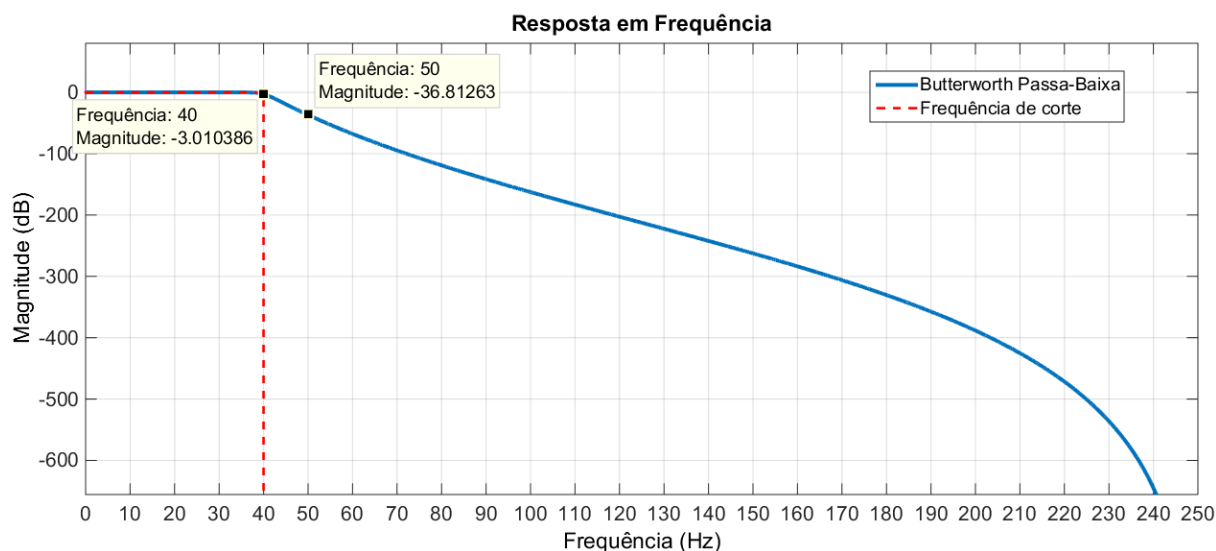


Figura 28 – Resposta em frequência do filtro Butterworth Passa-Baixa.
Fonte: Autoria própria.

A Figura 29 apresenta o espectro resultante da filtragem do sinal bruto de ECG. As frequências acima de 40Hz, que foram eliminadas permanecendo as frequências que correspondem as componentes discriminantes do ECG para identificação de pessoas.





Figura 29 – Espectro de frequência do sinal de ECG filtrado.
Fonte: Autoria própria.

Na Figura 30 (a), é ilustrado o sinal de ECG bruto e na Figura 30 (b), o sinal de ECG filtrado.



**Figura 30 – (a) Sinal de ECG bruto e (b) Sinal de ECG filtrado com filtro Passa-Baixa.
Fonte: Autoria própria.**

Na próxima seção são realizadas as etapas para extração de características do ECG.

5.3 EXTRAÇÃO DE CARACTERÍSTICAS

5.3.1 Detecção da Onda R

Para a detecção do pico R do sinal de ECG, utilizou-se o método do Limiar Adaptativo *Wavelet* aplicado por Abibullaev e Seo (2010) com base na proposta de Donoho (1995).

Este consiste em adotar uma função *wavelet* que mais se assemelha ao sinal de ECG para detectar o complexo QRS. Para isso, são utilizados os coeficientes de aproximação *wavelet* para calcular o limiar que será adotado como base para localizar os picos R.

A família *wavelet* escolhida foi a Daubechies “db3” e os coeficientes de aproximação nível 1.

A função do limiar é dada por:

$$T_s(\lambda, w_k) = \begin{cases} R(w_k) & \text{se } |w_k| > \lambda \\ 0 & \text{se } |w_k| < \lambda \end{cases} \quad (5.1)$$

onde w_k representa os coeficientes da *wavelet* do sinal R (representa os possíveis picos R do sinal de ECG) e λ o limiar que é obtido pela Equação (5.2).

$$\lambda = \sigma \sqrt{2 \log(N)} \quad (5.2)$$

na qual N representa o número de amostras da decomposição *wavelet* do sinal sendo analisado e σ é o nível de ruído dos coeficientes *wavelet* definido por $\sigma = MAD/0,6745$. O MAD é o desvio médio absoluto da escala escolhida, sendo o somatório do produto dos desvios (em módulo, ou valor absoluto) de cada valor observado em relação à média. A constante 0,6745 (como padrão) é usado porque N é extenso para uma distribuição normal.

Os valores de w_k que forem maiores do que o valor de λ correspondem a ocorrência de um pico R (Figura 31). A partir do valor de λ , estabeleceu-se o coeficiente de corte e assim são detectadas as incidências dos picos R.

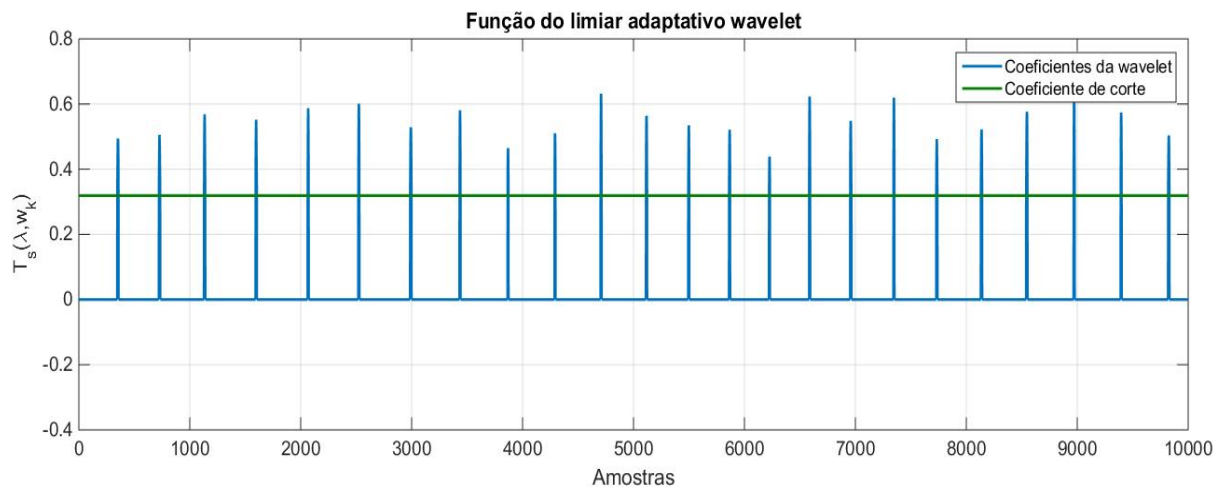
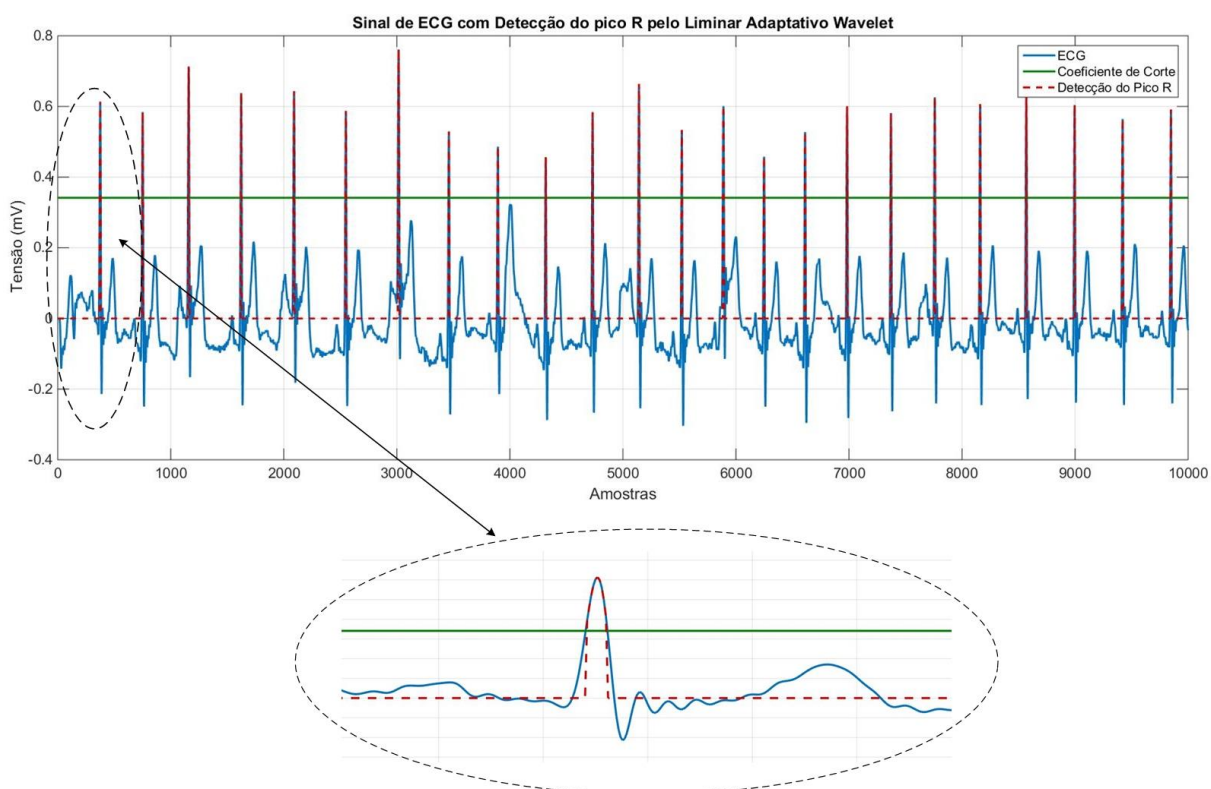


Figura 31 – Aplicação da técnica do limiar adaptativo wavelet para detectar os picos R.
Fonte: Autoria própria.

Como apresentado na Expressão (5.1), os valores de w_k menores do que λ são substituídos por 0. Já os valores de w_k maiores do que λ são mantidos, indicando a detecção do pico R.

A Figura 32 ilustra o limiar adaptativo *wavelet* sobreposto ao sinal de ECG.



**Figura 32 – Detecção usando wavelet 'db3' e escala 1 para o coeficiente de corte.
Fonte: Autoria própria.**

Este método não garante a detecção de todos os picos R, sendo em alguns casos necessário o ajuste manual.

Após a realização da detecção do pico R, foram escolhidas as duas formas de separação dos ciclos cardíacos.

5.3.2 Segmentação do Sinal

Após a detecção dos picos R do sinal de ECG, o primeiro e o último pico R foram descartados. Este procedimento foi realizado para garantir que não houvessem ciclos incompletos, ou seja, sem a onda P ou a T.

Depois de separar estes picos, foram definidas duas formas de segmentação: com 167 e com 280 amostras.

- A primeira, com 167 amostras (fragmentos P+QRS, onde é localizado o pico R e a partir dele são separadas 110 amostras antes e 56 depois do pico) formando, desta maneira, a onda P mais o complexo QRS.

- A segunda, com 280 amostras (fragmentos P+QRS+T com 110 amostras antes e 170 depois do pico R) que compõem, praticamente, todas as ondas do ECG.

A Figura 33 ilustra os ciclos sobrepostos, de uma pessoa, após a detecção do pico R para as ondas P+QRS contendo 167 amostras. Desta forma, pode-se visualizar o quão similar são os diversos ciclos cardíacos. Foi desconsiderado o efeito da variação da taxa de batimento cardíaco (frequência cardíaca).

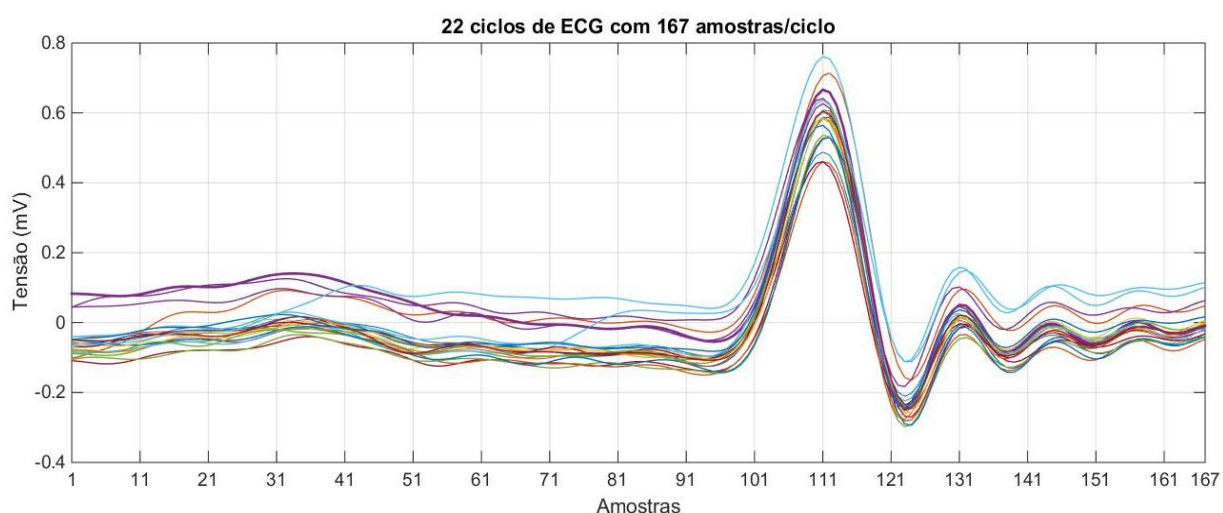


Figura 33 – 22 ciclos de ECG com 167 amostras/ciclo.
Fonte: Autoria própria.

A Figura 34 ilustra os ciclos de ECG com as ondas P+QRS+T contendo 280 amostras/ciclo.




Figura 34 – 22 ciclos de ECG com 280 amostras/ciclo.
Fonte: Autoria própria.

De cada um dos segmentos (ciclo) foi subtraído o valor médio (foi realizado o cálculo da média dos ciclos e, em seguida, feito a subtração de cada ciclo pela média), sendo que o resultado é apresentado na Figura 35 para ciclos contendo 167 amostras/ciclo.




Figura 35–Ciclos cardíacos com 167 amostras/ciclo ajustados subtraindo a média.
Fonte: Autoria própria.

Da mesma forma, para fragmento contendo as ondas P+QRS+T, foi realizada a subtração da média para ciclos contendo 280 amostras/ciclo, como mostra a Figura 36.




Figura 36 – Ciclos cardíacos com 280 amostras/ciclo ajustados subtraindo a média.
Fonte: Autoria própria.

É necessário eliminar os ciclos que apresentam distorções devido a artefatos de movimento, respiração e fragmentos associados a patologias (LUGOVAYA, 2005).

Do conjunto de ciclos cardíacos extraídos, aplicou-se a correlação, que indica a similaridade para que se estime os 10 ciclos mais próximos como mostra a Figura 37 para os ciclos contendo 167 amostras/ciclo.




Figura 37 – Os 10 ciclos cardíacos com 167 amostras/ciclo estimados pela correlação.
Fonte: Autoria própria.

Para o fragmento contendo as ondas P+QRS+T (280 amostras), também foi aplicada a correlação, como mostra a Figura 38.




Figura 38 – Os 10 ciclos cardíacos com 280 amostras/ciclo estimados pela correlação.
Fonte: Autoria própria.

Deste modo, o espaço amostral do ECG aparece como um conjunto de 10 fragmentos, tanto para o PQRST quanto para o PQRST, que possuem o mais elevado nível de similaridade.

5.3.3 Redução da Dimensão do Espaço de Características do Sinal

O sinal de ECG original possui 10.000 amostras (cerca de 20 segundos), sendo extenso e redundante. Isto faz com que o processamento se torne difícil ou computacionalmente intratável.

A redução do espaço de características tem como objetivo fazer a mudança do espaço de características iniciais, com uma base correlacionada, em um novo espaço de características com uma base não correlacionada. Este procedimento permite redução de dimensionalidade com mínima perda de informações (LUGOVAYA, 2005).

Dois métodos para redução do espaço de características foram utilizados: *wavelet* e PCA (Análise dos Componentes Principais – *Principal Components Analysis*).

A família *wavelet* empregada para realizar a redução da dimensão do espaço de características do sinal de ECG foi a Daubechies “db3” com 3 níveis de decomposição. Nas quais, para cada ciclo cardíaco, foram extraídos os coeficientes de aproximação. Na Figura 39, é mostrado os coeficientes de aproximação dos 10 ciclos cardíacos para o fragmento P+QRS da decomposição *wavelet* “db3” nível 1.




Figura 39 – Coeficientes de aproximação da decomposição *wavelet* “db3” nível 1 para janela contendo as ondas P+QRS.

Fonte: Autoria própria.

Na Figura 40, ilustra-se os coeficientes de aproximação dos 10 ciclos cardíacos para o fragmento P+QRS da decomposição *wavelet* "db3" nível 2.

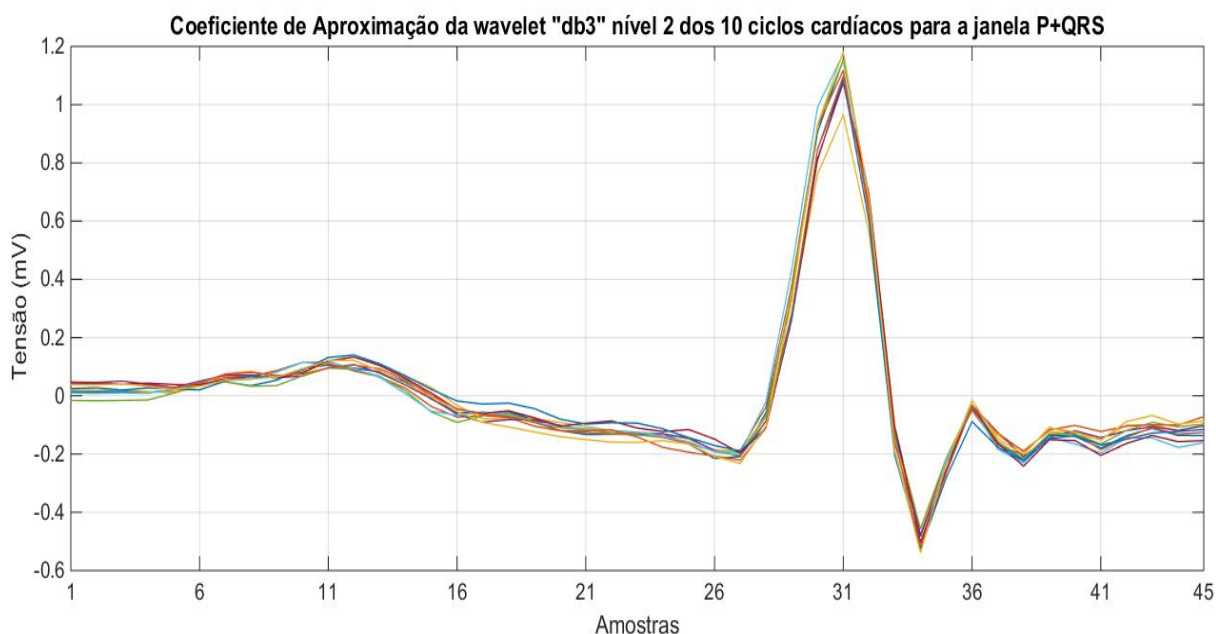


Figura 40 – Coeficientes de aproximação da decomposição *wavelet* "db3" nível 2 para janela contendo as ondas P+QRS.
Fonte: Autoria própria

Na Figura 41 são mostrados os coeficientes de aproximação dos 10 ciclos cardíacos para o fragmento P+QRS da decomposição *wavelet* "db3" nível 3.




Figura 41 – Coeficientes de aproximação da decomposição *wavelet* "db3" nível 3 para janela contendo as ondas P+QRS.
Fonte: Autoria própria.

Depois de obter os coeficientes de cada nível de decomposição *wavelet* foi realizada a soma vetorial do sinal (soma dos vetores dos ciclos cardíacos) de cada

ciclo reconstruído. Primeiramente para a decomposição *wavelet* “db3” no nível 1, a redução foi de 1.670 amostras do sinal de ECG para 86 amostras, contendo as ondas P+QRS.




Figura 42 – Resultado da soma vetorial dos 10 ciclos cardíacos contendo as ondas P+QRS com a wavelet “db3” nível 1.
Fonte: Autoria própria.

Para *wavelet* “db3” no nível 2, resultou em 45 amostras com a soma vetorial para a janela contendo as ondas P+QRS.




Figura 43 – Resultado da soma vetorial dos 10 ciclos cardíacos contendo as ondas P+QRS com a wavelet “db3” nível 2.
Fonte: Autoria própria.

Para o nível 3 de decomposição *wavelet*, a soma vetorial foi de 25 amostras para a janela contendo as ondas P+QRS.




Figura 44 – Resultado da soma vetorial dos 10 ciclos cardíacos contendo as ondas P+QRS com a wavelet “db3” nível 3.
Fonte: Autoria própria.

Foram realizados os mesmos procedimentos para a janela contendo as ondas P+QRS+T. Na Figura 45, é apresentado os coeficientes de aproximação da *wavelet* “db3” nível 1 dos 10 ciclos cardíacos de ECG.




Figura 45 – Coeficientes de aproximação da wavelet “db3” nível 1 dos 10 ciclos cardíacos para a janela contendo as ondas P+QRS+T.
Fonte: Autoria própria.

Na Figura 46, são apresentados os coeficientes de aproximação *wavelet* “db3” nível 2 dos 10 ciclos cardíacos contendo as ondas P+QRS+T.

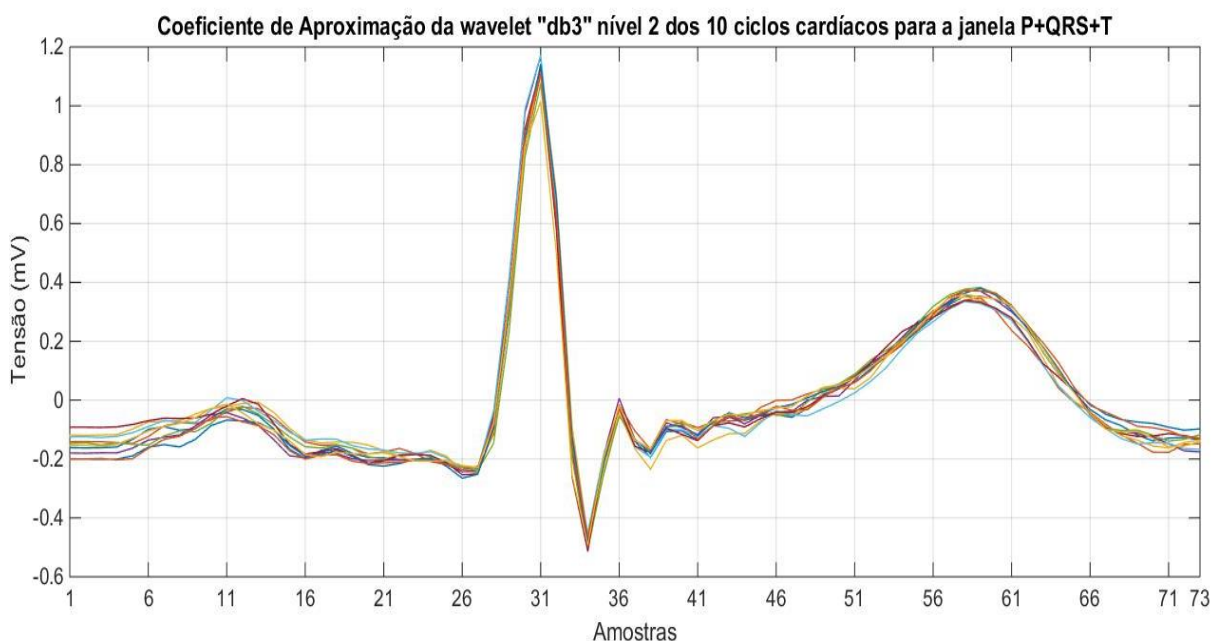


Figura 46 – Coeficientes de aproximação da wavelet “db3” nível 2 dos 10 ciclos cardíacos para a janela contendo as ondas P+QRS+T.
Fonte: Autoria própria.

A decomposição *wavelet* “db3” nível 3 contendo os coeficientes de aproximação dos 10 ciclos cardíacos contendo as ondas P+QRS+T são apresentados na Figura 47.

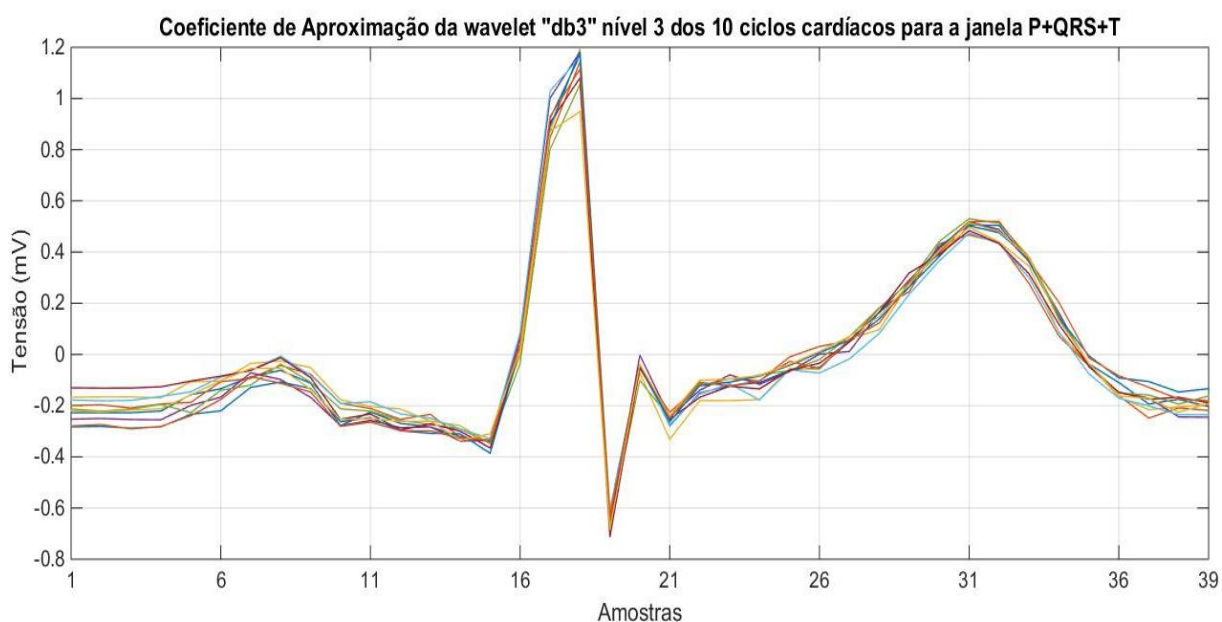


Figura 47 – Coeficientes de aproximação da wavelet “db3” nível 3 dos 10 ciclos cardíacos para a janela contendo as ondas P+QRS+T.
Fonte: Autoria própria.

Após a obtenção dos coeficientes de aproximação *wavelet* de cada nível de decomposição, foi realizado a soma vetorial dos 10 ciclos cardíacos.

Na Figura 48, é ilustrada o resultado da soma vetorial para a *wavelet* “db3” nível 1, tendo sido o sinal reduzido o sinal de 2.800 para 142 amostras.




Figura 48 – Resultado da soma vetorial dos 10 ciclos cardíacos contendo as ondas P+QRS+T com a wavelet “db3” nível 1.
Fonte: Autoria própria.

No nível 2 da decomposição *wavelet*, o sinal de ECG foi reduzido para 73 amostras (Figura 49).




Figura 49 – Resultado da soma vetorial dos 10 ciclos cardíacos contendo as ondas P+QRS+T com a wavelet “db3” nível 2.
Fonte: Autoria própria.

Já na decomposição *wavelet* "db3" nível 3, com a soma vetorial, a redução foi de 39 amostras (Figura 50).




Figura 50 – Resultado da soma vetorial dos 10 ciclos cardíacos contendo as ondas P+QRS+T com a wavelet "db3" nível 3.
Fonte: Autoria própria.

O grupo contendo 167 amostras (P+QRS) por ciclo de ECG passou a ter 86 amostras com a redução através da decomposição *wavelet* "db3" nível 1, 45 amostras com a redução através da decomposição nível 2 e 25 amostras com a redução pela decomposição *wavelet* nível 3.

Já o grupo contendo 280 amostras (P+QRS+T) por ciclo de ECG ficou com 142 amostras com a redução por meio da *wavelet* "db3" nível 1, 73 amostras para a decomposição da *wavelet* "db3" nível 2 e 39 amostras com a decomposição da *wavelet* "db3" nível 3.

Na Tabela 2 é possível verificar de forma mais clara as reduções obtidas pela decomposição *wavelet*.

Tabela 2 – Redução das amostras para os dois grupos de amostras de ciclos de ECG.
Fonte: Autoria própria.

Decomposição Wavelet	167 amostras (P+QRS)	280 amostras (P+QRS+T)
Nível 1	86	142
Nível 2	45	73
Nível 3	25	39

Com a técnica de PCA as componentes principais são extraídas. Para o caso do sinal de ECG utilizado neste trabalho verificou-se que a primeira componente

principal, ou autovalor, possui 97,9% (contribuição da componente principal obtida pela Equação (5.3)) de informação e por isso, decidiu-se utilizar apenas uma componente.

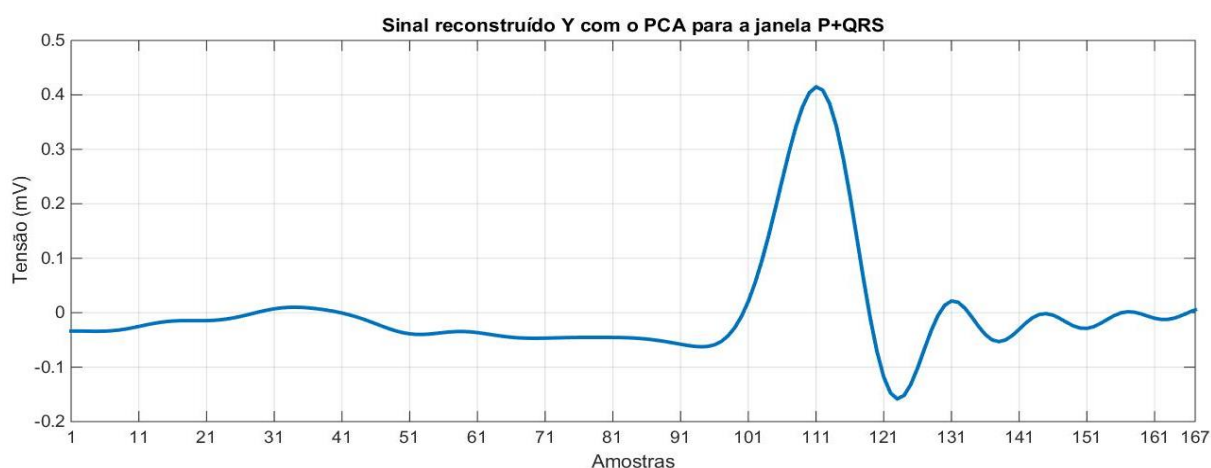
$$C_i = \frac{\lambda_i}{\sum_{i=1}^N \lambda_i} \quad (5.3)$$

onde N é a quantidade de autovalores, λ_i é o valor do autovalor.

A redução aplicada com a técnica do PCA foi para diminuir o número de ciclos cardíacos, ou seja, de 10 (dez) ciclos foi reduzido para apenas 1 (um). Para a janela contendo as ondas P+QRS, cada vetor de ciclo cardíaco possui 167 amostras e somando os 10 (dez) ciclos temos um total de 1670 amostras. Aplicando a técnica do PCA foi obtido um único ciclo contendo 167 amostras que representa, praticamente, todas as características dos 10 (dez) ciclos em apenas 1 (um) ciclo, como mostra a Figura 51. A expressão a seguir é aplicada para obter o sinal reconstruído \mathbf{Y} .

$$\mathbf{Y} = \mathbf{A}\mathbf{v}'\mathbf{X} \quad (5.4)$$

onde $\mathbf{A}\mathbf{v}$ é o vetor do autovalor com a maior quantidade de energia do sinal de ECG e \mathbf{X} é o vetor contendo os 10 ciclos cardíacos mais correlacionados.



**Figura 51 – Redução do sinal de ECG com a técnica PCA utilizando a janela P+QRS.
Fonte: Autoria própria.**

Para a janela contendo as ondas P+QRS+T, o resultado da reconstrução pela técnica do PCA é mostrado na Figura 52. A redução do espaço de características foi de 2800 amostras para 280 amostras.




Figura 52 – Redução do sinal de ECG com a técnica PCA utilizando a janela P+QRS+T.
Fonte: Autoria própria.

Após a realização da filtragem e redução das características do sinal de ECG, o próximo passo foi realizar a normalização dos dados para inserção na rede neural. A expressão utilizada para esta finalidade foi a seguinte:

$$\mathbf{X}_{\text{norm}} = \frac{\mathbf{X}}{\max(\text{abs}(\mathbf{X}))} \quad (5.5)$$

onde \mathbf{X} representa o resultado da aplicação das técnicas de processamento de sinais, que foram descritas anteriormente.

O valor absoluto máximo global compreende a maior amplitude da matriz do sinal. Desta forma, todos os dados permaneceram com média zero.

5.4 REDES ELM E MLP PARA A IDENTIFICAÇÃO DE PESSOAS

Neste trabalho, verificou-se o uso de duas redes neurais artificiais para identificação de pessoas: a ELM e a MLP.

A Rede Máquina de Aprendizado Extremo (ELM), que se destaca pelo seu rápido processo de treinamento, por possuir uma arquitetura simples contendo apenas 3 camadas, das quais apenas na camada de saída os pesos são ajustados com o operador de *Moore-Penrose*. Seu algoritmo implementado no *Software Matlab®* é disponibilizado pelo Dr. Guang Bin Huang em seu website: <http://www.ntu.edu.sg/eee/icis/cv/egbhuang.htm>.

A *Perceptron* Múltiplas Camadas (MLP - *Multilayer Perceptron*) que possui grande popularidade devida as suas extensas aplicabilidades e metodologia de treinamento sistemática e confiável.

Para comparação do desempenho de cada rede neural, foram definidas as mesmas características construtivas. Sendo que ambas possuem apenas 3 camadas e função de ativação tangente hiperbólica (Seção 4.1, Equação (4.3)).

No algoritmo da ELM, os registros de ECG foram divididos em treinamento e teste, cerca de 60% ou 179 registros de dados para treinamento e 40% ou 131 registros de dados para teste.

Em contrapartida, na MLP os registros de ECG foram segmentados em treinamento, validação e teste, cerca de 60% ou 179 registros de dados divididos entre o treinamento e a validação. Destes, 131 registros são para o treinamento e 48 registros para validação. Os 40% ou 131 registros de dados do conjunto principal foram usados para teste.

A quantidade de neurônios da camada oculta foi incrementada de 10 em 10 até 1000. Em seguida, foram coletados os melhores resultados de cada iteração da rede, a qual foi executada 30 vezes. O desempenho global de cada topologia foi obtido com a média dos 30 resultados da etapa de teste.

6 RESULTADOS

Os resultados da rede ELM sem a inserção do coeficiente de regularização, para os conjuntos de treinamento e de teste informados anteriormente, são apresentados na Tabela 3.

Tabela 3 – Média dos 30 testes com 90 pessoas utilizando a ELM sem coeficiente de regularização.

Fonte: Autoria própria.

Sem coeficiente de regularização

Janela	Função	Nº de amostras	Nº de neurónios	Taxa de acerto treinamento (%)	Taxa de acerto teste (%)	Dp teste	Tempo de treinamento
P+QRS	Wavelet Nível 1	86	826	100	89,69	±0,72	12,6s
	Wavelet Nível 2	45	766	100	84,05	±1,24	10s
	Wavelet Nível 3	25	570	100	82,67	±0,70	9,6s
	PCA	167	822	100	92,60	±0,67	16,2s
P+QRS+T	Wavelet Nível 1	142	696	100	88,47	±0,70	12s
	Wavelet Nível 2	73	725	100	86,44	±0,62	11,7s
	Wavelet Nível 3	39	795	100	85,73	±0,73	12,6s
	PCA	280	745	100	90,81	±0,76	13,2s

Os melhores resultados foram obtidos usando o método PCA para redução do espaço de características, tanto para a janela contendo as ondas P+QRS quanto para a janela com as ondas P+QRS+T.

Para P+QRS (ondas PQRST do ECG) o resultado $92,60 \pm 0,67\%$ foi o melhor em termos de classificação, porém com o maior tempo médio de treinamento (16,2s), deixando claro o aumento do custo computacional nesta fase. Foi também o que apresentou a topologia ELM com a segunda maior média de neurónios na camada oculta.

Nota-se que o número de amostras de entrada não é a que determina a quantidade de neurónios necessários na camada oculta, ou o tempo de treinamento.

Os resultados para cada topologia ELM com a inserção do coeficiente de regularização para maximizar a capacidade de generalização da rede neural artificial ELM são apresentados na Tabela 4.

Os valores para o coeficiente de regularização ($C = 2^\lambda$) foram definidos com valores para λ compreendidos entre -24 a 25, ou seja, um vetor contendo 50 elementos $C = \{2^{-24}, 2^{-24}, \dots, 2^0, \dots, 2^{25}\}$. Dessa forma, fixa-se cada valor do coeficiente separadamente e este é apresentado às entradas de validação da rede, gerando uma medida de erro quadrático médio. O C que apresentou o menor erro de validação foi aquele que permitiu a melhor generalização da rede.

Tabela 4 – Média dos 30 testes com 90 pessoas utilizando a ELM com coeficiente de regularização.

Fonte: Autoria própria.

Com coeficiente de regularização “C” variando entre 2^{-24} a 2^{25}

Janela	Função	Nº de amostras	C	Nº de neurônios	Taxa de acerto treinamento (%)	Taxa de acerto teste (%)	Dp teste	Tempo de treinamento
P+QRS	Wavelet Nível 1	86	2^{10}	589	100	94,15	$\pm 0,46$	7,2s
	Wavelet Nível 2	45	2^{12}	604	100	91,48	$\pm 0,35$	6,6s
	Wavelet Nível 3	25	2^{14}	353	100	88,6	$\pm 0,34$	4,2s
	PCA	167	2^9	597	100	96,11	$\pm 0,54$	7,8s
P+QRS+ T	Wavelet Nível 1	142	2^7	504	100	91,42	$\pm 0,52$	7,2s
	Wavelet Nível 2	73	2^8	495	100	90,87	$\pm 0,71$	6s
	Wavelet Nível 3	39	2^9	572	100	92,37	$\pm 0,54$	7,2s
	PCA	280	2^9	633	100	92,70	$\pm 0,59$	9s

Nas Tabela 3 e Tabela 4, é possível observar que a melhor média obtida nos testes ($96,11 \pm 0,54\%$) com a ELM foi com a janela contendo as ondas P+QRS e técnica de processamento de sinais PCA.

Nos testes com a técnica de processamento de sinais *wavelet*, houve um aumento significativo na taxa de acerto dos testes com a utilização do coeficiente de regularização na rede ELM. E, de um modo geral, houve diminuição na quantidade de neurônios da camada oculta e no tempo de treinamento.

A Figura 53 ilustra o gráfico contendo os resultados da média e desvio padrão para a rede neural ELM, utilizando as técnicas de processamentos de sinais *wavelet* e PCA com as duas janelas de ciclos cardíacos do ECG (uma com as ondas P+QRS e outra com P+QRS+T).




Figura 53 – Gráfico da Média e Desvio Padrão dos testes para as janelas P+QRS e P+QRS+T com wavelet “db3” e PCA (ELM). Onde N corresponde ao número de amostras do sinal de entrada.

Fonte: Autoria própria.

Visualmente, os resultados das médias foram superiores em todos os testes com a inserção do coeficiente de regularização.

A máxima taxa de acerto no teste obtida em cada janela e técnica de processamento de sinal, são apresentados na Tabela 5 e Tabela 6.

Tabela 5 – Melhores resultados utilizando a ELM para a janela contendo as ondas P+QRS.

Fonte: Autoria própria.

Função	Nº de amostras	Nº de neurônios	Coefficiente de regularização	Resultado da identificação (%)
Wavelet - nível 1	86	796	-	90,84
Wavelet - nível 1	86	706	2 ⁹	95,42
Wavelet - nível 2	45	945	-	87,79
Wavelet - nível 2	45	575	2 ¹²	92,37
Wavelet - nível 3	25	665	-	83,97
Wavelet - nível 3	25	235	2 ¹⁴	89,31
PCA	167	757	-	94,66
PCA	167	727	2 ⁹	96,95

Tabela 6 – Melhores resultados utilizando a ELM para a janela contendo as ondas P+QRS+T.
Fonte: Autoria própria.

Função	Nº de amostras	Nº de neurônios	Coefficiente de regularização	Resultado da identificação (%)
Wavelet - nível 1	142	882	-	90,08
Wavelet - nível 1	142	432	2 ⁶	92,37
Wavelet - nível 2	73	873	-	87,79
Wavelet - nível 2	73	253	2 ⁹	93,13
Wavelet - nível 3	39	779	-	87,02
Wavelet - nível 3	39	419	2 ¹²	93,89
PCA	280	710	-	92,37
PCA	280	900	2 ⁷	93,89

Na Figura 54, o gráfico mostra com mais clareza os resultados apresentados na Tabela 5 e Tabela 6.

Melhores resultados obtidos com a Rede Neural Artificial ELM




Figura 54 – Gráfico com os melhores resultados obtidos com a ELM. Onde N corresponde ao número de amostras do sinal de entrada.

Fonte: Autoria própria.

Após a aquisição dos resultados com a RNA Máquina de Aprendizado Extremo (ELM), seguiu-se para os testes com a Rede Neural Artificial *Perceptron* Múltiplas Camadas (MLP).

A MLP utilizada possui 3 camadas, tal como foi realizado na ELM, os neurônios da camada oculta foram aumentados de 10 em 10 até 1000, sendo o melhor resultado escolhido; depois de 30 iterações da rede, foi extraída a média desses 30 melhores resultados.

A função de ativação utilizada para os testes foi a tangente hiperbólica. A taxa de aprendizagem foi definida em $1e^{-4}$, precisão especificada em $1e^{-7}$ e número máximo de épocas em $2e^3$. Os resultados são apresentados na Tabela 7.

Tabela 7 – Média dos 30 testes com 90 pessoas utilizando a MLP.
Fonte: Autoria própria.

Wavelet “db3” nível 1 (P+QRS – 86 amostras)							
EQM do treinamento	Neurônios intermediários	Épocas do treinamento	Tempo de treinamento	Taxa de acerto do treinamento (%)	Dp ±	Taxa de acerto teste com dados validação (%)	Dp ±
9,6257e-4	756	1962	326s	99,47	0,83	83,84	1,69
						85,42	1,52
Wavelet “db3” nível 2 (P+QRS – 45 amostras)							
EQM do treinamento	Neurônios intermediários	Épocas do treinamento	Tempo de treinamento	Taxa de acerto do treinamento (%)	Dp ±	Taxa de acerto teste com dados validação (%)	Dp ±
4,2906e-3	806	1981	305s	91,53	2,65	76,31	2,02
						77,25	2,02
Wavelet “db3” nível 3 (P+QRS – 25 amostras)							
EQM do treinamento	Neurônios intermediários	Épocas do treinamento	Tempo de treinamento	Taxa de acerto do treinamento (%)	Dp ±	Taxa de acerto teste com dados validação (%)	Dp ±
7,7251e-3	771	2000	348s	70,69	3,64	61,88	1,76
						60,64	1,62
PCA (P+QRS – 167 amostras)							
EQM do treinamento	Neurônios intermediários	Épocas do treinamento	Tempo de treinamento	Taxa de acerto do treinamento (%)	Dp ±	Taxa de acerto teste com dados validação (%)	Dp ±
3,4809e-4	487	1956	301s	99,90	0,44	82,29	1,99
						83,56	1,64

Wavelet "db3" nível 1 (P+QRS+T – 142 amostras)									
EQM do treinamento	Neurônios intermediários	Épocas do treinamento	Tempo de treinamento	Taxa de acerto do treinamento (%)	Dp ±	Taxa de acerto teste com dados validação (%)	Dp ±	Taxa de acerto teste com dados treinamento (%)	Dp ±
1,8616e-4	488	1920	368s	99,97	0,14	78,63	1,69	79,85	1,67
Wavelet "db3" nível 2 (P+QRS+T – 73 amostras)									
EQM do treinamento	Neurônios intermediários	Épocas do treinamento	Tempo de treinamento	Taxa de acerto do treinamento (%)	Dp ±	Taxa de acerto teste com dados validação (%)	Dp ±	Taxa de acerto teste com dados treinamento (%)	Dp ±
8,0877e-4	716	2000	319s	99,69	0,62	80,66	1,46	81,81	1,53
Wavelet "db3" nível 3 (P+QRS+T) – 39 amostras									
EQM do treinamento	Neurônios intermediários	Épocas do treinamento	Tempo de treinamento	Taxa de acerto do treinamento (%)	Dp ±	Taxa de acerto teste com dados validação (%)	Dp ±	Taxa de acerto teste com dados treinamento (%)	Dp ±
3,4119e-3	854	1974	381s	95,09	2,78	74,45	1,98	75,90	2,08
PCA (P+QRS+T – 280 amostras)									
EQM do treinamento	Neurônios intermediários	Épocas do treinamento	Tempo de treinamento	Taxa de acerto do treinamento (%)	Dp ±	Taxa de acerto teste com dados validação (%)	Dp ±	Taxa de acerto teste com dados treinamento (%)	Dp ±
7,2729e-5	347	1695	317s	100	0	71,19	1,47	72,42	1,71

Os resultados das médias e desvios padrão obtidos nos treinamentos da rede neural artificial MLP para as técnicas de processamento de sinais *wavelet* e PCA com a janela P+QRS, são ilustrados graficamente na Figura 55.




Figura 55 – Gráfico das médias e desvios padrão dos treinamentos da rede neural artificial MLP para a janela P+QRS. Onde N corresponde ao número de amostras do sinal de entrada. Fonte: Autoria própria.

Os resultados demonstram que a rede neural artificial MLP obteve em quase todos os treinamentos a máxima Taxa de acerto de treinamento. Apenas para o caso do treinamento com a *wavelet* “db3” nível 3 (25 amostras) os valores foram menores. Pode-se dizer também, que a rede neural artificial não teve problema com uma memorização excessiva, o que poderia causar um *overfitting*.

Na Figura 56, são ilustrados os resultados das médias e desvios padrão dos treinamentos com a janela P+QRS+T para as duas técnicas de processamento de sinais.




Figura 56 – Gráfico das médias e desvios padrão dos treinamentos da rede neural artificial MLP para a janela P+QRS+T. Onde N corresponde ao número de amostras do sinal de entrada. Fonte: Autoria própria.

Como observado nos resultados apresentados na Figura 55, para a janela P+QRS+T, novamente a decomposição nível 3 da *wavelet* (39 amostras) obteve o menor resultado no treinamento. Para o PCA (280 amostras), o treinamento obteve a máxima taxa de classificação, o que pode significar que a rede teve uma memorização excessiva.

Apesar disso, o resultado médio do número de neurônios e épocas de treinamento demonstram que a rede não teve os valores máximos alcançados, ou seja, o treinamento da rede MLP parou antes de alcançar o valor máximo de épocas definida.

Na Figura 57, são apresentados os resultados da média e desvio padrão dos testes realizados com a Rede MLP para a janela contendo as ondas P+QRS.




Figura 57 – Gráfico da média e desvio padrão dos testes para as janelas P+QRS (MLP). Onde N corresponde ao número de amostras do sinal de entrada.

Fonte: Autoria própria.

Como observado no gráfico (Figura 55), a rede obteve os valores máximos nos treinamentos com a *wavelet* nível 1 (N=86) e PCA (N=167). Nos testes (Figura 57), estes foram os que obtiveram os melhores resultados.

Para a *wavelet* “db3” nível 1 (86 amostras, ondas P+QRS), o resultado foi de 85,42±1,52% de classificação, necessitando cerca de 326s para treinamento. Para a PCA (167 amostras, ondas P+QRS), o resultado foi de 83,56±1,64% de classificação e cerca de 301s para treinamento. Pode-se deduzir que, nestes dois casos, a rede obteve uma melhor generalização com o treinamento, o que resultou em melhores índices de classificação. Já o contrário ocorre para a *wavelet* nível 3 em que o treinamento e teste gerou os piores resultados.

Com relação ao tempo de treinamento, para todos os casos, a rede necessitou de mais de 300s para treinar. O menor tempo de treinamento foi obtido com a PCA contendo 167 amostras (ondas P+QRS). Nota-se que o menor tempo de treinamento não está relacionado com o número de amostras de entrada da RNA.

Na Figura 58, são ilustrados os resultados dos testes com a rede MLP para a janela contendo as ondas P+QRS+T.

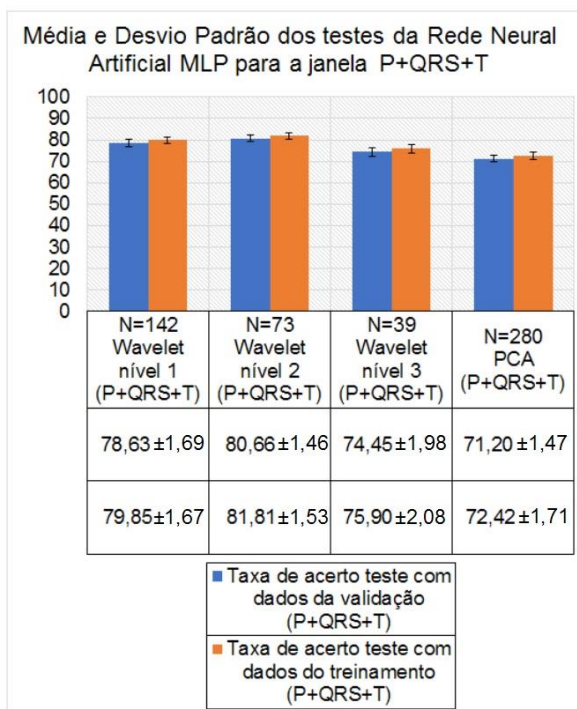


Figura 58 – Gráfico da média e desvio padrão dos testes para as janelas P+QRS+T (MLP). Onde N corresponde ao número de amostras do sinal de entrada.
Fonte: Autoria própria.

Para a janela contendo as ondas P+QRS+T, o melhor resultado foi obtido com a *wavelet* “db3” nível 2 (73 amostras), 81,81±1,53% de classificação e cerca de 319s para treinamento. Os outros níveis de decomposição tiveram seus resultados bem próximos, já a PCA obteve o pior resultado.

Outro ponto interessante observado, foi o tempo necessário para treinamento da *wavelet* “db3” nível 3 (39 amostras, ondas P+QRS+T) que de todos os testes foi o que teve o maior tempo.

Os melhores resultados obtidos nos testes com a rede neural MLP são apresentados na Tabela 8.

Tabela 8 – Melhores resultados obtidos com a Rede Neural Artificial MLP.
Fonte: Autoria própria.

P+QRS				
Função	Amostras	Nº de neurônios	Épocas	Porcentagem de classificação (%)
Wavelet - nível 1	86	486	2000	88,55
Wavelet - nível 2	45	705	2000	82,44
Wavelet - nível 3	25	655	1997	66,41
PCA	167	797	1829	87,02
P+QRS+T				
Função	Amostras	Nº de neurônios	Épocas	Porcentagem de classificação (%)
Wavelet - nível 1	142	502	2000	81,68
Wavelet - nível 2	73	863	2000	86,26
Wavelet - nível 3	39	939	2000	80,15
PCA	280	320	1711	76,34

Os resultados apresentados na Tabela 8 mostram que, em quase todos os casos, a rede teve sua parada pelo número de épocas de treinamento. Isso pode significar que a rede poderia ter continuado e obtido melhor generalização.

Os melhores resultados obtidos com a rede neural artificial MLP são ilustrados no gráfico da Figura 59.




Figura 59 – Gráfico com os melhores resultados obtidos com a MLP. Onde N corresponde ao número de amostras do sinal de entrada.
Fonte: Autoria própria.

Para a Rede Neural Artificial MLP, o melhor resultado foi obtido com a janela contendo as ondas P+QRS e técnica de processamento de sinais *wavelet* “db3” nível 1 (86 amostras). Porém com a PCA contendo as ondas P+QRS (167 amostras), o resultado foi bem próximo, superando os níveis 2 e 3 de decomposição *wavelet*.

7 DISCUSSÃO

A utilização do coeficiente de regularização mostrou-se eficiente em relação a maximização da capacidade de generalização da rede neural artificial ELM nos testes realizados (Tabela 5). Observa-se que, em ambos os testes, houve um aumento significativo da Taxa de acerto, tanto para a técnica de processamento de sinais *wavelet* quanto para a PCA.

Para a *wavelet*, o melhor resultado foi obtido com a decomposição nível 1 contendo 86 amostras. Com estes resultados (Tabela 9), são apresentadas a relação das pessoas que foram erroneamente identificadas.

Tabela 9 – Pessoas erroneamente identificadas considerando a quantidade de registros utilizados para teste com wavelet “db3” nível 1 janela P+QRS (ELM).

Fonte: Autoria própria.

Wavelet “db3” nível 1 ondas P+QRS (86 amostras)		
Pessoa	Nº de registros	Quantidade erroneamente identificada
P ₄₀	2	1
P ₄₆	2	1
P ₆₀	1	1
P ₆₉	1	1
P ₈₆	1	1
P ₈₇	1	1

O melhor resultado obtido pela técnica de redução de dimensão PCA é abordado na Tabela 10, onde são apresentadas as pessoas que foram erroneamente identificadas.

Tabela 10 – Pessoas erroneamente identificadas considerando a quantidade de registros utilizados para teste com PCA janela P+QRS (ELM).

Fonte: Autoria própria.

PCA ondas P+QRS (167 amostras)		
Pessoa	Nº de registros	Quantidade erroneamente identificada
P ₂₄	2	2
P ₄₆	2	1
P ₈₆	1	1

Tomando como pressuposto que existe mais de um registro de cada pessoa utilizado para teste e que, em alguns casos, apenas um destes não foi identificado corretamente, a relação da porcentagem de classificação será diferente se for considerado a quantidade de pessoas para cálculo.

Neste caso, a porcentagem de identificação será de 97,78% de classificação para a técnica de processamento de sinais PCA utilizando as ondas P+QRS contendo 167 amostras e de 95,55% de classificação para a técnica de processamento de sinais *wavelet* utilizando as ondas P+QRS contendo 86 amostras.

Com os resultados apresentados nas Tabela 4 e Tabela 5, foi realizada uma comparação entre os resultados obtidos por Lugovaya (2005) e este trabalho. No trabalho de Lugovaya (2005) foi utilizada a decomposição *wavelet* nível 3, o mesmo nível de decomposição foi realizado neste trabalho.

A Figura 60 apresenta os resultados obtidos com os testes realizados neste trabalho e o obtido por Lugovaya (2005).




Figura 60 – Gráfico comparativo dos resultados com a wavelet “db3” nível 3 e o resultado de Lugovaya (2005). Onde N corresponde ao número de amostras do sinal de entrada.

Fonte: Autoria própria.

No trabalho de Lugovaya (2005), o fragmento P+QRS+T possui inicialmente 250 amostras e depois da decomposição com a *wavelet* “db3” nível 3 passa a ter 34 amostras. Já neste trabalho, o fragmento P+QRS+T possui inicialmente 280 amostras e depois da decomposição com a *wavelet* “db3” nível 3, passa a ter 39 amostras.

Foi também realizado um comparativo com o fragmento P+QRS, que inicialmente possuía 167 amostras, e depois da decomposição pela função *wavelet* “db3”, passou a ter 25 amostras.

Os resultados obtidos com a rede neural artificial ELM, utilizando a técnica de processamento de sinal *wavelet*, para reduzir a dimensão do sinal, foram melhores

que os obtidos por Lugovaya (2005). Foi também observado que, com um menor número de amostras (25), obteve-se melhores resultados.

Já os resultados utilizando a técnica de processamento de sinais PCA e rede neural artificial ELM, são comparados na Figura 61.




Figura 61 – Gráfico comparativo dos resultados com a PCA e o resultado de Lugovaya (2005). Onde N corresponde ao número de amostras do sinal de entrada. Fonte: Autoria própria.

A maneira como foi realizada a redução de dimensionalidade do sinal de ECG pela técnica PCA neste trabalho foi diferente da realizada pela Lugovaya (2005), no qual, fez uso de dois métodos para redução: critério de *Kaiser* (reduzindo para 30 amostras) e *Scree test* (reduzindo para 10 amostras).

Além disso, Lugovaya (2005) faz a correção do intervalo QT utilizando a fórmula de Framingham, o que não foi realizado neste trabalho.

Tawfik et al. (2010) investigaram duas diferentes abordagens para compensar a alteração do intervalo QT causado pela alteração da frequência cardíaca: Usando a fórmula de correção de Framingham e usando o comprimento do intervalo QT fixo, concluindo que apenas com o complexo QRS sem qualquer alteração no sinal de ECG foi possível obter melhores resultados. Comprovando que o complexo QRS é estável contra a variabilidade da frequência cardíaca.

A redução da dimensão do sinal pela técnica PCA adotada neste trabalho teve bons resultados. Porém, quando comparada ao trabalho de Lugovaya (2005), não foram muito significativos. Salienta-se que Lugovaya (2005) obteve resultado de 96% de classificação com apenas 30 amostras, e este trabalho, obteve resultado de 93,89% com 280 amostras. No entanto, para a janela contendo as ondas P+QRS (167 amostras) o resultado foi 96,95%.

Para a rede MLP foram realizadas as mesmas análises feitas para a rede ELM. Primeiramente são apresentados os melhores resultados e, em seguida, as considerações sobre os resultados obtidos nos testes.

Com base nos resultados da Tabela 8, são apresentados na Tabela 11 o resultado da classificação obtida pela técnica de redução *wavelet* “db3” nível 1 com ondas P+QRS. Nela estão a relação das pessoas que foram erroneamente identificadas juntamente com as quantidades de registros utilizados para teste.

Tabela 11 – Pessoas erroneamente identificadas considerando a quantidade de registros utilizados para teste com wavelet janela P+QRS (MLP).
Fonte: Autoria própria.

wavelet ondas P+QRS (86 amostras)		
Pessoas com erro na identificação	Nº de registros	Quantidade erroneamente identificada
P ₂	9	1
P ₇	1	1
P ₁₃	1	1
P ₂₀	1	1
P ₂₆	2	1
P ₂₇	1	1
P ₄₆	2	1
P ₅₁	2	2
P ₅₂	4	1
P ₆₀	1	1
P ₆₁	2	1
P ₇₀	1	1
P ₈₀	1	1
P ₈₇	1	1

A maioria das pessoas que tiveram problemas na identificação possuem apenas 1 registro para teste. Para as demais, apenas duas possuem mais de 2 registros para teste.

O problema na classificação da maioria das pessoas utilizadas para teste talvez pudesse ser solucionado aumentando o número de registros.

O melhor resultado obtido com a PCA (Tabela 8) é apresentado na Tabela 12 para verificação das pessoas que tiveram os registros erroneamente identificados pela rede MLP.

Tabela 12 – Pessoas erroneamente identificadas considerando a quantidade de registros utilizados para teste com PCA janela P+QRS (MLP).

Fonte: Autoria própria.

PCA ondas P+QRS (167 amostras)		
Pessoas com erro na identificação	Nº de registros	Quantidade erroneamente identificada
P ₂	9	2
P ₆	1	1
P ₃₂	2	1
P ₄₀	2	1
P ₄₄	1	1
P ₄₆	2	1
P ₅₁	2	2
P ₅₂	4	1
P ₅₉	2	1
P ₆₀	1	1
P ₆₁	2	1
P ₇₀	1	1
P ₈₀	1	1
P ₈₆	1	1
P ₈₇	1	1

Como pode ser observado, a grande maioria das pessoas que apresentaram problemas de identificação, possuem apenas 1 registro para teste. Novamente, o problema pode estar relacionado ao número de registros necessários para que a rede MLP possa melhor generalizar e assim, obter melhores resultados de classificação.

Comparando a Tabela 11 e Tabela 12, observa-se que a técnica de processamento de sinais PCA com a janela contendo as ondas P+QRS (167 amostras) teve o menor número de pessoas que tiveram todos os registros erroneamente identificadas pela rede MLP.

Logo considerando-se o número de pessoas usadas para teste da rede neural MLP, o melhor resultado foi obtido com a técnica de processamento de sinais PCA utilizando a janela P+QRS contendo 167 amostras, na qual, a porcentagem de identificação foi de 91,11%.

As melhores porcentagens de classificação foram agrupadas na Tabela 8, onde observou-se que utilizando a técnica de processamento de sinais *wavelet*, a rede

neural artificial MLP obteve, de modo geral, bons resultados, porém o maior índice de classificação foi obtido com a técnica PCA utilizando a janela P+QRS contendo 167 amostras.

Foi também definido inicialmente o número máximo de épocas como um dos critérios de parada do algoritmo da MLP. Com isso, alguns testes atingiram seu critério de parada antes de atingirem o valor especificado do erro quadrático médio. Uma análise pode ser realizada com o aumento do número máximo de épocas, porém é preciso se ater a memorização excessiva (*overfitting*).

Analisando o desvio padrão de cada rede, pode-se observar que a ELM possui taxas pequenas de variação, ao contrário da MLP, que possui índices mais elevados. Com isso, pode-se deduzir que a ELM não necessita ser treinada várias vezes, porque os resultados demonstram que ela possui pouca variação entre os treinos. Isso constitui um ganho, pois não há necessidade de treinamentos prolongados.

A Tabela 13 apresenta a relação de alguns trabalhos que utilizaram as redes neurais artificiais para classificação do sinal de ECG na identificação de pessoas, incluindo os resultados obtidos neste trabalho.

Tabela 13 – Comparação dos resultados obtidos em trabalhos que utilizaram as Redes Neurais Artificiais.

Fonte: Autoria própria.

Estudo	Nº de pessoas	Classificador	Desempenho
Shen et al. (2002)	20	template matching e DBNN (rede neural artificial baseada em decisão)	template matching: 95% e DBNN: 80%
Wan et al. (2008)	38	Rede neural artificial MLP	100%
Boumbarov et al. (2009)	9	Rede neural artificial RBF	62%
Mohamed M. et al. (2010)	22	Rede neural artificial MLP	99,09%
Chen et al. (2012)	47	Rede neural artificial MLP	75%
Naraghi et al. (2012)	10	Rede neural artificial MLP	95,60%
Wu e Zhang (2014)	33	Rede neural artificial MLP	99,64%
Abbaspour et al. (2015)	78	Rede neural artificial MLP	99,99%
Yarong e Gang (2015)	15	Rede neural artificial MLP	96,40%
Este trabalho	90	Redes neurais artificiais ELM e MLP	ELM: 96,11% MLP: 85,42%

Com base nos trabalhos apresentados na Tabela 13, é possível observar que a grande maioria utiliza pequeno número de pessoas para teste. Dos trabalhos

apresentados, o de Abbaspour et al. (2015) é o mais significativo em relação ao número de indivíduos para teste e também, obteve um excelente resultado. Fazendo uma comparação entre o número de pessoas que foram efetivamente identificadas nos testes realizados neste trabalho, a rede neural artificial ELM conseguiu classificar 87 pessoas (Tabela 10).

8 CONCLUSÃO

Os resultados obtidos pelo emprego das técnicas de processamento de sinais *wavelet* e PCA foram superiores aos de Lugovaya (2005) considerando a taxa de acerto. No entanto, para a técnica de processamento de sinais PCA a redução realizada no trabalho de Lugovaya (2005) foi mais significativa.

Realizando um comparativo entre as duas RNA's, Máquinas de Aprendizado Extremo (*Extreme Learning Machine* – ELM) e *Perceptron* Multicamadas (*Multilayer Perceptron* – MLP) como ferramenta para identificação de pessoas juntamente com o emprego das técnicas de redução de dimensão do ECG, observou-se que o índice de classificação da ELM é maior.

Isto demonstra que o operador de *Moore-Penrose* é uma ferramenta eficaz para este tipo de teste, pois opera de maneira rápida com garantia da norma mínima dos pesos para solução de mínimos quadrados (BARTLETT, 1998).

No que se refere ao tempo de treinamento, observou-se que a ELM supera a MLP, necessitando apenas alguns segundos para classificação. Em contrapartida, a MLP necessita de alguns minutos para realizar a mesma operação.

Com relação às técnicas de processamento de sinais, os resultados foram melhores com o emprego da Análise dos Componentes Principais (*Principal Component Analysis* – PCA) utilizando a ELM. Já para a MLP, os melhores resultados foram com a *wavelet*. Provavelmente isso se deve ao tipo de função utilizada para minimização do erro.

Observando alguns trabalhos que seguem a mesma linha de pesquisa e que utilizam as Redes Neurais Artificiais como técnica de identificação de pessoas, os resultados foram satisfatórios, tendo em vista que, a quantidade de pessoas utilizadas neste trabalho aumentou a complexidade no processo de classificação.

Uma vez que as técnicas de processamento de sinais possuem uma vasta gama de possibilidades de utilização, são necessários maiores estudos nesta área.

9 TRABALHOS FUTUROS

Lugovaya (2005) verifica que apenas 2 componentes principais são insuficientes para classificação. O que deve ser verificado é como ela utilizou o método para realizar a redução das características, e então, comprovar se isso realmente irá interferir na classificação com a emprego das redes neurais artificiais.

Outro ponto importante é com relação a correção do intervalo QT. No trabalho de Lugovaya (2005) foi realizada esta correção utilizando a fórmula de Framingham, o que não foi feito neste trabalho e que pode ou não contribuir na diminuição dos erros de classificação. Apesar de que, no trabalho de Tawfik et al. (2010) os resultados mostram que apenas com o complexo QRS é possível obter melhores resultados.

Com relação a rede ELM, é possível melhorar sua otimização utilizando a seção áurea para busca do coeficiente de regularização, de forma a alcançar um valor mais preciso, o que pode contribuir para melhorar a capacidade de generalização da ELM (KULAIF; ZUBEN, 2014).

Empregar a rede neural artificial Função de Base Radial (RBF – *Radial Basis Functions*) para comparação de desempenho entre as redes utilizadas neste trabalho.

Aumentar o banco de dados de ECG, tanto para pessoas com sinal normal quanto para pessoas com problemas cardiovasculares, com o intuito de evidenciar a validade deste dado biométrico.

Investigar o efeito da variação da taxa cardíaca (frequência cardíaca) sobre a capacidade de generalização das RNA's.

E por fim, utilizar em um sistema embarcado.

REFERÊNCIAS

ABBASPOUR, H.; RAZAVI, S. M.; MEHRSHAD, N. Electrocardiogram Based Identification using a New Effective Intelligent Selection of Fused Features. **Journal of Medical Signals and Sensors**, v. 5, n. 1, p. 30–39, mar. 2015.

ABIBULLAEV, B.; SEO, H. D. A New QRS Detection Method Using Wavelets and Artificial Neural Networks. **Journal of Medical Systems**, v. 35, n. 4, p. 683–691, 20 jan. 2010.

AGRAFIOTI, F.; HATZINAKOS, D. **ECG Based Recognition Using Second Order Statistics**. Communication Networks and Services Research Conference, 2008. CNSR 2008. 6th Annual. **Anais...** In: COMMUNICATION NETWORKS AND SERVICES RESEARCH CONFERENCE, 2008. CNSR 2008. 6TH ANNUAL. Maio 2008a

AGRAFIOTI, F.; HATZINAKOS, D. **Fusion of ECG sources for human identification**. 3rd International Symposium on Communications, Control and Signal Processing, 2008. ISCCSP 2008. **Anais...** In: 3RD INTERNATIONAL SYMPOSIUM ON COMMUNICATIONS, CONTROL AND SIGNAL PROCESSING, 2008. ISCCSP 2008. mar. 2008b

AZEVEDO, F. M. DE; BRASIL, L. M.; OLIVEIRA, R. C. L. DE. **Redes neurais com aplicações em controle e em sistemas especialistas**. Florianópolis, SC: Visual Books, 2000.

BARTLETT, P. L. The sample complexity of pattern classification with neural networks: the size of the weights is more important than the size of the network. **IEEE Transactions on Information Theory**, v. 44, n. 2, p. 525–536, mar. 1998.

BIEL, L. et al. **ECG analysis: a new approach in human identification**. Proceedings of the 16th IEEE Instrumentation and Measurement Technology Conference, 1999. IMTC/99. **Anais...** In: PROCEEDINGS OF THE 16TH IEEE INSTRUMENTATION AND MEASUREMENT TECHNOLOGY CONFERENCE, 1999. IMTC/99. 1999

BIEL, L. et al. ECG analysis: a new approach in human identification. **IEEE Transactions on Instrumentation and Measurement**, v. 50, n. 3, p. 808–812, jun. 2001.

BOCCATO, L. et al. Unorganized Machines: From Turing's Ideas to Modern Connectionist Approaches. **International Journal of Natural Computing Research**, v. 2, n. 4, p. 1–16, 34 2011.

BOUMBAROV, O.; VELCHEV, Y.; SOKOLOV, S. **ECG personal identification in subspaces using radial basis neural networks**. IEEE International Workshop on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications, 2009. IDAACS 2009. **Anais...** In: IEEE INTERNATIONAL WORKSHOP ON INTELLIGENT DATA ACQUISITION AND ADVANCED COMPUTING SYSTEMS: TECHNOLOGY AND APPLICATIONS, 2009. IDAACS 2009. set. 2009

BRAGA, A. DE P. **Redes neurais artificiais teoria e aplicações**. Rio de Janeiro: Livros Técnicos e Científicos, 2000.

BUENO-CRESPO, A.; GARCÍA-LAENCINA, P. J.; SANCHO-GÓMEZ, J.-L. Neural architecture design based on extreme learning machine. **Neural Networks**, v. 48, p. 19–24, dez. 2013.

CALIL, J.; GOMIDE, E. Equipamentos médico-hospitalares e o gerenciamento da manutenção–capacitação a distância. **Série F–Comunicação e Educação em Saúde. Secretaria de Gestão de Investimentos em Saúde, projeto REFORSUS. Ministério da Saúde. Brasília**, 2002.

CARR, J. J.; BROWN, J. M. **Introduction to biomedical equipment technology**. 4th ed. Upper Saddle River, N.J: Prentice Hall, 2001.

CARTER, R. et al. **O livro do cérebro**. Rio de Janeiro: Agir, 2012.

CASTELLS, F. et al. Principal Component Analysis in ECG Signal Processing. **EURASIP J. Appl. Signal Process.**, v. 2007, n. 1, p. 98–98, jan. 2007.

CHAN, A. D. C. et al. **Person Identification using Electrocardiograms**. IEEE, 2006Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4055075>>. Acesso em: 20 ago. 2015

CHAN, A. D. C. et al. Wavelet Distance Measure for Person Identification Using Electrocardiograms. **IEEE Transactions on Instrumentation and Measurement**, v. 57, n. 2, p. 248–253, 2008.

CHEN, H. et al. **A new ECG identification with neural network**. IEEE, dez. 2012Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6421372>>. Acesso em: 3 dez. 2015

CHIU, C.-C.; CHUANG, C.-M.; HSU, C.-Y. **A Novel Personal Identity Verification Approach Using a Discrete Wavelet Transform of the ECG Signal**. IEEE, 2008Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4505721>>. Acesso em: 15 nov. 2015

CYBENKO, G. Approximation by superposition of sigmoidal functions. **Mathematics of Control, Signals and Systems**, v. 2, n. 4, p. 303–314, 1989.

DAUBECHIES, I. **Ten Lectures on Wavelets**. [s.l.] Society for Industrial and Applied Mathematics, 1992.

DE CASTRO, L. N. **Fundamentals of Natural Computing Basic Concepts, Algorithms, and Applications**. Hoboken: CRC Press, 2006.

DONOHO, D. L. De-noising by soft-thresholding. **IEEE Transactions on Information Theory**, v. 41, n. 3, p. 613–627, Maio 1995.

FATEMIAN, S. Z.; HATZINAKOS, D. **A new ECG feature extractor for biometric recognition**. 2009 16th International Conference on Digital Signal Processing. **Anais...** In: 2009 16TH INTERNATIONAL CONFERENCE ON DIGITAL SIGNAL PROCESSING. jul. 2009

FATTAH, S. A. et al. **Human identification method using time and wavelet domain features based on modified dECG**. 2012 7th International Conference on Electrical Computer Engineering (ICECE). **Anais...** In: 2012 7TH INTERNATIONAL CONFERENCE ON ELECTRICAL COMPUTER ENGINEERING (ICECE). Dezembro 2012

GAHI, Y. et al. **Biometric Identification System Based on Electrocardiogram Data**. IEEE, nov. 2008 Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4689083>>. Acesso em: 15 jan. 2016

GARCIA, I. A. **A segurança na identificação: a biometria da íris e da retina**. text— [s.l.] Universidade de São Paulo, 20 maio 2009.

GIFFONI, R. T.; TORRES, R. M. Breve história da eletrocardiografia. v. 20, n. 2, p. 263–270, 2010.

GOLDBERGER, A. L. et al. PhysioBank, PhysioToolkit, and PhysioNet : Components of a New Research Resource for Complex Physiologic Signals. **Circulation**, v. 101, n. 23, p. e215–e220, 13 jun. 2000.

GÜLER, İ.; ÜBEYLI, E. D. ECG beat classifier designed by combined neural network model. **Pattern Recognition**, v. 38, n. 2, p. 199–208, fev. 2005.

GUPTA, H. R.; MEHRA, R.; BATAN, S. Power spectrum estimation using Welch method for various window techniques. **International Journal of Scientific Research Engineering & Technology**, v. 2, n. 6, p. 389–392, 2013.

GUTIERREZ, C. E. C. **Eliminação do ruído por encolhimento de wavelets: Uma aplicação à série de Preço Spot de Energia Elétrica do Brasil**. Rio de Janeiro: PUC-Rio, 2002.

HALL, J. E.; GUYTON, A. C. **Guyton and Hall textbook of medical physiology**. 12th ed ed. Philadelphia, Pa: Saunders/Elsevier, 2011.

HAYKIN, S.; ENGEL, P. M. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001.

HUANG, G.-B. et al. Extreme Learning Machine for Regression and Multiclass Classification. **IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics**, v. 42, n. 2, p. 513–529, abr. 2012.

HUANG, G.-B.; WANG, D. H.; LAN, Y. Extreme learning machines: a survey. **International Journal of Machine Learning and Cybernetics**, v. 2, n. 2, p. 107–122, 25 maio 2011.

HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. **Extreme learning machine: a new learning scheme of feedforward neural networks**. 2004 IEEE International Joint Conference on Neural Networks, 2004. Proceedings. **Anais...** In: 2004 IEEE INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2004. PROCEEDINGS. jul. 2004

HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: Theory and applications. **Neurocomputing**, Neural Networks Selected Papers from the 7th Brazilian Symposium on Neural Networks (SBRN '04) 7th Brazilian Symposium on Neural Networks. v. 70, n. 1–3, p. 489–501, dez. 2006.

HYVÄRINEN, A.; KARHUNEN, J.; OJA, E. **Independent Component Analysis**. [s.l.] John Wiley & Sons, 2004.

JAIN, A. K.; ROSS, A. A.; NANDAKUMAR, K. **Introduction to biometrics**. New York: Springer, 2011.

JAIN, A. K.; ROSS, A.; PRABHAKAR, S. An introduction to biometric recognition. **IEEE Transactions on Circuits and Systems for Video Technology**, v. 14, n. 1, p. 4–20, jan. 2004.

JBATT. **EKG Training Life as a Medical Student**, 16 ago. 2009. Disponível em: <<http://lifeasamedicalstudent.blogspot.com.br/2009/08/ekg-training.html>>. Acesso em: 23 nov. 2015

JOLLIFFE, I. T. **Principal Component Analysis**. [s.l.] Springer Science & Business Media, 2006.

KONG, A.; ZHANG, D.; KAMEL, M. A survey of palmprint recognition. **Pattern Recognition**, v. 42, n. 7, p. 1408–1418, 2009.

KULAIF, A. C. P.; ZUBEN, F. J. V. **Técnicas de regularização para máquinas de aprendizado extremo**. Dissertação de Mestrado. Disponível em: <<http://www.bibliotecadigital.unicamp.br/document/?code=000938122>>. Acesso em: 1 out. 2016.

LEHNINGER, A. L. et al. **Lehninger Princípios de bioquímica**. São Paulo: Sarvier, 2002.

LOUZADA, H. A.; SIRAVENHA, A. C. Q.; PELAES, E. G. Utilização de Redes Neurais do tipo Extreme Learning Machine na classificação da cobertura de solo do Município de Novo Progresso-PA. 2015.

LUGOVAYA, T. S. Biometric Human Identification based on ECG. jun. 2005.

MAHMOODABADI, S. Z. et al. **ECG Feature Extraction Based on Multiresolution Wavelet Transform**. 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference. **Anais...** In: 2005 IEEE ENGINEERING IN MEDICINE AND BIOLOGY 27TH ANNUAL CONFERENCE. jan. 2005

MALEGORI, G.; FERRINI, G. Tip-sample interactions on graphite studied using the wavelet transform. **Beilstein Journal of Nanotechnology**, v. 1, p. 172–181, 22 dez. 2010.

MALLAT, S. G. **A wavelet tour of signal processing: the sparse way.** 3rd ed ed. Amsterdam ; Boston: Elsevier/Academic Press, 2009.

MARTINS, L. **Tecido Nervoso.** Disponível em: <<http://www.infoescola.com/biologia/tecido-nervoso/>>. Acesso em: 18 nov. 2015.

MATHWORKS. **Wavelet Families.** Disponível em: <<http://www.mathworks.com/help/wavelet/ug/wavelet-families-additional-discussion.html>>. Acesso em: 18 dez. 2016a.

MATHWORKS. **Introduction to Wavelet Families.** Disponível em: <<http://www.mathworks.com/help/wavelet/gs/introduction-to-the-wavelet-families.html>>. Acesso em: 18 dez. 2016b.

MATHWORKS. **wavedec.** Disponível em: <<http://www.mathworks.com/help/wavelet/ref/wavedec.html>>. Acesso em: 1 jul. 2017c.

MATHWORKS. **Critically-Sampled Discrete Wavelet Transform.** Disponível em: <<http://www.mathworks.com/help/wavelet/gs/discrete-wavelet-transform.html>>. Acesso em: 28 jul. 2016d.

MATHWORKS. **Critically-Sampled Wavelet Reconstruction.** Disponível em: <<http://www.mathworks.com/help/wavelet/gs/wavelet-reconstruction.html>>. Acesso em: 28 jul. 2016e.

MATTANA, C. et al. Brazilian Journal of Forensic Sciences, Medical Law and Bioethics. 2012.

MAZI, R. C.; DAL PINO JÚNIOR, A. Identificação biométrica através da impressão digital usando redes neurais artificiais. **Anais do XIV ENCITA**, p. 19–22, 2008.

MOND, H. G.; GARCIA, J.; VISAGATHILAGAR, T. Twisted Leads: The Footprints of Malpositioned Electrocardiographic Leads. **Heart, Lung and Circulation**, 10 jun. 2015.

MORTON, P. G. et al. **Critical care nursing: a holistic approach.** [s.l.] Lippincott Williams & Wilkins Philadelphia, 2005. v. 1

NAJARIAN, K.; SPLINTER, R. **Biomedical Signal and Image Processing, Second Edition.** 2 edition ed. Boca Raton, Fla.: CRC Press, 2012.

NARAGHI, M., Eahi; ALMASI, A.; SHAMSOLLAHI, M., Bagher. **Human Identification Using ECG Feature Extracted from Innovation Signal of Extended Kalman Filter.** . In: BIOMEDICAL ENGINEERING AND INFORMATICS (BMEI), 2012 5TH INTERNATIONAL CONFERENCE ON. Chongqing: 2012

NUNES, F. T. TÉCNICAS DE BIOMETRIA BASEADAS EM PADRÕES FACIAIS E SUA UTILIZAÇÃO NA SEGURANÇA PÚBLICA. 9 jul. 2015.

OME. **ECG (EKG) - bundle branch block**Oxford Medical Education, 2014. Disponível em: <<http://www.oxfordmedicaleducation.com/ecg/bundle-branch-block/>>. Acesso em: 12 nov. 2015

PAL, S.; MITRA, M. Increasing the accuracy of ECG based biometric analysis by data modelling. **Measurement**, v. 45, n. 7, p. 1927–1932, ago. 2012.

PASTORE, C. A. et al. Diretrizes da Sociedade Brasileira de Cardiologia sobre Análise e Emissão de Laudos Eletrocardiográficos. **Arquivos Brasileiros de Cardiologia**, v. 93, n. 3, p. 1–19, 2009.

PATHOUMVANH, S. et al. **ECG analysis for person identification**. IEEE, out. 2013Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6687703>>. Acesso em: 3 dez. 2015

PLATANIOTIS, K. N.; HATZINAKOS, D.; LEE, J. K. M. **ECG Biometric Recognition Without Fiducial Detection**. Biometric Consortium Conference, 2006 Biometrics Symposium: Special Session on Research at the. **Anais...** In: BIOMETRIC CONSORTIUM CONFERENCE, 2006 BIOMETRICS SYMPOSIUM: SPECIAL SESSION ON RESEARCH AT THE. set. 2006

QIBIN ZHAO; LIQING ZHANG. **ECG Feature Extraction and Classification Using Wavelet Transform and Support Vector Machines**. IEEE, 2005Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1614807>>. Acesso em: 15 jan. 2016

RIOUL, O.; VETTERLI, M. Wavelets and signal processing. **IEEE Signal Processing Magazine**, v. 8, n. 4, p. 14–38, out. 1991.

SAECHIA, S.; KOSEYAPORN, J.; WARDKEIN, P. **Human Identification System Based ECG Signal**. TENCON 2005 2005 IEEE Region 10. **Anais...** In: TENCON 2005 2005 IEEE REGION 10. nov. 2005

SAHAMBI, J. S.; TANDON, S. N.; BHATT, R. K. P. Using wavelet transforms for ECG characterization. An on-line digital signal processing system. **IEEE Engineering in Medicine and Biology Magazine**, v. 16, n. 1, p. 77–83, jan. 1997.

SÁNCHEZ, J. E. R. **Sistema de Monitoramento de Múltiplos Sensores por Redes Neurais Auto-Associativas e Lógica Fuzzy**. [s.l.] PUC-Rio, 2011.

SANTOSO, S. et al. Power quality assessment via wavelet transform analysis. **IEEE Transactions on Power Delivery**, v. 11, n. 2, p. 924–930, abr. 1996.

SHEN, T. W.; TOMPKINS, W. J.; HU, Y. H. **One-lead ECG for identity verification**. IEEE, 2002Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1134388>>. Acesso em: 19 ago. 2015

SHEN, T.-W.; TOMPKINS, W. J.; HU, Y. H. Implementation of a one-lead ECG human identification system on a normal population. **Journal of Engineering and Computer Innovations**, v. 2, n. 1, p. 12–21, 2011.

SHLENS, J. A Tutorial on Principal Component Analysis. **arXiv:1404.1100 [cs, stat]**, 3 abr. 2014.

SILVA, J. F. DA [UNESP. Sistema de armazenamento de imagens comprimidas através da transformada wavelet. **Aleph**, p. 99 f. : il., (algumas color.), 25 jun. 2008.

SILVA, I. N. DA; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**. 1. ed. São Paulo, SP: Artliber, 2010.

SMITH, L. I. A tutorial on principal components analysis. **Cornell University, USA**, v. 51, p. 52, 2002.

SUFI, F.; KHALIL, I.; HU, J. ECG-Based Authentication. In: STAVROULAKIS, P.; STAMP, M. (Eds.). **Handbook of Information and Communication Security**. [s.l.] Springer Berlin Heidelberg, 2010. p. 309–331.

SUNG, K.-K.; POGGIO, T. Example-based learning for view-based human face detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 20, n. 1, p. 39–51, jan. 1998.

TAWFIK, M. M.; SELIM, H.; KAMAL, T. **Human identification using time normalized QT signal and the QRS complex of the ECG**. In: COMMUNICATION SYSTEMS NETWORKS AND DIGITAL SIGNAL PROCESSING (CSNDSP), 2010 7TH INTERNATIONAL SYMPOSIUM ON. Newcastle upon Tyne: IEEE, 2010. Disponível em: <http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=5580317>

TORTORA, G. J.; DERRICKSON, B. **Corpo humano: fundamentos de anatomia e fisiologia**. [s.l: s.n.].

VERGARA, G. et al. Comparing ELM Against MLP for Electrical Power Prediction in Buildings. In: VICENTE, J. M. F. et al. (Eds.). **Bioinspired Computation in Artificial Systems**. Lecture Notes in Computer Science. [s.l.] Springer International Publishing, 2015. p. 409–418.

WAN, Y.; YAO, J.; MEMBER, S. A Neural Network to Identify Human Subjects with Electrocardiogram Signals. In: **Proceedings of the World Congress on Engineering and Computer Science**, p. 1–4, 2008.

WANG, Y.; PLATANIOTIS, K. N.; HATZINAKOS, D. **Integrating Analytic and Appearance Attributes for Human Identification from ECG Signals**. Biometric Consortium Conference, 2006 Biometrics Symposium: Special Session on Research at the. **Anais...** In: BIOMETRIC CONSORTIUM CONFERENCE, 2006 BIOMETRICS SYMPOSIUM: SPECIAL SESSION ON RESEARCH AT THE. set. 2006

WEBSTER, J. G.; CLARK, J. W. (EDS.). **Medical instrumentation: application and design**. 4th ed ed. Hoboken, NJ: John Wiley & Sons, 2010.

WU, J. J.; ZHANG, Y. **ECG identification based on neural networks**. 2014 11th International Computer Conference on Wavelet Active Media Technology and Information Processing (ICCWAMTIP). **Anais...** In: 2014 11TH INTERNATIONAL COMPUTER CONFERENCE ON WAVELET ACTIVE MEDIA TECHNOLOGY AND INFORMATION PROCESSING (ICCWAMTIP). dez. 2014a

WU, J.-J.; ZHANG, Y. **ECG identification based on neural networks**. IEEE, dez. 2014bDisponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7073368>>. Acesso em: 3 dez. 2015

YARONG, W.; GANG, Z. Study of human identification by Electrocardiography frequency features. 2015.

YOUNG, R. K. **Wavelet Theory and Its Applications**. [s.l.] Springer Science & Business Media, 1993.

ZHANG, Z.; WEI, D. **A New ECG Identification Method Using Bayes' Teorem**. IEEE, 2006Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4142615>>. Acesso em: 15 jan. 2016