

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

REGIS AUGUSTO CARDOZO

**SISTEMA DE APOIO AO DIAGNÓSTICO DE ARRITMIAS
CARDÍACAS**

DISSERTAÇÃO

**PONTA GROSSA
2018**

REGIS AUGUSTO CARDOZO

**SISTEMA DE APOIO AO DIAGNÓSTICO DE ARRITMIAS
CARDÍACAS**

Dissertação apresentada como requisito parcial à 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

PONTA GROSSA

2018

Ficha catalográfica elaborada pelo Departamento de Biblioteca
da Universidade Tecnológica Federal do Paraná, Câmpus Ponta Grossa
n.37/18

C268 Cardozo, Regis Augusto

Sistema de apoio ao diagnóstico de arritmias cardíacas. / Regis Augusto
Cardozo. 2017.
124 f.; il. 30 cm

Orientador: Prof. Dr. Sérgio Okida

Dissertação (Mestrado em Engenharia Elétrica) - Programa de Pós-Graduação
em Engenharia Elétrica. Universidade Tecnológica Federal do Paraná, Ponta
Grossa, 2018.

1. Coração - Doenças. 2. Arritmia - Diagnóstico. 3. Análise de componentes
principais. I. Okida, Sérgio. II. Universidade Tecnológica Federal do Paraná. III.
Título.

CDD 621.3

Elson Heraldo Ribeiro Junior. CRB-9/1413. 03/07/2018.



**Universidade Tecnológica Federal do
Paraná Campus de Ponta Grossa**
Diretoria de Pesquisa e Pós-Graduação
**PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA**



FOLHA DE APROVAÇÃO

Título de Dissertação Nº **40/2017**

SISTEMA DE APOIO AO DIAGNÓSTICO DE ARRITMIAS CARDÍACAS

por

Regis Augusto Cardozo

Esta dissertação foi apresentada às **15 horas e 30 minutos** do dia **22 de fevereiro de 2018** como requisito parcial para a obtenção do título de MESTRE EM ENGENHARIA ELÉTRICA, com área de concentração em Controle e Processamento de Energia, Programa de Pós-Graduação 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. Dr. Kathya Silvia Collazos Linares
(UTFPR)**

**Prof. Dr. Hugo Valadares Siqueira
(UTFPR)**

Prof. Dr. Sergio Okida (UTFPR)
Orientador

Prof. Dr. Angelo Marcelo Tuset
Coordenador do PPGEE

A FOLHA DE APROVAÇÃO ASSINADA ENCONTRA-SE NO DEPARTAMENTO DE
REGISTROS ACADÊMICOS DA UTFPR – CÂMPUS PONTA GROSSA

AGRADECIMENTOS

Deus esteve ao meu lado e me deu força, ânimo e crença para não desistir e continuar lutando por este meu sonho e objetivo de vida. À Ele, eu devo minha gratidão.

À esta instituição tão imponente, eu agradeço pelo ambiente propício à evolução e crescimento; bem como à todas as pessoas que a tornam assim tão especial para quem conhece.

Ao longo de todo meu percurso, eu tive o privilégio de trabalhar de perto com os melhores professores, educadores e orientadores. Sem eles, não seria possível estar aqui hoje de coração repleto de orgulho.

À minha família e amigos que nunca desistiram de mim e sempre me ofereceram amor, especialmente aos meus pais, por todo suporte, a estes uma promessa de gratidão eterna.

À todas as pessoas que de alguma forma fizeram parte da minha trajetória, eu agradeço com todo meu coração.

E, por último, mas não menos importante, à minha companheira, que me deu o incentivo final para a realização e conclusão deste trabalho.

RESUMO

CARDOZO, Regis Augusto. **Sistema de Apoio a Diagnóstico de Arritmias Cardíacas**. 2018. 124 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2018.

Em 2013, 4,2% da população brasileira com idade acima de 18 anos tiveram algum diagnóstico de doenças cardíacas; 13,5% destas apresentaram limitações nas suas atividades habituais devido à doença. Desta forma, o uso de sistemas de auxílio médico que produzam um bom desempenho é algo desejável, pois, além de auxiliarem médicos especialistas no diagnóstico de doenças de um modo geral, sistemas com este propósito podem ser utilizados em momentos em que a presença destes especialistas para a análise dos resultados nem sempre é possível. Sistemas assim são, também, úteis na monitorização de pacientes com equipamentos do tipo *mHealth*. Deste modo, este trabalho propõe e avalia um sistema de auxílio a diagnóstico de arritmias cardíacas, para a classificação de 11 tipos de batimentos cardíacos que foram agrupados em 5 supertipos, utilizando-se de sinais eletrocardiográficos. Avaliando-se a influência de uma técnica de filtragem adaptativa com o uso de Filtro Morfológico e de uma técnica mais clássica, baseada em filtros de resposta ao impulso finito, a Transformada *Wavelet* Discreta. As características extraídas do sinal de eletrocardiograma foram obtidas com a análise de componentes principais (PCA), variando a quantidade de componentes entre 10, 12 e 14. Assim como, foram avaliados alguns classificadores baseados em redes neurais artificiais (RNAs). Duas RNAs de função de base radial (RBF) híbridas com a RNA máquina de aprendizado extremo (ELM), uma com uma camada oculta e outra com duas; e duas RNAs com apenas a ELM, porém com duas funções de ativação diferentes (Função Logística e Função Gaussiana). Outro ponto avaliado foi a influência da presença ou não do coeficiente de regularização no algoritmo ELM. Os resultados foram obtidos através do método de validação cruzada por k partições, com 5 partições sendo combinadas 2 a 2, de modo a se realizar 10 treinamentos e testes, utilizando-se 2 partições para treinamento e as outras 3 para o teste. Os resultados alcançados demonstram que as funções de ativação testadas não afetam de forma significativa os resultados nas RNAs ELM. Foi observado, igualmente, que o coeficiente de regularização apenas influencia os resultados quando há mais de 1000 neurônios na camada escondida, com a apresentação de resultados melhores. Concluiu-se, também, que apesar de na maioria dos casos o resultado não ser afetado pela técnica de filtragem, o Filtro Morfológico apresentou resultados levemente melhores onde há resultados significativamente diferentes. Por fim, tem-se que o melhor resultado obtido foi de $96,61 \pm 0,51\%$ com Filtro Morfológico com a RNA ELM, com 12 componentes principais e 1500 neurônios na camada escondida.

Palavras-chave: Sistema de Auxílio a Diagnóstico. Arritmias Cardíacas. Redes de Função de Base Radial. Máquina de Aprendizado Extremo. Análise de Componentes Principais.

ABSTRACT

CARDOZO, Regis Augusto. **Diagnosis Assistance System for Cardiac Arrhythmia**. 2018. 124 p. Dissertation (Master Degree in Electrical Engineering) – Federal Technology University – Paraná. Ponta Grossa, 2018.

In 2013, 4.2% of the Brazilian population over the age of 18 had a diagnosis of heart disease, 13.5% of whom had limitations in their usual activities due to the disease. Therefore the use of medical assistance systems that produce a good performance is desirable. Besides helping medical specialists in the diagnosis of diseases, systems for this purpose may be used when the presence of this specialist for the analysis of the results is not always possible. Being useful also in patients monitoring equipment of the mHealth type. Thus, this work proposes and evaluates a diagnosis assistance system of cardiac arrhythmias, to classify 11 types of heart beats that were grouped into 5 supertypes, using electrocardiographic signals. This work evaluates the influence of an adaptive filtering technique with the use of Morphological Filter and a classical technique based on finite impulse response filters, the Discrete Wavelet Transform. The characteristics extracted from the electrocardiogram signal were obtained with the principal component analysis (PCA), varying the number of components between 10, 12 and 14. Some classifiers based on artificial neural networks (ANNs) were also evaluated. Two hybrid radial-based function ANNs (RBFs) with the training algorithm of extreme learning machine (ELM) ANN, one with one hidden layer and the other with two; and two ANNs with only the ELM algorithm, but with two different activation functions (Logistic Function and Gaussian Function). Another point evaluated was the influence of the presence or not of the regularization coefficient in the ELM algorithm. The results were obtained by the k -partitions validation method, with 5 partitions being combined 2 by 2, in order to perform 10 training and tests, using 2 partitions for training and the other 3 for testing. The results obtained demonstrate that the tested activation function do not affect significantly the results on the RNAs with ELM algorithm. It was also observed that the regularization coefficient has only influenced the results when there are more than 1000 neurons in the hidden layer, always presenting better results. It was also concluded that although in most cases the result is not affected by the filtering technique, the Morphological Filter presents slightly better results where there are significantly different results. Finally, the best average accuracy obtained was $96.61 \pm 0.51\%$, with Morphological Filter, RNA with ELM algorithm, 12 principal components and 1500 neurons in the hidden layer.

Keywords: Diagnosis Assistance System. Cardiac Arrhythmia. Radial-Based Function Artificial Neural Network. Extreme Learning Machine. Principal Component Analysis.

LISTA DE FIGURAS

Figura 1 – Estrutura do coração humano e fluxo do sangue	21
Figura 2 – Estrutura do sistema excitatório do coração humano.....	22
Figura 3 – Sinal de ECG e suas principais ondas	23
Figura 4 – Posicionamento clássico dos eletrodos num exame de ECG	24
Figura 5 – Ponto do terminal central de referência de Wilson	25
Figura 6 – Derivações unipolares precordiais e seus respectivos eletrodos	25
Figura 7 – Análise multiresolução com esquema piramidal de um sinal $x(n)$	48
Figura 8 – Análise multiresolução com banco de filtros com decomposição e reconstrução do sinal discreto $x(n)$ (a) e com decomposição do sinal $x(n)$ em várias escalas (b)	49
Figura 9 – Neurônio artificial.....	52
Figura 10 – Formato de uma RNA com uma camada escondida.....	55
Figura 11 – Validação cruzada por amostragem aleatória	60
Figura 12 – Validação cruzada por k -partições	61
Figura 13 – Etapas de operação de um sistema de identificação de arritmias cardíacas.....	62
Figura 14 – Funcionamento do filtro morfológico de Sun, Chan e Krishnan (2002) ..	66
Figura 15 – Exemplo da filtragem utilizando Filtro Morfológico. (a) Sinal Original; (b) Flutuação de Linha de Base; (c) Sinal sem Linha de Base; (d) Sinal Filtrado.....	67
Figura 16 – Filtros obtido da Wavelet mãe Daubechie D6, para Decomposição: (a) Passa-Baixa; (b) Passa-Alta; e para Reconstrução (c) Passa-Baixa; (d) Passa-Alta	68
Figura 17 – Decomposição (a) e Reconstrução (b) <i>Wavelet</i> de 9 níveis aplicada neste trabalho.....	69
Figura 18 – Exemplo da filtragem utilizando Transformada <i>Wavelet</i> . (a) Sinal Original; (b) Flutuação de Linha de Base; (c) Sinal Filtrado	70
Figura 19 – Algoritmo de Pan e Tompkins (1985)	72
Figura 20 – Técnica dos limiares adaptativos de Pan e Tompkins (1985)	73
Figura 21 – Exemplo da segmentação dos batimentos cardíacos em trecho do 108 da base de dados MIT-BIH.....	75
Figura 22 – RNA Híbrida RBF-ELM com duas camadas escondidas	78
Figura 23 – Formato da RNA com uma camada escondida utilizada neste trabalho	80
Figura 24 – Formato da RNA com duas camadas escondidas utilizada neste trabalho	81
Figura 25 – Exemplo de sinal de ECG (a) e seu respectivo espectro de frequência (b)	84
Figura 26 – Comparação entre as componentes de frequência de um sinal de ECG sem filtro, filtrado com Filtro Morfológico e com Transformada <i>Wavelet</i>	85

LISTA DE GRÁFICOS

Gráfico 1 – Exemplo da operação de erosão (a) e dilatação (b) num sinal unidimensional	40
Gráfico 2 – Exemplo da operação de abertura(a) e fechamento(b) num sinal unidimensional	41
Gráfico 3 – Exemplo de funções <i>wavelet</i> ; (a) Daubechie 4; (b) Daubechie 6; (c) Symlet 8; (d) Coiflet 3.....	43
Gráfico 4 – Exemplo do uso dos parâmetros de dilatação e translação em uma função <i>wavelet</i> discreta.....	46
Gráfico 5 – Exemplo de funções de ativação; (a) Rampa Simétrica 4; (b) Logística; (c) Gaussiana.....	53
Gráfico 6 – Análise da variância dos componentes principais após filtragem com a Transformada <i>Wavelet</i> (a) e com o Filtro Morfológico (b)	77
Gráfico 7 – Efeito do Coeficiente de Regularização na rede ELM com Função Logística com 10 componentes principais e filtragem por Transformada <i>Wavelet</i> , com 500 (a) e 1500 (b) neurônios na camada escondida	88
Gráfico 8 – Taxa de acerto médio após filtragem com a Transformada <i>Wavelet</i> e com o Filtro Morfológico com 10 componentes principais, para: (a) ELM com Função Logística/Gaussiana; (b) Rede Híbrida RBF-ELM.....	90
Gráfico 9 – Taxa de acerto médio do algoritmo RBF-ELM Híbrido com 10 componentes principais após filtragem com a Transformada <i>Wavelet</i> (a) e com o Filtro Morfológico (b).....	91
Gráfico 10 – Taxa de acerto médio após filtragem com a Transformada <i>Wavelet</i> e com o Filtro Morfológico com 12 componentes principais: (a) ELM com Função Logística/Gaussiana; (b) Rede Híbrida RBF-ELM.....	92
Gráfico 11 – Taxa de acerto médio do algoritmo RBF-ELM Híbrido com 12 componentes principais após filtragem com a Transformada <i>Wavelet</i> (a) e com o Filtro Morfológico (b).....	93
Gráfico 12 – Taxa de acerto médio após filtragem com a Transformada <i>Wavelet</i> e com o Filtro Morfológico com 14 componentes principais: (a) ELM com Função Logística/Gaussiana; (b) Rede Híbrida RBF-ELM.....	95
Gráfico 13 – Taxa de acerto médio do algoritmo RBF-ELM Híbrido com 14 componentes principais após filtragem com a Transformada <i>Wavelet</i> (a) e com o Filtro Morfológico (b).....	95

LISTA DE TABELAS

Tabela 1 – Desempenho de detectores de complexo QRS.....	30
Tabela 2 – Desempenho de trabalhos encontrados na literatura que classificam sobre a norma AAMI (1995)	37
Tabela 3 – Frequência de corte de 9 níveis de decomposição <i>wavelet</i> pelo lado da aproximação para uma frequência de amostragem de 360 amostras/s	70
Tabela 4 – Quantidade de batimentos utilizados nos algoritmos de inteligência computacional com Transformada <i>Wavelet</i>	79
Tabela 5 – Quantidade de batimentos utilizados nos algoritmos de inteligência computacional com Filtro Morfológico	79
Tabela 6 – Exemplo valores críticos da distribuição <i>t</i> de Student para os níveis de significância de 10%, 5%, 2% e 1%	83
Tabela 7 – Resultados que apresentaram diferença significativa ($\alpha = 0,05$, $GL = 18$, $t = 2,101$) para a taxa de acerto médio para o algoritmo ELM com Função Logística.....	86
Tabela 8 – Resultados que apresentaram diferença significativa ($\alpha = 0,05$, $GL = 18$, $t = 2,101$) para a taxa de acerto médio para o algoritmo ELM com Função Gaussiana	87
Tabela 9 – Taxa de acerto no teste das redes ELM com Função Logística/Gaussiana e a Rede Híbrida RBF-ELM com 10 componentes principais	90
Tabela 10 – Taxa de acerto no teste das redes ELM com Função Logística/Gaussiana e Rede Híbrida RBF- ELM com 12 componentes principais	92
Tabela 11 – Taxa de acerto no teste das redes ELM com Função Logística/Gaussiana e Rede Híbrida RBF-ELM com 14 componentes principais	94
Tabela 12 – Comparativo entre os melhores resultados para as propostas de RNAs	96
Tabela 13 – Melhores resultados para as propostas de RNAs	97
Tabela 14 – Média de acerto, Sensibilidade, Especificidade, Valor Preditivo Positivo e Valor Preditivo Negativo por tipo de batimento da RNA ELM com Função Logística/Gaussiana, com 12 Componentes Principais e filtragem por Filtro Morfológico.....	98
Tabela 15 – Média de acerto, Sensibilidade, Especificidade, Valor Preditivo Positivo e Valor Preditivo Negativo por tipo de batimento da RNA Híbrida RBF-ELM com 1 camada escondida, com 14 Componentes Principais e filtragem por Transformada <i>Wavelet</i>	99
Tabela 16 – Média de acerto, Sensibilidade, Especificidade, Valor Preditivo Positivo e Valor Preditivo Negativo por tipo de batimento da RNA Híbrida RBF-ELM com 2 camadas escondidas, com 14 Componentes Principais e filtragem por Transformada <i>Wavelet</i>	100
Tabela 17 – Comparativo entre os melhores resultados deste trabalho e de outros que utilizam RNAs	101
Tabela 18 – Taxa de acerto no teste do algoritmo RBF-ELM Híbrido com 10 componentes principais com filtragem por Transformada <i>Wavelet</i>	122

Tabela 19 – Taxa de acerto no teste do algoritmo RBF-ELM Híbrido com 10 componentes principais com filtragem por Filtro Morfológico	122
Tabela 20 – Taxa de acerto no teste do algoritmo RBF-ELM Híbrido com 12 componentes principais com filtragem por Transformada <i>Wavelet</i>	123
Tabela 21 – Taxa de acerto no teste do algoritmo RBF-ELM Híbrido com 12 componentes principais com filtragem por Filtro Morfológico	123
Tabela 22 – Taxa de acerto no teste do algoritmo RBF-ELM Híbrido com 14 componentes principais com filtragem por Transformada <i>Wavelet</i>	124
Tabela 23 – Taxa de acerto no teste do algoritmo RBF-ELM Híbrido com 14 componentes principais com filtragem por Filtro Morfológico	124

LISTA DE SIGLAS

α	Nível de significância; valor-p; <i>p-value</i>
ADC	Conversor Analógico Digital (<i>Analog to Digital Converter</i>)
<i>aVF</i>	Derivação frontal aumentada de Emanuel Goldberger do posicionamento de eletrodos durante um exame de eletrocardiograma
<i>aVL</i>	Derivação lateral esquerda aumentada de Emanuel Goldberger do posicionamento de eletrodos durante um exame de eletrocardiograma
<i>aVR</i>	Derivação lateral direita aumentada de Emanuel Goldberger do posicionamento de eletrodos durante um exame de eletrocardiograma
BD	Batimento Desconhecido, composto por: PV, FR e batimentos não classificados
BEA	Batimento de Escape Atrial
BEV	Batimento de Escape Ventricular
BF	Batimento de Fusão
BIH	Hospital Beth Israel (<i>Beth Israel Hospital</i>)
BNE	Batimento não Ectópico, composto por: batimentos normais, BRE, BRD e BEA
BRD	Bloqueio de Ramo Direito
BRE	Bloqueio de Ramo Esquerdo
BSE	Batimento Supraventricular Ectópico, composto por: EA, EAA e extrassístole juncional
BVE	Batimento Ventricular Ectópico, composto por: EV e BEV
CR	Coeficiente/Fator de Regularização
CWT	Transformada <i>Wavelet</i> Contínua (<i>Continuous Wavelete Transform</i>)
DSP	Processador Digital de Sinais (<i>Digital Signal Processor</i>)
<i>D1</i>	Derivação bipolar 1 de Einthoven do posicionamento de eletrodos durante um exame de eletrocardiograma
<i>D2</i>	Derivação bipolar 2 de Einthoven do posicionamento de eletrodos durante um exame de eletrocardiograma
<i>D3</i>	Derivação bipolar 3 de Einthoven do posicionamento de eletrodos durante um exame de eletrocardiograma
DCT	Transformada de Cosseno Discreta (<i>Discret Cosine Transform</i>)
DTCWT	Decomposição <i>Wavelet</i> Complexa de Duas Árvores (<i>Dual Tree Complex Wavelet Transform</i>)
DWT	Transformada <i>Wavelet</i> Discreta (<i>Discret Wavelet Transform</i>)
EA	Extrassístole Atrial

EAA	Extrassístole Atrial com Aberrância de Condução
ECG	Eletrocardiograma
ELM	Máquina de Aprendizado Extremo (<i>Extreme Learn Machine</i>)
EV	Extrassístole Ventricular
FFT	Transformada Rápida de Fourier (<i>Fast Fourier Transform</i>)
FR	Fusão de Ritmo
GL	Graus de Liberdade
HOS	Alta Ordem Estatística (<i>High Order Statistic</i>)
Hz	Hertz, unidade de medida para frequência
IC	Inteligência Computacional
ICA	Análise de Componentes Independentes (<i>Independent Component Analysis</i>)
LA	Posição do eletrodo no braço esquerdo (<i>Left Arm</i>)
LDA	Análise de Discriminante Linear (<i>Linear Discriminant Analysis</i>)
LL	Posição do eletrodo na perna esquerda (<i>Left Leg</i>)
MIT	Instituto de Tecnologia de Massachusetts (<i>Massachusetts Institute of Technology</i>)
MLP	Rede Neural Perceptron Multicamadas (<i>Multilayer Perceptron</i>)
ms	Milissegundos
PCA	Análise de Componentes Principais (<i>Principal Component Analysis</i>)
PNN	Rede Neural Probabilística (<i>Probabilistic Neural Network</i>)
PSO	Método de Otimização de Enxame de Partículas (<i>Particle Swarm Optimization</i>)
PV	Parassístole Ventricular
RA	Posição do eletrodo no braço direito (<i>Right Arm</i>)
RBF	Rede Neural de Função de Base Radial (<i>Radial Basis Function</i>)
RNA	Rede Neural Artificial
SARBF	Rede Neural de Função de Base Radial com Estrutura Adaptativa (<i>Structure-Adaptive Radial Basis Function</i>)
SVM	Máquina de Vetor de Suporte (<i>Support Vector Machine</i>)
V1, V2, V3 V4, V5, V6,	Derivações unipolares precordiais de Frank N. Wilson do posicionamento de eletrodos durante um exame de eletrocardiograma
VF	Derivação unipolar frontal de Frank N. Wilson do posicionamento de eletrodos durante um exame de eletrocardiograma
VL	Derivação unipolar lateral esquerda de Frank N. Wilson do posicionamento de eletrodos durante um exame de eletrocardiograma

VR Derivação unipolar lateral direita de Frank N. Wilson do posicionamento de eletrodos durante um exame de eletrocardiograma

LISTA DE ACRÔNIMOS

AAMI Associação para o Aprimoramento da Instrumentação Médica
(*Association for the Advancement of Medical Instrumentation*)

FIR Filtro de Resposta ao Impulso Finito (*Finite Impulse Response*)

Holter Monitorização Eletrocardiográfica Ambulatorial

SUMÁRIO

1 INTRODUÇÃO	16
1.1 OBJETIVOS.....	17
1.1.1 Objetivo Principal.....	17
1.1.2 Objetivos Específicos.....	17
1.2 JUSTIFICATIVA.....	17
1.3 ORGANIZAÇÃO DO TRABALHO.....	18
2 FUNDAMENTAÇÃO TEÓRICA	20
2.1 O ELETROCARDIOGRAMA NO USO DE DIAGNÓSTICO DE DOENÇAS CARDÍACAS	20
2.1.1 O Coração Humano	20
2.1.2 O Eletrocardiograma	22
2.1.3 Monitorização Eletrocardiográfica Contínua	26
2.1.4 Arritmias Cardíacas	27
2.1.5 Trabalhos Correlatos	28
2.2 FILTROS MORFOLÓGICOS	38
2.2.1 Operadores Morfológicos.....	39
2.3 TRANSFORMADA <i>WAVELET</i>	42
2.3.1 Transformada <i>Wavelet</i> Contínua (CWT).....	42
2.3.2 Transformada <i>Wavelet</i> Discreta (DWT).....	45
2.4 ANÁLISE DE COMPONENTES PRINCIPAIS.....	49
2.5 ALGORITMOS DE INTELIGÊNCIA COMPUTACIONAL	51
2.5.1 Redes Neurais Artificiais.....	51
2.5.1.1 Rede neural de função de base radial	55
2.5.1.2 Máquina de aprendizado extremo	57
2.5.1.3 Rede neural artificial híbrida RBF-ELM.....	60
2.5.2 Método de Validação Cruzada.....	60
3 DESENVOLVIMENTO	62
3.1 BASE DE DADOS.....	62
3.2 FILTRAGEM DE SINAIS ELETROCARDIOGRÁFICOS	63
3.2.1 Filtro Morfológico	65
3.2.2 Transformada <i>Wavelet</i>	67
3.3 SEGMENTAÇÃO DOS BATIMENTOS	71
3.3.1 Algoritmo de Pan e Tompkins (1985).....	71
3.3.2 Implementação do Algoritmo de Segmentação	74
3.4 EXTRAÇÃO DE CARACTERÍSTICAS.....	76
3.5 RNA HÍBRIDA RBF-ELM	77
3.6 CLASSIFICAÇÃO DAS ARRITMIAS.....	78
3.7 ANÁLISE ESTATÍSTICA DOS RESULTADOS	81
4 RESULTADOS E DISCUSSÕES	84

4.1 AVALIAÇÃO DAS TÉCNICAS DE FILTRAGEM	84
4.2 AVALIAÇÃO DO COEFICIENTE DE REGULARIZAÇÃO	86
4.3 AVALIAÇÃO REDE TREINADA COM APENAS O ALGORITMO ELM	88
4.4 AVALIAÇÃO GERAL.....	89
4.4.1 Resultados utilizando 10 Componentes Principais	89
4.4.2 Resultados utilizando 12 Componentes Principais	91
4.4.3 Resultados utilizando 14 Componentes Principais	94
4.5 AVALIAÇÃO DA QUANTIDADE DE COMPONENTES PRINCIPAIS	96
4.6 ANÁLISE DETALHADA DOS MELHORES RESULTADOS	97
4.7 AVALIAÇÃO COM RELAÇÃO A OUTROS TRABALHOS	101
5 CONCLUSÃO.....	103
5.1 TRABALHOS FUTUROS	104
REFERÊNCIAS.....	106
APÊNDICE A – Resultados para a Rede Híbrida RBF-ELM com 2 Camadas Escondidas	121

1 INTRODUÇÃO

Em 2013 no Brasil, 4,2% da população com mais de 18 anos foi diagnosticado com doença cardíaca, sendo que 13,5% destes tiveram suas nas atividades habituais limitadas pela doença (IBGE, 2014). Em 2012, o risco de morte por doenças cardiovasculares chegou a 372 por 100 mil habitantes no Brasil (MANSUR; FAVARATO, 2016). Nos Estados Unidos, o último levantamento realizado em 2013 mostra que o risco de morte é de 222,9 por 100 mil habitantes (MOZAFFARIAN et al., 2016). Estima-se que, atualmente, 31,5% das mortes ao redor do mundo são devido a doenças cardiovasculares (BENJAMIN et al., 2017).

O exame mais utilizado para diagnósticos clínicos de arritmias cardíacas (ocasionadas na maioria dos casos pelo mal funcionamento do coração) é o Eletrocardiograma (ECG); este se constitui no registro da atividade elétrica produzida pelo coração humano durante o seu funcionamento (MARTINS et al., 2016).

Existem dois tipos principais de arritmias cardíacas que podem ser classificadas com um eletrocardiograma (LUZ et al., 2016): as arritmias morfológicas (afetam a forma do sinal eletrocardiográfico) e as arritmias rítmicas (afetam um conjunto de batimentos, produzindo mais ou menos batimentos em uma determinada faixa de tempo).

O processo para identificar e classificar arritmias morfológicas pode ser muito desgastante, pois muitas vezes é necessário analisar a morfologia de cada um dos batimentos encontrados numa gravação eletrocardiográfica com horas de duração, existindo a possibilidade de falha humana durante a análise devido a fadiga (HOLTER, 1961; LUZ et al., 2016).

Desta forma, a interpretação automática de um exame de eletrocardiograma é uma alternativa desejável (KUNDU; NASIPURI; KUMAR BASU, 2000; LUZ et al., 2016). Além de uma interpretação prévia dos batimentos, a medição dos intervalos e das amplitudes das ondas presentes no ECG pode auxiliar médicos no diagnóstico de exames de longa duração (KLIGFIELD et al., 2007).

1.1 OBJETIVOS

1.1.1 Objetivo Principal

O objetivo deste trabalho é propor e avaliar um sistema de apoio ao diagnóstico de arritmias cardíacas ¹(com filtragem, extração de características, análise e classificação dos batimentos), através da utilização de sinais eletrocardiográficos de pessoas adultas, para o auxílio ao diagnóstico médico.

1.1.2 Objetivos Específicos

Para alcançar o objetivo principal, este trabalho apresenta como objetivos específicos a implementação e avaliação:

- De técnicas de filtragem utilizadas em sinais eletrocardiográficos;
- De um algoritmo para detecção de batimentos cardíacos;
- Do uso de uma técnica de análise, extração das características e redução da dimensionalidade do sinal;
- De técnicas de inteligência computacional (IC) para a classificação de padrões.

1.2 JUSTIFICATIVA

As principais causas de óbitos entre homens e mulheres acima dos 30 anos devem-se às doenças cardiovasculares (MARTINS et al., 2016). Entretanto, foi constatado que arritmias mais graves são, em geral, precedidas por arritmias menos severas e de mais fácil identificação (LOWN; KLEIN; HERSHBERG, 1969) e que quanto mais cedo é feita a detecção da arritmia, maior é a chance de recuperação do paciente (DAY, 1963, 1965). Deste modo, conclui-se que a análise constante de pacientes em risco pode aumentar a sobrevivência dos mesmos.

¹ Devido ao seu uso amplo, o registro correto e interpretações precisas do ECG são críticos, sendo evidente que todo e qualquer laudo deve ser confirmado e revisado por especialistas da área (KLIGFIELD et al., 2007). Por isso, o sistema proposto é apenas de apoio ao diagnóstico.

Além disso, a monitorização contínua permite não só uma maior chance de detecção de doenças episódicas e silenciosas, como também permite um controle terapêutico de pacientes que sofreram de ataques isquêmicos verificando a eficácia no tratamento dos mesmos (WIMMER; SCIRICA; STONE, 2013). Sistemas para o monitoramento constante e remoto de pacientes (sistemas de telemedicina) são encontrados na literatura (WOODWARD; ISTEPANIAN; RICHARDS, 2001), tendo aplicações com idosos (COYLE; BOYDELL; BROWN, 1995), pacientes de risco (PATEL; BABBS, 1992) e de soldados do exército americano (CROWTHER; POROPATICH, 1995).

No Reino Unido, sistemas de telemedicina são usados há anos e abrangem diversas áreas como tele radiologia, tele cardiologia e tele odontologia. Há um prospecto de alto crescimento e investimento na área (ISTEPANIAN, 1999). Atualmente, os sistemas tradicionais de telemedicina do tipo *desktop* estão evoluindo para sistemas do tipo *mHealth*², devido ao crescimento da disponibilidade, miniaturização, desempenho e altas taxas de transferência de dados dos *smartphones* e ao crescimento expansivo do uso de tecnologias de comunicação móvel³ (ISTEPANIAN; JOVANOVA; ZHANG, 2004).

Este crescente aumento do uso de sistemas de monitorização contínua implicará na geração de uma grande quantidade de dados que necessitarão de laudo. Desta maneira, o desenvolvimento e uso de sistemas de análise automática poderão auxiliar um médico nesta árdua tarefa, selecionando os principais pontos do exame que apresentam arritmias. Tais sistemas seriam capazes de detectar anomalias e enviar um alerta para uma rápida contra resposta, assim, elevando as chances de sobrevivência do paciente.

1.3 ORGANIZAÇÃO DO TRABALHO

Após breve introdução sobre a problemática do trabalho, os objetivos e a justificativa, o restante do trabalho está organizado do seguinte modo:

² O termo *mHealth* é definido pela *Global Observatory for eHealth* como o uso de dispositivos móveis (como telefones celulares, dispositivos de monitorização de pacientes, assistentes digitais pessoais e outros dispositivos sem fio) para uso na prática médica e na saúde pública (WHO, 2016).

³ O Brasil apresenta um crescimento de mais de 20 milhões desde o início de 2016, no uso de *smartphones* com tecnologia 4G (GSMA, 2017).

- **Capítulo 2:** Uma revisão bibliográfica com os conceitos necessários para a compreensão do trabalho desenvolvido;
- **Capítulo 3:** O desenvolvimento do presente trabalho, com a elucidação sobre como as técnicas explicadas no Capítulo 2 foram utilizadas para a resolução do problema;
- **Capítulo 4:** Os resultados e as discussões que foram obtidos por meio da avaliação das técnicas estudadas;
- **Capítulo 5:** Uma conclusão concisa sobre o que foi observado nos resultados; além de propostas de pesquisas a serem realizadas futuramente em cima do que foi observado neste trabalho;

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção, é abordado como o eletrocardiograma se tornou uma das principais ferramentas no auxílio ao diagnóstico de doenças cardíacas, bem como, algumas das técnicas utilizadas na filtragem, segmentação dos batimentos, extração de característica e análise automática dos sinais eletrocardiográficos.

2.1 O ELETROCARDIOGRAMA NO USO DE DIAGNÓSTICO DE DOENÇAS CARDÍACAS

Em 1903, Willem Einthoven iniciou os estudos sobre a eletrocardiografia, usando um galvanômetro de corda ligado a uma caneta tinteiro para registrar os impulsos elétricos oriundos do coração, gravando-os diretamente no papel. Em suas pesquisas, Einthoven também introduziu as marcações clássicas dos sinais de ECG, nomeando suas principais ondas com as letras: P, Q, R, S e T (FYE, 1994; GIFFONI; TORRES, 2010; NAJARIAN; SPLINTER, 2012).


Antes da eletrocardiografia, o estudo do ritmo cardíaco era realizado com auxílio de esfigmógrafos, instrumentos que medem os impulsos produzidos por vasos sanguíneos. A partir do estudo de Lewis (1909), o eletrocardiograma passou a ser usado para reconhecer as situações de normalidade e anormalidades do funcionamento cardíaco, sendo as anormalidades geradas por sobrecargas, alterações de condução do potencial de ação, alterações de bombeamento do coração, alterações do ritmo, entre outras causas (GIFFONI; TORRES, 2010; MARTINS et al., 2016).

2.1.1 O Coração Humano

O coração se encontra entre os dois pulmões na metade superior do tórax, com aproximadamente dois terços do seu tamanho situado à esquerda da linha mediana do corpo, possuindo o formato de cone com a ponta arredondada e o tamanho aproximado de uma mão fechada (CARR; BROWN, 2001; GOLDBERGER; GOLDBERGER; SHVILKIN, 2013; TORTORA, 2003).

O coração humano (Figura 1) pode ser dividido em esquerdo e direito. Cada lado possui duas câmaras, uma superior (denominada átrio) e uma inferior (denominada ventrículo). Os átrios são separados dos ventrículos por valvas atrioventriculares. Sendo a que separa o átrio direito do ventrículo direito chamada de tricúspide, enquanto a que separa o átrio esquerdo do ventrículo esquerdo é chamada de bicúspide (ou mitral) (HALL; GUYTON, 2011).

Figura 1 – Estrutura do coração humano e fluxo do sangue



Fonte: Hall e Guyton (2011)


Cada ventrículo possui uma segunda valva chamada semilunar que o separa da artéria. O papel de cada valva é permitir o fluxo de sangue em somente em uma direção (CARR; BROWN, 2001; HALL; GUYTON, 2011; MARTINS et al., 2016).

Como o centro do sistema circulatório, o coração tem como funções principais: impulsionar o sangue para sofrer oxigenação nos pulmões (realizado pelo lado direito do coração), coletar o sangue oxigenado dos pulmões e então impulsionar este pelos vasos sanguíneos para todos os órgãos e sistemas do corpo humano (lado esquerdo do coração) (NAJARIAN; SPLINTER, 2012; TORTORA, 2003).

Para impulsionar o sangue por todo o corpo, as células especializadas do sistema de condução cardíaco (Figura 2) coordenam a despolarização (contração do músculo cardíaco, fase conhecida como sístole) e repolarização (relaxamento do

músculo cardíaco, resultando no enchimento de sangue do coração, fase conhecida como diástole) de tempos em tempos. Esta sucessão contínua de contrações cardíacas é chamada de ritmo cardíaco. As descargas rítmicas ou potenciais de ação (PA) são gerados normalmente no nodo sinoatrial e propagam pelas vias internodais, contraindo os átrios. Após, o PA percorre o feixe de His (ou feixe atrioventricular, A-V), os ramos direito e esquerdo do feixe e as fibras de Purkinje produzindo a contração ventricular. Uma nova contração pode ser iniciada após a repolarização ventricular (HALL; GUYTON, 2011; MARTINS et al., 2016; NAJARIAN; SPLINTER, 2012).

Figura 2 – Estrutura do sistema excitatório do coração humano




Fonte: Hall e Guyton (2011)

2.1.2O Eletrocardiograma

O processo repetitivo de despolarização e repolarização do coração, durante cada ciclo cardíaco, gera diferenças locais no potencial de ação. Isto gera corrente que se propaga até a superfície do corpo, podendo ser medida na superfície usando eletrocardiógrafos ou monitores cardíacos. O registro desses sinais, chamado eletrocardiograma, é um dos mais utilizados em diagnósticos de doenças cardiovasculares, sendo este um exame de baixo custo, grande disponibilidade, rápida realização e interpretação (HALL; GUYTON, 2011; MARTINS et al., 2016; NAJARIAN; SPLINTER, 2012).

No sinal produzido num exame de eletrocardiograma (Figura 3), a despolarização atrial, iniciada no nodo sinoatrial (Figura 2), resulta na formação da onda P. A despolarização segue pelas vias internodais para o nodo atrioventricular (A-V), porém, não é captada pelos eletrodos devido ao tamanho do nodo e a sua distância ao eletrodo.

Figura 3 – Sinal de ECG e suas principais ondas



Fonte: Adaptado de Hall e Guyton (2011)

Na sequência, as ondas Q, R e S são geradas pela despolarização do septo ventricular (parede que separa os ventrículos direito e esquerdo), das fibras de Purkinje e da parede ventricular (formando o complexo QRS). Por fim, a repolarização ventricular⁴ produz a onda T (HALL; GUYTON, 2011; MARTINS et al., 2016).

O padrão mais antigo e usual de posicionamento dos eletrodos para um ECG foi proposto por Einthoven (Figura 4); consiste na colocação de um eletrodo em cada braço e um na perna esquerda, com um eletrodo na perna direita servindo de referência (GOLDMAN; AUSIELLO, 2009; NAJARIAN; SPLINTER, 2012). Com cada par de eletrodos posicionados em lados diferentes do coração nas extremidades do corpo⁵, têm-se as três derivações bipolares (HALL; GUYTON, 2011):

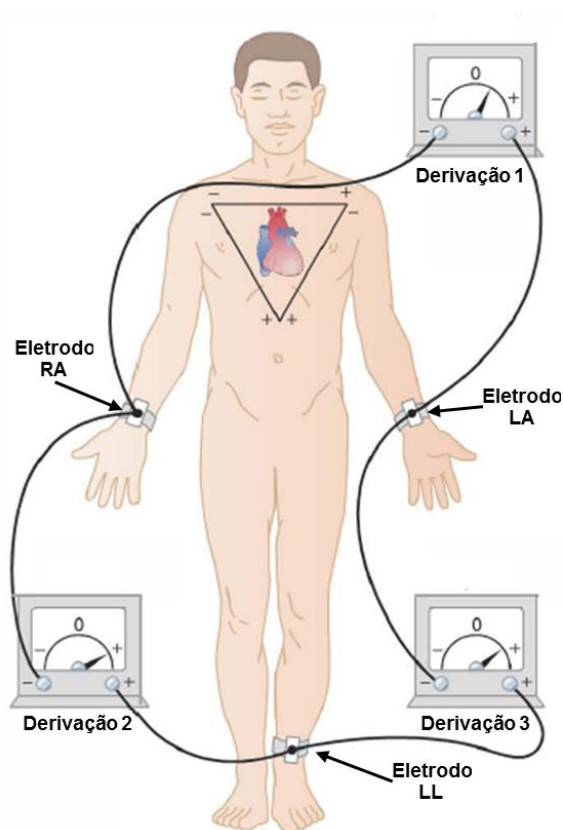
- **Derivação 1 (D1):** o terminal negativo do eletrocardiógrafo é conectado ao braço direito (eletrodo RA, do Inglês: *Right Arm*); o terminal positivo, ao braço esquerdo (eletrodo LA, do Inglês: *Left Arm*);

⁴ A repolarização atrial não é registrada sobre condições normais, devido ao seu acontecimento ocorrer durante a despolarização ventricular e ser extremamente fraco.

⁵ Em testes ergométricos, nos registros ambulatoriais ou até mesmo em pacientes amputados ou com bandagens nas extremidades, os eletrodos são aplicados próximo ao torso.

- **Derivação 2 (D2):** o terminal negativo é conectado ao braço direito (eletrodo RA); o terminal positivo, à perna esquerda (eletrodo LL, do Inglês: *Left Leg*);
- **Derivação 3 (D3):** o terminal negativo é conectado ao braço esquerdo (eletrodo LA); o terminal positivo, à perna esquerda (eletrodo LL).


Figura 4 – Posicionamento clássico dos eletrodos num exame de ECG



Fonte: Adaptado de Hall e Guyton (2011)

Em 1934, Frank N. Wilson introduziu as derivações unipolares, provando de forma matemática a possibilidade do registro da atividade elétrica do coração em qualquer parte do corpo através de um terminal central (T, Figura 5). Este estabelece um ponto de referência para o posicionamento de eletrodos unipolares, que antes utilizavam um eletrodo numa extremidade do corpo como referência (WILSON et al., 1934a, 1934b).

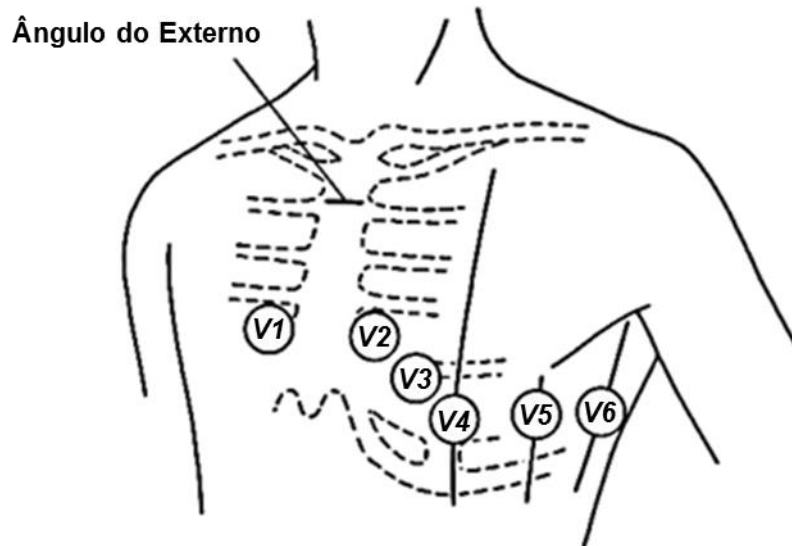
Figura 5 – Ponto do terminal central de referência de Wilson



Fonte: Adaptado de Wilson et al. (1934a)

Nas derivações unipolares precordiais, seis eletrodos são colocados no peito (V1, V2, V3, V4, V5 e V6, Figura 6) e as medições são feitas com relação ao terminal central de referência de Wilson.

Figura 6 – Derivações unipolares precordiais e seus respectivos eletrodos



Fonte: Adaptado de Goldberger, Goldberger e Shvilkin (2013)

Além dos eletrodos nas posições precordiais, os eletrodos nas posições de Einthoven também podem ser utilizados de forma unipolar, sendo então suas medições chamadas VR, VL e VF (braço direito, braço esquerdo e perna esquerda, respectivamente).

Através das derivações unipolares dos eletrodos na posição tradicional de Einthoven, em Goldberger (1942) foram introduzidas as derivações aumentadas aVR , aVL e aVF conforme as equações (2.1), (2.2) e (2.3).

$$aVR = VR - \frac{VL + VF}{2} \quad (2.1)$$

$$aVL = VL - \frac{VR + VF}{2} \quad (2.2)$$

$$aVF = VF - \frac{VR + VL}{2} \quad (2.3)$$

No total, combinando as três derivações bipolares de Einthoven com as seis derivações unipolares precordiais de Wilson, juntamente com as três derivações aumentadas de Goldberger, tem-se um total de 12 registros que são tipicamente obtidos durante um exame cardíaco de rotina (CARR; BROWN, 2001; NAJARIAN; SPLINTER, 2012).

2.1.3 Monitorização Eletrocardiográfica Contínua

A monitorização eletrocardiográfica ambulatorial (*Holter*), introduzida por Holter (1961), é o registro do ECG por um período determinado (geralmente de 24 a 48 horas), possibilitando a detecção de anormalidades eletrocardiográficas transitórias no contexto de vida normal do paciente (FYE, 1994; GIFFONI; TORRES, 2010; MARTIS; ACHARYA; MIN, 2013).

Ao longo dos anos, o *Holter* tornou-se cada vez mais moderno e portátil, possuindo atualmente a capacidade de digitalização do sinal captado em alta resolução permitindo a detecção de sinais de baixa amplitude para a detecção de doenças específicas que não poderiam ser detectadas com eletrocardiógrafos convencionais (GIFFONI; TORRES, 2010; MARTINS et al., 2016).

Além disso, os equipamentos *Holter* captam uma maior gama de frequência dos sinais (0,05 Hz a 300 Hz) contra a de um ECG tradicional (1 Hz a 80 Hz).

O equipamento básico de *Holter* é também composto por um sistema de análise presente, em geral, em um computador pessoal. Estes sistemas permitem, não somente a reprodução completa do registro, mas também fornecem ferramentas para o tratamento dos dados pré-analisados, muitas vezes possuindo também algum

algoritmo para reconhecimento prévio de arritmias, análise da variabilidade de frequência cardíaca, entre outros (MARTINS et al., 2016).

Deste modo, a análise dos dados obtidos num *Holter* permite contemplar um panorama completo do eletrocardiograma durante o período realizado, correlacionando os eventos eletrocardiográficos ao longo do dia com as atividades do paciente, sua frequência cardíaca e os sintomas (MARTINS et al., 2016).

2.1.4 Arritmias Cardíacas

Um funcionamento anormal do sistema cardiovascular é associado com certas condições patológicas que podem ser genéticas ou devido ao mau funcionamento do coração por causa de infecções, falta de oxigênio e obstrução dos vasos sanguíneos (NAJARIAN; SPLINTER, 2012).

Após sua criação, o eletrocardiograma tornou-se o meio mais comum para diagnóstico clínico, sendo considerado o melhor meio para o diagnóstico de arritmias cardíacas e distúrbios de condução intraventriculares (KLIGFIELD et al., 2007).

Dentre tantos tipos de arritmias cardíacas existentes, este trabalho focará apenas no entendimento de dez, que estão presentes na base de dados escolhida. Estes tem como característica a alteração na morfologia do sinal de ECG e são descritos a seguir (PASTORE et al., 2016):

1. **Bloqueio de Ramo Esquerdo (BRE):** Provocado na maioria dos casos por doenças no ventrículo esquerdo, o bloqueio de ramo esquerdo provoca deformações na morfologia e na duração do complexo QRS, sendo essas semelhantes em quase todas as derivações padrões (ROSENBAUM, 1968).

2. **Bloqueio de Ramo Direito (BRD):** Assim como o bloqueio de ramo esquerdo, o bloqueio de ramo direito também deforma o complexo QRS, porém este pode apresentar diversos padrões e ser gerado por qualquer tipo de doença cardíaca tanto do ventrículo esquerdo quanto no direito (ROSENBAUM, 1968).

3. **Extrassístole Atrial (EA):** É um batimento atrial precoce, originário de uma região diferente do nodo sinusal, provocando deformações na onda P.

4. **Extrassístole Atrial com Aberrância de Condução (EAA):** Ocasionado por um estímulo supraventricular precoce, este tipo de extrassístole encontra dificuldade na propagação do estímulo para a contração ventricular,

apresentando uma onda P seguida de um complexo QRS alargado com morfologia semelhante a de bloqueio de ramo.

5. **Extrassístole Ventricular (EV):** Apresenta-se como batimento originado precocemente no ventrículo, também afeta a morfologia e a duração do complexo QRS (BISTENI et al., 1960).

6. **Batimento de Fusão (BF):** Corresponde ao batimento prematuro originado no ventrículo, que se funde com um batimento normal do coração. Apresenta uma onda P seguida de um complexo QRS alargado.

7. **Batimento de Escape Atrial (BEA):** Batimento oriundo da ausência da atividade do nodo sinoatrial, sendo somente gerado para suprir a ausência. Apresenta uma onda P com morfologia diferenciada da normal.

8. **Batimento de Escape Ventricular (BEV):** Batimento de origem ventricular tardio. Surge em consequência da inibição temporária de outros ritmos.

9. **Parassístole Ventricular (PV):** Corresponde ao batimento oriundo de um marca-passo artificial que funciona em paralelo ao ventrículo.

10. **Fusão de Ritmo (FR):** Batimento originário da fusão entre o batimento ocasionado por um marca-passo artificial e a despolarização natural do músculo.

2.1.5 Trabalhos Correlatos

O uso de sinais de ECG na classificação de arritmias de forma automática é muito estudado, com relatos de estudos realizados desde a década de 60 e 70 (KUNDU; NASIPURI; KUMAR BASU, 2000; MOODY; MARK, 2001).

Dentre os vários trabalhos realizados ao longo dos anos, a maioria dos sistemas para a classificação automática de arritmias realiza quatro etapas de operação: (1) pré-processamento do sinal de ECG, onde a maioria dos trabalhos faz a remoção dos ruídos presentes no sinal; (2) segmentação do sinal em batimentos cardíacos; (3) extração das características de cada batimentos; e (4) algoritmo de reconhecimento de padrões (LUZ et al., 2016).

Entre todas as propostas para a redução digital de ruídos em sinais biológicos a mais clássica é a utilização de filtros de resposta ao impulso finito (FIR, do inglês: *Finite Impulse Response*) (LYNN, 1971). Apesar de funcionarem bem para atenuação de frequências conhecidas, não conseguem remover boa parte dos ruídos de

frequências desconhecidas (como ruídos musculares). Se usados de forma incorreta, distorcem a morfologia do sinal (LUZ et al., 2016).

Diferentemente das técnicas convencionas os filtros adaptativos (como filtros morfológicos) suprimem ruídos e corrigem as flutuações de linha de base com mínima distorção das ondas características do sinal, pois não apresentam frequência de corte fixa (FERRARA; WIDRAW, 1982; SUN; CHAN; KRISHNAN, 2002; YELDERMAN et al., 1983).

Além da filtragem adaptativa, outra técnica muito utilizada nas últimas décadas é a filtragem realizada pelo uso da Transformada *Wavelet*. Sendo esta considerada muito simples de um ponto de vista computacional e, também, com uma maior capacidade de preservação de características quando comparado a técnicas convencionais (ADDISON, 2005; LUZ et al., 2016; QIN et al., 2017; SAYADI; SHAMSOLLAHI, 2007; SINGH; TIWARI, 2006; ZADEH; KHAZAEI; RANAEE, 2010).

Para a etapa de segmentação dos batimentos presentes num exame de eletrocardiograma (segunda etapa), diversos algoritmos foram criados e avaliados ao longo dos anos. Para uma comparação mais justa, selecionou-se os trabalhos que avaliaram seus algoritmos com a mesma base de dados (MIT-BIH), sendo apresentados na Tabela 1.

Entre os algoritmos de classificação automática de arritmias estão as redes neurais artificiais (RNA) com arquiteturas *feedforward* com uma única camada escondida, como a rede de função de base radial (RBF, do Inglês: *Radial Base Function*), a rede Perceptron de Multicamadas (MLP, do inglês: *Multi Layer Perceptron*) e a RNA máquina de aprendizado extremo (ELM, do inglês: *Extreme Learning Machine*) que tem por característica uma precisão elevada para baixo tempo de treinamento e custo computacional extremamente reduzido (HUANG; ZHU; SIEW, 2006).

Todos os trabalhos apresentados e descritos nesta seção utilizam a base de dados de arritmias MIT-BIH. Alguns poucos trabalhos utilizam outras base de dados, ou sinais coletados para a verificação do trabalho, além da base de dados MIT-BIH.

Tabela 1 – Desempenho de detectores de complexo QRS

Trabalho	Total de Batimentos	Verdadeiro Positivo	Verdadeiro Positivo (%)	Falso Positivo	Falso Negativo
Nygårds e Sörnmo (1983), porém, teste feito por Lagerholm et al. (2000)	109963	109627	99,69	N/A	336
Pan e Tompkins (1985)	116137	115860	99,76	507	277
Hamilton e Tompkins (1986)	109267	108927	99,69	248	340
Li, Zheng e Tai (1995)	116137	116025	99,90	65	112
Poli, Cagnoni e Valli (1995)	109963	109522	99,10	545	441
Lee et al. (1996)	109481	109146	95,69	137	335
Bahoura, Hassani e Hubin (1997)	116137	115963	99,85	133	174
Afonso et al. (1999)	90909	90535	99,59	406	374
Hamilton (2002)	N/A	N/A	93,91	N/A	N/A
Moraes et al. (2002)	N/A	N/A	99,22	N/A	N/A
Martinez et al. (2004)	109428	109208	99,80	153	220
Chen, Chen e Chan (2006)	102654	102195	99,55	529	459
Darrington (2006)	109663	108626	99,05	860	1037
Palodeto (2006)	13162	13154	99,94	12	8
Ghaffari, Golbayani e Ghasemi (2008)	110159	109837	99,71	N/A	322
Jafari, Moghadam, Fard, Moradi e Tajvidi (2008)	N/A	N/A	99,70	N/A	N/A
Zheng, Wu (2008)	91285	90989	99,68	375	296
Adnane, Jiang, Choi (2009)	109494	109241	99,77	393	253
Elgendi, Jonkman e De Boer (2009)	44677	43343	97,01	N/A	1334
Zidelmal et al. (2012)	109494	109101	99,71	193	393
Elgendi (2013)	109985	~109743	99,78	N/A	~242

Fonte: Autoria própria

Em seu trabalho, Palodeto (2006) realizou a classificação de arritmias de adultos e neonatos. Utilizou os sinais da base de dados de arritmias MIT-BIH e registros de neonatos coletados no Hospital Infantil Joana de Gusmão para classificar batimentos normais, com extrassístole ventricular e com bloqueio de ramos. Utiliza filtros adaptativos no pré-processamento, filtro de média aparada por alfa (*alpha-trimmed mean filter*) para a remoção dos ruídos impulsivos e filtro morfológico para a remoção do ruído de linha de base, apresentando resultados melhores se comparados aos filtros digitais *Butterworth* (quarta ordem do tipo passa-alta com frequência de

corte em 0,03Hz) e *notch* (60Hz). Utilizou uma técnica de detecção de picos própria, com o uso de Transformada *Wavelet* Discreta (DWT, do Inglês: *Discret Wavelet Transform*, também chamada de decomposição *wavelet*), apresentou uma taxa de acerto 99,90%. Para a classificação das arritmias utilizou uma heurística para as arritmias rítmicas que leva como base os intervalos entre as ondas, a frequência cardíaca e a idade do paciente. Já para as arritmias morfológicas, utilizou uma rede neural artificial Perceptron Multicamadas (MLP, do Inglês: *Multilayer Perceptron*) com duas camadas escondidas, uma com 25 e outra com 9 neurônios, considerou como entrada 225 amostras ao entorno de cada pico R, obteve uma sensibilidade de 92,55% e uma especificidade de 99,71%.

Kim et al. (2007) utilizaram uma rede neural máquina de aprendizado extremo para a classificação de 7 tipos de batimentos cardíacos (normal, BRE, BRD, EA, EV, PV e BEV). Para isto, cada batimento é segmentado com 180 amostras ao redor de cada pico R. Utilizando-se da amplitude do pico R, do intervalo entre picos R e de componentes principais extraídos do segmento. O melhor resultado que obtiveram foi com 280 neurônios na camada oculta e 22 componentes principais, alcançando uma taxa de acerto médio de 97,47%.

Já Kim et al. (2009) classificaram 6 tipos de batimentos (normal, BRE, BRD, EA, EV e PV); utilizaram o filtro morfológico proposto por Sun, Chan e Krishnan (2002), segmentaram os batimentos em 90 amostras ao redor de cada pico R. Como algoritmo de identificação de padrão utilizaram uma rede neural de função de base radial e uma RNA ELM. Como variáveis de entrada, utilizaram a amplitude do pico R, componentes principais extraídos das 90 amostras de cada batimento; utilizaram também o intervalo entre picos R atual, a proporção entre o intervalo entre picos R atual e o próximo e entre o intervalo entre picos R atual e os 10 anteriores. O melhor resultado que obtiveram para a rede neural artificial ELM foi com 10 componentes principais e 800 neurônios na camada escondida atingindo uma taxa de acerto de 98,72%. Já para a rede RBF, o melhor resultado obtido foi com 10 componentes principais e 1400 neurônios, alcançando uma taxa de acerto de 89,36%.

Mateo et al. (2016) classificaram 2 classes de batimentos, agrupando os batimentos em não ectópicos e ectópicos. Além da base de dados de arritmias MIT-BIH, também utilizaram as bases de fibrilação atrial MIT-BIH, ritmo sinusal normal MIT-BIH, base de dados de 12 derivações de arritmias do Instituto de Cardiologia de

São Petesburgo, base de dados europeia ST-T, entre outras. Para a classificação, a rede neural RBF apresentou uma taxa de acerto de 99,79%

O trabalho desenvolvido por Qin et al. (2017) classificou 6 tipos de batimentos (normal, BRE, BRD, EA, EV e PV). A filtragem do sinal empregada manteve as componentes entre a faixa de frequência 0,7 e 180Hz, com cada batimento sendo segmentado em 0,7 segundos (252 amostras) ao entorno de cada pico R. A extração das características do sinal realizada deu-se pela decomposição *wavelet* usando a *wavelet* mãe bior6.8, mantendo todos os detalhes das subdivisões. A análise de componentes principais também foi realizada, mantendo apenas os 12 primeiro componentes. O algoritmo usado na classificação foi a Máquina de Vetor de Suporte (SVM, do inglês: *Support Vector Machine*) com função de base radial e apresentou uma taxa de acerto de 99,7%.

Zidelmal et al. (2013) classificaram três classes de batimentos (normal, BRE e BRD). Removeram as componentes abaixo de 2,8Hz através da DWT de 6 níveis. Detectaram os complexos QRS através do método proposto por Zidelmal et al. (2012), utilizando o intervalo entre picos R anterior e posterior normalizado, a média de 10 intervalos entre picos ao redor do batimento selecionado (também normalizado), a duração entre as ondas Q e S. Além das informações temporais de cada batimento, utilizaram 4 coeficientes do preditivo linear usado para aproximar a função a cada batimento, 6 componentes da Transformada Rápida de Fourier (FFT, do Inglês: *Fast Fourier Transform*) (após a passagem de uma janela Blackman de 180ms; 7,5Hz; 10Hz; 12,5Hz; 15Hz; 17,5Hz e 20Hz), mais a análise de força dos detalhes 4 e 5 de uma decomposição *wavelet*. Para a classificação das arritmias, utilizaram uma SVM modificada que alcançou uma taxa de acerto de 98,2%.

O sistema proposto por Yu e Chou (2008) classificou 8 tipos de batimentos (normal, BRE, BRD, EA, EV, PV, BEV e *flutter* ventricular), segmentaram cada batimento em 200 amostras ao redor de cada complexo QRS. Antes de aplicar a análise de componentes independentes, uma normalizaram os dados com a remoção do valor médio das amostras. Além dos componentes independentes, utilizaram o intervalo entre picos R na entrada dos algoritmos de classificação. Com o algoritmo rede neural probabilística (PNN, do Inglês: *Probabilistic Neural Network*) e com 33 componentes independentes foi atingindo uma taxa de acerto de 98,71%. Já com 23 componentes independentes e com uma MLP, foi alcançado uma taxa de acerto de 98,37%.

Dokur e Ölmez (2001) classificaram 10 tipos de batimentos (normal, BRE, BRD, EV, PV, EA, EAA, BF, BEA, BEV). Normalizaram todos os sinais pela maior amplitude e removendo a média do sinal. Segmentaram todos os batimentos com 256 amostras ao entorno de cada pico R. As características extraídas de cada batimento consistem nos detalhes 2, 3 e 4 e da aproximação 4 de uma DWT com a *wavelet* mãe Daubechies D2, totalizando o total de 147 elementos. Para reduzir a quantidade de elementos, realizaram uma análise de divergência e concluíram que com apenas os 8 componentes com maior divergência alcançavam uma taxa de divergência de 7,21. Para o algoritmo de classificação, utilizaram uma rede neural com uma única camada escondida. A camada escondida representa uma hiperesfera, com seus pesos e a quantidade de neurônios necessária sendo ajustados através de um algoritmo genético. A taxa de acerto que alcançaram foi de 95,7% com 20 neurônios na camada escondida.

Em um trabalho prévio Cardozo et al. (2017) classificaram 11 tipos de batimentos cardíacos (normal, BRE, BRD, EV, EA, EAA, BEV, BEA, BF, PV, FR). Filtraram os sinais eletrocardiográficos com a utilização do filtro morfológico proposto por Sun, Chan e Krishnan (2002). Segmentaram os batimentos cardíacos e efetuaram a separação considerando 99 amostras a esquerda e 100 amostras a direita do pico R. Para a extração de características efetuaram a análise de componentes principais, selecionando os 10 principais componentes para a entrada no algoritmo de classificação. Utilizaram a rede neural artificial ELM para a classificação, apresentando uma taxa de acerto de $96,86 \pm 0,05\%$ para a ELM sem coeficiente de regularização e de $96,09 \pm 0,06\%$ para a ELM com coeficiente de regularização, ambas com 1000 neurônios na camada escondida.

Vários trabalhos classificam 5 tipos de arritmias cardíacas propostos pela Associação para o Aprimoramento da Instrumentação Médica (AAMI, do Inglês: Association for the Advancement of Medical Instrumentation) (1995):

1. **Batimento não Ectópico (BNE):** Composto por batimentos normais, bloqueio de ramo esquerdo, bloqueio de ramo direito e batimento de escape atrial;
2. **Batimento Supraventricular Ectópico (BSE):** Composto por extrassístole atrial, extrassístole atrial com aberrância de condução e extrassístole juncional;
3. **Batimento Ventricular Ectópico (BVE):** Composto por extrassístole ventricular e batimento de escape ventricular;

4. **Batimento de Fusão (BF):** Composto por batimentos de fusão;
5. **Batimento Desconhecido (BD):** Composto por parassístole ventricular, fusão de ritmos e batimentos não classificados.

Entre os trabalhos que utilizam a classificação proposta por AAMI (1995) estão Chen et al. (2017); Elhaj et al. (2016); Ghorbani Afkhami e Azarnia; Tinati (2016); Herry et al. (2017); Martis et al. (2013); Martis, Acharya e Min (2013); Nikan, Gwadry-Sridhar e Bauer (2017); Shadmand e Mashoufi (2016); Thomas, Das e Ari (2015).

Chen et al. (2017) utilizaram a Transformada *Wavelet* como proposta por Poornachandra (2008) para a remoção dos ruídos dos sinais eletrocardiográficos, segmentaram cada batimento com 100 amostras a esquerda do pico R e 199 a direita, de modo a compreender uma janela de 0,83 segundos. Para a redução da dimensionalidade dos batimentos, usaram uma matriz de projeção aleatória em que cada coluna foi normalizada e cada linha foi transformada por uma transformada de cosseno discreta (DCT, do Inglês: *Discrete Cosine Transform*) de modo a se obter 30 amostras. Ademais, aplicaram dados temporais como o intervalo RR anterior, posterior e a média dos últimos 10 intervalos. Destarte, empregaram 33 amostras de entrada no classificador de padrões. Aplicando uma SVM com função de base radial obtiveram 98,46% de taxa de acerto. Chen et al. (2017) ainda testou com 15 classes obtendo 93,10% de acerto.

Elhaj et al. (2016) utilizou a DWT com a *wavelet* mãe Daubechies D6, com nove níveis de decomposição para se obter o sinal entre as frequências 0,351 e 45Hz. Detectou cada batimento com o algoritmo de Pan e Tompkins (1985) e o segmentou com 99 amostras a esquerda e 100 a direita dos picos R. Para a redução da dimensionalidade do sinal, usaram uma decomposição *wavelet* de modo a se obter as componentes do sinal entre 0 e 11,25Hz e entre 11,25 e 22,5Hz. Após obter as duas componentes, aplicaram uma análise de componentes principais (PCA, do Inglês: *Principal Component Analysis*) selecionando os 6 principais componentes para ambas as faixas de frequência. De mais a mais, realizaram uma análise multivariada baseado em alta ordem estatística (HOS, do Inglês: *High Order Statistic*) de análise de componentes independentes (ICA, do Inglês: *Independent Component Analysis*) de modo a se escolher os 16 principais componentes independentes. Portanto, utilizaram 28 dados para a entrada do classificador. Como classificador, aplicaram uma SVM com função de base radial, a qual apresentou uma taxa de acerto de 98,91%. O

resultado foi comparado com uma rede MLP com 40 neurônios na camada escondida, indicando uma taxa de acerto próxima de 98,90%.

Ghorbani Afkhami, Azarnia e Tinati (2016) empregaram o filtro mediana (proposto por Awodeyi, Alty e Ghavami (2013)), para a remoção do ruído de linha de base. Segmentaram os batimentos mantendo 250 ms (90 amostras) antes e 400 ms (144 amostras) após dos picos R. Para a entrada no classificador, utilizaram dois intervalos entre picos R (anterior e posterior), mais 3 componentes da análise HOS: (1) *skewness* ou desequilíbrio (equivale a 3ª ordem estatística dos momentos de uma distribuição); (2) *kurtosis* (é uma medida comparativa entre a distribuição do sinal com uma distribuição normal de mesma variância, equivale a 4ª ordem estatística dos momentos de uma distribuição); e o (3) 5º momento, em conjunto com as componentes do modelo de mistura gaussiana encontrados para cada conjunto. O sistema de classificação utilizado consiste em uma união de 100 árvores de decisão, a qual obteve uma taxa de acerto de 99,70%. Do mesmo modo, testaram o mesmo sistema, entretanto considerando 16 classes, apontando uma taxa de acerto de 96,15%.

No sistema proposto por Herry et al. (2017), além da base de dados de arritmias MIT-BIH, utilizaram os dados da Associação para o Aprimoramento de Instrumentação Médica (AAMI, do Inglês: *Association for the Advancement of Medical Instrumentation*). O sistema não realizou a remoção de nenhum tipo de ruído, pois utilizou-se apenas da Transformada *Synchrosqueezing* (SST, do Inglês: *Symchrosqueezing Transform*) no instante do pico R, mais a amplitude do mesmo, a duração do complexo QRS, e os intervalos entre picos R anterior, posterior e a média dos últimos 10. Para a detecção dos complexos, usaram o algoritmo de Elgendi (2013), modificado para considerar um período mínimo entre picos de 250 ms (proposto por Pan e Tompkins (1985)). Para a classificação, aplicaram o classificador SVM, obtendo uma taxa de acerto de 83,20% (desconsiderando a classe de arritmias desconhecidas) e de 87,29% quando considerado apenas 2 classes (normal e anormal).

Martis et al. (2013) realizaram a remoção de ruído utilizando a DWT de 9 níveis (*wavelet* mãe Daubechies D6), mantendo as componentes do sinal entre as frequências 0,351 e 45 Hz. Aplicaram a técnica de detecção de picos R de Pan e Tompkins (1985), mantendo 99 amostras a esquerda e 100 a direita de cada pico. Posteriormente a segmentação dos batimentos, reduziram o sinal através da DCT,

com a PCA, mantendo os 12 componentes principais produzidos. Para a classificação utilizaram a PNN, alcançando a taxa de acerto de 99,52%.

Martis, Acharya e Min (2013) usaram a mesma técnica já descrita para a remoção dos ruídos com a Transformada *Wavelet* Discreta de 9 níveis (*wavelet* mãe Daubechies D6), mantendo o sinal entre 0,351 e 45 Hz. Aplicaram o algoritmo de detecção de complexos QRS de Pan e Tompkins (1985), segmentando os batimentos em 99 amostras a esquerda e 100 a direita de cada pico R. Contudo, realizaram a redução da dimensionalidade através da DWT com *wavelet* mãe discreta de Mayer, produzindo dois sinais, um com as componentes entre as frequências 0 e 11,25Hz e outro com as componentes entre as frequências 11,25 e 22,5Hz. Após a criação destes dois sinais, utilizaram a técnica ICA, selecionando 6 componentes independentes para cada um. O algoritmo de classificação de padrões utilizado foi a PNN, obtendo uma taxa de acerto de 99,28%.

Nikan, Gwadry-Sridhar e Bauer (2017) realizaram a identificação de picos R através de um algoritmo próprio (baseado em um algoritmo de assentamento parabólico) e um filtro do tipo passa faixa, mantendo as componentes entre 5 e 15 Hz, como proposto por Pan e Tompkins (1985). Segmentaram cada batimento presente nos sinais de acordo com os intervalos entre picos R anterior e posterior, produzindo amostras de batimentos com tamanhos variados. Para a redução das características de cada batimento, executaram uma decomposição *wavelet* de 8 níveis juntamente com a técnica unidimensional uniforme chamada *local binary pattern*; criaram então, um histograma de tudo e inseriram os dados deste numa RNA ELM, produzindo uma taxa de acerto de 98,99%.

Shadmand e Mashoufi (2016) utilizaram um filtro passa Butterworth com 4 polos e com frequência de normalizada em $0,1\pi$ para a remoção do ruído de linha de base, aplicaram a decomposição *wavelet* de 8 níveis, com a remoção da aproximação e do detalhe 8. Segmentaram os batimentos selecionando 100 amostras ao redor de cada pico R, e para a extração de características aplicaram a função Hermitiana com 7 níveis de aproximação. Consideraram conjuntamente o parâmetro de comprimento da função Hermitiana e o tempo médio entre dois picos R vizinhos. O sistema de classificação proposto e utilizado consistiu em uma rede neural artificial baseada em blocos, cujo formato de cada bloco, seus pesos sinápticos e os limiares de ativação empregados foram determinados através do método de otimização por enxame de

partículas (PSO, do Inglês: *Particle Swarm Optimization*). A taxa de acerto obtida foi de 89,83%.

Thomas, Das e Ari (2015) removeram os ruídos, mantendo apenas as componentes entre 4 e 22Hz. Depois da remoção dos ruídos, normalizaram a amplitude do sinal, através da divisão pelo valor do máximo pico presente. Segmentaram os batimentos, selecionando 128 amostras a esquerda e a direita de cada pico R. Para a extração das características do sinal, aplicaram uma decomposição *wavelet* complexa de duas árvores (DTCWT, do Inglês: *Dual Tree Complex Wavelet Transform*) e extraíram os componentes da quarta e quinta escala. Extraíram ademais informações (força, *kurtosis* e *skweness*) da FFT da DTCWT e o intervalo entre picos R. Utilizaram o algoritmo de classificação de padrões MLP com 43 neurônios na camada escondida, atingindo uma taxa de acerto de 91,91%.

A Tabela 2 exibe um resumo dos trabalhos comentados anteriormente quanto ao classificador usado no trabalho e a taxa de acerto alcançada, sobre a classificação proposta por AAMI (1995).

Tabela 2 – Desempenho de trabalhos encontrados na literatura que classificam sobre a norma AAMI (1995)

			(continua)
Trabalho	Quantidade de Classes	Classificador	Taxa de Acerto (%)
Dokur e Ölmez (2001)	10	RNA com uma camada escondida tipo hiperesfera	95,70
Kim et al. (2007)	7	Rede do tipo <i>feedforward</i>	97,47
Yu e Chou (2008)	8	MLP	98,37
Yu e Chou (2008)	8	PNN	98,71
Kim et al. (2009)	6	RBF	89,36
Martis et al. (2013)	5 como proposto por AAMI (1995)	PNN	99,52
Martis, Acharya e Min (2013)	5 como proposto por AAMI (1995)	PNN	99,28
Zidelmal et al. (2013)	3	SVM modificada	98,20
Thomas, Das e Ari (2015)	5 como proposto por AAMI (1995)	MLP com 43 neurônios	91,91
Elhaj et al. (2016)	5 como proposto por AAMI (1995)	SVM com função de base radial	98,91
Elhaj et al. (2016)	5 como proposto por AAMI (1995)	MLP com 40 neurônios	98,90

Tabela 2 – Desempenho de trabalhos encontrados na literatura que classificam sobre a norma AAMI (1995)

			(conclusão)
Trabalho	Quantidade de Classes	Classificador	Taxa de Acerto (%)
Ghorbani Afkhami, Azarnia e Tinati (2016)	5 como proposto por AAMI (1995)	100 árvores de decisão	99,70
Ghorbani Afkhami, Azarnia e Tinati (2016)	16	100 árvores de decisão	96,15
Mateo et al. (2016)	2	RBF	99,79
Shadmand e Mashoufi (2016)	5 como proposto por AAMI (1995)	RNA baseada em blocos + PSO	89,93
Cardozo et al. (2017)	11	ELM com coeficiente de regularização	96,86
Chen et al. (2017)	5 como proposto por AAMI (1995)	SVM com função de base radial	98,46
Chen et al. (2017)	15	SVM com função de base radial	93,10
Herry et al. (2017)	5 como proposto por AAMI (1995)	SVM	83,20
Herry et al. (2017)	2	SVM	87,29
Nikan, Gwadry-Sridhar e Bauer (2017)	5 como proposto por AAMI (1995)	ELM sem coeficiente de regularização	98,99
Qin et al. (2017)	6	SVM com função de base radial	99,70

Fonte: Autoria própria

2.2 FILTROS MORFOLÓGICOS

A morfologia matemática, técnica desenvolvida por Matheron (1975) e Serra (1993, 1982), tem como base a teoria de conjuntos. Esta técnica utiliza operadores morfológicos, entre os operadores morfológicos temos a erosão e a dilatação e, resultantes das combinações destes, a abertura e o fechamento. Desta forma, os filtros morfológicos realizam transformações em um determinado sinal, tendo como base a teoria de morfologia matemática (MARAGOS; SCHAFER, 1987; STEVENSON; ARCE, 1987).

Filtros morfológicos são amplamente utilizados e conhecidos pela sua capacidade de preservar o formato do sinal e suprimir os ruídos. Foi primeiramente desenvolvido para o processamento de imagens binárias, sendo posteriormente ampliados para imagens em escalas de cinza e então, adaptados para sinais

unidimensionais variantes no tempo (CHU; DELP, 1989; HARALICK; STERNBERG; ZHUANG, 1987; STERNBERG, 1986).

Um dos problemas com filtros morfológicos dá-se pelo fato deste não ser um filtro linear, não sendo possível realizar uma análise em termos da resposta em frequência, embora a sua característica adaptativa seja um dos seus pontos fortes para remoção de ruídos de sinais que mudam com o tempo, como sinais eletrocardiográficos.

Outro problema observado é que os filtros morfológicos apresentam uma resposta melhor para frequências de amostragem acima de 1 kHz, pois seu desempenho está ligado com o tamanho dos elementos estruturantes utilizados, cujo tamanho é diretamente proporcional a frequência de amostragem, tornando o processamento mais custoso (CHU; DELP, 1989).

2.2.1 Operadores Morfológicos

Para cada operador morfológico, considera-se duas funções discretas, um sinal $\mathbf{f} \in \mathbb{R}^{1 \times L}$ e um elemento estruturante $\mathbf{k} \in \mathbb{R}^{1 \times M}$, com $L > M$.

Durante a operação de erosão (\odot , Equação (2.4)), o elemento estruturante é transladado através do sinal, subtraindo-se os elementos de \mathbf{k} pelos elementos de \mathbf{f} ao redor da amostra escolhida (m) e então escolhe-se o menor valor das diferenças como o novo valor do sinal. Este operador é conhecido como operador de encolhimento (do inglês: *shrinking*), pois diminui a amplitude do sinal e remove picos (CHU; DELP, 1989; SUN; CHAN; KRISHNAN, 2002).

$$(\mathbf{f} \odot \mathbf{k})[m] = \min_{n=0, \dots, M-1} \mathbf{f} \left[m + n - \frac{M-1}{2} \right] - \mathbf{k}[n] \quad (2.4)$$

para $m = \frac{M-1}{2}, \dots, L - \frac{M+1}{2}$

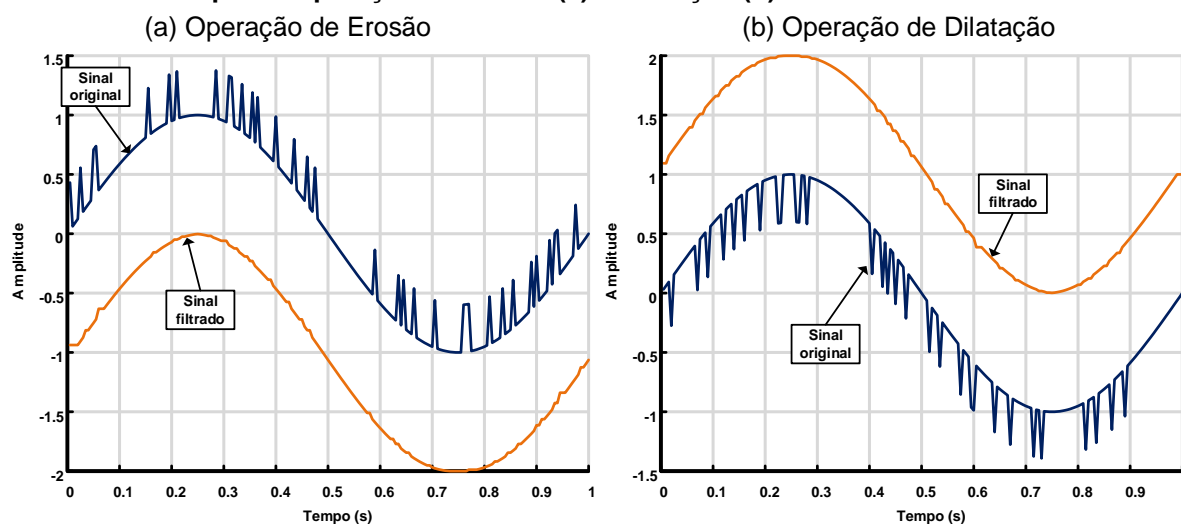
Para a dilatação (\oplus , Equação (2.5)) o elemento estruturante é espelhado, sendo posteriormente transladado através do sinal \mathbf{f} , realizando a soma entre os valores, determinando como o valor da posição escolhida (m) o maior elemento da soma, sendo também chamado de operador de expansão (do inglês: *expansion*). Tem como características o aumento na amplitude do sinal e a remoção de vales (CHU; DELP, 1989; SUN; CHAN; KRISHNAN, 2002).

$$\begin{aligned}
 (f \oplus k)[m] &= \max_{n=0, \dots, M-1} f \left[m + n - \frac{M-1}{2} \right] + k[n] \\
 \text{para } m &= \frac{M-1}{2}, \dots, L - \frac{M+1}{2}
 \end{aligned}
 \tag{2.5}$$

Como exemplo das operações morfológicas de erosão e dilatação, utiliza-se um sinal senoidal com a frequência de 1Hz afetado por ruídos impulsivos (Gráfico 1, em azul) e o elemento estruturante como $k = [1, 1, 1, 1, 1]$. O Gráfico 1(a) mostra a remoção de ruídos impulsivos positivos através da operação de erosão, já o Gráfico 1(b) apresenta a remoção dos ruídos impulsivos negativos com a operação de dilatação, os sinais filtrados são apresentados em laranja.

É possível observar que, apesar do elemento estruturante utilizado em ambas as operações ser o mesmo, este se comporta de maneira diferente. Como na operação de erosão há um decréscimo do sinal pelo elemento estruturante, há então a ocorrência da remoção de ruídos impulsivos positivos e, também, a ocorrência de um desvio de linha de base negativo. Já para a operação de dilatação, há, então, a remoção dos ruídos impulsivos negativos e um desvio de linha de base positivo.

Gráfico 1 – Exemplo da operação de erosão (a) e dilatação (b) num sinal unidimensional



Fonte: Autoria própria

Da combinação das operações de erosão e dilatação, tem-se outras duas operações, abertura e fechamento.

A operação de abertura (\circ , Equação (2.6)) consiste na realização de uma operação de erosão, seguida de uma dilatação usando o mesmo elemento estruturante, sendo geralmente utilizado para suprimir picos enquanto a amplitude do

restante do sinal tende a se manter a mesma (CHU; DELP, 1989; MARAGOS; SCHAFFER, 1986; SONG; DELP, 1989; SUN; CHAN; KRISHNAN, 2002).

$$f \circ k = (f \ominus k) \oplus k \quad (2.6)$$

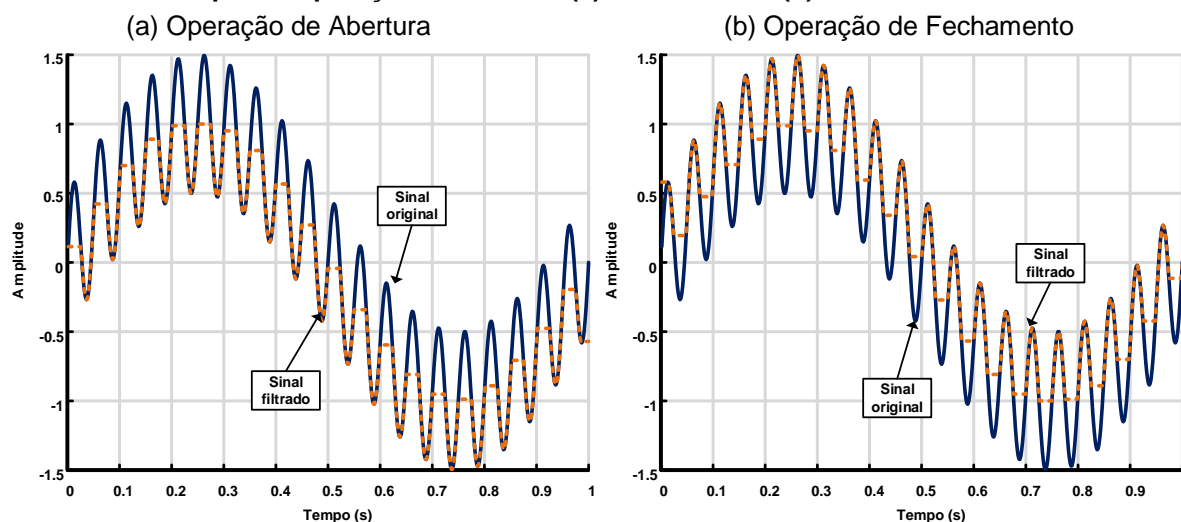
Já a operação de fechamento (\bullet , Equação (2.7)) é obtida através da operação de dilatação seguida da erosão, utilizando o mesmo elemento estruturante, de forma a suprimir vales mantendo as demais amplitudes do sinal (CHU; DELP, 1989; MARAGOS; SCHAFFER, 1986; SONG; DELP, 1989; SUN; CHAN; KRISHNAN, 2002).

$$f \bullet k = (f \oplus k) \ominus k \quad (2.7)$$

Para o exemplo das operações morfológicas de abertura e fechamento faz-se uso de um sinal senoidal com a frequência de 1Hz com amplitude 1, afetado por outro sinal de frequência 20Hz com amplitude 0,5 (Gráfico 2, em azul). Como elemento estruturante foi utilizado $k = [0, \dots, 0, \dots, 0]$ de tamanho 15 para ambas as operações. Os sinais filtrados são apresentados em laranja no Gráfico 2.

O Gráfico 2(a) mostra a remoção dos picos positivos ao entorno do sinal de 1Hz através da operação de abertura, já o Gráfico 2(b) demonstra a remoção dos vales ao entorno do sinal de 1Hz com a operação de fechamento.

Gráfico 2 – Exemplo da operação de abertura(a) e fechamento(b) num sinal unidimensional



Fonte: Autoria própria

2.3 TRANSFORMADA WAVELET

Diferente dos modos tradicionais de análise em tempo-frequência, a Transformada *Wavelet* permite a localização arbitrária de componentes de alta frequência do sinal no domínio do tempo. Isto só é possível graças a largura variável da janela, a qual está relacionada com a escala de observação (ADDISON, 2005). Além disso, a Transformada *Wavelet*, ao contrário de outras transformadas, permite que suas funções base apresentem formas de onda variadas (DAUBECHIES, 1990).

A Transformada *Wavelet* vem sendo empregada na eletrocardiografia em várias áreas. Uma das áreas de maior aplicação é para a detecção das ondas produzidas pelo coração, devido a sua capacidade de análise em tempo-frequência. Capacidade, esta, que pode ser empregada diretamente na detecção de anormalidades que ocorrem em frequências específicas (ADDISON, 2005).

2.3.1 Transformada *Wavelet* Contínua (CWT)

Para uma função ser classificada como função *wavelet* e poder ser utilizada na Transformada *Wavelet* Contínua (CWT, do Inglês: *Continuous Wavelet Transform*), alguns critérios devem ser estabelecidos.

Uma função $\psi(t)$ constitui-se em *wavelet* se $\psi(t) \in L^2(\mathbb{R})$; ou seja, ela pertence ao espaço das funções quadraticamente integráveis (de energia finita), de modo a satisfazer a Equação (2.8).

$$E = \int_{-\infty}^{+\infty} |\psi(t)|^2 dt < \infty \quad (2.8)$$

Ela também deve obedecer a condição de admissibilidade (Equação (2.9)), que implica que não existem componentes de frequência próximo de $t = 0$ (ADDISON, 2005; SILVA, 2008).

$$C_\psi = \int_{-\infty}^{+\infty} |\Psi(\omega)|^2 |\omega|^{-1} d\omega < \infty \quad (2.9)$$

Em que:

$\Psi(\omega)$ é a Transformada de Fourier de $\psi(t)$, que é obtida conforme a Equação (2.10).

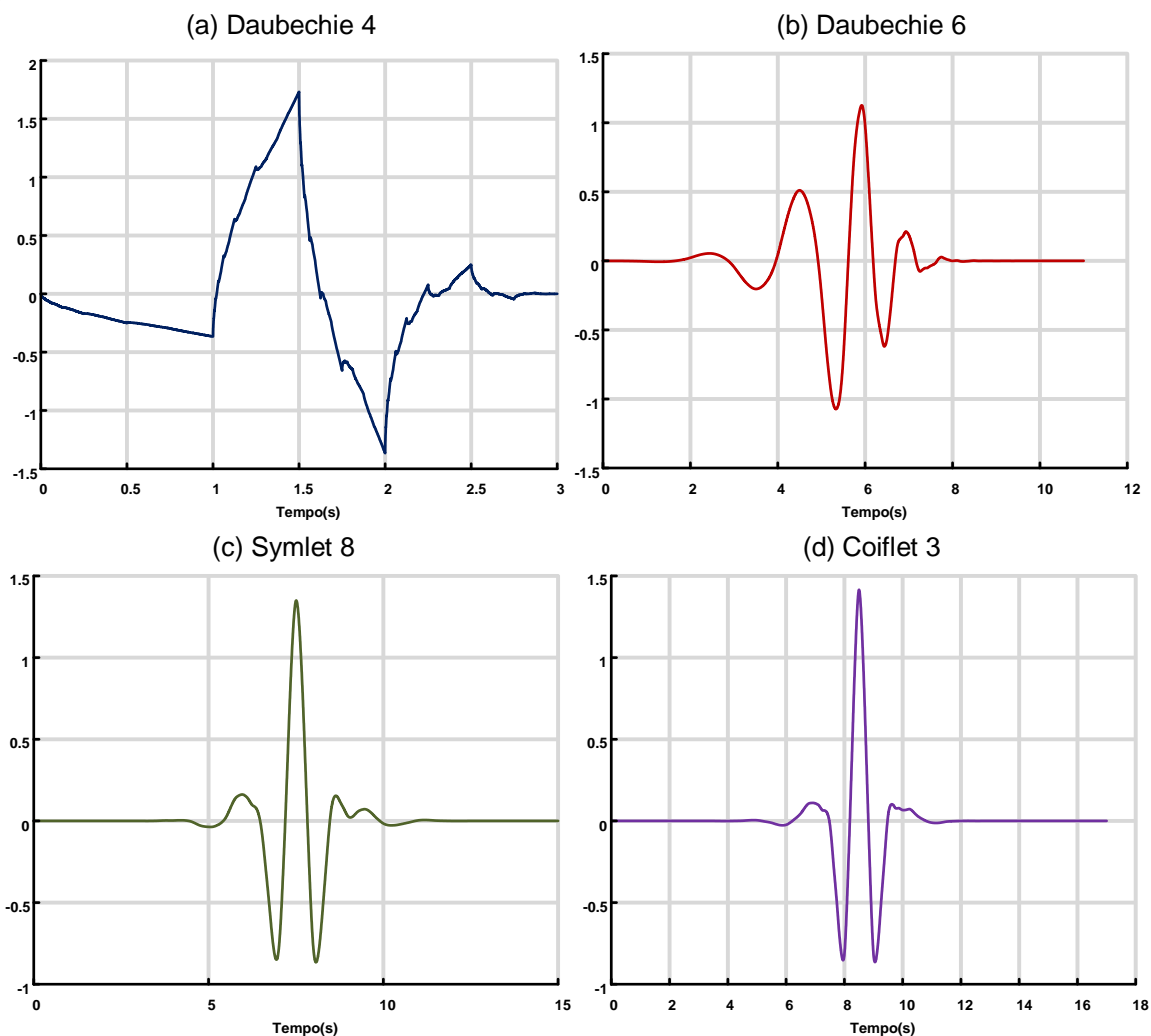
$$\Psi(\omega) = \int_{-\infty}^{+\infty} \psi(t) e^{-i(2\pi\omega)t} dt \quad (2.10)$$

A Equação (2.9) determina que graficamente a função $\psi(t)$ deve oscilar de modo a anular sua integral (Equação (2.11)), tornando sua média zero (DAUBECHIES, 1992).

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (2.11)$$

O Gráfico 3 apresenta exemplos de funções *wavelets*. Os Gráfico 3 (a) e (b) apresentam exemplos de funções Daubechies, sendo respectivamente a Dauvechie 4 e Daubechie 6. Já o Gráfico 3(c) apresenta a Symlet 8 e o Gráfico 3(d) a Coiflet 3.

Gráfico 3 – Exemplo de funções *wavelet*; (a) Daubechie 4; (b) Daubechie 6; (c) Symlet 8; (d) Coiflet 3



Fonte: Autoria própria

As *wavelets* são consideradas famílias de funções, pois a maioria das funções são derivadas de uma única função (chamada de *wavelet* mãe). Para tal, a função é indexada por dois parâmetros, um para a posição e outra para a frequência, que são usados como demonstrado na Equação (2.12) (VETTERLI; HERLEY, 1992).

$$\psi^{(a,b)}(t) = |a|^{-1/2} h\left(\frac{t-b}{a}\right) \quad (2.12)$$

Em que:

$\psi(t)$ é uma função *wavelet* mãe;

$a \in \mathbb{R}$, $a \neq 0$, é o parâmetro de escala da *wavelet*, que altera a frequência da mesma;

$b \in \mathbb{R}$ é o parâmetro de localização (ou translação) da *wavelet*.

Em (2.12), para $|a| < 1$, a *wavelet* torna-se uma versão mais concentrada e reduzida de $h(t)$, já para $|a| > 1$ a *wavelet* torna-se mais esparsa com componentes de baixa frequência (DAUBECHIES, 1990).

Deste modo, a CWT de uma função contínua no tempo $x(t)$ é definida como mostrado na Equação (2.13) (ADDISON, 2005; VETTERLI; HERLEY, 1992).

$$CWT(a,b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} x(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad (2.13)$$

Em que:

$\psi^*(t)$ é o complexo conjugado da função *wavelet* mãe $\psi(t)$;

$a \in \mathbb{R}$, $a \neq 0$ é o parâmetro de escala da *wavelet*;

$b \in \mathbb{R}$ é o parâmetro de translação da *wavelet*.

E de forma análoga à Transformada de Fourier, o sinal original $x(t)$ pode ser reconstruído usando uma Transformada *Wavelet* Inversa, como demonstrado na Equação (2.14).

$$x(t) = \frac{1}{C_\psi} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} CWT(a,b) \psi^{(a,b)}(t) db \frac{da}{a^2} \quad (2.14)$$

Em que:

$\psi^{(a,b)}(t)$ é uma função *wavelet*;

$a \in \mathbb{R}$, $a \neq 0$ é o parâmetro de escala da *wavelet*;

$b \in \mathbb{R}$ é o parâmetro de translação da *wavelet*;

C_ψ é definido pela Equação (2.9).

2.3.2 Transformada *Wavelet* Discreta (DWT)

Para aplicações do tipo discretas (incluindo análise de sinais), os parâmetros de dilatação e translação da *wavelet* são restritos a certos valores. Desta forma, transforma-se a Equação (2.12) na Equação (2.16), ao atribuir os valores de dilatação e translação conforme a Equação (2.15).

$$\begin{aligned} a &= a_0^m \\ b &= nb_0 a_0^m \end{aligned} \quad (2.15)$$

$$\psi^{(m,n)}(t) = |a_0|^{-m/2} h(a_0^{-m}t - nb_0) \quad (2.16)$$

Em que:

$\psi^{(m,n)}(t)$ é uma função *wavelet*;

$a_0 \in \mathbb{R}$, $a_0 > 1$ é o passo fixo de escala da *wavelet*;

$b_0 \in \mathbb{R}$, $b_0 \neq 0$ é o passo fixo de translação da *wavelet*;

$m, n \in \mathbb{Z}$, $m \geq 0$, $n \geq 0$.

Assim a Transformada *Wavelet* Discreta (DWT, do inglês: *Discrete Wavelet Transform*) é a Transformada *Wavelet* Contínua, porém associada a funções *wavelets* discretas (Equação (2.16)), reescrevendo a Equação (2.13) em (2.17), a qual mapeia $L^2(\mathbb{R})$ em $l^2(\mathbb{Z}^2)$.

$$DWT(m, n) = |a_0|^{-m/2} \int_{-\infty}^{+\infty} x(t) \psi^*(a_0^{-m}t - nb_0) dt \quad (2.17)$$

A escolha mais comum para a_0 e b_0 são 2 e 1, respectivamente, de modo a se obter uma transformada *wavelet* ortonormal (também chamada de diádica). A escolha de b_0 é em geral arbitrária, porém a escolha de a_0 é feita de modo determinado, sendo que outros valores poderiam também serem escolhidos para a obtenção de uma *wavelet* ortonormal (DAUBECHIES, 1988).

A utilização de uma base ortonormal implica que não haverá redundância de informações entre os sinais decompostos e na possibilidade de decomposição do sinal em diferentes escalas no tempo e na frequência (DAUBECHIES, 1992).


Como exemplo do uso dos parâmetros de dilatação e de translação discretos em uma função *wavelet*, utiliza-se os mesmos na função descrita em (2.18) (conhecida como Chapéu Mexicano (DAUBECHIES, 1990)), mostrando no Gráfico 4 o uso de alguns parâmetros (com $a_0 = 2$ e $b_0 = 1$):

1. $m = -1; n = -20$
2. $m = 0; n = 0;$
3. $m = 1; n = 7,5$

$$\psi(t) = \frac{2}{\sqrt{3}} \pi^{-1/4} (1-t^2) e^{-t^2/2} \quad (2.18)$$

No Gráfico 4, observa-se a interferência dos parâmetros discretos de escala e deslocamento, no qual para m menor que zero ocorre uma compressão do sinal e para m maior que zero ocorre uma dilatação do sinal. É possível notar que os parâmetros de escala também afetam o deslocamento de forma direta, como determinado pela Equação (2.15).

Gráfico 4 – Exemplo do uso dos parâmetros de dilatação e translação em uma função *wavelet* discreta



Fonte: Adaptado de Daubechies (1990)

Uma forma de codificar a Transformada *Wavelet* Discreta se dá com a utilização de técnicas de Análise Multiresolução de Sinal como a decomposição piramidal em sub-faixas com a utilização de filtros espelhados; ou a decomposição através de banco de filtros (MALLAT, 1989; RIOUL; VETTERLI, 1991).

Dado uma sequência $x(n)$, $n \in \mathbb{Z}$, pode-se obter uma resolução mais baixa do sinal por intermédio de um filtro passa baixa com a frequência de corte como $\pi/2$, sendo o filtro representado por $g(n)$. Tendo como base o teorema de Nyquist, pode-

se dobrar a escala do sinal, subamostrando o mesmo pela metade, sendo o resultado ($y(n)$) demonstrado na Equação (2.19) (RIOUL; VETTERLI, 1991).

$$y(n) = \sum_{k=-\infty}^{+\infty} g(k)x(2n-k) \quad (2.19)$$

A mudança de resolução é obtida pelo filtro passa baixa, com a perda dos detalhes de alta frequência, e a mudança de escala é obtida pela subamostragem ($\downarrow 2$, Figura 7 e Figura 8).

Baseado na resposta subamostrada e com componentes de frequência mais baixos, é possível obter uma aproximação ($a(n)$) do sinal original ($x(n)$). Para isto, primeiramente aumenta-se a resolução do sinal, dobrando a quantidade de amostras (inserindo o valor zero entre as amostras presentes, Equação (2.20), $\uparrow 2$ na Figura 7 e Figura 8), obtendo a função $y'(n)$ a partir da função $y(n)$ (RIOUL; VETTERLI, 1991).

$$y'(2n) = y(n) \quad , \quad y'(2n+1) = 0 \quad (2.20)$$

Então $y'(n)$ é interpolado com um filtro $g'(n)$, para se obter a aproximação ($a(n)$), como demonstrado na Equação (2.21).

$$a(n) = \sum_{k=-\infty}^{+\infty} g'(k)y'(n-k) \quad (2.21)$$

Como $a(n)$ não é igual a $x(n)$, pois $a(n)$ é a aproximação do sinal do original com a metade da frequência, calcula-se a diferença entre a aproximação e o sinal original, como apresentado na Equação (2.22).

$$d(n) = x(n) - a(n) \quad (2.22)$$

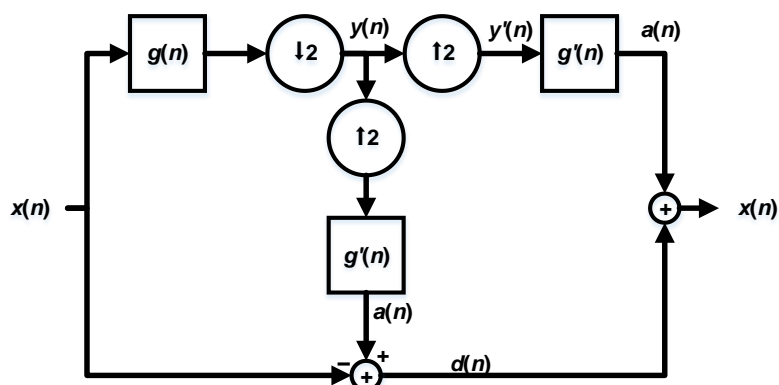
Neste caso, é considerado a utilização de um filtro perfeito com a frequência de corte na metade da frequência máxima do sinal, ficando claro que $d(n)$ contém exatamente as frequências acima de $\pi/2$ de $x(n)$; deste modo, $d(n)$ pode, também, ser subamostrado pela metade sem a perda de informação (RIOUL; VETTERLI, 1991).

Sendo assim, a análise multiresolução de um sinal, consiste na separação do sinal original ($x(n)$) em uma aproximação grosseira ($a(n)$) e mais um detalhe adicional contido em $d(n)$.

Todo este processo pode ser observado na Figura 7, a qual mostra o sinal $x(n)$, que sofre uma subamostragem após passar por um filtro passa baixa, conforme a Equação (2.19). É reamostrado como mostrado na Equação (2.20), então sua aproximação é obtida de acordo com a Equação (2.21) e seu detalhe calculado

conforme a Equação (2.22). Por fim, pode-se obter o sinal original através da soma da aproximação e do detalhe.

Figura 7 – Análise multiresolução com esquema piramidal de um sinal $x(n)$



Fonte: Adaptado de Rioul e Vetterli (1991)

Outro modo de se obter o detalhe adicional do sinal é com a utilização de um filtro passa alta com frequência de corte em $\pi/2$, utilizando um filtro representado por $h(n)$, seguido de uma subamostragem pela metade. Deste modo, para a reconstrução do sinal original, basta aumentar a resolução do sinal e então filtrar o mesmo por $h'(n)$ (MALLAT, 1989; RIOUL; VETTERLI, 1991).

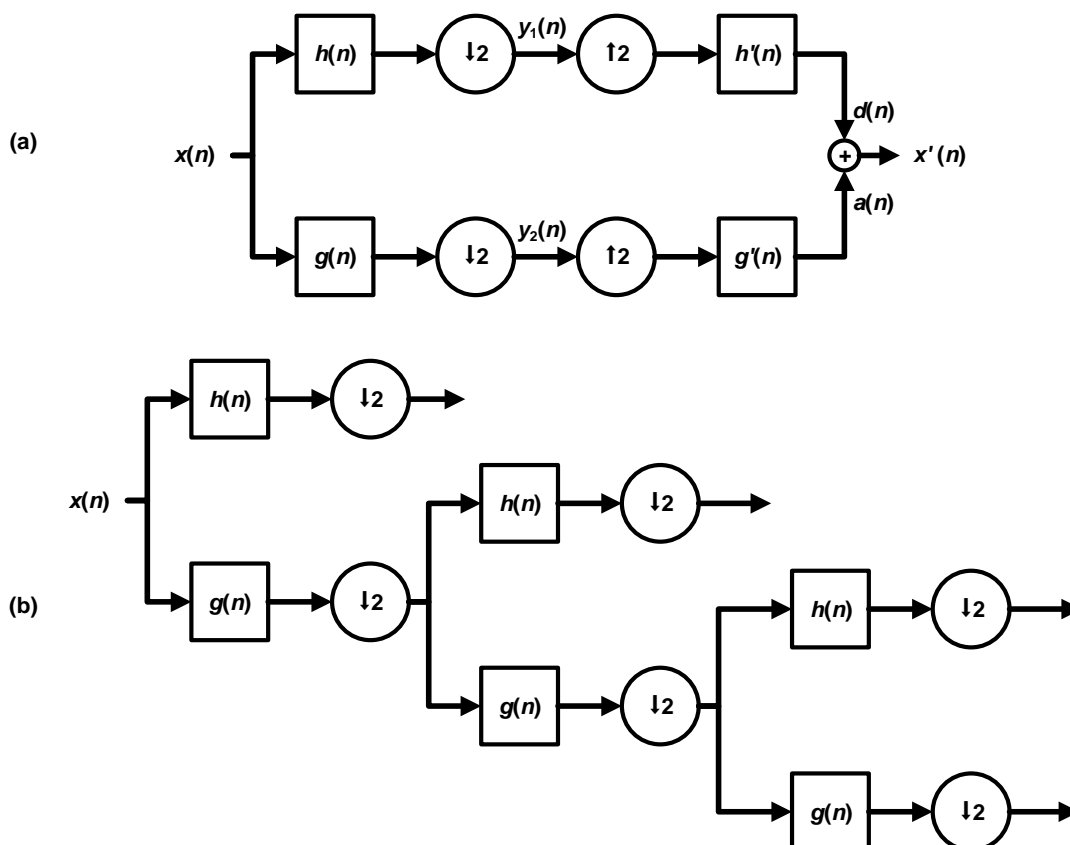
Ao contrário do método apresentado na Figura 7, o sinal reconstruído ($x'(n)$) não é idêntico ao sinal original, pois os filtros utilizados, em geral, não possuem propriedades de reconstrução perfeitas.

Todo este processo é chamado de banco de filtros e pode ser observado na Figura 8 (a) e (b), na qual o sinal $x(n)$ é filtrado por um filtro passa baixa $g(n)$ e por um filtro passa alta $h(n)$, sendo então subamostrado. Na Figura 8(a), inclusive, é possível visualizar a reconstrução do sinal original através da soma da aproximação e do detalhe calculados.

A Figura 8 (b) mostra como funcionaria a análise multiresolução utilizando filtros. Posteriormente a filtragem e subamostragem do sinal $x(n)$ são obtidos dois sinais, nos quais as componentes de frequência do sinal original foram divididas entre ambos. Ou seja, se a componente de maior frequência no sinal original era $F_s/2$ Hz, os sinais resultantes apresentaram componentes entre $0 - F_s/4$ Hz (pelo lado do filtro $g(n)$) e entre $F_s/4 - F_s/2$ Hz (pelo lado do filtro $h(n)$). Caso deseje-se as componentes de mais baixa frequência então continua-se a decomposição pelo lado do filtro passa baixa (como mostrado na figura), do contrário se deseja-se uma componente entre

frequências específicas pode-se obtê-las através de uma outra sequência de filtragem.

Figura 8 – Análise multiresolução com banco de filtros com decomposição e reconstrução do sinal discreto $x(n)$ (a) e com decomposição do sinal $x(n)$ em várias escalas (b)



Fonte: Adaptado de Rioul e Vetterli (1991) e de Mallat (1989)

2.4 ANÁLISE DE COMPONENTES PRINCIPAIS

De acordo com Jolliffe (1986), a análise de componentes principais (PCA, do inglês: *Principal Componente Analysis*) é uma técnica estatística cujo propósito é agrupar informações de um grande conjunto de variáveis correlacionadas em um pequeno conjunto de poucas variáveis não correlatas. Estas variáveis são chamadas componentes principais e estarão ordenadas de modo que as primeiras contêm a maior parte da variância presente em todo o conjunto original de variáveis.

A aplicação da análise de componentes principais na eletrocardiografia se dá na forma da extração de características das propriedades das formas de ondas

contidas no sinal, de modo a se detectar anomalias presentes no mesmo (CASTELLS et al., 2007).

É importante também para a aplicação dos dados nos algoritmos de inteligência computacional, os quais são afetados diretamente pela quantidade de variáveis utilizadas, de modo que quanto mais variáveis maior o custo computacional (DUDA; HART; STORK, 2006; HAYKIN, 1999).

Considerando uma matriz de dados $\mathbf{X} \in \mathbb{R}^{N \times L}$, em que: N é a quantidade total de amostras e L o número de variáveis. Esta precisa possuir uma média zero, como isto nem sempre é comum, calcula-se uma nova matriz de dados (\mathbf{X}') subtraindo a matriz de média ($\bar{\mathbf{X}}$) da matriz de dados original (\mathbf{X}), conforme é mostrado na Equação (2.23) (HAYKIN, 1999).

$$\mathbf{X}' = \mathbf{X} - \bar{\mathbf{X}} \quad (2.23)$$

Com a matriz de dados ajustada, a matriz de covariância ($\mathbf{C} \in \mathbb{R}^{L \times L}$), é calculada conforme a Equação (2.24).

$$\mathbf{C} = \frac{1}{N-1} (\mathbf{X}'^T \mathbf{X}') \quad (2.24)$$

Em seguida, calcula-se as matrizes de autovalores (formada com cada autovalor $\lambda_i \in \mathbb{R}$ presente na diagonal principal de $\mathbf{D} \in \mathbb{R}^{L \times L}$, (2.25)) e autovetores ($\mathbf{V} \in \mathbb{R}^{L \times L}$) da matriz \mathbf{C} , de acordo com a Equação (2.26) (HAYKIN, 1999).

$$\mathbf{D} = \text{diag}[\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_L] \quad (2.25)$$

$$\mathbf{D} = \mathbf{V}^{-1} \mathbf{C} \mathbf{V} \quad (2.26)$$

A matriz de autovetores é então rearranjada de acordo com seus autovalores correspondentes, de modo que os autovalores estejam organizados em ordem decrescente, conforme (2.27) (DUDA; HART; STORK, 2006).

$$\lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_L \quad (2.27)$$

Da matriz \mathbf{V} pode-se, então, calcular a matriz de dados projetados ($\mathbf{P} \in \mathbb{R}^{N \times L}$), seguindo-se a Equação (2.28).

$$\mathbf{P} = \mathbf{X}' \mathbf{V}^T \quad (2.28)$$

Cada autovalor equivale a variância de cada componente do vetor de dados, e como o autovetor utilizado está ordenado de acordo com seu autovalor equivalente, temos que as componentes com maior variância estão contidas nas primeiras colunas à esquerda da matriz \mathbf{P} .

A partir das variâncias, pode-se calcular qual a porcentagem (v_i) que cada componente influencia no sinal pela Equação (2.29).

$$v_i(\%) = \frac{100d_i}{\sum_{i=1..L} d_i} \quad (2.29)$$

Desta forma, para a redução de dimensionalidade, pode-se selecionar apenas as primeiras E colunas, que são as que apresentam maior influência nos dados projetados.

2.5 ALGORITMOS DE INTELIGÊNCIA COMPUTACIONAL

O ato de reconhecer padrões a partir de dados não processados e tomar uma ação baseada na “categoria” do padrão é algo crucial para a sobrevivência do ser humano. Portanto, sistemas de reconhecimento de padrões confiáveis são imensamente úteis sendo empregadas nas mais diversas áreas, como reconhecimento de voz, de impressão digital, de caracteres ou, como é o caso deste trabalho, de doenças cardíacas, entre outras. (DUDA; HART; STORK, 2006).

A inteligência computacional (IC) tem como um dos principais objetivos desenvolver paradigmas ou algoritmos que realizem tarefas cognitivas, devendo, assim, ser capaz de realizar três coisas: (1) armazenar conhecimento, (2) aplicar o conhecimento armazenado para resolver problemas e (3) adquirir novos conhecimentos através de experiência (HAYKIN, 1999).

Isto posto, esta Seção cita e discute o funcionamento de algumas técnicas de inteligência computacional utilizadas por este trabalho. Estas podem ser empregadas em sistemas para reconhecimento de padrões, o que aparenta ser uma tarefa que exige muito tempo de análise e estudo, porém, que torna-se um processo mais simples, confiável e rápido, por este ser realizado por uma máquina.

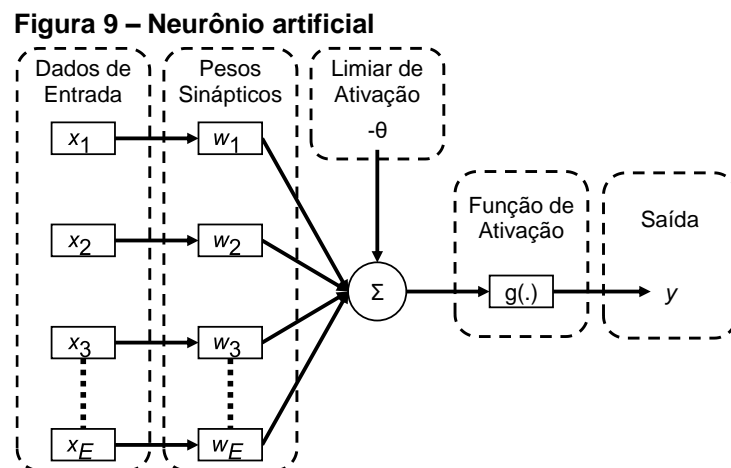
2.5.1 Redes Neurais Artificiais

O processamento de informações do cérebro humano é realizado pelo sistema nervoso, que tem como célula elementar o neurônio; por sua vez, este conduz estímulos elétricos por meio de conexões (sinapses) para outros neurônios, formando uma rede neural.

Os estímulos elétricos são ponderados internamente por elementos neurotransmissores de forma dinâmica, sendo que uma célula nervosa precisa ser estimulada além de um limiar de ativação para que um impulso elétrico seja propagado. Desta forma, a estrutura de redes neurais artificiais (RNAs) foi desenvolvida, tendo como base os modelos do sistema nervoso (SILVA; SPATTI; FLAUZINO, 2010).

O funcionamento do neurônio artificial genérico pode ser observado na Figura 9 e na Equação (2.30), na qual os dados de entrada ($\mathbf{x} \in \mathbb{R}^{E \times 1}$) são multiplicados cada qual pelo seu respectivo peso sináptico ($\mathbf{w} \in \mathbb{R}^{1 \times E}$) e então subtraído do limiar de ativação ($\theta \in \mathbb{R}$), em seguida a soma dos resultados é aplicada a uma função de ativação ($g(\cdot)$) para a obtenção da saída ($y \in \mathbb{R}$) (MCCULLOCH; PITTS, 1943; ROSENBLATT, 1958).

$$y = g\left(\sum_{j=1}^E w_j x_j - \theta\right) \quad (2.30)$$



Fonte: Adaptado de Silva, Spatti e Flauzino (2010)


A função de ativação tem como objetivo limitar a saída do neurônio artificial a um intervalo de valores conhecidos. Esta pode ser uma entre diversas, como a função rampa simétrica (Equação (2.31), Gráfico 5(a)), logística (Equação (2.32), Gráfico 5(b)), gaussiana (Equação (2.33), Gráfico 5(c)), etc.

$$g(u) = \begin{cases} a & , \text{se } u > a \\ u & , \text{se } -a \leq u \leq a \\ -a & , \text{se } u < -a \end{cases} \quad (2.31)$$

$$g(u) = \frac{1}{1 + e^{-\beta u}} \quad (2.32)$$

$$g(u) = e^{-\frac{(u-c)^2}{2\sigma^2}} \quad (2.33)$$

Gráfico 5 – Exemplo de funções de ativação; (a) Rampa Simétrica 4; (b) Logística; (c) Gaussiana



Fonte: Autoria própria

Diz-se que o conhecimento do neurônio (e conseqüentemente da rede neural) está concentrado nos pesos sinápticos, os quais, junto com o limiar de ativação, são ajustados na etapa de treinamento (aprendizagem) para que a saída obtida seja a mais próxima possível da saída desejada (SILVA; SPATTI; FLAUZINO, 2010).

Existem diversas formas de se treinar uma rede neural, sendo que os métodos de treinamento podem ser divididos em diversos modos, não obstante, as principais técnicas podem ser divididas em dois métodos:

- **Treinamento supervisionado:** consiste na apresentação de uma saída desejada para uma dada entrada, envolvendo muitas vezes o erro entre as duas para a atualização dos pesos. Algumas delas envolvem o cálculo do gradiente descendente, e/ou ainda a realizam de forma analítica.

- **Treinamento não supervisionado:** consiste na atualização dos pesos sem a necessidade de saber qual a saída desejada, utilizando métodos que consistem na menor distância euclidiana entre os vetores de dados, para a determinação de grupos que contenham características semelhantes.

Após o término da fase de aprendizagem da RNA, esta é avaliada através de um conjunto de teste, que consiste em uma parte do banco de dados que não foi utilizada na etapa de treinamento.

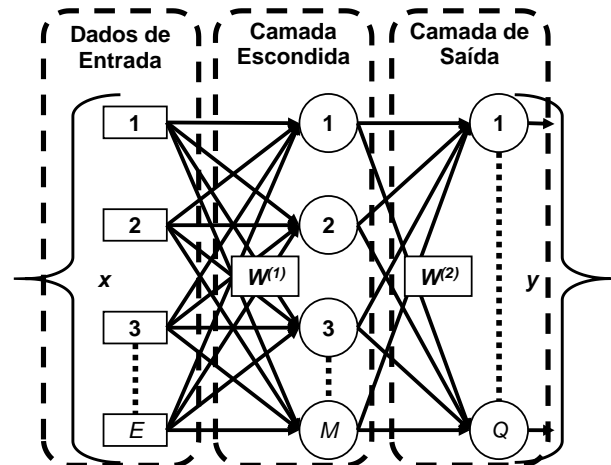
Uma rede neural artificial pode possuir diversos formatos de conexões entre os neurônios, sendo este chamado de arquitetura. Dentre as diversas arquiteturas de RNAs, existem as do tipo *feedforward* (Figura 10), que tem como características reunir neurônios em camadas (conjunto de neurônios ligados em paralelo com a mesma entrada), propagando os sinais em direção a camada de saída, sem apresentar ciclos. Redes deste tipo podem possuir uma ou mais camadas de neurônios, com cada camada contendo quantidades diferentes de neurônios artificiais (LIPPMANN, 1987).

A última camada de neurônios de uma RNA é comumente chamada de camada de saída, sendo as demais consideradas camadas escondidas, cada qual com sua respectiva função de ativação determinada previamente. A função de ativação mais comumente empregada na camada de saída é a função linear (LIPPMANN, 1987; SILVA; SPATTI; FLAUZINO, 2010).

O conjunto de pesos de uma camada de neurônios é comumente expresso como uma matriz, com cada linha correspondendo a um neurônio. Uma rede neural artificial com uma camada escondida pode ser observado na Figura 10 e descrita na Equação (2.34), na qual existe um conjunto de E dados de entrada ($\mathbf{x} \in \mathbb{R}^{E \times 1}$), a camada escondida (a qual contem M neurônios) com seus pesos contidos na matriz $\mathbf{W}^{(1)} \in \mathbb{R}^{M \times E}$, a camada de saída com seus pesos $\mathbf{W}^{(2)} \in \mathbb{R}^{Q \times M}$ e as Q saídas da rede neural ($\mathbf{y} \in \mathbb{R}^{Q \times 1}$). Na Figura 10 o limiar de ativação e a função de ativação estão considerados intrínsecos a cada neurônio.

Na RNA mostrada na Figura 10 e na Equação (2.34) os dados de entrada são multiplicados cada qual pelo seu peso específico com relação a um determinado neurônio da camada escondida, os resultados somados e o seu limiar de ativação subtraído (como no neurônio artificial da Figura 9 e Equação (2.30)). Sendo que a entrada dos neurônios da próxima camada é a saída dos neurônios da camada anterior.

Figura 10 – Formato de uma RNA com uma camada escondida



Fonte: Autoria própria, baseado em Silva, Spatti e Flauzino (2010)

$$y = g^{(2)} \left(W^{(2)} g^{(1)} \left(W^{(1)} x - \theta^{(1)} \right) - \theta^{(2)} \right) \quad (2.34)$$

Em que:

$\theta^{(1)} \in \mathbb{R}^{M \times 1}$ é o limiar de ativação da camada escondida;

$\theta^{(2)} \in \mathbb{R}^{Q \times 1}$ é o limiar de ativação da camada de saída;

$g^{(1)}()$ é a função de ativação da camada escondida e;

$g^{(2)}()$ é a função de ativação da camada de saída (normalmente uma função linear).

2.5.1.1 Rede neural de função de base radial

As RNAs denominadas de funções de base radial (RBF, do inglês: *Radial Basis Function*) são compostas por apenas uma camada escondida (apresentando a arquitetura do tipo *feedforward* como apresentada na Figura 10) e, ao contrário de diversas outras redes neurais, o treinamento desta camada é feito de modo não supervisionado e sua função de ativação será, neste trabalho, a gaussiana (2.35):

$$g(\mathbf{x}) = e^{-\frac{(\mathbf{x}-\mathbf{c})^2}{2\sigma^2}} \quad (2.35)$$

Em que:

$\sigma^2 \in \mathbb{R}$ é a variância da função, a qual indica o quão disperso estão as amostras do seu centro;

$\mathbf{x} \in \mathbb{R}^{Ex1}$ é um vetor de uma amostra e;

$\mathbf{c} \in \mathbb{R}^{Ex1}$ é o centro da função.

Para a camada de saída, é aplicada a função de ativação linear, com os pesos desta camada sendo ajustados de modo supervisionado.

O processo de treinamento da RBF pode ser dividido em duas etapas. Na primeira, os pesos da camada escondida são ajustados de modo não supervisionado; na segunda, são ajustados os pesos da camada de saída de maneira supervisionada. Faz-se essa divisão, pois, em geral, as RNAs ajustam os pesos de ambas as camadas ao longo da mesma iteração de treinamento, ajustando ambas de modo supervisionado ou não (SILVA; SPATTI; FLAUZINO, 2010).

Inicialmente, para a primeira etapa do treinamento, os pesos dos neurônios da camada escondida ($\mathbf{W}^{(1)} \in \mathbb{R}^{M \times E}$) são inicializados com os valores de M amostras, escolhidas de forma a abranger cada classe a ser classificada. Então, cada amostra é adicionada ao “grupo” do neurônio que se encontra geometricamente mais próximo. Ou seja, é calculada a distância euclidiana do peso de cada neurônio com relação a amostra selecionada, o neurônio que apresentar a menor distância euclidiana acrescenta a amostra ao seu grupo ($\Omega^{(j)}$, sendo j o neurônio com a menor distância euclidiana).

Após todas as amostras serem separadas entre os grupos, os pesos de cada neurônio j da camada escondida ($\mathbf{w}^{(1)}_j \in \mathbb{R}^{1 \times E}$) é ajustado (conforme a Equação (2.36)), levando-se em consideração o grupo ($\Omega^{(j)}$) com suas amostras ($\mathbf{x}_v \in \mathbb{R}^{E \times 1}$) e a quantidade de amostras contidas no grupo ($m^{(j)}$) (HAYKIN, 1999).

$$\mathbf{w}_j^{(1)} = \frac{1}{m^{(j)}} \sum_{\mathbf{x}_v \in \Omega^{(j)}} \mathbf{x}_v^T \quad (2.36)$$

De forma iterativa, o processo é repetido até que não haja mais alterações na composição dos grupos. Após ajustados os pesos, calcula-se a variância de cada neurônio utilizando a equação (2.37) (SILVA; SPATTI; FLAUZINO, 2010):

$$\sigma_j^2 = \frac{1}{m^{(j)}} \sum_{\mathbf{x}_v \in \Omega^{(j)}} (\mathbf{x}_v^T - \mathbf{w}_j^{(1)}) (\mathbf{x}_v^T - \mathbf{w}_j^{(1)})^T \quad (2.37)$$

A saída da camada escondida ($\mathbf{Z} \in \mathbb{R}^{M \times N}$) tem seus elementos ($z_{i,j} \in \mathbb{R}$) calculados pela Equação (2.38), que é a aplicação da função de ativação (definida na Equação (2.35)) nos dados ($\mathbf{x}_j \in \mathbb{R}^{E \times 1}$) da amostra j com relação ao neurônio i ($\mathbf{w}_i^{(1)} \in \mathbb{R}^{1 \times E}$) da camada de entrada.

$$z_{i,j} = e^{-\frac{(\mathbf{x}_j^T - \mathbf{w}_i^{(1)}) (\mathbf{x}_j^T - \mathbf{w}_i^{(1)})^T}{2\sigma_j^2}} \quad (2.38)$$

Por fim, ajusta-se os pesos da camada de saída ($\mathbf{W}^{(2)} \in \mathbb{R}^{Q \times M}$, inicializados com valores aleatórios entre 0 e 1). O método mais comum de ajuste de pesos é através da fórmula do gradiente descendente, expressa na equação (2.39) (HAYKIN, 1999; SILVA; SPATTI; FLAUZINO, 2010).

$$\mathbf{W}^{(2)} = \mathbf{W}^{(2)} + \eta(\mathbf{D} - \mathbf{Y})\mathbf{Z}^T \quad (2.39)$$

Em que:

η é a taxa de aprendizagem;

$\mathbf{Z} \in \mathbb{R}^{M \times N}$ é a saída da camada escondida;

$\mathbf{D} \in \mathbb{R}^{Q \times N}$ é a saída desejada da rede e;

$\mathbf{Y} \in \mathbb{R}^{Q \times N}$ é a saída obtida (calculada conforme a Equação (2.40)).

$$\mathbf{Y} = \mathbf{W}^{(2)}\mathbf{Z} \quad (2.40)$$

Os pesos da camada de saída são ajustados até que a diferença do erro quadrático médio (E_M , Equação (2.42)) entre as iterações alcance a precisão requerida (ϵ , Equação (2.41)).

$$\left| E_M^{atual} - E_M^{anterior} \right| \leq \epsilon \quad (2.41)$$

$$E_M = \frac{1}{N} \sum_{i=1}^N \frac{(\mathbf{d}_i - \mathbf{y}_i)(\mathbf{d}_i - \mathbf{y}_i)^T}{2} \quad (2.42)$$

Em que:

N é a quantidade de amostras;

$\mathbf{d}_i \in \mathbb{R}^{Q \times 1}$ é a saída desejada para a amostra i e;

$\mathbf{y}_i \in \mathbb{R}^{Q \times 1}$ é a saída obtida para a amostra i .

2.5.1.2 Máquina de aprendizado extremo

A RNA máquina de aprendizado extremo (ELM, do inglês: *Extreme Learning Machine*), trata-se de uma RNA que possui apenas uma camada escondida de neurônios. Ao contrário das técnicas tradicionais de treinamento, na ELM a camada escondida não é treinada, pois com a escolha arbitrária dos pesos de entrada e do limiar de ativação é possível tratar a RNA como um sistema linear e determinar os pesos da camada de saída de modo analítico, alcançando não somente o menor erro de treinamento, como também uma menor norma entre os pesos, o que garante uma

melhor generalização e torna o processo de aprendizado mais rápido (BARTLETT, 1998; HUANG; ZHU; SIEW, 2004, 2006).

Como definido e apresentado na Figura 10, as redes neurais utilizadas com a *Extreme Learning Machine* possuem apenas duas camadas de neurônios artificiais, uma escondida ($\mathbf{W}^{(1)} \in \mathbb{R}^{M \times E}$) e uma de saída ($\mathbf{W}^{(2)} \in \mathbb{R}^{Q \times M}$); sendo M a quantidade de neurônios na camada escondida, E o número de dados de entrada e Q o número de saídas. Com seu resultado ($\mathbf{y}_i \in \mathbb{R}^{Q \times 1}$) para uma dada entrada ($\mathbf{x}_i \in \mathbb{R}^{E \times 1}$) obtido pela equação (2.43), sendo uma variante da Equação (2.34), onde da camada de saída são suprimidos o limiar de ativação e, também, a função de ativação por ser uma função linear (HUANG; ZHU; SIEW, 2004).

$$\mathbf{y}_i = \mathbf{W}^{(2)} \mathbf{g}(\mathbf{W}^{(1)} \mathbf{x}_i - \boldsymbol{\theta}) \quad (2.43)$$

Em que:

$\boldsymbol{\theta}$ é o limiar de ativação ($\boldsymbol{\theta} \in \mathbb{R}^{M \times 1}$);

$\mathbf{g}()$ é a função de ativação e;

i varia de 1 até N (número de amostras).

Agupando as N amostras de entradas, teremos um conjunto de amostras de entradas $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N] \in \mathbb{R}^{E \times N}$ associado a um conjunto de saídas $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N] \in \mathbb{R}^{Q \times N}$. Reescrevendo a Equação (2.43) na Equação (2.44), considerando agora o limiar de ativação como $\boldsymbol{\Theta} = [\boldsymbol{\theta}, \boldsymbol{\theta}, \dots, \boldsymbol{\theta}] \in \mathbb{R}^{M \times N}$, ou seja, uma repetição da primeira coluna N vezes.

$$\mathbf{Y} = \mathbf{W}^{(2)} \mathbf{g}(\mathbf{W}^{(1)} \mathbf{X} - \boldsymbol{\Theta}) \quad (2.44)$$

A saída da camada escondida ($\mathbf{H} \in \mathbb{R}^{M \times N}$), pode ser separada do restante do sistema descrito anteriormente, pois os pesos da camada de entrada são definidos de forma aleatória (com valores entre -1 e 1) e, também, o limiar de ativação (com valores entre 0 e 1) (HUANG; ZHU; SIEW, 2006)

$$\mathbf{H} = \mathbf{g}(\mathbf{W}^{(1)} \mathbf{X} - \boldsymbol{\Theta}) \quad (2.45)$$

Substituindo a Equação (2.45) na Equação (2.44) tem-se o sistema expresso na Equação (2.46).

$$\mathbf{Y} = \mathbf{W}^{(2)} \mathbf{H} \quad (2.46)$$

Considerando $\mathbf{D} \in \mathbb{R}^{Q \times N}$ como a saída desejada da rede, tem-se que o objetivo da rede neural ELM, é encontrar um $\mathbf{W}^{(2)}$ que minimize a Equação (2.47), para que o erro entre a saída desejada e a saída obtida seja o menor possível na etapa de

treinamento e também seja alcançada a menor norma de $\mathbf{W}^{(2)}$ (HUANG; ZHU; SIEW, 2006).

$$\arg \min_{\mathbf{W}^{(2)}} \|\mathbf{W}^{(2)}\mathbf{H} - \mathbf{D}\| \quad (2.47)$$

Pode-se então determinar de forma analítica os pesos sinápticos da camada de saída, utilizando a Equação (2.48).

$$\mathbf{W}^{(2)} = \mathbf{D}(\mathbf{H})^\dagger \quad (2.48)$$

Em que: o operador $()^\dagger$ é o operador da pseudo-inversa, que, neste caso, é calculado pela técnica de Moore-Penrose (Equação (2.49)⁶). Esta técnica é a mais utilizada para resolver esta questão, pois ela garante a menor norma dos pesos bem como o menor erro quadrático médio entre a saída da rede e o sinal desejado (HUANG et al., 2012).

$$(\mathbf{H})^\dagger = (\mathbf{H}^\top \mathbf{H})^{-1} \mathbf{H}^\top \quad (2.49)$$

Outra forma de melhorar o cálculo dos pesos da camada escondida leva em consideração o que Hoerl e Kennard (1970) provaram, que com a adição de um valor pequeno e positivo na diagonal principal da multiplicação de uma matriz pela sua transposta, a solução se torna mais estável e apresenta uma maior generalização. Assim, Huang et al. (2012) modificou a estrutura do cálculo da pseudo-inversa de Moore-Penrose adicionando um fator de regularização ($C \in \mathbb{R}$) na diagonal principal de $\mathbf{H}^\top \mathbf{H}$ transformando a equação (2.49) em (2.50).

$$(\mathbf{H})^\dagger = \left(\frac{\mathbf{I}}{C} + \mathbf{H}^\top \mathbf{H} \right)^{-1} \mathbf{H}^\top \quad (2.50)$$

Em que:

\mathbf{I} é uma matriz identidade de tamanho M ;

C é o fator, ou coeficiente, de regularização (CR), determinado de acordo com a Equação (2.51), com $\lambda \in \mathbb{Z}$.

$$C = 2^\lambda \quad (2.51)$$

Após determinados os pesos sinápticos, a resposta da rede neural (\mathbf{Y}) para a entrada desejada (\mathbf{X}) pode, então, ser calculada pela Equação (2.44).

⁶ A técnica de Moore-Penrose implica que a inversa de uma dada matriz $\mathbf{A} \in \mathbb{R}^{M \times N}$ será a matriz $\mathbf{A}^+ \in \mathbb{R}^{N \times M}$.

2.5.1.3 Rede neural artificial híbrida RBF-ELM

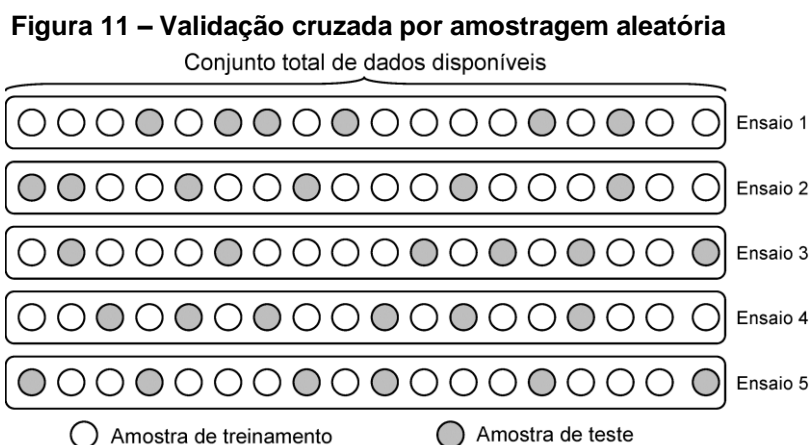
Wen et al. (2017) e Wen, Xie e Pei (2016) propuseram uma RNA híbrida entre a rede neural artificial de função de base radial com estrutura adaptativa (SARBF, do inglês: *Structure-Adaptive Radial Basis Function*) e a RNA máquina de aprendizagem extrema (ELM), unindo ambas em cascata.

Na RNA SARBF os centros das funções gaussianas são ajustados de modo a se otimizar a cobertura de cada classe de amostras; ou seja, cada neurônio é criado e centrado de modo a cobrir geometricamente o máximo possível das amostras de uma classe, enquanto, cobre o mínimo possível as amostras de outras classes.

2.5.2 Método de Validação Cruzada

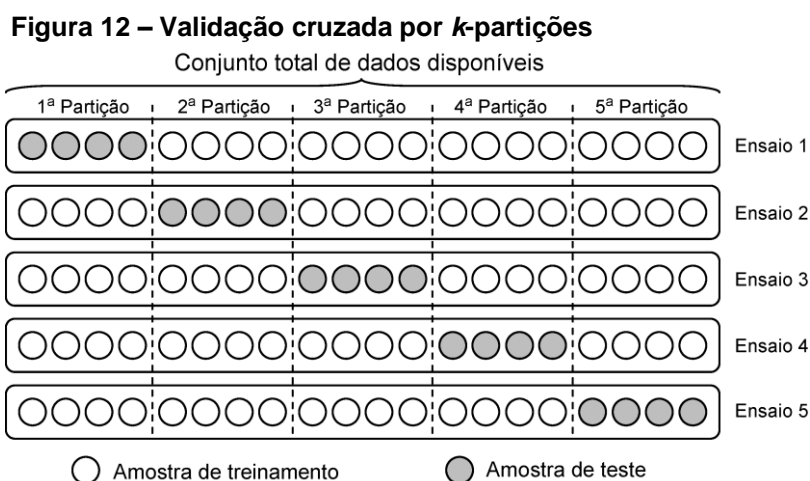
Para comparar os vários algoritmos de inteligência computacional, necessita-se um método para avaliá-los. Para tal, uma das técnicas estatísticas mais utilizadas é o método de validação cruzada (*cross-validation*) (SILVA; SPATTI; FLAUZINO, 2010). O método de validação cruzada tem por objetivo avaliar a aptidão de cada algoritmo quando aplicado a um conjunto de dados diferente do utilizado durante o seu treinamento (KROGH; VEDELSBY, 1995; ROSS et al., 2009).

Dentre os métodos de validação cruzada, o mais simples é o método de validação cruzada por amostragem aleatória (*random subsampling cross-validation*, Figura 11), na qual o conjunto de dados é subdividido aleatoriamente entre amostras para treinamento e teste (SILVA; SPATTI; FLAUZINO, 2010).



Fonte: Silva, Spatti e Flauzino (2010)

Outra forma de validação cruzada utilizada é o método de k -partições (k -fold cross-validation, Figura 12), no qual realizam-se k -subdivisões do conjunto total de amostras, de modo que cada uma destas partições apresentem aproximadamente o mesmo número de amostras. São então realizados k treinamentos e testes de modo que todos os subconjuntos sejam usados pelo menos uma vez para teste e para treinamento (KOHAVI, 2001).



Fonte: Silva, Spatti e Flauzino (2010)

Uma outra técnica utilizada dentro do método de validação cruzada é a técnica da parada antecipada (*early stopping*), na qual uma parte do conjunto de treinamento é separado do restante (conjunto de validação). Este terceiro conjunto é, então, utilizado de tempos em tempos (durante as iterações do treinamento), de modo a avaliar o resultado produzido pelo algoritmo de IC para que o mesmo não sofra de *overfitting* (sobre treinamento, no qual o resultado fica “viciado” ao conjunto de treinamento e o algoritmo de IC perde sua capacidade de generalização) (BISHOP, 1995; PRECHELT, 1998; TETKO; LIVINGSTONE; LUIK, 1995).

3 DESENVOLVIMENTO

Este capítulo discorre como as técnicas estudadas foram empregadas para o sistema desenvolvido, o qual deve operar de acordo com a Figura 13, selecionando o sinal de ECG de um paciente a ser analisado, filtrando-o e detectando os complexos QRS para a segmentação dos batimentos. Seguindo por uma etapa de extração de características do sinal e também, de redução da dimensionalidade do mesmo; por fim, são classificados os tipos de arritmias presentes no mesmo.

Figura 13 – Etapas de operação de um sistema de identificação de arritmias cardíacas



Fonte: Autoria própria

Todos os algoritmos descritos e utilizados foram criados e executados utilizando o software MatLab®.

3.1 BASE DE DADOS

Para o desenvolvimento do sistema, utilizou-se os sinais eletrocardiográficos presentes na base de dados de arritmias cardíacas MIT-BIH. Esta base de dados foi o primeiro material contendo um conjunto de dados para testes de detectores de arritmias a tornar-se disponível e tem sido utilizado desde 1980 para este propósito, assim como, para outras pesquisas no ramo da cardiologia.

Os registros começaram a ser obtidos em 1975 pelo Laboratório de Arritmias do Hospital Beth Israel de Boston (BIH, do inglês: *Beth Israel Hospital*) em parceria com o Instituto de Tecnologia de Massachusetts (MIT, do inglês: *Massachusetts Institute of Technology* – MIT). A base de dados apresenta 48 registros de aproximadamente meia hora cada, obtidos de 47 pacientes (25 homens e 22 mulheres) com idade entre 23 e 89 anos, a partir de gravações de *Holter* (MOODY; MARK, 1992, 2001).

Os registros, na época, foram obtidos através de equipamentos que possuíam um gravador de fita de dois canais e foram digitalizados através de uma unidade de reprodução ligada a um computador com um conversor analógico digital de 11 *bits* com resolução de $\pm 5\text{mV}$. A digitalização foi feita a uma taxa de 360 amostras por

segundo por canal. Como a digitalização em duas vezes a velocidade de gravação era rápido demais (devido às limitações técnicas do computador utilizado) 30 dos registros foram digitalizados na mesma velocidade de gravação. Posteriormente, com a melhora do *hardware* do computador, os outros registros foram digitalizados em duas vezes a velocidade de gravação (MOODY; MARK, 1992, 2001).

Após a digitalização, todos os registros foram impressos e entregues a dois cardiologistas para avaliação. Após avaliarem os registros separadamente, juntaram-se para entrar em consenso sobre as divergências, sendo que alguns dos batimentos permaneceram sem classificação devido à falta de concordância sobre os mesmos. Na maioria dos registros, o primeiro canal foi utilizado para a gravação da derivação *D2* modificada (com eletrodos posicionados no tronco do paciente); o outro canal contém, em geral, a derivação *V1*, sendo as vezes a derivação *V2*, *V4* ou *V5*, dependendo da enfermidade do paciente (MOODY; MARK, 1992, 2001).

Dos registros existentes no banco de dados, escolheu-se os que apresentavam a *D2* modificada no canal 1 e a derivação *V1* no canal 2 para a utilização neste trabalho, pois são as duas derivações mais encontradas no banco de dados (com 46 e 39 registros, respectivamente). Garantindo, também, que todos os eletrodos colocados nos pacientes apresentavam a mesma configuração. Embora tenha-se escolhido os registros que possuíam a derivação *D2* modificada e a derivação *V1*, foi utilizado apenas a derivação *D2* destes registros para a classificação de arritmias.

Desta forma, dos 48 registros existentes no banco de dados, serão utilizados apenas 39. De todos foram desconsiderados os primeiros 5 minutos (108.000 amostras), pois este é o período em que o equipamento estava sendo testado e colocado no paciente, o que resulta em possíveis ruídos pela movimentação dos eletrodos (MOODY; MARK, 2001).

3.2 FILTRAGEM DE SINAIS ELETROCARDIOGRÁFICOS

Como ferramenta primária para diagnóstico de doenças cardíacas, os sinais captados durante exames de ECG precisam conter a menor quantidade possível de ruído, pois a amplitude e duração das principais ondas são avaliadas por um médico especialista ou um sistema de auxílio a diagnóstico e ruídos podem interferir

diretamente na característica do sinal (JAGTAP; UPLANE, 2013; JINGWEI; WENWEN, 2015; SUN; CHAN; KRISHNAN, 2002).

Os ruídos encontrados num sinal eletrocardiográfico podem ser classificados pela sua origem como (MOODY; MULDROW; MARK, 1984):

1. **Desvios de Linha de Base:** é um sinal de baixa frequência geralmente causado pela movimentação do paciente ou das derivações;
2. **Ruído da Movimentação dos Eletrodos:** é geralmente o mais difícil de lidar, uma vez que pode imitar os elementos do sinal de ECG. Geralmente é o resultado de forças mecânicas intermitentes que atuam nos eletrodos;
3. **Ruído Muscular:** tem um espectro que sobrepõem o do ECG, mas que se estende para altas frequências;
4. **Interferência de Linha de Alimentação:** ocorre nos múltiplos das frequências principais da rede elétrica (50 ou 60 Hz).

Filtros analógicos têm sido utilizado para condicionamento de sinais de ECG e são essenciais para a correta digitalização do sinal, limitando a frequência máxima do sinal e evitando o *aliasing* (alteração na frequência do sinal devido a inobservância do teorema de Shannon-Nyquist). Porém, os filtros digitais, implementados como programas em microprocessadores, surgiram como uma alternativa na remoção de ruídos específicos muitas vezes realizando tarefas que seriam difíceis ou impossíveis usando apenas filtros analógicos (AHLSTROM; TOMPKINS, 1985).

Sendo assim, o processamento de sinais de ECG de forma digital é uma técnica bem estabelecida que tem como objetivo melhorar a taxa sinal-ruído de um sinal de ECG para medições mais precisas (PAHLM; SORNMO, 1987).

Tipicamente, o eletrocardiógrafo capta a forma de onda analógica do ECG, o amplifica, realiza filtragem anti-*aliasing* e digitaliza, através de um conversor analógico digital (ADC, do inglês: *Analog to Digital Converter*). Os valores binários gerados são, então, transmitidos para um processador de sinal digital (DSP, do inglês: *Digital Signal Processor*) que realiza uma filtragem em tempo discreto usando um algoritmo (BAILEY et al., 1990; JAGTAP; UPLANE, 2013).

As técnicas convencionais empregadas para suprimir os ruídos de forma digital são em geral baseadas em filtros passa-faixa. Entretanto, este tipo de técnica de filtragem linear tem uma frequência de corte fixa que distorce significativamente o complexo QRS, assim como o segmento ST. Não é adaptativo e, portanto, não consegue rastrear as mudanças de características de um sinal de ECG variante no

tempo, que tendem a se alterar periodicamente, com período correspondente a um batimento cardíaco (SUN; CHAN; KRISHNAN, 2002).

Técnicas de filtragem adaptativa vem sendo desenvolvidas com o objetivo de remoção de ruído de sinais de ECG. Dentre as filtragens adaptativas existem os filtros morfológicos, o filtro de média aparada por alfa, (*alpha-trimmed mean filter*), filtro adaptativo dos mínimos quadrados (*least mean square adaptive filter*), etc (KALRA, 2017; KOISHYBAEV et al., 2017; PALODETO, 2006; TAYEL; ELTRASS; AMMAR, 2017; VINOTH; KUMARGANESH, 2016).

Além de técnicas adaptativas, tem-se utilizado frequentemente a Transformada *Wavelet*, por juntar uma análise tempo-frequência, decompondo o sinal em diferentes escalas, obtendo-se coeficientes em cada escala. Através da escolha adequada da escala e desconsiderando-se os coeficientes abaixo dos limiares predefinidos, pode-se separar os ruídos dos componentes de sinal de ECG (ADDISON, 2005).

Duas técnicas de filtragem de sinais de ECG são empregadas neste trabalho, uma utilizando uma filtragem adaptativa com base em Filtro Morfológico e outra utilizando Transformada *Wavelet*.

3.2.1 Filtro Morfológico

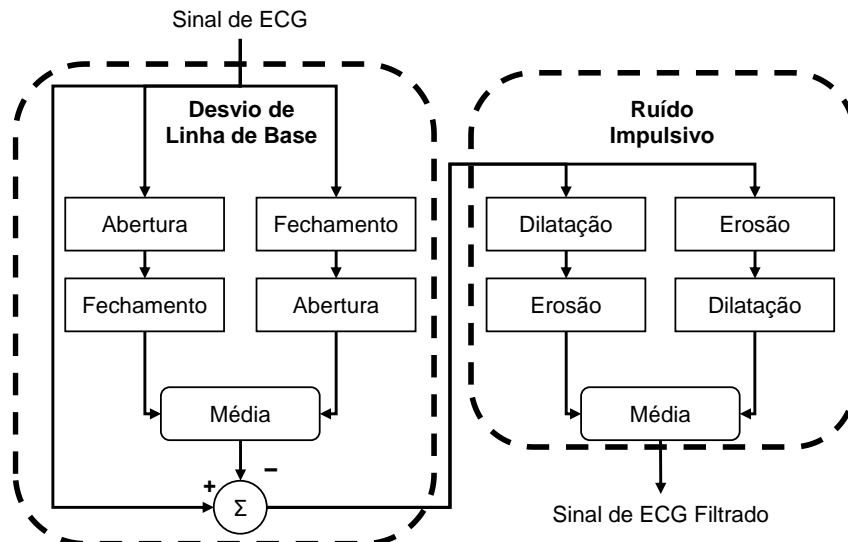
Para a filtragem de sinais de ECG em tempo real, Sun; Chan e Krishnan (2002) propuseram um filtro digital que utiliza operadores morfológicos para a remoção dos principais ruídos e artefatos que afetam o sinal. O algoritmo de filtragem consiste em duas etapas: remoção do desvio de linha de base, e remoção do ruído impulsivo. Cada etapa é demonstrada na Figura 14, na qual primeiramente o desvio de linha de base é calculado e removido do sinal, seguindo para a etapa de remoção de ruído impulsivo.

Durante a primeira etapa, primeiramente, determina-se o desvio de linha de base (f_B , Equação (3.1)), observado na Figura 15(b), através da média de operações de abertura (\circ) e fechamento (\bullet) aplicadas sobre o sinal original (f_O , Figura 15(a)).

$$f_B = \frac{(f_O \circ k_A \bullet k_F + f_O \bullet k_F \circ k_A)}{2} \quad (3.1)$$

onde o elemento estruturante de abertura (k_A) possui o tamanho igual a 72(um quinto da frequência de amostragem), e o elemento estruturante de fechamento (k_F) possui o tamanho igual 108(três décimos da frequência de amostragem); ambos apresentam valores iguais a zero (SUN; CHAN; KRISHNAN, 2002).

Figura 14 – Funcionamento do filtro morfológico de Sun, Chan e Krishnan (2002)



Fonte: Autoria própria, baseado em Sun, Chan e Krishnan (2002)

Após encontrado o sinal da linha de base, este é subtraído do sinal original para a obtenção do sinal sem flutuação de linha de base (f_N , Equação (3.2), Figura 15(c)).

$$f_N = f_O - f_B \quad (3.2)$$

Para a remoção do ruído impulsivo realiza-se a média de operações de dilatação (\oplus) e erosão (\odot) (SUN; CHAN; KRISHNAN, 2002), conforme a Equação (3.3).

$$s = \frac{(f_N \oplus k_1 \odot k_2 + f_N \odot k_1 \oplus k_2)}{2} \quad (3.3)$$


Em que:

s é o sinal filtrado (Figura 15(d));

$k_1 = [0, 1, 5, 1, 0]$ e $k_2 = [0, 0, 0, 0, 0]$ são os elementos estruturantes.

A Figura 15 apresenta um exemplo das etapas e dos sinais obtidos com um Filtro Morfológico. Primeiramente é calculado a flutuação de linha de base (Figura 15(b)) do sinal original (Figura 15(a)), então a mesma é subtraída obtendo o sinal sem a flutuação de linha de base (Figura 15(c)). Por último são removidos os ruídos impulsivos obtendo o sinal filtrado (Figura 15(d)).

Figura 15 – Exemplo da filtragem utilizando Filtro Morfológico. (a) Sinal Original; (b) Flutuação de Linha de Base; (c) Sinal sem Linha de Base; (d) Sinal Filtrado



Fonte: Autoria própria

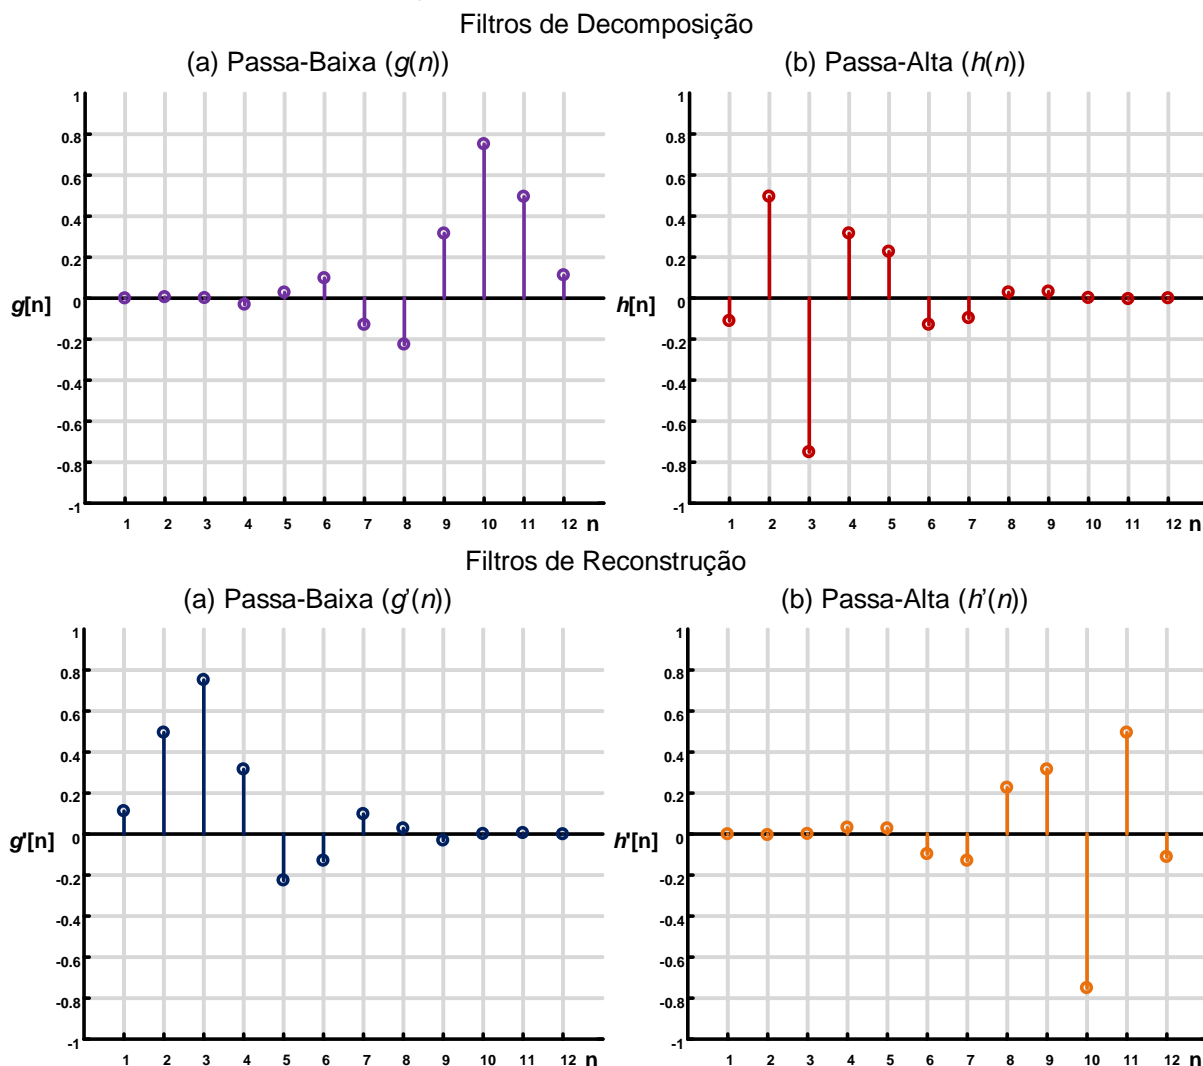
3.2.2 Transformada *Wavelet*

A técnica de filtragem com Transformada *Wavelet* utilizada neste trabalho aplica a Transformada *Wavelet* Discreta através da análise multiresolução, como o empregado por Dokur e Ölmez (2001), Martis, Acharya, Min (2013), Martis et al. (2013) e Elhaj et al. (2016).

A filtragem consiste em decompor o sinal em 9 níveis de aproximações e detalhes, sempre decompondo pelo lado da aproximação como mostra a Figura 17, com os filtros obtidos da *Wavelet* mãe Daubechie 6. A Figura 16 mostra os coeficientes

do filtros utilizados, tanto para a decomposição, com os filtros passa-baixa ($g(n)$, Figura 16(a)) e passa-alta ($h(n)$, Figura 16(b)), quanto para a reconstrução do sinal, também, com os filtros passa-baixa ($g'(n)$, Figura 16(c)) e passa-alta ($h'(n)$, Figura 16(d)).

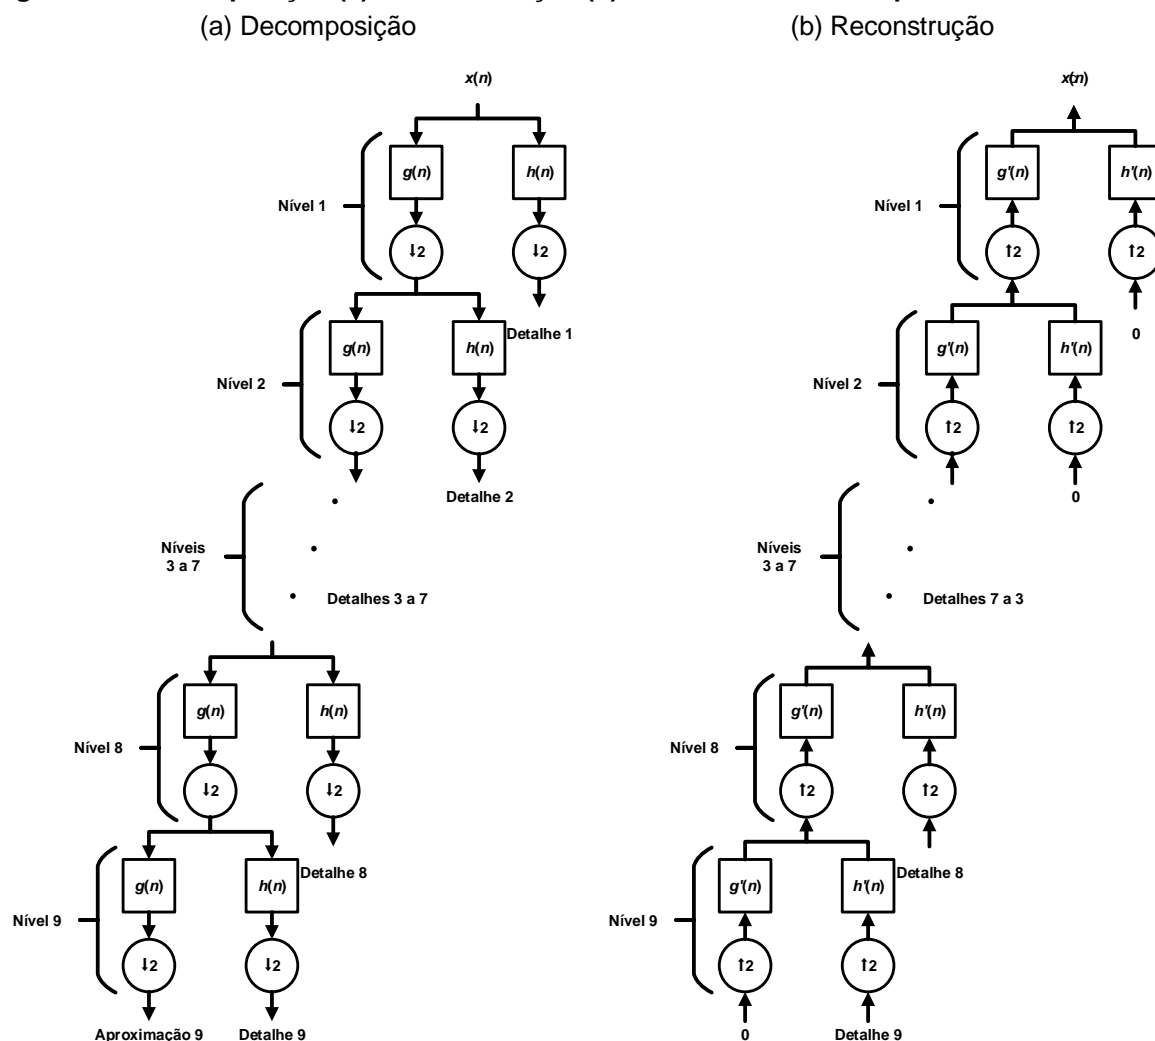
Figura 16 – Filtros obtido da Wavelet mãe Daubechie D6, para Decomposição: (a) Passa-Baixa; (b) Passa-Alta; e para Reconstrução (c) Passa-Baixa; (d) Passa-Alta



Fonte: Autoria própria

A Figura 17(a) apresenta a decomposição em vários níveis pelo lado da aproximação. Cada nível de decomposição realiza uma filtragem no sinal com um filtro passa baixa ($g(n)$) e um filtro passa alta ($h(n)$) e posteriormente o sinal é subamostrado ($\downarrow 2$).

Figura 17 – Decomposição (a) e Reconstrução (b) *Wavelet* de 9 níveis aplicada neste trabalho



Ao término de cada subamostragem obtém-se uma aproximação (pelo lado do filtro passa-baixa) e um detalhe (pelo lado do filtro passa-alta), por isto é dito: uma decomposição pelo lado da aproximação. As componentes de frequência abrangidas por cada nível de decomposição, tanto pelas aproximações, quanto pelos detalhes obtidos, podem ser observadas na Tabela 3.

Após realizada a decomposição, a reconstrução do sinal dá-se como mostrado na Figura 17(b), na qual é desconsiderado a nona aproximação e os detalhes um e dois, inserindo-se um vetor de amplitude zero. Isso faz com que apenas as componentes entre as frequências 0,351 e 45 Hz sejam mantidas. Para a reconstrução dos sinais, aumenta-se a resolução do sinal ($\uparrow 2$) com a inserção de zeros entre os valores existentes e então, utilizam-se os filtros de reconstrução passa-baixa ($g'(n)$) e passa-alta ($h'(n)$).


Tabela 3 – Frequência de corte de 9 níveis de decomposição *wavelet* pelo lado da aproximação para uma frequência de amostragem de 360 amostras/s

Nível de Decomposição	Frequência Abrangidas pela Aproximação (Hz)	Frequência Abrangidas pelo Detalhe (Hz)
1	0,00 – 90,00	90,00 – 180,00
2	0,00 – 45,00	45,00 – 90,00
3	0,00 – 22,50	22,50 – 45,00
4	0,00 – 11,25	11,25 – 22,50
5	0,00 – ~5,63	~5,63 – 11,25
6	0,00 – ~2,81	~2,81 – ~5,63
7	0,00 – ~1,41	~1,41 – ~2,81
8	0,00 – ~0,73	~0,73 – ~1,41
9	0,00 – ~0,35	~0,35 – ~0,73

Fonte: Autoria própria

A Figura 18 apresenta um exemplo da filtragem por Transformada *Wavelet*. É possível observar o sinal original (Figura 18(a)), o desvio de linha de base (Figura 18(b)), encontrado na aproximação de nível 9 e o sinal filtrado (A Figura 18(c)).

Figura 18 – Exemplo da filtragem utilizando Transformada *Wavelet*. (a) Sinal Original; (b) Flutuação de Linha de Base; (c) Sinal Filtrado



Fonte: Autoria própria

3.3 SEGMENTAÇÃO DOS BATIMENTOS

As principais ondas de um sinal de eletrocardiograma são as ondas Q, R e S, que, de modo geral, são tratadas como algo único chamado de complexo QRS (JUNIOR; VALENTIM; BRANDAO, 2016). Estas ondas são importantes, pois costumam se destacar das demais ondas (ainda mais na derivação 2), já que elas ocorrem devido a despolarização ventricular e os ventrículos possuem um tamanho maior que os átrios; deste modo, geram uma maior diferença de potencial e, conseqüentemente, ondas de maior amplitude. Devido a este fato, torna-se mais fácil, do ponto de vista computacional, encontrar um batimento ao longo do sinal de ECG pelo complexo QRS (THAKOR; WEBSTER; TOMPKINS, 1983).


Como o sistema desenvolvido consiste em avaliar a morfologia do sinal com algoritmos computacionais para o auxílio à diagnósticos, torna-se imprescindível um bom detector de complexos QRS, pois a correta detecção do batimento implica, não só, na correta classificação da arritmia, como também evita processamentos desnecessários e, conseqüentemente, preocupações por parte do paciente e do médico que realizará o diagnóstico final (BARHATTE; GHONGADE; THAKARE, 2015; JUNIOR; VALENTIM; BRANDAO, 2016).

Para a detecção do complexo QRS, foi escolhido o algoritmo de Pan e Tompkins (1985). Embora existam outros que apresentem resultados levemente melhores, este é o mais utilizado na literatura, sendo assim, o algoritmo mais aceito pela comunidade.

3.3.1 Algoritmo de Pan e Tompkins (1985)

Visando a criação de um algoritmo para detecção do complexo QRS em tempo real, Pan e Tompkins (1985) criaram um que se utiliza de um filtro linear digital do tipo passa-faixa, de transformações não lineares e de um algoritmo de decisão que utiliza limiares adaptativos. Pan e Tompkins desenvolveram-no considerando que o sinal de ECG seria amostrado a uma frequência de 200 Hz.

O algoritmo (descrito na Figura 19) primeiramente filtra o sinal de ECG entre as frequências de 5 e 15 Hz, de modo a se maximizar a energia do complexo QRS. Para isto foi projetado um filtro passa-baixa em cascata com um filtro passa-alta.

Figura 19 – Algoritmo de Pan e Tompkins (1985)

Fonte: Adaptado de Pan e Tompkins (1985)

Devido a frequência de amostragem escolhida por Pan e Tompkins, não seria possível criar um filtro passa-baixa com a frequência de corte desejada. Sendo assim, em seu trabalho, foi projetado um filtro passa-baixa com a frequência de corte de aproximadamente 11Hz (Equação (3.4)).

$$H(z) = \frac{(1 - z^{-6})^2}{(1 - z^{-1})^2} \quad (3.4)$$

O filtro passa-alta projetado encontra-se demonstrado na Equação (3.5) e possui frequência de corte de aproximadamente 5Hz.

$$H(z) = \frac{(-1 + 32z^{-16} + z^{-32})}{(1 + z^{-1})} \quad (3.5)$$

Em seguida, utiliza-se um filtro derivativo (com função de transferência descrita na Equação (3.6)) para a obtenção do declive ocasionado pelo complexo QRS (PAN; TOMPKINS, 1985).

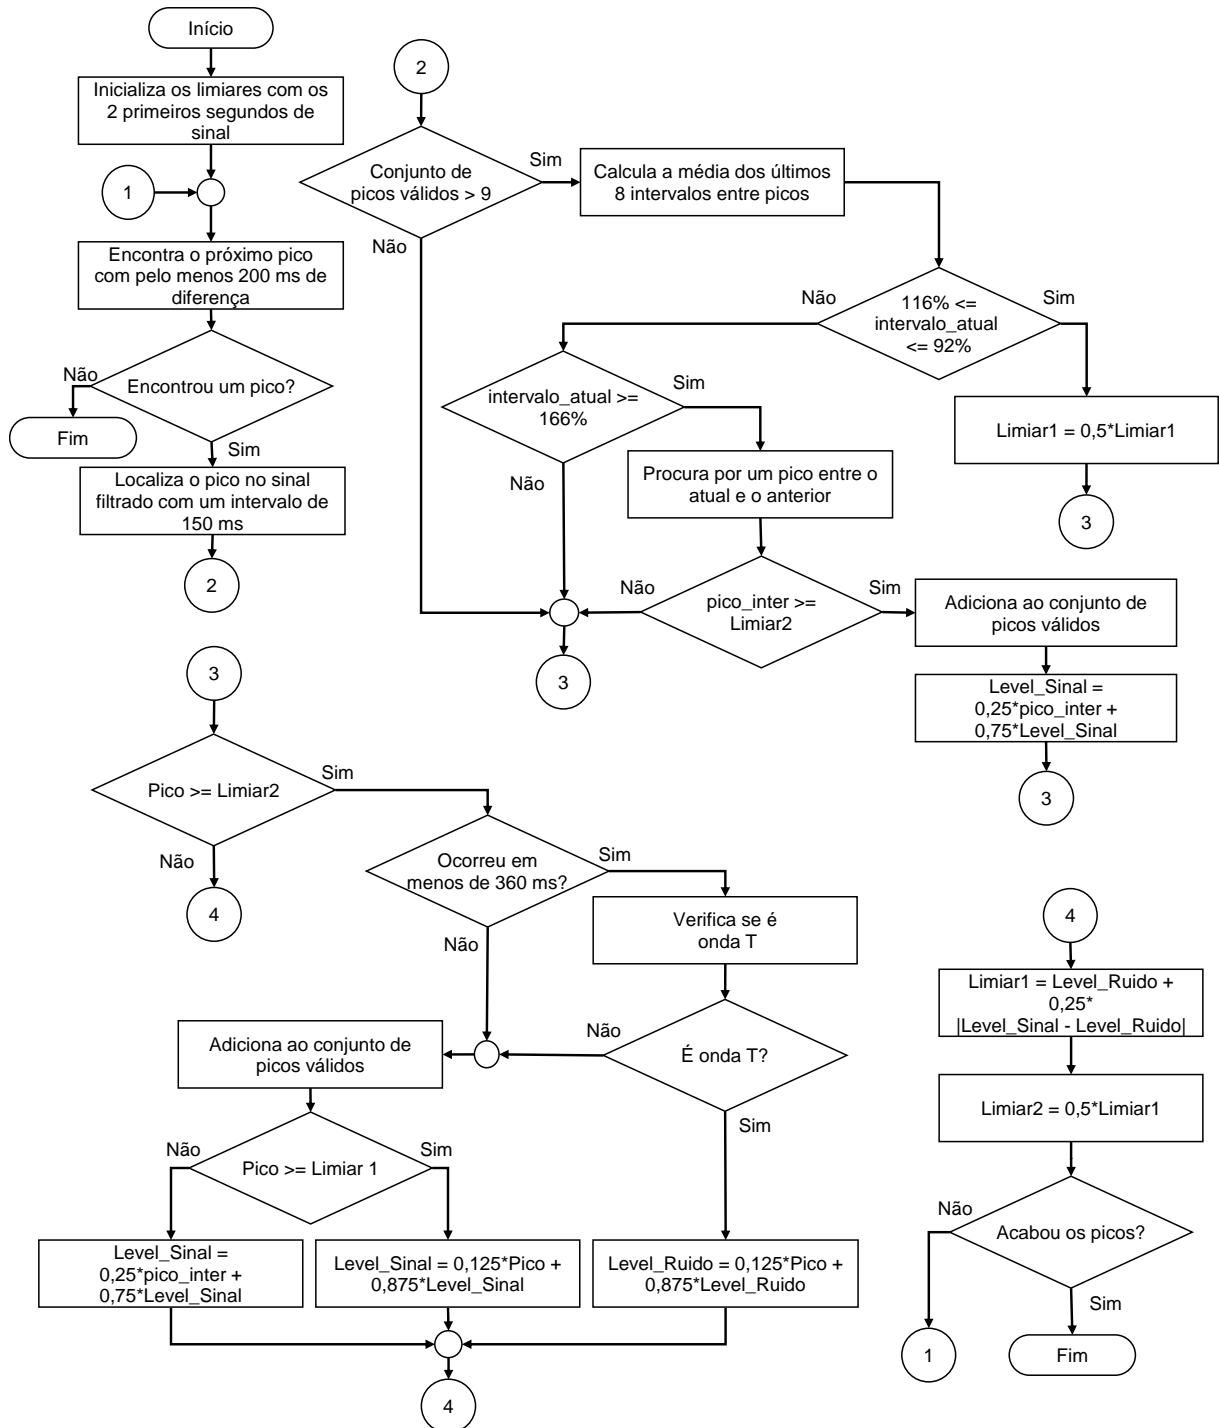
$$H(z) = \left(\frac{1}{8T}\right)(-z^{-2} - 2z^{-1} + 2z^1 + z^2) \quad (3.6)$$

Após a passagem pelo filtro derivativo, cada elemento do sinal é elevado ao quadrado, tornando todos os pontos positivos e enfatizando as altas amplitudes, para então ser aplicado um filtro integrador do tipo média móvel. Como a duração de um complexo QRS para ser considerada normal tem no máximo 120 ms (PASTORE et al., 2016; PASTORE; SAMESIMA; MUNERATO, 2012), uma janela de 150 ms foi utilizada para o filtro integrador (PAN; TOMPKINS, 1985).

Por fim, os principais picos são destacados (considerando que um intervalo entre dois picos R, fisiologicamente, não deve ser menor que 200 ms (PASTORE et al., 2016; PASTORE; SAMESIMA; MUNERATO, 2012)) e avaliados de acordo com dois limiares adaptativos. Ambos os limiares são utilizados para encontrar cada batimento, e portanto reduzir falsos negativos, sendo um sempre a metade do outro.

O funcionamento do algoritmo dos limiares adaptativos pode ser visto de forma detalhada na Figura 20, (PAN; TOMPKINS, 1985).

Figura 20 – Técnica dos limiares adaptativos de Pan e Tompkins (1985)



Fonte: Adaptado de Pan e Tompkins (1985)

Os limiares adaptam-se às características do sinal, considerando o nível do sinal e o nível do ruído. Por exemplo, se um complexo QRS não for encontrado em um intervalo de tempo correspondente a 166% do intervalo atual entre picos R, o maior pico detectado no intervalo de tempo anterior, que estiver entre os dois limiares, é

considerado como sendo um possível complexo QRS, e então é aplicada a redução dos limiares. Os limiares são ajustados a cada pico encontrado, sendo este ou não um complexo QRS (PAN; TOMPKINS, 1985).

Além disso, o algoritmo considera outros fatores, como quando uma nova detecção ocorre após 200 ms, porém antes de 360 ms. Escolhe-se o pico com a queda mais abrupta para ser considerado um pico R, pois o outro pode se tratar de uma onda T com amplitude elevada (PAN; TOMPKINS, 1985).

Um dos problemas da técnica de dois limiares utilizada no algoritmo de Pan e Tompkins (1985), é que ela só é útil para um batimento cardíaco regular, ou seja, em casos de anormalidades como batimentos bigeminados ou trigeminados, não é possível achar o batimento faltante olhando o intervalo de tempo anterior (PAN; TOMPKINS, 1985).

3.3.2 Implementação do Algoritmo de Segmentação

Para o algoritmo de detecção do complexo QRS de Pan e Tompkins (1985), como o filtro para a maximização da energia do complexo QRS (passa-faixa entre 5 e 15 Hz) proposto e utilizado em seu trabalho trata-se de um filtro para uma frequência de amostragem de 200 Hz, escolheu-se por utilizar um filtro *Butterworth* de ordem 3, como o proposto por Sedghamiz (2014), mantendo apenas as componentes entre 5 e 15 Hz, como era a ideia inicial de Pan e Tompkins (1985).

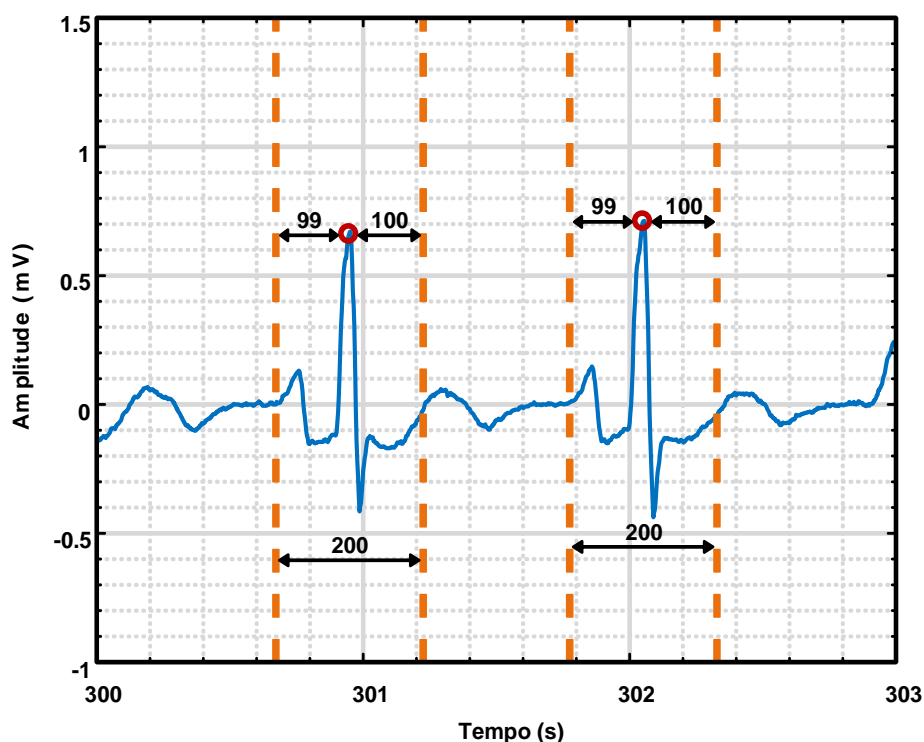
Para ser considerado um batimento correto, delimitou-se uma janela de 5 amostras para o ponto marcado na base de dados MIT-BIH como complexo QRS, pois verificou-se que nem sempre o complexo QRS marcado na base de dados estava exatamente no pico R, algo que foi destacado por Moody e Mark (2001) como um problema durante a digitalização.

Para a segmentação dos batimentos, foi levado em conta que o período entre o começo da onda P e o começo do complexo QRS é considerado normal se a duração for entre 120 ms e 200 ms (GOLDBERGER; GOLDBERGER; SHVILKIN, 2013; PASTORE; SAMESIMA; MUNERATO, 2012). O complexo QRS é considerado normal quando a duração for inferior a 120 ms e o período entre o início da onda Q e final da onda T é considerado normal até 450 ms para homens e 470 para mulheres (PASTORE et al., 2016).

Deste modo, pode-se dizer que 260 ms antes do pico R são interessantes de estar contido no batimento segmentado, o que a uma taxa de amostragem de 360 Hz equivale a aproximadamente 94 amostras; sendo assim, foram selecionadas 99 amostras antes do pico R de cada batimento.

Como nenhuma das arritmias presentes nos sinais selecionados da base de dados afeta de forma direta a onda T, é dispensável a presença completa desta onda, sendo mais interessante o segmento ST (medido do final do complexo QRS até o início da onda T (PASTORE et al., 2016; PASTORE; SAMESIMA; MUNERATO, 2012)). Desta forma, foram selecionados 100 amostras após o pico R de cada batimento. Ou seja, cada batimento consistiu em 99 amostras selecionadas antes do pico R e 100 amostras selecionadas após, totalizando 200 amostras para a representação de um batimento cardíaco, como mostra o exemplo na Figura 21.

Figura 21 – Exemplo da segmentação dos batimentos cardíacos em trecho do 108 da base de dados MIT-BIH



Fonte: Autoria própria

3.4 EXTRAÇÃO DE CARACTERÍSTICAS

Após a filtragem e segmentação dos batimentos, tanto para os sinais filtrados com Filtro Morfológico, quanto para os sinais filtrados com Transformada *Wavelet*, fez-se a extração das características através da análise de componentes principais. A análise de componentes principais para sinais de eletrocardiograma é possível de duas formas: intrabatimentos e entrebatimentos (CASTELLS et al., 2007).

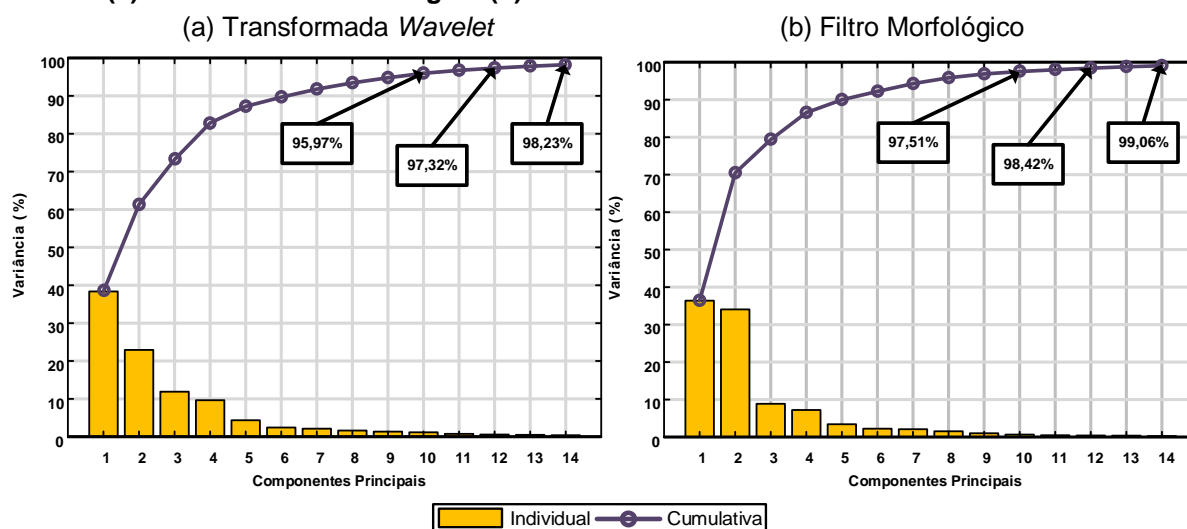
A análise entrebatimentos tem por escopo produzir um sinal de batimento de modo que este represente o conjunto de batimentos contidos na matriz de dados \mathbf{X} . Para isto a matriz de dados deve ser na forma $\mathbb{R}^{L \times N}$, sendo L o número de batimentos e N as amostras. Esta forma de análise pode ser aplicada em sistemas de identificação de pessoas, como o proposto por Favoretto (2016), em que é desejável obter um único batimento que represente as principais características dos batimentos de uma pessoa.

Já na análise intrabatimentos, utiliza-se a matriz de dados na forma $\mathbb{R}^{N \times L}$, sendo L o número de batimentos e N as amostras. Isto de modo que, sejam observados quais os pontos de máxima variância entre os batimentos e, então, as características sejam agrupadas em cada batimento. Produz-se para cada batimento um sinal equivalente no qual as componentes estão agrupadas de forma a maximizar a variância.

Para este trabalho utiliza-se a análise intrabatimentos, pois é desejado analisar cada batimento de cada paciente separadamente e ao mesmo tempo conseguir reduzir a quantidade de amostras utilizadas no sistema. Para isso, foi conjuntamente realizada uma análise de variância sobre os componentes principais, observando que para ser alcançado pelo menos 98% da variância do sinal necessitava-se de 12 componentes para os sinais filtrados com o Filtro Morfológico (Gráfico 6(a)) e de 14 componentes para os sinais filtrados com a Transformada *Wavelet* (Gráfico 6(b)).

Visando observar o efeito da quantidade de entradas nas RNAs testadas, variou-se a quantidade de componentes principais utilizadas entre 10, 12 e 14.

Gráfico 6 – Análise da variância dos componentes principais após filtragem com a Transformada Wavelet (a) e com o Filtro Morfológico (b)



Fonte: Autoria própria

3.5 RNA HÍBRIDA RBF-ELM

Ao contrário do proposto em Wen et al. (2017) e Wen, Xie e Pei (2016), a estrutura híbrida investigada neste trabalho não utilizará uma rede RBF com estrutura adaptativa, mas sim uma rede RBF tradicional, sem existir a preocupação com os centros das funções gaussianas cobrirem amostras de classes diferentes.

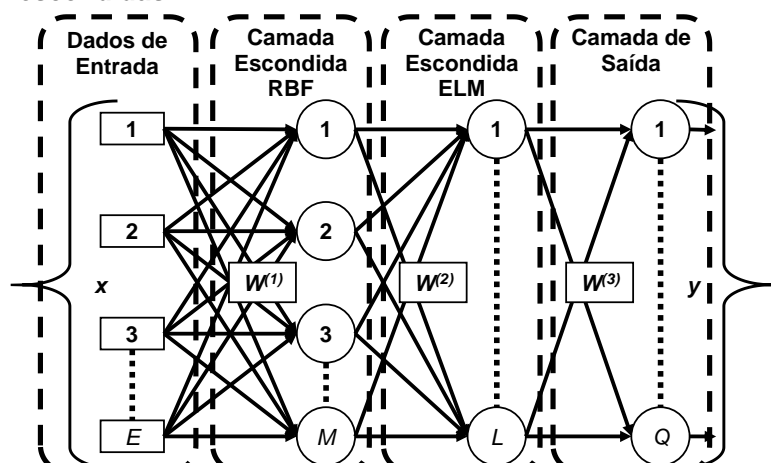
Deste modo, este trabalho utilizará duas estruturas híbridas entre a rede RBF e a RNA ELM.

A primeira rede híbrida consiste na rede RBF, porém com a etapa de treinamento da camada de saída sendo realizada do mesmo modo que a da RNA ELM, mantendo, assim, a mesma topologia de uma única camada escondida.

Desta forma, os pesos dos neurônios da camada escondida são calculados de modo não supervisionado (Seção 2.5.1.1); os pesos da camada de saída são calculados de modo linear, através da pseudo-inversa de Moore-Penrose.

Já a segunda rede híbrida, consiste na mesma rede RBF, porém com uma camada escondida a mais, sendo os pesos desta camada escondida determinados de modo aleatório, como na RNA ELM; por fim, uma camada de saída com os pesos calculados através da rede neural artificial ELM. Assim, a segunda estrutura híbrida apresenta 2 camadas escondidas (Figura 22).

Figura 22 – RNA Híbrida RBF-ELM com duas camadas escondidas



Fonte: Autoria própria, adaptado de Wen et al. (2017) e de Silva, Spatti e Flauzino (2010)

3.6 CLASSIFICAÇÃO DAS ARRITMIAS

Para a inserção dos dados na rede neural artificial, é uma prática comum normaliza-los para que sejam retiradas informações não relevantes ao sistema e evitar que haja a saturação dos neurônios. Sendo assim, foram normalizados os elementos da matriz de dados ($X \in \mathbb{R}^{E \times N}$, sendo E o número de componentes principais escolhidos e N a quantidade de batimentos) de forma estatística, utilizando o desvio padrão (σ^2) e a média (μ) da matriz de dados, conforme a Equação (3.7).

$$X = \frac{X - \mu}{\sigma^2} \quad (3.7)$$

Após normalizados, os batimentos foram separados em 5 tipos, conforme proposto por AAMI (1995) (descrita na Seção 2.1.5).

Foi utilizado o método de validação cruzada em $k = 5$ partições, separando igualmente cada novo tipo de batimento entre elas. Cada partição recebeu a mesma quantidade de amostras de cada tipo de batimento, levando-se em consideração também o registro do qual o batimento é pertencente. Deste modo, um determinado tipo de batimento de um registro só é utilizado se existir pelo menos uma amostra para cada partição.

Como batimentos normais existem em abundância na base de dados, todos os tipos foram limitados a um total máximo de 153 amostras por registro (de modo que nenhum tipo de batimento passe de seis mil amostras no conjunto total).

A composição de cada partição pode ser observada na Tabela 4 e na Tabela 5. Para o treinamento, validação e teste, foram combinadas cada partição duas a duas, de forma a se obter a média de 10 treinamentos e testes. Para o treinamento, foram utilizadas 2 partições enquanto as 3 restantes foram utilizadas para o teste.

O conjunto de validação foi escolhido de modo aleatório, selecionando-se 20% de cada tipo do conjunto de treinamento. A quantidade total, utilizada em cada execução, tanto para treinamento, teste e validação pode ser visualizada na Tabela 4 e Tabela 5.

Tabela 4 – Quantidade de batimentos utilizados nos algoritmos de inteligência computacional com Transformada *Wavelet*

Tipo de Batimento	Quantidade por Partição	Quantidade para Treinamento	Quantidade para Validação	Quantidade para Teste
Não Ectópico	3011	4817	1205	9033
Supraventricular Ectópico	428	684	172	1284
Ventricular Ectópico	647	1035	259	1941
De Fusão	112	179	45	336
Desconhecido	627	1003	251	1881
Total	4825	7718	1932	14475

Fonte: Autoria própria

Como cada método de filtragem produz pequenas diferenças nos sinais, houve variações quanto à quantidade de batimentos identificados com o algoritmo de detecção de complexo QRS. Por isso, há uma diferença na quantidade de Batimentos não Ectópicos, Ectópicos Supraventricular e Desconhecidos na Tabela 4 e Tabela 5.

Tabela 5 – Quantidade de batimentos utilizados nos algoritmos de inteligência computacional com Filtro Morfológico

Tipo de Batimento	Quantidade por Partição	Quantidade para Treinamento	Quantidade para Validação	Quantidade para Teste
Não Ectópico	3010	4816	1204	9030
Ectópico Supraventricular	428	684	172	1284
Ectópico Ventricular	680	1088	272	2040
De Fusão	112	179	45	336
Desconhecidos	629	1006	252	1887
Total	4859	7773	1945	14577

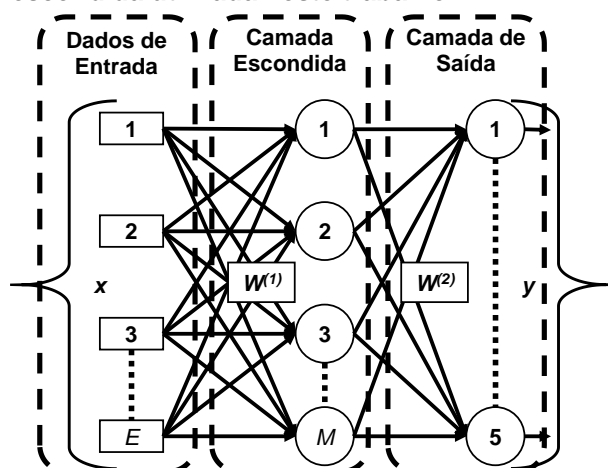
Fonte: Autoria própria

A primeira RNA utilizada foi uma Rede híbrida RBF-ELM com 1 camada escondida. Numa rede RBF comum, durante a segunda etapa de treinamento, os pesos e os limiares de ativação da camada de saída são atualizados pelo método do gradiente descendente. Contudo, nesta rede híbrida, visando a obtenção de uma rede com uma maior capacidade de generalização e com uma etapa de treinamento mais rápida, foram atualizados os pesos da camada de saída como no método de treinamento da máquina de aprendizado extremo (ELM), de forma analítica.

Para comparação, foram testadas outras duas redes com somente uma camada escondida e com o método de treinamento idêntico ao proposto por Huang et al. (2012) e Huang, Zhu e Siew (2004) no algoritmo ELM, determinando os pesos da camada escondida de modo aleatório e os pesos da camada de saída de forma analítica. Uma das RNAs utilizou a função de ativação logística com valor $\beta=1$ (Equação (2.32), sendo tratada como: ELM com Função Logística) enquanto a outra utilizou a função de ativação de base radial (gaussiana, Equação (2.33), sendo tratada como: ELM com Função Gaussiana).

As redes com uma camada escondida tem a estrutura da Figura 23, onde E o número de componentes principais escolhidos (variando entre 10, 12 e 14) e M é a quantidade de neurônios na camada escondida (variando entre 100 e 1500, com incrementos de 200).

Figura 23 – Formato da RNA com uma camada escondida utilizada neste trabalho

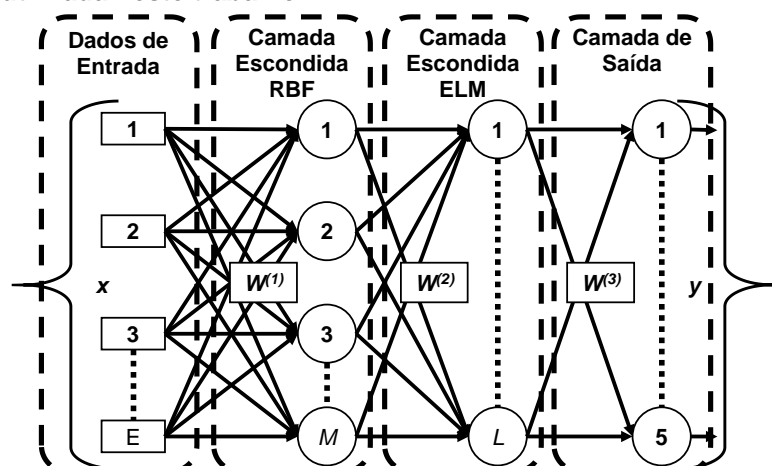


Fonte: Autoria própria, baseado em Silva, Spatti e Flauzino (2010)

Avaliou-se também, outra Rede Híbrida RBF-ELM com duas camadas escondidas (Figura 24), sendo os pesos da primeira camada ($W^{(1)}$) treinados de modo não supervisionado como na rede RBF, e, como na ELM, os pesos da segunda

camada escondida ($W^{(2)}$) são determinados aleatoriamente e os pesos da camada de saída ($W^{(3)}$) calculados de modo analítico. A quantidade de neurônios nas camadas escondidas (M e L) foi também variada (entre 100 e 1500, com incrementos de 200). O número de entrada (E) foi determinado com o número de componentes principais escolhidos (variando entre 10, 12 e 14).

Figura 24 – Formato da RNA com duas camadas escondidas utilizada neste trabalho



Fonte: Autoria própria, baseado em Silva, Spatti e Flauzino (2010)

Como todas as redes avaliadas apresentam parte do algoritmo ELM, também avaliou-se o efeito do coeficiente de regularização AS na resposta, com λ variando de -24 até 25, como proposto por Huang et al. (2012) (vide equação (2.51)), avaliando com o conjunto de validação, qual o melhor valor de C para a topologia. Cada rede e topologia foi igualmente avaliada sem o uso do coeficiente de regularização.

Por fim, o conjunto de teste foi apresentado para cada rede e cada topologia, avaliando através da média e do desvio padrão da taxa de acerto de cada uma das 10 execuções para cada topologia.

3.7 ANÁLISE ESTATÍSTICA DOS RESULTADOS

As análises dos resultados extraídos neste trabalho foram feitas levando-se como base os resultados obtidos com o teste de hipótese estatística Teste-T de Student. Isto se dá pelo fato de os dados serem amostrados através de um conjunto finito de testes, então, existe a hipótese de que os resultados obtidos são pertencentes ao mesmo conjunto de amostras. Ou seja, existe a hipótese de as RNAs testadas não produzirem resultados estatisticamente diferentes por serem muito semelhantes.

Desta forma um teste de hipóteses é um procedimento estatístico pelo qual uma hipótese é rejeitada ou não, através de um risco máximo de erro. Em geral as hipóteses estatísticas dividem-se em dois tipos, igualdade ou desigualdade (CALLEGARI-JACQUES, 2007):

1. **Hipótese nula (H_0):** define a ausência de diferença entre os parâmetros;
2. **Hipótese alternativa (H_1):** hipótese contrária a nula, há diferença entre os parâmetros.

Todo teste de hipóteses está sujeito a erro. O mais comum é chamado de erro do Tipo I, no qual a hipótese nula é erroneamente rejeitada, isto é, afirma-se que há uma diferença quando não existe. A probabilidade de isto ocorrer é igual a α , que é o risco máximo admitido. Em geral, o valor de α mais comumente adotado para os testes estatísticos é de 0,05, ou 5% (CALLEGARI-JACQUES, 2007).

Para comparação entre as médias de duas amostras independentes (com o objetivo de se verificar se as amostras são pertencentes ao mesmo conjunto) o teste mais comum é o chamado Teste-T de Student, que foi concebido em Student (1908). Este teste de hipótese consiste em 5 etapas simples:

1. Determina-se as hipóteses estatísticas:
 - $H_0: \mu_A = \mu_B$
 - $H_1: \mu_A \neq \mu_B$
2. Determina-se o nível de significância α .
3. Determina-se o grau de liberdade (gl), conforme a Equação (3.8).
4. Determina-se o valor crítico calculado (t_{calc}), determinado pela Equação (3.9).
5. Aplica-se a decisão. Para a hipótese nula ser aceita, a Equação (3.11) deve ser satisfeita.

$$gl = n_A + n_B - 2 \quad (3.8)$$

Em que:

n_A e n_B são os tamanhos das amostras A e B.

$$t_{calc} = \frac{(\bar{X}_A - \bar{X}_B)}{\sqrt{s_0^2 \left(\frac{1}{n_A} + \frac{1}{n_B} \right)}} \quad (3.9)$$

Em que:

\bar{X}_A é a média da amostra A;

\bar{x}_B é a média da amostra B e;

s_0^2 é a variância estimada da população calculada pela Equação (3.10).

$$s_0^2 = \frac{(n_A - 1)s_A^2 + (n_B - 1)s_B^2}{n_A + n_B - 2} \quad (3.10)$$

Em que:

s_A^2 é a variância da amostra A e;

s_B^2 é a variância da amostra B.

$$|t_{calc}| \leq t_{\alpha;gl} \quad (3.11)$$

Em que:

$t_{\alpha;gl}$ é o valor crítico da distribuição t de Student determinado de forma tabelada pelo grau de liberdade e pelo nível de significância especificado (Tabela 6).

A Tabela 6 apresenta alguns exemplos de valores críticos para os níveis de significância de 10%, 5%, 2% e 1%.

Tabela 6 – Exemplo valores críticos da distribuição t de Student para os níveis de significância de 10%, 5%, 2% e 1%

Grau de Liberdade (gl)	Nível de Significância (α)			
	0,10 (10%)	0,05 (5%)	0,02 (2%)	0,01 (1%)
1	6,314	12,706	31,821	63,657
5	2,015	2,571	3,365	4,032
10	1,812	2,228	2,764	3,169
15	1,753	2,131	2,603	2,947
20	1,725	2,086	2,528	2,845
25	1,708	2,060	2,485	2,787
30	1,697	2,042	2,457	2,750
40	1,684	2,021	2,423	2,704

Fonte: Adaptado de Callegaril-Jacques (2007)

4 RESULTADOS E DISCUSSÕES

Este capítulo apresenta e avalia os resultados obtidos durante o processo de validação cruzada, comparando não só os resultados obtidos entre as 4 RNAs, mas também, a influência do tipo de filtragem aplicada, da quantidade de componentes principais utilizadas e da quantidade de neurônios na camada escondida.

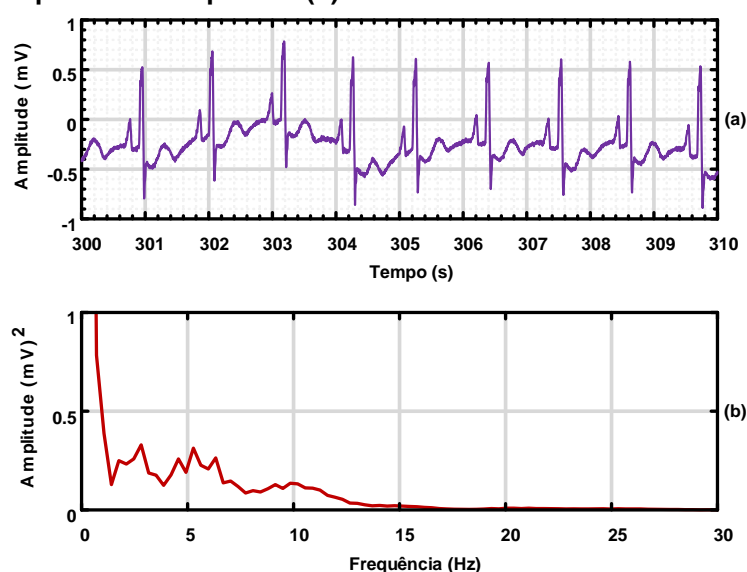
Para todos os Testes-T de Student realizados o nível de significância estabelecido foi de 5%, ou seja, foi utilizado um valor-p (*p-value*, α) de 0,05.

Os resultados da taxa de acerto médio e do desvio padrão referentes a Rede Híbrida RBF-ELM com 2 camadas escondidas encontram-se em valores numéricos nas Tabela 18 a Tabela 23 no Apêndice A.

4.1 AVALIAÇÃO DAS TÉCNICAS DE FILTRAGEM

O monitoramento cardíaco através de um eletrocardiograma exige componentes na faixa de frequência no intervalo 0,5 – 40 Hz, sem a interferência dos ruídos de baixa e alta frequência (CALIL; GOMIDE, 2002). A Figura 25(a) apresenta um sinal de ECG e a Figura 25(b) as componentes de frequência que estão presentes no mesmo.

Figura 25 – Exemplo de sinal de ECG (a) e seu respectivo espectro de frequência (b)

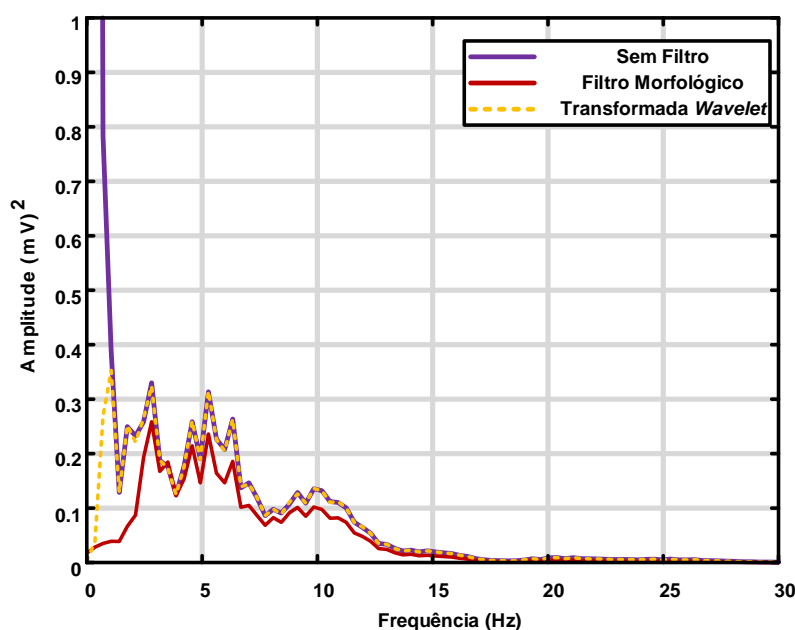


Fonte: Autoria própria

É possível observar na Figura 25(a) como o sinal é afetado pelas componentes de baixa frequência, através da flutuação de linha de base, o qual pode ser também observado na Figura 25(b), através do periodograma de *Welch*, com janela *Hamming* de tamanho 256, utilizando 8 segmentos com 50% de sobreposição entre os segmentos (GUPTA; BATAN; MEHRA, 2013).

Ao filtrar o sinal apresentado na Figura 25(a) tanto pelo Filtro Morfológico quanto pela Transformada *Wavelet*, obtêm-se os espectros de frequência mostrados na Figura 26. Nesta figura, é possível observar que ambas as técnicas de filtragem foram eficazes em remover as componentes de baixa frequência. Entretanto, a filtragem por Transformada *Wavelet* remove apenas as componentes de muita baixa frequência, mantendo praticamente a mesma magnitude no restante do sinal. Já a filtragem por Filtro Morfológico atenua todas as componentes até quase 7Hz, reduzindo também a magnitude do restante do sinal.

Figura 26 – Comparação entre as componentes de frequência de um sinal de ECG sem filtro, filtrado com Filtro Morfológico e com Transformada *Wavelet*



Fonte: Autoria própria

4.2 AVALIAÇÃO DO COEFICIENTE DE REGULARIZAÇÃO

A fim de avaliar o efeito do coeficiente de regularização (CR) nas redes neurais utilizadas neste trabalho, variou-se o mesmo de acordo com o proposto por Huang et al. (2012), com λ variando de -24 até 25 (vide equação (2.51)).

Após avaliado com o Teste-T de Student, observou-se que apenas em alguns casos das RNAs que foram treinadas apenas com o algoritmo ELM há uma diferença significativa entre os resultados com e sem o CR. Na Tabela 7, são apresentados os resultados significativamente diferentes sem e com CR para a rede ELM com Função Logística. Na Tabela 8, são comparados os resultados para a rede ELM com Função Gaussiana.

Todos os testes aplicados levaram-se em conta um valor $\alpha = 0,05$ e 18 graus de liberdade (GL), sendo comparado com o valor $t = 2,101$.

Tabela 7 – Resultados que apresentaram diferença significativa ($\alpha = 0,05$, GL = 18, $t = 2,101$) para a taxa de acerto médio para o algoritmo ELM com Função Logística

Tipo de Filtro	Quantidade de Componentes Principais Utilizada	Quantidade de Neurônios na Camada Escondida	Taxa de Acerto sem Coeficiente de Regularização (%)	Taxa de Acerto com Coeficiente de Regularização (%)	Valor t calculado
Transformada Wavelet	10	1500	95,15 $\pm 0,63$	95,89 $\pm 0,34$	3,292
Filtro Morfológico	10	1300	95,16 $\pm 0,81$	95,98 $\pm 0,49$	2,727
Filtro Morfológico	10	1500	95,12 $\pm 0,98$	96,16 $\pm 0,39$	3,110
Filtro Morfológico	12	1100	96,16 $\pm 0,33$	96,56 $\pm 0,22$	3,202
Filtro Morfológico	12	1300	95,76 $\pm 0,62$	96,61 $\pm 0,30$	3,885
Filtro Morfológico	12	1500	95,78 $\pm 0,74$	96,59 $\pm 0,52$	2,831

Fonte: Autoria própria

Observa-se que em todos os casos apresentados na Tabela 7 e Tabela 8, os resultados obtidos utilizando o fator de regularização foram superiores ao sem CR.

Tabela 8 – Resultados que apresentaram diferença significativa ($\alpha = 0,05$, GL = 18, $t = 2,101$) para a taxa de acerto médio para o algoritmo ELM com Função Gaussiana

Tipo de Filtro	Quantidade de Componentes Principais Utilizada	Quantidade de Neurônios na Camada Escondida	Taxa de Acerto sem Coeficiente de Regularização (%)	Taxa de Acerto com Coeficiente de Regularização (%)	Valor t calculado
Transformada Wavelet	10	1500	95,15 $\pm 0,63$	95,89 $\pm 0,34$	3,292
Filtro Morfológico	10	1100	95,39 $\pm 0,64$	95,96 $\pm 0,53$	2,148
Filtro Morfológico	10	1300	95,17 $\pm 0,82$	95,93 $\pm 0,50$	2,493
Filtro Morfológico	10	1500	95,06 $\pm 0,96$	96,13 $\pm 0,38$	3,267
Filtro Morfológico	12	1100	96,20 $\pm 0,28$	96,58 $\pm 0,22$	3,469
Filtro Morfológico	12	1300	95,73 $\pm 0,66$	96,55 $\pm 0,39$	3,415
Filtro Morfológico	12	1500	95,74 $\pm 0,77$	96,62 $\pm 0,52$	2,971

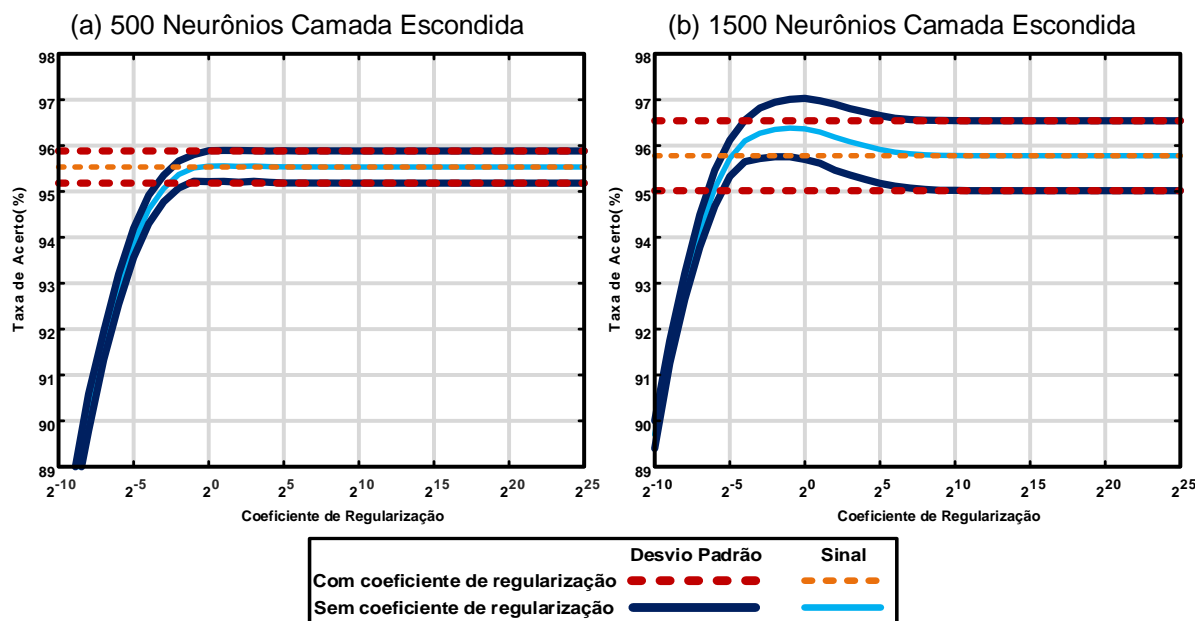
Fonte: Autoria própria

O efeito do CR no resultado pode ser observado no Gráfico 7, o qual apresenta a taxa de acerto médio e seu desvio padrão tanto para o resultado sem o CR (em laranja), quanto para o resultado com CR (em azul claro).

O Gráfico 7 apresenta a correlação observada na Tabela 7 e Tabela 8, da influência do CR com a quantidade de neurônios na camada escondida, para a mesma RNA (ELM com Função Logística) com a mesma técnica de filtragem (Transformada *Wavelet*) e com a mesma quantidade de componentes principais (10). No Gráfico 7(b), com 1500 neurônios na camada escondida, a RNA apresentou em média resultados melhores para os valores de CR entre 2^{-4} e 2^5 , já no Gráfico 7(a), com 500 neurônios na camada escondida, o fator de regularização não apresenta melhorias no resultado.

É possível observar no Gráfico 7 que além do incremento na taxa de acerto médio com o acréscimo do CR, há também um aumento no desvio padrão, apresentando um estado estacionário semelhante ao sem CR. É, da mesma forma, possível constatar que com menos neurônios na camada escondida o desvio padrão tende a ser menor tanto para a RNA com e sem CR.

Gráfico 7 – Efeito do Coeficiente de Regularização na rede ELM com Função Logística com 10 componentes principais e filtragem por Transformada *Wavelet*, com 500 (a) e 1500 (b) neurônios na camada escondida



Fonte: Autoria própria

O efeito percebido no Gráfico 7(b), no qual o emprego do CR ajuda a melhorar o resultado da rede neural é semelhante ao efeito observado por Siqueira (2013). Porém, agora é possível avaliar e determinar que, para o problema em questão, a influência do CR é determinada pelos dados de entrada (que são afetados pelo tipo de filtragem e pela quantidade de componentes principais utilizadas), pela quantidade de neurônios na camada escondida e pela função de ativação utilizada.

É, inclusive, possível observar que para o problema de identificação de arritmias cardíacas, o CR apresentou resultados melhores para mais de 1000 neurônios na camada escondida, sendo que para menos do que esta quantidade não há melhoras significativas, como também foi observado por Cardozo et al. (2017).

Por fim, é possível afirmar que, apesar de nos demais casos não haver uma diferença no resultado, o emprego do coeficiente de regularização só tende a melhorar o resultado. Deste modo, os demais resultados serão apresentados com o uso do coeficiente de regularização.

4.3 AVALIAÇÃO REDE TREINADA COM APENAS O ALGORITMO ELM

Após avaliado com o Teste-T de Student, foi observado que tanto a ELM com Função Logística quanto a ELM com Função Gaussiana apresentam resultados que

não diferem estatisticamente entre si. Ou seja, as funções de ativação que foram testadas na camada escondida não influenciaram o resultado. Sendo assim, os resultados apresentados no restante do trabalho para a rede apenas treinada com o algoritmo ELM serão a média e o desvio padrão de todos os resultados combinados com ambas as funções de ativação.

4.4 AVALIAÇÃO GERAL

Para avaliar como o tipo de filtragem afeta o resultado, foi primeiramente testado as redes neurais com a inserção de 10, depois com 12 e, por último, com 14 componentes principais na entrada das redes neurais.

4.4.1 Resultados utilizando 10 Componentes Principais

O Gráfico 8 e a Tabela 9 apresentam uma comparação entre os algoritmos ELM com Função Logística/Gaussiana e a RNA híbrida RBF-ELM, mostrando a taxa de acerto médio e o desvio padrão sobre todas as execuções. Na Tabela 9 os melhores resultados alcançados com cada rede estão destacados dos demais.

Ao compararmos a resposta da rede ELM no Gráfico 8(a) com a Rede Híbrida RBF-ELM de uma única camada escondida no Gráfico 8(b) e também na Tabela 9, é possível verificar que a rede ELM foi melhor em todos os casos, menos com a filtragem por Transformada *Wavelet* e com 100 neurônios na camada escondida.

Verifica-se na Tabela 9 que, além de não produzir resultados melhores, a Rede Híbrida RBF-ELM com uma única camada escondida apresentou um desvio padrão maior que a rede apenas treinada com o algoritmo ELM.

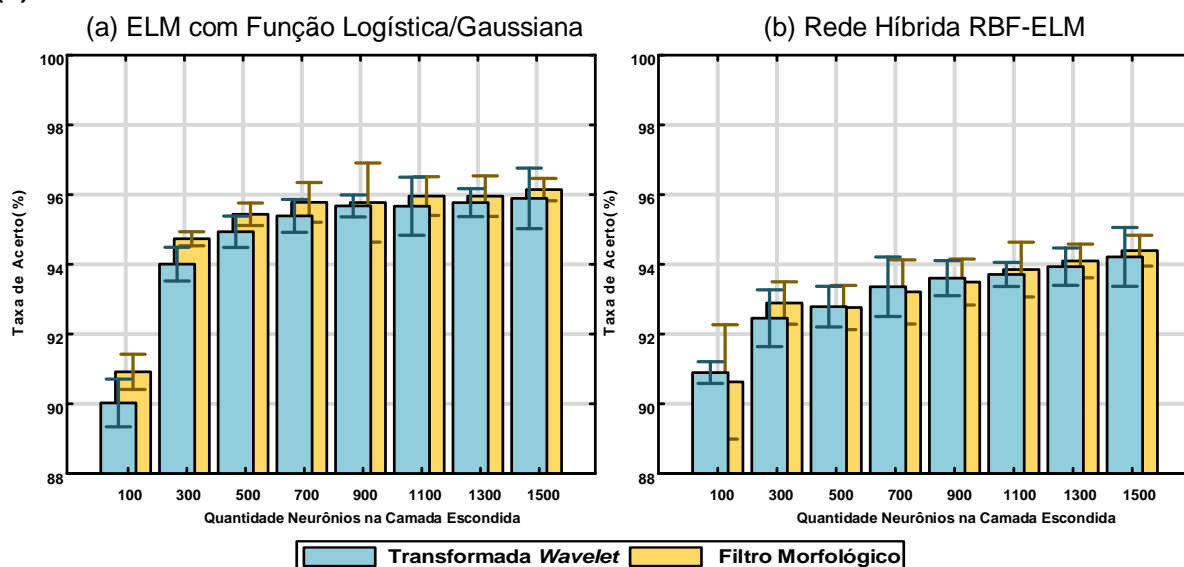
É possível reparar, também, que a resposta com Filtro Morfológico foi levemente melhor em praticamente todos os casos. Todavia, como visualizado na Tabela 9, a diferença diminui conforme é acrescentado a quantidade de neurônios na camada escondida, de modo que com 900, 1100 e 1300 neurônios na camada escondida não há diferença estatística (de acordo com o Teste-T de Student) dos resultados apresentados com ambos os filtros.

Tabela 9 – Taxa de acerto no teste das redes ELM com Função Logística/Gaussiana e a Rede Híbrida RBF-ELM com 10 componentes principais

Quantidade de Neurônios	ELM com Função Logística/Gaussiana		Rede Híbrida RBF- ELM	
	<i>Wavelet</i>	Morfológico	<i>Wavelet</i>	Morfológico
100	90,02 ±0,71	90,92 ±0,64	90,89 ±1,15	90,63 ±2,03
300	94,01 ±0,33	94,73 ±0,21	92,45 ±1,02	92,89 ±1,02
500	94,93 ±0,34	95,44 ±0,21	92,79 ±0,81	92,76 ±1,00
700	95,39 ±0,43	95,78 ±0,30	93,36 ±0,97	93,21 ±1,30
900	95,68 ±0,49	95,77 ±0,64	93,60 ±0,68	93,49 ±1,16
1100	95,67 ±0,53	95,96 ±0,52	93,71 ±0,85	93,85 ±0,95
1300	95,77 ±0,42	95,96 ±0,48	93,93 ±0,71	94,10 ±0,82
1500	95,89 ±0,33	96,14 ±0,38	94,21 ±0,90	94,39 ±0,85

Fonte: Autoria própria

Gráfico 8 – Taxa de acerto médio após filtragem com a Transformada *Wavelet* e com o Filtro Morfológico com 10 componentes principais, para: (a) ELM com Função Logística/Gaussiana; (b) Rede Híbrida RBF-ELM



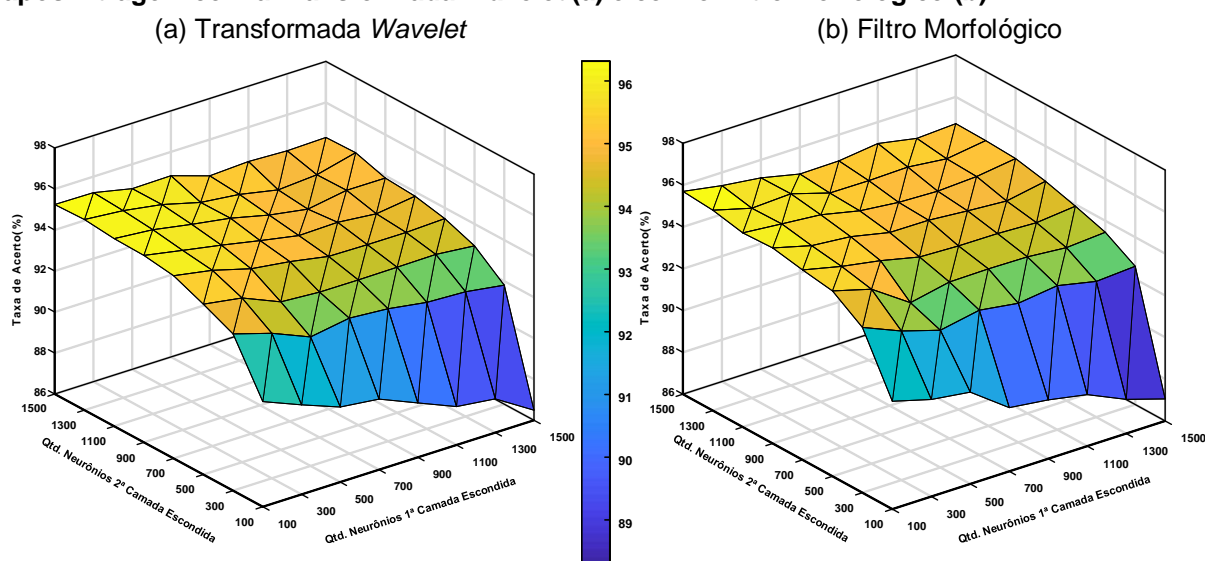
Fonte: Autoria própria

A resposta da Rede Híbrida RBF-ELM com 2 Camadas (Gráfico 9) não apresentou resultados estatisticamente diferentes (de acordo com o Teste-T de Student) tanto para os sinais filtrados com o Filtro Morfológico, quanto para os filtrados com Transformada *Wavelet*. É observado que quanto maior o número de neurônios na segunda camada escondida melhor é o resultado. Enquanto, um maior número de neurônios na primeira camada escondida degrada o resultado. Isto pode ser devido ao fato de a primeira camada ser ajustada de modo não supervisionado com o algoritmo da RBF.

De modo similar as outras redes com uma única camada escondida, a parte da rede que apresenta treinamento baseado no algoritmo ELM mostra-se melhor com uma maior quantidade de neurônios.

Nota-se também, que os resultados apresentam um desvio padrão semelhante ao encontrado na Rede Híbrida RBF-ELM com uma única camada escondida (Tabela 18 e Tabela 19 encontrados no 0). Isto deve ser ao fato de ambos utilizarem a primeira etapa de treinamento das redes RBF, as quais são inteiramente afetadas pelo conjunto de treinamento apresentado.

Gráfico 9 – Taxa de acerto médio do algoritmo RBF-ELM Híbrido com 10 componentes principais após filtragem com a Transformada *Wavelet* (a) e com o Filtro Morfológico (b)



Fonte: Autoria própria

De modo geral, o algoritmo que apresentou melhores resultados para a utilização de 10 componentes principais foi o algoritmo ELM com Função Logística/Gaussiana, com 1500 neurônios na camada escondida apresentando uma taxa de acerto médio de $96,14 \pm 0,38\%$.

4.4.2 Resultados utilizando 12 Componentes Principais

Os resultados obtidos com 12 componentes principais podem ser observados no Gráfico 10 e na Tabela 10. Os resultados obtidos com RNA com ELM com Função Logística/Gaussiana com 12 componentes principais são significativamente diferentes e melhores que os obtidos com 10 componentes quando a quantidade de neurônios na camada escondida foi superior a 700. Na Tabela 10 os melhores resultados alcançados com cada rede estão destacados dos demais.

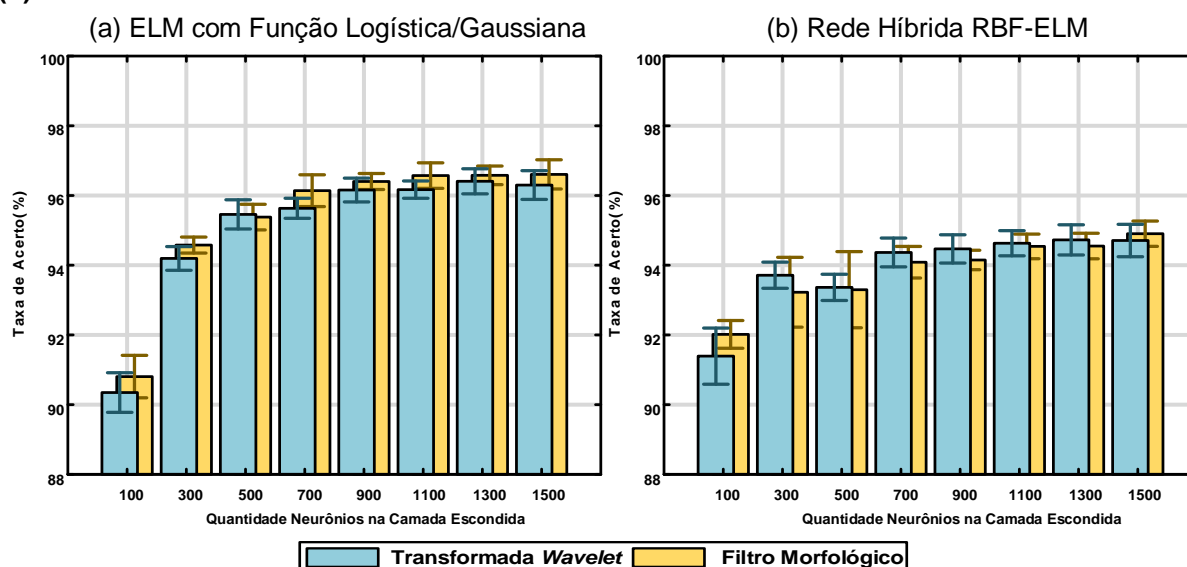
Observa-se que a rede com ELM apresenta melhores resultados em quase todos os casos; a exceção ocorre para 100 neurônios na camada escondida, na qual a Rede Híbrida RBF-ELM com uma camada escondida, apontou resultados melhores.

Tabela 10 – Taxa de acerto no teste das redes ELM com Função Logística/Gaussiana e Rede Híbrida RBF- ELM com 12 componentes principais

Quantidade de Neurônios	ELM com Função Logística/Gaussiana		Rede Híbrida RBF- ELM	
	<i>Wavelet</i>	Morfológico	<i>Wavelet</i>	Morfológico
100	90,35 ±0,52	90,80 ±0,55	91,39 ±1,57	92,01 ±1,04
300	94,19 ±0,51	94,58 ±0,56	93,71 ±1,01	93,22 ±1,55
500	95,46 ±0,32	95,38 ±0,60	93,37 ±0,87	93,30 ±1,56
700	95,63 ±0,66	96,14 ±0,31	94,37 ±1,09	94,09 ±1,07
900	96,16 ±0,41	96,40 ±0,46	94,47 ±1,01	94,15 ±1,01
1100	96,17 ±0,76	96,57 ±0,21	94,63 ±1,07	94,54 ±1,08
1300	96,41 ±0,38	96,58 ±0,34	94,73 ±1,05	94,55 ±1,10
1500	96,30 ±0,56	96,61 ±0,51	94,71 ±0,95	94,90 ±0,97

Fonte: Autoria própria

Gráfico 10 – Taxa de acerto médio após filtragem com a Transformada *Wavelet* e com o Filtro Morfológico com 12 componentes principais: (a) ELM com Função Logística/Gaussiana; (b) Rede Híbrida RBF-ELM



Fonte: Autoria própria

É possível observar na Tabela 10 e no Gráfico 10 que ao contrário das redes com 10 componentes principais na entrada, os resultados estatisticamente diferentes entre os filtros utilizados foi com a rede ELM com Função Logística/Gaussiana com

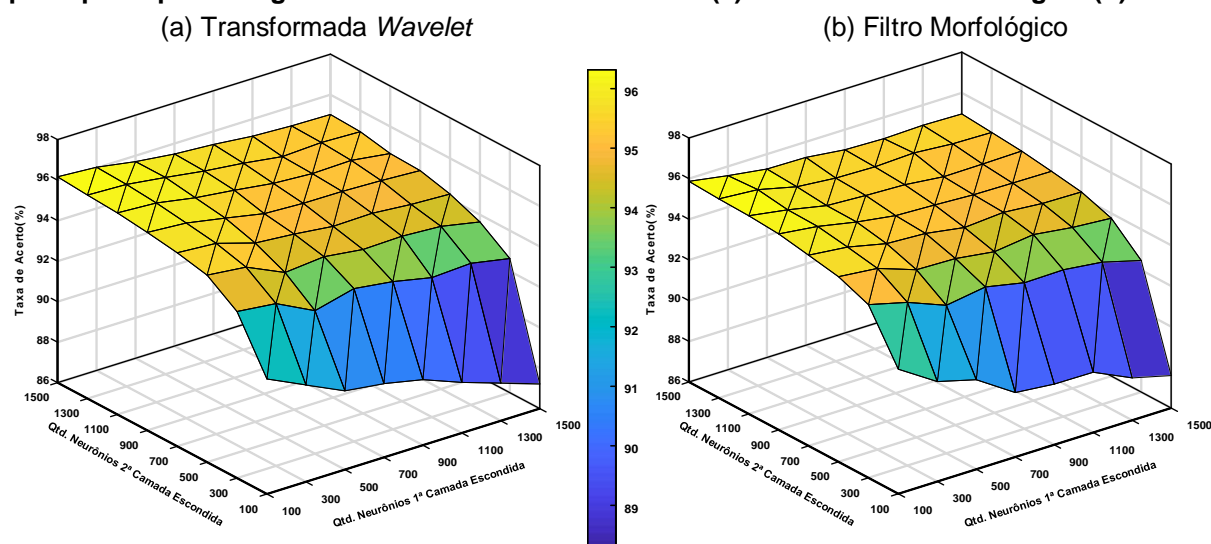
menos de 500, com 700 e com 1100 neurônios na camada escondida, apresentando resultados melhores com o filtro Morfológico nestes casos. Os demais resultados não diferem estatisticamente entre um filtro e outro.

A Rede Híbrida RBF-ELM com duas camadas escondidas, também apresentou resultados semelhantes com 12 componentes principais, aos obtidos com 10 componentes principais, com praticamente todos os resultados sendo semelhantes estatisticamente. É possível observá-los no Gráfico 11.

Novamente observa-se outra semelhança com a Rede Híbrida RBF-ELM com uma única camada escondida e a Rede Híbrida RBF-ELM com duas camadas e 10 componentes principais, as quais apresentaram estatisticamente o mesmo resultado com filtragem por Transformada *Wavelet* e por Filtro Morfológico.

Outra característica, visualizada no Gráfico 11, está no fato de a quantidade de neurônios na 1ª camada escondida afetar de forma inversa o resultado a quantidade de neurônios na 2ª camada escondida. Novamente, isto ocorre devido aos pesos da primeira camada são ajustados de modo não supervisionado com o algoritmo da RBF.

Gráfico 11 – Taxa de acerto médio do algoritmo RBF-ELM Híbrido com 12 componentes principais após filtragem com a Transformada *Wavelet* (a) e com o Filtro Morfológico (b)



Fonte: Autoria própria

Para 12 componentes principais, o algoritmo que apresentou melhores resultados foi novamente o ELM com Função Logística/Gaussiana contendo 1500 neurônios na camada escondida, o qual apresenta uma taxa de acerto médio de $96,61 \pm 0,51\%$.

4.4.3 Resultados utilizando 14 Componentes Principais

O Gráfico 12 e a Tabela 11 apresentam os resultados obtidos com 14 componentes principais. Na Tabela 11 os melhores resultados alcançados com cada rede estão destacados dos demais.

Ao contrário do esperado, o único resultado estatisticamente diferente daqueles obtidos com 12 componentes principais foi para a rede ELM com Função Logística/Gaussiana com 100 neurônios na camada escondida. Sendo o resultado visualmente menor com 14 componentes principais, como pode ser observado na Tabela 11 comparada à Tabela 10.

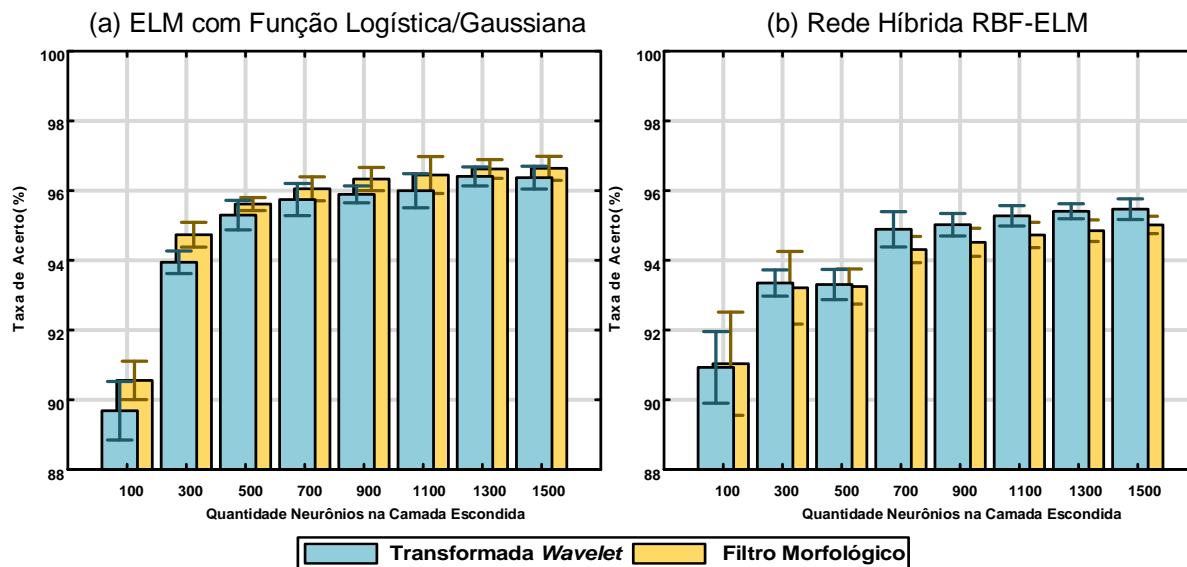
Ainda comparando estatisticamente e observando a Tabela 11, os únicos resultados que diferem entre as técnicas de filtragem aplicadas são com 100 e 300 neurônios na camada escondida com a rede ELM com Função Logística/Gaussiana. Têm-se melhores resultados com o emprego do Filtro Morfológico.

Tabela 11 – Taxa de acerto no teste das redes ELM com Função Logística/Gaussiana e Rede Híbrida RBF-ELM com 14 componentes principais

Quantidade de Neurônios	ELM com Função Logística/Gaussiana		Rede Híbrida RBF-ELM	
	<i>Wavelet</i>	Morfológico	<i>Wavelet</i>	Morfológico
100	89,68 ±0,83	90,55 ±0,54	90,93 ±0,99	91,03 ±1,48
300	93,94 ±0,73	94,73 ±0,33	93,35 ±0,96	93,21 ±1,33
500	95,30 ±0,61	95,62 ±0,58	93,31 ±1,05	93,25 ±1,08
700	95,74 ±0,53	96,05 ±0,65	94,89 ±0,83	94,31 ±1,32
900	95,89 ±0,67	96,33 ±0,44	95,02 ±0,76	94,52 ±1,17
1100	96,00 ±0,72	96,45 ±0,55	95,28 ±1,05	94,73 ±1,26
1300	96,41 ±0,60	96,62 ±0,48	95,41 ±0,87	94,85 ±1,12
1500	96,37 ±0,57	96,64 ±0,60	95,47 ±0,88	95,02 ±1,16

Fonte: Autoria própria

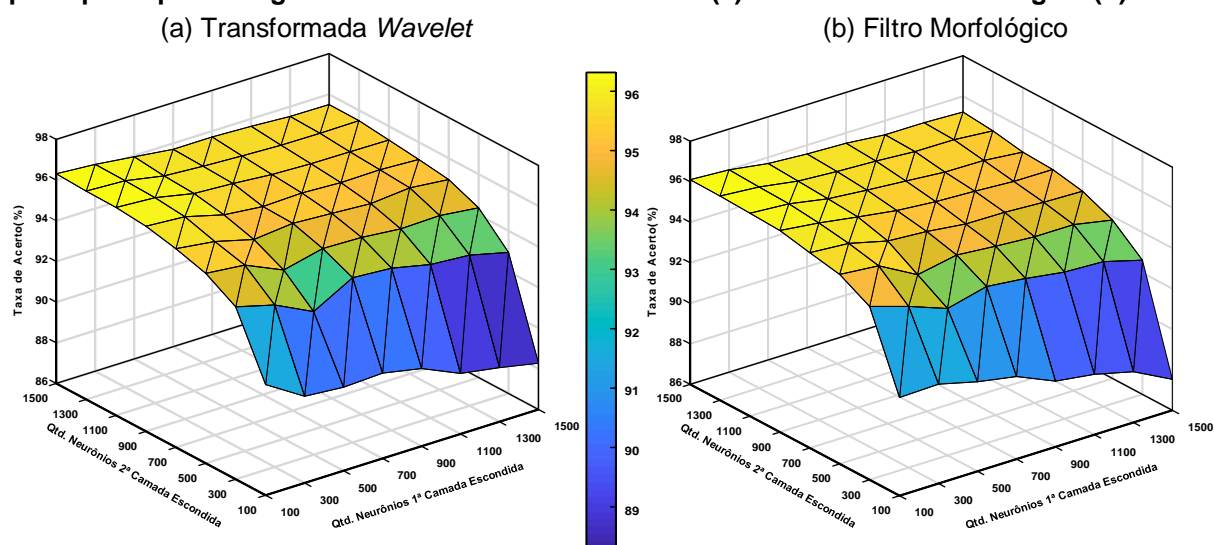
Gráfico 12 – Taxa de acerto médio após filtragem com a Transformada *Wavelet* e com o Filtro Morfológico com 14 componentes principais: (a) ELM com Função Logística/Gaussiana; (b) Rede Híbrida RBF-ELM



Fonte: Autoria própria

Para a Rede Híbrida RBF-ELM com 2 camadas escondidas, da mesma forma que ocorreu com as outras redes, praticamente nenhum resultado apresentou diferença estatística se comparado aos resultados com 12 componentes principais; a única diferença ocorreu com 1500 neurônios na primeira camada escondida e com 100 neurônios na segunda camada escondida.

Gráfico 13 – Taxa de acerto médio do algoritmo RBF-ELM Híbrido com 14 componentes principais após filtragem com a Transformada *Wavelet* (a) e com o Filtro Morfológico (b)



Fonte: Autoria própria

O melhor resultado encontrado com o filtro morfológico, 14 componentes principais e a rede ELM com Função Logística/Gaussiana, com 1500 neurônios na camada escondida apresentando uma taxa de acerto médio de $96,64 \pm 0,60\%$.

4.5 AVALIAÇÃO DA QUANTIDADE DE COMPONENTES PRINCIPAIS

A Tabela 12 apresenta um comparativo entre os melhores resultados para as quatro RNAs avaliadas por este trabalho. Nota-se pelos resultados apresentados previamente que não há quase diferenças significativas quanto aos resultados produzidos se comparados com relação às técnicas de filtragem. Os casos, nos quais, há alguma diferença os resultados com o Filtro Morfológico apresentaram-se melhores.

Apesar de haver um acréscimo nos melhores resultados para o incremento de 10 para 12 componentes principais, o Teste-T de Student apontou que apenas para a rede ELM com Função Logística/Gaussiana há alguma diferença estatística. Sendo esta, a única que apresenta diferença significativa quando acrescido o valor de componentes principais de 10 para 12.

Tabela 12 – Comparativo entre os melhores resultados para as propostas de RNAs

Rede Neural Artificial	Quantidade de Componentes Principais	Técnica de Filtragem	Quantidade de Neurônios	Taxa de Acerto no Teste (%)
ELM com Função Logística/ Gaussiana	10	Filtro Morfológico	1500	$96,14 \pm 0,38$
	12			$96,61 \pm 0,51$
	14			$96,64 \pm 0,60$
Rede Híbrida RBF-ELM com 1 Camada Escondida	10	Filtro Morfológico	1500	$94,39 \pm 0,85$
	12			$94,90 \pm 0,97$
	14	Transformada <i>Wavelet</i>		$95,47 \pm 0,88$
Rede Híbrida RBF-ELM com 2 Camadas Escondidas	10	Filtro Morfológico	100-1500	$95,70 \pm 1,11$
	12	Transformada <i>Wavelet</i>		$96,17 \pm 1,14$
	14			$96,31 \pm 1,07$

Fonte: Autoria própria

Para as demais redes neurais e os demais casos, o acréscimo de componentes principais não apresenta melhoras significativas. Isto deve ocorrer, ainda mais para as redes híbridas, devido ao alto desvio padrão apresentado (se comparado a rede ELM).

De modo geral, quase todos os melhores resultados foram obtidos e associados ao número de neurônios, sendo que quanto maior a quantidade melhor o resultado. A exceção ocorre para a rede Híbrida RBF-ELM com 2 camadas escondidas, onde a quantidade de neurônios na primeira camada atuou de modo inverso no resultado, apresentando sempre um resultado pior quando acrescida a quantidade de neurônios. Apesar disso, a quantidade de neurônios na segunda camada escondida continua a ser diretamente proporcional à qualidade do resultado.

Observa-se, também, que os algoritmos que utilizam o treinamento não supervisionado de uma rede RBF produziram resultados com um maior nível de desvio padrão.

Afinal, pode-se dizer que os melhores resultados foram obtidos com a rede neural artificial ELM com a função de ativação logística ou gaussiana e com 1500 neurônios na camada escondida, apresentando seu melhor resultado de $96,61 \pm 0,51\%$ com 12 componentes principais e com filtragem por Filtro Morfológico.

4.6 ANÁLISE DETALHADA DOS MELHORES RESULTADOS

Para uma análise mais detalhada, escolheu-se os melhores resultados de cada RNA, que se encontram apresentados na Tabela 13.

Tabela 13 – Melhores resultados para as propostas de RNAs

Rede Neural Artificial	Quantidade de Componentes Principais	Técnica de Filtragem	Quantidade de Neurônios	Taxa de Acerto no Teste (%)
ELM com Função Logística/ Gaussiana	12	Filtro Morfológico	1500	96,61 $\pm 0,51$
Rede Híbrida RBF-ELM com 1 Camada Escondida	14	Transformada <i>Wavelet</i>	1500	95,47 $\pm 0,88$
Rede Híbrida RBF-ELM com 2 Camadas Escondidas	14	Transformada <i>Wavelet</i>	100-1500	96,31 $\pm 1,07$

Fonte: Autoria própria

A análise foi feita com relação a cada tipo de batimento, considerando os 4 itens seguintes:

- **Sensibilidade (Se):** é a probabilidade de um batimento com um determinado tipo ser classificado corretamente;
- **Especificidade (Es):** é a probabilidade de um batimento de outro tipo não ser classificado como o tipo em questão;
- **Valor Preditivo Positivo (VPP):** é a probabilidade de um batimento classificado como um determinado tipo ser realmente daquele tipo;
- **Valor Preditivo Negativo (VPN):** é a probabilidade de um batimento não classificado como aquele tipo não ser daquele tipo.

Os valores de Se, Es, VPP e VPN para os resultados obtidos no texto com a RNA ELM com Função Logística/Gaussiana encontram-se na Tabela 14, em que também é apresentado a média de acerto com relação a cada uma dos 5 tipos de batimentos.

Tabela 14 – Média de acerto, Sensibilidade, Especificidade, Valor Preditivo Positivo e Valor Preditivo Negativo por tipo de batimento da RNA ELM com Função Logística/Gaussiana, com 12 Componentes Principais e filtragem por Filtro Morfológico

		Resultado do classificador					Total	Se (%)	VPN (%)
		NE	ESV	EV	F	D			
Tipo correto	NE	8895,70 ±78,10	87,40 ±24,59	44,95 ±56,01	1,10 ±1,68	0,85 ±0,99	9030	98,51 ±0,86	97,51 ±1,98
	ESV	164,20 ±17,84	1110,90 ±17,83	6,55 ±2,37	2,10 ±1,80	0,25 ±0,44	1284	86,52 ±1,39	98,70 ±1,71
	EV	73,65 ±12,90	18,80 ±11,94	1929,95 ±28,09	16,40 ±9,29	1,20 ±1,01	2040	94,61 ±1,38	99,12 ±1,34
	F	32,45 ±3,55	0,65 ±0,81	32,75 ±14,96	270,15 ±14,14	0,00 ±0,00	336	80,40 ±4,21	99,54 ±1,82
	D	9,50 ±3,27	0,20 ±0,41	1,70 ±1,30	0,00 ±0,00	1875,60 ±2,78	1887	99,40 ±0,15	99,91 ±2,33
Total		9141,90	1159,00	2194,80	254,10	1827,20	14577		
Es (%)		94,96 ±1,93	99,19 ±1,72	99,31 ±1,34	99,86 ±1,82	99,98 ±2,33			
VPP (%)		96,95 ±0,85	91,21 ±1,46	95,74 ±1,39	93,24 ±4,88	99,88 ±0,15			

Fonte: Autoria própria

Nota: batimento não ectópico (NE); batimento ectópico supraventricular (ESV); batimento ectópico ventricular (EV); batimento de fusão (F); batimento desconhecido (D); sensibilidade (Se), especificidade (Es), valor preditivo positivo (VPP), valor preditivo negativo (VPN)

Enquanto a Tabela 15 apresenta os valores de Se, Es, VPP, VPN e a média de acerto, com relação a cada uma dos 5 tipos de batimentos, para os resultados obtidos no teste com a RNA Híbrida RBF-ELM com 1 camada escondida.

Tabela 15 – Média de acerto, Sensibilidade, Especificidade, Valor Preditivo Positivo e Valor Preditivo Negativo por tipo de batimento da RNA Híbrida RBF-ELM com 1 camada escondida, com 14 Componentes Principais e filtragem por Transformada *Wavelet*

		Resultado do classificador					Total	Se (%)	VPN (%)
		NE	ESV	EV	F	D			
Tipo correto	NE	8818,50 ±137,18	58,30 ±10,83	148,70 ±132,57	5,50 ±3,17	2,00 ±1,83	9033	97,63 ±1,52	95,97 ±3,37
	ESV	160,10 ±23,61	1109,50 ±26,63	14,00 ±6,82	0,10 ±0,32	0,30 ±0,48	1284	86,41 ±2,07	98,69 ±3,47
	EV	91,10 ±26,38	9,90 ±7,42	1827,10 ±34,05	10,60 ±8,76	2,30 ±5,95	1941	94,13 ±1,75	99,08 ±2,25
	F	45,60 ±6,47	0,50 ±0,53	38,00 ±22,58	251,90 ±23,18	0,00 ±0,00	336	74,97 ±6,90	99,41 ±3,36
	D	37,60 ±20,22	2,70 ±3,95	28,80 ±17,81	0,00 ±0,00	1811,90 ±20,96	1881	96,33 ±1,11	99,45 ±3,72
Total		9152,90	1180,90	2056,60	268,10	1816,50	14475		
Es (%)		93,86 ±3,30	99,46 ±3,50	98,17 ±2,23	99,89 ±3,37	99,96 ±3,74			
VPP (%)		96,35 ±1,50	93,95 ±2,25	88,84 ±1,66	93,96 ±8,65	99,75 ±1,15			

Fonte: Autoria própria

Nota: batimento não ectópico (NE); batimento ectópico supraventricular (ESV); batimento ectópico ventricular (EV); batimento de fusão (F); batimento desconhecido (D); sensibilidade (Se), especificidade (Es), valor preditivo positivo (VPP), valor preditivo negativo (VPN)

Por sua vez, a Tabela 16 mostra os valores de Se, Es, VPP, VPN e a média de acerto, com relação a cada um dos 5 tipos de batimentos, no teste para a RNA Híbrida RBF-ELM com 2 camadas escondidas.

É possível notar que a RNA ELM com Função Logística/Gaussiana apresentou resultados estatisticamente diferentes ($\alpha = 5\%$) e melhores com relação a sensibilidade (Se) e a valor preditivo negativo (VPN) para batimentos não ectópicos (NE) e desconhecidos (D) que as demais redes. Porém, para os demais tipos de batimentos, quando houve alguma diferença estatística na Se, quem se apresentou melhor foi a RNA Híbrida RBF-ELM com 2 camadas escondidas. Para os outros batimentos os VPNs não apresentaram resultados estatisticamente diferentes.

A RNA Híbrida RBF-ELM com 2 camadas escondidas também apresentou resultados diferentes ($\alpha = 5\%$), se sobressaindo as demais, para especificidades (Es) e valor preditivo positivo (VPP) para os batimentos do tipo ectópico supraventricular.

Tabela 16 – Média de acerto, Sensibilidade, Especificidade, Valor Preditivo Positivo e Valor Preditivo Negativo por tipo de batimento da RNA Híbrida RBF-ELM com 2 camadas escondidas, com 14 Componentes Principais e filtragem por Transformada *Wavelet*

		Resultado do classificador					Total	Se (%)	VPN (%)
		NE	ESV	EV	F	D			
Tipo correto	NE	8745,30 ±146,92	68,30 ±12,25	201,60 ±151,76	13,80 ±6,14	4,00 ±2,79	9033	96,82 ±1,63	94,84 ±1,84
	ESV	85,20 ±13,16	1180,60 ±14,51	17,40 ±10,65	0,60 ±1,07	0,20 ±0,42	1284	91,95 ±1,13	99,22 ±3,01
	EV	41,80 ±10,94	9,60 ±5,10	1878,00 ±13,08	10,10 ±6,12	1,50 ±1,72	1941	96,75 ±0,67	99,49 ±1,91
	F	21,90 ±7,91	1,20 ±0,79	34,60 ±17,49	278,10 ±15,18	0,20 ±0,42	336	82,77 ±4,52	99,59 ±2,85
	D	4,60 ±4,17	3,00 ±2,26	14,10 ±6,10	0,00 ±0,00	1859,30 ±7,47	1881	98,85 ±0,40	99,83 ±3,43
Total		9152,90	1180,90	2056,60	268,10	1816,50	14475		
Es (%)		97,18 ±1,88	99,38 ±3,02	97,86 ±1,88	99,83 ±2,85	99,95 ±3,44			
VPP (%)		98,28 ±1,65	93,50 ±1,15	87,52 ±0,61	91,90 ±5,02	99,68 ±0,40			

Fonte: Autoria própria

Nota: batimento não ectópico (NE); batimento ectópico supraventricular (ESV); batimento ectópico ventricular (EV); batimento de fusão (F); batimento desconhecido (D); sensibilidade (Se), especificidade (Es), valor preditivo positivo (VPP), valor preditivo negativo (VPN)

Conclui-se que a RNA ELM com Função Logística/Gaussiana alcançou uma taxa de acerto maior pois se mostrou melhor, em geral, para os batimentos do tipo NE, que são os batimentos que compreendem a maior porção do conjunto de teste. Enquanto a RNA Híbrida RBF-ELM com 2 camadas escondidas, apesar de não atingir uma taxa de acerto tão grande, se destacou perante os demais em quase todos os outros tipos de batimento.

4.7 AVALIAÇÃO COM RELAÇÃO A OUTROS TRABALHOS

A Tabela 17 faz uma breve comparação dos melhores resultados obtidos neste trabalho com os resultados de outros artigos que possuem o mesmo propósito e que utilizaram redes neurais e técnicas semelhantes.

Tabela 17 – Comparativo entre os melhores resultados deste trabalho e de outros que utilizam RNAs

(continua)					
Estudo	Quantidade de Classes	Técnica de Extração de Característica	Técnica de Filtragem	Classificador	Taxa de Acerto no Teste (%)
Kim et al. (2007)	7 (normal, BRE, BRD, EA, EV, PV e BEV)	•PCA – 22	–	•RNA do tipo MLP •280 neurônios	97,47
Kim et al. (2009)	6 (normal, BRE, BRD, EA, EV e PV)	•PCA – 10 •Intervalo entre Picos R	Filtro Morfológico	•ELM •Sem coeficiente de regularização •800 neurônios	98,72
Kim et al. (2009)	6 (normal, BRE, BRD, EA, EV e PV)	•PCA – 10 •Intervalo entre Picos R	Filtro Morfológico	•RBF •1400 neurônios	89,36
Martis et al. (2013)	5 de acordo com AAMI (1995)	•PCA – 12	Transformada <i>Wavelet</i>	•PNN	99,52
Martis, Acharya e Min (2013)	5 de acordo com AAMI (1995)	•ICA – 6	Transformada <i>Wavelet</i>	•PNN	99,28
Este trabalho	5 de acordo com AAMI (1995)	•PCA – 12	Filtro Morfológico	•ELM com Função Logística/Gaussiana •Com coeficiente de regularização •1500 neurônios	96,61 ±0,51
Este trabalho	5 de acordo com AAMI (1995)	•PCA – 14	Filtro Morfológico	•Rede Híbrida RBF-ELM 1 camada escondida •Com coeficiente de regularização •1500 neurônios	95,47 ±0,88

Tabela 17 – Comparativo entre os melhores resultados deste trabalho e de outros que utilizam RNAs

					(conclusão)
Estudo	Quantidade de Classes	Técnica de Extração de Característica	Técnica de Filtragem	Classificador	Taxa de Acerto no Teste (%)
Este trabalho	5 de acordo com AAMI (1995)	•PCA – 14	Transformada <i>Wavelet</i>	<ul style="list-style-type: none"> • Rede Híbrida RBF-ELM 2 camada escondida • Com coeficiente de regularização • 100 / 1500 neurônios 	96,31 ±1,07

Fonte: Autoria própria

Conforme é possível observar pela Tabela 17, os demais trabalhos apresentaram, em geral, resultados levemente melhores que este. Porém estes ou utilizaram outras redes neurais (como a rede probabilística – PNN) ou utilizaram mais informações para a inserção no algoritmo classificador, como intervalos entre picos R, ou até mesmo mais características da análise de componentes principais. Este trabalho, porém, apresentou resultados melhores com a utilização da rede neural com função de base radial (RBF) dos já encontrados na literatura para o mesmo problema.

5 CONCLUSÃO

Este trabalho propôs-se a criar e avaliar um sistema de auxílio a diagnóstico de arritmias cardíacas, para a classificação de 11 tipos de batimentos cardíacos que foram agrupados em 5 supertipos, utilizando-se de sinais eletrocardiográficos. Avaliou-se a influência da técnica de filtragem no resultado, comparando uma técnica de filtragem adaptativa (Filtro Morfológico) e uma técnica de filtragem baseada em filtros FIR (Transformada *Wavelet* Discreta). As características extraídas do sinal de eletrocardiograma foram obtidas com a análise de componentes principais (PCA), variando a quantidade de componentes entre 10, 12 e 14 para verificar a atuação do mesmo nos resultados. Além disso, foram avaliados alguns classificadores baseados em redes neurais artificiais (RNAs). Duas RNAs híbridas RBF-ELM, uma com uma camada oculta e outra com duas; e duas RNAs ELM, cada qual com uma função de ativação diferente (Função Logística e Função Gaussiana).

Os resultados obtidos neste trabalho demonstram que todas as técnicas comparadas podem ser empregadas em sistemas de apoio ao diagnóstico de arritmias cardíacas, apresentando em todos os casos, resultados superiores a 95% de acerto.

Comparando os resultados obtidos sobre as técnicas de filtragem, ficou claro na maioria das vezes que filtragem não influenciou de forma significativa. Sendo que, quando houve alguma diferença, os resultados atingidos com o uso do Filtro Morfológico, proposto por Sun, Chan e Krishnan (2002), apresentaram-se ligeiramente melhores.

Fica claro que o Filtro Morfológico afeta o sinal em toda as faixas de frequência se comparado a Transformada *Wavelet*, esta afeta apenas as frequências desejadas. Porém, isto não aparentou afetar de forma negativa, mas sim de forma positiva o sinal. Dando a entender que apesar de reduzir as amplitudes de todas as faixas de frequência do sinal, o Filtro Morfológico aplicado deixa as características das ondas mais aparentes para que estas possam se destacar dos ruídos e dos trechos comuns.

Com relação à utilização do coeficiente de regularização na RNA ELM, os efeitos observados neste trabalho foram semelhantes aos observados por Siqueira (2013), demonstrando que o CR aumenta a capacidade de generalização, obtendo nos casos estudados um aumento na taxa de acerto de até quase 1 ponto percentual quando o CR está entre 2^{-4} e 2^5 . Para o problema em questão, é possível concluir que

a influência do CR é determinada pelos dados de entrada (que são afetados pelo tipo de filtragem e pela quantidade de componentes principais utilizadas) e pela quantidade de neurônios na camada escondida. É, ainda, possível deduzir que para a identificação de arritmias cardíacas, o CR apresentou resultados melhores para mais de 1000 neurônios na camada escondida, sendo que para menores quantidades não há diferença estatística entre os resultados, como também foi observado por Cardozo et al. (2017).

Conclui-se, também, que as funções de ativação testadas para as RNAs ELM (Função Gaussiana e Função Logística) aparentam não afetar o resultado, pois, estatisticamente apresentaram resultados semelhantes.

As RNAs híbridas RBF-ELM de modo geral não alcançaram resultados melhores. Para a RNA híbrida com apenas uma camada escondida, a etapa de treinamento não supervisionado, em geral, não apresentou melhoria nos resultados, apenas em algumas ocasiões, quando haviam 100 e/ou 300 neurônios na camada escondida. Já os resultados obtidos com a RNA híbrida com duas camadas escondidas permitiram observar que a etapa de treinamento não supervisionado apresenta melhores resultados com menos neurônios, algo que não ocorre com todas as redes quando se trata do treinamento de modo analítico da ELM, que apresenta resultados melhores com mais neurônios na camada escondida.

Observando os trabalhos que utilizam técnicas semelhantes e a mesma linha de pesquisa, é possível concluir que houve uma melhoria significativa se comparado a rede RBF simples com a rede híbrida RBF-ELM com uma camada escondida. É, inclusive, possível observar que alguns trabalhos utilizam outros dados para a entrada nos algoritmos de IC (como o intervalo entre picos R) e não só os obtidos com a análise de componentes principais (como realizado neste trabalho).

De modo geral, neste trabalho pôde-se observar como as técnicas empregadas e suas variantes afetam o sinal.

5.1 TRABALHOS FUTUROS

O filtro morfológico proposto por Sun, Chan e Krishnan (2002), apesar de eficiente, ainda merece mais estudos, sobre sua real interferência no sinal. Uma futura

análise mais profunda sobre a real influência em sinais eletrocardiográficos é imprescindível.

A análise de componentes principais é apenas uma técnica para a análise e redução da dimensionalidade de sinais; outras técnicas como a análise de componentes independentes (ICA) e a análise de discriminante linear (LDA), apresentaram em outro trabalho (MARTIS; ACHARYA; MIN, 2013) resultados melhores, e valem um estudo maior.

Outros algoritmos de inteligência computacional, como outras topologias de redes neurais artificiais, ou algoritmos imunológicos artificiais, podem produzir resultados melhores. Nesse ponto, existe um campo para um estudo sobre estas outras técnicas. Aliás, as redes híbridas RBF-ELM aparentemente apresentam resultados melhores que a RNA ELM quando há poucos neurônios. Cabe um estudo maior sobre a influência do treinamento não supervisionado na resposta das RNAs.

Além disso, o fato da base de dados ser de antes dos anos de 1980 e de apresentar pontos que ficam confusos na descrição de como os dados foram coletados e digitalizados, cria, em alguns momentos, empecilhos para a real identificação do que possa ter acontecido, como por exemplo o fato de alguns registros terem sido digitalizados em duas vezes o tempo de amostragem, sem o conhecimento de que o resultado digitalizado não sofreu influência (MOODY; MARK, 2001). Deste modo, para uma validação melhor do sistema, talvez fosse necessário a aquisição de dados próprios.

REFERÊNCIAS

- AAMI. Recommended practice for testing and reporting performance results of ventricular arrhythmia detection algorithms. **AAMI standards and recommended practices**, v. 2.2: biomedical equipment, n. 2: monitoring and diagnostic equipment, p. 921–944, 1995.
- ADDISON, P. S. Wavelet transforms and the ECG: a review. **Physiological Measurement**, v. 26, n. 5, p. R155, 2005.
- ADNANE, M.; JIANG, Z.; CHOI, S. Development of QRS detection algorithm designed for wearable cardiorespiratory system. **Computer Methods and Programs in Biomedicine**, v. 93, n. 1, p. 20–31, 1 jan. 2009.
- AFONSO, V. X. et al. ECG beat detection using filter banks. **IEEE Transactions on Biomedical Engineering**, v. 46, n. 2, p. 192–202, fev. 1999.
- AHLSTROM, M. L.; TOMPKINS, W. J. Digital Filters for Real-Time ECG Signal Processing Using Microprocessors. **IEEE Transactions on Biomedical Engineering**, v. BME-32, n. 9, p. 708–713, set. 1985.
- AWODEYI, A. E.; ALTY, S. R.; GHAVAMI, M. **Median Filter Approach for Removal of Baseline Wander in Photoplethysmography Signals**. 2013 European Modelling Symposium. **Anais...** In: 2013 EUROPEAN MODELLING SYMPOSIUM. nov. 2013
- BAHOURA, M.; HASSANI, M.; HUBIN, M. DSP implementation of wavelet transform for real time ECG wave forms detection and heart rate analysis. **Computer Methods and Programs in Biomedicine**, v. 52, n. 1, p. 35–44, 1 jan. 1997.
- BAILEY, J. J. et al. Recommendations for standardization and specifications in automated electrocardiography: bandwidth and digital signal processing. A report for health professionals by an ad hoc writing group of the Committee on Electrocardiography and Cardiac Electrophysiology of the Council on Clinical Cardiology, American Heart Association. **Circulation**, v. 81, n. 2, p. 730–739, fev. 1990.
- BARHATTE, A. S.; GHONGADE, R.; THAKARE, A. S. **QRS complex detection and arrhythmia classification using SVM**. 2015 Communication, Control and Intelligent Systems (CCIS). **Anais...** In: 2015 COMMUNICATION, CONTROL AND INTELLIGENT SYSTEMS (CCIS). nov. 2015

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.

BENJAMIN, E. J. et al. Heart Disease and Stroke Statistics-2017 Update: A Report From the American Heart Association. **Circulation**, v. 135, n. 10, p. e146–e603, 7 mar. 2017.

BISHOP, C. M. **Neural Networks for Pattern Recognition**. [s.l.] Clarendon Press, 1995.

BISTENI, A. et al. A new approach for the recognition of ventricular premature beats*. **The American Journal of Cardiology**, v. 5, n. 3, p. 358–369, 1 mar. 1960.

CALIL, S. J.; GOMIDE, E. T. **Equipamentos Médico-Hospitalares e o Gerenciamento da Manutenção: capacitação a distância**. Brasília, DF: Editora MS, 2002.

CALLEGARI-JACQUES, S. **Bioestatística: princípios e aplicações**. Porto Alegre: Artmed, 2007.

CARDOZO, R. et al. SISTEMA DE AUXÍLIO AO DIAGNÓSTICO DE ARRITMIAS CARDÍACAS USANDO MÁQUINAS DE APRENDIZADO EXTREMO. **V Congresso Brasileiro de Eletromiografia e Cinesiologia | X Simpósio de Engenharia Biomédica**, 2017.

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

CASTELLS, F. et al. Principal Component Analysis in ECG Signal Processing. **EURASIP Journal on Advances in Signal Processing**, v. 2007, n. 1, dez. 2007.

CHEN, S. et al. Heartbeat classification using projected and dynamic features of ECG signal. **Biomedical Signal Processing and Control**, v. 31, p. 165–173, 1 jan. 2017.

CHEN, S.-W.; CHEN, H.-C.; CHAN, H.-L. A real-time QRS detection method based on moving-averaging incorporating with wavelet denoising. **Computer Methods and Programs in Biomedicine**, v. 82, n. 3, p. 187–195, 1 jun. 2006.

CHU, C. H.; DELP, E. J. Impulsive noise suppression and background normalization of electrocardiogram signals using morphological operators. **IEEE transactions on bio-medical engineering**, v. 36, n. 2, p. 262–273, fev. 1989.

COYLE, G.; BOYDELL, L.; BROWN, L. Home telecare for the elderly. **Journal of Telemedicine and Telecare**, v. 1, n. 3, p. 183–184, 1995.

CROWTHER, J. B.; POROPATICH, R. Telemedicine in the U.S. Army: case reports from Somalia and Croatia. **Telemedicine Journal: The Official Journal of the American Telemedicine Association**, v. 1, n. 1, p. 73–80, 1995.

DARRINGTON, J. Towards real time QRS detection: A fast method using minimal pre-processing. **Biomedical Signal Processing and Control**, Voice Models and Analysis for Biomedical Applications. v. 1, n. 2, p. 169–176, 1 abr. 2006.

DAUBECHIES, I. Orthonormal bases of compactly supported wavelets. **Communications on Pure and Applied Mathematics**, v. 41, n. 7, p. 909–996, 1 out. 1988.

DAUBECHIES, I. The wavelet transform, time-frequency localization and signal analysis. **IEEE Transactions on Information Theory**, v. 36, n. 5, p. 961–1005, set. 1990.

DAUBECHIES, I. **Ten lectures on wavelets**. 9. print ed. Philadelphia, Pa: Soc. for Industrial and Applied Mathematics, 1992.

DAY, H. W. An Intensive Coronary Care Area. **Diseases of the Chest**, v. 44, n. 4, p. 423–427, 1 out. 1963.

DAY, H. W. Effectiveness of an intensive coronary care area. **The American Journal of Cardiology**, v. 15, n. 1, p. 51–54, 1 jan. 1965.

DOKUR, Z.; ÖLMEZ, T. ECG beat classification by a novel hybrid neural network. **Computer Methods and Programs in Biomedicine**, v. 66, n. 2, p. 167–181, 1 set. 2001.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. 2. ed ed. New York: Academic Internet Publications, 2006.

EINTHOVEN, W. Ein neues Galvanometer. **Annalen der Physik**, v. 317, n. 13, p. 1059–1071, 1903.

ELGENDI, M. Fast QRS Detection with an Optimized Knowledge-Based Method: Evaluation on 11 Standard ECG Databases. **PLOS ONE**, v. 8, n. 9, p. e73557, 16 set. 2013.

ELGENDI, M.; JONKMAN, M.; DE BOER, F. Improved QRS Detection Algorithm using Dynamic Thresholds. **International Journal of Hybrid Information Technology**, v. 2, p. 65–80, 1 jan. 2009.

ELHAJ, F. A. et al. Arrhythmia recognition and classification using combined linear and nonlinear features of ECG signals. **Computer Methods and Programs in Biomedicine**, v. 127, p. 52–63, 1 abr. 2016.

FAVORETTO, S. **Máquinas de Aprendizado Extremo Aplicadas à Identificação de Pessoas através do Eletrocardiograma (ECG)**. Dissertação Mestrado—Ponta Grossa, PR: Universidade Tecnologia Federal do Paraná - Campus Ponta Grossa, 2016.

FERRARA, E. R.; WIDRAW, B. Fetal Electrocardiogram Enhancement by Time-Sequenced Adaptive Filtering. **IEEE Transactions on Biomedical Engineering**, v. BME-29, n. 6, p. 458–460, jun. 1982.

FYE, W. B. A History of the origin, evolution, and impact of electrocardiography. **The American Journal of Cardiology**, v. 73, n. 13, p. 937–949, 15 maio 1994.

GHAFFARI, A.; GOLBAYANI, H.; GHASEMI, M. A new mathematical based QRS detector using continuous wavelet transform. **Computers & Electrical Engineering**, Advances on Computer-based Biological Signal Processing Techniques. v. 34, n. 2, p. 81–91, 1 mar. 2008.

GHORBANI AFKHAMI, R.; AZARNIA, G.; TINATI, M. A. Cardiac arrhythmia classification using statistical and mixture modeling features of ECG signals. **Pattern Recognition Letters**, v. 70, p. 45–51, 15 jan. 2016.

GIFFONI, R. T.; TORRES, R. M. Breve história da eletrocardiografia. **Rev. méd. Minas Gerais**, v. 20, n. 2, p. 263–270, maio 2010.

GOLDBERGER, A. L.; GOLDBERGER, Z. D.; SHVILKIN, A. **Goldberger's clinical electrocardiography: a simplified approach**. 8. ed ed. Philadelphia, PA: Elsevier/Saunders, 2013.

GOLDBERGER, E. A simple, indifferent, electrocardiographic electrode of zero potential and a technique of obtaining augmented, unipolar, extremity leads. **American Heart Journal**, v. 23, n. 4, p. 483–492, 1 abr. 1942.

GOLDMAN, L.; AUSIELLO, D. **Cecil medicina**. Rio de Janeiro: Elsevier, 2009.

GUPTA, H. R.; BATAN, S.; MEHRA, R. Power Spectrum Estimation using Welch Method for various Window Techniques. **International Journal of Scientific Research Engineering & Technology (IJSRET)**, v. 2, n. 6, p. 389–392, set. 2013.

HALL, J. E.; GUYTON, A. C. **Tratado de fisiologia médica**. 12. ed. Rio de Janeiro (RJ): ELSEVIER, 2011.

HAMILTON, P. **Open source ECG analysis**. Computers in Cardiology. **Anais... In: COMPUTERS IN CARDIOLOGY**. set. 2002

HAMILTON, P. S.; TOMPKINS, W. J. Quantitative Investigation of QRS Detection Rules Using the MIT/BIH Arrhythmia Database. **IEEE Transactions on Biomedical Engineering**, v. BME-33, n. 12, p. 1157–1165, dez. 1986.

HARALICK, R. M.; STERNBERG, S. R.; ZHUANG, X. Image Analysis Using Mathematical Morphology. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. PAMI-9, n. 4, p. 532–550, jul. 1987.

HAYKIN, S. **Neural networks: a comprehensive foundation**. Delhi: Pearson Education, 1999.

HERRY, C. L. et al. Heart beat classification from single-lead ECG using the synchrosqueezing transform. **Physiological Measurement**, v. 38, n. 2, p. 171, 2017.

HOERL, A. E.; KENNARD, R. W. Ridge Regression: Biased Estimation for Nonorthogonal Problems. **Technometrics**, v. 12, n. 1, p. 55–67, fev. 1970.

HOLTER, N. J. New Method for Heart Studies: Continuous electrocardiography of active subjects over long periods is now practical. **Science**, v. 134, n. 3486, p. 1214–1220, 20 out. 1961.

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.; ZHU, Q.-Y.; SIEW, C.-K. **Extreme learning machine: a new learning scheme of feedforward neural networks**. . In: 2004 IEEE INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS. jul. 2004

HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: Theory and applications. **Neurocomputing**, Neural Networks. v. 70, n. 1, p. 489–501, 1 dez. 2006.

IBGE. **Pesquisa nacional de saúde 2013: percepção do estado de saúde, estilos de vida e doenças crônicas: Brasil, grandes regiões e unidades da federação**. 1. ed. Rio de Janeiro, RJ: IBGE, 2014.

ISTEPANIAN, R. S. H. Telemedicine in the United Kingdom: current status and future prospects. **IEEE Transactions on Information Technology in Biomedicine**, v. 3, n. 2, p. 158–159, jun. 1999.

ISTEPANIAN, R. S. H.; JOVANOVIĆ, E.; ZHANG, Y. T. Guest Editorial Introduction to the Special Section on M-Health: Beyond Seamless Mobility and Global Wireless Health-Care Connectivity. **IEEE Transactions on Information Technology in Biomedicine**, v. 8, n. 4, p. 405–414, dez. 2004.

JAFARI MOGHADAM FARD, P.; MORADI, M. H.; TAJVIDI, M. R. A novel approach in R peak detection using Hybrid Complex Wavelet (HCW). **International Journal of Cardiology**, v. 124, n. 2, p. 250–253, 29 fev. 2008.

JAGTAP, S. K.; UPLANE, M. D. Digital Filter Approach for ECG in Signal Processing. In: **Proceedings of International Conference on Advances in Computing**. [s.l.] Springer, New Delhi, 2013. p. 1075–1082.

JINGWEI, D.; WENWEN, J. **Design of Digital Filter on ECG Signal Processing**. 2015 Fifth International Conference on Instrumentation and Measurement, Computer, Communication and Control (IMCCC). **Anais...** In: 2015 FIFTH INTERNATIONAL CONFERENCE ON INSTRUMENTATION AND MEASUREMENT, COMPUTER, COMMUNICATION AND CONTROL (IMCCC). set. 2015

JOLLIFFE, I. T. **Principal component analysis**. New York: Springer-Verlag, 1986.

JUNIOR, E. A.; VALENTIM, R. A. DE M.; BRANDAO, G. B. Real Time QRS Detection Based on Redundant Discrete Wavelet Transform. **IEEE Latin America Transactions**, v. 14, n. 4, p. 1662–1668, abr. 2016.

KALRA, A. **Elimination of Skin-stretch Induced Motion Artefacts From Electrocardiogram Signals**. Tese Doutorado—[s.l.] Auckland University of Technology, 2017.

KIM, J. et al. **Algorithm for Classifying Arrhythmia using Extreme Learning Machine and Principal Component Analysis**. 2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. **Anais...** In: 2007 29TH ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY. ago. 2007

KIM, J. et al. Robust algorithm for arrhythmia classification in ECG using extreme learning machine. **BioMedical Engineering OnLine**, v. 8, p. 31, 28 out. 2009.

KLIGFIELD, P. et al. Recommendations for the standardization and interpretation of the electrocardiogram: part I: the electrocardiogram and its technology a scientific statement from the American Heart Association Electrocardiography and Arrhythmias Committee, Council on Clinical Cardiology; the American College of Cardiology Foundation; and the Heart Rhythm Society endorsed by the International Society for Computerized Electrocardiology. **Journal of the American College of Cardiology**, v. 49, n. 10, p. 1109–1127, 13 mar. 2007.

KOHAVI, R. A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. v. 14, 3 mar. 2001.

KOISHYBAEV, D. N. et al. **Adaptive noise cancellation in ECG signal**. 2017 International Conference “Quality Management, Transport and Information Security, Information Technologies” (IT QM IS). **Anais...** In: 2017 INTERNATIONAL CONFERENCE “QUALITY MANAGEMENT, TRANSPORT AND INFORMATION SECURITY, INFORMATION TECHNOLOGIES” (IT QM IS). set. 2017

KROGH, A.; VEDELSBY, J. **Neural Network Ensembles, Cross Validation, and Active Learning**. Advances in Neural Information Processing Systems. **Anais...** MIT Press, 1995

KUNDU, M.; NASIPURI, M.; KUMAR BASU, D. Knowledge-based ECG interpretation: a critical review. **Pattern Recognition**, v. 33, n. 3, p. 351–373, 1 mar. 2000.

LAGERHOLM, M. et al. Clustering ECG complexes using Hermite functions and self-organizing maps. **IEEE Transactions on Biomedical Engineering**, v. 47, n. 7, p. 838–848, jul. 2000.

LEE, J. et al. **A simple real-time QRS detection algorithm**. Proceedings of 18th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. **Anais...** In: PROCEEDINGS OF 18TH ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY. out. 1996

LEWIS, T. REPORT CXIX. AURICULAR FIBRILLATION: A COMMON CLINICAL CONDITION. **British Medical Journal**, v. 2, n. 2552, p. 1528, 27 nov. 1909.

LI, C.; ZHENG, C.; TAI, C. Detection of ECG characteristic points using wavelet transforms. **IEEE Transactions on Biomedical Engineering**, v. 42, n. 1, p. 21–28, jan. 1995.

LIPPMANN, R. An introduction to computing with neural nets. **IEEE ASSP Magazine**, v. 4, n. 2, p. 4–22, abr. 1987.

LOWN, B.; KLEIN, M. D.; HERSHBERG, P. I. Coronary and precoronary care. **The American Journal of Medicine**, Symposium on Atherosclerosis. v. 46, n. 5, p. 705–724, 1 maio 1969.

LUZ, E. J. DA S. et al. ECG-based heartbeat classification for arrhythmia detection: A survey. **Computer Methods and Programs in Biomedicine**, v. 127, p. 144–164, 1 abr. 2016.

LYNN, P. A. Recursive digital filters for biological signals. **Medical & biological engineering**, v. 9, n. 1, p. 37–43, 1 jan. 1971.

MALLAT, S. G. A theory for multiresolution signal decomposition: the wavelet representation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 11, n. 7, p. 674–693, jul. 1989.

MANSUR, A.; FAVARATO, D. Trends in Mortality Rate from Cardiovascular Disease in Brazil, 1980-2012. **Arquivos Brasileiros de Cardiologia**, v. 107, 24 maio 2016.

MARAGOS, P.; SCHAFER, R. **Applications of morphological filtering to image analysis and processing**. ICASSP '86. IEEE International Conference on Acoustics, Speech, and Signal Processing. **Anais...** In: ICASSP '86. IEEE INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH, AND SIGNAL PROCESSING. abr. 1986

MARAGOS, P.; SCHAFER, R. Morphological filters—Part I: Their set-theoretic analysis and relations to linear shift-invariant filters. **IEEE Transactions on Acoustics, Speech, and Signal Processing**, v. 35, n. 8, p. 1153–1169, ago. 1987.

MARTINEZ, J. P. et al. A wavelet-based ECG delineator: evaluation on standard databases. **IEEE Transactions on Biomedical Engineering**, v. 51, n. 4, p. 570–581, abr. 2004.

MARTINS, M. DE A. et al. **Clínica médica, volume 2: doenças cardiovasculares, doenças respiratórias, emergências e terapia intensiva**. 2. ed. Barueri, SP: Editora Manole Ltda., 2016. v. 2

MARTIS, R. J. et al. Characterization of ECG beats from cardiac arrhythmia using discrete cosine transform in PCA framework. **Knowledge-Based Systems**, v. 45, p. 76–82, 1 jun. 2013.

MARTIS, R. J.; ACHARYA, U. R.; MIN, L. C. ECG beat classification using PCA, LDA, ICA and Discrete Wavelet Transform. **Biomedical Signal Processing and Control**, v. 8, n. 5, p. 437–448, set. 2013.

MATEO, J. et al. An efficient method for ECG beat classification and correction of ectopic beats. **Computers & Electrical Engineering**, v. 53, p. 219–229, 1 jul. 2016.

MATHERON, G. **Random Sets and Integral Geometry**. New York: Wiley, 1975.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115–133, 1 dez. 1943.

MOODY, G. B.; MARK, R. G. **MIT-BIH Arrhythmia Database**, 1992. Disponível em: <<https://www.physionet.org/physiobank/database/mitdb/>>. Acesso em: 19 maio. 2017

MOODY, G. B.; MARK, R. G. The impact of the MIT-BIH Arrhythmia Database. **IEEE Engineering in Medicine and Biology Magazine**, v. 20, n. 3, p. 45–50, maio 2001.

MOODY, G. B.; MULDROW, W. K.; MARK, R. G. NOISE STRESS TEST FOR ARRHYTHMIA DETECTORS. **Computers in Cardiology**, n. 11, p. 381–384, 1984.

MORAES, J. C. T. B. et al. **A QRS complex detection algorithm using electrocardiogram leads**. Computers in Cardiology. **Anais...** In: COMPUTERS IN CARDIOLOGY. set. 2002

MOZAFFARIAN, D. et al. Heart Disease and Stroke Statistics—2016 Update: A Report From the American Heart Association. **Circulation**, v. 133, n. 4, p. e38–e360, 26 jan. 2016.

NAJARIAN, K.; SPLINTER, R. **Biomedical signal and image processing**. 2. ed. Boca Raton, FL: CRC Press, 2012.

NIKAN, S.; GWADRY-SRIDHAR, F.; BAUER, M. Pattern Recognition Application in ECG Arrhythmia Classification. **Proceedings of the 10th International Joint Conference on Biomedical Engineering Systems and Technologies**, BIOSTEC 2017. v. 5, p. 48–56, fev. 2017.

NYGÅRDS, M.-E.; SÖRNMO, L. Delineation of the QRS complex using the envelope of the e.c.g. **Medical and Biological Engineering and Computing**, v. 21, n. 5, p. 538–547, 1 set. 1983.

PAHLM, O.; SORNMO, L. Data Processing of Exercise ECG's. **IEEE Transactions on Biomedical Engineering**, v. BME-34, n. 2, p. 158–165, fev. 1987.

PALODETO, V. **SISTEMA COMPUTACIONAL PARA O PROCESSAMENTO, A ANÁLISE E A CLASSIFICAÇÃO DO SINAL ELETROCARDIOGRÁFICO DE NEONATOS E ADULTOS**. Dissertação Mestrado—Florianópolis, SC: Universidade Federal de Santa Catarina, mar. 2006.

PAN, J.; TOMPKINS, W. J. A real-time QRS detection algorithm. **IEEE transactions on bio-medical engineering**, v. 32, n. 3, p. 230–236, mar. 1985.

PASTORE, C. et al. III Diretrizes da Sociedade Brasileira de Cardiologia sobre análise e emissão de laudos eletrocardiográficos. **Arquivos Brasileiros de Cardiologia**, v. 106, n. 4, 2016.

PASTORE, C. A.; SAMESIMA, N.; MUNERATO, R. **ABC do ECG**. [s.l.] Medcel, 2012.

PATEL, U. H.; BABBS, C. F. A computer-based, automated, telephonic system to monitor patient progress in the home setting. **Journal of Medical Systems**, v. 16, n. 2–3, p. 101–112, jun. 1992.

POLI, R.; CAGNONI, S.; VALLI, G. Genetic design of optimum linear and nonlinear QRS detectors. **IEEE Transactions on Biomedical Engineering**, v. 42, n. 11, p. 1137–1141, nov. 1995.

POORNACHANDRA, S. Wavelet-based denoising using subband dependent threshold for ECG signals. **Digital Signal Processing**, v. 18, n. 1, p. 49–55, 1 jan. 2008.

PRECHELT, L. Automatic early stopping using cross validation: quantifying the criteria. **Neural Networks**, v. 11, n. 4, p. 761–767, 1 jun. 1998.

QIN, Q. et al. Combining Low-dimensional Wavelet Features and Support Vector Machine for Arrhythmia Beat Classification. **Scientific Reports**, v. 7, 20 jul. 2017.

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

ROSENBAUM, M. B. Types of right bundle branch block and their clinical significance. **Journal of Electrocardiology**, v. 1, n. 2, p. 221–232, 1 jan. 1968.

ROSENBLATT, F. The Perceptron: A Probabilistic Model for Information Storage and Organization in The Brain. **Psychological Review**, p. 65–386, 1958.

ROSS, K. A. et al. Cross-Validation. In: LIU, L.; ÖZSU, M. T. (Eds.). . **Encyclopedia of Database Systems**. Boston, MA: Springer US, 2009. p. 532–538.

SAYADI, O.; SHAMSOLLAHI, M. B. Multiadaptive Bionic Wavelet Transform: Application to ECG Denoising and Baseline Wandering Reduction. **EURASIP Journal on Advances in Signal Processing**, v. 2007, n. 1, p. 041274, 1 dez. 2007.

SEDGHAMIZ, H. **Matlab Implementation of Pan Tompkins ECG QRS detector**.

Disponível em:

<https://www.researchgate.net/publication/313673153_Matlab_Implementation_of_Pan_Tompkins_ECG_QRS_detector>. Acesso em: 22 jan. 2018.

SERRA, J. **Image analysis and mathematical morphology. Vol. 1: [...]**. 4th print ed. London: Acad. Pr, 1993.

SERRA, J. P. **Image analysis and mathematical morphology**. London ; New York: Academic Press, 1982.

SHADMAND, S.; MASHOUFI, B. A new personalized ECG signal classification algorithm using Block-based Neural Network and Particle Swarm Optimization. **Biomedical Signal Processing and Control**, v. 25, p. 12–23, 1 mar. 2016.

SILVA, I. N. DA; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.

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.

SINGH, B. N.; TIWARI, A. K. Optimal selection of wavelet basis function applied to ECG signal denoising. **Digital Signal Processing**, v. 16, n. 3, p. 275–287, 1 maio 2006.

SIQUEIRA, H. V. **Máquinas desorganizadas para previsão de séries de vazão**. Tese Doutorado—Campinas, SP: Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação, 2013.

SONG, J.; DELP, E. J. **The generalized morphological filter**. Twenty-Third Asilomar Conference on Signals, Systems and Computers, 1989. **Anais...** In: TWENTY-THIRD ASILOMAR CONFERENCE ON SIGNALS, SYSTEMS AND COMPUTERS, 1989. out. 1989

STERNBERG, S. R. Grayscale morphology. **Computer Vision, Graphics, and Image Processing**, v. 35, n. 3, p. 333–355, 1 set. 1986.

STEVENSON, R.; ARCE, G. Morphological filters: Statistics and further syntactic properties. **IEEE Transactions on Circuits and Systems**, v. 34, n. 11, p. 1292–1305, nov. 1987.

STUDENT. The Probable Error of a Mean. **Biometrika**, v. 6, n. 1, p. 1, mar. 1908.

SUN, Y.; CHAN, K. L.; KRISHNAN, S. M. ECG signal conditioning by morphological filtering. **Computers in Biology and Medicine**, v. 32, n. 6, p. 465–479, nov. 2002.

TAYEL, M. B.; ELTRASS, A. S.; AMMAR, A. I. A new multi-stage combined kernel filtering approach for ECG noise removal. **Journal of Electrocardiology**, 18 out. 2017.

TETKO, I. V.; LIVINGSTONE, D. J.; LUIK, A. I. Neural network studies. 1. Comparison of overfitting and overtraining. **Journal of Chemical Information and Computer Sciences**, v. 35, n. 5, p. 826–833, 1 set. 1995.

THAKOR, N. V.; WEBSTER, J. G.; TOMPKINS, W. J. Optimal QRS detector. **Medical & Biological Engineering & Computing**, v. 21, n. 3, p. 343–350, maio 1983.

THOMAS, M.; DAS, M. K.; ARI, S. Automatic ECG arrhythmia classification using dual tree complex wavelet based features. **AEU - International Journal of Electronics and Communications**, v. 69, n. 4, p. 715–721, 1 abr. 2015.

TORTORA, G. J. **Corpo Humano: fundamentos de anatomia e fisiologia**. Porto Alegre: Artmed, 2003.

VETTERLI, M.; HERLEY, C. Wavelets and filter banks: theory and design. **IEEE Transactions on Signal Processing**, v. 40, n. 9, p. 2207–2232, set. 1992.

VINOTH, S. V.; KUMARGANESH, S. Fetal ECG Extraction using LMS Filter. **SSRG International Journal of Electronics and Communication Engineering (SSRG-IJECE)**, v. 3, n. 11, nov. 2016.

WEN, H. et al. Hybrid Structure-Adaptive RBF-ELM Network Classifier. **IEEE Access**, v. 5, p. 16539–16554, 2017.

WEN, H.; XIE, W.; PEI, J. A Structure-Adaptive Hybrid RBF-BP Classifier with an Optimized Learning Strategy. **PLoS ONE**, v. 11, n. 10, 28 out. 2016.

WHO. **Global diffusion of eHealth: making universal health coverage achievable. Report of the third global survey on eHealth**. 1. ed. Geneva: World Health Organization, 2016.

WILSON, F. N. et al. Electrocardiograms that represent the potential variations of a single electrode. **American Heart Journal**, v. 9, n. 4, p. 447–458, 1 abr. 1934a.

WILSON, F. N. et al. The determination and the significance of the areas of the ventricular deflections of the electrocardiogram. **American Heart Journal**, v. 10, n. 1, p. 46–61, 1 out. 1934b.

WIMMER, N. J.; SCIRICA, B. M.; STONE, P. H. The Clinical Significance of Continuous ECG (Ambulatory ECG or Holter) Monitoring of the ST-Segment to Evaluate Ischemia: A Review. **Progress in Cardiovascular Diseases**, Ambulatory ECG Monitoring: Clinical Practice and Research Applications. v. 56, n. 2, p. 195–202, 1 set. 2013.

WOODWARD, B.; ISTEPANIAN, R. S. H.; RICHARDS, C. I. Design of a telemedicine system using a mobile telephone. **IEEE Transactions on Information Technology in Biomedicine**, v. 5, n. 1, p. 13–15, mar. 2001.

YELDERMAN, M. et al. ECG Enhancement by Adaptive Cancellation of Electrosurgical Interference. **IEEE Transactions on Biomedical Engineering**, v. BME-30, n. 7, p. 392–398, jul. 1983.

YU, S.-N.; CHOU, K.-T. Integration of independent component analysis and neural networks for ECG beat classification. **Expert Systems with Applications**, v. 34, n. 4, p. 2841–2846, 1 maio 2008.

ZADEH, A. E.; KHAZAEI, A.; RANAEE, V. Classification of the electrocardiogram signals using supervised classifiers and efficient features. **Computer Methods and Programs in Biomedicine**, v. 99, n. 2, p. 179–194, 1 ago. 2010.

ZHENG, H.; WU, J. **Real-time QRS detection method**. HealthCom 2008 - 10th International Conference on e-health Networking, Applications and Services. **Anais...**
In: HEALTHCOM 2008 - 10TH INTERNATIONAL CONFERENCE ON E-HEALTH NETWORKING, APPLICATIONS AND SERVICES. jul. 2008

ZIDELMAL, Z. et al. QRS detection based on wavelet coefficients. **Computer Methods and Programs in Biomedicine**, v. 107, n. 3, p. 490–496, 1 set. 2012.

ZIDELMAL, Z. et al. ECG beat classification using a cost sensitive classifier. **Computer Methods and Programs in Biomedicine**, v. 111, n. 3, p. 570–577, 1 set. 2013.

APÊNDICE A – Resultados para a Rede Híbrida RBF-ELM com 2 Camadas Escondidas

Tabela 18 – Taxa de acerto no teste do algoritmo RBF-ELM Híbrido com 10 componentes principais com filtragem por Transformada *Wavelet*

		Quantidade de Neurônios na 1ª Camada Escondida							
		100	300	500	700	900	1100	1300	1500
Quantidade de Neurônios na 2ª Camada Escondida	100	91,12 ±1,31	90,36 ±1,14	89,65 ±1,21	89,42 ±1,19	88,64 ±1,24	87,68 ±1,35	87,49 ±1,50	86,44 ±1,20
	300	93,54 ±1,14	93,06 ±1,12	92,26 ±1,01	92,55 ±1,15	92,39 ±1,05	92,10 ±0,99	92,06 ±0,90	91,79 ±0,93
	500	94,30 ±0,92	94,00 ±1,07	93,22 ±1,00	93,09 ±0,93	93,05 ±1,17	93,09 ±0,84	93,08 ±0,92	92,91 ±0,85
	700	94,90 ±1,28	94,56 ±1,00	94,03 ±0,84	93,79 ±1,20	93,40 ±0,87	93,39 ±0,95	93,40 ±0,86	93,47 ±1,13
	900	95,12 ±1,19	94,68 ±0,98	94,40 ±0,88	94,05 ±0,95	93,67 ±0,85	93,70 ±0,82	93,51 ±0,87	93,78 ±0,84
	1100	95,15 ±1,41	94,98 ±1,06	94,63 ±0,93	94,34 ±1,07	93,88 ±1,04	93,57 ±1,14	93,89 ±0,80	93,81 ±0,86
	1300	95,29 ±1,18	95,13 ±1,09	94,81 ±1,04	94,31 ±1,27	94,07 ±1,11	93,73 ±1,09	93,86 ±1,18	94,11 ±1,16
	1500	95,24 ±1,28	95,21 ±1,07	94,81 ±0,87	94,82 ±0,75	94,21 ±1,27	94,33 ±0,96	94,23 ±0,81	94,29 ±1,01

Fonte: Autoria própria

Tabela 19 – Taxa de acerto no teste do algoritmo RBF-ELM Híbrido com 10 componentes principais com filtragem por Filtro Morfológico

		Quantidade de Neurônios na 1ª Camada Escondida							
		100	300	500	700	900	1100	1300	1500
Quantidade de Neurônios na 2ª Camada Escondida	100	91,16 ±2,03	90,62 ±1,52	90,39 ±1,28	89,00 ±1,27	88,80 ±1,04	88,39 ±1,14	87,52 ±1,70	87,02 ±0,79
	300	93,90 ±0,89	93,13 ±1,33	92,56 ±1,17	92,87 ±1,16	92,64 ±1,13	92,83 ±1,13	92,38 ±1,33	92,58 ±0,93
	500	94,84 ±0,98	94,34 ±1,09	92,95 ±1,46	93,45 ±1,19	93,49 ±1,10	93,45 ±0,91	93,27 ±1,07	93,44 ±0,93
	700	95,06 ±1,03	94,65 ±1,08	94,29 ±0,96	93,89 ±1,13	93,77 ±1,15	93,79 ±1,07	93,68 ±1,14	93,88 ±0,93
	900	95,36 ±0,94	94,84 ±1,09	94,68 ±1,11	94,26 ±1,19	94,25 ±1,01	94,11 ±1,10	93,98 ±0,94	94,31 ±1,10
	1100	95,26 ±0,91	95,07 ±1,21	94,93 ±1,12	94,53 ±1,09	94,32 ±1,05	94,16 ±1,06	94,21 ±1,01	94,59 ±1,09
	1300	95,59 ±1,12	95,05 ±1,15	95,17 ±1,14	94,60 ±1,18	94,59 ±1,15	94,63 ±1,07	94,36 ±0,91	94,69 ±1,01
	1500	95,70 ±1,11	95,37 ±1,04	95,15 ±0,93	94,71 ±1,01	94,74 ±1,07	94,96 ±1,17	94,62 ±0,9	94,60 ±1,05

Fonte: Autoria própria

Tabela 20 – Taxa de acerto no teste do algoritmo RBF-ELM Híbrido com 12 componentes principais com filtragem por Transformada *Wavelet*

		Quantidade de Neurônios na 1ª Camada Escondida							
		100	300	500	700	900	1100	1300	1500
Quantidade de Neurônios na 2ª Camada Escondida	100	91,66 ±1,42	90,76 ±1,29	89,81 ±1,49	89,61 ±1,28	89,21 ±1,49	88,44 ±1,43	87,77 ±1,46	87,17 ±0,98
	300	94,22 ±1,22	94,01 ±1,16	93,05 ±1,21	93,52 ±1,27	93,22 ±1,37	92,83 ±1,32	92,91 ±1,24	92,59 ±1,11
	500	95,23 ±1,10	95,01 ±1,14	94,14 ±0,98	94,33 ±1,14	94,08 ±1,25	93,99 ±1,26	94,00 ±1,13	93,63 ±1,09
	700	95,55 ±1,00	95,37 ±1,02	94,83 ±0,97	94,67 ±1,03	94,44 ±1,09	94,49 ±1,00	94,31 ±1,30	94,19 ±0,97
	900	95,77 ±1,12	95,60 ±1,13	95,23 ±0,85	94,71 ±1,19	94,83 ±1,09	94,75 ±1,00	94,65 ±0,99	94,45 ±1,13
	1100	95,95 ±1,09	95,84 ±1,09	95,49 ±0,91	95,25 ±1,08	94,98 ±1,08	94,90 ±1,05	94,90 ±1,06	94,62 ±0,88
	1300	96,05 ±1,12	95,97 ±1,14	95,72 ±1,00	95,41 ±0,94	95,16 ±1,03	94,93 ±1,02	95,03 ±0,95	94,95 ±0,99
	1500	96,17 ±1,14	96,03 ±1,08	95,71 ±1,00	95,47 ±1,09	95,35 ±1,04	95,14 ±1,04	95,06 ±1,02	95,02 ±0,96

Fonte: Autoria própria

Tabela 21 – Taxa de acerto no teste do algoritmo RBF-ELM Híbrido com 12 componentes principais com filtragem por Filtro Morfológico

		Quantidade de Neurônios na 1ª Camada Escondida							
		100	300	500	700	900	1100	1300	1500
Quantidade de Neurônios na 2ª Camada Escondida	100	92,11 ±0,90	90,90 ±1,39	90,39 ±1,46	89,15 ±1,80	88,95 ±0,96	88,96 ±1,24	88,06 ±1,13	87,58 ±1,06
	300	94,48 ±1,14	93,99 ±1,12	93,22 ±1,48	93,56 ±1,30	93,15 ±1,31	93,19 ±1,17	92,94 ±0,98	92,39 ±1,23
	500	95,10 ±1,05	94,89 ±1,19	94,23 ±1,07	94,17 ±1,14	93,91 ±1,24	94,10 ±1,06	93,88 ±1,02	93,70 ±1,18
	700	95,38 ±1,12	95,17 ±1,01	94,72 ±1,07	94,59 ±1,09	94,28 ±1,24	94,45 ±1,16	94,28 ±1,07	94,23 ±1,03
	900	95,64 ±1,16	95,39 ±1,05	95,00 ±1,05	94,73 ±1,17	94,59 ±1,06	94,53 ±1,20	94,48 ±1,07	94,49 ±1,13
	1100	95,76 ±1,05	95,43 ±1,13	95,04 ±1,00	94,92 ±1,12	94,85 ±1,10	94,64 ±1,11	94,63 ±1,10	94,67 ±1,08
	1300	95,82 ±1,20	95,53 ±1,00	95,18 ±0,97	95,01 ±1,20	94,95 ±1,04	95,04 ±1,15	94,89 ±1,08	94,83 ±1,11
	1500	95,87 ±1,13	95,55 ±1,06	95,25 ±0,96	95,21 ±0,95	95,01 ±1,12	94,95 ±1,09	94,95 ±1,05	94,97 ±1,15

Fonte: Autoria própria

Tabela 22 – Taxa de acerto no teste do algoritmo RBF-ELM Híbrido com 14 componentes principais com filtragem por Transformada *Wavelet*

		Quantidade de Neurônios na 1ª Camada Escondida							
		100	300	500	700	900	1100	1300	1500
Quantidade de Neurônios na 2ª Camada Escondida	100	91,44 ±0,96	90,21 ±1,24	90,08 ±1,38	90,18 ±1,30	89,77 ±1,30	88,95 ±1,02	88,59 ±1,26	88,23 ±1,14
	300	94,47 ±0,91	93,92 ±1,15	93,01 ±1,27	94,04 ±1,05	93,95 ±1,17	93,49 ±1,22	93,34 ±1,00	92,93 ±1,08
	500	95,31 ±1,03	95,13 ±1,18	94,28 ±1,20	94,71 ±0,96	94,64 ±1,08	94,49 ±1,12	94,51 ±1,08	94,29 ±1,04
	700	95,76 ±1,10	95,50 ±1,19	94,99 ±1,07	95,18 ±0,91	95,07 ±1,03	94,93 ±1,03	95,08 ±1,00	94,94 ±0,96
	900	96,08 ±1,02	95,92 ±1,08	95,39 ±1,05	95,26 ±1,04	95,31 ±1,00	95,22 ±1,17	95,25 ±1,00	95,13 ±0,91
	1100	96,21 ±1,07	96,10 ±1,06	95,68 ±1,06	95,52 ±1,18	95,41 ±0,93	95,36 ±1,13	95,31 ±0,92	95,32 ±0,99
	1300	96,27 ±1,06	96,13 ±1,03	95,77 ±0,99	95,65 ±1,12	95,56 ±1,00	95,48 ±1,10	95,47 ±1,01	95,46 ±0,91
	1500	96,31 ±1,07	96,15 ±1,10	95,94 ±1,00	95,71 ±1,20	95,69 ±1,12	95,63 ±1,09	95,46 ±1,03	95,49 ±0,95

Fonte: Autoria própria

Tabela 23 – Taxa de acerto no teste do algoritmo RBF-ELM Híbrido com 14 componentes principais com filtragem por Filtro Morfológico

		Quantidade de Neurônios na 1ª Camada Escondida							
		100	300	500	700	900	1100	1300	1500
Quantidade de Neurônios na 2ª Camada Escondida	100	90,85 ±1,93	90,87 ±0,80	90,40 ±0,96	90,05 ±1,33	89,22 ±1,24	88,95 ±1,04	88,47 ±0,86	87,48 ±1,00
	300	94,56 ±1,13	93,94 ±1,07	93,24 ±1,07	93,66 ±1,29	93,48 ±1,34	93,22 ±1,33	93,14 ±1,18	92,58 ±1,33
	500	95,33 ±1,13	95,15 ±1,09	94,13 ±1,22	94,43 ±1,26	94,31 ±1,28	94,17 ±1,31	94,17 ±1,15	93,79 ±1,21
	700	95,62 ±1,11	95,50 ±1,17	94,99 ±1,01	94,87 ±1,13	94,63 ±1,32	94,55 ±1,22	94,48 ±1,18	94,40 ±1,28
	900	95,94 ±1,08	95,71 ±1,12	95,33 ±0,98	95,12 ±1,07	94,95 ±1,20	94,87 ±1,27	94,76 ±1,15	94,66 ±1,33
	1100	95,99 ±1,06	95,84 ±1,08	95,51 ±1,04	95,34 ±1,09	95,19 ±1,22	95,02 ±1,34	94,98 ±1,14	94,81 ±1,31
	1300	96,08 ±1,04	95,92 ±0,96	95,61 ±0,98	95,48 ±1,09	95,38 ±1,16	95,18 ±1,25	95,21 ±1,10	95,02 ±1,27
	1500	96,10 ±1,06	95,99 ±1,00	95,70 ±0,91	95,55 ±1,04	95,48 ±1,16	95,31 ±1,16	95,31 ±1,09	95,20 ±1,24

Fonte: Autoria própria