

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA MECÂNICA**

JÚLIA BERTELLI DUARTE

**INTELIGÊNCIA ARTIFICIAL APLICADA A ANÁLISE DE
ELETROENCEFALOGRAFIA**

UBERLÂNDIA

2018

JÚLIA BERTELLI DUARTE

**INTELIGÊNCIA ARTIFICIAL APLICADA A ANÁLISE DE
ELETROENCEFALOGRAFIA**

Tese apresentada ao Programa de Pós-Graduação de Engenharia Mecânica da Faculdade de Engenharia Mecânica da Universidade Federal de Uberlândia para a obtenção do título de **Doutora em Engenharia Mecânica**.

Área de Concentração: Mecânica dos Sólidos e Vibrações

Orientador: Prof. Dr. Marcus Antonio Viana Duarte

UBERLÂNDIA

2018

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

D812i Duarte, Júlia Bertelli, 1987-
2018 Inteligência artificial aplicada a análise de eletroencefalografia
[recurso eletrônico] / Júlia Bertelli Duarte. - 2018.

Orientador: Marcus Antônio Viana Duarte.
Tese (Doutorado) - Universidade Federal de Uberlândia, Programa
de Pós-Graduação em Engenharia Mecânica.
Modo de acesso: Internet.
Disponível em: <http://dx.doi.org/10.14393/ufu.te.2018.815>
Inclui bibliografia.
Inclui ilustrações.

1. Engenharia mecânica. 2. Eletroencefalografia. 3. Epilepsia. 4.
Algoritmos genéticos. I. Duarte, Marcus Antônio Viana (Orient.) II.
Universidade Federal de Uberlândia. Programa de Pós-Graduação em
Engenharia Mecânica. III. Título.

CDU: 621

Maria Salete de Freitas Pinheiro - CRB6/1262



ALUNA: Júlia Bertelli Duarte

NÚMERO DE MATRÍCULA: 11313EMC017

ÁREA DE CONCENTRAÇÃO: Mecânica dos Sólidos e Vibrações

LINHA DE PESQUISA: Dinâmica de Sistemas Mecânicos

PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA: NÍVEL DOUTORADO

TÍTULO DA TESE:

“Inteligência Artificial Aplicada a Análise de Eletroencefalografia”

ORIENTADOR: Prof. Dr. Marcus Antonio Viana Duarte

A Tese foi **APROVADA** em reunião pública, realizada no Auditório do Laboratório de Mecânica dos Fluidos - Bloco 5P, Campus Santa Mônica, em 26 de fevereiro de 2018, às 14:00 horas, com a seguinte Banca Examinadora:

NOME	ASSINATURA
Prof. Dr. Marcus Antonio Viana Duarte	UFU
Prof. Dr. Antonio Marcos Gonçalves de Lima	UFU
Prof. Dr. Francisco Paulo Lépore Neto	UFU
Prof. Dr. Luciano Luporini Menegaldo	COPPE/UFRJ
Prof. Dr. Nilson Barbieri	PUCPR

Uberlândia, 26 de fevereiro de 2018

À minha família. Base de tudo.

Amo vocês!

AGRADECIMENTOS

Agradeço primeiramente à Deus, que esteve sempre ao meu lado, mesmo nas tribulações, de onde tirei forças para continuar e terminar este caminho. À minha mãezinha, Maria Santíssima, por passar a frente e seguir comigo pelos caminhos, por mais tortuosos que estes parecessem.

Ao meu pai duas vezes, e orientador, Marcus Antonio Viana Duarte, por nunca desistir de mim e acreditar na minha capacidade para realizar este trabalho. Por todas as discussões, puxões de orelha, conselhos. Você é o meu maior exemplo de profissional, íntegro, competente e correto. E também o melhor pai do mundo. Amo você!

À minha mãe, Isabel, por ser o elo de ligação entre meu pai, quando ele não queria me dar broncas. E por todas as cobranças para que eu conseguisse terminar este trabalho. Te amo!

Ao meus irmãos e cunhadas, Ricardo, André, Paulinha e Ju, por estarem sempre presentes em minha vida e por estarem ao meu lado, independente da escolha que eu faça.

Aos meus amigos por todo apoio e risadas.

Aos meus amigos e colegas da UFTM, por permitirem que eu me dedicasse integralmente para a conclusão deste trabalho.

Ao Doutor Antônio Costa, por me apresentar este assunto tão intrigante e interessante que me desafiou.

Ao Programa de Pós-Graduação da Faculdade de Engenharia Mecânica e à Universidade Federal de Uberlândia pela oportunidade de desenvolver este trabalho.

Para cada dia basta os seus próprios problemas.

(Mt 6,34)

DUARTE, JB. Inteligência Artificial aplicada à análise de Eletroencefalografia [tese].
Uberlândia: Faculdade de Engenharia Mecânica, Universidade Federal de Uberlândia, 2018.

RESUMO

O desenvolvimento tecnológico da eletrônica, interligado ao crescimento no conhecimento científico sobre as causas das doenças humanas no final de século XX, possibilitou desenvolver novos equipamentos e técnicas diagnósticas e terapêuticas na Medicina. Um sistema de inteligência artificial deve ser capaz de armazenar conhecimento, aplicar este conhecimento na resolução de problemas e adquirir novos conhecimentos através da experiência. A medicina atualmente gasta um longo tempo na análise de exames neurológicos que em sua maioria não apresentam alguma anomalia. Para auxiliar o especialista, deseja-se desenvolver um programa, baseado em inteligência artificial, capaz de separar os sinais cerebrais em sinais com e sem anomalias. Sinais de eletroencefalograma serão utilizados neste trabalho devido à grande necessidade de programas para auxílio ao seu diagnóstico. Para isto, utilizou-se de um banco de dados disponível publicamente de Bern-Barcelona, que consiste em sinais com presença de ictal (evento no sinal causado por uma crise epilética) e sem a presença de ictal. Para avaliação dos procedimentos desenvolvidos, utilizou-se das métricas de sensibilidade, especificidade, precisão, valores positivos preditos, valores negativos preditos e coeficiente de correlação de Mathew. Utilizou-se seis procedimentos de classificação (kNN, WkNN, LDA, QDA, PNN e MLP-BP) e dois algoritmos de otimização (algoritmo genético e evolução diferencial) para testar a eficiência destes na classificação de sinais focais e não focais. Já para o cálculo dos sintomas, utilizou-se de técnicas de análise de sinais, como a análise estatística clássica (valor RMS e curtose, por exemplo), Transformadas Wavelet e de Hilbert-Huang, análise envelope e cálculos de entropia e k-NEO. De uma pré-análise, os parâmetros que mais se repetiram como possíveis sintomas foram Valor RMS, fator de crista e curtose, com 15, 14 e 10 ocorrências respectivamente. Os melhores resultados observados foram utilizando evolução diferencial em conjunto com WkNN, que resultou numa precisão de aproximadamente 84%.

Palavras-chave: Eletroencefalografia. Epilepsia. Transformada Wavelet. Transformada de Hilbert Huang. k-NEO. Entropia. Análise Envelope. Análise Discriminante Linear. Análise Discriminante Quadrática. *k-Nearest Neighbor*. WkNN. Rede Neural Probabilística. Perceptron multicamadas. Algoritmos Genéticos. Evolução Diferencial.

DUARTE, JB. Artificial Intelligence applied to Electroencephalography analysis [thesis]. Uberlândia: Faculdade de Engenharia Mecânica, Universidade Federal de Uberlândia, 2018.

ABSTRACT

The technological development of electronics, linked to growth of scientific knowledge on the causes of human diseases in the late twentieth century, made it possible to develop new equipment and diagnostic and therapeutic techniques in Medicine. An artificial intelligence system must be able to stock knowledge, applied this knowledge and acquire new knowledge through experience. The physics spend a large time in neurological exams analysis and most of all are not an anomaly. To assist the specialist, we want to develop a program, based on artificial intelligence, capable of separating the brain signals into signs with and without anomalies. Electroencephalogram signs are used in this work because of the great need for programs to aid in their diagnosis. To do this, an available database of Bern-Barcelona are used, which consists of signs with and without the presence of ictal (signal event caused by an epileptic seizure). For the evaluation of the developed processes, we used the metrics of sensitivity, specificity, accuracy, positive predictive values, negative predictive values and Mathew correlation coefficient. We used six classification procedures (kNN, WkNN, LDA, QDA, PNN and MLP-BP) and two optimization algorithms (genetic algorithm and differential evolution) to test an application of these in the classification of focal and non-focal signals. For calculation of symptoms, statistical analysis such as a classical statistical analysis (RMS value and kurtosis, for example), Wavelet and Hilbert-Huang Transforms, analysis envelope and entropy and k-NEO calculations are used. From a pre-analysis, the parameter that most repeat as possible symptoms as RMS value, crest factor and kurtosis, with 15, 14 and 10 occurrences respectively. The best results observed is using WkNN, with differential evolution, which resulted in an accuracy of approximately 84%.

Keywords: Electroencephalography. Epilepsy. Wavelet Transform. Hilbert Huang Transform. k-NEO. Entropy. Envelope Analysis. Linear Discriminant Analysis. Quadratic Discriminant. k-nearest neighbor. WkNN. Probabilistic Neural Network. Multilayer Perceptron. Genetic Algorithms. Differential Evolution.

LISTA DE ILUSTRAÇÕES

Figura 2.1. Desenho esquemático de um neurônio motor.....	8
Figura 2.2. O Sistema Internacional 10-20 visto de (a) esquerda e (b) acima da cabeça. A = Lóbulo da orelha, C = central, Pg = nasofaríngea, P = parietal, F = frontal, Fp = polar frontal, O = occipital.....	11
Figura 2.3. Arranjo de eletrodos do tipo Unipolar e Dipolar.....	12
Figura 2.4. EEG normal com olhos fechados em um estado de vigília	13
Figura 2.5. Olhos abertos. Artefatos de movimento vertical dos olhos e Reação Berger (bloqueio da atividade alfa).....	13
Figura 2.6. Ritmos característicos e a comparação dos ritmos durante uma crise epilética.	14
Figura 2.7. Gráfico de uma senóide.	21
Figura 2.8. Diagrama para extração das características e pontos definidos pelo modelo..	23
Figura 2.9. Diagrama de blocos para ilustrar o Aprendizado Supervisionado.	29
Figura 2.10. Arquitetura de uma rede MLP-BP com duas camadas ocultas.	30
Figura 2.11. Fluxograma de um Algoritmo Genético Simples.	32
Figura 3.1. Sinais adquiridos do banco de dados de Bern-Barcelona: (a) Sinal focal do EEG e (b) Sinal não focal do EEG.	37
Figura 3.2. Exemplo de um diagrama de caixa.....	42
Figura 3.3. Fluxograma da Metodologia Proposta.....	45
Figura 4.1. Diagrama de caixas para o parâmetro ValorRMS	48
Figura 4.2. Diagrama de caixas para o parâmetro V_P	48
Figura 4.3. Diagrama de caixas para o parâmetro V_{PP}	49
Figura 4.4. Diagrama de caixas para o parâmetro S_k	49
Figura 4.5. Gráfico de um sinal não focal do banco de dados, a título de exemplo	50
Figura 4.6. Boxplot para o parâmetro K_x	51
Figura 4.7. Boxplot para o parâmetro K_4	51
Figura 4.8. Boxplot para o parâmetro FC	52
Figura 4.9. Diagrama de caixa para o estimador K_6	53
Figura 4.10. Diagrama de caixa para V_p filtrado em Gama, unipolar, não normalizado...	53
Figura 4.11. Diagrama de caixa para os parâmetros filtrados na banda otimizada.....	55

Figura 4.12. Melhores parâmetros observados para os sinais unilaterais normalizados filtrados com Gama	56
Figura 4.13. Melhores parâmetros observados para os sinais unilaterais normalizados filtrados com Usuário	57
Figura 4.14. Melhores parâmetros observados para os sinais dipolares normalizados filtrados com Gama (3.142 e 3.154) e Usuário (3.165, 3.167 e 3.168)	57
Figura 4.15. Diagrama de caixa para os sinais unipolares tratados com escala delta da WT.	58
Figura 4.16. Diagrama de caixa para os sinais dipolares tratados com escala delta da WT.	59
Figura 4.17. Diagrama de caixa para os sinais dipolares tratados com escala teta da WT.	60
Figura 4.18. Diagrama boxplot para os sinais unipolares tratados com escala alfa da WT.	60
Figura 4.19. Diagrama boxplot para os sinais dipolares tratados com escala alfa da WT.	61
Figura 4.20. Diagrama de caixas para os sinais unipolares tratados com escala beta da WT	62
Figura 4.21. Diagrama boxplot para os sinais unipolares tratados com escala gama da WT	63
Figura 4.22. Diagrama boxplot para os sintomas de FC mais relevantes, da análise de envelope dos sinais tratados por WT.....	64
Figura 4.23. PSD dos primeiros dois modos intrínsecos para o sinal focal.	65
Figura 4.24. PSD dos modos intrínsecos três e quatro para o sinal focal.....	65
Figura 4.25. PSD dos modos intrínsecos cinco e seis do sinal focal.	65
Figura 4.26. Densidade Espectral de Potência dos primeiros modos intrínsecos para o conjunto de dados não focal.	66
Figura 4.27. Melhores parâmetros observados para o primeiro modo empírico.....	67
Figura 4.28. Melhores parâmetros observados para as EMD.....	67
Figura 4.29. Melhores parâmetros observados para a HHT do primeiro modo.	68
Figura 4.30. Melhores parâmetros observados para a HHT do segundo modo.....	69
Figura 4.31. Melhores parâmetros observados para a HHT do terceiro modo.....	69
Figura 4.32. Melhores parâmetros observados para a análise k-NEO.....	70
Figura 5.1. Gráfico dos tempos de processamento para todos os sintomas calculados.....	73
Figura 5.2. Gráfico dos tempos de processamento para os sintomas calculados, excluindo os relacionados a EMD.....	73

Figura 5.3. Influência média do número de parâmetros na precisão do algoritmo kNN. ...	79
Figura 5.4. Influência do fator k na precisão do algoritmo kNN.	79
Figura 5.5. Influência média do número de parâmetros na precisão do algoritmo WkNN.	85
Figura 5.6. Influência do fator k na precisão do algoritmo kNN.	85
Figura 5.7. Gráfico de dispersão para os dois sintomas escolhidos no QDA.	88
Figura 5.8. Diagrama de caixas com os sintomas para a melhor configuração, WkNN com sete parâmetros.....	93

LISTA DE TABELAS

Quadro 2.1. Comparação entre as bandas encontradas em EEG.....	9
Tabela 4.1. Quantidade de candidatos a sintoma para cada um dos oito parâmetros analisados.	71
Tabela 5.1. Valores obtidos para a classificação por kNN.....	74
Tabela 5.1. Valores obtidos para a classificação por kNN.....	75
Tabela 5.1. Valores obtidos para a classificação por kNN.....	76
Quadro 5.2. Sintomas escolhidos para a configuração de kNN com N_p igual a 5 e k igual a 13.....	77
Quadro 5.3. Sintomas escolhidos para a configuração de kNN com N_p igual a 8 e k igual a 13.....	77
Tabela 5.4. Valores médios, e respectivos desvios padrões, para as métricas de avaliação de desempenho, para as melhores configurações para kNN.	78
Tabela 5.5. Valores obtidos para a classificação por WkNN.	80
Tabela 5.5. Valores obtidos para a classificação por WkNN.	81
Tabela 5.5. Valores obtidos para a classificação por kNN.....	82
Quadro 5.6. Sintomas escolhidos para a configuração de W kNN com N_p igual a 4 e k igual a 13.	83
Quadro 5.7. Sintomas escolhidos para a configuração de WkNN com N_p igual a 7 e k igual a 11.....	83
Quadro 5.8. Sintomas escolhidos para a configuração de WkNN com N_p igual a 7 e k igual a 13.....	83
Tabela 5.9. Valores médios, e respectivos desvios padrões, para as métricas de avaliação de desempenho, para as melhores configurações para WkNN.	84
Tabela 5.10. Valores obtidos para a classificação por LDA e passo 1.....	86
Quadro 5.11. Sintomas escolhidos para a configuração de LDA com N_p igual a 4.	87
Tabela 5.12. Valores médios, e respectivos desvios padrões, para as métricas de avaliação de desempenho, para a melhor configuração para LDA com passo 1.....	87
Tabela 5.13. Valores obtidos para a classificação por QDA e passo 1.	89
Quadro 5.14. Sintomas escolhidos para a configuração de QDA com N_p igual a 6.....	89
Tabela 5.15. Valores médios, e respectivos desvios padrões, para as métricas de avaliação de desempenho, para a melhor configuração para QDA com passo 1.	90

Tabela 5.16. Valores obtidos para a classificação via PNN.....	90
Quadro 5.17. Sintomas escolhidos para a classificação via PNN com N_p igual a 3.	91
Tabela 5.18. Valores médios, e respectivos desvios padrões, para as métricas de avaliação de desempenho, para a PNN com três parâmetros.....	91
Tabela 5.19. Valores obtidos para a classificação via MLP-BP.	92

LISTA DE SÍMBOLOS

Letras Arábicas

A	Amplitude do sinal
J	Número imaginário
T	Tempo [s]
E	Número de Euler
H	Transformada de Hilbert
$x(t)$	Sinal no domínio do tempo
A	Fator de dilatação
B	Translação da origem
T	Período [s]
V_P	Valor Pico
V_{PP}	Valor Pico a Pico
S_k	Assimetria
M'_3	Momento central de terceira ordem
K_x	Curtose
M'_4	Momento central de quarta ordem
FC	Fator de Crista
N	Número inteiro, tamanho amostral
I	Índice inteiro
K	Parâmetro de resolução
P	Candidato a pico
A	Início do pico
B	Fim do pico
Q	Máximo local da onda lenta
R	Ponto final da onda lenta
Dur_{AP}	Duração da primeira meia onda do pico
$\overline{AP_x}$	Projeção do vetor AP no eixo x
Dur_{PB}	Duração da segunda meia onda do pico
$\overline{PB_x}$	Projeção do vetor PB no eixo x
Dur_{spike}	Soma das durações para o pico

<i>Dur_slowwave</i>	Soma das durações para a onda lenta
$\overline{BQ_x}$	Projeção do vetor BQ no eixo x
$\overline{QR_x}$	Projeção do vetor QR no eixo x
<i>Amp_AP</i>	Amplitude da primeira meia onda do pico
$\overline{AP_y}$	Projeção do vetor AP no eixo y
<i>Amp_PB</i>	Amplitude da segunda meia onda do pico
$\overline{PB_y}$	Projeção do vetor PB no eixo y
<i>Amp_spike</i>	Média das amplitudes para o pico
<i>Amp_slowwave</i>	Média das amplitudes para a onda lenta
$\overline{BQ_y}$	Projeção do vetor BQ no eixo y
$\overline{QR_y}$	Projeção do vetor QR no eixo y
<i>Slope_AP</i>	Inclinação da primeira meia onda do pico
<i>Slope_PB</i>	Inclinação da segunda meia onda do pico
<i>Slope_sharpness</i>	Nitidez do pico
<i>Area_spike</i>	Área do pico
x_A	Posição do ponto A
x_B	Posição do ponto B
S_1	Área definida na Fig. 2.10
<i>Area_slowwave</i>	Área da onda lenta
x_R	Posição do ponto R
S_2	Área definida na Fig. 2.10
$ShEn_{avg}$	Entropia média de Shannon
$RenEn_{Avg}$	Entropia média de Renyi
$ApEn_{Avg}$	Entropia aproximada média
$SpEn_{Avg}$	Entropia média da amostra
$S1_{Avg}$	Entropia média de fase 1
$S2_{Avg}$	Entropia média de fase 2
D	Função Discriminante de Fisher
M	Ponto médio entre as médias populacionais
SEM	Sensibilidade
SPF	Especificidade
ACC	Precisão
X_{focal}	Matriz de sintomas para o conjunto de dados focal

X_{nfocal}	Matriz de sintomas para o conjunto de dados não focal
TP	Verdadeiro positivo
TN	Verdadeiro negativo
FN	Falso positivo
FP	Falso negativo
$\overline{X_{Focal}}$	Média amostral do conjunto focal
$\overline{X_{nFocal}}$	Média amostral do conjunto não focal
S_{Focal}^2	Variância amostral do conjunto focal
S_{nFocal}^2	Variância amostral do conjunto não focal
Coef	Vetor com a posição do sintomas selecionados pelos procedimentos de otimização
N_p	Número de parâmetros utilizados na classificação
N_a	Quantidade de conjunto de sintomas para treinamento
N_t	Quantidade de conjunto de sintomas para avaliação
N	Número de vezes que o procedimento se repete
n_1	Tamanho da amostra 1
n_2	Tamanho da amostra 2
R_1	Soma das fileiras das observações para amostra 1.
R_2	Soma das fileiras das observações para amostra 1.
ACC_v	Precisão para o conjunto de dados utilizado para a validação
ACC_t	Precisão média para o conjunto dados utilizado para o teste
s_t	Desvio padrão do conjunto de dados para teste

Letras Gregas

Ω	Frequência angular portadora
ω	Frequência angular moduladora
φ	Ângulo de fase
ϕ	Ângulo de fase
ψ	Função wavalet de base
σ	Desvio padrão populacional
μ	Média populacional
ψ_k	Cálculo do k-NEO

Σ Matriz comum de covariância entre populações

Lista de Abreviaturas

EEG	Eletroencefalograma
ECG	Eletrocardiograma
IA	Inteligência Artificial
WT	Transformada Wavelet
PCA	Análise de Componentes Principais
dB4	Função Daubechies 4
DWT	Transformada Wavelet Discreta
MLP-BP	Rede Perceptron multicamadas com retropropagação do erro
HHT	Transformada de Hilbert-Huang
RNA	Rede Neural Artificial
MDA	Análise Discriminante Múltipla
LDA	Análise Discriminante Linear
QDA	Análise Discriminante Quadrática
kNN	<i>k-Nearest Neighbor</i>
LVQ	Aprendizagem por Quantização Vetorial
SVM	Máquina de Vetores de Suporte
GA	Algoritmo Genético
ED	Evolução Diferencial
LF	Baixa Frequência
HF	Alta Frequência
HOS	Espectro de Alta Ordem
ICA	Análise de Componentes Independentes
IMF	Função de Modos Intrínsecos
EMD	Modo de Decomposição Empírico
HSA	Análise Espectral de Hilbert
PNN	Rede Neural Propabilística
RMS	Valor Médio Quadrático
k-NEO	<i>k-point Nonlinear Energy Operator</i>
NEO	<i>Nonlinear Energy Operator</i>

PPV	Valores Positivos Preditos
NPV	Valores Negativos Preditos
MCC	Coefficiente de Correlação de Mathew
WkNN	kNN ponderado pela distância
PSD	Densidade Espectral de Potência

SUMÁRIO

1. INTRODUÇÃO	1
1.1. OBJETIVO.....	5
1.2. ORGANIZAÇÃO DA TESE	6
2. FUNDAMENTOS TEÓRICOS	7
2.1. O CÉREBRO HUMANO.....	7
2.2. ELETROENCEFALOGRAFIA.....	8
2.3. FUNDAMENTO DE ANÁLISE DE SINAIS	14
2.3.1. Análise De Componentes Principais (PCA).....	14
2.3.2. Análise De Componentes Independentes (ICA).....	15
2.3.3. Análise Envelope.....	16
2.3.4. Função de Modos Intrínsecos (IMF)	18
2.3.5. Decomposição em Modos Empíricos (EMD).....	18
2.3.6. Transformada De Hilbert Huang (HHT)	19
2.3.7. Transformada Wavelet.....	19
2.3.8. Análise estatística clássica no domínio do tempo: Valor RMS, Valor Pico, Valor Pico a Pico, Assimetria, Curtose, Fator de Crista, k_4 e k_6	20
2.3.8.1. Valor Médio Quadrático (RMS), Valor Pico (V_P) e Valor Pico a Pico (V_{PP})	20
2.3.8.2. Assimetria (Skewness – S_k)	21
2.3.8.3. Curtose (K_x)	21
2.3.8.4. Fator de Crista (FC)	22
2.3.8.5. Estimadores k_4 e k_6	22
2.3.9. Estimador <i>k-point nonlinear energy operator</i> (k-NEO).....	22
2.3.10. Medidas de Entropia	25
2.4. REDES NEURAS ARTIFICIAIS.....	28
2.5. ALGORITMOS GENÉTICOS.....	31

2.6. EVOLUÇÃO DIFERENCIAL	32
2.7. ANÁLISE DISCRIMINANTE MÚLTIPLA.....	33
2.7.1. Análise Discriminante Linear (LDA).....	33
2.7.2. Análise Discriminante Quadrática	34
2.7.3. k-Nearest Neighbor	34
3. MATERIAIS E MÉTODOS.....	36
3.1. ESCOLHA DO BANCO DE DADOS	36
3.2. AVALIAÇÃO DOS PROCEDIMENTOS	38
3.3. DETECTORES E PARÂMETROS (SINTOMAS) UTILIZADOS.....	39
3.4. ANÁLISE PRELIMINAR DOS PARÂMETROS UTILIZADOS	41
3.4.1. Diagrama de Caixa.....	41
3.5. PROCEDIMENTOS DE CLASSIFICAÇÃO UTILIZADOS.....	43
3.6. PROCEDIMENTOS DE OTIMIZAÇÃO	43
3.7. FLUXOGRAMA DA METODOLOGIA UTILIZADA	43
3.8. ROTINAS DE PROGRAMAÇÃO E PARÂMETROS UTILIZADOS.....	45
4. ANÁLISE PRELIMINAR DOS PARÂMETROS ESTUDADOS	47
4.1. ANÁLISE PRELIMINAR DOS PARÂMETROS ESTATÍSTICOS CLÁSSICOS	47
5. APRESENTAÇÃO E ANÁLISE DOS RESULTADOS OBTIDOS.....	72
5.1. TEMPO NECESSÁRIO PARA O CÁLCULO DOS PARÂMETROS	72
5.2. MELHORES SINTOMAS USANDO kNN	74
5.2. MELHORES SINTOMAS UTILIZANDO DE WkNN COMO CLASSIFICADOR	80
5.3. MELHORES SINTOMAS USANDO LDA.....	86
5.4. MELHORES SINTOMAS USANDO QDA	87
5.5. MELHORES SINTOMAS USANDO PNN	90
5.6. MELHORES SINTOMAS USANDO MLP-BP	91
5.7. CONSIDERAÇÕES FINAIS SOBRE O CAPÍTULO	92

6. CONCLUSÕES	94
6.1. TRABALHOS FUTUROS.....	95

CAPÍTULO I

INTRODUÇÃO

O desenvolvimento tecnológico da eletrônica, interligado ao crescimento no conhecimento científico sobre as causas das doenças humanas no final de século XX, possibilitou desenvolver novos equipamentos e técnicas diagnósticas e terapêuticas na Medicina (Sabbatini, 1995).

O organismo humano é considerado o mais completo e a mais “perfeita” máquina do universo, sendo composto por cerca de 100 trilhões de células, e, dentre elas, 2 bilhões morrem diariamente. A manutenção dessa máquina é feita pelos sistemas nervoso, circulatório e linfático (Oda, 2013). Quando algo não está ocorrendo bem, o corpo humano emite diferentes sinais e das mais variadas naturezas.

Define-se sinal biológico como uma variável medida em organismos vivos, a tempo contínuo ou em amostras periódicas e esses podem ser de natureza elétrica, ou bioelétricas (sinais cardíacos medidos por eletrocardiograma – ECG, sinais sinápticos medidos por Eletroencefalograma – EEG, movimento dos olhos medidos por eletro-oculograma, tônus muscular medido por eletromiograma), mecânica (pressão arterial, força da contração muscular), química (PH, glicemia, teor alcoólico no sangue), térmica, magnética (sinais cardíacos medidos por Magnetocardiograma e sinais sinápticos medidos por Magnetoencefalograma) entre outros (Gomes, 2003).

Atualmente, já se reconhece cinco tipos de ondas cerebrais, sendo elas: delta (0,5 a 4 Hz), teta (4 a 8 Hz), alfa (8 a 13 Hz), beta (13 a 30 Hz) e gama (acima de 30 Hz), com características, faixas de tensões e frequências diferentes. As ondas delta normalmente ocorrem quando se está em sono profundo, com uma variação de 75 a 200 mV, já a teta raramente é presente em seres humanos. Ondas alfa são quando a pessoa está em vigília, ondas beta com aumento de vigilância e atenção e a onda gama para movimentos voluntários do organismo. (Blinowska e Durka, 2006).

A medicina atualmente gasta um longo tempo na análise de exames que em sua maioria não apresentam alguma anomalia. Para o caso do neurologista, mais de 80% dos exames analisados são considerados bons, sem anomalias. Sinais de eletroencefalograma (EEG) serão utilizados

neste trabalho devido à grande necessidade de programas para auxílio ao seu diagnóstico, além de o especialista gastar longo tempo para analisar horas de registros (Travessa, 2006).

Haikin (2011) toma emprestada a definição de IA dada por Sage nos anos 1990, que diz que: “o objetivo da IA é o desenvolvimento de paradigmas ou algoritmos que requeiram máquinas para realizar tarefas cognitivas, para as quais os humanos são altamente melhores”. Dito isso, vale ressaltar que um sistema de IA deve ser capaz de armazenar conhecimento, aplicar este conhecimento na resolução de problemas e adquirir novos conhecimentos através da experiência, tendo, portanto, três componentes fundamentais: representação, raciocínio e aprendizagem (Sage, 1990 apud Haikin, 2011).

Muitos trabalhos já foram desenvolvidos na área. Helena (2004) em sua tese de doutorado utilizou de Transformadas Wavelet (WT) para detectar fusos de sono – ondas cerebrais bem definidas e uma das componentes de EEG – em adultos jovens e diz que a necessidade de desenvolver uma análise automática do sono tem dois objetivos básicos: reduzir o tempo gasto na análise visual e explorar novas medidas quantitativas e suas relações com certos tipos de distúrbios do sono.

Adeli, Zhou e Dadmehr (2003) usaram da WT para analisar e caracterizar descargas epileptiformes na forma de picos de 3-Hz e onda complexa em pacientes com crise de ausência ou pequeno mal. A crise de ausência é um dos principais tipos de convulsão e sua fisiopatologia não é completamente compreendida, sendo diagnosticada pelos especialistas principalmente por análise visual do sinal. Ao aplicar WT nos sinais de EEG, os autores verificaram que as características transientes foram precisamente localizadas nos dois domínios, tempo e frequência, porém para se utilizar dessa ferramenta matemática, faz-se necessário conhecer e identificar a melhor família de Wavelet para cada aplicação.

Negri (2014) utiliza em sua monografia, duas famílias de WT (Daubechies 4 – dB4 – e Coiflet 1) e três níveis para detecção de crise epilética em sinais de EEG. Foram analisadas medidas de desempenho como média de acertos e porcentagem de picos em crise, para verificar a eficiência da metodologia apresentada. Após aplicar a WT, utilizou-se da técnica de limiarização, cujo objetivo é destacar os picos para verificação da existência destes no local da ocorrência da crise, com três limiares para identificar as crises epiléticas, sendo elas, 30, 50 e 80% do valor máximo de pico do sinal avaliado. A autora destaca que ambas as famílias de wavelet utilizadas geraram resultados muito parecidos. Quanto ao limiar, apesar de 30% ter maior média de acertos (em torno de 75%), possui baixa porcentagem de picos (em torno de 15%). Isso se dá devido a falsos positivos. A melhor configuração obtida foi Coiflet 1 com 50% de limiar, resultando em 65,96% de média de acertos e 37,32% de picos.

Cheong, Sudirman e Hussin (2015) utilizaram da Transformada Discreta de Wavelet (DWT) para extrair características, que foram utilizadas numa rede neural do tipo MLP-BP para classificar níveis leves, moderados e severos de autismo. O banco de dados utilizado é composto por sinais obtidos de 30 crianças autistas com idades entre 3 e 10 anos, sendo 5 delas com autismo médio, 11 com autismo moderado e 14 com autismo severo. Os autores obtiveram um nível de acerto de 92,3%, utilizando a família dB4 para a wavelet, 8 camadas ocultas na rede neural, 65% dos dados para treinamento, 25% para validação e 10% para teste da rede.

Faust, Acharya, Adeli H. e Adeli A. (2015) fizeram um estudo para avaliar a utilização das transformadas de wavelet no processamento de sinais de EEG, com o intuito de verificar a aplicação das análises auxiliadas por computador para a detecção de convulsões e diagnóstico de epilepsia.

Abbasi e Esmailpour (2017) também utilizaram de DWT e MLP-BP, porém com o intuito de desenvolver um novo método para detectar espasmos epiléticos, através da seleção de características estatísticas dos sinais cerebrais. Os autores alegam que houve uma melhora significativa na sensibilidade, especificidade e precisão (em torno de 98%).

Bachmann, Lass e Hinrikus (2017) propuseram um método simples para detecção de depressão, a partir da análise de um único canal a curto prazo em sinais de EEG. Para essa detecção, utilizaram da análise espectral de potência, pelo cálculo da assimetria linear e por análise de flutuação não linear. Ao combinar linearmente as duas técnicas resultou numa precisão de classificação de 91%.

Observa-se muitos trabalhos utilizando da Transformada de Hilbert Huang (HHT) para análise de sinais tanto cerebrais quanto cardíacos, como também de sistemas mecânicos, como por exemplo, rolamentos.

Hsu, Lian, Huang e Chou (2014) utilizam de HHT para processar sinais de variabilidade da frequência cardíaca com o intuito de associar a frequência cardíaca à sonolência ao dirigir, uma vez que a maioria dos acidentes de trânsito ocorrem devido a cansaço. Os autores utilizam a densidade espectral de potência da relação entre banda de baixa frequência e de alta frequência (LF/HF) para detectar a sonolência nos motoristas. Resultados mostram que a relação diminui quando o indivíduo passa do estado de alerta para o estado de sonolência.

Zhu e Lin (2014), por sua vez, basearam-se em HHT para explorar as características de tempo-frequência de ondas de pico para os sintomas da epilepsia, analisando principalmente a energia do espectro de Hilbert. Os autores detectaram diferenças significativas entre a energia do sinal com ondas de pico e sem essas ondas, em torno de mais de 10%. Para a função residual,

a diferença também foi alta, uma razão de 27,36% para uma onda normal e 12,37% para uma onda com picos.

As redes neurais estão sendo largamente utilizadas, juntamente com as ferramentas de análise de sinais, para a classificação de sinais de EEG.

Travessa (2006) propõe em sua dissertação a utilização de rede neural do tipo MLP com o algoritmo de retropropagação-complexo para separar as espículas das piscadas em sinais de EEG.

Ponten, Tewarie, Slooter, Stam e Van Dellen (2013) utilizaram de modelagem de redes neurais em padrões de EEG para poder compreender a fisiopatologia das alterações de encefalopatias no EEG utilizando simulações de atividades cerebrais.

Aliabadi, Keynia e Abdali (2013) e Omerhodzic, Avdakovic, Nuhanovic e Dizdarevic (2013) utilizam de redes neurais artificiais em sinais de EEG que detectam epilepsia. O primeiro utiliza de redes neurais para o diagnóstico de epilepsia enquanto que o segundo utiliza de RNA com Wavelet para verificar a distribuição de energia em sinais de EEG.

O grande problema dos trabalhos já publicados na área é que os mesmos procuram detectar doenças específicas e não se tem alguma anomalia no sinal, independente do que seja, ou seja, deseja-se analisar apenas um tipo de doença, como epilepsia ou retirada de artefatos, como o piscar dos olhos.

O grande problema das metodologias baseadas em sintomas de análise de sinais para a classificação de sinais de EEG reside na dificuldade de identificar, quantificar os valores limites e os parâmetros a serem utilizados bem como se as variações nos sinais são artefatos ou alguma anomalia.

Uma outra metodologia para identificação é a análise discriminante múltipla (MDA), uma técnica estatística para análise multivariada de dados. Esta técnica é adequada quando a variável dependente é dicotômica e não-métrica, caso deste trabalho, onde deseja-se classificar os sinais de acordo com a presença ou não de patologias. A MDA tem por objetivo primário entender diferenças de grupos e prever a probabilidade de que uma entidade pertencerá ou não a uma determinada classe de acordo com suas variáveis independentes métricas (Hair, Black, Babin, Anderson, Tatham, 2009).

Dentre as funções existentes para se fazer a MDA, a função de análise discriminante linear (LDA), ou discriminante linear de Fisher, a função discriminante quadrática (QDA) e a função *k-Nearest Neighbor* (KNN) são as mais utilizadas e conhecidas.

Kim, Choi, Moon e Mun (2010), compararam, em um estudo, as funções LDA, QDA e KNN para classificação de sinais relativos a movimento de pulso obtidos por eletromiograma.

As taxas de reconhecimento foram de 84,9% para kNN, 82,4% para QDA e 81,1% para LDA. Houve uma diferença estatisticamente significativa entre os algoritmos kNN e LDA.

Dixon e Brereton (2009) fizeram um estudo para comparar o desempenho de cinco classificadores representados como métodos de fronteira como dependentes da estrutura de dados. Os classificadores analisados foram: Distância Euclidiana aos Centroides, LDA, QDA, Aprendizagem por Quantização Vetorial (LVQ) e Máquina de Vetores de Suporte (SVM). Os autores desejavam provar que a qualidade do método escolhido deve depender da distribuição das amostras no espaço de variáveis, e que nem sempre a comparação de diferentes métodos de classificação, utilizando critérios como a porcentagem classificada corretamente em um conjunto de testes como um indicador do desempenho do algoritmo, com o intuito de demonstrar qual método é “melhor”, pode ser aplicada.

Para isso, Dixon e Brereton (2009) utilizaram de quatro conjuntos de dados sintéticos cada um com 200 amostras divididos entre duas classes, e outros dois conjuntos de dados sintéticos contendo 400 amostras, igualmente divididos entre as duas classes. Os autores concluem que o desempenho dos classificadores depende sim, e muito, da forma como os dados estão distribuídos. Abordagens como LVQ e SVM que tentam determinar limites complexos são melhores quando os dados normalmente não são distribuídos, mas podem ser propensos a superar o contrário. O QDA tende a desempenhar melhor desempenho em dados multinormais, embora possa ser influenciado por variáveis não discriminativas que mostram uma diferença de variância. Por fim, os autores recomendam observar a estrutura de dados antes da construção do modelo para determinar qual o melhor modelo aplicado para o caso em estudo.

Murugappan (2011) utilizou de WT associada a kNN para classificação de emoções humanas, utilizando de sinais de EEG. Primeiramente, adquiriu-se sinais com 62 eletrodos ativos, os mesmos foram filtrados nas cinco bandas de frequência (alfa, beta, gama, teta e delta) usando Transformada Wavelet. Após, selecionou-se dois conjuntos diferentes de eletrodo, um com 24 canais e outro com 62 canais. kNN dá uma taxa máxima de classificação média de 82,87% em 62 canais e 78,57% em 24 canais, respectivamente.

1.1. OBJETIVO

Analisando os trabalhos publicados na área, observa-se que os procedimentos utilizados para classificação dos sinais cerebrais possuem como foco poucos parâmetros relacionados ao problema. Esta tese tem então, por objetivo, envolver o maior número de parâmetros que venham a ser candidatos à detecção de sinais focal (sinal que se detectou o primeiro evento

como crise epilética) e não focal, através da análise de EEG, e, com isso, avaliar tanto a eficácia dos mesmos quanto o tempo de processamento.

Para isto, deseja-se usar técnicas avançadas de análises de sinais, associadas a redes neurais artificiais ou análise discriminante, e algoritmos de otimização, como Algoritmos Genéticos (GA) e Evolução Diferencial (ED). Pretende-se caracterizar e classificar sinais sinápticos cerebrais adquiridos via Eletroencefalografia quanto à existência de possíveis patologias (epilepsia, morte encefálica, doenças degenerativas, por exemplo) e não existência de patologias como os falsos positivos e artefatos. Neste trabalho não será focado o tipo da doença e sim a presença ou ausência de anomalias que possam ser associadas a patologias,

1.2. ORGANIZAÇÃO DA TESE

Para tanto, o trabalho é dividido em cinco capítulos. No Capítulo I é apresentado o estado da arte, uma breve introdução teórica para situar o tema da tese e seus objetivos. No Capítulo II é apresentada uma revisão bibliográfica, bem como a fundamentação teórica utilizada para a realização deste trabalho. O Capítulo III apresenta a metodologia utilizada. Já no Capítulo IV, é feita uma análise prévia via análise de diagramas de caixas e no Capítulo V são apresentados e discutidos os resultados obtidos através das diferentes abordagens apresentadas. Por fim, no Capítulo VI são mostradas as principais conclusões com possíveis trabalhos futuros.

CAPÍTULO II

FUNDAMENTOS TEÓRICOS

Apresenta-se neste capítulo os fundamentos teóricos necessários para a realização da tese. Inicialmente, é importante conhecer e entender o cérebro humano, bem como um breve histórico sobre o surgimento de eletroencefalografia e as técnicas de medição dos sinais sinápticos cerebrais. Apresenta-se também os cálculos estatísticos convencionais e não convencionais utilizados para o cálculo dos sintomas e também uma breve explicação sobre os métodos de Inteligência Artificial utilizados: Redes Neurais artificiais, Algoritmos Genéticos, Evolução Diferencial e Análise Discriminante Múltipla.

2.1. O CÉREBRO HUMANO

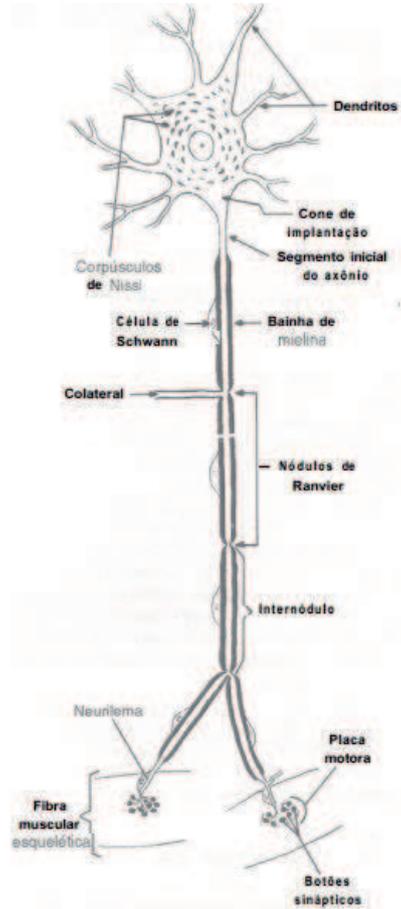
Inicialmente, para conseguir formular o problema, é necessário entender o funcionamento do cérebro humano. O cérebro é um órgão do corpo humano que faz parte do sistema nervoso central, responsável, de um ponto fisiológico, por servir como estrutura física subjacente da mente. Já do ponto de vista biológico, o cérebro é responsável por gerar comportamentos que promovam o bem-estar de um animal. O cérebro controla o comportamento, seja ativando músculos, seja causando a secreção de substâncias químicas, como os hormônios.

O tecido nervoso compreende basicamente dois tipos celulares: os neurônios e as células gliais ou neuroglia. O neurônio é a sua unidade fundamental, com a função básica de receber, processar e enviar informações. A neuroglia compreende células que ocupam os espaços entre os neurônios, com funções de sustentação, revestimento ou isolamento, modulação da atividade neuronal e defesa. (Machado e Campos, 2013)

Ainda de acordo com Machado e Campos (2013), os neurônios são células altamente excitáveis que se comunicam entre si usando uma linguagem elétrica, ou seja, modificações do potencial da membrana. A membrana celular separa dois ambientes que apresentam composições iônicas próprias: o meio intracelular (citoplasma), onde predominam íons orgânicos com cargas negativas e potássio e o meio extracelular, onde predominam sódio e cloro. As cargas elétricas dentro e fora da célula são responsáveis pelo estabelecimento de um

potencial elétrico de membrana, gerando assim um sinal elétrico. A Figura 2.1 mostra um neurônio motor.

Figura 2.1. Desenho esquemático de um neurônio motor.



Fonte: Machado (2013)

2.2. ELETROENCEFALOGRAFIA

A eletroencefalografia (EEG) é o estudo do registro gráfico das correntes elétricas desenvolvidas no encéfalo, realizado através de eletrodos aplicados no couro cabeludo, na superfície encefálica, ou até mesmo dentro da substância encefálica.

“Desde a descoberta, por Luigi Galvani, em 1784, que o tecido nervoso é eletricamente excitável, a neurofisiologia lentamente começou a desvendar as propriedades da bioeletrogênese, ou seja, a geração de impulsos elétricos em nervos e músculos. Este trabalho foi realizado ao longo do século XIX, por cientistas como Emil du Bois-Reymond, que, ajudados por sucessivos desenvolvimentos técnicos que permitiam a medida de correntes elétricas cada vez menores, passaram a

estudar com crescente detalhe as propriedades da atividade elétrica do sistema nervoso. O registro da atividade cerebral exigia a detecção de correntes e potenciais elétricos uma ou duas ordens de magnitude mais débeis do aqueles registrados em nervos e músculos, por isso ele teve que esperar por um maior progresso na eletrotécnica. Isso veio a ocorrer mais tarde, com o desenvolvimento de galvanômetros e eletrômetros de maior sensibilidade, como o eletrômetro de d'Arsonval, o galvanômetro refletor, inventado por Lord Kelvin em 1858, o eletrômetro de Edelman e o eletrômetro capilar de mercúrio, inventado por Gabriel Lippmann (1845-1921), em 1873. Estes instrumentos já eram capazes de medir correntes da ordem de algumas dezenas de microamperes. Foi apenas na década de 1920, no entanto, que a neurociência conseguiu determinar que o cérebro humano também apresentava atividade elétrica na forma de ondas oscilantes constantes. Em 1929, um neurologista e psiquiatra alemão chamado Hans Berger (1873-1921), que trabalhava na Universidade de Jena, na Alemanha, anunciou ao mundo científico e médico que era possível registrar as fracas correntes elétricas geradas no cérebro humano, sem a necessidade de abrir o crânio, e mostrá-las na forma de um registro em papel. Berger denominou a esta nova forma de registro fisiológico de eletroencefalograma (ou EEG); e determinou que existiam dois ritmos dominantes, a que ele determinou ritmos alfa (de 8 a 10 ciclos por segundo) e beta (de 12 a 20 ciclos por segundo). Esta atividade mudava de características de acordo com o estado funcional do cérebro, tais como após estimulações sensoriais, no sono, na anestesia, na hipóxia (falta de oxigênio) e em certas doenças nervosas, como a epilepsia". (Sabattini, 2003)

Hoje, já reconhece-se cinco tipos de ondas cerebrais, sendo elas: delta, teta, alfa, beta e gama. Tatum (2014) apresenta em seu trabalho uma comparação entre as bandas existentes em EEG, bem como as patologias dentro de cada banda. O Quadro 2.1 mostra essa comparação.

Quadro 2.1. Comparação entre as bandas encontradas em EEG.

Banda	Frequência (Hz)	Funções Normais	Patologias
Sub-Delta	0,0 – 0,5	<ul style="list-style-type: none"> • Artefatos 	<ul style="list-style-type: none"> • ritmo interictal e ictal com crises focais
Delta	0,5 – 3,5	<ul style="list-style-type: none"> • Sono • Hiperventilação • Ondas lentas na juventude • Idosos 	<ul style="list-style-type: none"> • encefalopatia • lesões estruturais envolvendo a substância branca cerebral

Quadro 2.1. Comparação entre as bandas encontradas em EEG.

(conclusão)

Teta	3,5 - < 8	<ul style="list-style-type: none"> • sonolência • crianças • Idosos 	<ul style="list-style-type: none"> • Encefalopatia metabólica • Lesões (menor correlação que a Delta)
Alfa	8 – 13	<ul style="list-style-type: none"> • Ritmo posterior dominante • Ritmo Mu • “Terceiro” Ritmo 	<ul style="list-style-type: none"> • ritmo ictal com convulsões • coma
Beta	13 – 30	<ul style="list-style-type: none"> • efeito de medicação • sonolência 	<ul style="list-style-type: none"> • Ritmo “<i>Breach</i>” • overdose por drogas (contínuo e com alta amplitude) <ul style="list-style-type: none"> • ritmo ictal associadas a crises
Gamma	30 – 80	<ul style="list-style-type: none"> • Movimento motor voluntário • Aprendizagem • Memória 	<ul style="list-style-type: none"> • Convulsões
Mu	8 – 12	<ul style="list-style-type: none"> • Neurônios motores em estado de descanso 	<ul style="list-style-type: none"> • Supressão Mu pode indicar que os neurônios espelhos motores <i>mirror neurons</i> estão trabalhando. Deficiência na supressão Mu pode desempenhar um papel no autismo.
	80 – 250	<ul style="list-style-type: none"> • Processamento Cognitivo • Consolidação da memória episódica 	<ul style="list-style-type: none"> • Frequência de crises interictal e ictal <ul style="list-style-type: none"> • Epileptogenesis
	250 – 500	<ul style="list-style-type: none"> • 	<ul style="list-style-type: none"> • Convulsões
	500 – 1000	<ul style="list-style-type: none"> • Aquisição de informação sensorial 	<ul style="list-style-type: none"> • Convulsões

Fonte: Tatum (2014)

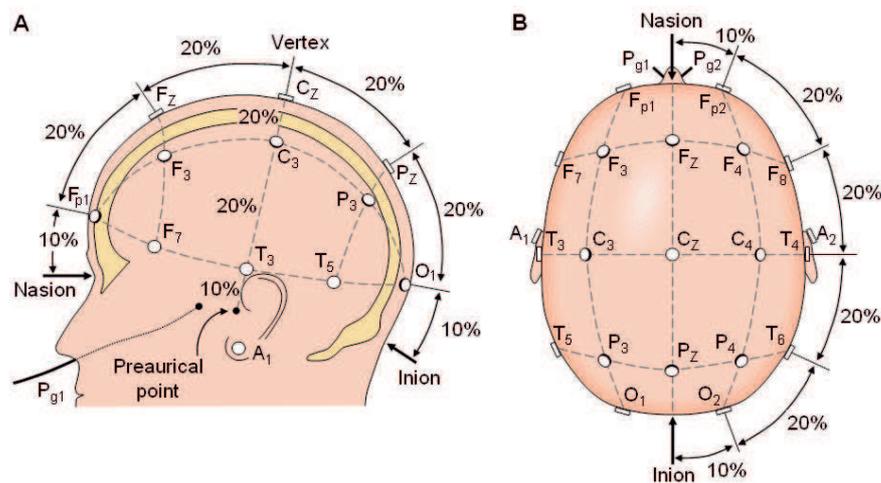
Para realizar um EEG, faz-se necessária a utilização de 22 a 23 eletrodos que captam o sinal cerebral, sendo um de referência cardíaca (ECG). O Sistema Internacional 10-20 faz uso de 21 eletrodos (excluindo os eletrodos localizados nos lóbulos das orelhas, que são utilizados como

referência A1 e A2). Os eletrodos ímpares estão à esquerda e os pares à direita (Sanei e Chambers, 2007).

O Sistema Internacional 10-20 normalmente é empregado para registrar o EEG espontâneo. Neste sistema, os eletrodos estão localizados na superfície do couro cabeludo, como mostrado nas Fig. 2.2a e 2.2b. As posições são determinadas da seguinte forma: os pontos de referência são nasion, que é o ponto superior do nariz, nivelado com os olhos e inion, que é o nódulo ósseo na base do crânio na linha média na parte de trás da cabeça. A partir desses pontos, os perímetros do crânio são medidos nos planos transversal e médio. Os locais de eletrodos são determinados dividindo esses perímetros em intervalos de 10% e 20%. Três outros eletrodos são colocados de cada lado equidistantes dos pontos vizinhos, como mostrado na Fig. 2.2b. (Malmivuo e Plonsey, 1995).

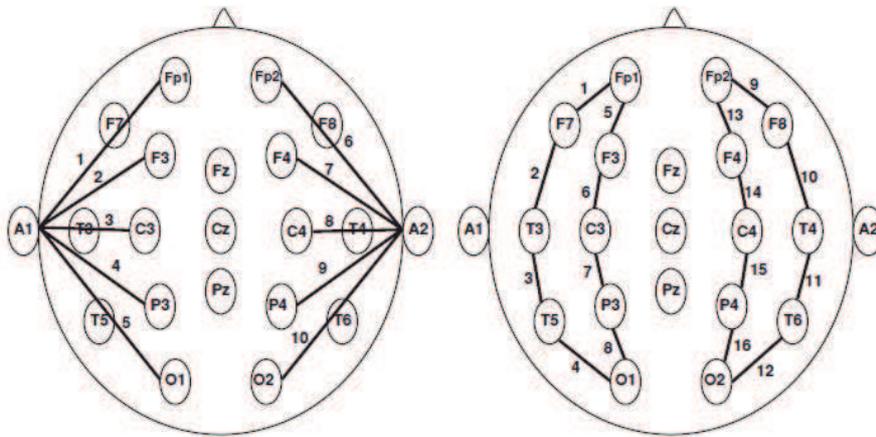
Já a Fig. 2.3 mostra o arranjo dos eletrodos usados na medição do EEG que podem ser unipolares ou dipolares. No primeiro, o potencial de cada eletrodo é comparado a um eletrodo neutro ou à média de todos os eletrodos, enquanto que nos dipolares, a diferença de potencial entre um par de eletrodos é medida.

Figura 2.2. O Sistema Internacional 10-20 visto de (a) esquerda e (b) acima da cabeça. A = Lóbulo da orelha, C = central, Pg = nasofaríngea, P = parietal, F = frontal, Fp = polar frontal, O = occipital.



Fonte: Malmivuo e Plonsey (1995)

Figura 2.3. Arranjo de eletrodos do tipo Unipolar e Dipolar.



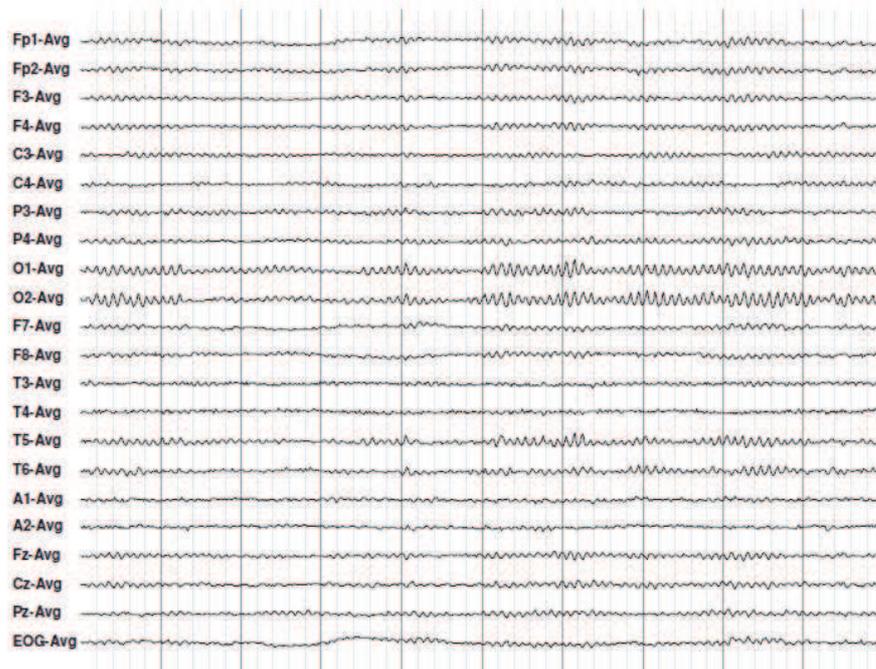
Fonte: Domínio Público

Tatum, Husain, Benbadis e Kaplan (2008) em seu livro “*Handbook of EEG Interpretation*” apresenta vários exemplos de EEG normais bem como os patológicos, ambos com artefatos. Artefatos são alterações nos sinais que não tem nenhuma ligação com anomalias cerebrais. Podem ser divididos por:

- Artefatos Técnicos: muitas vezes presente apenas em um canal, sobreposto a atividade cerebral, exibindo uma distribuição absurda ou campo elétrico. São considerados artefatos técnicos: eletrodos defeituosos, aterramento, interferência eletromagnética, ruído de rede entre outros;
- Artefatos Biológicos: início súbito e/ou rescisão do sinal; padrão cresce/decrece, várias outras frequências que ocorrem em diferentes regiões. São considerados artefatos biológicos: atividade muscular, eletrocardiogramas, pulso cardíaco, respiração, movimentos corporais, movimento dos olhos entre outros.

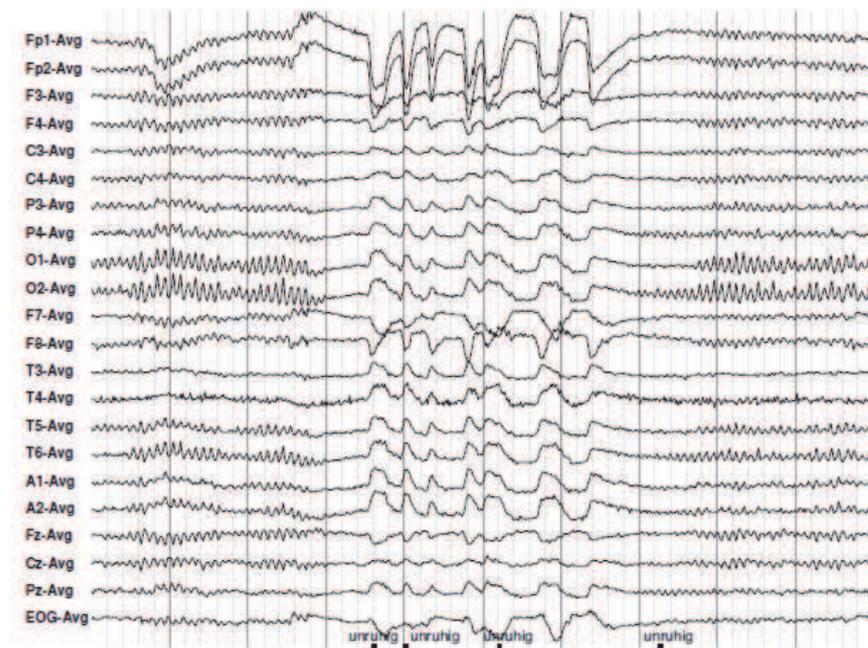
A Figura 2.4 é um exemplo de EEG considerado sem patologia. Já a Figura 2.5 é um exemplo de EEG considerado sem patologia porém com a presença de um artefato. E a Figura 2.6 é um EEG com epilepsia.

Figura 2.4. EEG normal com olhos fechados em um estado de vigília



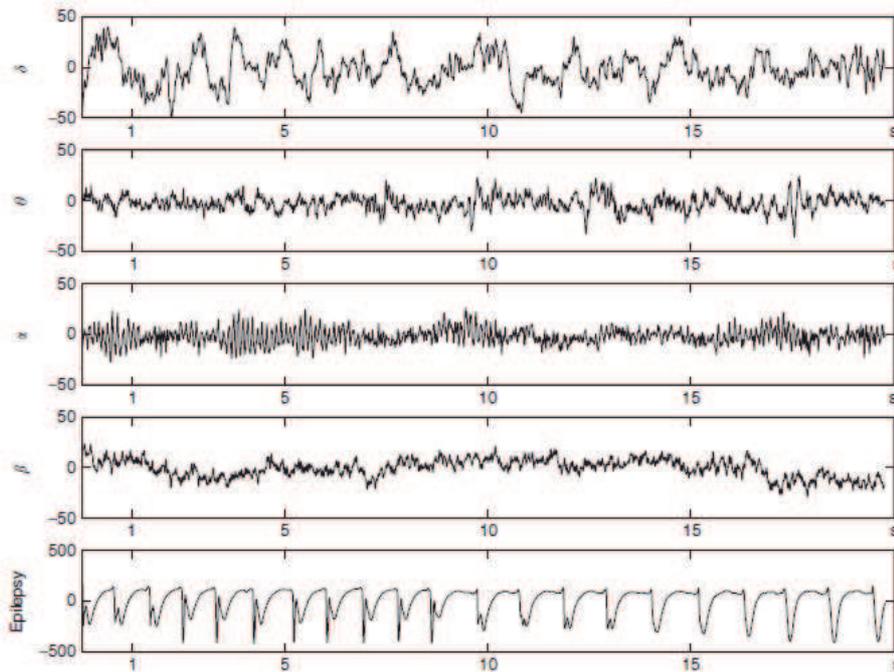
Fonte: Tatum et al (2008)

Figura 2.5. Olhos abertos. Artefatos de movimento vertical dos olhos e Reação Berger (bloqueio da atividade alfa).



Fonte: Tatum et al (2008)

Figura 2.6. Ritmos característicos e a comparação dos ritmos durante uma crise epiléptica.



Fonte: Tatum et al (2008)

Ao analisar as figuras, percebe-se a grande dificuldade que é a definição do que é artefato (Fig. 2.5) e o que é patologia (Fig. 2.6), bem como definir as características do sinal fazendo uma análise apenas temporal.

2.3. FUNDAMENTO DE ANÁLISE DE SINAIS

Fez-se também uma pequena revisão das técnicas de análise de sinais associadas a sinais biológicos em geral. As principais técnicas estão especificadas a seguir:

2.3.1. Análise De Componentes Principais (PCA)

A Análise de Componentes Principais (PCA) foi desenvolvida por Karl Pearson em 1901 para resolver problemas de aplicação em análise estatística multivariada, com o intuito de agregar valores dispersos em medições numéricas (Kolenikov e Angeles, 2004). É, então, uma técnica estatística multivariada que descreve um conjunto de observações correlacionadas em termos de um novo conjunto de variáveis não correlacionadas e ortogonais, chamados de componentes principais, que são combinações lineares das variáveis originais. A transformação dos dados para o domínio PCA é realizada pela decomposição da matriz de covariância em

valores e vetores próprios (Abdi e Willians, apud Ribeiro, Braga Jr, Horgan, Ferreira e Sáfadi, 2014).

Os componentes principais apresentam propriedades importantes: cada componente principal é uma combinação linear de todas as variáveis originais, são independentes entre si e estimados com o propósito de reter, em ordem de estimação, o máximo de informação, em termos da variação total contida nos dados. A análise de componentes principais é associada à ideia de redução de massa de dados, com menor perda possível da informação (Varella, 2008).

O objetivo de utilizar PCA, ou seja, uma transformação linear, em sinais biológicos é reduzir e compactar os dados obtidos ao mensurar o sinal, por exemplo, de EEG, uma vez que o mesmo contém muita informação e o tempo de coleta é muito longo para cada paciente, ocupando muito espaço computacional.

Ribeiro et al (2014) aplica PCA na análise espectral de padrões de laser *speckle* dinâmico, que é um fenômeno que interpreta padrões ópticos formados iluminando uma superfície sob mudanças com luz coerente. PCA nesse trabalho foi usado para filtrar dados com o objetivo de reduzir tempo computacional e melhorar a robustez da filtragem.

Já Carvalho e Dantas Filho (2014) estudaram a qualidade da gasolina e a composição química utilizando PCA. Uma vez que os resultados de composição química cromatográfica e dos parâmetros físico-químicos das amostras de gasolina constituem dados multivariados e foram interpretados aplicando PCA como ferramenta quimiométrica, para melhor explorar a relação entre amostras e variáveis, possibilitando discriminar sua variabilidade de acordo com a similaridade apresentada pelas amostras coletadas em diferentes distribuidoras de combustíveis.

Ghaedi, Ghaedi, Abdi, Roosta, Sahraei e Daneshfar (2014) utilizam de PCA combinada com redes neurais artificiais e otimização via algoritmo genético para avaliar os efeitos das variáveis em nanopartículas de sulfeto de cobre em carvão ativado com o intuito de remover corantes da água.

2.3.2. Análise De Componentes Independentes (ICA)

A Análise de Componentes Independentes pode ser vista como uma extensão da PCA, que só pode impor a independência até segunda ordem e, conseqüentemente, define direções que são ortogonais. ICA foi inicialmente proposto por Herault e Jutten por volta de 1986 graças a sua semelhança com PCA e consiste em encontrar uma transformação linear que minimiza a dependência estatística entre seus componentes (Comon, 1994), de forma que essa

representação linear seja feita para dados não-gaussianos cujos componentes são estatisticamente independentes, ou tão independentes quanto possível (Hyvärinen e Oja, 2000).

ICA foi inicialmente desenvolvido para problemas do tipo “*cokctail party*”. Hyvärinen e Oja (2000) citam como aplicação de ICA sinais elétricos de atividade cerebral gravados por EEG, que consiste em gravações de potencial elétrico em diferentes posições do escalpo. Estes potenciais são gerados misturando alguns componentes subjacentes de atividades cerebrais, o que seria similar a um problema do tipo “cocktail party”, deseja-se encontrar a componente original da atividade cerebral, mas só podemos observar misturas de componentes. ICA pode revelar informações interessantes sobre a atividade do cérebro, dando acesso a suas componentes independentes.

ICA é largamente utilizado em sinais cerebrais obtidos via EEG com o intuito de se retirar os artefatos, que são alterações nos sinais que não tem nenhuma ligação com anomalias cerebrais, tais como movimento de olho, movimento involuntário muscular, ruído de rede, entre outros.

Shih, Liao, Huang, Fang, Cauwenberghs e Jung (2013) apresentam uma variação de ICA, chamada ORICA que é uma análise de componentes independentes recursiva on-line, uma vez que algoritmos ICA não são adequados para a execução em um ambiente em tempo real. Neste trabalho, os autores apresentam uma metodologia utilizando de controles integrados VLSI como hardware de processador ORICA em tempo real para separação do sinal EEG multicanal.

Shou e Ding (2014) apresentaram um estudo comparativo entre os métodos ICA e CSD da detecção de erros em sinais de EEG espacial-espectral-temporal. Os autores concluem que o método ICA possui desempenho superior em relação ao original e CSD na redução de correlação mútua entre os sinais processados, e também na melhoria da sensibilidade de detecção de sinais relacionados com erros, especialmente em atividades oscilatórias em janelas de pré e pós estímulo.

2.3.3. Análise Envelope

Um sinal modulado em fase é um sinal que contém informação de fase variante no tempo. Uma representação simples de um sinal com modulação de fase é dado pela Eq. 2.1.

$$x(t) = A \sin(\Omega t + \phi + \beta \sin(\omega t + \varphi)) \quad (2.1)$$

Onde A é a amplitude do sinal, Ω é a frequência angular portadora, ω é a frequência angular moduladora e φ e ϕ são ângulos de fase.

A demodulação de um sinal, então, implica na reconstrução do sinal de maneira que o histórico temporal da variação de fase seja extraída do sinal original.

Para a Eq. 2.1, numa primeira aproximação, utilizou-se uma transformada cosseno inversa, o que resultaria num resultado errôneo, visto que a função cosseno, por exemplo, tem como ambiguidade o fato de não haver distinção entre os ângulos do primeiro quarto e do segundo com o terceiro quadrantes, respectivamente.

Entretanto, expressando a Eq. 2.1 na forma complexa, resulta na Eq. 2.2.

$$x(t) = Ae^{j[\Omega t + \phi + \beta \sin(\omega t + \varphi)]} \quad (2.2)$$

As características de fase para qualquer instante de tempo podem ser obtidas observando o ângulo entre a parte real e a imaginária do sinal complexo para qualquer instante de tempo. Um sinal complexo que carrega as informações de fase é conhecido como sinal analítico.

Utilizando a formulação de Euler, expressa pela Eq. 2.3, o exemplo dado pela Eq. 2.1 pode ser representado na forma analítica adicionando ao sinal original um seno com a fase instantânea do sinal original multiplicado pela unidade imaginária j .

$$e^{j\theta} = \cos \theta + j \sin \theta \quad (2.3)$$

Em resumo, para construir um sinal analítico, basta achar uma função que transforme um cosseno em um seno. A função que faz isto é a transformada de Hilbert, sendo que:

$$H[\sin(t)] = -\cos(t) \text{ e } H[\cos(t)] = \sin(t)$$

Onde H é a transformada de Hilbert do sinal.

Em última análise, um sinal analítico pode ser representado, utilizando Hilbert, pela Eq. 2.4.

$$\tilde{x}(t) = x(t) + jH[x(t)] \quad (2.4)$$

2.3.4. Função de Modos Intrínsecos (IMF)

Huang, Shen, Long, Wu, Shih, Zheng, Yen, Tung e Liu (1998) propuseram uma classe de funções denominadas como Funções de Modos Intrínsecos (IMF), com o intuito de satisfazer, fisicamente, as condições necessárias para definir uma frequência instantânea significativa, ou seja, deve-se ter funções simétricas em relação à média local igual a zero e que a quantidade de máximos e mínimos locais seja igual a quantidade de cruzamentos por zero.

Sendo assim, os autores definiram uma IMF como sendo uma função que satisfaça as seguintes condições (Huang *et al*, 1998):

- Em um conjunto de dados, o número de extremos e o número de cruzamentos por zero devem ser iguais ou diferir em pelo menos um;
- O valor médio do envelope definido pelos máximos locais e o do envelope definido pelos mínimos locais deve ser zero, em qualquer ponto;
- A IMF gerada não pode ter nenhum mínimo local com valor acima de zero e nenhum máximo local com valor abaixo de zero.

2.3.5. Decomposição em Modos Empíricos (EMD)

O método de decomposição em modos empíricos é utilizado para reduzir os dados nas IMFs necessárias. É um método que trabalha com dados não estacionários e não-lineares, é intuitivo, direto, a posteriori e adaptativo. A EMD tem por essência, identificar os modos intrínsecos em suas escalas de tempo de forma empírica, e, posteriormente, decompor esses dados (Huang *et al*, 1998).

Segundo Huang *et al* (1998), a decomposição é baseada nos seguintes pressupostos:

- O sinal deve possuir pelo menos dois valores extremos, sendo um valor máximo e um valor mínimo;
- A escala de tempo é definida pelo lapso de tempo entre os extremos;
- Se os dados possuírem apenas pontos de inflexão, sem que estes sejam extremos, então o sinal pode ser diferenciado quantas vezes forem necessárias para revelar os extremos. O resultado final pode ser obtido realizando a integração dos componentes.

Uma maneira sistemática de extrair as IMF é chamada de *sifting*. Este método pode ser encontrado detalhadamente em Huang *et al* (1998). De maneira resumida, encontra-se

inicialmente os pontos de máximo e de mínimo locais do sinal. Estes pontos (máximos e mínimos) serão interligados por uma interpolação cúbica, chamada de envelope superior para os pontos de máximo e inferior para os pontos de mínimo. Após, calcula-se a média entre os dois envelopes, gerando a primeira componente, que é a diferença entre o sinal e essa média. Vale ressaltar que o processo pode se repetir caso a componente encontrada não atenda às condições necessárias para ser uma IMF. Caso isso ocorra, a nova componente é encontrada pela diferença entre a componente anterior e a média dos envelopes para essa interação.

Ao encontrar a IMF, esta componente pode ser separada a partir do sinal original, o que gera um resíduo (diferença entre o sinal original e a IMF). Se esse resíduo também conter informações sobre o sinal, assume-se que este é um novo dado e o processo de *sifting* é aplicado nesse resíduo.

2.3.6. Transformada De Hilbert Huang (HHT)

A Transformada de Hilbert Huang (HHT) vem sendo largamente utilizada uma vez que é uma técnica de decomposição de sinais utilizada para sinais não-lineares e não-estacionários, que não podem ser resolvidos utilizando da Transformada de Fourier.

HHT é uma boa ferramenta para se decompor sinais em funções de modos intrínsecos (IMF) e obter dados de frequência instantaneamente e é dividido em duas partes: na primeira o EMD é utilizado para decompor o sinal em várias IMF. Feito isso, as IMF selecionadas são transformadas no espectro de Hilbert através da Transformada de Hilbert. A análise espectral de Hilbert (HSA) fornece uma maneira de analisar os dados de frequência da IMF como funções do tempo (Hsu et al, 2014). A HHT nada mais é que a implementação de EMD somada a transformada de Hilbert, ou técnica de envelope.

2.3.7. Transformada Wavelet

A Transformada Wavelet é muito utilizada para identificação de epilepsia em sinais de EEG. Uma função wavelet é a interpretação de uma onda de curta duração com crescimento e decrescimento rápidos. Sua teoria baseia-se na representação de funções em diferentes escalas e diferentes resoluções (tempo-escala), considerando assim uma das suas principais características (DAUBECHIES, 1992, apud Silva, 2008).

A WT é, na verdade, uma análise espectral de Fourier, porém possui uma janela ajustável, que são chamadas de funções de base. Tem por definição geral a Eq. 2.5 (Huang *et al*, 1998).

$$W(a, b; X, \psi) = |a|^{-\frac{1}{2}} \int_{-\infty}^{\infty} X(t) \psi^* \left(\frac{t - b}{a} \right) dt \quad (2.5)$$

Onde: $\psi^*(.)$ é a função wavelet de base que satisfaz as condições para cada problema, a é o fator de dilatação e b é a translação da origem.

Apesar de não aparecer explicitamente, a variável $1/a$ é referente a escala de frequência e b é a escala temporal.

2.3.8. Análise estatística clássica no domínio do tempo: Valor RMS, Valor Pico, Valor Pico a Pico, Assimetria, Curtose, Fator de Crista, k_4 e k_6 .

2.3.8.1. Valor Médio Quadrático (RMS), Valor Pico (V_P) e Valor Pico a Pico (V_{PP})

O valor médio quadrático (RMS), também chamado de valor eficaz, é uma das medidas mais importantes de amplitude, pois leva em conta tanto a cronologia da onda, como também considera o valor de amplitude que está diretamente ligado à energia contida na onda, indicando o poder destrutivo da vibração. Este pode ser calculado através da Eq. 2.6.

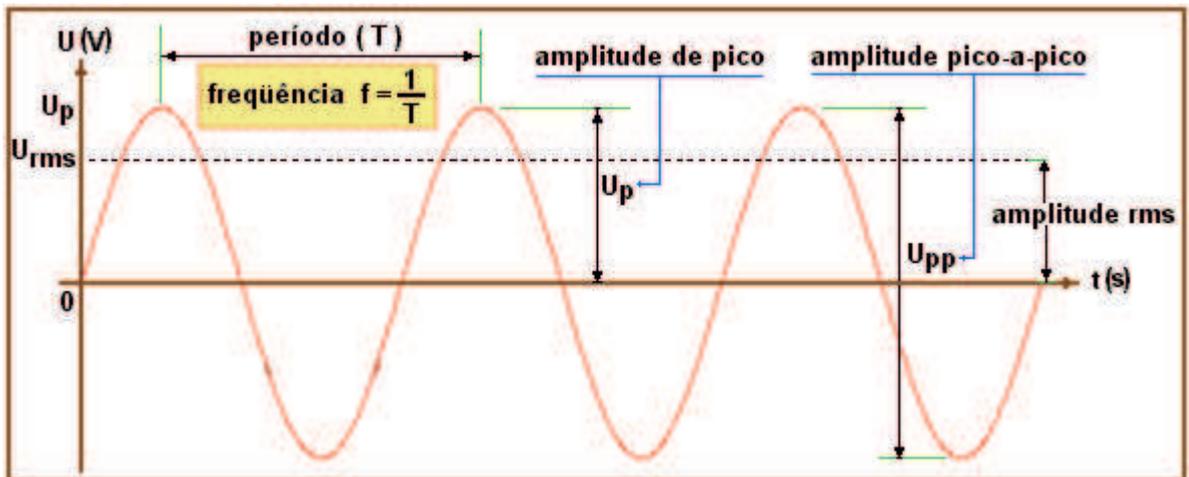
$$NívelRMS = \sqrt{\frac{1}{T} \int_0^T x^2(t) dt} \quad (2.6)$$

Onde T é o período do sinal.

Valor Pico (V_P) de um sinal é o valor máximo (pico positivo) ou mínimo (pico negativo) de amplitude encontrado no sinal. Já o Valor Pico a Pico (V_{PP}) é a diferença entre o valor máximo de amplitude e o valor mínimo de amplitude encontrado no sinal.

A Figura 2.7 mostra um gráfico de uma função seno, indicando seus valores pico, pico a pico, período e valor RMS.

Figura 2.7. Gráfico de uma senóide.



Fonte: Netto (2011)

2.3.8.2. Assimetria (Skewness – S_k)

Assimetria é o grau de desvio, ou afastamento da simetria, de uma distribuição em relação à média. Se a curva de frequência de uma distribuição tem uma “cauda” mais longa à direita do que à esquerda da ordenada máxima, diz-se que a distribuição é assimétrica à direita ou assimétrica positiva. Se ocorrer o inverso, é uma distribuição assimétrica à esquerda ou negativa. O coeficiente de assimetria é dado pela Eq. 2.7.

$$S_k = \frac{M'_3}{(\sigma^2)^{1,5}} \quad (2.7)$$

onde: M'_3 é o momento central de terceira ordem e σ é o desvio padrão da amostra.

2.3.8.3. Curtose (K_x)

Curtose é o grau de achatamento de uma distribuição, considerado usualmente em relação à distribuição normal. Esta pode ser calculada utilizando a Eq. 2.8.

$$K_x = \frac{M'_4}{(\sigma^2)^2} \quad (2.8)$$

onde: M'_4 é o momento central de quarta ordem.

A distribuição que tem um pico relativamente alto é chamada leptocúrtica, enquanto que a que possui o topo mais achatado é denominada platicúrtica. Já a distribuição normal, que tem uma forma intermediária, é denominada mesocúrtica, e sua curtose vale 3.

2.3.8.4. Fator de Crista (FC)

O Fator de Crista (FC), definido pela Eq. 2.9, é muito utilizado para detecção de falhas em rolamentos e é um indicador de ocorrências fora da normalidade.

$$FC = 10 \log_{10} \frac{V_P}{ValorRMS} \quad (2.9)$$

2.3.8.5. Estimadores k_4 e k_6

O estimador k_4 é muito utilizado para análise de vibrações em manutenção preditiva e é definido pela Eq. 2.10. Já o estimador k_6 é, na verdade, o momento central de sexta ordem, e é dado pela Eq. 2.11.

$$k_4 = ValorRMS \cdot K_x \quad (2.10)$$

$$k_6 = \frac{\sum_{i=1}^n (x_i - \mu)^6}{n} \quad (2.11)$$

onde μ é a média do sinal e n o número de pontos da amostra.

2.3.9. Estimador *k-point nonlinear energy operator* (k-NEO)

Este estimador foi apresentado por Liu, Lin, Tsai e Sun (2013) com o intuito de desenvolver um modelo para detecção de picos em sinais de EEG de pessoas com epilepsia. O k-NEO é utilizado para detectar todos os possíveis candidatos a picos existentes no sinal.

O k-NEO é uma variação do estimador NEO (*Nonlinear Energy Operator*), comumente utilizado na detecção de ocorrências súbitas nos sinais em alta frequência, o que o torna um estimador com aplicação em processamento de sinais, processamento de imagem e demodulação AM/FM (Kaiser, 1990; Maragos e Kaiser, 1993). Uma vez que NEO é muito

sensível a altos picos de ruído, Choi, em 2002, propôs a versão estendida k-NEO, apresentada na Eq. 2.12.

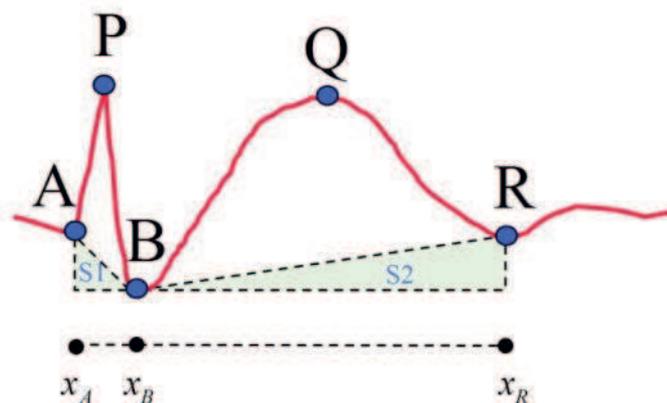
$$\psi_k\{x(n)\} = x^2(n) - x(n-k)x(n+k) \quad (2.12)$$

onde k é um parâmetro de resolução relacionado à largura do pico dos candidatos detectados e $x(n)$ é a amostra de entrada.

Dado um candidato a pico P , detectado pela Eq. 2.12, define-se outros quatro pontos importantes: A , B , Q e R , mostrados na Fig. 2.10. O grupo de pontos A , P e B representa o pico, enquanto o grupo dos pontos B , Q e R representa a porção da onda lenta. Um único pico possui apenas o primeiro grupo de pontos, enquanto um pico seguido por uma onda lenta tem os dois grupos de pontos. Os dois primeiros pontos característicos são designados por A e B , que correspondem ao início e fim do pico, respectivamente. Ao rastrear uma inclinação positiva, anteriormente ao ponto P , define-se o ponto A . O Ponto B é definido de maneira análoga, porém posteriormente ao ponto P . Já os pontos Q e R correspondem ao máximo local e ao ponto final da onda lenta (Liu *et al*, 2013).

Definidos os pontos, calcula-se 13 características, divididas em quatro categorias (duração, amplitude, inclinação e área), dadas pelas Eq. 2.13 a 2.25. O diagrama de referências para a extração dessas características é mostrado também na Fig. 2.8.

Figura 2.8. Diagrama para extração das características e pontos definidos pelo modelo.



Fonte: Liu *et al* (2013)

$$Dur_{AP} = \overline{AP}_x \quad (2.13)$$

$$Dur_{PB} = \overline{PB}_x \quad (2.14)$$

$$Dur_{spike} = \overline{AP}_x + \overline{PB}_x \quad (2.15)$$

$$Dur_slowwave = \overline{BQ_x} + \overline{QR_x} \quad (2.16)$$

$$Amp_AP = \overline{AP_y} \quad (2.17)$$

$$Amp_PB = \overline{PB_y} \quad (2.18)$$

$$Amp_spike = (\overline{AP_y} + \overline{PB_y})/2 \quad (2.19)$$

$$Amp_slowwave = (\overline{BQ_y} + \overline{QR_y})/2 \quad (2.20)$$

$$Slope_AP = \overline{AP_y}/\overline{AP_x} \quad (2.21)$$

$$Slope_ = -\overline{PB_y}/\overline{PB_x} \quad (2.22)$$

$$Slope_sharpness = Slope_AP - Slope_PB \quad (2.23)$$

$$Area_spike = \int_{x_A}^{x_B} f(x)dx - S_1 \quad (2.24)$$

$$Area_slowwave = \int_{x_B}^{x_R} f(x)dx - S_2 \quad (2.25)$$

onde:

- Dur_AP é a duração da primeira meia onda do pico;
- $\overline{AP_x}$ é a projeção do vetor AP no eixo x;
- Dur_PB é a duração da segunda meia onda do pico;
- $\overline{PB_x}$ é a projeção do vetor PB no eixo x;
- Dur_spike é a soma das durações para o pico;
- $Dur_slowwave$ é a soma das durações para a onda lenta;
- $\overline{BQ_x}$ é a projeção do vetor BQ no eixo x;
- $\overline{QR_x}$ é a projeção do vetor QR no eixo x;
- Amp_AP é a amplitude da primeira meia onda do pico;
- $\overline{AP_y}$ é a projeção do vetor AP no eixo y;
- Amp_PB é a amplitude da segunda meia onda do pico;
- $\overline{PB_y}$ é a projeção do vetor PB no eixo y;
- Amp_spike é a média das amplitudes para o pico;
- $Amp_slowwave$ é a média das amplitudes para a onda lenta;
- $\overline{BQ_y}$ é a projeção do vetor BQ no eixo y;
- $\overline{QR_y}$ é a projeção do vetor QR no eixo y;
- $Slope_AP$ é a inclinação da primeira meia onda do pico;
- $Slope_PB$ é a inclinação da segunda meia onda do pico;

- *Slope_sharpness* é a nitidez do pico;
- *Area_spike* é a área do pico;
- x_A é a posição do ponto A;
- x_B é a posição do ponto B;
- S_1 é a área definida na Fig. 2.8;
- *Area_slowwave* é a área da onda lenta;
- x_R é a posição do ponto R;
- S_2 é a área definida na Fig. 2.8.

2.3.10. Medidas de Entropia

A entropia, para a termodinâmica, é a medida do grau de desordem de um sistema, relacionada a segunda lei da Termodinâmica, e que muda com a mudança de estado e tende a aumentar com o tempo. Já contextualizando na teoria de informação, a entropia é um indicador da quantidade de informação armazenada em uma distribuição de probabilidade (Kannathal, Choo, Acharaya e Sadasivan, 2005).

Os autores consideram que aplicado em EEG, a entropia descreve a variabilidade dentro do sinal, estatisticamente falando, uma vez que pode ser descrita como uma medida de disseminação dos dados. Sinais com uma ampla distribuição de propabilidade com baixa curtose, terão uma alta entropia. Já os sinais com uma distribuição estreita e com alta curtose terão baixa entropia (Kannathal *et al*, 2005).

Para Sharma, Pachori e Acharya (2015), “a entropia é uma medida da complexidade da série temporal. Os parâmetros não-lineares podem ser úteis para descrever a dinâmica dos sinais EEG considerando a natureza não-linear e não estacionária dos sinais EEG”.

Neste trabalho, foram utilizados os parâmetros de entropia, aplicados nas IMF, descritos em Sharma, Pachori e Acharya (2015), que são:

- Entropia média de Shannon ($ShEn_{avg}$):
Esta entropia é calculada multiplicando-se o nível de potência, obtido através do cálculo da densidade espectral de potência, em cada frequência pelo logaritmo da inversa do mesmo nível de potência (Eq. 2.27). Já a entropia média é definida pela Eq. 2.28, onde x e y representam os sinais focal e não-focal do EEG.

$$ShEn = \sum_f P_f \log\left(\frac{1}{P_f}\right) \quad (2.27)$$

$$ShEn_{avg} = \frac{ShEn_x + ShEn_y}{2} \quad (2.28)$$

- Entropia média de Renyi ($RenEn_{Avg}$):

A Entropia de Renyi é definida pela Eq. 2.29. Neste trabalho foi utilizado $\alpha = 2$, conhecido como Entropia Quadrática de Renyi (Eq. 2.30). Já a entropia média de Renyi é dada pela Eq. 2.31, onde x e y correspondem também ao sinal focal e não focal, respectivamente.

$$RenEn(\alpha) = \frac{1}{1 - \alpha} \log(P_f^\alpha), \alpha > 0, \alpha \neq 1 \quad (2.29)$$

$$RenEn(2) = -\log\left(\sum_f P_f^2\right) \quad (2.30)$$

$$RenEn_{avg} = \frac{RenEn_x + RenEn_y}{2} \quad (2.31)$$

- Entropia aproximada média ($ApEn_{Avg}$):

Esta entropia é uma medida da complexidade das séries temporais e é muito utilizada nas áreas de processamento de sinais biomédicos (Sharma, Pachori e Acharya, 2015). Ela mede a aleatoriedade de uma série temporal em múltiplas dimensões. Considerando uma série temporal $x(i)$ de tamanho N e construindo $N - d + 1$ vetores $X(1), X(2), \dots, X(N - d + 1)$, qualquer vetor $X(i)$ pode ser expressado pela Eq. 2.32.

$$X(i) = \{x(i), x(i + 1), \dots, (x(i + d - 1))\}, 1 \leq i \leq N - d + 1 \quad (2.32)$$

Onde d é a dimensão de incorporação.

Para uma dada série temporal $x(i)$, a entropia aproximada é dada pela Eq. 2.33.

$$ApEn(d, r, N) = \phi^d(r) - \phi^{d+1}(r) \quad (2.33)$$

Onde:

$$\phi^d(r) = \frac{1}{(N-d+1)} \sum_i \ln(C_i^d(r)) \quad (2.34)$$

$$C_i^d(r) = \frac{1}{(N-d+1)} N_i^r \quad (2.35)$$

Onde N_i^r mede a distância entre dois vetores $X(i)$ e $X(j)$, que é menor que a tolerância r .

O valor médio é utilizado para classificar os sinais em focal e não focal, e é dada pela Eq. 2.36.

$$ApEn_{avg} = \frac{ApEn_x + ApEn_y}{2} \quad (2.36)$$

- Entropia média da amostra ($SpEn_{Avg}$):

A Entropia da amostra é uma versão modificada de $ApEn$ e é usada para medir a complexidade de séries temporais. O $SpEn$ evita o erro de bias causado pelo uso das auto combinações no cálculo de $ApEn$, além de melhorar o desempenho. Usando as mesmas suposições de $ApEn$, $SpEn$ pode ser calculado pela Eq. 2.37.

$$SpEn(d, r, N) = -\ln\left(\frac{A^d(r)}{B^d(r)}\right) \quad (2.37)$$

Onde:

$$A^d(r) = \frac{1}{(N-d)} \sum_{i=1}^{N-d} C_i^{d+1}(r) \quad (2.38)$$

$$B^d(r) = \frac{1}{(N-d)} \sum_{i=1}^{N-d} C_i^d(r) \quad (2.39)$$

$$C_i^d(r) = \frac{1}{(N-d)} C_i, i = 1, 2, \dots, N-d \quad (2.40)$$

Onde C_i é a soma das distâncias entre $X(i)$ e $X(j)$, porém excluindo as auto combinações. A Entropia média é definida então pela Eq. 2.41.

$$SpEn_{avg} = \frac{SpEn_x + SpEn_y}{2} \quad (2.41)$$

- Entropias médias de fase (S1Avg e S2Avg):

As entropias de fase utilizam de espectros de alta ordem (HOS) para o cálculo. HOS é definido em termos estatísticos de alta ordem, conhecidos como cumulantes, ou seja, são representações espectrais de momentos de alta ordem. Estes espectros podem ser definidos tanto para sinais determinísticos quanto para processos randômicos. O biespectro do sinal pode ser definido pela Eq. 2.42.

$$B(f_1, f_2) = E[F(f_1)F(f_2)F^*(f_1 + f_2)] \quad (2.42)$$

Onde E é a esperança de uma varável e $F(f)$ é a transformada de Fourier de um sinal $x(i)$.

As entropias de fase S_1 e S_2 são calculadas a partir do biespectro e são similares às entropias espectrais. Podem ser calculadas pelas Eq. 2.43 e 2.44.

$$S_1 = - \sum_k p_k \log(p_k) \quad (2.43)$$

Onde: $p_k = \frac{|B(f_1, f_2)|}{\sum_{\Omega} |B(f_1, f_2)|}$ e Ω é o domínio principal da região não redundante

$$S_2 = - \sum_j q_j \log(q_j) \quad (2.44)$$

Onde: $q_j = \frac{|B(f_1, f_2)|^2}{\sum_{\Omega} |B(f_1, f_2)|^2}$

As entropias médias de fase se calculam como já feito anteriormente com as outras entropias.

2.4. REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais (RNA), de acordo com Haykin (2001), representam uma tecnologia que tem raízes em muitas disciplinas e encontram aplicações em campos diversos, tais com modelagem, análise de séries temporais, reconhecimento de padrões, processamento de sinais e controle em virtude de ter como propriedade a habilidade de aprender a partir de dados de entrada supervisionados ou não.

Sendo assim, as RNA possuem a capacidade de aprender por exemplos e fazer interpolações do que aprendem. A etapa de aprendizagem consiste em um processo iterativo de ajuste de

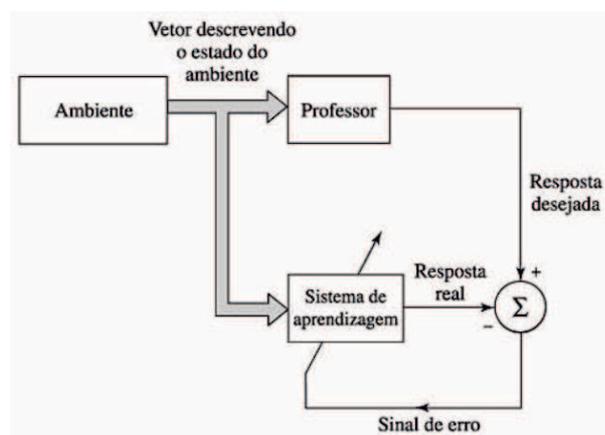
parâmetros da rede, os pesos das conexões entre as unidades de processamento que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando. Estes métodos para treinamento de redes podem ser agrupados em dois grupos: Aprendizado Supervisionado, método em que a entrada e a saída desejadas para a rede são fornecidas por um supervisor externo e cujo objetivo é ajustar parâmetros da rede, de forma a encontrar uma ligação entre os pares de entrada e saída fornecidos, e Aprendizado Não Supervisionado, em que não há professor ou supervisor para acompanhar o processo de aprendizado, e somente os padrões de entrada estão disponíveis.

Aprendizagem é definida por Haikin (2001) como: “processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida.” Ou seja, a rede neural sofre modificações em seus parâmetros e responde de uma nova maneira ao ambiente.

Existem diversos tipos de aprendizagem que podem ser usadas para a solução de redes neurais. Para este trabalho, como se conhece as características do sinal com anomalia e sem anomalia, utiliza-se de Redes com Aprendizado Supervisionado, ou com um Professor.

A Figura 2.9 apresenta um diagrama de blocos que ilustra este tipo de aprendizagem. O professor é quem tem o conhecimento do ambiente, conseguindo criar um conjunto de dados de entrada e saída. Portanto, no aprendizado supervisionado, este professor avalia a resposta da rede ao padrão de entrada. Os pesos são calculados de forma que a resposta de saída da rede coincida com o conjunto de entrada e saída do professor.

Figura 2.9. Diagrama de blocos para ilustrar o Aprendizado Supervisionado.



Fonte: Haikin (2001)

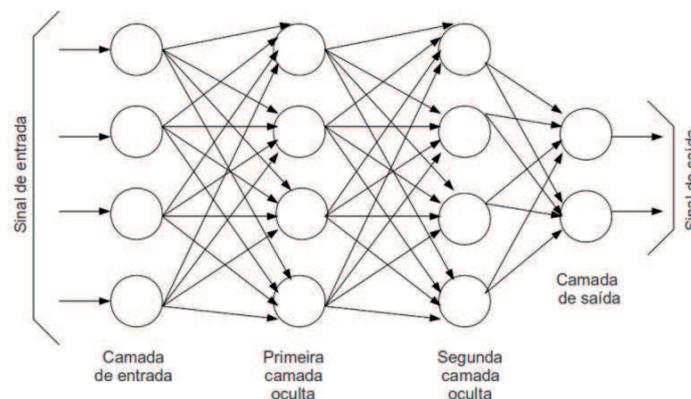
Para as redes com aprendizado supervisionado, existem várias arquiteturas diferentes, como: rede perceptron com camada única ou múltiplas camadas, redes de função de base radial, máquinas de vetor de suporte, máquina de comitê, entre outras. Neste trabalho, foi utilizada a

estrutura perceptron multicamadas com retropropagação do erro (MLP-BP), por ser a mais utilizada e de fácil implementação, além de ser um problema não linearmente separável.

Esta rede consiste de um conjunto de dados na camada de entrada, uma ou mais camadas ocultas e uma camada de saída. O sinal vai se propagar para frente através da rede, camada a camada. Utiliza-se também o algoritmo de retropropagação do erro, que consiste em dois passos: um passo para frente, chamado de propagação, onde o vetor de entrada é aplicado aos nós da rede e o efeito se propaga camada a camada, gerando um vetor de saída com pesos sinápticos da rede todos fixos; e um passo para trás, a retropropagação, onde o sinal real da rede é subtraída da resposta desejada, gerando um sinal de erro. Esse sinal de erro é propagado para trás da rede, ajustando os sinais sinápticos de forma que a resposta real se aproxime mais da resposta desejada (Haikin, 2001).

A Figura 2.10 mostra como é a arquitetura de uma rede MLP-BP, com duas camadas ocultas e totalmente conectada, ou seja, um neurônio em qualquer camada da rede está conectado a todos os neurônios da camada anterior.

Figura 2.10. Arquitetura de uma rede MLP-BP com duas camadas ocultas.



Fonte: Haikin (2001)

Uma outra rede utilizada neste trabalho é a Rede Neural Propabilística (PNN), por ser uma rede também de fácil implementação, muito utilizada em problemas de classificação, que é o foco deste trabalho, e tem uma velocidade de processamento muito alta, quando comparadas a redes multicamadas (Masters, 1995).

Este algoritmo leva em consideração a probabilidade relativa dos eventos ocorridos e usa esta informação para a predição, e é baseada na teoria dos classificadores Bayesianos descritos por Meisel nos anos 1970. As PNN operam segundo conceitos de estatística tradicional, utilizando de funções densidade de probabilidade (requeridas pela teoria Bayesiana), e por isso

é possível associar o algoritmo a uma rede neural (divide-se em vários neurônios), o que faz que com que esta combinação tenha uma capacidade de operar em paralelo (Masters, 1995). Vale ressaltar que o número de camadas deve ser igual ao número de parâmetros necessários para identificar uma determinada classe.

2.5. ALGORITMOS GENÉTICOS

Algoritmos genéticos (GA) caracterizam um método de otimização heurístico, de caráter aleatório, baseado em uma população genética e foi introduzido por John Holland na década de 1970. De acordo com Kumar, Husian, Upreti e Gupta (2010), os algoritmos genéticos são algoritmos de busca probabilística baseado no mecanismo natural de seleção e evolução e o mesmo sempre é inicializado com uma população. O método consiste na sobrevivência das estruturas melhor adaptadas e na transmissão das características, ou seja, na troca de informações entre cromossomos.

A cada iteração, uma nova cadeia de caracteres, ou população, é gerada usando as melhores características dos elementos da geração anterior. Basicamente, os GA seguem as seguintes etapas:

- 1º) Geração de uma população inicial com indivíduos escolhidos de maneira aleatória;
- 2º) Avaliação dos indivíduos através do cálculo da função objetivo;
- 3º) Seleção dos indivíduos mais aptos;
- 4º) Aplicação dos operadores genéticos de cruzamento, ou seja, as características dos indivíduos escolhidos são recombinadas, gerando novos indivíduos;
- 5º) Aplicação do operador genético de mutação, ou seja, as características dos indivíduos resultantes do processo de reprodução são alteradas, acrescentando, assim, variedade à população;
- 6º) Geração de uma nova população.

Estas etapas seguem até que um critério de convergência ou de parada seja satisfeito. A Fig. 2.11 mostra o fluxograma para um algoritmo de GA.

Figura 2.11. Fluxograma de um Algoritmo Genético Simples.



Fonte: A autora (2013)

2.6. EVOLUÇÃO DIFERENCIAL

O método de Evolução Diferencial (ED) foi proposto, em 1995, por Storn and Price e é um algoritmo evolutivo usado para resolver problemas de otimização. Uma das principais características dessa metodologia é que esta apresenta uma concepção puramente matemática, baseada em operações vetoriais. Por isso, a mesma é considerada como uma abordagem estrutural (Coelho, 2003 apud Lobato, 2008).

O método consiste em gerar aleatoriamente uma população de indivíduos, onde cada indivíduo representa um ponto de busca no espaço de soluções de um determinado problema. Caso não se conheça a priori o problema, a população inicial é gerada através de uma distribuição uniforme.

Basicamente, as ED seguem as seguintes etapas (Lobato, 2008):

1º) Geração da população inicial. Esta deve ter soluções aceitáveis para o problema em estudo e os valores atribuídos às variáveis não violam as fronteiras de projeto;

2º) Seleção de um indivíduo, de maneira randômica, para ser substituído. Seleciona-se três diferentes indivíduos para serem os genitores, e apenas um é selecionado como genitor principal;

3º) Modificação de cada variável do genitor principal, de acordo com uma probabilidade;

4º) Adição da diferença entre as duas outras variáveis, oriundas dos genitores secundários, ao valor atual da variável oriunda do genitor principal, ponderada por uma taxa de perturbação. Este procedimento é conhecido como cruzamento;

5º) Avaliação do vetor resultante. Caso este apresente uma função de adaptação melhor que o genitor principal, ele o substitui, senão, esse vetor é mantido na população.

2.7. ANÁLISE DISCRIMINANTE MÚLTIPLA

A Análise Discriminante Múltipla (MDA) é uma técnica estatística apropriada quando se tem variáveis independentes métricas e uma variável dependente categórica, ou seja, tem-se variáveis independentes métricas como o ValorRMS do sinal, que tem relação direta com a variável dependente, a presença ou não de anomalias no sinal do EEG.

De acordo com Hair, Black, Babin, Anderson e Tatham (2009), a análise discriminante determina uma variável estatística, que tem por definição, ser uma combinação linear das duas ou mais variáveis independentes, contidas em grupos definidos *a priori*, que melhor discriminarão os objetos. Esta discriminação é obtida através de pesos para cada variável independente, a fim de maximizar a diferença entre os grupos. O que difere a análise discriminante de outras técnicas multivariadas, como regressão múltipla, é a capacidade de se ter mais de uma função discriminante, o que faz com que o objeto possa ter mais de um escore determinante (soma dos valores obtidos pela multiplicação de cada variável independente pelo seu peso).

Nesta técnica, é possível verificar se a média entre dois ou mais grupos de variáveis independentes são iguais. Para isto utiliza-se de centroides (média dos escores determinantes de todos os indivíduos de cada grupo), tendo como teste de significância, a distância entre os centroides (Hair *et al*, 2009).

Dentro de MDA é possível destacar três modelos, utilizados neste trabalho: Análise Discriminante Linear, ou de Fisher, Análise Discriminante Quadrática e *k-Nearest Neighbor*.

2.7.1. Análise Discriminante Linear (LDA)

De acordo com Hastie, Tibshirani e Friedman (2008), da teoria de decisão para classificação é necessário conhecer a classe posterior para se ter uma classificação ótima. A LDA então, segundo os autores, é um caso especial de modelo da densidade de cada classe, onde as matrizes

de covariância devem ser iguais, o que causa a o cancelamento dos fatores de normalização, bem como a parte quadrática dos expoentes.

A LDA utiliza da função discriminante de Fisher, que é uma combinação linear das características originais a qual se caracteriza por produzir a máxima separação entre duas populações. Esta função de Fisher, para uma determinada observação x_0 , é dada pela Eq. 2.45 e o ponto médio (m) entre as duas médias populacionais é dada pela média entre os discriminantes (Varella, 2007).

$$D(x_0) = [\mu_1 - \mu_2]' \cdot \Sigma^{-1} \cdot x_0 \quad (2.45)$$

onde: D é a função discriminante de Fisher e Σ é a matriz comum de covariância entre as populações 1 e 2.

A regra então de classificação da LDA é dada por:

- Aloca-se x_0 no grupo 1 se $D(x_0) \geq m$;
- Aloca-se x_0 no grupo 2 se $D(x_0) < m$.

2.7.2. Análise Discriminante Quadrática

A Análise Discriminante Quadrática é generalização do método linear, desde que existam apenas duas classes e que suas medidas sejam normalmente distribuídas, para quando não se consegue obter as matrizes de covariância iguais para todos os grupos (Dixon e Brereton, 2009; Bhattacharya, Khasnobish, Chatterjee, Konar e Tibarewala, 2010).

Ao contrário da distância linear, a distância quadrática não é simétrica e esta distância é calculada usando a matriz variância-covariância da amostra de cada classe em vez da matriz agrupada global.

Como o próprio nome diz, a QDA cria uma superfície limite quadrática, o que consiste em duas seções separadas de linhas de fronteira. Isso significa que a QDA é capaz de classificar de maneira correta amostras de uma classe mesmo que estas estejam em diferentes regiões do espaço de variáveis (Dixon e Brereton, 2009).

2.7.3. k-Nearest Neighbor

O k-NN é um algoritmo de classificação de fácil implementação computacional simples de se compreender e muito utilizada para reconhecimento de padrões. O mesmo consiste em

determinar, como o próprio nome diz, os k vizinhos mais próximos entre o conjunto de treinamento e as categorias dos k vizinhos são utilizadas como peso para os candidatos de cada categoria.

O desempenho do k -NN depende de dois fatores (Bhattacharya *et al*, 2010):

- A escolha de uma função de similaridade, ou métrica de distância adequada;
- Valor apropriado para k . Caso o k seja grande, pode-se sobrecarregar as classes pequenas, e caso k seja pequeno, não há vantagens em se utilizar o algoritmo.

A métrica mais utilizada para o cálculo das distâncias é a Euclidiana.

CAPÍTULO III

MATERIAIS E MÉTODOS

Apresenta-se neste capítulo todos os materiais e métodos utilizados para a detecção de anomalias nos sinais de EEG, identificando sinais estatisticamente iguais, e agrupando-os. Em um primeiro momento, fez-se necessária a escolha de um banco de dados confiável e de grande utilização em pesquisas. Após a escolha do banco de dados, fez-se uma análise visual através dos boxplot dos sinais, para atestar a qualidade do banco de dados utilizado. Calculou-se os parâmetros estatísticos para se obter os sintomas que serão utilizados como dados de entrada nos procedimentos de classificação. Feito isso, construiu-se um conjunto de dados para treinamento dos procedimentos de classificação, um outro conjunto de dados para validação desses procedimentos e, por fim, um conjunto para testes.

3.1. ESCOLHA DO BANCO DE DADOS

Para o desenvolvimento deste trabalho, utilizou-se o banco de dados Bern-Barcelona descrito em Andrzejak, Schindler e Rummel (2012), que está disponível publicamente, e já foi citado 89 vezes, de acordo com o Google Acadêmico (2018). Destes, aproximadamente 36 datam de 2017 em diante.

Os sinais utilizados pelos autores são gravações de EEG intracraniais de cinco pacientes com epilepsia. É importante ressaltar que todos os pacientes apresentaram epilepsia de lóbulo temporal farmacorresistente de longa data e foram candidatos à cirurgia de epilepsia. Os sinais foram adquiridos em 512 Hz e 1024 Hz. Como pré-processamento, todos os sinais foram filtrados por um filtro Butterworth de quarta ordem do tipo passa banda entre 0,5 e 150 Hz. Todos os sinais adquiridos com 1024 Hz foram re-amostrados para a frequência de 512 Hz (Andrzejak, Schindler e Rummel, 2012).

O banco de dados é composto, então, por (Andrzejak, Schindler e Rummel, 2012):

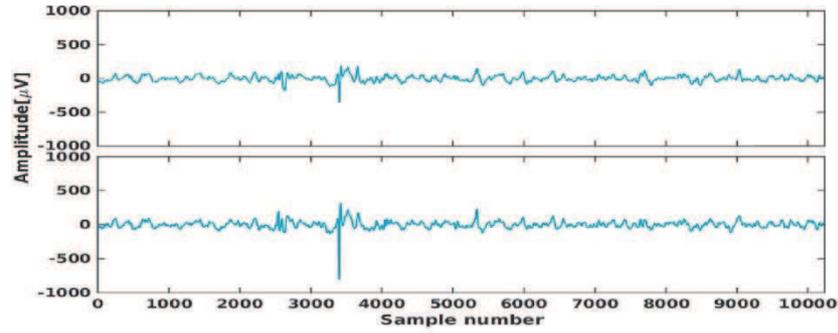
- Define-se como canal focal, todos os canais em que se detectou a primeira mudança ictal (evento no sinal causado por uma crise epilética), julgadas por inspeção visual de pelo menos dois neurologistas certificados;

- Define-se como canal não focal, todos os outros canais incluídos na gravação do EEG;
- Foram selecionados aleatoriamente 3750 pares de sinais simultaneamente gravados x e y, todos do conjunto considerado como canal focal;
- Para cada par de sinais, foram selecionados um dos pacientes, de maneira aleatória, um dos canais focais deste paciente (sinal x), um dos canais vizinhos a este canal focal (sinal y) e uma janela de tempo;
- Antes de incluir o par de sinais no banco de dados, todos foram novamente inspecionados visualmente;
- Em seguida, dividiu-se as gravações em janelas de 20 segundos, o que corresponde a um sinal com 10240 pontos. Gravações das crises convulsivas e de três horas após a última crise foram excluídas.

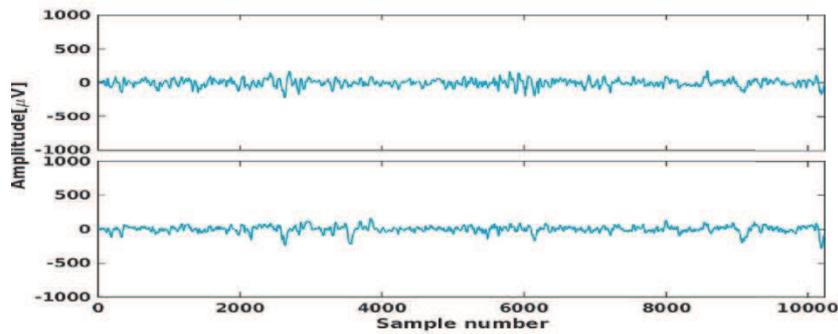
Escolheu-se, de maneira aleatória, 100 conjuntos para o treinamento dos procedimentos de classificação. Outros 200 sinais, também escolhidos aleatoriamente, (conjunto 101 a 300), foram utilizados para avaliar a precisão dos procedimentos desenvolvidos.

Na Figura 3.1 é apresentado um sinal focal e um não focal do banco de dados. So observar a figura, percebe-se que visualmente é muito difícil detectar a diferença entre eles.

Figura 3.1. Sinais adquiridos do banco de dados de Bern-Barcelona: (a) Sinal focal do EEG e (b) Sinal não focal do EEG.



(a) Focal EEG Signal. Top: X series. Bottom: Y series



(b) Non-Focal EEG Signal. Top: X series. Bottom: Y series

Fonte: Andrzejak, Schindler e Rummel, 2012

3.2. AVALIAÇÃO DOS PROCEDIMENTOS

Para a avaliação dos procedimentos desenvolvidos, utilizou-se as métricas propostas por Sharma, Pachori e Acharya (2015), que também utilizaram o banco de dados de Bern-Barcelona: Sensibilidade (SEN), dada pela Eq.3.1; Especificidade (SPF), dada pela Eq. 3.2; Precisão (ACC); dada pela Eq. 3.3, Valores Positivos Preditos (PPV), dados pela Eq. 3.4; Valores Negativos Preditos (NPV), dados pela Eq. 3.5; e Coeficiente de Correlação de Mathew (MCC), dado pela Eq. 3.6.

$$SEN = \frac{TP}{TP + FN} \times 100 (\%) \quad (3.1)$$

$$SPF = \frac{TN}{TN + FP} \times 100 (\%) \quad (3.2)$$

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \times 100 (\%) \quad (3.3)$$

$$PPV = \frac{TP}{TP + FP} \times 100 (\%) \quad (3.4)$$

$$NPV = \frac{TN}{TN + FN} \times 100 (\%) \quad (3.5)$$

$$MCC = \frac{TP \times TN - FN \times FP}{\sqrt{(TP + FN)(TP + FP)} \times \sqrt{(TN + FN)(TN + FP)}} \times 100 (\%) \quad (3.6)$$

onde: TP (verdadeiro positivo) é a quantidade de pares focais identificados de maneira correta, TN (verdadeiro negativo) a quantidade de pares não focais identificados de maneira correta, FN (falso negativo) o número de pares focais identificados erroneamente e FP (falso negativo) o número de pares não focais identificados erroneamente.

3.3. DETECTORES E PARÂMETROS (SINTOMAS) UTILIZADOS

Os parâmetros utilizados como dados de entrada (sintomas) para os procedimentos de classificação foram: Nível RMS, Valor Pico, Valor Pico a Pico, Assimetria, Curtose, Fator de Crista, estimador k4 e estimador k6, descritos na seção 2.3.8.

Os 300 conjuntos de dados utilizados neste trabalho passaram por tratamentos de sinal, sendo eles: processos de filtragem, análise envelope, Transformada Wavelet Contínua, Funções de Modos Intrínsecos em conjunto com métricas de avaliação de picos de baixa frequência K-NEO, Transformada de Hilbert-Huang e cálculo de entropia (28 parâmetros aplicados às IMF retirados de Sharma, Pachori e Acharya, 2015). Além disso, aplicou-se os tratamentos tanto para o arranjo unipolar quanto para o dipolar. Para os sinais filtrados, utilizou-se os valores dos parâmetros não normalizados e normalizados (pela média e desvio padrão). Já para os outros tratamentos, apenas os sinais normalizados foram utilizados. Assim, calculou-se os sintomas para cada tratamento, o que resultou em 1180 sintomas que foram utilizados para classificar os pares em focal e não focal.

É importante ressaltar que nos processos de filtragem foram utilizados filtros Butterworth com seis polos, e as bandas dos filtros foram escolhidas de acordo com os tipos de onda encontradas nos EEG. Os filtros utilizados foram assim denominados:

- Total: sinal filtrado com filtro passa baixa em 256 Hz;
- Delta: sinal filtrado com filtro passa baixa em 4 Hz;
- Teta: sinal filtrado com filtro passa banda de 3 a 7 Hz;

- Alfa: sinal filtrado com filtro passa banda de 7 a 13 Hz;
- Beta: sinal filtrado com filtro passa banda de 13 a 30 Hz;
- Gama: sinal filtrado com filtro passa alta de 30 Hz;
- Usuário: sinal filtrado com filtro passa banda de 8 a 245 Hz.

Para garantir a convergência dos filtros do tipo IIR, fez-se necessária uma pré-filtragem e re-amostragem nas frequências de 64 Hz para os filtros Delta e Beta e de 32 Hz para os filtros Teta e Alfa.

A combinação dos filtros (Total, Delta, Teta, Alfa, Beta, Gama e Usuário) com os pares de sinais unipolares e dipolares normalizados e não normalizados resultaram nos sintomas de 3.1 a 3.224. Já a aplicação da técnica de envelope nos sinais normalizados unipolares e dipolares resultaram nos sintomas 3.225 a 3.336.

O próximo conjunto de sintomas é dado pela aplicação da WT contínua, com função base dB4. As escalas foram escolhidas para contemplar as faixas de frequência de teta, alfa, beta e gama. Como se tem infinitas possibilidades para as escalas, fez-se um estudo para determinar quais escalas melhor discriminariam os sintomas ValorRMS, V_P, V_{PP}, S_k, K_x, FC, k4 e k6.

Este estudo consiste em: dado o intervalo de escalas de interesse e o conjunto de dados X_{focal} e X_{nfocal} de cada sintoma, utilizou-se a função objetivo apresentada pela Eq. 3.7. Assumiu-se para este caso a hipótese de que as populações possuem variância constante, ou seja, são homocedásticas.

$$Obj = \max\left(\frac{\|\overline{X_{Focal}} - \overline{X_{nFocal}}\|}{S_{Focal}^2 + S_{nFocal}^2}\right) \quad (3.7)$$

onde: $\overline{X_{Focal}}$ é a média do conjunto focal, $\overline{X_{nFocal}}$ é a média do conjunto não focal, S_{Focal}^2 é a variância do conjunto focal e S_{nFocal}^2 é a variância do conjunto não focal.

De posse das oito funções objetivo (uma para cada parâmetro estudado), um procedimento de otimização baseado em GA foi utilizado para determinar as melhores escalas para cada função objetivo, e depois, escolheram-se as escalas que maximizavam o maior número de funções objetivo. Feito este procedimento, as WT aplicadas nos sinais unipolares e dipolares normalizados resultaram nos sintomas de 3.337 a 3.416.

O cálculo do módulo do envelope dos sinais em que se aplicou a WT resultaram nos sintomas de 3.417 a 3.496. Já os sintomas de 3.497 a 3700 são resultados da aplicação da IMF,

e englobam o índice de ortogonalidade, os seis primeiros modos intrínsecos e respectivos resíduos, tanto para os sinais unipolares quanto para os sinais dipolares.

Os sintomas de 3.701 a 3.892 são resultado da aplicação de HHT nas seis primeiras IMF, e respectivos resíduos, para os sinais unipolares e dipolares. Os 13 parâmetros do K-NEO foram calculados para um limite de 2 segundos e largura de pico de 20 a 65 milissegundos, com um espaçamento de 5 milissegundos. Para cada par de sinal, foram identificados no máximo dez picos. A utilização dos valores máximos e médios de cada par resulta em 260 sintomas, sendo eles de 3.893 a 3.1152.

Por fim, os valores de entropia aplicados às seis primeiras IMF e seus respectivos resíduos, resultaram nos sintomas de 3.1153 a 3.1180.

3.4. ANÁLISE PRELIMINAR DOS PARÂMETROS UTILIZADOS

Primeiramente, fez-se uma análise estatística com o objetivo de avaliar os parâmetros como possíveis sintomas para a classificação das populações dos pares focal e não focal, do banco de dados utilizado. A análise foi apenas qualitativa, visual, e foi feita através da avaliação dos diagramas de caixa (boxplot) de 100 pares de sinais focal e não focal, escolhidos de maneira aleatória dentre os 3750 pares.

3.4.1. Diagrama de Caixa

Os gráficos boxplot, também conhecidos como diagrama de caixa e bigodes, é uma ferramenta que condensa um conjunto de informações estatísticas a respeito da distribuição de um conjunto de dados, em apenas um gráfico.

Dentre essas informações, destaca-se:

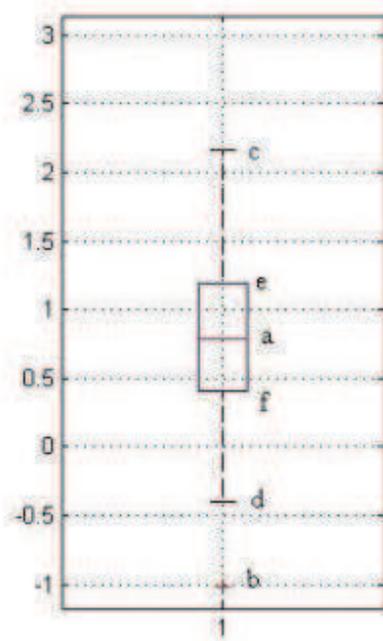
- Uma grande qualidade da mediana, em relação à média, reside no fato de que a mesma é menos sensível a valores extremos, o que é muito útil em análise que envolve dados com grandes dispersões, como é o caso em estudo;
- A distância entre as linhas do primeiro e terceiro quartil e a mediana dá uma ideia sobre o nível de achatamento (curtose) da distribuição;
- A diferença entre os comprimentos das caixas superior e inferior é um indicativo da assimetria da distribuição;
- A distância entre os bigodes e a mediana é um indicativo das “excursões fora da média” do grupo de dados;

- As cruces estão normalmente relacionadas a problemas na aquisição dos dados.

A Figura 3.2 apresenta um exemplo de gráfico boxplot, onde:

- a indica o valor da mediana (linha vermelha);
- b são os valores que estão fora dos bigodes (cruz vermelha);
- c é o bigode superior, e indica o valor mínimo de dados que é maior que o primeiro quartil menos 1,5 vezes o comprimento do interquartil (diferença entre os valores do terceiro quartil (e) e o primeiro quartil (f));
- d é o bigode inferior, e indica o valor máximo dos dados que é menor que o terceiro quartil mais uma constante vezes o comprimento do interquartil;
- e é a linha superior da caixa e indica o terceiro quartil (25% dos dados estão acima dessa linha);
- f é a linha inferior da caixa e indica o primeiro quartil (25% dos dados estão abaixo dessa linha).

Figura 3.2. Exemplo de um diagrama de caixa.



Fonte: A autora (2013)

Visualmente, os melhores candidatos a sintoma devem ter medianas dos parâmetros focal e não focal bem separadas e o terceiro quartil de uma amostra deve ser menor do que o primeiro quartil da outra amostra. A não interseção do limite superior de uma amostra com o limite

inferior da outra amostra é um forte indicativo de amostras pertencentes a populações diferentes.

3.5. PROCEDIMENTOS DE CLASSIFICAÇÃO UTILIZADOS

Os procedimentos de classificação utilizados foram o kNN – escolhido por ser de fácil implementação e por ser utilizado com sucesso em análise de sinais de EEG (Awan, Rajput, Syed, Igbal, Sabat, Mansoor, 2016; Rajaguru e Prabhakar, 2017; Ren, Qu, Chai, Tang e Zhou, 2017); k-NN ponderado pela distância WkNN, desenvolvido por Rajaguru e Prabhakar (2016); LDA, por ter baixo custo computacional; QDA; PNN, pela velocidade de treinamento e facilidade de paralelização; MLP-BP, por ser largamente utilizada em classificação de EEG (Orhan, Hekim e Ozer, 2011; Kumar, Dewal e Anand, 2014; Anh, Hoang, Thang e Bui, 2016). Todos os procedimentos foram descritos no Capítulo II.

3.6. PROCEDIMENTOS DE OTIMIZAÇÃO

Foram utilizados GA e ED como algoritmos para a otimização da melhor configuração dos sintomas para cada um dos procedimentos de classificação. Estes algoritmos foram escolhidos devido a sua robustez e facilidade de implementação, além de ser de domínio da autora.

3.7. FLUXOGRAMA DA METODOLOGIA UTILIZADA

Escolhido um dos procedimentos de classificação, dentre os seis possíveis, e um dos algoritmos de otimização, a Fig. 3.3 mostra o fluxograma utilizado no desenvolvimento da metodologia de trabalho proposta, a fim de obter o melhor conjunto de sintomas capaz de classificar os pares de sinais em sinais focais e não focais.

O fluxograma, mostrado na Fig. 3.3, descreve a seguinte sequência de ações:

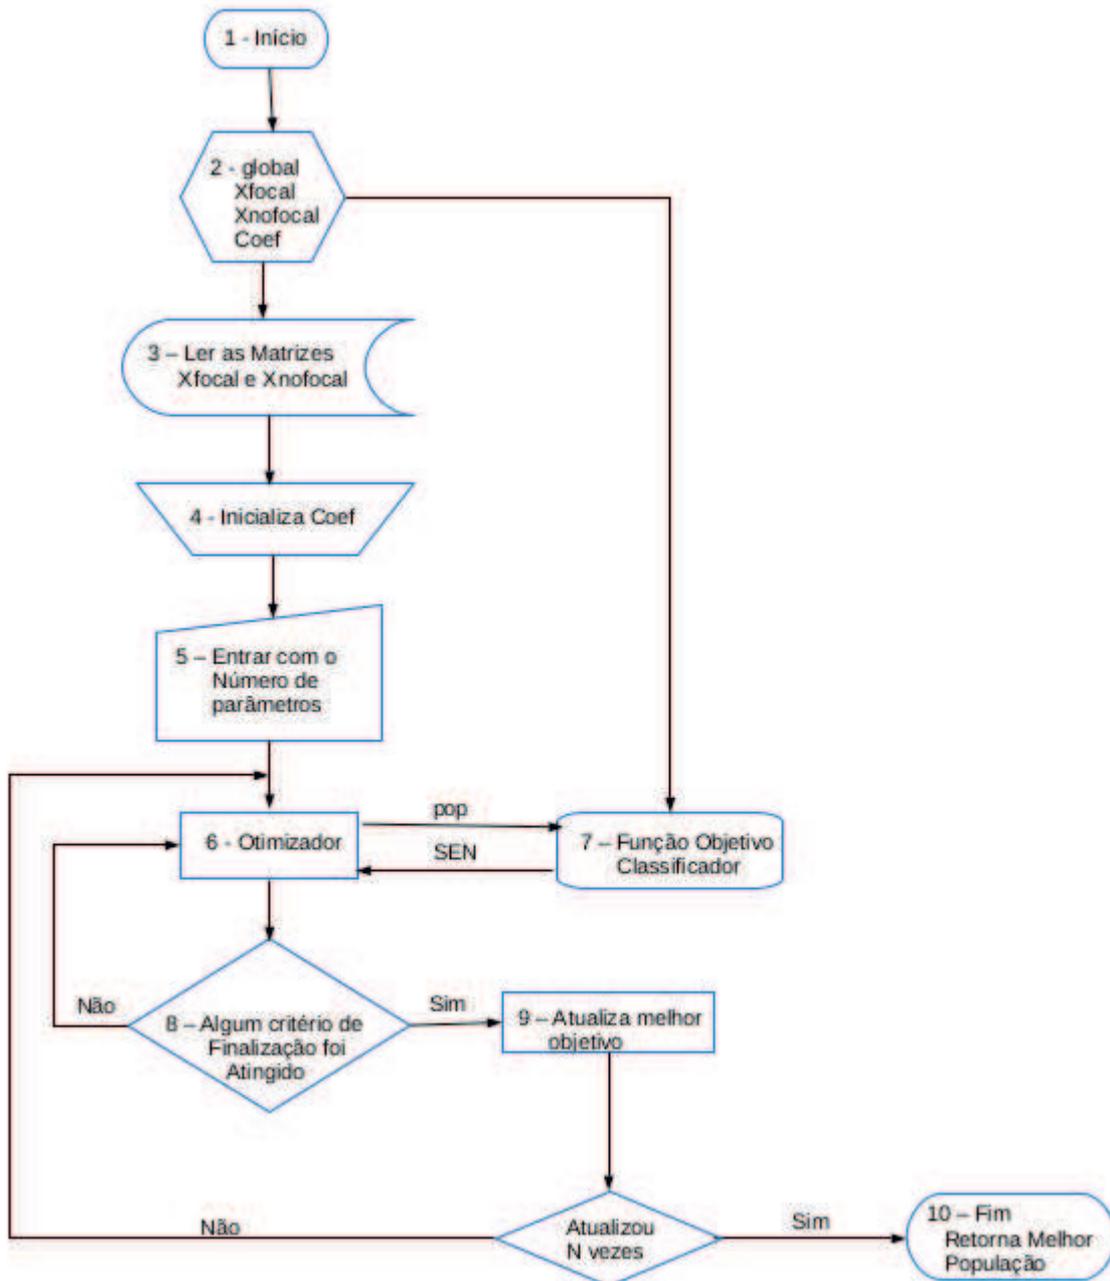
1. Início: inicialização das variáveis e parâmetros do processo de otimização;
2. Alocação de memória para as variáveis globais: matrizes X_{focal} e X_{nfocal} , com todos os sintomas calculados para o conjunto de pares em análise (1180 valores) e vetor Coef, que aponta para a localização dos sintomas escolhidos pelo algoritmo de otimização nas matrizes X_{focal} e X_{nfocal} ;
3. Leitura das matrizes X_{focal} e X_{nfocal} armazenadas no disco rígido;

4. Entra-se com o vetor Coef contendo as posições dos sintomas selecionados;
5. Entra-se com o número de parâmetros N_P que serão utilizados na classificação;
6. O algoritmo de otimização passa para a função objetivo um vetor pop contendo as N_P posições;
7. Uma vez que os parâmetros da otimização são números inteiros (posição de colunas numa matriz), a função objetivo arredonda os valores de pop para o inteiro mais próximo, confere se há parâmetros se repetindo e aciona o procedimento de classificação que vai utilizar N_a conjuntos de sintomas para treinamento e N_t conjuntos de sintomas utilizados para avaliação, através do cálculo de SEN. No caso de sintomas repetidos, a penalização se dá pela diminuição do número de sintomas utilizados no processo de classificação. Deste modo, é possível que se tenha uma população com sintomas repetidos;
8. O processo de otimização termina quando SEN atingir 100% (na verdade -100, uma vez que os algoritmos de otimização utilizados minimizam a função objetivo) ou um número máximo de gerações, quando se usa de GA e avaliação de funções objetivos, quando se usa ED, seja alcançado;
9. A otimização é repetida N vezes, com o intuito de atingir o mínimo global da função objetivo;
10. O procedimento retorna a posição dos N_P melhores sintomas encontrados.

Finalizado o processo de otimização, utiliza-se um dos procedimentos de classificação em dez conjuntos contendo 50 pares de sinais focal e 50 pares de sinais não focal, escolhidos de maneira aleatória entre os dados selecionados para a validação destes procedimentos. Após a escolha dos dados, calcula-se as métricas descritas na seção 3.2 e respectivos desvios padrões amostrais.

Deseja-se verificar o custo computacional dos procedimentos adotados neste trabalho. Para isto, o tempo médio total para avaliar dez segundos de sinal é calculado. Apesar de variar de máquina para máquina, optou-se por utilizar o tempo médio em segundos por ser uma medida mais realista. Define-se tempo médio total como sendo o tempo médio gasto para o cálculo do sintoma de maior custo computacional somado ao tempo médio gasto para classificação. Utilizou-se apenas o tempo médio do sintoma com maior custo computacional porque o processo de cálculo dos sintomas é facilmente paralelizado.

Figura 3.3. Fluxograma da Metodologia Proposta



Fonte: A autora (2018)

3.8. ROTINAS DE PROGRAMAÇÃO E PARÂMETROS UTILIZADOS

Todas as rotinas e procedimentos foram desenvolvidos na plataforma Scilab (Scilab Home, 2018) que é um programa científico para programação numérica, multi plataforma e que possui uma linguagem de programação de alto nível dedicado às aplicações científicas e de engenharia. Este programa foi escolhido devido a sua característica livre, distribuído gratuitamente, multi plataforma e de domínio do autor.

Os pacotes adicionais (ATOMS) utilizados foram:

1. NaN 1.3.4: caixa de ferramentas estatística e aprendizado de máquinas (machine learning);
2. Neural Network Module 2.0: caixa de ferramentas com redes neurais;
3. Empirical Mode Decomposition Toolbox 1.3: caixa de ferramentas para decomposição de modos empíricos (IMF).

Para a otimização via GA, foi utilizada a função nativa `optim_ga` com a seguinte configuração:

- população com tamanho variando entre 10 e 50 N_p , em função do tempo para avaliação da função objetivo;
- fração de cruzamento de 0,7;
- intervalo de migração de 20;
- fração de migração de 0,1;
- fator de penalidade de 100;
- 20 gerações;
- população inicial gerada por uma função externa;
- vetor com os limites inferiores das restrições laterais;
- vetor com os limites superiores das restrições laterais.

O algoritmo de evolução diferencial foi retirado de Jarausch (2001) e modificado para trabalhar com parâmetros de números inteiros. As configurações utilizadas foram:

- Tamanho da população de 10 a 20 vezes N_p em função do tempo para avaliação da função objetivo;
- peso aplicado ao vetor de diferenças (constante de mutação) igual a 0,8;
- constante de crossover igual a 0,5;
- número máximo de gerações igual a 200;
- estratégia DE/rand/1/binomial.

Já para a rede PNN, utilizou-se de um executável externo, compilado usando os arquivos fontes fornecidos por Masters (1995).

CAPITULO IV

ANÁLISE PRELIMINAR DOS PARÂMETROS ESTUDADOS

Apresenta-se neste capítulo, uma análise estatística preliminar através da análise visual dos diagramas de caixa para cada parâmetro estudado, a fim de definir quais os melhores parâmetros a serem utilizados como sintomas para a classificação dos pares de sinais em focal e não focal. O principal objetivo deste capítulo é a velha máxima: “o que os olhos não veem, o coração não sente”.

4.1. ANÁLISE PRELIMINAR DOS PARÂMETROS ESTATÍSTICOS CLÁSSICOS

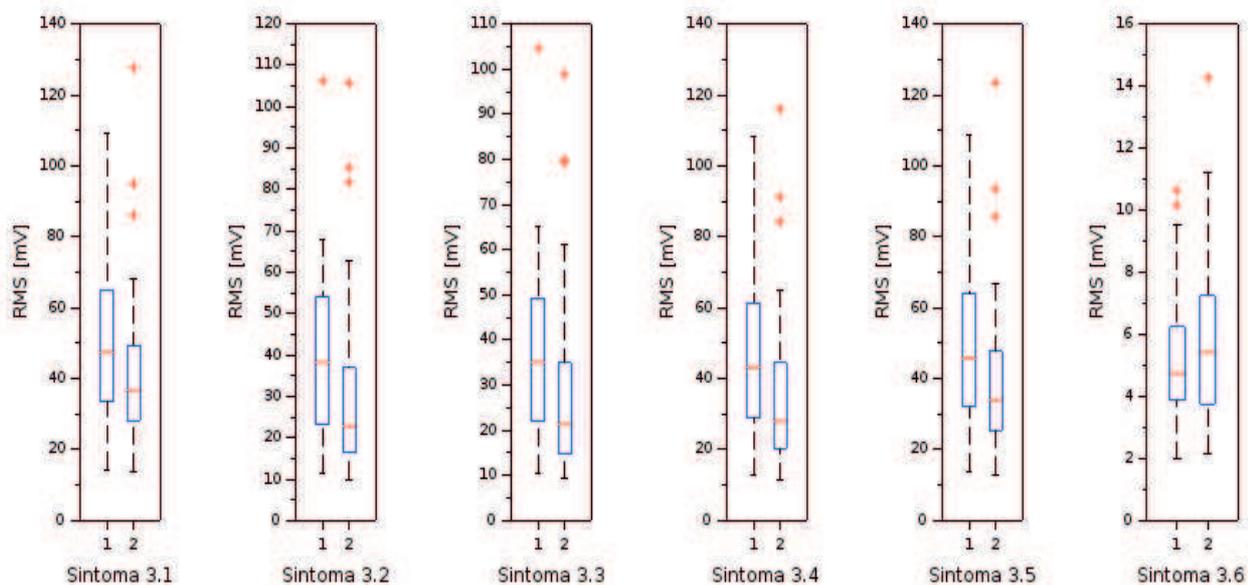
Desejou-se fazer uma inspeção visual dos sintomas relacionados aos oito parâmetros básicos (ValorRMS, V_P , V_{PP} , S_k , K_x , FC, k_4 e k_6) calculados nos sinais filtrados Total, Delta, Teta, Alfa, Beta e Gama. Para a análise, foram utilizados os boxplot dos sintomas calculados para os primeiros 50 conjuntos de sinais (focal e não focal) do banco de dados. Em função da ocorrência de valores de sintomas muito fora, a apresentação dos resultados foi limitada a dois interquartis.

Na Figura 4.1 são mostrados os gráficos boxplot do Valor RMS calculado para sinais unipolares, não normalizados, com as opções de filtro Total (Sintoma 3.1), Delta (Sintoma 3.2), Teta (Sintoma 3.3), Alfa (Sintoma 3.4), Beta (Sintoma 3.5) e Gama (Sintoma 3.6). A caixa 1 representa os conjuntos de sinais focal e a caixa 2 os conjuntos de sinais não focal.

Da análise da Fig. 4.1, observa-se que o terceiro quartil dos sintomas com os filtros delta (Sintoma 3.2) e teta (Sintoma 3.3), para os sinais não focal, estão abaixo das medianas dos sinais focal. Para o filtro gama (Sintoma 3.6) há uma inversão na magnitude das medianas.

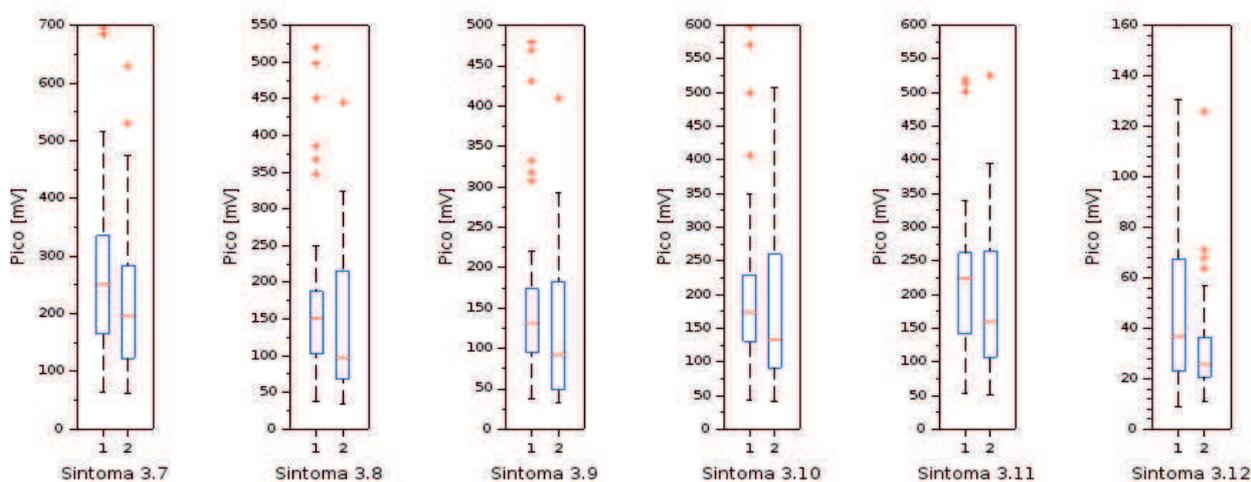
A Figura 4.2 apresenta os gráficos boxplot para o parâmetro V_P calculado para sinais unipolares, não normalizados, com as opções Total (Sintoma 3.7), Delta (Sintoma 3.8), Teta (Sintoma 3.9), Alfa (Sintoma 3.10), Beta (Sintoma 3.11) e Gama (Sintoma 3.12).

Figura 4.1. Diagrama de caixas para o parâmetro ValorRMS



Fonte: A autora, 2018.

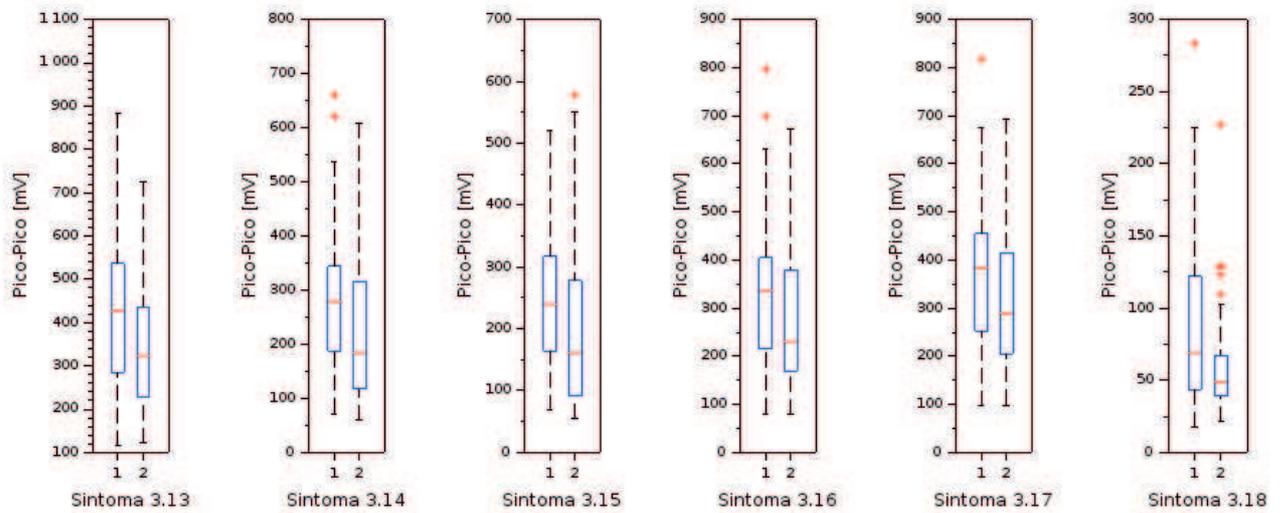
Figura 4.2. Diagrama de caixas para o parâmetro V_P



Fonte: A autora, 2018.

Ao comparar as Fig. 4.1 e 4.2, observa-se que há uma separação maior entre as medianas dos sintomas V_P e para o Gama (Sintoma 3.12) o terceiro quartil do conjunto não focal é menor que a mediana do conjunto focal.

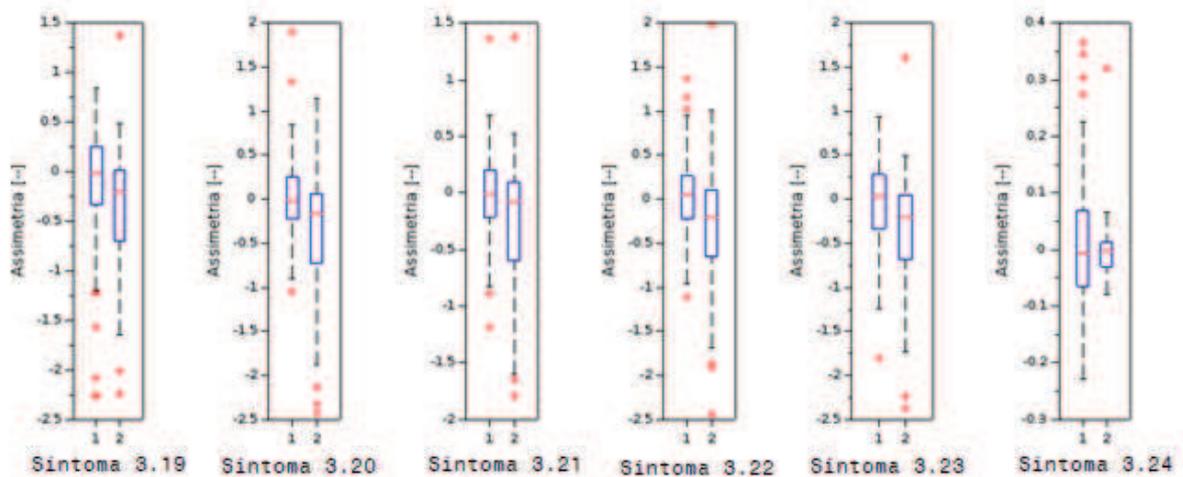
Na Figura 4.3 são apresentados os diagramas para os V_{PP} calculados para sinais unipolares, não normalizados, com as opções de filtro Total (Sintoma 3.13), Delta (Sintoma 3.14), Teta (Sintoma 3.15), Alfa (Sintoma 3.16), Beta (Sintoma 3.17) e Gama (Sintoma 3.18).

Figura 4.3. Diagrama de caixas para o parâmetro V_{PP} 

Fonte: A autora, 2018

Observa-se, na Fig. 4.3, que todas as medianas dos sinais não focais se localizam abaixo dos sinais focais, e que, para o Sintoma 3.13, a terceiro interquartil não focal é da mesma ordem de grandeza da mediana do focal.

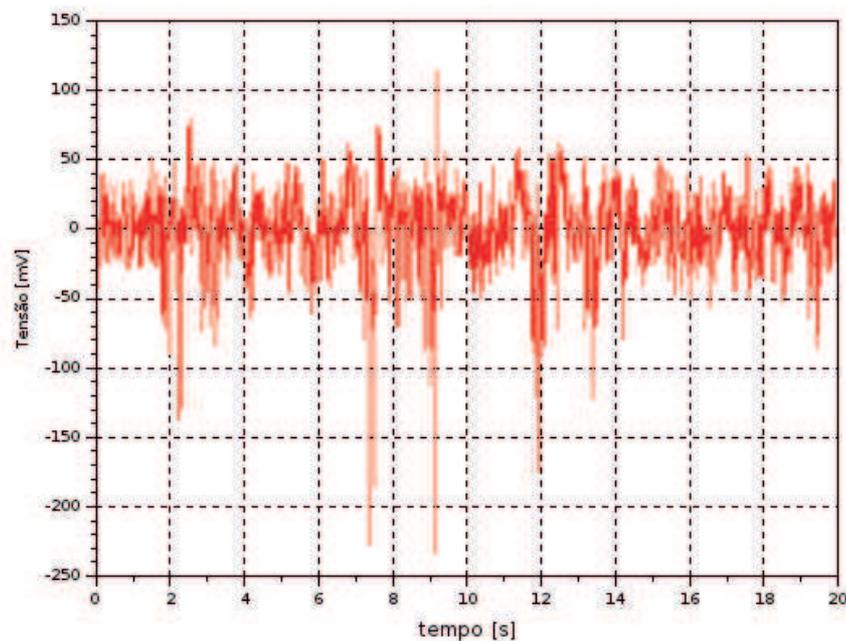
A Figura 4.4 mostra os diagramas para o parâmetro S_k calculados para sinais unipolares, não normalizados, com as opções de filtro Total (Sintoma 3.19), Delta (Sintoma 3.20), Teta (Sintoma 3.21), Alfa (Sintoma 3.22), Beta (Sintoma 3.23) e Gama (Sintoma 3.24).

Figura 4.4. Diagrama de caixas para o parâmetro S_k 

Fonte: A autora, 2018.

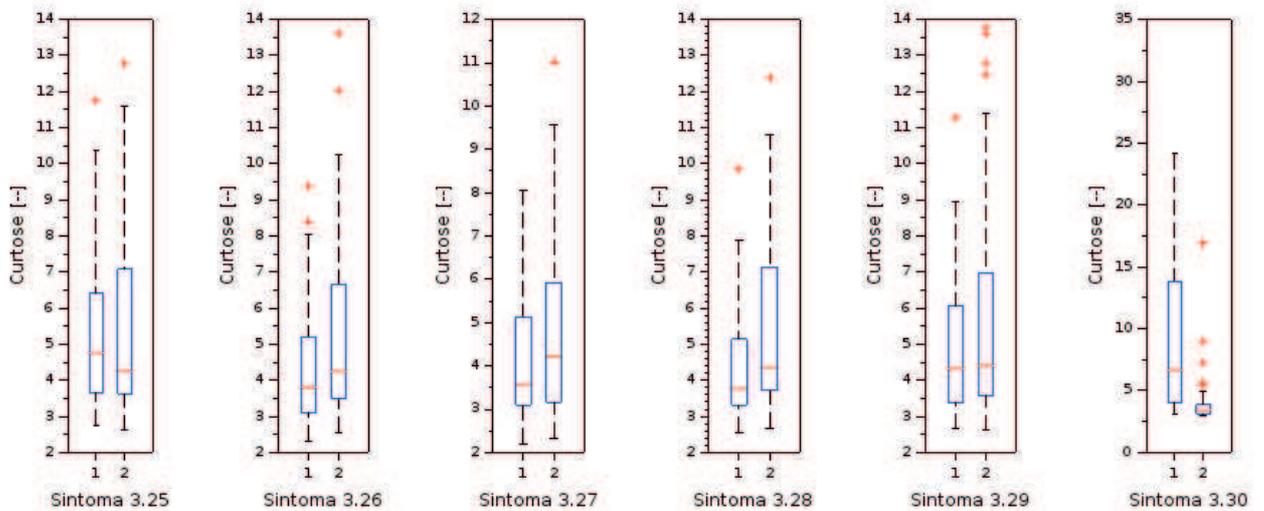
Da análise da Fig. 4.4, nota-se que os terceiros interquartis de S_k filtrado com Total, Delta, Beta e Gama do grupo não focal são da mesma ordem de grandeza das medianas do grupo focal. Observa-se, também, que a distribuição dos conjuntos focal para todos os filtros aparenta ser simétrica, ou seja, a mediana se localiza no meio dos interquartis. Com exceção do Gama, as distribuições dos sintomas não focal aparentam ser assimétricas negativas, indicando uma tendência dos sinais não focais possuírem picos negativos de grande magnitude. A Figura 4.5 mostra um sinal não focal do banco de dados utilizados, a fim de demonstrar esta afirmativa. Da figura, nota-se claramente os picos negativos, em torno de 7 segundos, 9 segundos e 13 segundos, com magnitude de aproximadamente -220, -240 e -180 mV, respectivamente, enquanto o sinal tem uma magnitude de aproximadamente 50 mV.

Figura 4.5. Gráfico de um sinal não focal do banco de dados, a título de exemplo.



Fonte: A autora, 2018.

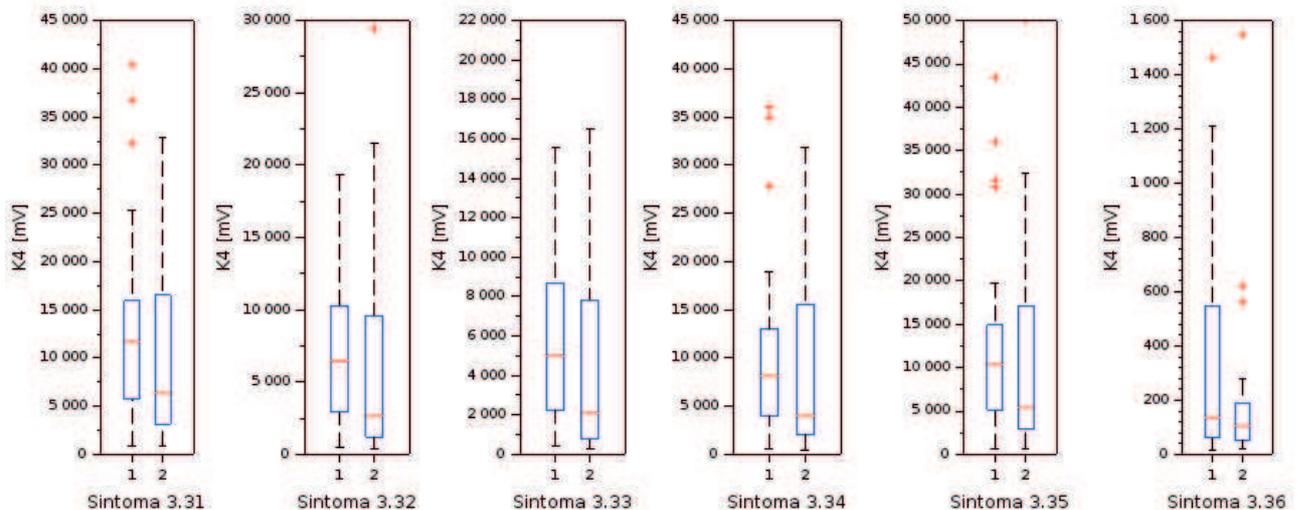
Já na Fig. 4.6 são mostrados os gráficos boxplot para os valores de K_x calculados para os sinais unipolares, não normalizados, com as opções de filtro Total (Sintoma 3.25), Delta (Sintoma 3.26), Teta (Sintoma 3.27), Alfa (Sintoma 3.28), Beta (Sintoma 3.29) e Gama (Sintoma 3.30).

Figura 4.6. Boxplot para o parâmetro K_x 

Fonte: A autora, 2018.

Observa-se na Fig 4.6 que para o filtro gama (Sintoma 3.30) existe uma forte tendência de que as populações são diferentes. Analisando os sinais focal, observa-se que pode existir ocorrências longe da média.

A Figura 4.7 apresenta os gráficos boxplot para o parâmetro k_4 calculado para sinais unipolares, não normalizados, com as opções Total (Sintoma 3.31), Delta (Sintoma 3.32), Teta (Sintoma 3.33), Alfa (Sintoma 3.34), Beta (Sintoma 3.35) e Gama (Sintoma 3.36).

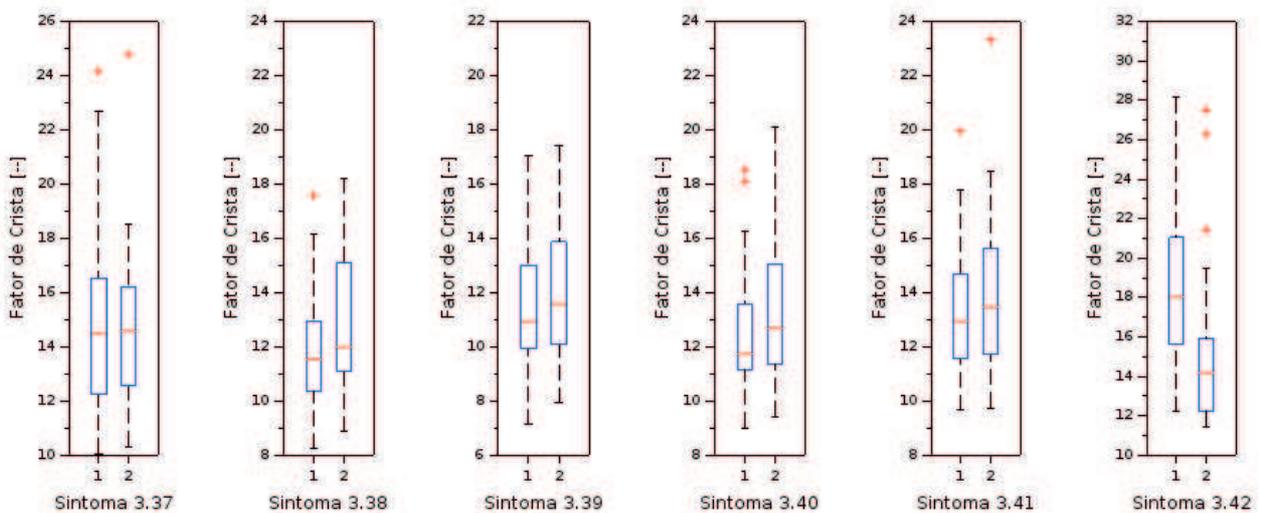
Figura 4.7. Boxplot para o parâmetro K_4 .

Fonte: A autora, 2018.

Analisando os interquartis da Fig. 4.7, observa-se que o sintoma K4 não é um bom candidato para discriminar as populações focal e não focal do banco de dados dos sinais unipolares não normalizados, uma vez que as caixas são pouco diferentes.

Na Figura 4.8 são apresentados os diagramas para os FC calculados para sinais unipolares, não normalizados, com as opções de filtro Total (Sintoma 3.37), Delta (Sintoma 3.38), Teta (Sintoma 3.39), Alfa (Sintoma 3.40), Beta (Sintoma 3.41) e Gama (Sintoma 3.42).

Figura 4.8. Boxplot para o parâmetro FC



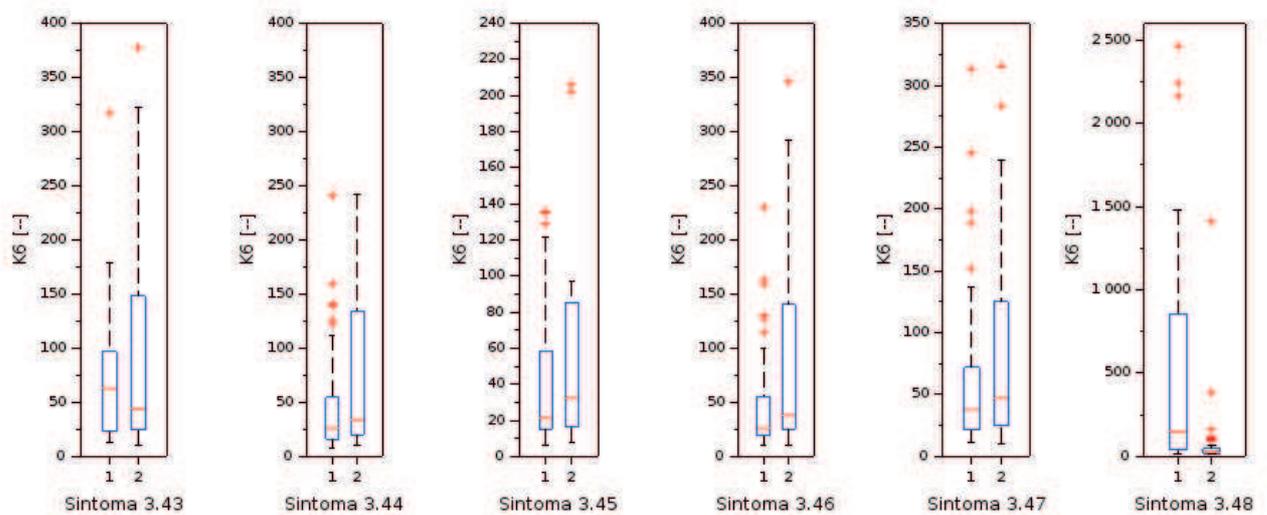
Fonte: A autora, 2018.

Ao analisar a Fig. 4.8, observa-se que para todos os sintomas, exceto o Gama, a mediana dos não focal ficam acima das medianas para o focal. Já o Sintoma 3.42 é um bom candidato para ser sintoma, uma vez que o terceiro quartil do conjunto não focal tem aproximadamente a mesma ordem de grandeza do primeiro quartil do conjunto focal.

Na Figura 4.9 são mostrados os diagramas de caixa para os estimadores K6 calculados para os sinais unipolares, não normalizados, com as opções de filtro Total (Sintoma 3.43), Delta (Sintoma 3.44), Teta (Sintoma 3.45), Alfa (Sintoma 3.46), Beta (Sintoma 3.47) e Gama (Sintoma 3.48).

O Sintoma 3.48, ao analisar a Fig. 4.9, apresenta-se como um bom candidato para discriminação dos sinais focal e não focal, considerando o banco de dados utilizado.

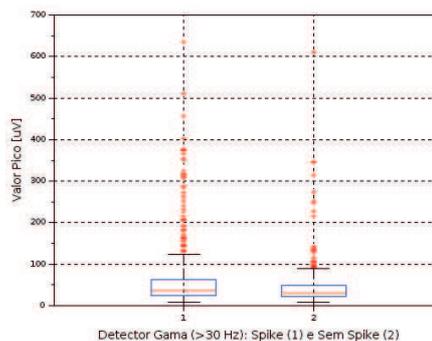
Figura 4.9. Diagrama de caixa para o estimador K6



Fonte: A autora, 2018.

Em função dos resultados analisados visualmente, desejou-se obter uma banda de frequência otimizada que resultaria nos melhores resultados para os estimadores analisados.

Inicialmente, utilizou-se como função objetivo um teste t, com 99% de confiança, para comparação de médias populacionais com 500 sinais (sem repetição), com picos de epilepsia e sem picos de epilepsia, escolhidos de maneira aleatória a partir dos 3750 dados disponíveis no banco. Por possuir valores de sintomas muito fora da tendência central, as estatísticas paramétricas foram inviabilizadas como função objetivo. Para ilustrar esta afirmativa, a Fig. 4.10 mostra os diagramas de caixas para o filtro Gama e V_P (montagem unipolar). Ao fazer o teste t, resultou num valor-P de $2,5 \cdot 10^{-5}$ indicando que as duas populações são diferentes. Porém, ao analisar a Fig. 10, observa-se que esta afirmação de populações diferentes não procede, uma vez que as caixas são praticamente iguais.

Figura 4.10. Diagrama de caixa para V_P filtrado em Gama, unipolar, não normalizado

Fonte: A autora, 2018

Analisou-se então um teste não paramétrico aplicado para duas amostras independentes, que pode ser considerado uma versão não paramétrica do teste t para comparar duas populações, o teste U de Mann-Whitney, também conhecido como teste de Wilcoxon-Mann-Whitney (Salkind, 2010).

Este teste foi proposto por Frank Wilcoxon nos anos 1945 para amostras de mesmo tamanho, e H. B. Mann e D. R. Whitney estenderam sua aplicação, em 1947, para amostras de tamanhos diferentes, fornecendo também valores de probabilidade para a distribuição U, ou seja, as estatísticas de teste (Salkind, 2010).

O teste U tem como hipótese nula que os grupos possuem mesma distribuição, com 99% de confiança. Para o cálculo de U, atribui-se valores para as amostras a fim de construir um ranking, dados pela Eq. 4.1, onde n_1 e n_2 são os tamanhos amostrais e R_1 e R_2 são a soma das fileiras das observações para cada amostra (Salkind, 2010).

$$\begin{aligned}
 U_1 &= n_1 n_2 + \frac{n_1(n_1 + 1)}{2} - R_1 \\
 U_2 &= 1n_1 n_2 + \frac{n_2(n_2 + 1)}{2} - R_2
 \end{aligned}
 \tag{4.1}$$

A estatística é definida como o mínimo entre U_1 e U_2 , e é muito útil para amostras pequenas, porém para amostras grandes, a distribuição U tende a uma distribuição normal com média e desvio padrão dados pela Eq. 4.2.

$$\begin{aligned}
 \mu &= \frac{n_1 n_2}{2} \\
 \sigma &= \sqrt{\frac{n_1 n_2 (n_1 + n_2 + 1)}{12}}
 \end{aligned}
 \tag{4.2}$$

Ao utilizar este teste, porém, como para amostras grandes ele tende a uma distribuição normal, os mesmos problemas encontrados para o teste t apareceram, uma vez que a variância do estimador tende à variância da população dividida pelo tamanho da amostra, o que implica que, para amostras muito grandes, as médias amostrais possuem variâncias muito pequenas e qualquer diferença nas médias amostrais resultam em testes de hipóteses indicando populações diferentes (baixos valores-P).

Portanto, para encontrar uma função objetivo, a métrica utilizada neste trabalho consistiu em:

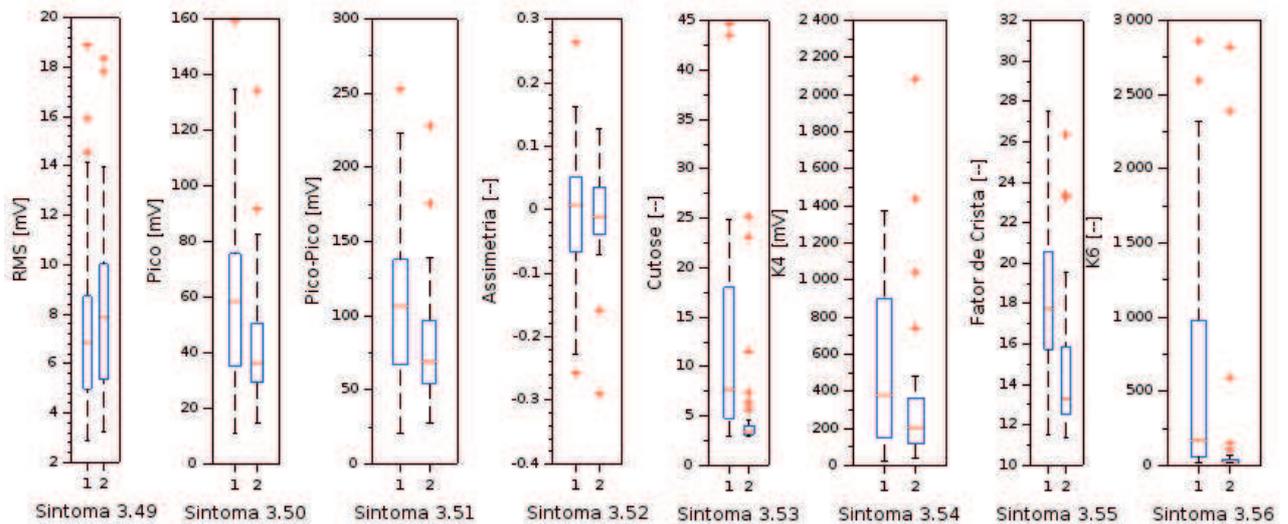
1. Realizar 100 testes de igualdade de médias calculando o valor-P para o teste U. Em cada teste são utilizados 20 valores do conjunto de dados focal e não focal;
2. Calcular a média \bar{x} e variância amostral s^2 para cada teste;
3. Utilizar a função de qualidade Menor-é-melhor de Taguchi (Rodrigues, 2018) para a construção da função objetivo z , dada pela Eq. 4.3.

$$z = \bar{x}^2 + s^2 \quad (4.3)$$

Definida a função objetivo, utilizou-se de GA para minimizar z em função da banda de frequência limitada entre 8 e 245 Hz. O tamanho da população foi de 100 indivíduos. O valor mínimo obtido para a função objetivo foi de 0,0016, para a banda de frequência entre 19.68 e 188.03 Hz.

Calculou-se então os parâmetros estatísticos para os sinais unipolares não normalizados, filtrados na banda otimizada, resultando nos sintomas 3.49 para ValorRMS, 3.50 para V_p , 3.51 para V_{PP} , 3.52 para S_k , 3.53 para K_x , 3.54 para k_4 , 3.55 para FC e 3.56 para K_6 . A Figura 4.11 mostra os diagramas de caixa para estes sintomas.

Figura 4.11. Diagrama de caixa para os parâmetros filtrados na banda otimizada.



Fonte: A autora, 2018.

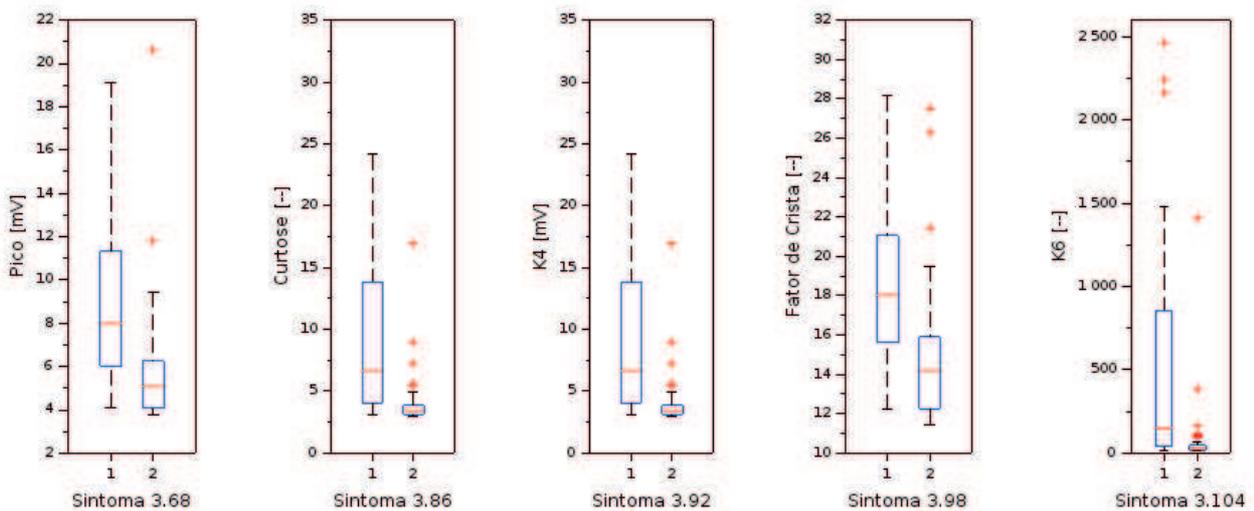
Analisando a Figura 4.11, observa-se que os parâmetros de curtose, fator de crista e k_6 são bons candidatos a sintomas para a classificação dos sinais. É importante ressaltar que o estimador K_4 sofre influência do ValorRMS, o qual apresenta uma mediana para os sinais não focal maior que a mediana para os sinais focal.

Os sintomas de 3.57 a 3.112 calculados possuem as mesmas métricas dos sintomas 3.1 a 3.56, porém agora o sinal foi normalizado pelas respectivas médias e desvios padrões. A partir deste ponto, serão apresentados apenas os resultados com diferenças amostrais mais significativas, uma vez que já se fez uma pré análise corroborando como é feita a escolha.

Deste bloco de sintomas, ao fazer uma análise visual dos diagramas, observou-se como melhores candidatos a sintoma, os sinais filtrados com Gama e com a banda otimizada, intitulada aqui como Usuário. A Figura 4.12 apresenta os gráficos boxplot para os sintomas mais significativos para os sinais filtrados com Gama, enquanto a Figura 4.13 mostra os mais significativos para os sinais filtrados por Usuário.

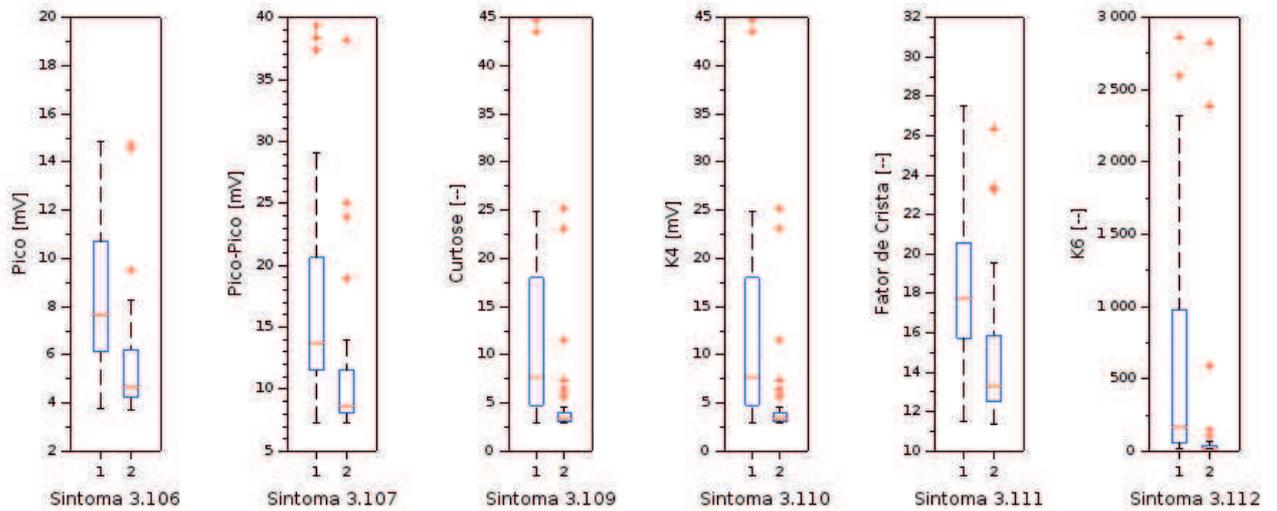
Ao analisar as figuras 4.12 e 4.13, observa-se que os estimadores curtose, K4, K6, FC e Pico se repetem nas duas figuras, e que os mesmos também foram considerados bons candidatos para os sintomas dos sinais não normalizados. Agora com os sinais normalizados, era esperado que V_P fosse um bom candidato, uma vez que os picos para os sinais com epilepsia são bem característicos.

Figura 4.12. Melhores parâmetros observados para os sinais unilaterais normalizados filtrados com Gama



Fonte: A autora, 2018.

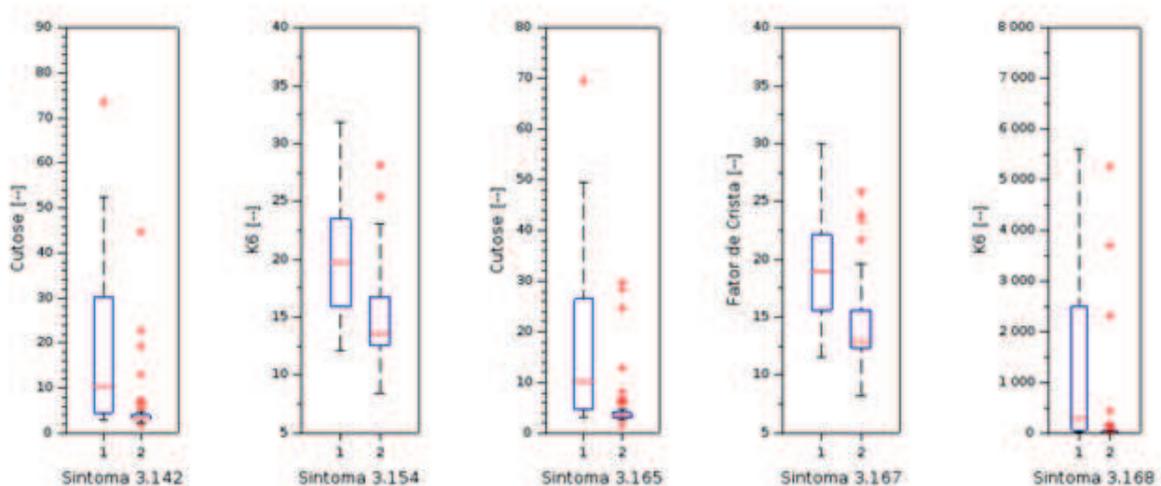
Figura 4.13. Melhores parâmetros observados para os sinais unilaterais normalizados filtrados com Usuário



Fonte: A autora, 2018.

Já os sintomas de 3.113 a 3.168 utilizou-se dos sinais dipolares não normalizados para o cálculo dos mesmos, com a mesma configuração dos sintomas 3.1 a 3.56. A Figura 4.14 apresenta os melhores resultados obtidos para os sinais dipolares, onde os melhores parâmetros foram novamente para sinais filtrados com Gama e Usuário. Os melhores resultados foram obtidos com parâmetros de espalhamento K6 (3.154 e 3.168), Curtose (3.142 e 3.165) e Fator de Crista (3.167).

Figura 4.14. Melhores parâmetros observados para os sinais dipolares normalizados filtrados com Gama (3.142 e 3.154) e Usuário (3.165, 3.167 e 3.168)



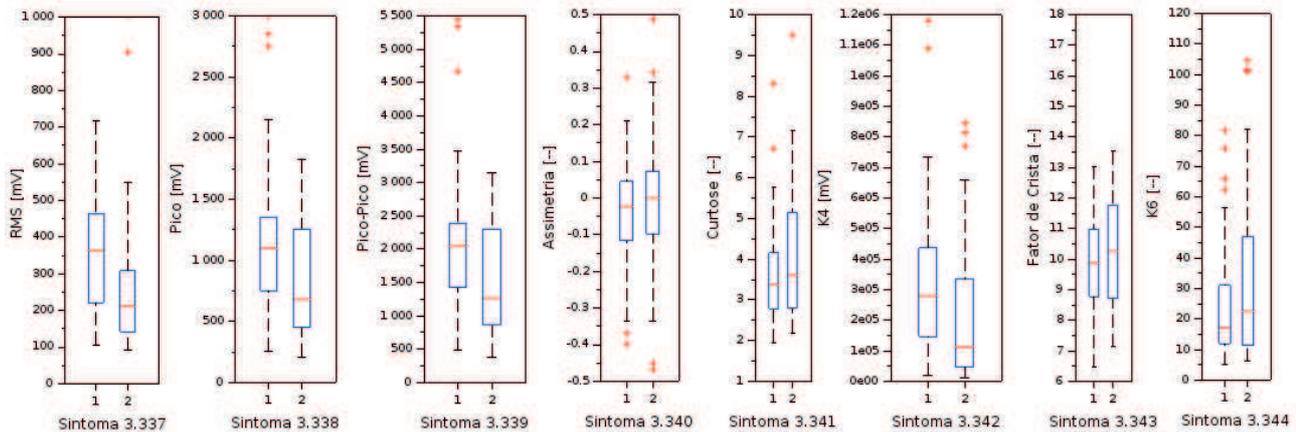
Fonte: A autora, 2018.

Os Sintomas de 169 a 224 são os mesmos de 57 a 168, porém utilizando sinais dipolares. A partir deste ponto, todos os sinais foram normalizados, uma vez que devido às grandes amplitudes, a normalização obtém resultados melhores. Novamente, os melhores resultados foram obtidos com parâmetros de espalhamento e com os sinais filtrados por Gama e Usuário. Já os sintomas de 225 a 336 são equivalentes aos sintomas de 57 a 168, porém neste bloco utilizou-se como dado de entrada para os cálculos os módulos dos envelopes dos sinais unipolares normalizados. As maiores separações são observadas para os sinais filtrados com Gama e Usuário, além do sintoma 3.323, que é o estimador K6 para o sinal com filtro Total.

O próximo conjunto de sintomas são os sinais tratados por Transformada Wavelet Contínua, com família de base dB4. As escalas foram escolhidas de forma a contemplar as faixas de frequências teta, alfa, beta e gama, conforme descrito na Seção 3.3.

Na Figura 4.15 são mostrados os parâmetros estudados para as escalas otimizadas para a banda delta, considerando os sinais unipolares normalizados. As escalas valem 160.84 para o sintoma ValorRMS, 91.45 para V_P , 90.50 para V_{PP} , 120.63 para S_k , 329.75 para K_x , 91.43 para K_4 , 348.27 para FC e 327.83 para K6. As escalas que abrangem a banda delta vão de 90 (≈ 4 Hz) a 350 (≈ 1 Hz).

Figura 4.15. Diagrama de caixa para os sinais unipolares tratados com escala delta da WT.



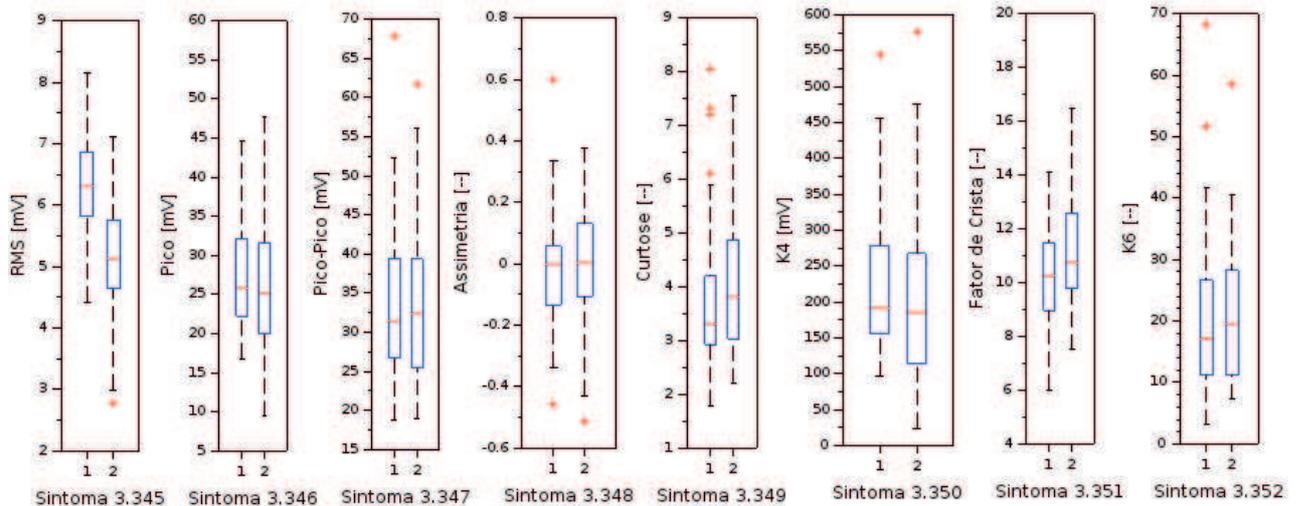
Fonte: A autora, 2018.

Apesar de se observar uma distância considerável entre as medianas dos parâmetros ValorRMS, V_P , V_{PP} e K_4 (Figura 4.15) ao analisar os interquartis e os bigodes, não é possível observar uma nítida separação entre as amostras focais e não focais.

Na Figura 4.16 são mostrados os parâmetros estudados para as escalas otimizadas para a banda delta, considerando os sinais dipolares normalizados. As escalas valem 115.30 para o

sintoma ValorRMS, 159.53 para V_P , 61.81 para V_{PP} , 108.16 para S_k , 231.16 para K_x , 155.41 para K_4 , 241.01 para FC e 315.10 para K_6 . Desta figura (4.16), observa-se que o parâmetro ValorRMS é um bom candidato a sintoma, uma vez que os interquartis estão bem separados.

Figura 4.16. Diagrama de caixa para os sinais dipolares tratados com escala delta da WT.

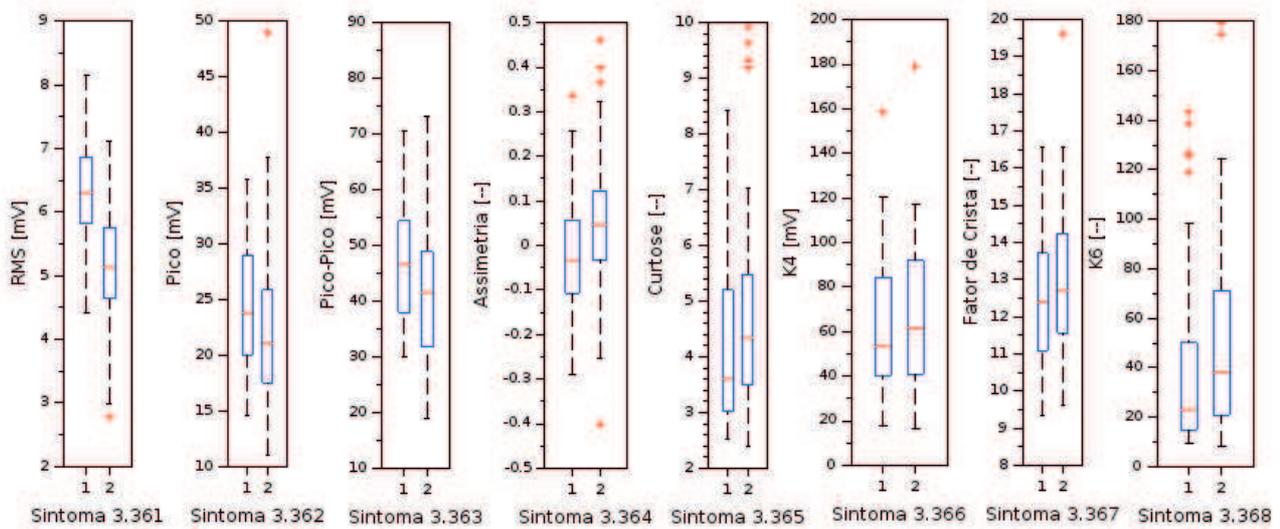


Fonte: A autora, 2018.

Os sintomas de 3.353 a 3.360 referem-se aos parâmetros estatísticos para as escalas otimizadas para a banda teta, considerando os sinais unipolares. As escalas valem 118.76 para o sintoma ValorRMS, 87.36 para V_P , 83.97 para V_{PP} , 73.14 para S_k , 56.21 para K_x , 76.69 para K_4 , 83.71 para FC e 55.19 para K_6 . As escalas que abrangem a banda teta vão de 120 (≈ 3 Hz) a 55 (≈ 7 Hz). Com esse conjunto de sintomas, não houve nenhuma separação visual significativa para escolha de possíveis candidatos.

Já a Figura 4.17 apresenta os parâmetros estudados para as escalas otimizadas para a banda teta, porém agora para os sinais dipolares normalizados. As escalas valem 115.07 para o sintoma ValorRMS, 112.95 para V_P , 119.34 para V_{PP} , 57.95 para S_k , 119.40 para K_x , 55.96 para K_4 , 82.08 para FC e 120.00 para K_6 . Assim como na Fig. 4.16, observa-se na Fig. 4.17, um bom distanciamento das medianas de alguns sintomas e uma boa separação entre os interquartis do sintoma ValorRMS.

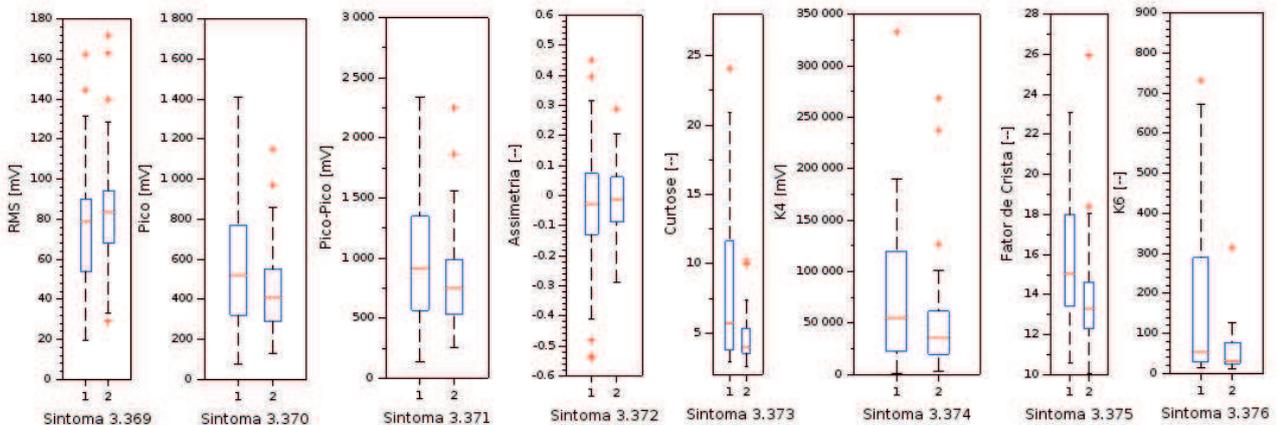
Figura 4.17. Diagrama de caixa para os sinais dipolares tratados com escala teta da WT.



Fonte: A autora, 2018

Os sintomas de 3.369 a 3.376, apresentados na Fig. 4.18, referem-se aos parâmetros estatísticos para as escalas otimizadas para a banda alfa, considerando os sinais unipolares. As escalas valem 28.18 para o sintoma ValorRMS, 30.72 para V_P , 29.18 para V_{PP} , 31.62 para S_k , 31.62 para K_x , 31.40 para K_4 , 28.11 para FC e 37.68 para K_6 . As escalas que abrangem a banda alfa vão de 28 (≈ 13 Hz) a 55 (≈ 7 Hz). Da análise da Fig. 4.18, pode-se observar a tendência de separação das populações para os parâmetros Fator de Crista e K_6 .

Figura 4.18. Diagrama boxplot para os sinais unipolares tratados com escala alfa da WT.

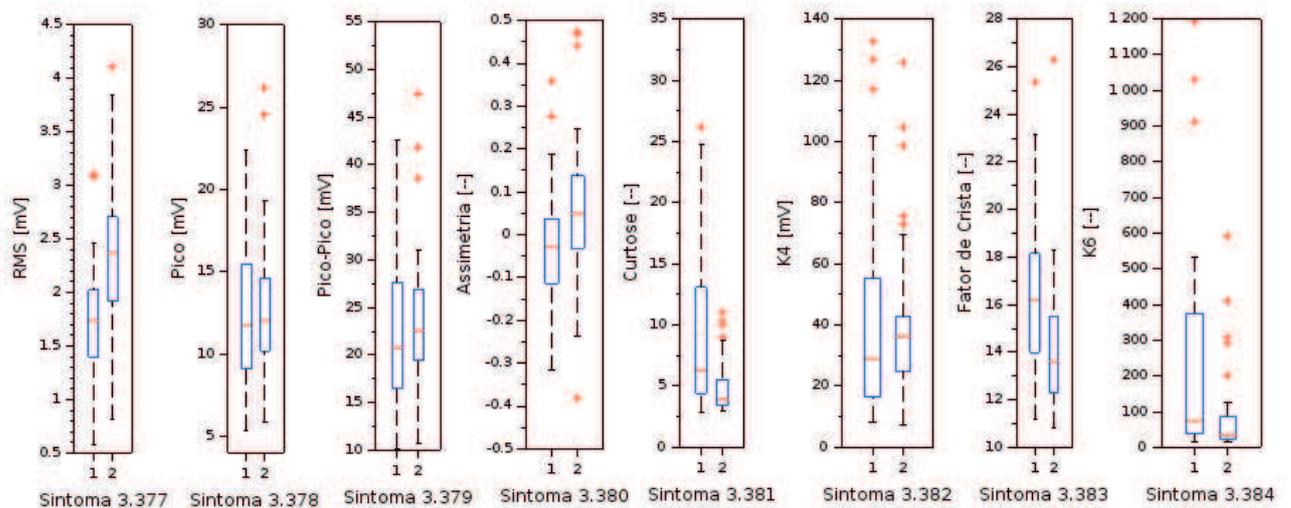


Fonte: A autora, 2018.

Na Figura 4.19 são mostrados os parâmetros estudados para as escalas otimizadas para a banda alfa, considerando agora os sinais dipolares normalizados. As escalas valem 28.71 para

o sintoma ValorRMS, 31.85 para V_P , 31.02 para V_{PP} , 54.07 para S_k , 28.53 para K_x , 35.50 para K_4 , 28.81 para FC e 32.53 para K_6 . Desta figura (4.19), além dos parâmetros já observados para o sinal unipolar, percebe-se também que o parâmetro ValorRMS é um bom candidato a sintoma, uma vez que os interquartis estão bem separados, bem como a curtose.

Figura 4.19. Diagrama boxplot para os sinais dipolares tratados com escala alfa da WT.

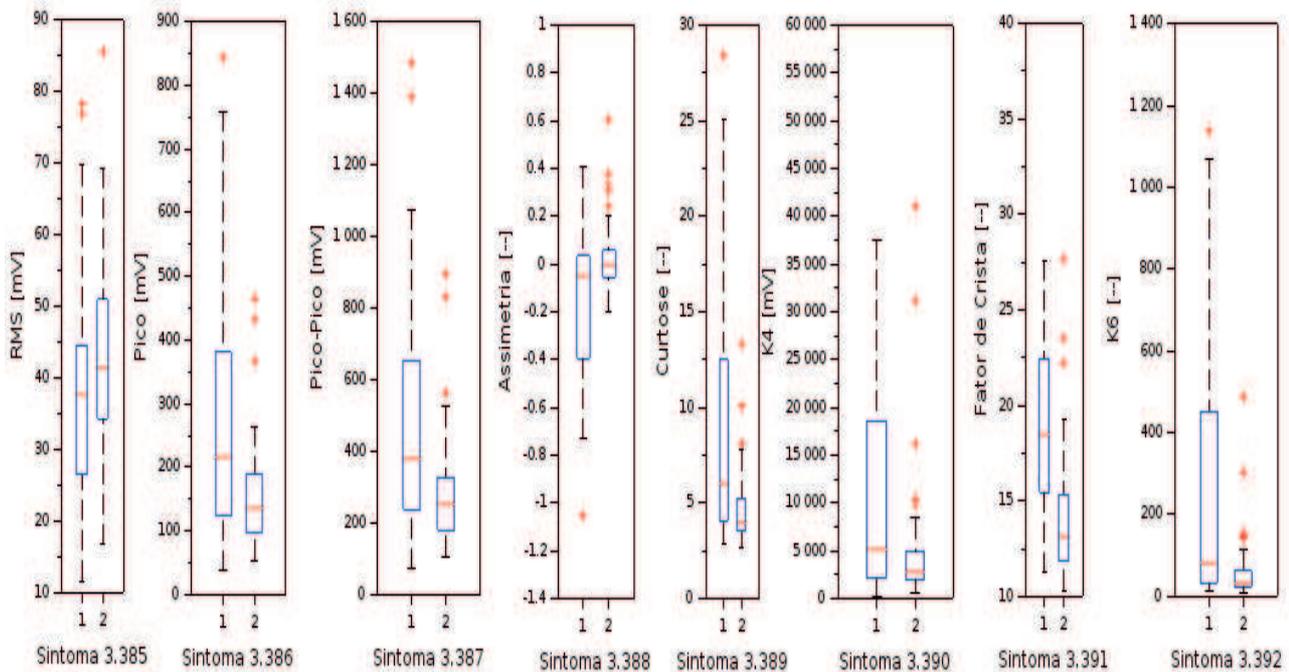


Fonte: A autora, 2018

Já a Figura 4.20 apresenta os parâmetros estudados para as escalas otimizadas para a banda beta, para os sinais unipolares normalizados. As escalas valem 16.27 para o sintoma ValorRMS, 12.48 para V_P , 12.70 para V_{PP} , 12.47 para S_k , 27.60 para K_x , 12.51 para K_4 , 12.89 para FC e 27.69. Para esta banda beta, as escalas que abrangem vão de 228 (≈ 13 Hz) a 12.15 (≈ 30 Hz).

Observa-se, na Fig. 4.20, que os sintomas 3.386, 3.387, 3.389, 3.390 e 3.392 o valor do terceiro quartil dos sinais não focal é menor que a mediana dos sinais focal. Porém, deste bloco de sintomas, o que melhor se candidata é o Sintoma 3.391, que representa o Fator de Crista, onde observa-se que o terceiro quartil dos sinais não focal é menor que o primeiro quartil dos sinais focal.

Figura 4.20. Diagrama de caixas para os sinais unipolares tratados com escala beta da WT.



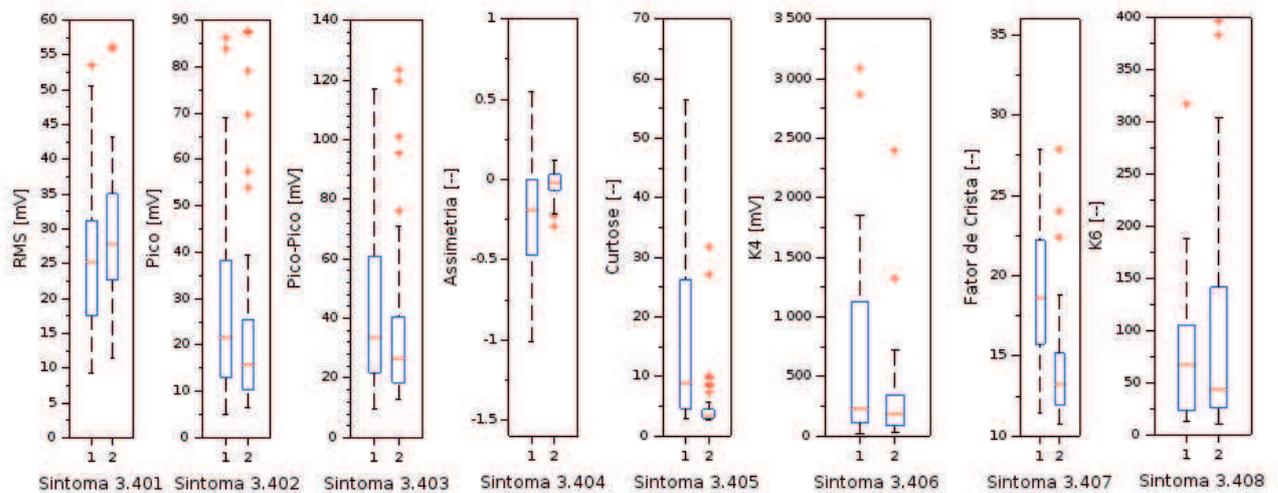
Fonte: A autora, 2018.

Os sintomas de 3.393 a 3.400 referem-se aos parâmetros estatísticos para as escalas otimizadas para a banda beta, considerando agora os sinais dipolares. As escalas valem 17.67 para o sintoma ValorRMS, 12.41 para V_P , 12.57 para V_{PP} , 16.27 para S_k , 25.99 para K_x , 12.38 para K_4 , 16.31 para FC e 27.21 para K_6 . Os diagramas destes sintomas são parecidos com os da Figura 4.20.

Na Figura 4.21 são mostrados os parâmetros estudados para as escalas otimizadas para a banda gama, considerando os sinais unipolares. As escalas valem 12.00 para o sintoma ValorRMS, 2.19 para V_P , 2.32 para V_{PP} , 4.41 para S_k , 12.05 para K_x , 4.64 para K_4 , 11.43 para FC e 1.50 para K_6 . As escalas que abrangem a banda gama vão de 12.15 (≈ 30 Hz) a 1.462 (≈ 250 Hz).

Analisando a Fig. 4.21, observa-se bons resultados para a assimetria, curtose e fator de crista, com os interquartis quase não intercedendo, para a assimetria, e abaixo para os sinais não focal nos sintomas 3.405 e 3.407, o que os torna bons candidatos.

Figura 4.21. Diagrama boxplot para os sinais unipolares tratados com escala gama da WT.



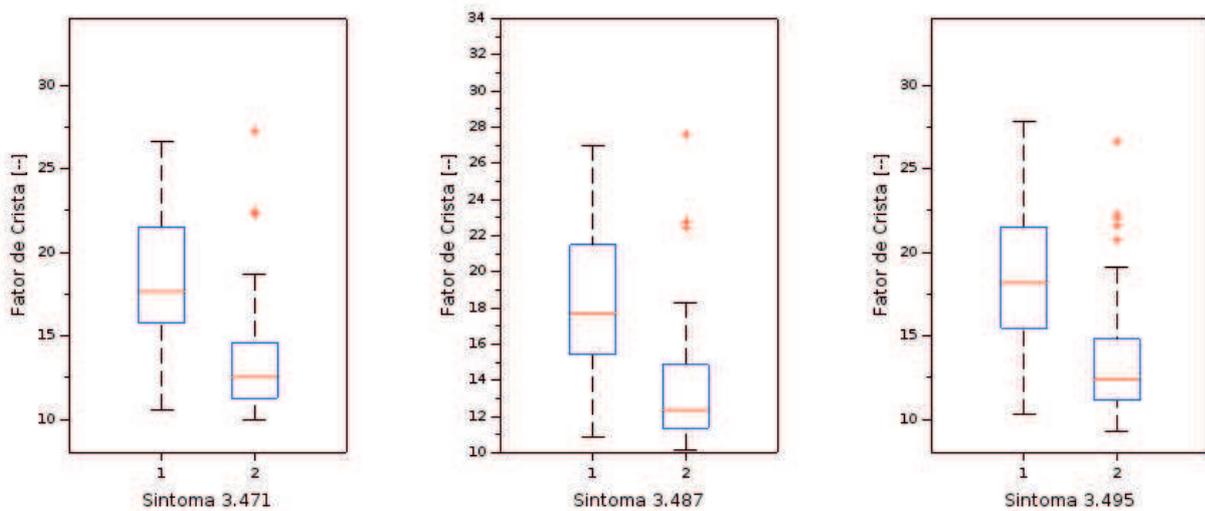
Fonte: A autora, 2018.

Já os sintomas de 3.409 a 3.416 referem-se aos parâmetros estatísticos para as escalas otimizadas para a banda gama, considerando agora os sinais dipolares. As escalas valem 12.00 para o sintoma ValorRMS, 2.19 para V_P , 2.32 para V_{PP} , 4.41 para S_k , 12.05 para K_x , 4.64 para K_4 , 11.43 para FC e 1.05. Para os sinais dipolares, apenas para o sintoma Fator de Crista observa-se uma diferença na média das duas populações.

Posteriormente, aplicou-se aos sinais tratados pela WT, uma análise envelope, o que resultou nos sintomas de 3.417 a 3.496, que são as funções de 3.337 a 3.416 aplicados sobre os módulos dos envelopes dos sinais. Os principais indicadores para a afirmação de que as populações são diferentes foram observadas nos sintomas 3.425 (ValorRMS da db4 do sinal dipolar normalizado - escala 115.30); 3.441 (ValorRMS da db4 do sinal dipolar normalizado - escala 115.07); 3.457 (Valor RMS da db4 do sinal dipolar normalizado - escala 28.71); 3.468 (Valor de S_k da db4 do sinal unipolar normalizado - escala 17.47); 3.471 (Valor de FC da db4 do sinal unipolar normalizado - escala 12.89); 3.473 (Valor RMS da db4 do sinal dipolar normalizado - escala 17.61); 3.476 (Valor de S_k da db4 do sinal dipolar normalizado - escala 16.27); 3.484 (Valor de S_k da db4 do sinal unipolar normalizado - escala 4.41); 3.485 (Valor de K_x da db4 do sinal unipolar normalizado - escala 12.05); 3.487 (Valor de FC da db4 do sinal unipolar normalizado - escala 11.43); 3.492 (Valor de S_k da db4 do sinal dipolar normalizado - escala 2.43); e 3.495 (Valor de FC da db4 do sinal dipolar normalizado escala - 12.08). A exceção do sintoma 3.457, onde o primeiro quartil do sinal não focal era maior que o terceiro do sinal não focal, todos os outros sintomas apresentaram o terceiro interquartil do conjunto focal menor do que o primeiro interquartil do conjunto não focal.

A título de ilustração, a Fig. 4.22 mostra os diagramas de caixas para os sintomas de FC relevantes. Observa-se nitidamente, uma diferença entre os diagramas, com valores de mediana bem diferentes.

Figura 4.22. Diagrama boxplot para os sintomas de FC mais relevantes, da análise de envelope dos sinais tratados por WT.



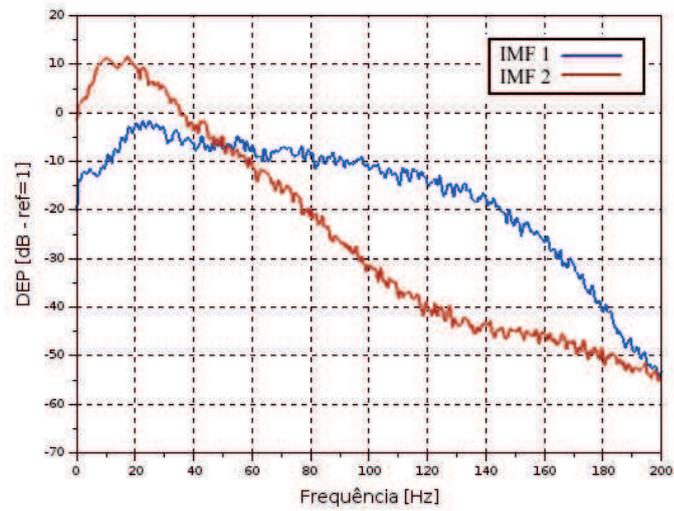
Fonte: A autora, 2018.

Os sintomas de 3.497 a 4.700 envolvem, sequencialmente, os seis primeiros modos empíricos (EMD), associados às seis primeiras IMF com a seguinte configuração por modo:

1. Índice de ortogonalidade do modo i para o sinal unipolar;
2. Os oito parâmetros do modo i para o sinal unipolar;
3. Os oito parâmetros do resíduo do modo i para o sinal unipolar;
4. Índice de ortogonalidade do modo i para o sinal dipolar;
5. Os oito parâmetros do modo i para o sinal dipolar;
6. Os oito parâmetros do resíduo do modo i para o sinal dipolar.

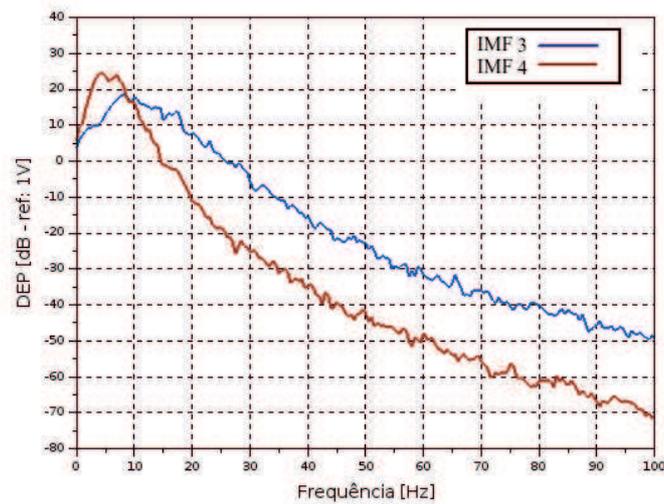
A utilização dos seis primeiros modos empíricos se justifica pela análise das Figuras de 4.23 a 4.25, onde são mostradas as estimativas das densidades espectrais de potência (PSD) para os seis primeiros modos empíricos utilizando 100 blocos de dados focal com uma resolução em frequência de 0,5 Hz.

Figura 4.23. PSD dos primeiros dois modos intrínsecos para o sinal focal.



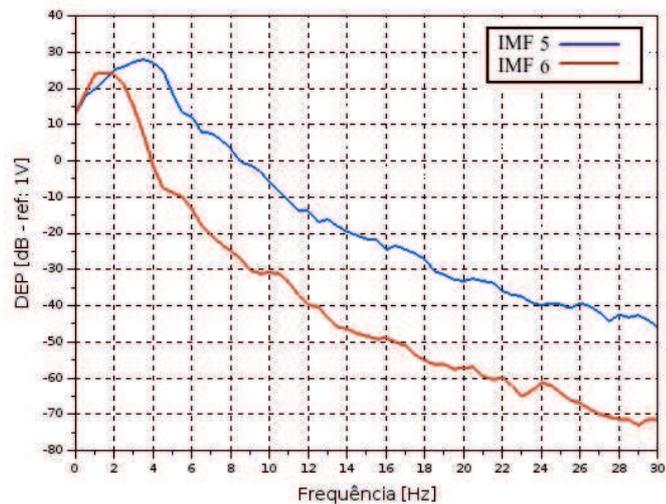
Fonte: A autora, 2018.

Figura 4.24. PSD dos modos intrínsecos três e quatro para o sinal focal.



Fonte: A autora, 2018.

Figura 4.25. PSD dos modos intrínsecos cinco e seis do sinal focal.



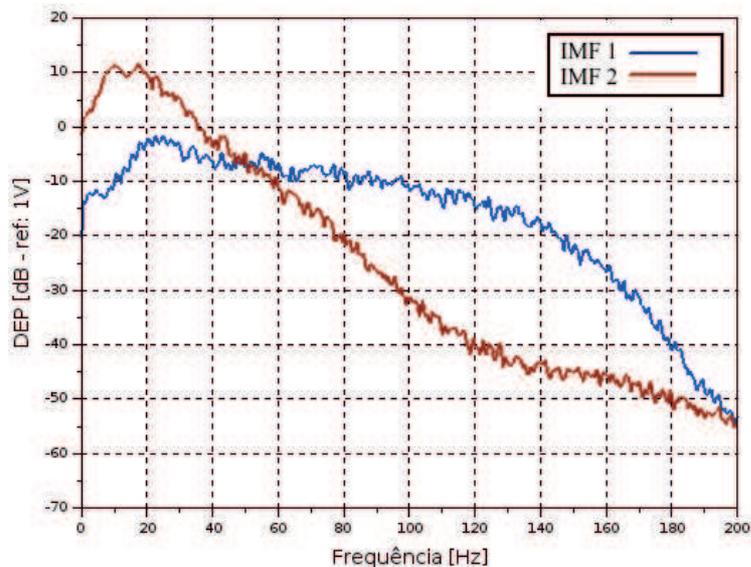
Fonte: A autora, 2018.

Da análise das figuras 4.23 a 4.25, observa-se que, comparado aos outros espectros, a PSD do IMF 1 cobre a banda de 15 a 200 Hz (Figura 4.23), ou seja cobre a banda de frequências que foi otimizada, aqui chamada de Usuário (19.68 a 188.03 Hz); a faixa de frequências das PSD dos IMF 2 e IMF 3 é aproximadamente igual à faixa do filtro Beta (13 a 30 Hz); a PSD do IMF 4 (Figura 4.24) é equivalente à PSD do filtro Alfa (passa bandas entre 7 a 13 Hz); e na Figura 4.25, observa-se que as PSD dos IMF 5 e IMF 6 são equivalentes aos filtros Delta (passa baixas em 4 Hz) e Teta (passa bandas de 3 a 7 Hz), respectivamente.

A PSD do resíduo das seis IMF tem uma banda em frequência de 0 a 2 Hz, e observa-se também que as PSD dos IMF dos sinais não focal têm o mesmo comportamento das PSD dos sinais focal. Para exemplificar esta afirmativa, a Fig. 4.26 mostra as PSD dos IMF 1 e 2 de 100 blocos de sinais não focal.

Ao comparar as Figuras 4.23 e 4.26, observa-se as mesmas faixas de frequência sendo contempladas.

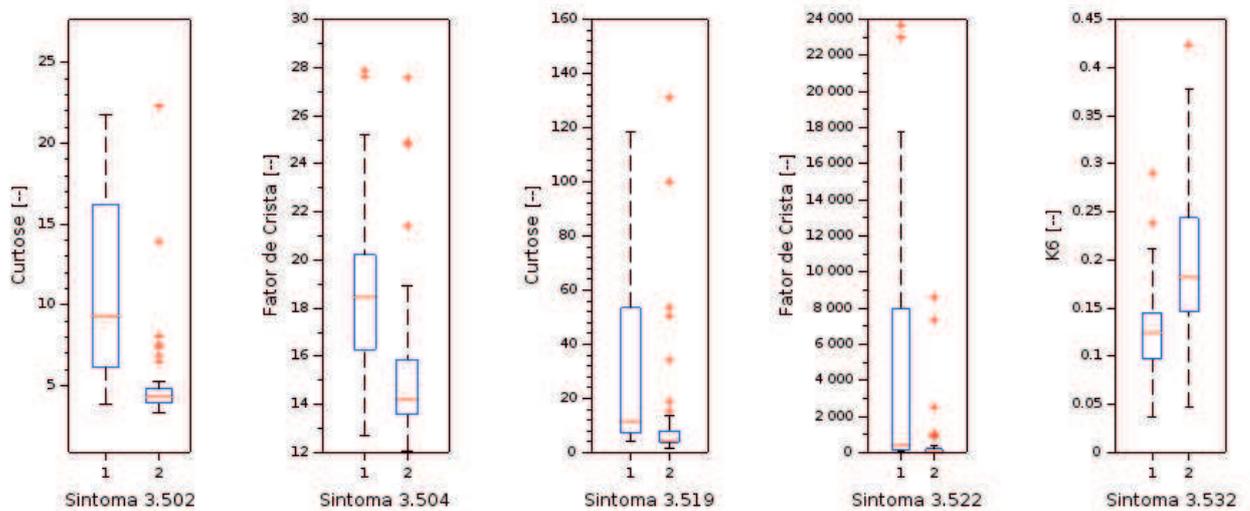
Figura 4.26. Densidade Espectral de Potência dos primeiros modos intrínsecos para o conjunto de dados não focal.



Fonte: A autora, 2018.

Na Figura 4.27 são mostrados os diagramas de caixas dos parâmetros do IMF 1 que, visualmente, melhor discrimina as duas populações. Ao observar a figura, nota-se uma boa separação proporcionada pela curtose e fator de crista do sinal unipolar normalizado, e também a amplitude do terceiro quartil do fator de crista da amostra focal, além da inversão do K6 dos sinais dipolares normalizados. O Sintoma 3.519 também diz respeito aos sinais dipolares.

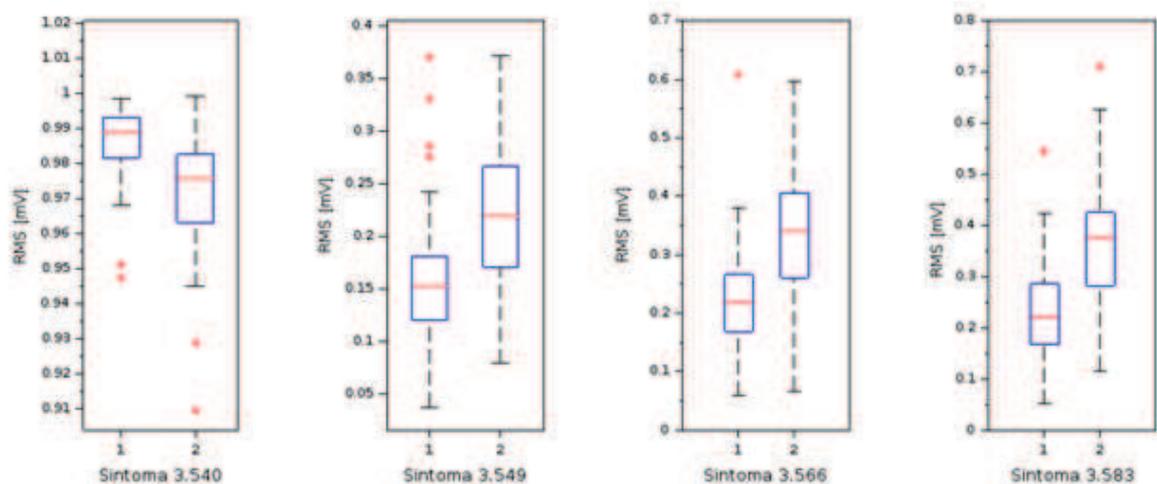
Figura 4.27. Melhores parâmetros observados para o primeiro modo empírico.



Fonte: A autora, 2018.

Os melhores resultados, mostrados na Figura 4.28, foram os sintomas: 3.540, que é o ValorRMS do resíduo do segundo modo para o sinal unipolar, o 3.549 é relativo ao ValorRMS e envolve os sinais do segundo modo dipolar normalizados, o 3.566 diz respeito ao terceiro modo unipolar, ValorRMS e sintoma 3.583 é o ValorRMS do terceiro modo para o sinal dipolar. É importante ressaltar que para todos os ValorRMS dos sinais dipolares, houve uma inversão no diagrama e para o 3.466.

Figura 4.28. Melhores parâmetros observados para as EMD.

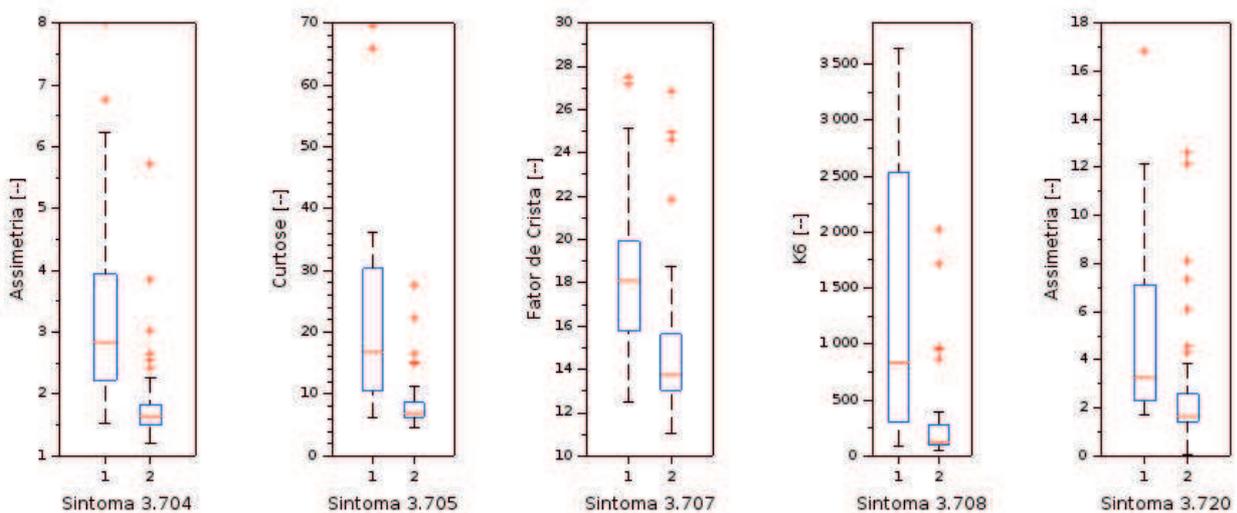


Fonte: A autora, 2018.

Os sintomas 3.701 a 3.892 envolvem, sequencialmente, as HHT utilizando os seis primeiros modos empíricos (EMD). As mesmas configurações utilizadas para os sintomas da EMD foram utilizadas neste bloco de sintomas.

A Figura 4.29 mostra os melhores sintomas utilizando de HHT para o primeiro modo empírico dos sinais unipolares normalizados, que foram S_k (3.704), K_x (3.705), FC (3.707) e K_6 (3.708). Já para os sinais dipolares normalizados do primeiro modo, somente a assimetria (3.720) mostrou-se como um bom candidato a discriminação das duas populações. Vale ressaltar, da análise da figura, que os interquartis não se cruzam, estando o interquartil dos sinais não focal sempre abaixo do interquartil dos sinais focal.

Figura 4.29. Melhores parâmetros observados para a HHT do primeiro modo.



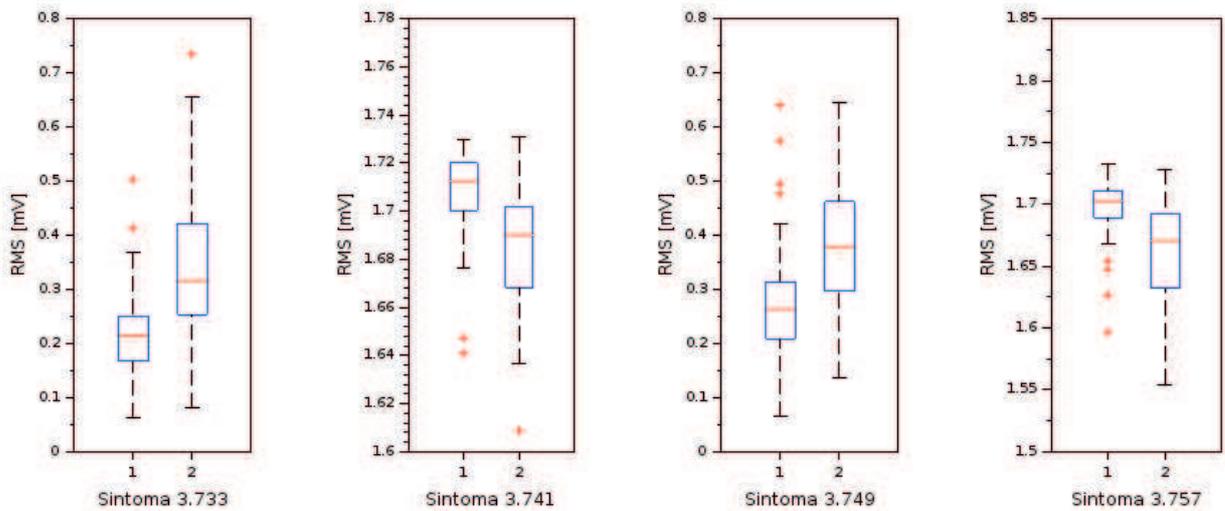
Fonte: A autora, 2018.

Já ao aplicar a HHT para o segundo modo, observou-se bons parâmetros tanto para o modo quanto para seu resíduo. A Figura 4.30 mostra estes parâmetros, todos relacionados ao cálculo do ValorRMS: segundo modo (3.733) e resíduo (3.741) dos sinais unipolares e segundo modo (3.749) e resíduo (3.757) dos sinais dipolares.

Observa-se que para os resíduos, os primeiros interquartis do conjunto focal se localizam acima dos terceiros interquartis do conjunto não focal, já para os resíduos há uma inversão. Estas inversões observadas podem ser explicadas devido ao fato da energia na região do segundo modo migrar para os outros modos (resíduos e primeiro modo) para o conjunto de sinais focal. Esta hipótese é validada ao analisar os melhores candidatos a sintomas para a discriminação dos sinais, utilizando da HHT do terceiro modo (Figura 4.31). Ao analisar e

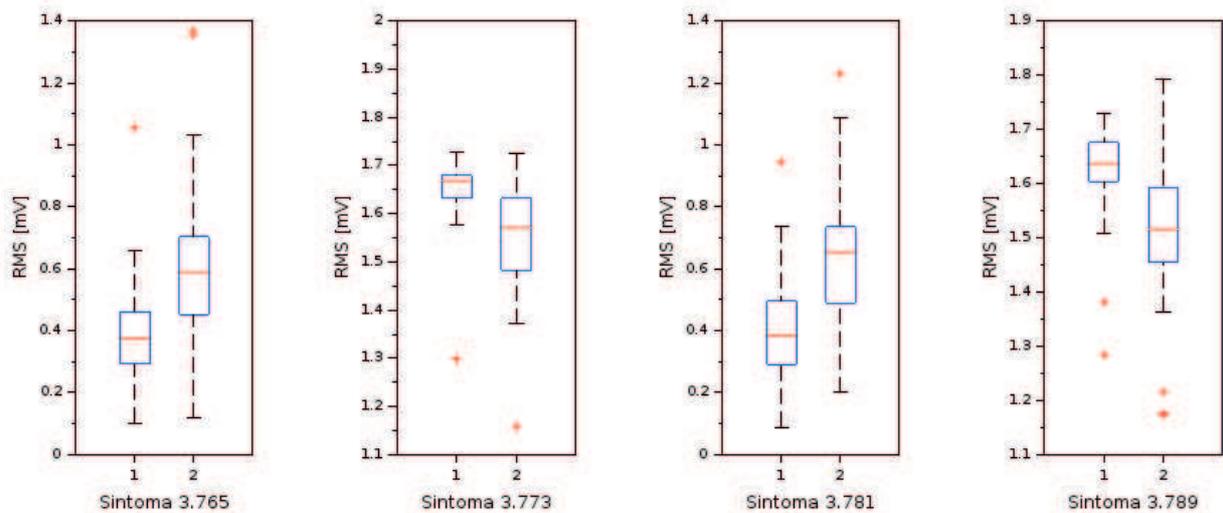
comparar as figuras, observa-se que a sequência do segundo modo se repete, tem-se os melhores candidatos o cálculo dos ValorRMS: para o terceiro modo (3.765) e resíduo (3.773) dos sinais unipolares e terceiro modo (3.781) e resíduo (3.789) dos sinais dipolares, e a inversão também ocorre para os modos. Analisando os modos 4, 5 e 6, não se obteve nenhum candidato a sintoma.

Figura 4.30. Melhores parâmetros observados para a HHT do segundo modo.



Fonte: A autora, 2018.

Figura 4.31. Melhores parâmetros observados para a HHT do terceiro modo.

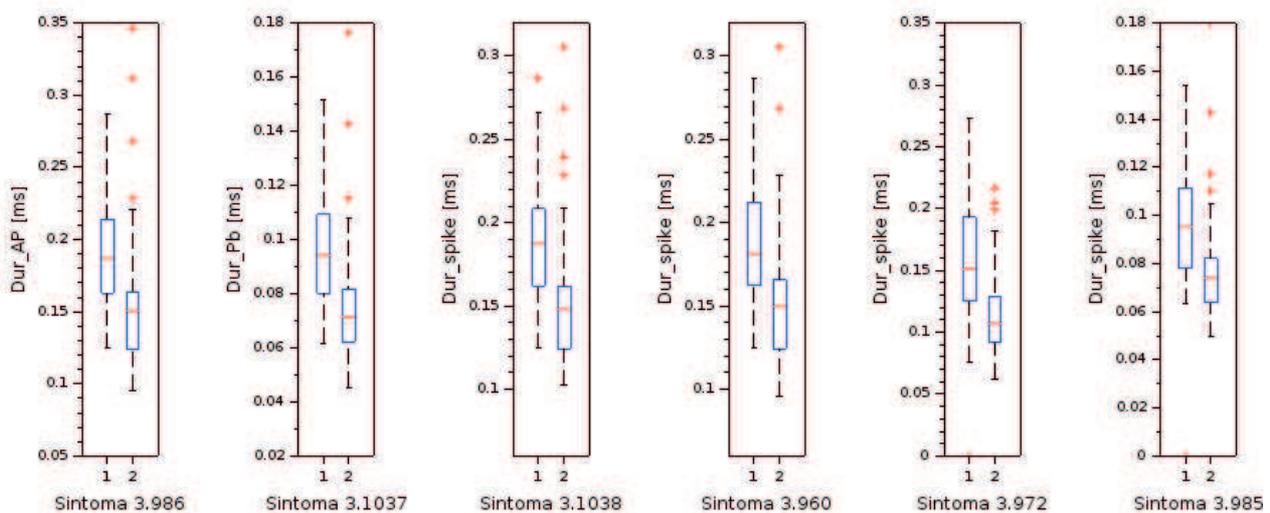


Fonte: A autora, 2018.

Os candidatos a sintomas de 3.893 a 3.1152 se referem aos treze sintomas do k-NEO, com largura de pico variando de 20 a 60 milissegundos e de 25 a 65 milissegundos, utilizando um intervalo de 10 milissegundos para os dois casos.

Da análise dos diagramas de caixas para os parâmetros de k-NEO, 12 candidatos a sintomas foram obtidos: uma Dur_AP, quatro Dur_PB, quatro Dur_spike, uma Amp_AP e duas Slope_PB. Dessas 12, apresenta-se na Fig. 4.32, os melhores resultados obtidos que foram os sintomas: 3.986 que é a Amp_AP para o intervalo de 60 ms; 3.1037 que é a Dur_PB para o intervalo de 35 ms; 3.1038 que é a Dur_spike para o intervalo de 35 ms; 3.960 que é a Dur_spike para o intervalo de 40 ms e 3.985 que é a Dur_spike para o intervalo de 60 ms.

Figura 4.32. Melhores parâmetros observados para a análise k-NEO.



Fonte: A autora, 2018.

Ao analisar a Fig. 4.32, observa-se que os melhores candidatos a sintoma são os valores médios relacionados às durações tanto de pico quanto de meia onda de pico, com valores de k escolhidos para períodos maiores que 35 ms.

Dentro do bloco de 50 conjuntos de dados utilizados para a análise utilizando k-NEO, foram encontrados 21 sinais com características da onda lenta que se sucede a um pico, para o conjunto focal. Já para o conjunto não focal foram observadas apenas nove ocorrências. Esta diferença, e a baixa frequência para o conjunto não focal explica o fato de não existir nenhuma métrica relacionadas às ondas lentas (Dur_slowwave, Amp_slowwave e Area_slowwave) como possíveis candidatos para este conjunto de dados.

Para os sintomas de 3.1153 a 3.1180, foram calculados os valores de entropia $RenEn_{Avg}$, $ShEn_{Avg}$, $ApEn_{Avg}$ e $SampEn_{Avg}$ para os seis primeiros modos intrínsecos e seus respectivos resíduos. Os melhores resultados foram observados para os valores pico a pico e assimetria do primeiro modo empírico.

Resumindo, na Tab. 4.1 são mostrados a quantidade de candidatos a sintoma, relacionados a cada um dos oito parâmetros estatísticos analisados neste trabalho (ValorRMS, Pico, Pico a Pico, Assimetria, Curtose, K4, Fator de Crista e K6).

Tabela 4.1. Quantidade de candidatos a sintoma para cada um dos oito parâmetros analisados.

Parâmetro	Vezes em que foi candidato a sintoma
ValorRMS	15
V_P	3
V_{PP}	3
S_k	9
K_x	10
K4	3
FC	14
K6	8

Fonte: A autora, 2018.

Ao analisar a Tab. 4.1, observa-se que os parâmetros que mais se repetiram foram ValorRMS, FC e K_x , com 15, 14 e 10 ocorrências respectivamente. Era esperado que o ValorRMS fosse um bom parâmetro uma vez que o conjunto de sinais focal possui mais energia, em função dos picos. A mesma coisa vale para FC e curtose, que medem as excursões fora da média, também relacionadas aos picos focais. Isto não significa que, ao ser associado a outros sintomas para a classificação via algoritmos de otimização e procedimentos de classificação, estes apresentarão os melhores resultados, uma vez que há uma combinação entre eles.

CAPÍTULO V

APRESENTAÇÃO E ANÁLISE DOS RESULTADOS OBTIDOS

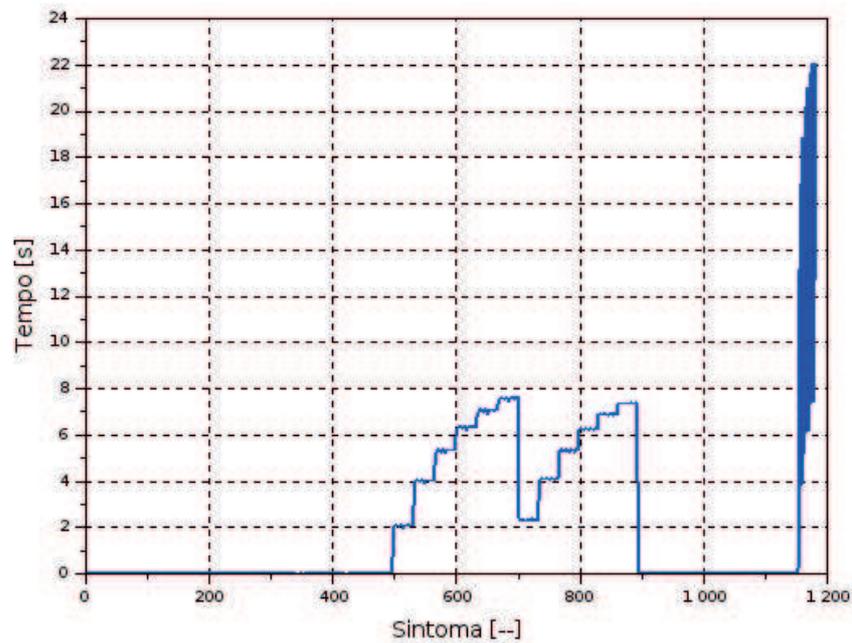
Neste capítulo, são apresentados os resultados obtidos utilizando as rotinas de otimização GA e ED para a escolha dos melhores sintomas que minimizam a função objetivo, associados aos procedimentos de classificação.

5.1. TEMPO NECESSÁRIO PARA O CÁLCULO DOS PARÂMETROS

Ao montar o Banco de Dados a ser utilizado para testar as metodologias adotadas neste trabalho, foram computados os tempos médios para o cálculo de cada parâmetro, considerando dez segundos de sinal. O parâmetro tempo médio em segundos foi escolhido para se ter uma ideia realista do tempo de computação dos sintomas para a realidade do ano de 2017. Para o cálculo do tempo médio optou-se por utilizar um notebook de médio porte com processador Intel® Core™ i5-4200M CPU@ 2.50GHz x 4 com memória de 8 GB. Para nenhuma rotina foi usado processamento paralelo, porém os tempos foram calculados como se houvesse esse processamento pois acredita-se que numa aplicação real os sintomas serão calculados em paralelo, portanto o tempo total para o cálculo de todos os sintomas será limitado pelo tempo de processamento do sintoma mais lento. Nos procedimentos de otimização foi utilizado um processador com 12 núcleos, 32 GB e processamento paralelo.

Na Figura 5.1 é mostrado o gráfico com os resultados dos tempos de processamento para todos os 1180 parâmetros estudados. Na figura, os parâmetros de 497 até 892 envolvem Decomposição em Modos Empíricos (EMD), o que exige muito processamento. Já os parâmetros de 1153 até 1180 envolvem, além da EMD, cálculos de entropia com custos máximos encontrados para parâmetros com avaliações de Entropia Média Aproximada.

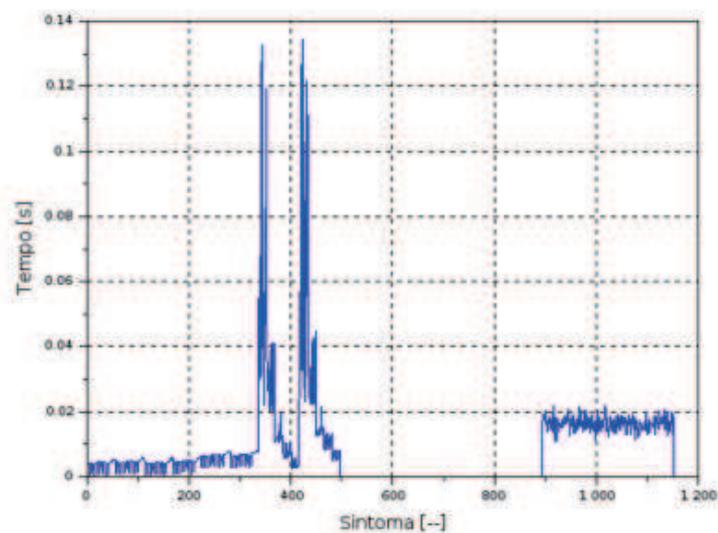
Figura 5.1. Gráfico dos tempos de processamento para todos os sintomas calculados.



Fonte: A autora, 2018

Devido ao alto custo computacional das EMD, apresenta-se na Fig. 5.2 o gráfico dos tempos de processamento, considerando um limite superior de 1 segundo, a fim de verificar quais os tempos de processamento para os outros sintomas.

Figura 5.2. Gráfico dos tempos de processamento para os sintomas calculados, excluindo os relacionados a EMD.



Fonte: A autora, 2018.

Da análise da Fig. 5.2, observa-se que os maiores tempos de computação ocorrem para os parâmetros envolvendo as WT. Os tempos de processamento dos parâmetros k_NEO são da ordem de 0,016 segundos. Os outros parâmetros têm um tempo médio de processamento de 6,7 milissegundos.

Conclui-se, ao analisar os tempos de processamento, que, mesmo permitindo processamento paralelo, deve-se evitar o uso de EMD em aplicações onde o tempo de resposta deve ser considerado.

5.2. MELHORES SINTOMAS USANDO kNN

Para a definição dos melhores sintomas a serem utilizados com o procedimento de classificação kNN, foram estudadas configurações com número de parâmetros N_p variando de 2 a 10, com passo de 1, e valores de k entre 2 e 23, utilizando apenas números primos. Depois de uma série de pré-testes realizados, optou-se pelo algoritmo de ED para a otimização, visto que o mesmo convergia mais rápido do que o GA para esta configuração. A função objetivo para todos os classificadores foi a precisão ACC.

Na Tabela 5.1 são apresentadas as configurações utilizadas para o kNN, a precisão obtida para o conjunto de validação ACC_v , a precisão média obtida para o conjunto de teste ACC_t e seu respectivo desvio padrão s_t .

Tabela 5.1. Valores obtidos para a classificação por kNN.

N_p	K	ACC_v	ACC_t	s_t
2	3	80,0	69,0	2,6
	5	84,0	68,8	3,6
	7	83,0	72,0	4,7
	11	81,0	72,0	3,8
	13	85,0	71,8	4,1
	17	83,0	75,0	5,3
	19	84,0	67,4	5,6
	23	84,0	71,8	3,1

Tabela 5.1. Valores obtidos para a classificação por kNN.

(continuação)

Np	K	ACC _v	ACC _t	s _t
3	3	85,0	70,6	1,3
	5	86,0	73,4	4,5
	7	84,0	73,8	3,9
	11	85,0	74,8	4,0
	13	86,0	78,8	3,3
	17	87,0	74,3	3,0
	19	87,0	75,2	3,7
	23	88,0	75,6	3,4
4	3	83,0	69,8	2,9
	5	86,0	76,2	2,3
	7	89,0	77,6	3,8
	11	87,0	71,6	5,3
	13	87,0	77,2	3,3
	17	88,0	76,6	3,2
	19	89,0	77,6	1,8
	23	87	77,6	3,3
5	3	84,0	76,8	1,9
	5	88,0	76,2	2,5
	7	87,0	74,6	2,3
	11	90,0	80,4	1,7
	13	89,0	77,4	2,7
	17	90,0	77,0	5,0
	19	88,0	73,8	5,3
	23	88,0	75,6	3,4
6	3	84,0	73,2	3,3
	5	88,0	79,4	2,3
	7	89,0	77,8	2,8
	11	87,0	78,6	2,6
	13	89,0	78,4	2,9
	17	90,0	76,6	2,9
	19	89,0	75,8	4,9
	23	88,0	77,8	4,1

Tabela 5.1. Valores obtidos para a classificação por kNN.

Np	K	ACC _v	ACC _t	(conclusão)
				s _t
7	3	84,0	72,6	4,0
	5	88,0	71,0	5,0
	7	87,0	77,4	4,8
	11	87,0	75,8	3,5
	13	89,0	79,8	2,9
	17	90,0	76,4	4,0
	19	89,0	75,8	4,9
	23	88,0	75,8	3,6
8	3	84,0	74,0	3,0
	5	88,0	75,0	4,6
	7	87,0	73,8	4,9
	11	87,0	77,6	1,5
	13	90,0	80,2	2,9
	17	90,0	77,0	5,0
	19	89,0	76,2	4,6
	23	88,0	74,4	2,5
9	3	85,0	72,8	4,5
	5	89,0	72,8	0,4
	7	88,0	77,6	4,4
	11	86,0	78,0	5,0
	13	87,0	78,4	5,1
	17	88,0	79,8	4,3
	19	89,0	79,0	3,5
	23	89,0	78,8	1,3
10	3	84,0	72,8	4,1
	5	89,0	73,8	5,8
	7	87,0	76,6	4,4
	11	87,0	69,6	4,6
	13	88,0	73,6	4,9
	17	88,0	79,4	3,7
	19	88,0	78,4	3,8
	23	88,0	80,8	2,8

Fonte: A autora, 2018

Estatisticamente, a melhor combinação de fatores para o KNN foram para 5 parâmetros e k igual a 11, resultando numa precisão média de teste de 80,4 e desvio de 1,7 e para 8 parâmetros e k igual a 13, o que resultou em uma precisão média de 80,2 e um desvio de 2,9. Os sintomas para cada uma das configurações, com as respectivas descrições e o tempo total de processamento, estão apresentados nos Quadros 5.2 e 5.3.

Quadro 5.2. Sintomas escolhidos para a configuração de kNN com Np igual a 5 e k igual a 13

Sintoma	Descrição	Tempo de Processamento [s]
3.276	Assimetria do módulo do envelope para o sinal unipolar normalizado filtrado por Usuário	0,12
3.425	Valor do fator de crista da db4 do sinal unipolar normalizado escala 11.43	
3.476	Valor Pico da db4 do sinal unipolar normalizado escala 12.476955	
3.674	Valor do Fator de Crista do modo 6 da EMD (6 modos) do sinal unipolar normalizado	
3.1115	Duração da segunda meia onda de pico para k igual a 60 milissegundos	

Fonte: A autora, 2018

Quadro 5.3. Sintomas escolhidos para a configuração de kNN com Np igual a 8 e k igual a 13

Sintoma	Descrição	Tempo de Processamento [s]
3.142	Curtose do sinal filtrado por Gama para o sinal dipolar não normalizado	44,22
3.238	Valor pico a pico do módulo do envelope do sinal unipolar filtrado em delta	
3.414	Valor do K4 da db4 do sinal dipolar normalizado com escala 3.31	
3.424	Valor K6 da db4 do sinal unipolar normalizado com escala 327.83	
3.506	Valor RMS do resíduo da EMD (1 modo) do sinal monopolar normalizado.	
3.642	Valor RMS do resíduo da EMD (5 modos) do sinal monopolar normalizado.	
3.767	Valor pico a pico do terceiro modo da HHT	
3.1115	Duração da segunda meia onda de pico para k igual a 60 milissegundos	

Fonte: A autora, 2018

Analisando os Quadros 5.2 e 5.3, observa-se um tempo de processamento muito maior para a configuração 8 parâmetros e k igual a 13, o que faz com que a configuração 5 parâmetros seja melhor, além de possuir um menor desvio padrão. Observa-se também que um dos sintomas se repetiu, 3.1115, e que as métricas ValorRMS e FC foram as que mais se repetiram, assim como já observado no Cap. 4.

A Tabela 5.4 mostra o valor médio, e respectivos desvios padrões, para todas as métricas de avaliação de desempenho utilizadas neste trabalho, para as duas melhores configurações. É importante lembrar que seis testes foram realizados, com um conjunto de dados diferentes.

Tabela 5.4. Valores médios, e respectivos desvios padrões, para as métricas de avaliação de desempenho, para as melhores configurações para kNN.

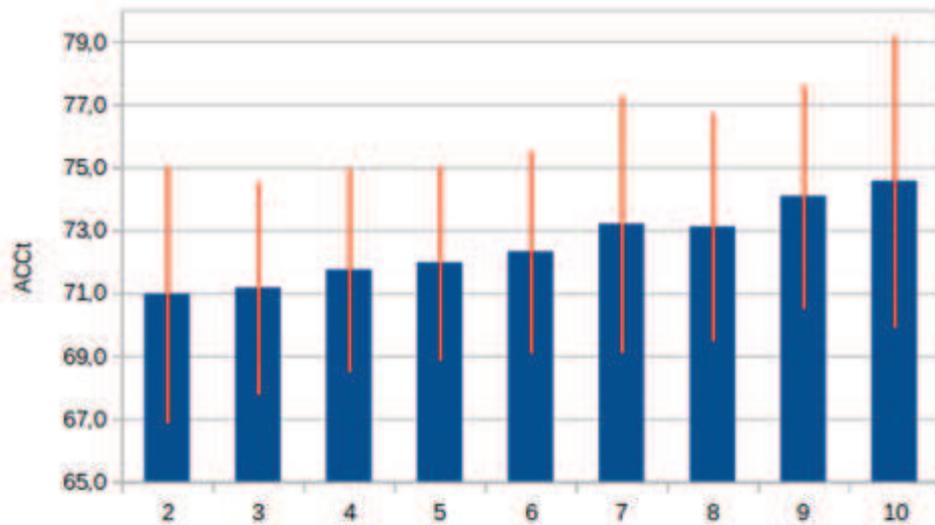
N_p	k	SEN [%]	SPF [%]	ACC [%]	PPV [%]	NPV [%]	MCC [%]
5	11	77,6	84,0	80,4	74,2	78,8	0,6
		3,0	2,4	1,7	5,7	2,1	0,1
8	13	81,6	78,8	80,2	84,6	81,1	0,6
		3,6	3,0	2,9	4,3	3,3	0,1

Fonte: A autora, 2018.

Da análise da Tab. 5.4, observa-se uma relativa variação para as métricas SEN e PPV, para ambos os casos, com desvios da ordem de 3 e 5, respectivamente. A sensibilidade reflete a habilidade de detectar os picos, a especificidade avalia a habilidade de se discriminar sinal não focal, PPV representa a fração de valores positivos identificados e que realmente são positivos enquanto NPV indica a fração de valores negativos identificados corretamente. Tem-se uma melhor identificação de verdadeiros positivos e negativos para a configuração com 8 parâmetros. Nota-se também que a SPF para 5 parâmetros é melhor do que para 8 e que o MCC é igual para ambos os casos, e este parâmetro quanto mais alto, melhor o desempenho do classificador.

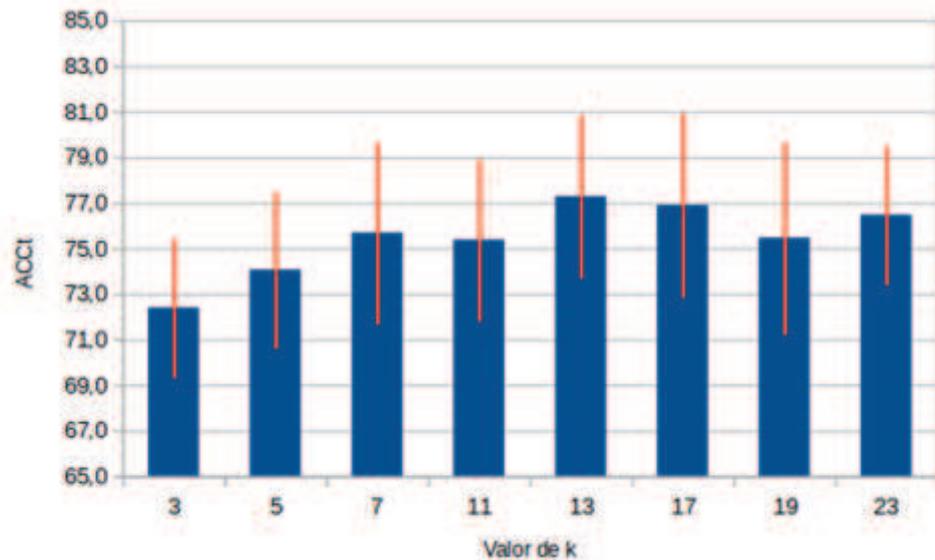
A Figura 5.3 mostra a influência média do número de parâmetros na precisão do algoritmo kNN, enquanto a Figura 5.4 mostra a influência do fator k na precisão do algoritmo para os seis testes realizados.

Figura 5.3. Influência média do número de parâmetros na precisão do algoritmo kNN.



Fonte: A autora, 2018.

Figura 5.4. Influência do fator k na precisão do algoritmo kNN.



Fonte: A autora, 2018.

Da análise das figuras, observa-se um aumento da precisão quando se aumenta o número de parâmetros. A configuração ótima seria k igual a 13, variando de 74 a 81% e 10 parâmetros, que varia entre 70 e 79%.

5.2. MELHORES SINTOMAS UTILIZANDO DE WkNN COMO CLASSIFICADOR

Para a definição dos melhores sintomas a serem utilizados com o classificador WkNN, as mesmas configurações utilizadas para kNN descritas na seção 5.1, foram adotadas. Na Tabela 5.5 são apresentadas as configurações utilizadas no WkNN, a ACC_v, a ACC_t e respectivo desvio padrão.

Tabela 5.5. Valores obtidos para a classificação por WkNN.

Np	K	ACC _v	ACC _t	s _t
2	3	86,0	79,4	5,0
	5	86,0	78,6	4,7
	7	85,0	78,0	4,4
	11	85,0	77,0	5,0
	13	85,0	77,4	5,2
	17	85,0	77,4	4,6
	19	86,0	79,2	4,3
	23	84,0	75,2	2,8
3	3	86,0	79,4	5,0
	5	87,0	78,2	6,4
	7	86,0	79,6	4,9
	11	86,0	77,4	3,5
	13	88,0	78,8	2,7
	17	87,0	79,2	2,6
	19	87,0	75,6	2,3
	23	87,0	74,8	2,2
4	3	88,0	77,8	7,4
	5	89,0	83,8	2,9
	7	88,0	81,6	2,2
	11	88,0	80,8	1,5
	13	89,0	82,6	0,9
	17	89,0	81,0	2,2
	19	89,0	79,2	3,0
	23	88,0	78,4	2,9

Tabela 5.5. Valores obtidos para a classificação por WkNN.

(continuação)

N_p	k	ACC_v	ACC_t	s_t
5	3	87,0	74,8	7,2
	5	88,0	82,0	3,9
	7	89,0	82,6	3,2
	11	88,0	72,4	6,4
	13	90,0	81,8	2,6
	17	89,0	79,8	2,8
	19	89,0	81,2	2,8
	23	90,0	84,0	2,3
6	3	87,0	73,8	7,7
	5	89,0	83,6	3,2
	7	88,0	74,8	6,5
	11	88,0	82,4	3,8
	13	88,0	79,0	2,9
	17	89,0	83,2	3,9
	19	89,0	79,6	3,0
	23	89,0	79,6	3,8
7	3	88,0	80,8	1,8
	5	88,0	77,2	3,4
	7	89,0	82,0	2,5
	11	89,0	84,2	1,9
	13	89,0	84,2	1,8
	17	89,0	78,0	4,0
	19	88,0	84,2	2,0
	23	89,0	83,0	2,8
8	3	89,0	81,4	2,1
	5	88,0	80,4	2,6
	7	88,0	83,8	3,0
	11	89,0	81,2	2,3
	13	90,0	75,2	3,1
	17	90,0	74,8	4,0
	19	91,0	80,8	3,3
	23	89,0	77,8	2,6

Tabela 5.5. Valores obtidos para a classificação por kNN.

Np	K	ACC _v	ACC _t	(conclusão)
				s _t
9	3	89,0	79,6	2,5
	5	90,0	82,6	2,7
	7	89,0	79,6	1,9
	11	89,0	82,0	3,4
	13	91,0	81,6	2,5
	17	89,0	75,2	4,1
	19	90,0	81,0	1,9
	23	91,0	82,6	3,2
10	3	89,0	82,2	3,5
	5	88,0	81,2	5,2
	7	89,0	81,0	2,9
	11	89,0	81,2	1,3
	13	88,0	73,4	5,7
	17	89,0	75,4	3,9
	19	89,0	81,4	2,5
	23	88,0	75,6	4,7

Fonte: A autora, 2018.

Estatisticamente, a melhor combinação de fatores para o WkNN foram para 4 parâmetros e k igual a 13, resultando numa precisão média de teste de 82,6 e desvio de 0,9; para 7 parâmetros e k igual a 11, o que resultou em uma precisão média de 84,2 e um desvio de 1,9; e para 7 parâmetros e k igual a 13, o que resultou em uma precisão média de 84,2 e um desvio de 1,8. É importante ressaltar que os valores de precisão para o grupo de validação foram todos da ordem de 88%. Os sintomas para cada uma das configurações, com as respectivas descrições e o tempo total de processamento, estão apresentados nos Quadros 5.6, 5.7 e 5.8

Quadro 5.6. Sintomas escolhidos para a configuração de W kNN com Np igual a 4 e k igual a 13.

Sintoma	Descrição	Tempo de Processamento [s]
3.72	Valor pico a pico unipolar normalizado com filtro alfa	0,12
3.164	Assimetria do sinal dipolar normalizado com filtro Usuário	
3.414	Valor do K4 da db4 do sinal dipolar normalizado com escala 3.31	
3.424	Valor do K6 do envelope da db4 do sinal unipolar normalizado com escala 327.83	

Fonte: A autora, 2018

Quadro 5.7. Sintomas escolhidos para a configuração de WkNN com Np igual a 7 e k igual a 11

Sintoma	Descrição	Tempo de Processamento [s]
3.49	Valor RMS do unipolar não normalizado com filtro Usuário	13,69
3.142	Curtose do sinal dipolar não normalizado com filtro gama	
3.399	Valor do fator de crista da db4 do sinal dipolar normalizado escala 16.31	
3.441	Valor RMS da db4 do sinal dipolar normalizado escala 115.07	
3.831	Valor pico a pico do quinto modo do sinal unipolar da HHT.	
3.849	Curtose do quinto modo do sinal dipolar da HHT.	
3.1137	Duração da onda lenta para k-NEO	

Fonte: A autora, 2018

Quadro 5.8. Sintomas escolhidos para a configuração de WkNN com Np igual a 7 e k igual a 13

Sintoma	Descrição	Tempo de Processamento [s]
3.49	Curtose do sinal filtrado por Gama para o sinal dipolar não normalizado	12,79
3.198	Curtose do sinal dipolar normalizado com filtro gama	
3.340	Valor de assimetria da db4 do sinal monopolar normalizado escala 120.63	
3.441	Valor K6 da db4 do sinal unipolar normalizado com escala 327.83	
3.463	Valor do fator de crista da db4 do sinal dipolar normalizado escala 28.81	
3.612	Valor da curtose do resíduo da EMD (4 modo) do sinal monopolar normalizado.	
3.1137	Duração da onda lenta para k-NEO	

Fonte: A autora, 2018

Analisando os Quadros 5.6, 5.7 e 5.8, observa-se o tempo de processamento muito pequeno quando se tem apenas 4 parâmetros, e um tempo equivalente para os casos com 7 parâmetros. Obteve-se um melhor resultado, então, para a configuração 4 parâmetros e k igual a 13, por possuir menor desvio padrão e um tempo de processamento muito pequeno. Observa-se também que houve uma repetição dos sintomas, 3.48, 3.441 e 3.1136, que representam valores RMS e área do pico.

A Tabela 5.9 mostra o valor médio, e respectivos desvios padrões, para todas as métricas de avaliação de desempenho utilizadas neste trabalho, para as duas melhores configurações. É importante lembrar que seis testes foram realizados, com um conjunto de dados diferentes.

Tabela 5.9. Valores médios, e respectivos desvios padrões, para as métricas de avaliação de desempenho, para as melhores configurações para WkNN.

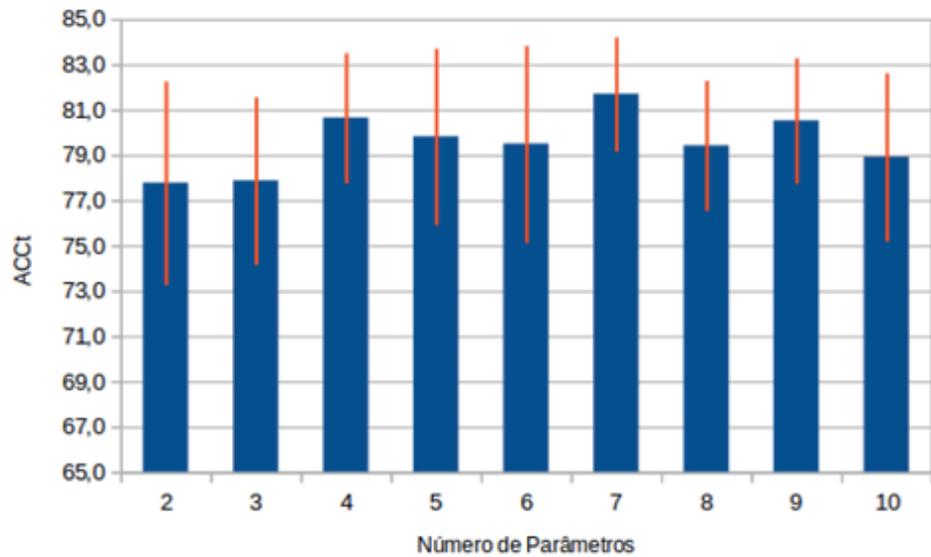
N_p	K	SEN [%]	SPF [%]	ACC [%]	PPV [%]	NPV [%]	MCC [%]
4	13	80,8	84,8	82,6	84,0	81,5	0,7
		2,3	2,3	0,9	1,9	1,5	0,1
7	11	88,4	80,0	84,2	81,5	87,4	0,7
		3,0	1,4	1,9	1,4	2,9	0,1
7	13	82,4	86,0	84,2	85,6	83,2	0,7
		4,3	3,7	1,8	3,4	3,4	0,1

Fonte: A autora, 2018.

Da análise da Tab. 5.9, observa-se que o MCC de todas as configurações foi igual, com mesmo desvio padrão, indicando um desempenho igual para este classificador. A SEN e o NPV da configuração com 7 parâmetros e k igual a 11 foram os valores mais altos encontrados para WkNN, resultando em 88,4% de capacidade de detectar os picos e 87,4% de detectar corretamente os picos negativos.

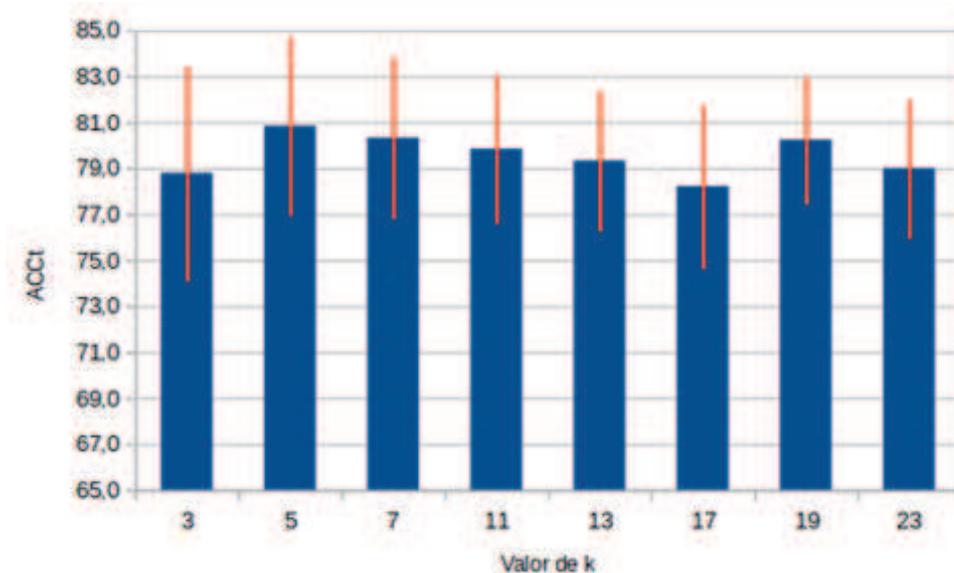
A Figura 5.5 mostra a influência média do número de parâmetros na precisão do algoritmo WkNN, enquanto a Fig. 5.6 mostra a influência do fator k na precisão do algoritmo para os seis testes realizados.

Figura 5.5. Influência média do número de parâmetros na precisão do algoritmo WkNN.



Fonte: A autora, 2018.

Figura 5.6. Influência do fator k na precisão do algoritmo kNN.



Fonte: A autora, 2018.

Da análise das figuras, não se observa nenhuma tendência para a escolha de parâmetros e k. A melhor configuração seria para 7 parâmetros, que possui maior precisão e menor desvio, e k igual a 5, que varia entre 77 e 85% de precisão.

5.3. MELHORES SINTOMAS USANDO LDA

Para a definição dos melhores sintomas a serem utilizados com a Análise Discriminante Linear (LDA), ou discriminante de Fischer, foram estudadas configurações com número de parâmetros N_p variando de 2 a 10, com passo 1, e de 12 a 33 com passo 2.

A Tabela 5.10 mostra os resultados para os valores de número de parâmetros variando de 2 a 10, para fins de análise. Observa-se que para N_p maior que 5, a função objetivo não evolui mais e os valores de ACC_t estabilizam em torno de 57%.

Tabela 5.10. Valores obtidos para a classificação por LDA e passo 1.

N_p	ACC_v	ACC_t	s_t
2	63,0	55,4	3,4
3	70,0	56,6	4,9
4	70,0	60,6	3,4
5	74,0	59,2	3,3
6	73,0	57,6	5,3
7	74,0	56,0	4,6
8	74,0	57,6	5,9
9	74,0	56,8	3,2
10	73,0	56,2	5,5

Fonte: A autora, 2018.

Estatisticamente, o melhor resultado para LDA com passo 1 é com 4 parâmetros, resultando numa precisão média de teste de 60,6 e desvio de 3,4. Os sintomas otimizados para esta configuração, com as respectivas descrições e o tempo total de processamento, estão apresentados no Quadro 5.11. Observa-se que, além de ter uma precisão baixa, o tempo de processamento é relativamente alto.

Quadro 5.11. Sintomas escolhidos para a configuração de LDA com N_p igual a 4.

Sintoma	Descrição	Tempo de Processamento [s]
3.1	Valor RMS global para sinal unipolar não normalizado	14,83
3.86	Curtose do sinal unipolar não normalizado filtrado em Gama	
3.344	Valor do K6 da db4 do sinal unipolar normalizado com escala 327.83	
3.873	Curtose do resíduo do sexto modo da HHT do sinal unipolar normalizado	

Fonte: A autora, 2018

A Tabela 5.12 apresenta o valor médio, e respectivos desvios padrões, para todas as métricas de avaliação de desempenho utilizadas neste trabalho, para a LDA com quatro parâmetros, e passo 1.

Tabela 5.12. Valores médios, e respectivos desvios padrões, para as métricas de avaliação de desempenho, para a melhor configuração para LDA com passo 1.

N_p	K	SEN [%]	SPF [%]	ACC [%]	PPV [%]	NPV [%]	MCC [%]
2	60,6	53,2	68,4	60,6	62,4	59,4	0,2
		8,2	5,2	3,4	3,0	4,5	0,1

Fonte: A autora, 2018.

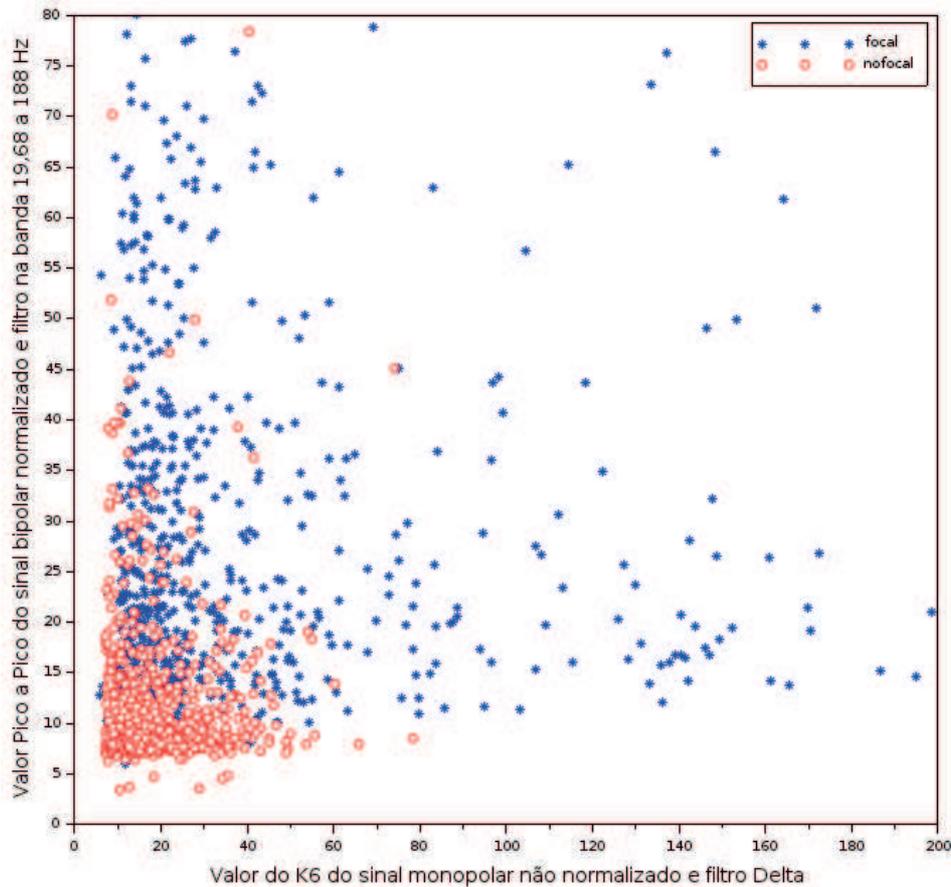
Observa-se resultados muito abaixo, quando comparados com os obtidos por kNN e WkNN, com valores de MCC da ordem de 0,2%. Os resultados obtidos para o número de parâmetros de 12 a 33, com passo 2, foram semelhantes aos apresentados e por isso foram desconsiderados.

5.4. MELHORES SINTOMAS USANDO QDA

Para a definição dos melhores sintomas a serem utilizados com a Análise Discriminante Quadrática (QDA) foram estudadas configurações com número de parâmetros N_p variando de 2 a 10, com passo 1, e de 12 a 33 com passo 2.

A melhor função objetivo do QDA foi obtida para a configuração com dois parâmetros e vale 83%, sendo que o gráfico de dispersão para os sintomas escolhidos é apresentado na Fig. 5.7. Para a construção do gráfico foram utilizados os 800 primeiros sinais do banco de dados.

Figura 5.7. Gráfico de dispersão para os dois sintomas escolhidos no QDA.



Fonte: A autora, 2018.

Da análise da Fig. 5.7, observa-se que os dados possuem uma característica quadrática, o que explica o insucesso do LDA para a classificação dos sinais focal e não focal. Observa-se também, uma fronteira bem definida separando os dois grupos de dados.

Em função do baixo custo da função objetivo, foi possível realizar uma classificação de 1600 conjuntos de dados escolhidos aleatoriamente. A Tabela 5.13 mostra os resultados para os valores de número de parâmetros variando de 2 até 10, para fins de análise.

Analisando os resultados apresentados na Tab. 5.13, observa-se que a medida que o N_p aumenta, a partir de 6 parâmetros, os valores da função objetivo ACC_v começam a diminuir, e para 8 até 10 parâmetros, os valores de ACC_t caem drasticamente, de 81% para 57%, aproximadamente. Por essa razão não são apresentados os resultados obtidos para 12 até 33 parâmetros. Já para os valores de N_p até 6, os valores médios de ACC_v se situam em torno de 80% com uma variância amostral baixa.

Tabela 5.13. Valores obtidos para a classificação por QDA e passo 1.

N_p	ACC_v	ACC_t	s_t
2	83,0	81,1	1,8
3	85,0	79,6	0,9
4	91,0	81,2	1,8
5	90,0	79,8	2,3
6	90,0	83,0	0,7
7	89,0	81,6	3,0
8	74,0	57,6	5,9
9	74,0	56,8	3,2
10	73,0	56,2	5,5

Fonte: A autora, 2018.

Estatisticamente, o melhor resultado para QDA com passo 1 é para seis parâmetros, resultando numa precisão média de teste de 83,0 e desvio de 0,7. Os sintomas otimizados para esta configuração, com as respectivas descrições e o tempo total de processamento, estão apresentados no Quadro 5.14. Observa-se que o QDA com seis parâmetros é um bom classificador pois, além de ter uma precisão alta com baixo desvio padrão, o tempo de processamento também é baixo.

Quadro 5.14. Sintomas escolhidos para a configuração de QDA com N_p igual a 6.

Sintoma	Descrição	Tempo de Processamento [s]
3.174	Valor RMS filtrado em Gama para sinal dipolar normalizado	0,13
3.273	Valor RMS do módulo do envelope filtrado em Usuário para sinal unipolar	
3.276	Assimetria do módulo do envelope filtrado em Usuário para sinal unipolar	
3.425	Valor RMS da db4 do sinal dipolar normalizado com escala 115.30	
3.451	Valor Pico a Pico da db4 do sinal monopolar normalizado com escala 29.18	
3.495	Valor do fator de crista da db4 do sinal dipolar normalizado com escala 12.08	

Fonte: A autora, 2018

A Tabela 5.15 apresenta o valor médio, e respectivos desvios padrões, para todas as métricas de avaliação de desempenho utilizadas neste trabalho, para a QDA com seis parâmetros, e passo 1.

Tabela 5.15. Valores médios, e respectivos desvios padrões, para as métricas de avaliação de desempenho, para a melhor configuração para QDA com passo 1.

N_p	K	SEN [%]	SPF [%]	ACC [%]	PPV [%]	NPV [%]	MCC [%]
6	90,0	88,4	77,6	83,0	79,8	87,5	0,7
		3,6	3,8	0,7	2,2	3,2	0,1

Fonte: A autora, 2018.

É interessante observar, da análise da Tab. 5.15, que o menor desvio padrão amostral ocorre para a métrica da função objetivo. Outra observação importante é que os valores de ACCt obtidos usando a QDA pertencem à mesma população dos valores de ACCt gerados pelo WkNN.

5.5. MELHORES SINTOMAS USANDO PNN

Para a definição dos melhores sintomas a serem utilizados para a classificação utilizando da Rede Neural Probabilística, PNN, foram estudadas configurações com número de parâmetros N_p variando de 2 a 8, com passo 1. Definiu-se oito parâmetros como limite para se evitar problemas de sobreajuste.

A Tabela 5.16 mostra os resultados para os valores de número de parâmetros variando de 2 a 8 para a PNN.

Tabela 5.16. Valores obtidos para a classificação via PNN.

N_p	ACC_v	ACC_t	s_t
2	73,0	65,6	5,0
3	83,0	82,0	1,0
4	82,0	81,2	2,3
5	82,0	77,6	2,3
6	83,0	81,0	1,0
7	83,0	82,0	2,0
8	82,0	81,4	1,7

Fonte: A autora, 2018.

Da análise da Tab. 5.16, observa-se que, exceto para dois parâmetros, todos os resultados foram estatisticamente iguais. Considera-se como o melhor resultado, a PNN com três parâmetros por possuir maior precisão com menor desvio (82% e 1,0, respectivamente), além de provavelmente ter um baixo custo computacional, o que pode ser comprovado pelo Quadro

5.17, que mostra os sintomas escolhidos pela otimização esta configuração, com as respectivas descrições.

Quadro 5.17. Sintomas escolhidos para a classificação via PNN com N_p igual a 3.

Sintoma	Descrição	Tempo de Processamento [s]
3.210	Fator de crista do sinal dipolar normalizado filtrado em Gama	0,12
3.345	Valor RMS da db4 do sinal dipolar normalizado com escala 115.30	
3.772	Valor do K6 para o terceiro modo da HHT para sinal unipolar.	
3.873	Curtose do resíduo do sexto modo da HHT do sinal unipolar	

Fonte: A autora, 2018

A Tabela 5.18 apresenta o valor médio, e respectivos desvios padrões, para todas as métricas de avaliação de desempenho utilizadas neste trabalho, para a PNN com três parâmetros.

Tabela 5.18. Valores médios, e respectivos desvios padrões, para as métricas de avaliação de desempenho, para a PNN com três parâmetros.

N_p	K	SEN [%]	SPF [%]	ACC [%]	PPV [%]	NPV [%]	MCC [%]
3	60,6	84,4	44,3	82,0	88,9	83,6	0,3
		1,7	0,9	1,0	5,6	1,1	0,1

Fonte: A autora, 2018.

Ao analisar a Tab. 5.17, observa-se que, à exceção do PVV, os desvios padrão obtidos são baixos, ou seja, há pouca variação nas métricas.

5.6. MELHORES SINTOMAS USANDO MLP-BP

Por último, apresenta-se a análise para a rede perceptron multicamadas com retropropagação do erro. Foram estudadas diversas configurações de número de camadas e função de ativação para poder encontrar a melhor configuração para a escolha dos sintomas. Assim como a PNN, para a MLP-BP, virou-se utilizar mais de oito parâmetros de entrada.

Na Tabela 5.19 são apresentados os resultados para os valores de número de parâmetros variando de 2 a 8 para a MLP-BP, com duas camadas ocultas.

Tabela 5.19. Valores obtidos para a classificação via MLP-BP.

N_p	ACC_v	ACC_t	s_t
2	76,0	74,8	1,8
3	82,0	79,4	2,2
4	83,0	79,0	2,3
5	82,0	77,6	2,3
6	83,0	72,4	1,6
7	83,0	82,0	2,0
8	82,0	81,4	1,7

Fonte: A autora, 2018.

Da análise da Tab. 5.19, e de simulações realizadas, observa-se que as redes MLP-BP com duas camadas ocultas, com ou sem regularização, não foram eficazes como procedimento de classificação utilizando o banco de dados proposto neste trabalho. Os valores de precisão de teste foram coerentes com os encontrados para os outros classificadores, porém, devido ao alto custo computacional para treinamento da rede, a mesma se torna inviável.

5.7. CONSIDERAÇÕES FINAIS SOBRE O CAPÍTULO

Utilizando os parâmetros que resultaram nos melhores valores de ACC para os classificadores WkNN, QDA e PNN, foram realizadas 1000 avaliações das funções objetivos para uma análise relativa dos tempos de processamento de cada classificador. Os resultados encontrados, em ordem crescente, foram 2,54, 8,98 e 55,11 segundos para o QDA, PNN e WkNN, respectivamente. A utilização da QDA no procedimento proposto mostrou-se bastante interessante em função do custo computacional. A mesma foi utilizada em quase todas as pré-análises.

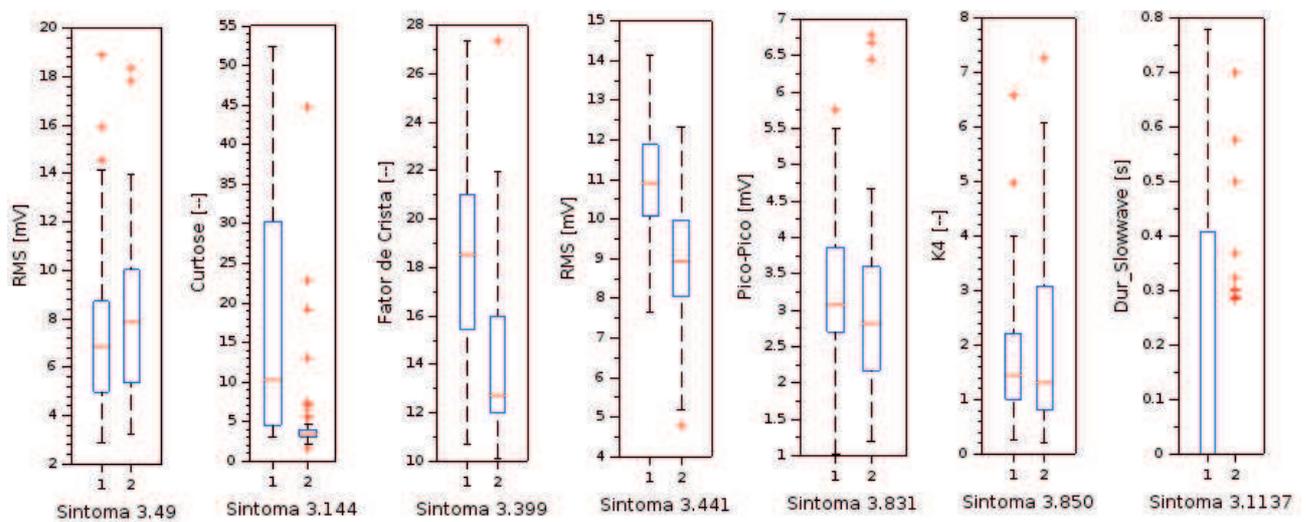
A principal vantagem da PNN é sua fácil implementação e utilização, uma vez que a mesma possui como dados de configuração apenas a função objetivo, além de possuir os valores de teste próximos aos valores utilizados para a validação da rede.

Já a WkNN, possui como desvantagem o alto custo computacional e a necessidade de se otimizar duas configurações de entrada, número de parâmetros e o fator k .

Por fim, na Fig. 5.8 são apresentados os diagramas de caixas para o melhor resultado encontrado entre todos os procedimentos, que é para WkNN com N_p igual a sete parâmetros e k igual a 11, onde pode-se observar a presença de três parâmetros com interquartis separados.

O objetivo deste trabalho é a obtenção dos sintomas utilizando apenas inteligência artificial, mas em uma aplicação prática, uma análise prévia dos diagramas de caixas facilita consideravelmente na escolha dos melhores sintomas para a classificação dos sinais. A melhor estratégia, testada na pré-análise, é escolher as maiores diferenças entre os interquartis como sintomas base e utilizar um procedimento de otimização para determinar os demais. No caso da figura, o parâmetro 3.1137 é um bom indicador de sinais não focal.

Figura 5.8. Diagrama de caixas com os sintomas para a melhor configuração, WkNN com sete parâmetros.



Fonte: A autora, 2018.

CAPÍTULO VI

CONCLUSÕES

Para o caso em estudo, ou seja, para a análise de sinais cerebrais obtidos via eletroencefalografia, e considerando o banco de dados utilizados de Bern-Barcelona, as principais conclusões obtidas neste trabalho foram:

- É imprescindível se fazer uma pré-análise das métricas utilizadas como prováveis sintomas para a discriminação dos sinais, pois facilita consideravelmente na escolha desses sintomas para a classificação. Para isso, utilizou-se de análise dos diagramas de caixas e bigodes;
- Desta pré-análise, os parâmetros que mais se repetiram como possíveis sintomas foram ValorRMS, FC e K_x , com 15, 14 e 10 ocorrências respectivamente. Era esperado que o ValorRMS fosse um bom parâmetro uma vez que o conjunto de sinais focal possui mais energia, em função dos picos. A mesma coisa vale para FC e curtose, que medem as excursões fora da média, também relacionados aos picos focais;
- Ao se calcular os modos intrínsecos, observou-se uma concordância com as bandas de frequências características dos sinais cerebrais, delta, alfa, teta, beta e gama, e também com a banda de frequências otimizada;
- Os melhores resultados obtidos, considerando como função objetivo a precisão do grupo de testes, para os procedimentos de classificação WkNN, QDA, PNN e MLP-BP, foram da mesma ordem de grandeza, porém, devido ao seu alto custo computacional para o treinamento, a MLP-BP não é considerada como um bom método, para o caso em estudo;
- O melhor valor da métrica SEN, que mede a capacidade do método em detectar os picos, foi de 88,4 para os classificadores WkNN, QDA e PNN, com o menor desvio padrão amostral para o PNN (1,7);
- Para o SPF, que avalia a habilidade de se discriminar sinal não focal, o melhor valor encontrado foi de $86,0 \pm 3,7$ para o WkNN. O valor de $44,3 \pm 0,9$ encontrado para a melhor ACC do PNN, deve ser levado em consideração;

- Os melhores valores de PPV foram encontrados para o kNN e WkNN (aproximadamente 84,0). O melhor resultado de ACC da PNN resultou num PPV igual a 88,9%, porém com um desvio amostral de 5,6%;
- Os melhores valores de NPV foram da ordem de 87,0% para os classificadores WkNN e QDA;
- Para a PNN, o classificador é bom para encontrar os picos e os valores positivos e negativos, nos sinais focais, porém para os sinais não focais, ele tem um baixo rendimento. Apesar de não se ter uma boa especificidade, isto não implica em uma precisão ruim;
- Os resultados encontrados, para o tempo de processamento dos classificadores, em ordem crescente, foram de 2,54, 8,98 e 55,11 segundos para o QDA, PNN e WkNN, respectivamente;
- A utilização da QDA no procedimento proposto mostrou-se bastante interessante em função do seu baixo custo computacional;
- A principal vantagem da PNN é sua fácil implementação e utilização, uma vez que a mesma possui como dados de configuração apenas a função objetivo, além de possuir os valores de teste próximos aos valores utilizados para a validação da rede;
- A WkNN, possui como desvantagem o alto custo computacional e a necessidade de se otimizar duas configurações de entrada, número de parâmetros e o fator k;
- A melhor estratégia, testada na pré-análise, é escolher as maiores diferenças entre os interquartis como sintomas base e utilizar um procedimento de otimização para determinar os demais;
- A metodologia aqui apresentada foi validada, uma vez que para classificadores diferentes, obteve-se valores de precisão semelhantes. Ou seja, conseguiu-se fazer uma classificação utilizando apenas de inteligência artificial, quanto a possível presença de anomalia no sinal de EEG.

6.1. TRABALHOS FUTUROS

Para trabalhos futuros, seria interessante se trabalhar com um outro banco de dados, uma vez que a qualidade do sinal influencia diretamente na eficácia da metodologia aqui apresentada. Uma outra abordagem é se trabalhar com sinais janelados com um tempo inferior

a 10 segundos, uma vez que os picos que representam as crises focais, possuem curta duração. Valores encontrados na literatura recomendam-se sinais de dois segundos com superposição.

Pode-se também trabalhar com filtros autoregressivos, ou então, com redes neurais artificiais do tipo multicamadas com propagação para frente (*feedforward*), para separar as regiões dos sinais de treinamento em focal e não focal, e para a classificação, utilizar de três neurônios de saída: focal, não focal e distúrbio no sinal não focal.

Percebeu-se ao longo do desenvolvimento do trabalho que as ondas lentas que seguem o pico dos sinais focal são um bom parâmetro para a detecção do sinal focal. O problema é que para os sinais não focal, esta onda normalmente não existe, o que resulta em um parâmetro do tipo existe-não existe. Uma opção interessante para abordar esta onda curta, seria fazer uma interpolação cúbica, utilizando pontos após a ocorrência de picos em todos os sinais e utilizar os coeficientes resultantes das interpolações como parâmetro.

REFERÊNCIAS BIBLIOGRÁFICAS

Abbasi, R., E Esmailpour, M. “Selecting Statistical Characteristics Of Brain Signals To Detect Epileptic Seizures Using Discrete Wavelet Transform And Perceptron Neural Network”. *International Journal Of Interactive Multimedia And Artificial Intelligence*, 2017, Vol. 4, Issue 5, P. 33-38.

<https://doi.org/10.9781/ijimai.2017.456>

Adeli, Hojjat; Zhou, Ziqin; Dadmehr, Nahid. Analysis Of Eeg Records In An Epileptic Patient Using Wavelet Transform. *Journal Of Neuroscience Methods*, V. 123, N. 1, P. 69-87, 2003.

[https://doi.org/10.1016/S0165-0270\(02\)00340-0](https://doi.org/10.1016/S0165-0270(02)00340-0)

Aliabadi, Roozbeh; Keynia, Farshid; Abdali, Mehran. Epilepsy Seizure Diagnosis In Eeg By Artificial Neural Networks. *Majlesi Journal Of Multimedia Processing*, V. 2, N. 2, 2013.

Andrzejak, R. G., Schindler, K., & Rummel, C. (2012). Nonrandomness, Nonlinear Dependence, And Nonstationarity Of Electroencephalographic Recordings From Epilepsy Patients. *Physical Review E*, 86(4), 046206.

<https://doi.org/10.1103/PhysRevE.86.046206>

Anh, N. T. H., Hoang, T. H., Thang, V. T., & Bui, T. Q. (2016, November). An Artificial Neural Network Approach For Electroencephalographic Signal Classification Towards Brain-Computer Interface Implementation. In *Computing & Communication Technologies, Research, Innovation, And Vision For The Future (Rivf)*, 2016 Ieee Rivf International Conference On (Pp. 205-210). Ieee.

<https://doi.org/10.1109/RIVF.2016.7800295>

Awan, U. I., Rajput, U. H., Syed, G., Iqbal, R., Sabat, I., & Mansoor, M. (2016, December). Effective Classification Of Eeg Signals Using K-Nearest Neighbor Algorithm. In *Frontiers Of Information Technology (Fit)*, 2016 International Conference On (Pp. 120-124). Ieee.

Bachmann, M., Lass, J., E Hinrikus, H. "Single Channel Eeg Analysis For Detection Of Depression." *Biomedical Signal Processing And Control*, 2017, Vol. 31, P. 391-397.

<https://doi.org/10.1016/j.bspc.2016.09.010>

Bhattacharyya, S., Khasnobish, A., Chatterjee, S., Konar, A., & Tibarewala, D. N. (2010, December). Performance Analysis Of Lda, Qda And Knn Algorithms In Left-Right Limb Movement Classification From Eeg Data. In *Systems In Medicine And Biology (Icsmb), 2010 International Conference On* (Pp. 126-131). Ieee.

Blinowska, K. And Durka, P., "Electroencephalography (Eeg)", 2006, John & Sons, Inc.; Wiley Encyclopeida Of Biomedical Engineering, 15p.

Carvalho, Fábio Israel M.; Dantas Filho, Heronides A. Estudo Da Qualidade Da Gasolina Tipo Ae Sua Composição Química Empregando Análise De Componentes Principais. *Quim. Nova*, V. 37, N. 1, P. 33-38, 2014.

<https://doi.org/10.1590/S0100-40422014000100007>

Cheong, L. C., Sudirman, R., E Hussin, S. S. "Feature Extraction Of Eeg Signal Using Wavelet Transform For Autism Classification." *Arpn Journal Of Engineering And Applied Sciences*, 2015, Vol. 10, Issue 19, P. 8533-8540

Choi, J. H., & Kim, T. (2002). Neural Action Potential Detector Using Multi-Resolution Teo. *Electronics Letters*, 38(12), 541-543.

<https://doi.org/10.1049/el:20020386>

Comon, Pierre. Independent Component Analysis, A New Concept?. *Signal Processing*, V. 36, N. 3, P. 287-314, 1994.

[https://doi.org/10.1016/0165-1684\(94\)90029-9](https://doi.org/10.1016/0165-1684(94)90029-9)

Dixon, Sarah J.; Brereton, Richard G. Comparison Of Performance Of Five Common Classifiers Represented As Boundary Methods: Euclidean Distance To Centroids, Linear Discriminant Analysis, Quadratic Discriminant Analysis, Learning Vector Quantization And Support Vector Machines, As Dependent On Data Structure. *Chemometrics And Intelligent Laboratory Systems*, V. 95, N. 1, P. 1-17, 2009. <https://doi.org/10.1016/j.chemolab.2008.07.010>

Faust, O., Acharya, U. R., Adeli, H., & Adeli, A. (2015). Wavelet-Based Eeg Processing For Computer-Aided Seizure Detection And Epilepsy Diagnosis. *Seizure*, 26, 56-64.

<https://doi.org/10.1016/j.seizure.2015.01.012>

Friedman, J., Hastie, T., & Tibshirani, R. (2008). *The Elements Of Statistical Learning: Data Mining, Inference, And Prediction 2 Ed.* New York: Springer Series In Statistics.

Ghaedi, M., Ghaedi, A. M., Abdi, F., Roosta, M., Sahraei, R., E Daneshfar, A. “Principal Component Analysis-Artificial Neural Network And Genetic Algorithm Optimization For Removal Of Reactive Orange 12 By Copper Sulfide Nanoparticles-Activated Carbon.”, *Journal Of Industrial And Engineering Chemistry*, 2014, V. 20, N. 3, P. 787-795.

<https://doi.org/10.1016/j.jiec.2013.06.008>

Gomes, W. Z., 2003, “Instrumentação De Sinais Biológicos”, <Www.Eletr.Ufpr.Br/Marlio/Medidas/Seminarios >

Google Acadêmico, [https://scholar-google-com-br.Ez34.Periodicos.Capes.Gov.Br/Scholar?hl=pt-br&as_sdt=2005&scioldt=0,5&cites=1026494720391773018&scipsc=](https://scholar.google.com.br/Ez34.Periodicos.Capes.Gov.Br/Scholar?hl=pt-br&as_sdt=2005&scioldt=0,5&cites=1026494720391773018&scipsc=), Visualizado Em 19 De Janeiro De 2018.

Hair, J. F., Black, W. C., Babin, B. J., Anderson, R. E., & Tatham, R. L. (2009). *Análise Multivariada De Dados.* Bookman Editora.

Hair, J. F., Black, W. C., Babin, B. J., Anderson, R. E., E Tatham, R. L. “Análise Multivariada De Dados”. Bookman Editora, 2009.

Haykin, S., “Redes Neurais – Princípios E Prática.”, 2ª Ed., Ed. Bookman, Porto Alegre, 2001.

Helena, E.L.S., “Detecção De Fusos De Sono Em Adultos Jovens Por Meio De Transformadas Wavelet.” Porto Alegre – Rs. Universidade Federal Do Rio Grande Do Sul – Programa De Pós-Graduação Em Medicina: Ciências Médicas, 2004, 120p. Tese De Doutorado.

Hsu, C. M., Lian, F. L., Huang, C. M., E Chou, J. H. “Heart Rate Variability Signal Processing For Safety Driving Using Hilbert-Huang Transform.” In: Computer, Consumer And Control (Is3c), 2014 International Symposium On. Ieee, 2014. P. 434-437.

Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., ... & Liu, H. H. (1998, March). The Empirical Mode Decomposition And The Hilbert Spectrum For Nonlinear And Non-Stationary Time Series Analysis. In Proceedings Of The Royal Society Of London A: Mathematical, Physical And Engineering Sciences (Vol. 454, No. 1971, Pp. 903-995). The Royal Society.

Hyvärinen, A., Oja, E. “Independent Component Analysis: Algorithms And Applications”, Neural Networks, 2000, V. 13, N. 4, P. 411-430.

[https://doi.org/10.1016/S0893-6080\(00\)00026-5](https://doi.org/10.1016/S0893-6080(00)00026-5)

Kaiser, J. F. (1990, April). On A Simple Algorithm To Calculate The'energy'of A Signal. In Acoustics, Speech, And Signal Processing, 1990. Icassp-90., 1990 International Conference On (Pp. 381-384). Ieee.

Kannathal, N., Choo, M. L., Acharya, U. R., & Sadasivan, P. K. (2005). Entropies For Detection Of Epilepsy In Eeg. Computer Methods And Programs In Biomedicine, 80(3), 187-194.

<https://doi.org/10.1016/j.cmpb.2005.06.012>

Kim, K. S., Choi, H. H., Moon, C. S., E Mun, C. W. “Comparison Of K-Nearest Neighbor, Quadratic Discriminant And Linear Discriminant Analysis In Classification Of Electromyogram Signals Based On The Wrist-Motion Directions”. Current Applied Physics, 2011, V. 11, Issue 3, P. 740-745.

<https://doi.org/10.1016/j.cap.2010.11.051>

Kolenikov, S. E Angeles, G. “The Use Of Discrete Data In Pca: Theory, Simulations, And Applications To Socioeconomic Indices.” Chapel Hill: Carolina Population Center, University Of North Carolina, 2004.

Kumar, M., Husian, M., Upreti, N., Gupta, D., “Genetic Algorithm: Review And Application.”, International Journal Of Information Technology And Knowledge Management, Vol. 2, N° 2, Pp. 451 – 454, 2010.

Kumar, Y., Dewal, M. L., & Anand, R. S. (2014). Epileptic Seizures Detection In Eeg Using Dwt-Based Apen And Artificial Neural Network. Signal, Image And Video Processing, 8(7), 1323-1334.

<https://doi.org/10.1007/s11760-012-0362-9>

Lekshmi, S. S., Selvam, V., & Rajasekaran, M. P. (2014, April). Eeg Signal Classification Using Principal Component Analysis And Wavelet Transform With Neural Network. In Communications And Signal Processing (Iccsp), 2014 International Conference On (Pp. 687-690). Ieee.

<https://doi.org/10.1109/ICCSP.2014.6949930>

Lekshmi, S. S.; Selvam, V.; Rajasekaran, M. P. “Eeg Signal Classification Using Principal Component Analysis And Wavelet Transform With Neural Network.” In: Communications And Signal Processing (Iccsp), 2014 International Conference On. Ieee, 2014. P. 687-690.

<https://doi.org/10.1109/ICCSP.2014.6949930>

Liu, Y. C., Lin, C. C. K., Tsai, J. J., & Sun, Y. N. (2013). Model-Based Spike Detection Of Epileptic Eeg Data. Sensors, 13(9), 12536-12547.

<https://doi.org/10.3390/s130912536>

Lobato, F. S., “Otimização Multi-Objetivo Para O Projeto De Sistemas De Engenharia.”, Uberlândia – Mg, Universidade Federal De Uberlândia, Engenharia Mecânica, 2008, 354 P. Tese De Doutorado

Machado, Angelo Barbosa Monteiro; Campos, Gilberto Belisario. Neuroanatomia Funcional. Belo Horizonte: Atheneu, 3ª Ed. 2013.

Malmivuo, J., & Plonsey, R.. “Bioelectromagnetism: Principles And Applications Of Bioelectric And Biomagnetic Fields”. Oxford University Press, Usa. 1995

<https://doi.org/10.1093/acprof:oso/9780195058239.001.0001>

Maragos, P., Kaiser, J. F., & Quatieri, T. F. (1993). On Amplitude And Frequency Demodulation Using Energy Operators. *Ieee Transactions On Signal Processing*, 41(4), 1532-1550.

<https://doi.org/10.1109/78.212729>

Masters, T., “Advanced Algorithms For Neural Network: A C++ Sourcebook.”, John Wiley & Sons, Inc., New York, 1995.

Murugappan, M. “Human Emotion Classification Using Wavelet Transform And Knn.” In *Pattern Analysis And Intelligent Robotics (Icpair)*, 2011 International Conference On Vol. 1, Pp. 148-153. Ieee. 2011.

<https://doi.org/10.1109/ICPAIR.2011.5976886>

Negri, Ana Paula Rosa. *Detecção De Crises Epilépticas Baseada Em Sinais De Eletroencefalograma Utilizando A Transformada Wavelet*. 2014. Monografia De Conclusão De Curso, Instituto Federal De Santa Catarina, São José, Sc.

Netto, L. F., “Sinais Elétricos E Suas Formas De Onda”, 2011, Http://Www.Feiradeciencias.Com.Br/Sala15/15_07.Asp

Oda, Shiguelo, 2013, “O Corpo Humano Possui Um Mecanismo Automático De Manutenção” <<Http://Www.Kotsubantyousei.Com.Br/Doencas/O-Corpo-Humano-Possui-Um-Mecanismo-Automatico-De-Manutencao>>

Omerhodzic, I., Avdakovic, S., Nuhanovic, A., Dizdarevic, K., “Energy Distribution Of Eeg Signals: Eeg Signal Wavelet-Neural Network Classifier.”, 2013, <Http://Arxiv.Org/Abs/1307.7897>

Orhan, U., Hekim, M., & Ozer, M. (2011). Eeg Signals Classification Using The K-Means Clustering And A Multilayer Perceptron Neural Network Model. *Expert Systems With Applications*, 38(10), 13475-13481.

<https://doi.org/10.1016/j.eswa.2011.04.149>

Ponten, S.C., Tewarie, P., Slooter, A.J.C., Stam, C.J., Van Dellen, E.. “Neural Network Modeling Of Eeg Patterns In Encephalopathy” *Journal Of Clinical Neurophysiology*, 2013, Vol. 30, Issue 5, P. 545-552

<https://doi.org/10.1097/WNP.0b013e3182a73e16>

Rajaguru, H., & Prabhakar, S. K. (2017). Knn Classifier And K-Means Clustering For Robust Classification Of Epilepsy From Eeg Signals. A Detailed Analysis. Anchor Academic Publishing.

Rajaguru, H., & Prabhakar, S. K. Weighted Knn Measures For Epilepsy Classification From Eeg Signals Utilized In Telemedicine Applications With A Pso Based Reduced Papr And Ber Analysis. *Journal Of Pharmaceutical Sciences And Research*, 8(4), 2016, Pp. 214-219.

Ren, H., Qu, J., Chai, Y., Tang, Q., & Zhou, Y. (2017). An Adaptive Unsupervised Classification Of Seizure Method Based On Lmdmsse With Eeg Signals. *Biomedical Research*, 28(7).

Ribeiro, K. M., Braga Jr, R. A., Horgan, G. W., Ferreira, D. D., E Sáfadi, T. “Principal Component Analysis In The Spectral Analysis Of The Dynamic Laser Speckle Patterns. *Journal Of The European Optical Society-Rapid Publications*,” V. 9, 2014..

Sabattini, R. M. E., “A História Da Eletroencefalografia”, *Revista Cerebro E Mente*, N19, Universidade Estadual De Campinas, Brasil, 2003, Http://Www.Cerebromente.Org.Br/N19/History/Historyeeg_P.Htm

Sabbatini, R. M., 1995. “O Computador No Processamento De Sinais Biológicos.” *Revista Informédica*, 2(12), Pp. 5-9.

Salkind, N. J. (Ed.). (2010). *Encyclopedia Of Research Design*(Vol. 1). Sage.

<https://doi.org/10.4135/9781412961288>

Sanei, S., E Chambers, J. A. “Eeg Signal Processing.” John Wiley & Sons, 2007

Sharma, R., Pachori, R. B., & Acharya, U. R. (2015). Application Of Entropy Measures On Intrinsic Mode Functions For The Automated Identification Of Focal Electroencephalogram Signals. *Entropy*, 17(2), 669-691.

<https://doi.org/10.3390/e17020669>

Shih, W. Y., Liao, J. C., Huang, K. J., Fang, W. C., Cauwenberghs, G., E Jung, T. P. “An Efficient Vlsi Implementation Of On-Line Recursive Ica Processor For Real-Time Multi-Channel Eeg Signal Separation.”, *Engineering In Medicine And Biology Society (Embc), 2013 35th Annual International Conference Of The Ieee. Ieee, 2013. P. 6808-6811.*

Shou, G. E Ding, L. “Detection Of Eeg Spatial–Spectral–Temporal Signatures Of Errors: A Comparative Study Of Ica-Based And Channel-Based Methods.”, *Brain Topography*, 2014, P. 1-15.

Silva, Jaqueline Ferreira Da. "Sistema De Armazenamento De Imagens Comprimidas Atraves Da Transformada Wavelet." (2008): 99p.

Srivastava, S., Gupta, M. R., & Frigiyik, B. A. (2007). Bayesian Quadratic Discriminant Analysis. *Journal Of Machine Learning Research*, 8(Jun), 1277-1305.

Tatum, W.O; Husain, A.M; Benbadis, S.R. And Kaplan, P.W., “Handbook Of Eeg Interpretation”, 2008, Demos, 289p.

Tatum, William O. Ellen R. “Grass Lecture: Extraordinary Eeg. *The Neurodiagnostic Journal*”, V. 54, N. 1, P. 3-21, 2014.

Travessa, S.S., “Análise Das Redes Neurais Complexas Na Detecção De Espículas E Piscadas Em Sinais De Eeg”, Florianópolis – Sc. Universidade Federal De Santa Catarina, Programa De Pós-Graduação Em Engenharia Elétrica, 2006, 100p. Dissertação De Mestrado.

Varella, C. A. A. “Análise De Componentes Principais”, Apostila Para Curso De Análise Multivariada Aplicada As Ciências Agrárias, Ufrj, 2008

Varella, C. A. A. “Análise Discriminante”, Apostila De Aula De Análise Multivariada Aplicada As Ciências Agrárias, – Seropédica, Rj, 2007.

Zhu, Jin-De; Lin, Chin-Feng. Analyzing Spike I Wave Electroencephalogram Signals For Epilepsy Based On Hilbert-Huang Transformation. In: Bioelectronics And Bioinformatics (Isbb), 2014 Ieee International Symposium On. Ieee, 2014. P. 1-3.

<https://doi.org/10.1109/ISBB.2014.6820937>