



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA DE TELEINFORMÁTICA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA**  
**MESTRADO ACADÊMICO EM ENGENHARIA DE TELEINFORMÁTICA**

**JÚLIO PEIXOTO DA SILVA JÚNIOR**

**MÉTODOS DE EXTRAÇÃO DE ATRIBUTOS PARA DETECÇÃO DE CRISES**  
**EPILEPTICAS: UMA ABORDAGEM COMPARATIVA**

**FORTALEZA**

**2019**

JÚLIO PEIXOTO DA SILVA JÚNIOR

MÉTODOS DE EXTRAÇÃO DE ATRIBUTOS PARA DETECÇÃO DE CRISES  
EPILÉTICAS: UMA ABORDAGEM COMPARATIVA

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia de Teleinformática do Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas

Orientador: Prof. Dr. Charles Casimiro Cavalcante

Coorientador: Prof. Dr. Guilherme de Alencar Barreto

FORTALEZA

2019

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

- S58m Silva Júnior, Júlio Peixoto da.  
Métodos de extração de atributos para detecção de crises epiléticas : Uma abordagem comparativa / Júlio Peixoto da Silva Júnior. – 2019.  
156 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2019.  
Orientação: Prof. Dr. Charles Casimiro Cavalcante.  
Coorientação: Prof. Dr. Guilherme de Alencar Barreto.
1. Epilepsia. 2. Classificação . 3. Aprendizado de Máquinas. 4. Coeficientes Mel-Cepstrais. 5. Extração de Atributos. I. Título.

CDD 621.38

---

JÚLIO PEIXOTO DA SILVA JÚNIOR

MÉTODOS DE EXTRAÇÃO DE ATRIBUTOS PARA DETECÇÃO DE CRISES  
EPILEPTICAS: UMA ABORDAGEM COMPARATIVA

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia de Teleinformática do Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas

Aprovada em: 08 de Fevereiro de 2019

BANCA EXAMINADORA

---

Prof. Dr. Charles Casimiro Cavalcante (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Guilherme de Alencar  
Barreto (Coorientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Romis Ribeiro de Faissol Attux  
Universidade Estadual de Campinas (UNICAMP)

---

Prof. Dr. Manoel Alves Sobreira Neto  
Universidade Federal do Ceará (UFC)



Dedico este trabalho aos meus pais, por todo apoio e carinho que recebi durante toda a vida.

## AGRADECIMENTOS

A presente dissertação de mestrado não poderia chegar ao bom porto sem o precioso apoio de várias pessoas.

Em primeiro lugar, não posso deixar de agradecer aos meus orientadores, Professor Dr. Guilherme Barreto e Professor Dr. Charles Casimiro, por toda a paciência, empenho e dedicação nesse dois anos com que sempre me orientaram neste trabalho e em todos os outros que realizei durante o mestrado. Ao médico neurocirurgião Rodrigo Becco que sempre contribuiu tirando dúvidas referente a área médica do trabalho.

Desejo igualmente agradecer a todos os meus colegas do Mestrado e Doutorado em Engenharia de Teleinformática cujo apoio e amizade estiveram presentes em todos os momentos. O convívio acadêmico na sala de estudo (“Centaurinho”) foi de fundamental importância para a troca de conhecimento, promover discussões relevantes para o trabalho e principalmente para o café. Agradeço especialmente ao Diego Perdigão, Allan Kelvin, David Nascimento, Michael Santos, Manoel Henrique, Renan Bessa, Haroldo Cabral e Policarpo Souza.

Agradeço aos funcionários do Departamento de Teleinformática (DETI).

Por fim, gostaria de agradecer à minha família e amigos pelo apoio incondicional, compreensão, carinho que me deram nessa jornada, especialmente aos meus pais, ao meu irmão Felipe Nascimento.

E à Fundação Cearense de Apoio ao Desenvolvimento (Funcap) pelo financiamento da pesquisa de doutorado via bolsa de estudos.

“O que prevemos raramente ocorre, e o que menos esperamos geralmente acontece.”

(Benjamin Disraeli)

## RESUMO

A Epilepsia é um distúrbio cerebral, caracterizado por crises epiléticas recorrentes, que afeta aproximadamente mais 50 milhões de pessoas em todo o mundo, tornando-se uma das doenças neurológicas mais comuns. O eletroencefalograma (EEG) é um método de monitoramento eletrofisiológico que registra a atividade elétrica do cérebro e é amplamente utilizado na detecção e análise de crises epiléticas. No entanto, muitas vezes, é difícil identificar mudanças sutis, mas críticas, na forma de onda do EEG através de uma inspeção visual. A natureza não linear e não estacionária do EEG contribui para as complexidades relacionadas à sua interpretação e à detecção de atividades normais e anormais (interictais e ictais). Portanto, há uma necessidade de um sistema de diagnóstico auxiliado por computador para identificar automaticamente as atividades anormais. Nessa dissertação, é proposto um sistema de auxílio ao diagnóstico paciente em específico, no qual foi realizada uma comparação entre quatro métodos de extração de características: a densidade espectral de potência, os coeficientes da codificação linear preditiva (LPC, do inglês *Linear Predictive Coding*) e coeficientes mel-cepstrais (MFCC, do inglês *Mel-Frequency Cepstral Coefficients*), e o uso da matriz de covariância. Esses métodos de extração foram combinados em cenários com três tipos de classificadores com propostas randomizadas: Máquina de Aprendizado Extremo (ELM, do inglês *Extreme Learning Machine*), *Random Kitchen Sinks* (RKS) e a Máquina de Aprendizado Mínimo (MLM, do inglês *Minimal Learning Machine*). E, para efeito de comparação, foi utilizado o classificador Máquina de Vetores de Suporte (SVM, do inglês *Support Vector Machines*). Nas simulações realizadas, os cenários propostos utilizaram arquivos com cerca de uma hora (em alguns casos até quatro horas), e os resultados apontaram que os classificadores aleatorizados são dependentes do método de extração de características utilizado. E verificou-se que o uso do vetor de atributos com os coeficientes mel-cepstrais apresentou o melhor desempenho dentre os métodos de extração, obtendo uma sensibilidade de 97%, especificidade de 98% e acurácia média de 99,8% em todos os classificadores.

**Palavras-chave:** Epilepsia. Classificação. Extração de Atributos. Densidade Espectral de Potência. Codificação Linear Preditiva. Coeficientes Mel-Cepstrais. *Extreme Learning Machine*. *Minimal Learning Machine*. *Random Kitchen Sinks*. *Support Vector Machine*, Curva ROC.

## ABSTRACT

Epilepsy is a brain disorder characterized by recurrent epileptic seizures that affects approximately 50 million people worldwide, making it one of the most common neurological diseases. The electroencephalogram (EEG) is an electrophysiological monitoring method that records the electrical activity of the brain and is widely used in the detection and analysis of epileptic seizures. However, it is often difficult to identify subtle but critical changes in the EEG waveform through visual inspection. The EEG signals are nonlinear and non-stationary in nature, which contribute to further complexities related to their manual interpretation and detection of normal and abnormal (interictal and ictal) activities. Therefore, there is a need for a computer aided diagnostic system to automatically identify the abnormal activities. It was found that the use of the attribute vector with the MFCC coefficients presented the best performance among the extraction methods, obtaining a sensitivity of 97%, specificity of 98% and a mean of 99.8% in all classifiers. In this dissertation we propose a system to aid the patient diagnosis in specific, in which a comparison was made between four methods of extraction of characteristics: Power Spectral Density, Linear Predictive Coding, Mel-Frequency Cepstral Coefficients and covariance matrix. These extraction methods were combined in scenarios with three types of randomized pattern classifiers: Extreme Learning Machine, Random Kitchen Sinks and Minimal Learning Machine. And for the purpose of comparison was used the classifier Support Vector Machine. In the simulations performed, the proposed scenarios used files with about one hour (in some cases up to four hours), were used and the results pointed out that the random classifiers are dependent on the method of extraction of characteristics used. It was found that the use of the attribute vector with MFCC coefficients presented the best performance among the extraction methods, obtaining a sensitivity of 97%, specificity of 98% and a mean of 99.8% in all classifiers..

**Keywords:** Epilepsy. Classification. Features Extraction. Power Spectral Density. Linear Predictive Coding. Extreme Learning Machine. Minimal Learning Machine. Random Kitchen Sinks. Support Vector Machine. ROC Curve.

## LISTA DE FIGURAS

Figura 1 – Os 10 tópicos mais relevantes de pesquisas relacionadas a doença com aplicação de inteligência artificial na literatura no banco de dados PubMed por ano . . . . .	22
Figura 2 – Casos de epilepsia registrados no SIAB até julho de 2015. . . . .	23
Figura 3 – Exemplo de 10 Segundos de EEG. . . . .	27
Figura 4 – Os algoritmos de aprendizado de máquina usados em trabalhos com dados eletrofisiológicos. . . . .	30
Figura 5 – Resumo gráfico. . . . .	32
Figura 6 – Estrutura do Neurônio. . . . .	36
Figura 7 – Potencial de ação. (1) Repouso; (2) Despolarização devido à entrada de íons de $Na^+$ ; (3) Repolarização devido a entrada de íons $K^+$ ; (4) Hiperpolarização devido ao fechamento dos canais de $K^+$ . . . . .	37
Figura 8 – A geração de campos elétricos muito pequenos por correntes sinápticas em células piramidais. . . . .	38
Figura 9 – Primeiro EEG de um ser humano. . . . .	39
Figura 10 – Diagrama básico do EEG Digital. . . . .	40
Figura 11 – Discretização de acordo com o número de bits. . . . .	41
Figura 12 – Sala de Monitoramento e Equipamento de Vídeo EEG. . . . .	42
Figura 13 – <i>Neurovirtual's BWAnalysis Acquisition/Review Software</i> . . . . .	43
Figura 14 – Sistema 10-20. . . . .	44
Figura 15 – Convenção dos Grafoelementos do EEG. . . . .	45
Figura 16 – Exemplos de artefatos presentes em uma EEG. (a) Artefacto ocular: piscar os olhos; (b) Artefacto ocular: movimento horizontal do globo ocular; (c) Artefacto muscular; (d) Artefacto devido ao movimento de um eléctrodo. . . . .	46
Figura 17 – Ritmos Cerebrais. . . . .	47
Figura 18 – Esquema simplificado da classificação dos tipos de crises. . . . .	50
Figura 19 – Exemplo dos estados ictal, pré e pós-ictal. Referente a uma das crises epiléticas do paciente CHB10. . . . .	52
Figura 20 – Grafoelementos associados com atividade epileptiforme: (a) descarga de onda aguda; (b) paroxismo generalizado de espícula-onda lenta; (c) espículas generalizadas. . . . .	53

Figura 21 – Exemplo de crise epilética paciente CBH01. . . . .	57
Figura 22 – Exemplo de crise epilética paciente CBH06. . . . .	57
Figura 23 – Exemplo de crise epilética paciente CBH10. . . . .	58
Figura 24 – Função de autocorrelação (FAC) e função de autocorrelação parcial (FACP) de um intervalo de 5s de um canal do EEG. . . . .	62
Figura 25 – Exemplo de 10 s de sinal do EEG. . . . .	65
Figura 26 – Densidade Espectral de Potência, utilizando a FFT. . . . .	65
Figura 27 – Periodograma de Welch. . . . .	70
Figura 28 – Sistema característico para o sistema homomórfico usando DTFT. . . . .	74
Figura 29 – Domínio Cepstral. Em (a) têm-se $ S(\omega)  =  U(\omega)  *  H(\omega) $ , combinação não linear. Em (b) as componentes são somadas, solucionando o problema da não linearidade. Em (c) Representação dos componentes do sinal no domínio <i>cepstral</i> . . . . .	74
Figura 30 – Filtros triangulares usados no cálculo do MFCC. . . . .	76
Figura 31 – Passos e exemplo a aplicação do MFCC no EEG. . . . .	77
Figura 32 – Problema da multilateração na estimação da saída. . . . .	87
Figura 33 – Representação da transformação de kernel. . . . .	88
Figura 34 – Os hiperplanos descrevem possíveis soluções para um problema linearmente separável. . . . .	90
Figura 35 – Truque do <i>Kernel</i> . . . . .	94
Figura 36 – Comparação entres as PSD em intervalos ictais e interictais. Segmento de 2s do paciente CHB01 canal FP1-F7. . . . .	101
Figura 37 – Comparação entres as PSD em intervalos ictais e interictais. Segmento de 2s do paciente CHB02 canal FP1-F7. . . . .	101
Figura 38 – Comparação entres as PSD em intervalos ictais e interictais. Segmento de 2s do paciente CHB03 canal FP1-F7. . . . .	102
Figura 39 – Procedimento para construção dos vetores de atributos a partir do método de Welch dos $N$ canais de EEG. . . . .	103
Figura 40 – Procedimento para construção dos vetores de atributos a partir do método de LPC com $p$ e $N$ canais. . . . .	104
Figura 41 – Coeficientes MFCC período ictal. . . . .	105
Figura 42 – Coeficientes MFCC período interictal. . . . .	105

Figura 43 – Exemplo de Curva ROC. . . . .	110
Figura 44 – Diagrama de Caixas. . . . .	111
Figura 45 – Curva ROC para os cenários - Paciente CHB03. . . . .	116
Figura 46 – Qualidade da classificação em todos os cenários do paciente CHB03. . . . .	120
Figura 47 – Curva ROC para o método do Coeficientes Mel-Cepstrais - Paciente CHB02. . . . .	122
Figura 48 – Curva ROC para o método do Coeficientes Mel-Cepstrais - Paciente CHB05. . . . .	123
Figura 49 – Fonte de erros causados por artefatos no EEG do paciente CHB05. . . . .	124
Figura 50 – Presença de artefatos nos dados paciente CHB03. . . . .	124
Figura 51 – Curva ROC para o método do Coeficientes Mel-Cepstrais - Paciente CHB07. . . . .	126
Figura 52 – Diagrama de Bloco dos tempos de extração em cada época. . . . .	127
Figura 53 – Método MFCC - CBH03 - Resultados em Diagrama de Caixas. . . . .	143
Figura 54 – Método LPC - CBH03 - Resultados em Diagrama de Caixas. . . . .	144
Figura 55 – Método da vetorização da Matriz de Covariância - CBH03 - Resultados em Diagrama de Caixas. . . . .	145
Figura 56 – Método de Extração PDS - CBH03 - Resultados em Diagrama de Caixas. . . . .	146
Figura 57 – Método de Extração MFCC - CBH02 - Resultados em Diagrama de Caixas. . . . .	147
Figura 58 – Método de Extração MFCC - CBH05 - Resultados em Diagrama de Caixas. . . . .	148
Figura 59 – Método de Extração MFCC - CBH07 - Resultados em Diagrama de Caixas. . . . .	149
Figura 60 – Espículas Rolândicas. Paciente de 3 anos de idade. Sonolento. Proeminente deflexão principal descendente desses pontos indica que eles ocupam um campo positivo (FP2 – F4 – F8) e um campo negativo (C4 – P4 – T6). . . . .	150
Figura 61 – Espículas frontais. Idade do paciente, 11 anos. Acordado. Picos ocorrem repetidamente no F4. . . . .	150
Figura 62 – Espículas occipitais. Paciente de 2 anos. Sono leve. O grau de propagação anterior (P4) e contralateral dos pontos occipitais de caráter variável. . . . .	151
Figura 63 – Espículas temporais anterior-mesiais em uma montagem frontal polar-central coronal. Observe o envolvimento principal de F8–A2–T4. . . . .	151
Figura 64 – Poliespículas temporais esquerdos. Paciente de 40 anos. As poliespículas podem ser um pouco mais difíceis de reconhecer do que picos únicos, já que eles não emergem de forma tão intensa da atividade em segundo plano. Estes aparecem principalmente na região médio-temporal esquerda (T3) com disseminação contígua para a região temporal anterior-inferior esquerda (F7). . . . .	152



Figura 65 – Espículas de ondas generalizadas. Idade do paciente, 9 anos. Acordado. Olhos fechados. Após 3 a 4 segundos a descarga de onda espícula envolve todos os eletrodos. . . . .	152
Figura 66 – Ondas de espículas lentas. Paciente, 55 anos. Acordado. Olhos abertos. Essas ondas de pico sincronizadas de 2 Hz são caracteristicamente mais abundantes em um único registro do que as ondas de pico de maior frequência. São observados “vales” eletropositivos proeminentes entre os componentes de ponta e onda. . . . .	153

## LISTA DE TABELAS

Tabela 1 – Índice de concordância no trabalho de Benbadis <i>et al.</i> (2009). . . . .	25
Tabela 2 – Resumo de trabalhos anteriores. . . . .	31
Tabela 3 – Nomenclatura sistema 10-20 . . . . .	44
Tabela 4 – Tipos de Montagem. . . . .	45
Tabela 5 – Resumo dos dados dos pacientes diagnosticados com epilepsia. . . . .	98
Tabela 6 – Exemplo de separação dos arquivos para testes do paciente CHB01. . . . .	98
Tabela 7 – Matriz de Confusão . . . . .	108
Tabela 8 – Métricas de Comparação entre os cenários. . . . .	109
Tabela 9 – Hiperparâmetros dos classificadores avaliados. . . . .	112
Tabela 10 – Lista de Parâmetros . . . . .	113
Tabela 11 – Crises catalogadas do paciente CHB03. . . . .	116
Tabela 12 – Média dos resultado para o método MFCC do paciente CHB03. . . . .	117
Tabela 13 – Média dos resultados para o método LPC do paciente CHB03. . . . .	118
Tabela 14 – Média dos resultado para o uso da matriz de covariância. . . . .	119
Tabela 15 – Média dos resultado para a PSD para o paciente CHB03. . . . .	119
Tabela 16 – Hiperparâmetros utilizados para o paciente CHB03. . . . .	121
Tabela 17 – Hiperparâmetros utilizados nos pacientes CHB02 e CHB05. . . . .	121
Tabela 18 – Média dos resultado utilizando o coeficiente MFCC - Paciente CHB02 . . .	122
Tabela 19 – Média dos resultado para os testes realizados utilizando o coeficiente MFCC - Paciente CHB05 . . . . .	123
Tabela 20 – Arquivos utilizados para o paciente CHB07. . . . .	125
Tabela 21 – Hiperparâmetros utilizados no paciente CHB07. . . . .	125
Tabela 22 – Média dos resultado para os testes realizados utilizando o coeficiente MFCC - Paciente CHB07. . . . .	126
Tabela 23 – Média do tempo de extração para cada época, em segundos. . . . .	127
Tabela 24 – Tempo de treinamento dos algoritmos de aprendizagem, em segundos. . . .	127

## LISTA DE ABREVIATURAS E SIGLAS

A/D	Analógico Digital
AR	Autorregressivos
ARMA	Autorregressivos de Médias Móveis
BCI	<i>Brain Computer Interface</i>
CNEP	Convulsões não-epiléticas psicogênicas
CPE	Crises Pseudoepilépticas
CSP	<i>Common Spatial Patterns</i>
DATASUS	Departamento de Informática do Sistema de Saúde Único
DCT	Transformada Discreta do Cosseno
DFFT	Transformada Discreta Rápida de Fourier
DFT	Transformada Discreta de Fourier
DT	Árvore de Decisão
DWT	Transformada Discreta de Wavelet
EEG	Eletroencefalograma
FAC	Função de Autocorrelação
FACP	Função de Autocorrelação Parcial
FFT	Transformada Rápida de Fourier
FIR	Filtro de resposta ao impulso finita
FT	Transformada de Fourier
GMM	Modelo de Misturas de Gaussianas
HT	Transformada de Hilbert
IA	Inteligência Artificial

IC	Intervalo de Confiança
ICA	<i>Independent Component Analysis</i>
IDFT	Transformada Inversa Discreta de Fourier
LDA	<i>Linear Discriminant Analysis</i>
LPC	<i>Linear Predictive Code</i>
LS-SVM	<i>Least Squares Support Vector Machine</i>
MFCC	Coefficientes Mel-Cepstrais
PCA	<i>Principal Component Analysis</i>
PEPS	Potenciais excitatórios pós-sinápticos
PIPS	Potenciais inibitórios pós-sinápticos
PSD	Densidade Espectral de Potência
RNA	Redes Neurais Artificiais
RP	Reconhecimento de Padrões
SNC	Sistema Nervoso Central
SVM	Support Vector Machine
WT	Transformada de Wavelet

## LISTA DE SÍMBOLOS

$\kappa$	Coefficiente de concordância estatístico.
$\mathcal{X}(\omega)$	Transformada de Fourier tempo contínuo
$\mathcal{X}(e^{j\omega})$	Transformada de Fourier tempo discreto.
$\omega$	Frequência angular
$S(e^{j\omega})$	Densidade Espectral de Potência
$r_{xx}$	Função de Autocorrelação.
$\mathbb{E}$	Operador Valor Esperado
$\mathbf{C}_y$	Matriz de Covariância
$\mathbf{R}_y$	Matriz de Autocorrelação
$f_s$	Frequência de amostragem
$\text{sign}(\cdot)$	Função sinal
$c$	Cepstrum
$c_{mel}$	Coefficientes Mel-Cepstrais
$\mathbf{w}_i$	Vetor de pesos ELM
$\phi(\cdot)$	função não linear (logística ou hiperbólica)
$\mathbf{D}_x$	Matriz de distância MLM (entrada-pontos de referência)
$\mathbf{\Delta}_y$	Matriz de distância MLM (saída-pontos de referências)
$\phi(\mathbf{x}, \mathbf{y})$	Função de <i>Kernel</i>
$\alpha_i$	Multiplicador de Lagrange
$\beta_i$	Multiplicador de Lagrange
$C$	Parâmetro de Regularização do classificador SVM
$\mu$	Vetor média
$\mathbf{I}$	Matriz Identidade
$\mathcal{N}(\mu, \sigma)$	Distribuição Gaussiana
$\mathcal{U}(-a, a)$	Distribuição Uniforme
$q$	Quantidade de Neurônios na camada oculta (ELM)

$R$	Quantidade de pontos de referência (MLM)
$D$	Dimensão do mapeamento do RKS
$\sigma^2$	Escalonamento do <i>kernel</i> gaussiano

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>21</b>
<b>1.1</b>	<b>Motivação</b>	<b>22</b>
<b>1.2</b>	<b>Descrição do Problema</b>	<b>24</b>
<b>1.3</b>	<b>Objetivos</b>	<b>30</b>
<i>1.3.1</i>	<i>Objetivo Geral</i>	<i>30</i>
<i>1.3.2</i>	<i>Objetivos Específicos</i>	<i>31</i>
<b>1.4</b>	<b>Produção Científica</b>	<b>32</b>
<b>1.5</b>	<b>Organização Geral da Dissertação</b>	<b>33</b>
<b>2</b>	<b>ELETOENCEFALOGRAMA E EPILEPSIA</b>	<b>35</b>
<b>2.1</b>	<b>Eletroencefalograma - EEG</b>	<b>35</b>
<i>2.1.1</i>	<i>Princípios básicos de neurofisiologia</i>	<i>35</i>
<i>2.1.2</i>	<i>Aspectos Técnicos do EEG</i>	<i>39</i>
<i>2.1.3</i>	<i>Ritmos Cerebrais</i>	<i>47</i>
<b>2.2</b>	<b>Epilepsia</b>	<b>48</b>
<i>2.2.1</i>	<i>Estágios de uma crise epiléptica</i>	<i>50</i>
<i>2.2.2</i>	<i>Atividade epileptiforme</i>	<i>51</i>
<i>2.2.3</i>	<i>Desafio do Diagnóstico</i>	<i>54</i>
<b>2.3</b>	<b>Conclusão</b>	<b>58</b>
<b>3</b>	<b>EXTRAÇÃO DE ATRIBUTOS</b>	<b>60</b>
<b>3.1</b>	<b>Características do EEG</b>	<b>61</b>
<b>3.2</b>	<b>Análise Espectral</b>	<b>63</b>
<i>3.2.1</i>	<i>Janelamento</i>	<i>66</i>
<i>3.2.2</i>	<i>Estimação da PSD pelo método de Welch</i>	<i>67</i>
<b>3.3</b>	<b>Codificação Linear Preditiva</b>	<b>70</b>
<i>3.3.1</i>	<i>Estimação dos Coeficientes pelo Método de Yule-Walker</i>	<i>71</i>
<b>3.4</b>	<b>Coeficientes Cepstrais</b>	<b>73</b>
<i>3.4.1</i>	<i>Coeficientes Mel Cepstrais</i>	<i>75</i>
<b>3.5</b>	<b>Matriz de Covariância como Extrator de Características</b>	<b>78</b>
<b>3.6</b>	<b>Conclusão</b>	<b>80</b>
<b>4</b>	<b>CLASSIFICADORES</b>	<b>81</b>

4.1	O problema da classificação . . . . .	83
4.2	Máquina de Aprendizado Extremo . . . . .	84
4.3	Máquina de Aprendizado Mínimo . . . . .	86
4.4	Random Kitchen Sinks . . . . .	88
4.5	Máquina de Vetor de Suporte . . . . .	90
4.6	Conclusão . . . . .	95
5	<b>METODOLOGIA DOS EXPERIMENTOS</b> . . . . .	97
5.1	Banco de Dados de EEG . . . . .	97
5.2	Preparação dos Arquivos . . . . .	97
5.3	Montagem dos Vetores de Características . . . . .	99
5.3.1	<i>PSD Método de Welch</i> . . . . .	100
5.3.2	<i>Codificação Linear Preditiva</i> . . . . .	103
5.3.3	<i>Coefficientes Mel-Cepstrais</i> . . . . .	104
5.3.4	<i>Vetor de atributos com a matriz de covariância</i> . . . . .	106
5.3.5	<i>Configuração dos Métodos de Extração</i> . . . . .	107
5.4	Avaliação dos Classificadores . . . . .	107
5.5	Seleção do Modelo . . . . .	111
5.6	Treinamento e Testes dos Classificadores . . . . .	112
5.7	Conclusão . . . . .	113
6	<b>RESULTADOS</b> . . . . .	115
6.0.1	<i>Paciente CHB03</i> . . . . .	115
6.0.2	<i>Resultados do Paciente CHB02 e CHB05</i> . . . . .	121
6.0.3	<i>Resultados do Paciente CHB07</i> . . . . .	125
6.1	Comparação do Tempo de Processamento . . . . .	126
7	<b>CONCLUSÃO</b> . . . . .	129
7.1	Objetivo Geral . . . . .	129
7.2	Objetivos Específicos . . . . .	130
7.3	Trabalhos Futuros . . . . .	131
	<b>REFERÊNCIAS</b> . . . . .	132
	<b>APÊNDICES</b> . . . . .	143
	<b>APÊNDICE A</b> – Demais Resultados . . . . .	143
	<b>APÊNDICE B</b> – Alguns padrões Epileptiforme . . . . .	150



<b>APÊNDICE C – Classificador Linear de Mínimos quadrados . . . . .</b>	<b>154</b>
---	------------

## 1 INTRODUÇÃO

Atualmente, há um grande interesse em aplicações de inteligência artificial (IA) em diversas áreas de pesquisa, impulsionado pela disponibilidade de grandes conjuntos de dados, avanços substanciais em poder de computação e no desenvolvimento de novos algoritmos de aprendizagem. Reconhecimento automático de padrões, descrição, classificação e agrupamento de padrões são problemas importantes em áreas de pesquisas, como biologia, psicologia, engenharia, medicina, *marketing*, visão computacional, inteligência artificial e sensoriamento remoto, dentre outras (JAIN *et al.*, 2000).


O reconhecimento de padrões (RP) é uma área de estudo que se desenvolveu significativamente nos anos 60. Há um vasto número de aplicações que vão desde os clássicos reconhecimento automático de caracteres e diagnóstico médico até os mais recentes, como problemas relacionados à mineração de dados. Isso vem atraindo um considerável esforço de pesquisa nas últimas décadas (WEBB; COPSEY, 2011).

Técnicas populares de IA, como Máquina de Vetores de Suporte (SVM, do inglês: *support vector machine*) e Redes Neurais Artificiais são ferramentas utilizadas nas principais áreas médicas de pesquisas relacionadas ao câncer, à neurologia e à cardiologia. As aplicações de IA são empregadas na classificação de diagnóstico precoce, indicação de tratamento, bem como na avaliação de prognóstico de um paciente. Apesar de um treinamento intensivo dos profissionais da saúde, o ser humano possui uma capacidade limitada e, em certos diagnósticos sob condições adversas (estresse, fadiga e incapacidade técnica), os sistemas computacionais costumam apresentar um desempenho melhor quando são projetados corretamente. Em curto prazo, a IA irá definitivamente ajudar os médicos a tomar melhores decisões clínicas ou até mesmo substituir o julgamento humano, supervisionado por uma junta médica, em certas áreas funcionais da saúde cada vez mais simples (JIANG *et al.*, 2017).

À vista disso, houve uma grande disseminação de estratégias de IA e RP na Medicina, como se observa no Gráfico 1, que trás os 10 principais tópicos de pesquisas relacionadas a doenças na literatura de inteligência artificial no banco de dados PubMed<sup>1</sup>. Quando é realizada a aplicação filtros à base de dados da PubMed relacionadas com o sistema neural, observa-se o uso dessas estratégias em várias aplicações distintas, dentre as quais podem-se citar os trabalhos no campo da tecnologia neuro protética (BOUTON *et al.*, 2016), interface homem/máquina (FA-

<sup>1</sup> PubMed é um motor de busca de livre acesso à base de dados MEDLINE de citações e resumos de artigos de investigação em biomedicina.

Figura 1 – Os 10 tópicos mais relevantes de pesquisas relacionadas a doença com aplicação de inteligência artificial na literatura no banco de dados PubMed por ano



Fonte: adaptado da Jiang *et al.* (2017).

RINA *et al.*, 2017), diagnóstico precoce de síndromes mentais como o Alzheimer (KHEDHER *et al.*, 2015), epilepsia (FERGUS *et al.*, 2015) e por fim destacar o grande número de aplicações de neuroimagem (GUORONG *et al.*, 2014; REHME *et al.*, 2015).

## 1.1 Motivação


As técnicas de auxílio à diagnóstico clínico utilizando IA e RP são altamente difundidas na Medicina e na Neurologia, conforme destacado anteriormente. Porém, quando se observa pontualmente a epilepsia, encontra-se um cenário em que o diagnóstico errôneo é um problema comum, no qual estudos relatam taxas de erros entre 4.6 a 30% em diferentes cenários (CHOWDHURY *et al.*, 2008), sendo de extrema necessidade o uso de técnicas computacionais e de aprendizados de máquinas que reduzam essas taxas. Pessoas diagnosticadas com epilepsia são duas ou três vezes mais propensas a morrer prematuramente quando comparadas a uma pessoa normal (WHO, 2018). Assim, o estudo da epilepsia é de extrema importância e relevância, e ela é estudada em diversas áreas de pesquisa da saúde e da engenharia.

Segundo a Organização Mundial de Saúde (OMS), aproximadamente 50 milhões de pessoas vivem com epilepsia em todo o mundo. Estima-se que a população com epilepsia ativa, ou seja, a que apresenta necessidade de tratamento, é de 4 para mil pessoas e podendo variar entre 7 e 14 por mil em países de baixa e média renda. Outro dado relevante, destacado pela OMS, é

que cerca de 2,4 milhões novos casos de epilepsia são diagnosticados todo ano no mundo. Nos países desenvolvidos, observa-se uma taxa de novos casos em torno de 30 a 50 pessoas por 100 mil habitantes, taxa que pode duplicar quando se observa os países subdesenvolvidos (WHO, 2018).

No Brasil, há raros trabalhos sobre a prevalência da epilepsia, os quais se restringem a estudos em pequenas regiões. Portanto, não se sabe exatamente qual é a realidade em relação ao tratamento e à situação de saúde das pessoas com epilepsia no país. Porém, quando se observam os dados do Sistema de Informação da Atenção Básica (SIAB) do Ministério da Saúde (DATASUS, 2018), gerados a partir do atendimento de equipes de Saúde Familiar e Agentes Comunitários de Saúde às famílias cadastradas (cerca de 60% da população brasileira em 2015). É possível verificar, na Figura 2, que, em 2015, cerca de 400 mil pessoas foram acometidas com essa doença cerebral crônica, que tem consequências neurobiológicas, cognitivas, psicológicas e sociais, prejudicando diretamente a qualidade de vida do indivíduo afetado nas famílias avaliadas pelo programa.

Figura 2 – Casos de epilepsia registrados no SIAB até julho de 2015.



Fonte: adaptado da DATASUS (2018).

O diagnóstico básico em suspeita de epilepsia é realizado através de uma anamnese<sup>2</sup> completa e cuidadosa, além de exames físicos e neurológicos. É possível que, em alguns casos, o diagnóstico seja realizado sem a necessidade de exames complementares, porém, normalmente, se faz necessário o uso do eletroencefalograma (EEG), exames de imagem do

<sup>2</sup> entrevista realizada pelo profissional de saúde com o indivíduo afetado ou testemunha.

encéfalo através de uma tomografia computadorizada ou de ressonância magnética nuclear, exames laboratoriais (eletrólitos, glicose, hemograma e leucograma), punção lombar para a análise do líquido cefalorraquidiano ou até rastreamento toxicológico do indivíduo (ENGEL, 2005).

Nas últimas décadas, a engenharia biomédica e a biomedicina proporcionaram diversos avanços tecnológicos que auxiliam os médicos e especialistas no estudo da epilepsia, tanto na semiologia quanto na epileptologia, mediante contribuições como: vídeo-eletroencefalografia (Vídeo-EEG), aplicação de técnicas genéticas, e, principalmente, de estudos estruturais funcionais do sistema nervoso, como ressonância magnética, tomografia por emissão de fóton único e tomografia por emissão de pósitrons

O EEG é uma ferramenta de grande importância na avaliação diagnóstica, se realizado por técnicos experientes e cuidadosamente analisado e interpretado no contexto de um cenário clínico bem descrito por médicos experientes. Há vantagens em se utilizar o EEG de escalpo, que é inteiramente inofensivo (por não ser intrusivo) e relativamente barato. Trata-se de uma ferramenta essencial na investigação de distúrbios neurológicos, especialmente da epilepsia, tanto no diagnóstico como na classificação dos tipos de crises (PANAYIOTOPOULOS, 2010).

## 1.2 Descrição do Problema

A experiência cotidiana mostra que a frequência de diagnósticos falhos cometidos por neurologistas que não estão familiarizados com as especificidades do EEG são comuns. Alguns trabalhos tentam apresentar a dificuldade de ter uma uniformidade na interpretação do EEG. No trabalho de Benbadis *et al.* (2009), os autores submeteram um comitê de neurologistas à tarefa de analisar e julgar se a descrição do(s) evento(s) em determinados cenários respeitavam os critérios de diagnósticos descritivos predefinidos e classificar entre: convulsões não epiléticas psicogênicas (CNEP), epilepsia ou não CNEP. Para avaliar a concordância, os pesquisadores utilizaram o coeficiente de kappa ( $\kappa$ ) (método estatístico para avaliar o nível da concordância) e observaram que, para o diagnóstico de crises não epiléticas psicogênicas, há concordância moderada ( $\kappa=0.57$ , IC 95% 0.39-0,76)<sup>3</sup>. Para o diagnóstico de epilepsia, houve concordância substancial ( $\kappa= 0.69$ , IC 95% 0,51-0,86). Para episódios fisiológicos não epiléticos, a concordância foi baixa ( $\kappa = 0.09$ , IC 95% 0.02-0.27). Os resultados estão sumarizados na Tabela 1.

<sup>3</sup> Onde IC é o intervalo de confiança.

Tabela 1 – Índice de concordância no trabalho de Benbadis *et al.* (2009).

	Índice $\kappa$	Intervalo de Confiança 95%	Interpretação de Concordância
CNEP	0.57	0.39-0.76	Moderada
epilepsia	0.69	0.51-0.86	Substancial
Não Epilético CNEP	0.09	0.02-0.27	Fraca

Fonte: adaptado de Benbadis *et al.* (2009).

Em Stroink *et al.* (2006), os autores abordam o índice  $\kappa = 0.66$  para concordância sobre se o EEG foi anormal ou normal. Os resultados apresentaram:

- $\kappa = 0.83$  para a presença de anormalidades epileptiformes<sup>4</sup>;
- $\kappa = 0.53$  para a anormalidade do padrão de fundo;
- $\kappa = 0.38$  para a presença de anormalidades focais não epileptiformes.

Observa-se que examinadores diferentes podem ter opiniões divergentes sobre a interpretação de certos elementos gráficos, e alguns fenômenos podem ser difíceis de interpretar. Embora os resultados possam refletir certas limitações (diagnóstico baseado em vídeo-EEG, natureza artificial do paradigma de escolha forçada, episódio único) dos estudos aqui apresentados, eles destacam as dificuldades e os componentes subjetivos inerentes a esse diagnóstico.

O uso do monitoramento prolongado por vídeo-EEG contribui no registro simultâneo de características comportamentais e eletrográficas do indivíduo. É uma ferramenta utilizada para investigar pacientes que apresentam diagnósticos difíceis e tratamento de eventos clínicos, em que há a intensificação ou recorrência súbitas dos sintomas. Quando é necessário observar os comportamentos clínicos relacionados com a síndrome epilética, o monitoramento por vídeo-EEG é a melhor ferramenta diagnóstica disponível por caracterizar os tipos de crises ou síndromes epiléticas, auxiliando no diagnóstico das crises (ASANO *et al.*, 2005). O vídeo-EEG de longa duração para o diagnóstico de epilepsia é uma proposta dispendiosa e trabalhosa (comparado com o EEG de rotina), pois envolve leitos hospitalares, equipamentos de monitoramento e uma equipe multidisciplinar altamente treinada, composta por técnicos, enfermeiros e um médico experiente e bem treinado para a avaliação.

Segundo Chowdhury *et al.* (2008), a anamnese incompleta e a interpretação excessiva do EEG pelos profissionais são apontadas como as principais causas de erros de diagnósticos. Para melhorar a precisão dos diagnósticos, é necessário atingir um padrão ouro. Porém, tal padrão ouro não está disponível no diagnóstico da epilepsia. Existe um sistema de classificação

<sup>4</sup> são ondas cerebrais que se destacam por sua morfologia diferente da atividade elétrica cerebral, com aspecto mais pontiagudo, com amplitude habitualmente mais elevada e composição variável em relação à linha de base do EEG.

para categorizar os tipos e síndromes de convulsões, mas não há critérios diagnósticos específicos para distinguir com segurança entre uma crise epilética e outros diagnósticos com características clínicas sobrepostas.


Além dos argumentos já apresentados, deve-se lembrar que epilepsia é um distúrbio do sistema nervoso central, e sua expressão clínica inclui sintomas cognitivos e psiquiátricos juntamente com as crises epiléticas. Portanto, os pacientes diagnosticados com epilepsia têm um grande risco de desenvolver diversos transtornos mentais, e, neste sentido, prevenir e tratar as crises precocemente reduz ou até anula o impacto neuropsicológico e as sequelas associadas a epilepsias de difícil controle.

Em sistemas de auxílio ao diagnóstico baseados em técnicas de Aprendizado de Máquinas, a qualidade da informação produzida (decisão) é extremamente dependente da qualidade dos dados adquiridos para análise e da escolha de um classificador que informe de modo confiável a presença ou ausência de certa patologia a partir do treinamento e validação sobre o conjunto de dados previamente coletado. Tanto a localização dos canais EEG envolvidos quanto o conteúdo espectral da atividade rítmica variam entre os indivíduos. Além disso, a assinatura EEG da convulsão de um paciente pode assemelhar-se à assinatura de EEG anormal, não convulsivo, coletada do mesmo paciente ou de um paciente diferente.

O EEG contém valiosas informações sobre a atividade cerebral. Sabe-se o quanto esse exame é importante para a detecção e diagnóstico preciso da epilepsia e outras síndromes, porém foi apresentado que a inspeção visual do EEG é demorada e, em segundo lugar, a sua interpretação é complexa e apontada como fonte de erros em muitos diagnósticos. Portanto, há uma necessidade de um sistema de diagnóstico que diferencie os instantes *Ictais* (período em que ocorre uma crise epilética), *Interictais* (período entre as crises, para um paciente já diagnosticado com a síndrome) e Normais (para pacientes que não são diagnosticados com epilepsia), fornecendo informações úteis para um diagnóstico mais preciso.

Um dos primeiros detectores de eventos convulsivos foi desenvolvido por Gotman (1982), cujo algoritmo procurava um padrão das crises epiléticas: atividade rítmica sustentada. Em suma, o algoritmo fazia uma varredura sequencial nos canais EEG pela presença de atividade rítmica com uma frequência dominante entre 3-20 Hz e uma amplitude 3 vezes maior que a de uma janela de fundo. O algoritmo declarava convulsão quando o grau de ritmicidade excedesse um limiar de pelo menos dois canais em um período de 4 segundos. Uma avaliação recente do algoritmo de Gotman em 652 horas de EEG de escalpo, que incluiu 126 convulsões de 28

Figura 3 – Exemplo de 10 Segundos de EEG.



Fonte: Shoeb (2010).

pacientes, mostrou que essa abordagem detecta apenas 50% dos testes e declara uma detecção falsa a cada meia hora (SHOEB, 2009).

Segundo Ramgopal *et al.* (2014), um sistema de detecção ou classificação de crises epiléticas consiste de duas partes. Primeiro, preprocessar, filtrar ou decompor o EEG para a extração de *features* ou características, e, segundo, usar os dados da primeira parte para a classificação através de algum algoritmo de classificação supervisionado. Pela natureza caótica e não estacionária dos sinais do EEG (MORMANN *et al.*, 2000), o processo de extração de características, na primeira etapa, desempenha um papel fundamental para o sucesso do sistema.

Na literatura, observa-se a proposição de vários métodos com o intuito de desenvolver e melhorar essa difícil tarefa da classificação e detecção de crises epiléticas. Com relação à extração de atributos, a maioria dos métodos observados se enquadram em uma dessas quatro categorias amplas: domínio do tempo, domínio da frequência, domínio de tempo-frequência e métodos não lineares. Nesta etapa, é criado um conjunto de características que serão usadas para



a realização de treinamento e classificação.

No domínio do tempo, os métodos mais comumente utilizados para análise são: a codificação linear preditiva (LPC, do inglês *Linear Predictive Coding*) (ALTUNAY *et al.*, 2010) e análise de componentes principais e independentes (*Principal Component Analysis* (PCA) e *Independent Component Analysis* (ICA) (SUBASI; GURSOY, 2010; ACHARYA *et al.*, 2012)), e os Modelos Autorregressivos Multivariados (MVAR-*Multivariate Autoregressive Modeling*) (KRUMIN; SHOHAM, 2010; PAGNOTTA; PLOMP, 2018).

Quando se observa o domínio da frequência (análise espectral), faz-se um exame detalhado da informação contida na frequência do sinal, utilizando normalmente a Transformada de Fourier (FT). Os métodos de estimação da densidade espectral de potência (PSD, do inglês *Power Spectral Density*) podem ser categorizados como não paramétricos e paramétricos. Nos métodos não paramétricos, primeiramente, a autocorrelação do sinal inicialmente estimada a partir de um conjunto de dados sequenciados no tempo e, para a estimativa do espectro de energia aplicando a FT à sequência de autocorrelação, comumente se utiliza o método de Welch (POLAT; GÜNEŞ, 2007) e, no trabalho de FAUST *et al.* (2010), foi utilizado o método Burg (BURG, 1967). A abordagem dos métodos paramétricos se resume em o sinal de entrada ser modelado como a saída de um filtro, no qual a entrada é o ruído gaussiano e, em seguida, os parâmetros de filtro correspondentes são encontrados. Existem muitos métodos para calcular os parâmetros do filtro de acordo com o modelo do filtro usado, pode-se citar o modelo ARMA (*Auto Regressive Moving Average*) (WU *et al.*, 2011).

Um método comumente utilizado na análise EEG é a decomposição dos sinais tanto no domínio da frequência quanto no domínio do tempo utilizando a Transformada de Wavelet (TW). Diversos trabalhos utilizam a TW por ser uma ferramenta de processamento de sinais não estacionários eficiente. No trabalho de Guo *et al.* (2011) e Chen *et al.* (2017), é utilizada a Transformada Discreta de Wavelet (TDW). Outros trabalhos realizam a chamada decomposição em pacotes wavelets (ACHARYA *et al.*, 2012; LI *et al.*, 2017; SHARMA *et al.*, 2017). A característica atraente da TW é que ela fornece informações de frequência precisas em baixas frequências e informações precisas de tempo em altas frequências. Normalmente, a Transformada de Wavelet é aplicada conjuntamente ou dando suporte a outro método de extração nesse contexto: pode-se citar os trabalhos de que utilizam a decomposição wavelet associada com a entropia do sinal (RAGHU *et al.*, 2017; GUPTA *et al.*, 2017; DAS; BHUIYAN, 2016). Outro método utilizado de decomposição de sinais, no domínio tempo-frequência, é a Transformada de

Hilbert (TH), como destacado nos trabalhos de Melges *et al.* (2007) e MARTIS *et al.* (2012).

Os métodos destacados acima são basicamente métodos lineares, que porventura foram combinados com algum método não linear. Porém, há uma diversidade de métodos não lineares que estão sendo aplicados no contexto da extração de características do sinal do EEG. Dentre eles, podem-se destacar os diferentes métodos de entropia, tais como a entropia de Kolmogorov–Sinai, entropia de Rényi e Shannon, entropia de permutação, entropia Fuzzy, entre outras (ACHARYA *et al.*, 2015; GUPTA *et al.*, 2017). Outros exemplos de métodos não lineares para a extração de atributos de sinais do EEG são: maior expoente de Lyapunov (GÜLER *et al.*, 2005) e cumulantes de ordem superior (ACHARYA *et al.*, 2011; ALAM; BHUIYAN, 2013).

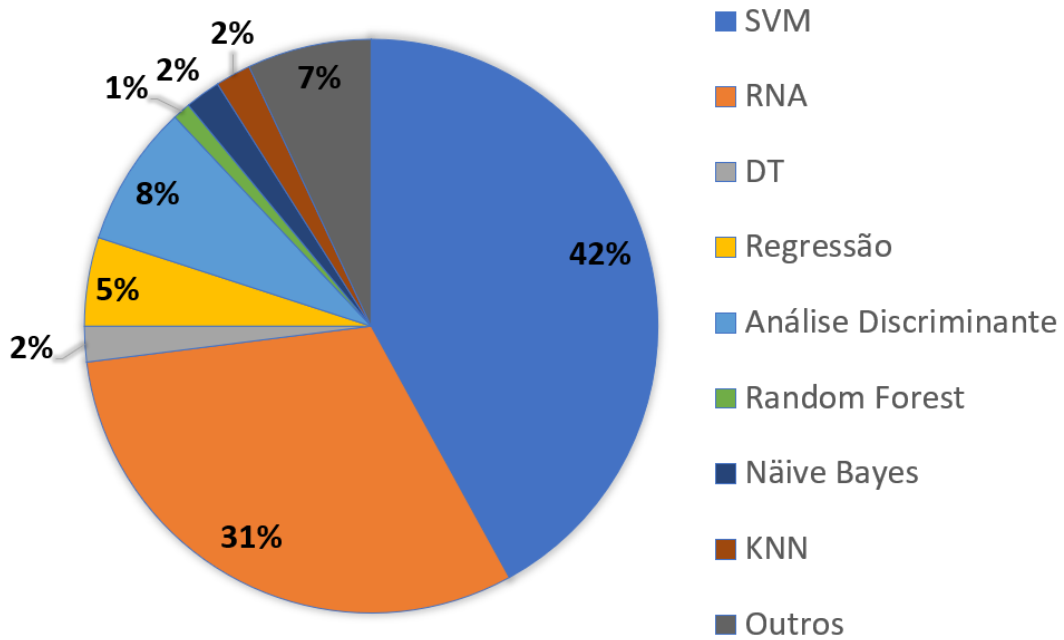
Destaca-se ainda o trabalho de HÖLLER *et al.* (2017), que realiza uma comparação entre diversos métodos de extração aqui destacados anteriormente, e as técnicas de redução de dimensionalidade do sinal ou dos atributos, que transformam o espaço de dados em um espaço de dados menor mantendo as informações relevantes.

Na tarefa de classificação ou detecção de crises epiléticas, após a fase de extração de atributos, é necessário efetuar o treinamento ou aprendizagem supervisionada do classificador. Nesta etapa, os parâmetros do modelo que determinam os critérios para a presença ou ausência de convulsões são estimados. Este passo envolve a escolha do tipo de algoritmo, seleção de parâmetros, testes, validação e análise dos resultados. Toda essa implementação da detecção de crises pode ser efetuada em tempo real, como também pode ser utilizada *a posteriori* à medida que mais dados são coletados.

Contudo, sabe-se que a aprendizagem supervisionada fornece resultados clinicamente mais relevantes. Sendo assim, os algoritmos de IA empregados em auxílio de diagnóstico na saúde geralmente usam o aprendizado supervisionado. Uma gama de algoritmos relevantes são utilizados, dentre os quais destacam-se a regressão linear, regressão logística, Classificador Nãive Bayes, árvore de decisão (DT), *k*-vizinho mais próximo (kNN, do inglês *k*-nearest neighbors), floresta aleatória (RF), análise discriminante, SVM e redes neurais artificiais (RNA) entre outros. Um levantamento recente no trabalho de Jiang *et al.* (2017), apresentado na Figura 4, mostra um comparativo para cada tipo de algoritmos de aprendizado de máquina em trabalhos publicados no PubMed referentes a estudos eletrofisiológicos.

Na Tabela 2, é apresentado um sumário dos trabalhos de referência apresentando os vetores de características utilizadas do EEG e os respectivos classificadores testados no trabalho. É importante salientar que os algoritmos devem ser testados em dados contínuos a

Figura 4 – Os algoritmos de aprendizado de máquina usados em trabalhos com dados eletrofisiológicos.



Fonte: Jiang *et al.* (2017).

longo prazo por cerca de horas ou dias, incluindo um número suficiente de convulsões e uma duração suficiente dos dados interictais. Um dado predito deve ser avaliado em termos de sensibilidade e especificidade para um dado período de ocorrência de crises. Os preditores devem ser estatisticamente validados para avaliar se um dado preditor tem um desempenho acima do nível de chance e desempenho deve ser avaliado prospectivamente em dados fora da amostra.

### 1.3 Objetivos

Uma vez exposto o problema de interesse e a motivação nas seções anteriores, a seguir os objetivos traçados para esta dissertação serão apresentados.

#### 1.3.1 *Objetivo Geral*

O objetivo geral desta pesquisa é, através da comparação de diversas técnicas de aprendizagem de máquina e de extração de atributos do sinal do eletroencefalograma, detectar/i-identificar automaticamente as atividades epileptogênicas e períodos ictais de uma crise epilética, usando um número mínimo de recursos discriminantes nos classificadores e buscando otimizar a sensibilidade e a especificidade do diagnóstico de epilepsia. Esse sistema de diagnóstico assistido por computador, cujo resumo gráfico é apresentado na Figura 5, será do tipo paciente-específico,

Tabela 2 – Resumo de trabalhos anteriores.

<b>Autor(es)</b>	<b>Atributos</b>	<b>Classificador(es)</b>
Altunay <i>et al.</i> (2010)	LPC	-
Subasi e Gursoy (2010)	PCA, ICA, e LDA	SVM
Acharya <i>et al.</i> (2012)	PCA com Transformada Wavelet	Árvores de Decisão (DT), Classificador Fuzzy , Modelo de Misturas de gaussianas(GMM) , KNN , Classificador Naive Bayes , Radial Basis Probabilistic Neural Network (RBPNN)
Polat e Güneş (2007)	PSD método de Welch	Árvore de Decisão
FAUST <i>et al.</i> (2010)	Método Burg (PSD)	SVM
Wu <i>et al.</i> (2011)	ARMA, Correlação Canônica	-
Guo <i>et al.</i> (2011)	DWT combinado com Algoritmo Genético	KNN
Chen <i>et al.</i> (2017)	DWT	SVM
Li <i>et al.</i> (2017)	Análise do Envelope de sinal com DWT combinado com a Transformada de Hilbert	Arranjo de Redes Neurais (ANN)
Sharma <i>et al.</i> (2017)	Bancos de Filtros Ortogonais DWT e Entropia Wavelet	Least-Square Suport Vector Machine (LS-SVM)
Raghu <i>et al.</i> (2017)	Transformada de Wavelet e diversos tipos de entropia combinados	Redes Neurais Recorrentes (RNN)
Gupta <i>et al.</i> (2017)	Transformada de Wavelet e diversos tipos de entropia combinados	KNN e LS-SVM
Das e Bhuiyan (2016)	Entropia, DWT e Método de Decomposição Empírico	KNN
Melges <i>et al.</i> (2007)	Transformada Discreta de Hilbert-Huang (TDH)	-
MARTIS <i>et al.</i> (2012)	Método de Decomposição Empírico (EMD)	Árvore de Decisão tipo CART e C4.5
Güler <i>et al.</i> (2005)	Maior Expoente de Lyapunov	RNN
Acharya <i>et al.</i> (2011)	Análise Espectral de Ordem Superior (HOSA)	SVM
Alam e Bhuiyan (2013)	Estatísticas de Ordem Superior	ANN

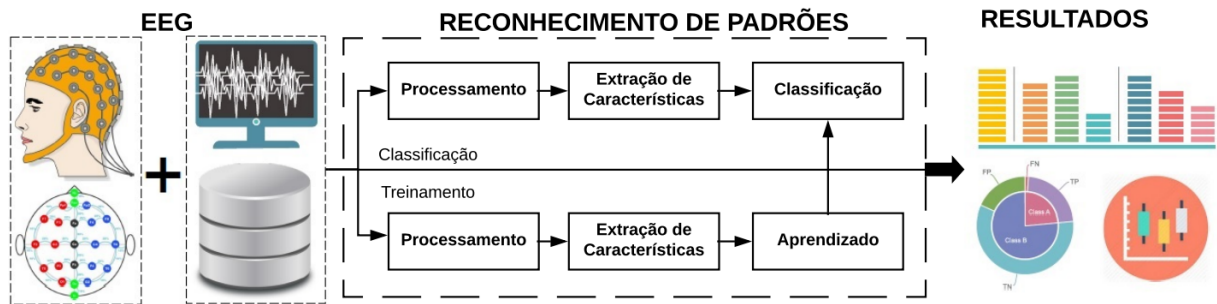
Fonte: o autor.

ou seja, personalizado para a anatomia, fisiologia ou característica de saúde de cada pessoa.

### 1.3.2 *Objetivos Específicos*

O objetivo geral da dissertação apresentado anteriormente, por ser bastante amplo, dá margem ao surgimento de vários objetivos menores e mais específicos, que serão listados a seguir:

Figura 5 – Resumo gráfico.



Fonte: o autor.

- Escolha de um conjunto de dados EEG de uso público, que seja compatível com o objetivo do trabalho e apresente uma rotulação dos intervalos (com ou sem crise epiléptica), e que contenha longos trechos;
- Otimização da sensibilidade e especificidade dos classificadores avaliados, a fim de detectar o início de uma crise o quanto antes;
- Implementação e subsequente avaliação de desempenho dos métodos de extração de características na tarefa de classificação de crises epilépticas a partir de sinais de EEG (análise espectral através da densidade espectral de potência, coeficientes LPC, Coeficientes Mel-Cepstrais e Matriz de Covariância);
- Implementar e avaliar o desempenho de classificadores aleatorizados (ELM - *Extreme learning Machine*, RKS - *Random Kitchen Sinks*, MLM - *Minimal Learning Machine*) e não randomizados (SVM e classificador linear) na tarefa de classificação de crises epilépticas a partir de sinais de EEG;
- Realização de estudo sistemático e abrangente envolvendo a combinação dos métodos de extração e classificadores supracitados.
- Investigação da adequabilidade ao problema de critérios de avaliação de classificadores;
- Utilizar a curva ROC (*receiver operating characteristic*) como ferramenta de comparação entre os cenários avaliados.

#### 1.4 Produção Científica

Ao longo do desenvolvimento desta dissertação os seguintes artigos científicos, s resultados parciais deste trabalho, foram publicados:

Rodrigues, N., **Peixoto, J.**, Barreto, G. A., & Becco, R. Randomized Pattern Classifiers for Epileptic Seizure Detection: A Critical Assessment. Trabalho publicado/aceito em anais

eventos do III Congresso Brasileiro de Inteligência Computacional- (CBIC 2017), 2017, Niterói. XIII Brazilian Congress on Computational Intelligence, 2017.

**Peixoto, J.**, Rodrigues, N., Barreto, G. A., & Becco, R. Avaliação de Desempenho da Rede Neural Máquina de Aprendizado Extremo na Detecção de Crises Epiléticas. Publicado no 8º Simpósio de Instrumentação e Imagens Médicas (SIIM) e o 7º Simpósio de Processamento de Sinais (SPS), 2018, São Bernardo do Campo. Anais do VIII Simpósio de Instrumentação e Imagens Médicas (SIIM) / VII Simpósio de Processamento de Sinais da UNICAMP. v. 1.

**Júlio Peixoto da Silva Jr**, Guilherme de Alencar Barreto e Charles Casimiro Cavalcante, “Detecção de Crises Epiléticas Usando o Modelo ANFIS e Coeficientes LPC: Uma Visão Crítica”. Trabalho publicado/aceito em anais eventos do Quinto Congresso Brasileiro de Sistemas Fuzzy. V CBSF, 2018, Fortaleza. Recentes Avanços em Sistemas Fuzzy, 2018. p. 213-224.

## 1.5 Organização Geral da Dissertação

O restante desta dissertação está organizado segundo os capítulos a seguir.

No Capítulo 2, é realizada uma revisão bibliográfica apresentando os principais conceitos da eletroencefalografia e da epilepsia. Será destacada a formação e as características das atividades eletrofisiológicas neurais do cérebro e os aspectos técnicos necessários para a aquisição dos sinais, tais como: a distribuição da localização dos eletrodos, tipos de montagem, ritmos cerebrais, artefatos, entre outros. Na segunda parte do capítulo, será apresentada a epilepsia, e será exposta a diferença entre síndrome Epilética, convulsão e crises epiléticas. Dando prosseguimento ao capítulo, será apresentado (de forma breve) os tipos e os estágios das crises epiléticas (objeto de estudo, a classificação entre períodos ictais e interictais). Em seguida, serão exibidas e discutidas as principais formas de onda de atividades anormais do EEG associadas com as crises epiléticas (ondas epileptiformes). Por fim, serão retratados os principais motivos pelo qual o diagnóstico da epilepsia é um desafio.

No Capítulo 3, serão abordadas as características do sinal do EEG e os métodos de extração de atributos. Será mostrado que os sinais da atividade cerebral apresentam uma alta não estacionariedade. Em seguida, dá-se início à apresentação e abordagem dos métodos de extração que serão utilizados no trabalho. Primeiramente, com a análise espectral e o uso do método de Welch para a estimação da densidade espectral de potência. O capítulo prossegue com a apresentação do método da codificação linear preditiva, no qual serão estimados os coeficientes

pelo método de Yule-Walker. Dando continuidade, será destacado o método dos coeficientes cepstrais, mais especificamente os Coeficientes Mel-Cepstrais. Finalmente, será apresentada uma abordagem do uso direto da matriz de covariância como extrator de características.

No Capítulo 4, é apresentado o problema de classificação e os quatro algoritmos que serão utilizados. São descritos três classificadores com propostas aleatorizadas: ELM, RKS e MLM. E, para fins de comparação, será utilizado o classificador SVM.

No Capítulo 5 é apresentado o banco de dados que será utilizado e a forma como os arquivos são preparados para a tarefa proposta no trabalho. E também será mostrado como foram realizadas as montagens dos vetores de características de cada método proposto e suas configurações. Serão apresentadas as métricas de comparação entre os cenários propostos, como foi realizada a seleção dos hiperparâmetros e a seleção dos modelos dos classificadores. E, por fim, como será realizada a etapa de treinamento e teste.

Os resultados são apresentados no Capítulo 6. Nesse capítulo, teremos a análise quantitativa e qualitativa dos resultados obtidos. Finalizando, no trabalho no capítulo 7, são feitas as considerações finais e as perspectivas para trabalhos futuros.

Por fim, há os apêndices:

- Apêndice A - apresenta demais resultados dos experimentos realizados (diagramas de caixa da especificidade, sensibilidade, acurácia, coeficiente de correlação de Matthews e a área sob a curva ROC).
- Apêndice B - alguns padrões de ondas epileptiformes são apresentados.
- Apêndice C - apresenta o Classificador Linear do método dos mínimos quadrados ordinários (OLS, do inglês *ordinary least square*).

## 2 ELETROENCEFALOGRAMA E EPILEPSIA

O electroencefalograma (EEG) é um método não invasivo, econômico e acessível, universalmente utilizado na investigação da epilepsia. A análise do traçado do EEG permite observar uma série de padrões cíclicos, sob a forma de ondas. A comparação do traçado de um indivíduo com o padrão normal permite a detecção de diversas anomalias do funcionamento cerebral, dentre elas a Epilepsia. Nesse capítulo, serão abordados os princípios básicos do EEG, a Epilepsia e os desafios em diagnóstica-la.

### 2.1 Eletroencefalograma - EEG

#### 2.1.1 *Princípios básicos de neurofisiologia*


O sistema nervoso central (SNC) é constituído, sumariamente, de dois tipos de células: nervosas e neurogliais. As células da glia, apesar de não apresentarem a função do tratamento da informação, são responsáveis pelo suporte e nutrição dos neurônios. Os neurônios são constituídos por quatro regiões: os dendritos, o corpo celular ou soma, o axônio e os seus terminais pré-sinápticos. No corpo celular é onde ocorrem todos os processos metabólicos da célula.

Na Figura 6, é apresentada a estrutura básica de um neurônio. Os dendritos são extensões da membrana exterior do neurônio, e são eles que recebem sinais elétricos provenientes de outros neurônios. Estes sinais são transmitidos através do axônio. Normalmente o axônio localiza-se do lado oposto à maioria dos dendritos e é responsável pela condução da informação até outros neurônios e músculos. Muitos destes axônios são revestidos por uma camada de mielina que é interrompida pelo nós de Ranvier. O isolamento permite uma maior rapidez na distribuição da informação. Na extremidade terminal de cada axônio encontra-se a fenda sináptica. É neste local que se estabelece a comunicação entre dois neurônios, através do contacto direto entre as membranas de ambos (sinapse elétrica) ou, mais comumente, mediada por neurotransmissores (sinapse química) (SCHOMER, 2010).

O corpo humano é constituído de um ambiente aquoso onde existem cátions e ânions, que diluídos se movem conforme o tipo predominante de carga elétrica no meio ao redor. As células do SNC, em repouso, apresentam uma diferença de potencial em relação a membrana com polaridade negativa. Este potencial é denominado de potencial de repouso de membrana,



Figura 6 – Estrutura do Neurônio.



Fonte: Schomer (2010).


e tem o valor típico de  $-70\text{ mV}$ , sendo mantido devido à diferença de íons nos meios intra e extracelulares.

Há um excesso de íons de Potássio ( $K^+$ ) no meio intracelular e um excesso de íons de Sódio ( $Na^+$ ) no meio extracelular, o que ocasiona uma difusão de  $K^+$  do meio intracelular para o meio extracelular. No estado de repouso a membrana celular é mais permeável aos íons de  $K^+$  do que aos de  $Na^+$ . A presença dos canais de  $Na^+$  abertos na membrana celular, ainda que em menor número do que os de  $K^+$ , alguns destes íons irão para o meio intracelular, impedindo que o potencial de equilíbrio de íons de  $K^+$  seja atingido, o que ocasionada um leve decaimento no valor absoluto da diferença de potencial. Com a contínua movimentação de íons através ocorre o aumento do potencial da célula. Desta forma, através do transporte de íons  $K^+$  para o interior da célula e  $Na^+$  para o exterior, a diferença de potencial é mantida. Tipo de transporte ativo denominado bomba de sódio/potássio.

O potencial de ação ocorre quando a célula, que se encontra em repouso, atingir um determinado limiar, de cerca de  $-55\text{ mV}$ . Após esse limiar ser atingido a célula despolariza e

passa a apresentar uma polaridade de 40 mV, fenômeno relacionado com um rápido aumento da permeabilidade da membrana pelos íons de  $Na^+$  que provoca um rápido aumento do seu potencial. Um aumento da permeabilidade da membrana aos íons  $K^+$  a redução para os  $Na^+$  ocasiona a repolarização da membrana, que irá novamente apresentar uma polaridade negativa em relação ao meio circundante. Ocorre uma hiperpolarização devido os canais de  $Na^+$  serem mais rápidos a fechar do que os de  $K^+$ , sendo atingido o potencial de repouso e criando o potencial de ação. Na Figura 7 são apresentadas as etapas para a ocorrência de um potencial de ação, que pode variar entre 1 e 10 ms.

Figura 7 – Potencial de ação. (1) Repouso; (2) Despolarização devido à entrada de íons de  $Na^+$ ; (3) Repolarização devido a entrada de íons  $K^+$ ; (4) Hiperpolarização devido ao fechamento dos canais de  $K^+$ .




Fonte: Bear Barry W. Connors (2006).

Os neurônios localizados no córtex cerebral estão agrupados e interagem uns com os outros através de sinapses, estimulando ou inibindo os neurônios vizinhos. O somatório desses potenciais excitatórios pós-sinápticos (PEPS) e dos potenciais inibitórios pós-sinápticos (PIPS) produzidos pelos neurônios piramidais corticais resulta na formação da atividade elétrica

cerebral (SCHOMER, 2010).

Figura 8 – A geração de campos elétricos muito pequenos por correntes sinápticas em células piramidais.



Fonte: Bear Barry W. Connors (2006).

Quando um PEPS chega na árvore dendrítica apical há uma rápida entrada do íon sódio ( $Na^+$ ) para o interior da célula. Assim, o meio extracelular tornará mais negativo em comparação com o meio intracelular. Esse desequilíbrio de cargas resulta em um fluxo de corrente da fonte (corpo neuronal) ao sorvedouro (dendritos apicais), formando um dipolo (o potencial negativo na superfície do córtex cerebral). O diferencial de tensão pode ser captado como uma deflexão negativa ocasionada por um eletrodo no escalpo que se encontra sobre esse campo elétrico, conforme apresentado na Figura 8. O registro gráfico do sinal elétrico desses potenciais relacionados com a atividade elétrica do cérebro é o que denomina-se de Eletroencefalograma (EEG).


### 2.1.2 Aspectos Técnicos do EEG

O EEG tem como finalidade obter o registro da atividade elétrica cerebral para o diagnóstico de eventuais anormalidades dessa atividade. Segundo Schomer (2010), seu uso é indicado em:

- suspeitas de alterações da atividade elétrica cerebral e dos ritmos cerebrais fisiológicos;
- diagnóstico diferencial entre eventos epilépticos e não epilépticos (síncope, arritmias cardíacas, distúrbios do sono e distúrbios psiquiátricos, entre outros);
- classificação de síndromes e crises epilépticas (por exemplo: parcial, generalizada; tônica, atônica, mioclônica, espasmos, tônica-clônica) e suas frequências;
- determinação da zona epileptogênica na investigação pré-cirúrgica para epilepsia;
- avaliações dos casos de epilepsia refratária ao tratamento medicamentoso, e;
- pacientes com alteração da consciência e avaliação diagnóstica de pacientes com outras doenças neurológicas (ex: infecciosas, degenerativas) e psiquiátricas.

Hans Berger, o descobridor do EEG humano, era um neuropsiquiatra que em registrou a atividade cerebral humana em seu primeiro relatório de 1929, como mostra a Figura 9. Na linha superior, é apresentada a gravação da atividade cerebral do jovem filho de Berger, e na linha inferior, uma onda senoidal de 10 Hz para marcação do tempo. Para a aquisição do sinal elétrico na época, Berger utilizou do galvanômetro de bobina dupla com a maior sensibilidade da época, 130  $\mu\text{V}/\text{cm}$  (BEAR BARRY W. CONNORS, 2006).

Figura 9 – Primeiro EEG de um ser humano.



Fonte: Bear Barry W. Connors (2006).

Atualmente, o EEG é através de sistemas computacionais, substituindo o procedimento analógico que antes era gravado com oscilógrafos, com inscrições à tinta, traçando o sinal obtido no papel. Porém, o papel da eletroencefalografia clínica tem diminuído ao longo dos últimos 30 anos, exceto pela Epileptologia<sup>1</sup>, que vem utilizando o EEG conjuntamente com o monitoramento de vídeo para a avaliação de diagnóstico (SCHOMER, 2010).

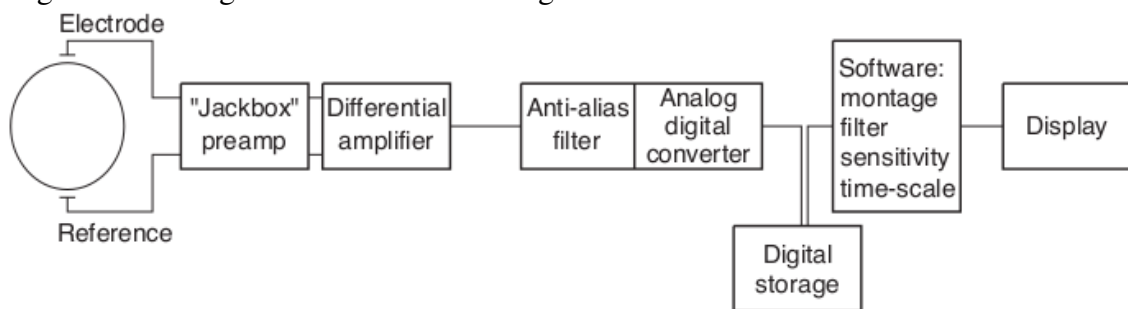
Basicamente, o EEG Digital, representado esquematicamente Figura 10, é composto

<sup>1</sup> Ramo da Medicina que estuda a epilepsia.

por uma parte analógica (eletrodos, *jackbox*, circuito amplificador e cabos) responsável para captação e amplificação dos sinais elétricos presentes no escalpo. O estágio de conversão do sinal analógico para representação digital é o passo mais crucial no processo de aquisição. O processo de digitalização divide o sinal EEG em dois eixos independentes: tempo e magnitude. Normalmente, um sinal temporal é digitalizado em intervalos discretos de tamanhos constantes, denominado por taxa de amostragem.

A escolha da taxa de amostragem impacta diretamente no quanto os dados obtidos e digitalizados refletem a fonte analógica, e essa escolha é limitada pelo nível de detalhamento desejado no sinal digitalizado, componentes utilizados e principalmente pelo o teorema de amostragem de Nyquist<sup>2</sup>. Portanto, é preciso remover essas frequências antes de passar por um conversor analógico-digital. Para isso, pode-se usar um filtro *anti-aliasing* passa-baixas antes do sinal ser digitalizado.

Figura 10 – Diagrama básico do EEG Digital.



Fonte: Schomer (2010).

O filtro *anti-aliasing* atenua as frequências acima da frequência de Nyquist, caso contrário o ruído de alta frequência será digitalizado juntamente com o o sinal. Porém, caso o corte for extremamente baixo, então os sinais com frequências acima deste limite e abaixo do Nyquist serão desnecessariamente atenuados e perdidos.


A digitalização também ocorre ao longo do eixo de magnitude. No conversor analógico digital (A/D) é necessário definir a escolha de alguns parâmetros: valor máximo (ou faixa dinâmica), diferença mínima identificável, profundidade de digitalização. Com um digitalizador linear de 12 bits ( $2^{12} = 4096$  níveis diferentes), por exemplo, pode-se representar magnitudes de até 1 mV. Para sinais de amplitude (por exemplo, registros de inatividade cerebral, em caso laudo de morte encefálica) a digitalização ser capaz de resolver o EEG em  $0,5\mu\text{V}$ . Uma resolução de pelo menos 12 bits é recomendada pela *International Federation of Clinical*

<sup>2</sup> Teorema de amostragem, afirma que a frequência mais alta distinguível é metade da frequência de amostragem.

*Neurophysiology* (IFCN) (NUWER *et al.*, 1999), e uma resolução digital maior é opcional.

O efeito prático da profundidade de digitalização de 4, 6 e 8 bits é apresentado na Figura 11 com um sinal senoidal. Note que para 4 bits, observa-se uma discretização do sinal razoavelmente perceptível; já para de 6 bits o passo digital é mais aparente apenas no pico e no vale, onde para cada intervalo de tempo a variação de tensão é pequena, mas estas mudanças são menores do que o menor passo discreto e não podem ser representadas.

Figura 11 – Discretização de acordo com o número de bits.



Fonte: Schomer (2010).

Deve-se salientar que tanto a taxa de amostragem quanto a resolução têm um impacto no tamanho do arquivo digital a ser gerado e armazenado em disco. Como exemplo, seja um EEG com 32 canais digitalizados com 16 bits (2 bytes) e uma taxa de amostragem de 400 Hz durante 1 hora, irá gerar  $(32 \times 2 \times 400 \times 3600) = 92,160,000$  bytes = 87,89 MB. Um EEG prolongado de 24 horas nessas configurações geraria cerca de aproximadamente 2 Gigabytes.

Após a digitalização dos dados, o mesmo pode ser visualizado em tempo real ou armazenado em um banco de dados. Há uma gama de dispositivos e softwares de vídeo-EEG, exemplo na Figura 13, que fazem parte integrante em diagnósticos de neurofisiologia. Esses sistemas de aquisição salvam os dados em discos rígidos e servidores que podem ser acessados remotamente, e garantem ao utilizador (médicos e especialistas) todas as atividades de aquisição,

revisão, análise, relatório e arquivo de exames possam ser geridos.

Figura 12 – Sala de Monitoramento e Equipamento de Vídeo EEG.



Fonte: o autor.

O monitoramento de vídeo-EEG de paciente internado é realizado em uma unidade de monitoramento de epilepsia fixa, e consiste em uma rede que usa câmeras fixas ou móveis. O sinal de vídeo é digitalizado e sincronizado, e tanto o EEG quanto os sinais de vídeo são exibidos simultaneamente para observação *online*. Segundo Benbadis *et al.* (2009), o vídeo-EEG é o critério padrão para o diagnóstico de convulsões ou ataques não-epilépticos. O uso do vídeo sincronizado auxilia a junta de especialistas a verificar a correlação entre o comportamento clínico do paciente, registrado em vídeo, e a sua atividade cerebral. O monitoramento de vídeo por EEG tornou-se disponível na maioria dos grandes centros de referência, e mais recentemente, em muitos hospitais menores e em nível ambulatorial. Como regra geral, o monitoramento prolongado de vídeo com EEG deve ser obtido em qualquer paciente que continue a apresentar convulsões frequentes, com ou sem a presença de medicamentos antiepilépticos.

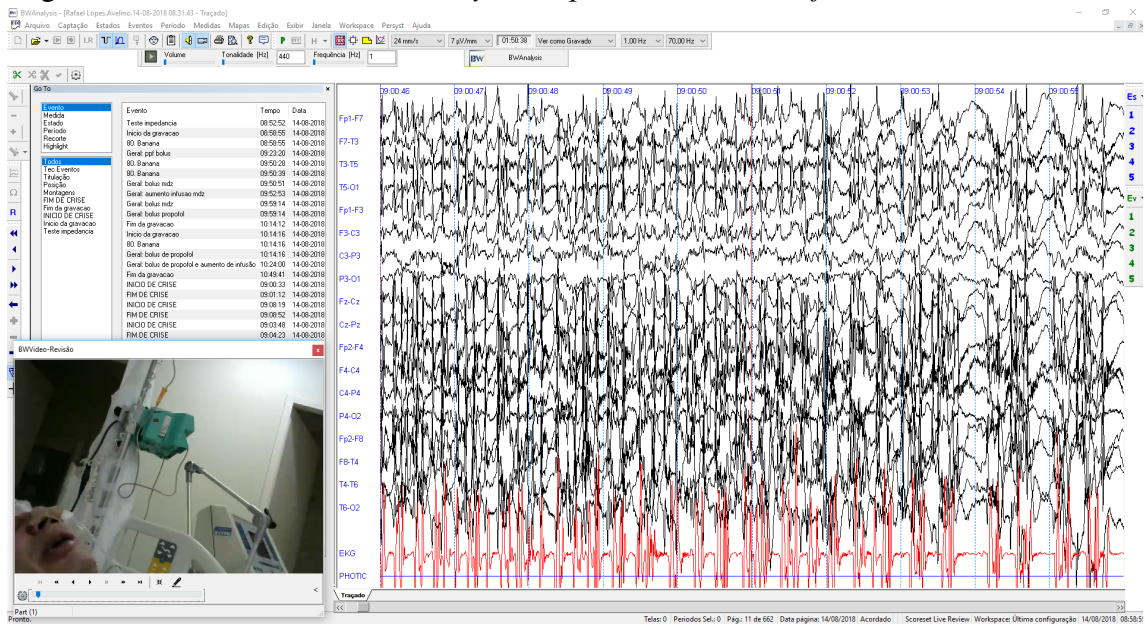
No exemplo do software BW Analysis<sup>3</sup>, apresentado na Figura 13, o exame realizado pode ser revisado por página (geralmente 10 segundos) ou em um modo contínuo de rolagem. Normalmente, o operador usa o modo de rolagem durante a aquisição ou ao revisar vídeo e EEG simultâneos. Já o modo de página é usado durante a revisão. Somente as características superficiais do EEG podem ser determinadas com esta velocidade de paginação rápida, mas pode ser útil para triagem de convulsões ou determinação dos estados de sono. As anormalidades no EEG ou comentários são adicionados na borda da página.

Há uma série de diretrizes e normas para a realização do EEG. Neste trabalho, serão abordadas algumas que são de suma importância no contexto da instrumentação (posicionamento

<sup>3</sup> Software disponibilizado pela Neurovirtual-MF Equipamentos Médicos



Figura 13 – *Neurovirtual's BWAnalysis Acquisition/Review Software.*



Fonte: o autor.

dos eletrodos e montagens), conceito de polaridade e artefatos.


A Comissão da Federação Internacional da Sociedade de Eletroencefalografia e Neurofisiologia Clínica, em 1958 (ACHARYA *et al.*, 2016), recomenda um sistema único para a colocação dos eletrodos para a obtenção dos sinais do EEG, conhecido como sistema internacional 10-20. Cujo o intuito é a uniformização da obtenção dos registros. O uso de medidas minimiza os erros de interpretação por má colocação dos eletrodos e o fato de que as medidas não são fixas permite seu uso em perímetros cefálicos de diferentes.

Esse padrão é denominado de sistema 10-20 porque todos os eletrodos são colocados a distâncias compreendidas entre 10% e 20% das referências utilizadas no crânio, conforme é apresentado na Figura 14. A posição de cada eletrodo sobre o escalpo é designada por uma letra e por um número estabelecido. Letras correspondem aos nomes dos lobos cerebrais subjacentes, exceto da região central, que representa a área nas proximidades do sulco central (ponto anatômico central no crânio), e da região frontopolar, que se refere à porção anterior do lobo frontal. Os números pares correspondem ao hemisfério direito e os ímpares ao esquerdo, sendo aumentada sua numeração nas direções anteroposterior e médio-lateral, conforme é apresentado na Tabela 3.

Outro conceito deveras importante é a polaridade dos grafoelementos dos EEG. O traçado do EEG é uma representação gráfica da diferença entre dois eletrodos ao longo de um determinado período de tempo. Esses eletrodos denominam-se G1 e G2. Por convenção, se a entrada G1 for mais negativa que a entrada G2, o sinal de saída irá deflexionar para cima,



Figura 14 – Sistema 10-20.



Fonte: Blume *et al.* (2010).

Tabela 3 – Nomenclatura sistema 10-20

Localização	Esquerdos	Diretos	Linha Central
Frontopolar	Fp1	Fp2	-
Frontal	F3	F4	-
Temporal Anterior	F7	F8	-
Temporal Médio	T3	T4	-
Central	C3	C4	-
Parietal	P3	P4	-
Temporal	T5	T6	-
Occipital	O1	O2	-
Auriculares	A1	A2	-
Frontal	-	-	Fz
Central	-	-	Cz
Parietal	-	-	Pz

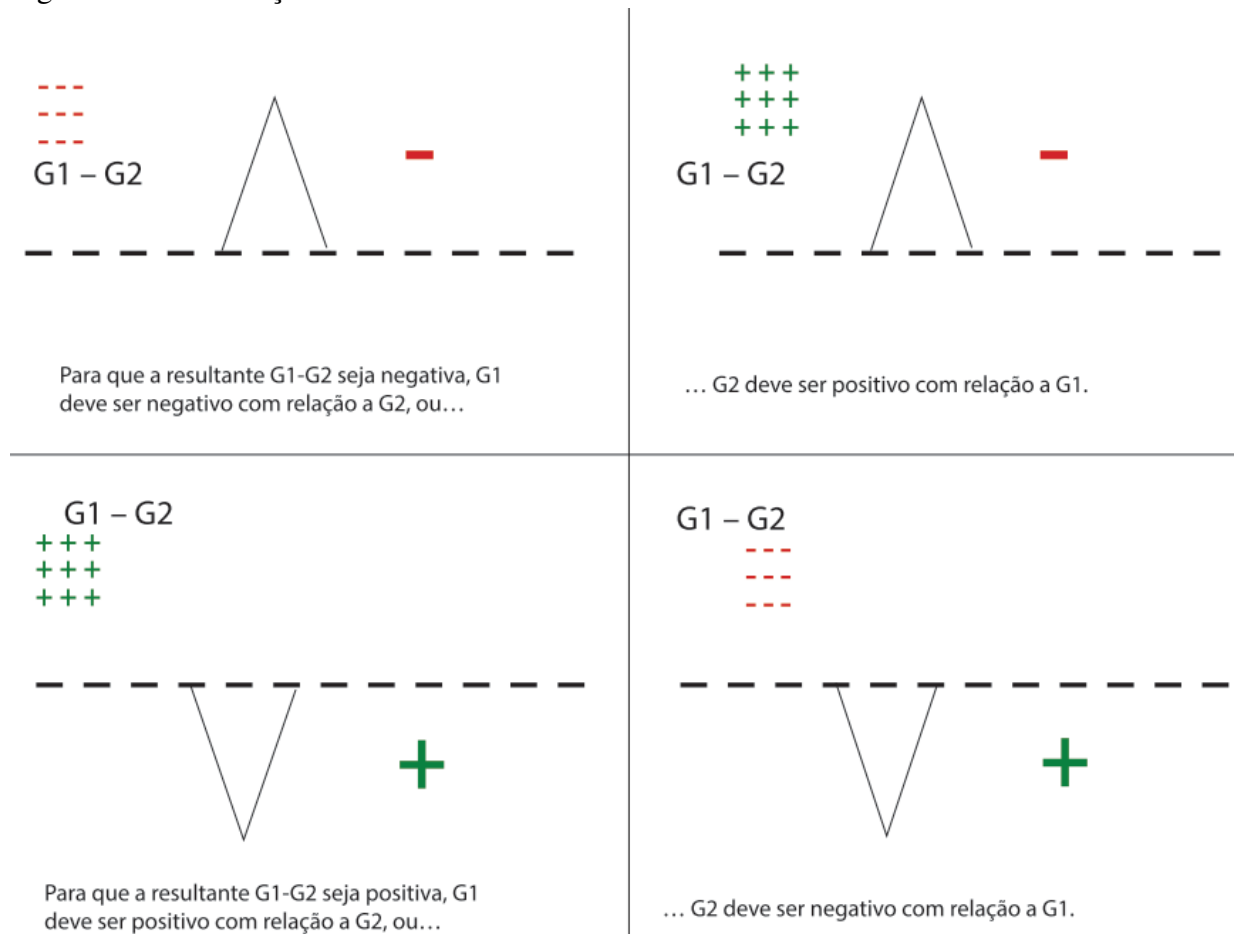
Fonte: o autor.

enquanto se a entrada G1 for mais positiva que a entrada G2, o sinal de saída será defletido para baixo. Na Figura 15, é apresentada a convenção internacional para a interpretação dos grafoelementos do EEG.

Na maioria dos casos, a atividade elétrica cerebral anormal tem polaridade negativa, que, no traçado do EEG, se apresenta de acordo com a convenção internacional como uma deflexão negativa. Isto é, a deflexão negativa é representada como um grafoelemento para cima, enquanto a polaridade positiva está representada com uma deflexão positiva (para baixo). Segundo Schomer (2010) a razão pela qual a maioria da atividade elétrica anormal do cérebro se apresenta com uma deflexão negativa é que a soma dos potenciais excitatórios pós-sinápticos e potenciais inibitórios pós-sinápticos comumente é apresenta carga negativa.

O modo em que os pares de eletrodos do sistema 10-20 se combinam denomina-se

Figura 15 – Convenção dos Grafoelementos do EEG.



Fonte: Schomer (2010).

derivação, por exemplo, Fp1-F7. O conjunto de derivações é chamado de montagem. Há dois tipos básicos de montagens, chamadas bipolares e referenciais. No EEG digital, a escolha das montagens poderá ser feita após a aquisição por parte do médico ao analisar o traçado. Como os dados digitais do EEG são adquiridos usando uma montagem referencial com fio (entrada 2 para todos os canais é a referência da máquina, ou REF), o computador pode executar cálculos nos dados armazenados para criar qualquer montagem desejada, quase instantaneamente. Por exemplo, transformar a montagem referencial em uma montagem bipolar requer os cálculos apresentados na Tabela 4.

Tabela 4 – Tipos de Montagem.


Canal	Montagem Referencial	Cálculo	Montagem Bipolar
1	Fp1-REF	Fp1-REF-(F7-REF)	Fp1-F7
2	F7-REF	F7-REF-(T3-REF)	F7-T3
3	T3-REF	T3-REF-(T5-REF)	T3-T5
4	T5-REF	T5-REF-(O1-REF)	T5-O1

Fonte: o autor.

No procedimento de gravação do EEG, há diversas fontes de ruídos que podem ser captados juntamente com o potencial elétrico do cérebro. Esse ruídos, denominados artefatos, são definidos como todo potencial elétrico proveniente de outra fonte que não seja o cérebro. Normalmente o EEG apresenta artefatos, que podem ser causados pela instrumentação, eletrodos, fisiológicos ou biológicos, respiratórios entre outros. Os artefatos podem alterar substancialmente os resultados, por exemplo, da análise espectral. O melhor método para evitarmos os artefatos no EEG quantitativo e topográfico é identificando-os durante a análise visual do traçado.

Os artefatos não fisiológicos comumente registrados são: a frequência fundamental da rede elétrica 60 Hz, artefatos de movimento, gotejamento venoso, radiação de alta frequência e ruído interno do aparelho. Os artefatos fisiológicos se dividem em: artefato muscular e de pulso, ECG (eletrocardiograma), movimento ocular, movimentos da língua, respiração, tremor e potenciais da pele.

Figura 16 – Exemplos de artefatos presentes em uma EEG. (a) Artefacto ocular: piscar os olhos; (b) Artefato ocular: movimento horizontal do globo ocular; (c) Artefato muscular; (d) Artefato devido ao movimento de um eletrodo.



Fonte: Adaptado de Tong (2009).


A presença de ruídos e artefatos pode ser minimizada, durante a realização do exame, seguindo algumas diretrizes com o intuito de facilitar a identificação destas anomalias e assim permitir uma análise de forma correta. O EEG deve ser realizado num ambiente controlado e

por um técnico qualificado que consiga obter um registro que seja o mais limpo possível. Além disso, durante a aquisição, é importante que o técnico esteja atento aos movimentos do paciente, anotando qualquer informação que ache relevante.

### 2.1.3 Ritmos Cerebrais

Os ritmos cerebrais no EEG variam drasticamente entre pessoas, idades ou estados. Frequentemente, são correlacionados com estados particulares de comportamento, como nível de atenção, sono ou vigília ou associados a patologias. Os principais ritmos do EEG são categorizados por sua faixa de frequência: *alpha* ( $\alpha$ ), *beta* ( $\beta$ ), *delta* ( $\delta$ ) e *theta* ( $\theta$ ) (SANEI; CHAMBERS, 2007).

Figura 17 – Ritmos Cerebrais.



Fonte: Malmivuo *et al.* (1995).

- *delta* ( $\delta$ ) - as ondas *delta* são compostas pelas frequências mais baixas no cérebro, especificamente de 0,5-4 Hz. Normalmente ocorrem no estado de sono profundo e em alguns processos anormais patológicos. Essas ondas são o ritmo dominante em crianças até um ano de idade. A banda delta tende a ser a mais alta em amplitude e também a mais lenta das ondas.
- *theta* ( $\theta$ ) - a atividade *theta* é classificada como ondas rítmicas lentas na faixa de frequência de 4-8 Hz. A presença dessas ondas reflete o estado entre a vigília e o sono. As ondas *theta* são anormais em adultos acordados, mas são perfeitamente normais em crianças de

até 13 anos e durante o sono. Também são observadas durante a ansiedade, dor, ativação comportamental e inibição comportamental. A aparência do excesso desse ritmo é um indicador de anormalidades no cérebro.

- *alpha* ( $\alpha$ ) - As ondas *alpha* são compostas de sinais cerebrais da faixa de frequência 8-13 Hz. Ondas *alpha* saudáveis promovem a desenvoltura mental, ajudam na capacidade de coordenar mentalmente e aumentam a sensação geral de relaxamento e fadiga. Está presente durante a maior parte da vida de um indivíduo quando domina o traçado de repouso (traçados normais de EEG). A mais importante das ondas registradas em um EEG adulto normal são as ondas *alpha* occipitais. A interferência nesta banda pode ser causada pela abertura dos olhos ou excitação.
- *beta* ( $\beta$ ) - as ondas *beta* são consideradas atividade cerebral rápida por se encontrarem na faixa de 13-30 Hz. Essas ondas são normalmente encontradas nos dois lados do cérebro simetricamente e são mais evidentes na região frontal. Em regiões com dado cortical eles podem estar ausentes ou ter um amplitude reduzida. Ritmo normal em períodos de alertas, ansiosos ou com os olhos abertos. Cerca de 80% tempo de funcionamento cérebro é no ritmo *beta*.

Os ritmos gama variando de cerca de 30 a 90 Hz e sinalizam um córtex ativado ou atento. Já os denominados ritmos *mu* são semelhantes em frequência aos ritmos *alpha*, mas são maiores em relação às áreas motoras e somatossensoriais. Os ritmos adicionais incluem fusos, breves ondas de 8 a 14 Hz associadas ao sono e ondulações, breves episódios de oscilações de 80 a 200 Hz.

## 2.2 Epilepsia

Houve, e ainda há, uma confusão sobre as terminologias em relação a esse distúrbio neurológico, pois normalmente são confundidas as definições de crises epiléticas, convulsão e Epilepsia. A crise epilética é definida como a ocorrência transitória de sinais e/ou sintomas decorrentes de atividade neuronal síncrona ou excessiva no cérebro. Esses sinais ou sintomas incluem fenômenos anormais súbitos e transitórios, como alterações da consciência, ou eventos motores, sensitivos/sensoriais, autonômicos ou psíquicos involuntários percebidos pelo paciente ou por um observador (THURMAN *et al.*, 2011). Todas as pessoas com Epilepsia têm ou tiveram recentemente crises epiléticas, mas nem todos aqueles que têm uma crise epilética serão diagnosticados com Epilepsia.

A convulsão é um sintoma que pode ser ocasionado em um crise epilética, porém pode ser causada por outros fatores como: febre alta em crianças com menos de 5 anos, doenças como meningites, encefalites, tétano, tumores cerebrais, infecção pelo vírus da HIV, epilepsia, traumas cranianos, abstinência após uso prolongado de álcool e de outras drogas, efeito colateral de alguns medicamentos, distúrbios metabólicos (como hipoglicemia, diabetes, insuficiência renal) e falta de oxigenação no cérebro entre outras causas.

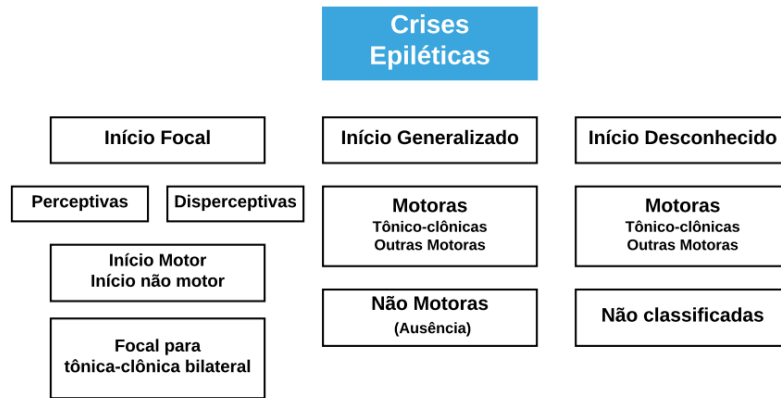
Fisher *et al.* (2005) e seu grupo de trabalho da ILAE (*International League Against Epilepsy*) propuseram uma definição conceitual da Epilepsia como um distúrbio cerebral caracterizado pela predisposição persistente do cérebro para gerar crises epiléticas. Portanto, o diagnóstico de Epilepsia requer a ocorrência de pelo menos uma crise epilética desde que seja demonstrada uma condição que predisponha o cérebro a gerar crises, como uma anormalidade eletroencefalográfica ou uma lesão cerebral às quais a ocorrência da crise possa ser atribuída. Em 2014, o mesmo grupo propôs uma definição operacional de epilepsia como uma doença do cérebro caracterizada por uma das seguintes condições:

- Pelo menos duas crises não provocadas (ou duas crises reflexas) ocorrendo em um intervalo superior a 24 horas;
- Uma crise não provocada (ou uma crise reflexa) e chance de ocorrência de uma nova crise estimada em pelo menos 60%, e;
- Diagnóstico de uma síndrome epilética;

Há diversos tipos de crises epiléticas. Em Fisher *et al.* (2017) a ILAE propõe um esquema de classificação no qual resumidamente se diferencia o tipo de início da crise (focal, generalizada ou desconhecida), motoras (espasmo epilético, tônico-clônicas entre outras) e não motoras (ausência, parada comportamental etc), um esquema simplificado é apresentado na Figura 18.

As crises focais parciais (focais ou locais) são aquelas que são originadas em uma rede neuronal limitada a um hemisfério, podendo ser muito localizadas ou mais amplamente distribuídas. Crises focais podem se originar em estruturas subcorticais. Em alguns casos, há mais de uma rede epileptogênica e mais de um tipo de crise, mas cada tipo individual tem o mesmo local de origem (BERG *et al.*, 2010). Crises parciais são subdivididas em crises parciais simples, quando há preservação da consciência (perceptivas), e crises parciais complexas, nas quais a consciência é comprometida (disperceptivas). Ambas podem evoluir para crises secundariamente generalizadas e apresentar ou não caráter motor (automatismos, atônicas, clônicas, espasmos

Figura 18 – Esquema simplificado da classificação dos tipos de crises.



Fonte: Adaptado de Fisher *et al.* (2017).

epiléticos, hipercinéticas, mioclônicas ou tônicas).

Segundo Berg *et al.* (2010), as crises epiléticas generalizadas se originam em algum ponto e rapidamente envolvem redes neuronais distribuídas de forma bilateral. Essas redes bilaterais podem incluir estruturas corticais e subcorticais, mas não necessariamente todo o córtex. Embora o início das crises individualmente possa parecer localizado, a localização e a lateralização não se mantêm de uma crise a outra.

### 2.2.1 Estágios de uma crise epilética

A natureza da crise epilética apresenta a transição de eventos considerados anormais. Neste trabalho, os diferentes estágios de uma crise epilética são referidos como estados ictais, interictais, pré-ictais e pós-ictais. Esses estados representam os diferentes estágios de uma crise epilética em seu sentido mais geral. Uma breve descrição desses estados e suas transições é feita a seguir.

**Estado Interictal** - refere-se ao estado de repouso normal que não contém atividade convulsiva, mas o EEG ainda é caracterizado pela condição epilética (atividade neuronal irregular) dada a possibilidade de convulsões. Não há certeza de quais fatores ou mecanismos tentam manter a homeostase<sup>4</sup> no cérebro, e também não tem certeza se esses mecanismos diferem para vários tipos de convulsões e síndromes epiléticas. Este período compreende mais de 99% da vida dos pacientes. Desta forma, o período interictal pode ser usado por neurologistas para diagnosticar uma condição epilética. Os traçados do EEG normalmente exibem pequenos picos e outras anormalidades conhecidas pelos neurologistas como convulsões subclínicas. Estas não são convulsões reais, mas sim pequenas indicações do

<sup>4</sup> Condição de relativa estabilidade da qual o organismo necessita para realizar suas funções adequadamente.

cérebro de que algo é anormal.

**Estado Ictal** - período de tempo durante o qual a crise epilética está em seu período de ativação. É caracterizada por um traçado de EEG que exhibe amplitudes e frequências significativamente maiores e há uma alteração imediata na sincronização e na ritmicidade que ocorre em áreas disseminadas do córtex cerebral. Os padrões normalmente vistos ao longo do traçado de repouso tornam-se repentinamente extremamente erráticos e imprevisíveis. Perda de consciência e espasmos musculares involuntários durante esse período são muito comuns. Outros sintomas também são comuns durante esse estado e normalmente o paciente não tem controle sobre o movimento do seu corpo e as convulsões tendem a ser proeminentes.

**Estado Pré-ictal e Pós-ictal** - O estado pré-ictal refere-se a um período de tempo que ocorre antes de uma convulsão, mas não se refere ao estado normal do cérebro. Este estado define que uma convulsão ocorrerá dentro de um certo período de tempo. A presença de um período pré-ictal vem sendo amplamente estudada por diversos pesquisadores. O estado pós-ictal representa o fim de uma crise epilética com uma transição do estado ictal para o estado normal ou interictal de um indivíduo. Isto é referido como o estado pós-ictal e significa o período de recuperação do cérebro. O déficit neurológico focal ou generalizado, que varia desde a depressão pós-ictal à afasia ou paralisia, é prevalente durante este estado. Esse período está associado a uma dificuldade de pensar claramente e a uma variedade de outros defeitos cognitivos.

No exemplo, Figura 19, é apresentada uma crise epilética generalizada do paciente *CHB10* (GOLDBERGER *et al.*, 2000). A epilepsia dura cerca de 35 segundos e pode-se verificar os instantes antes (pré-ictal) e depois (pós-ictal) com nitidez.


### 2.2.2 *Atividade epileptiforme*

O foco deste trabalho é nas atividades anormais do EEG associadas com as crises epiléticas. Os neurologistas buscam identificar as anormalidades no EEG a partir dos padrões dos grafoelementos. Na literatura, há dois termos para se referir a estes grafoelementos: espículas e ondas agudas. Em resumo, apresentado na Figura 20, a combinação dessas formas de onda compõem as principais manifestações anormais em um EEG:

- Espícula: é um grafoelemento de formato pontiagudo de carga negativa, claramente destacado da atividade de base, que compromete dois ou mais eletrodos. Usualmente, sua



Figura 19 – Exemplo dos estados ictal, pré e pós-ictal. Referente a uma das crises epiléticas do paciente CHB10.



Fonte: do autor.

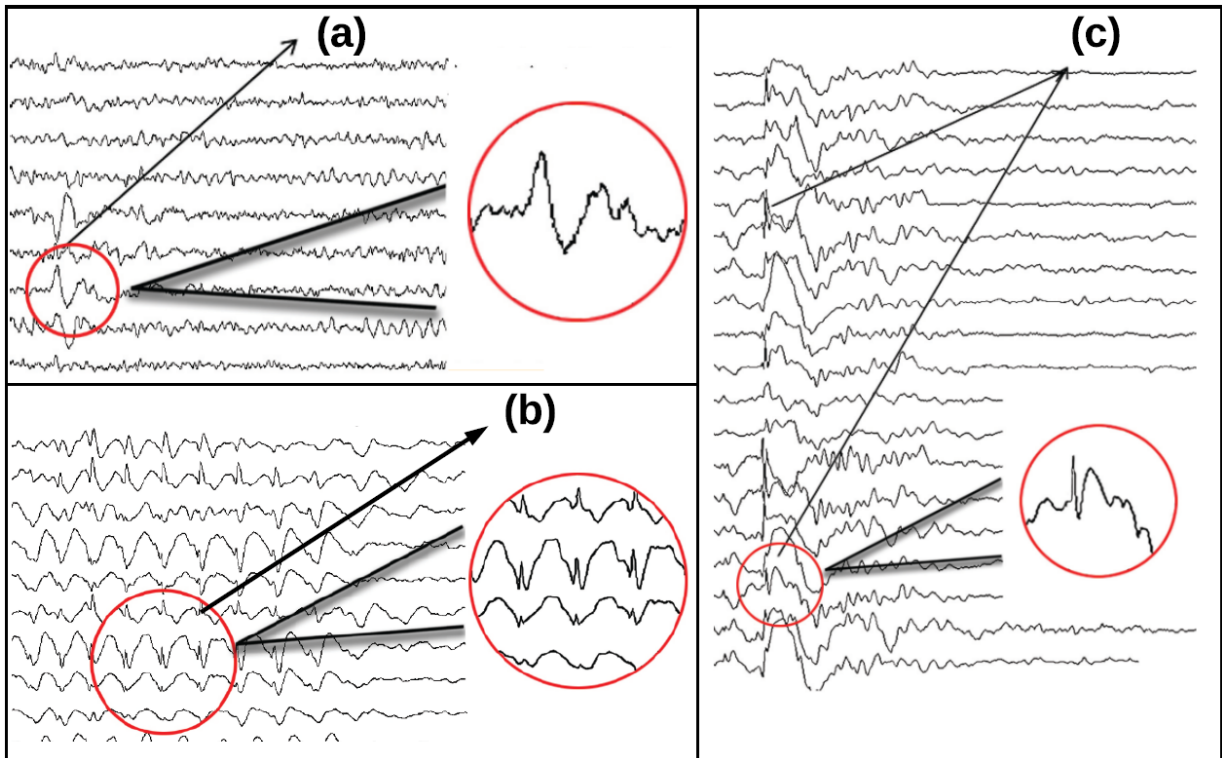
ascensão e queda são igualmente pronunciadas. Pode ser seguida de uma onda lenta e sua forma é relativamente simétrica. Sua duração é cerca de 70ms.

- Complexo de espícula-onda: este complexo é formado por dois componentes, uma espícula e uma onda que a acompanha, ambas negativas, comprometendo dois ou mais eletrodos.
- Onda aguda: trata-se de um grafoelemento de formato pontiagudo de carga negativa, claramente destacado da atividade de base, que compromete dois ou mais eletrodos. Usualmente, a ascensão é rápida e a queda é mais inclinada, sendo seguida de uma onda lenta, e sua amplitude é variável. A duração é de 70 a 200 ms.
- Poliespícula: refere-se à presença de duas ou mais espículas que podem ser ou não seguidas de onda lenta, sendo, neste caso, denominado complexo de poliespícula-onda.

Identificar os grafoelementos associados com a atividade epileptiforme no EEG é apenas parte da tarefa para um diagnóstico mais preciso da Epilepsia. Em Blume *et al.* (2010), o autor apresenta diversos padrões de EEG associados com atividades epileptiformes focais ou generalizadas. Fenômenos focais e/ou difusos de EEG periodicamente repetitivos, relativamente estereotipados, representam processos fisiologicamente agudos ou subagudos em crianças e adultos. Tais fenômenos podem ser espículas, poliespículas ou ondas delta. Sua localização e distribuição dependem, em grande parte, da lesão estrutural subjacente. A seguir, serão apresentados alguns padrões focais tais como: espículas rolândicas, temporais, occipitais e múltiplos pontos de foco independentes.

As espículas rolândicas (Figura 60, apresentada no Apêndice B) são descargas

Figura 20 – Grafoelementos associados com atividade epileptiforme: (a) descarga de onda aguda; (b) paroxismo generalizado de espícula-onda lenta; (c) espículas generalizadas.



Fonte: do autor.

caracteristicamente estereotipadas, abundantes e de alta voltagem com três fases claramente definidas e ondas lentas de destaque proeminentes que aparecem isoladamente ou em grupos na região central (canais C3 ou C4) usando o sistema 10-20. Geralmente, há uma deflexão acentuada para baixo da fase principal do pico nas derivações F3-C3 ou F4-C4, sugerindo um dipolo envolvendo essas derivações. As espículas rolândicas correspondem de 15 a 25% de todas as epilepsias na infância antes do 15 anos de idade, caracterizada por crises parciais ou generalizadas, que ocorrem normalmente durante o sono ou durante o despertar.

Outro padrão bastante conhecido e associado com crises epiléticas é o de espículas temporais (Figura 63, apresentada no Apêndice B). Esse padrão é observado principalmente em adolescentes e adultos, mas também podem surgir em crianças após os 6 anos de idade e são normalmente localizados no canais F7-8, T3-4 e A1-2. Os picos temporais podem estar associados a anormalidades de fundo focais, como a presença excessiva de ondas *delta* ou *tetha*. Os neurologistas devem distinguir as espículas temporais das espículas rolândicas, que também se estendem às derivações temporais, particularmente as regiões médio e posterior-temporal (T3,4 e T5,6). A importância dessa distinção reside em suas implicações clínicas marcadamente diferentes.

Distinguem-se também as espículas occipitais (Figura 62, apresentada no Apêndice B) de superfície negativa bem definidos aparecem unilateralmente ou bilateralmente de maneira síncrona ou independente. Comumente elas podem se propagar para as regiões parietais e póstero-temporais ipsilaterais. Picos occipitais são mais abundantes com os olhos fechados; a abertura dos olhos diminui ou abole sua aparência. Desta forma, eles podem ser distinguidos prontamente das ondas *lambda* ocasionalmente eletronegativas, que estão presentes somente quando um campo complexo está sendo escaneado. Pacientes com pontas occipitais durante a vigília podem desenvolver poliespículas posteriores durante o sono.

Múltiplos pontos de foco independentes, do inglês MISF (*Multiple Independent Spike Foci*), são picos que surgem em um foco em cada hemisfério. É razoável defini-lo como descargas epiléticas (pontas, ondas pontiagudas ou ambas) que surgem de pelo menos três posições de eletrodo não contíguo com pelo menos um foco em cada hemisfério (YAMATOIGI; OHTAHARA, 2006).

As descargas de picos de ondas generalizadas (2,5-3,5 Hz) no EEG representam a marca registrada do EEG nas crises generalizadas e nas epilepsias. Nas epilepsias generalizadas idiopáticas, os complexos de onda e espícula ocorrem sobre um fundo de EEG normal, e a frequência dos complexos está acima de 2,5 Hz na vigília (no sono, as descargas de espículas e ondas podem ser mais lentas, bem como mais irregulares) (BLUME *et al.*, 2010). Dentro de uma série de complexos de onda de pico, cada onda negativa de 200 a 500 ms é precedida por um vale positivo de 100 a 150 ms. Normalmente a amplitude da espícula aumenta e diminui durante a série onda-pico, mas geralmente é maior no seu início, apresentado na Figura 65 no Apêndice B.

Os surtos de ondas lentas (SSW-*Sharp Slow Waves*) consistem em um pico seguido por uma onda rítmica de cerca de 350 a 400 ms. Os surtos generalizados ocorrem em séries síncronas bilaterais prolongadas com uma taxa de repetição de 1 a 2 Hz. A morfologia, amplitude e taxa de repetição de SSWs podem variar moderadamente a cada crise. Esses surtos são geralmente distribuídos difusamente, mas podem ser expressos principalmente ou confinados nas regiões anterior ou posterior. Embora geralmente bilateralmente simétricas, podem ocorrer assimetrias transitórias e variáveis, conforme exemplo na Figura 66 no Apêndice B.

### **2.2.3 Desafio do Diagnóstico**

Segundo Teixeira (2007), algumas particularidades tornam o diagnóstico da Epilepsia especialmente difícil. Dentre elas podem-se citar:

1. raramente é possível surpreender ou reproduzir os sinais/sintomas em consulta sendo a avaliação clínica feita nos períodos interictais;
2. a anamnese e o exame físico geral e neurológico são frequentemente a base do diagnóstico, mas fornecem informações pouco específicas;
3. a ocorrência frequente de alteração de consciência limita a descrição dos sintomas pelo paciente, sendo necessário uma testemunha;
4. os exames complementares disponíveis para avaliação são de baixa sensibilidade e especificidade;
5. o registro de um evento é habitualmente limitado pela baixa frequência do fenômeno e o custo das avaliações;
6. erros diagnósticos podem ocorrer como consequência da tendência diagnóstica do médico, variável de acordo com especialidade;
7. inúmeros padrões de registros eletroencefalográficos, que variam de acordo com a idade, pessoa, tipo e origem da crise;
8. há fatores que podem causar nos pacientes paroxismos epileptiformes sem ser crise epilética (idade, condição clínica, uso de medicações etc).

Como dito anteriormente o EEG é uma avaliação dinâmica da função cerebral que fornece informações decisivas para o diagnóstico. No entanto, sua interpretação é difícil e fortemente dependente do observador, gerando por vezes mais problema do que solução. A crítica do resultado é frequentemente difícil para o neurologista não especializado em neurofisiologia e muito mais difícil para médicos de outras especialidades.

O EEG é uma ferramenta extremamente útil para auxiliar o clínico na classificação dos tipos de crise e síndromes de epilepsia. Porém, deve ser enfatizado que o uso apenas do EEG não deve ser parâmetro de diagnóstico para epilepsia, pois apresenta especificidade e sensibilidade baixas. Um terço dos pacientes com epilepsia apresentarão um EEG interictal completamente normal, 5% das crianças sem epilepsia demonstrarão anormalidades epileptiformes. Video-EEG ou EEG em ambulatório podem ser muito úteis, já que a maioria dos casos epiléticos terão um EEG correlacionado (STROINK *et al.*, 2003).

O diagnóstico preciso e a averiguação de casos continuam a ser um grande problema, porque a crise epilética é apenas um sintoma de muitas entidades causadoras. Isso porque a Epilepsia é uma síndrome, ou seja, um conjunto de sinais e sintomas que caracterizam certa condição. Várias condições médicas podem se manifestar como crises, ataques ou acessos

recorrentes, mas apenas uma parte delas é devida à epilepsia. As crises pseudoepilépticas (CPE) podem ser confundidas com Epilepsia devido à semelhança das manifestações comportamentais, mas não são consequentes a descargas cerebrais anormais, podendo ter origem fisiogênica ou psicogênica. O EEG deve ser realizado em todos os pacientes com suspeita de epilepsia para auxílio diagnóstico do tipo de crise e da síndrome epilética. No entanto, deve ser levada em conta na sua interpretação uma série de limitações que o método apresenta.

Existem padrões de eletroencefalograma que podem ser patognomônicos<sup>5</sup> ou altamente sugestivos de uma síndrome epilética. É importante diferenciar os diferentes padrões, não só para auxiliar o clínico na sua orientação diagnóstica, mas também para que o técnico saiba as características eletroencefalográficas específicas de cada síndrome epilética, para escolher o melhor exame e executar as manobras de ativação necessárias.

Entre os diversos padrões conhecidos destacam-se: a Epilepsia do tipo focal benigna da infância com descargas centrotemporais, Epilepsia occipital idiopática, Epilepsia de ausência da infância, Epilepsia mioclônica juvenil ou as epilepsias reflexas. Outros padrões bastante conhecidos pelos neurologistas são os EEG das Síndrome de West, Síndrome de Jeavons, Síndrome de Angelman, Síndrome de Rett, Síndrome do X-frágil, Síndrome do cromossomo 20 em anel, Síndrome da tetrassomia do cromossomo 15, Síndrome Wolf-Hirschhorn e da Doença de Jansky-Bielschowsky. Os tipos de EEG e achados eletroencefalográficos característicos dessas síndromes epiléticas não serão discutidos, pois excedem os objetivos deste trabalho.

Há um grande esforço da comunidade médica para unificar critérios de diagnósticos. E pode-se destacar também os inegáveis progressos nas definições dos padrões eletroencefalográficos que correspondem a crises epiléticas (padrões ictais), pois a interpretação incorreta é um problema bastante comum. É fundamental que o médico responsável pelo laudo esteja familiarizado com os critérios para distinguir descargas epiléticas de ondas mais agudas que não representam grafoelementos ictais e também de variantes normais.


Para destacar a dificuldade do diagnóstico serão apresentados, a seguir, três exemplos bem distintos de pacientes diferentes do banco de dados que será utilizado no trabalho (GOLDBERGER *et al.*, 2000). Na Figura 21, é apresentada uma crise tônico-clônica generalizada paciente CHB01, no qual a fase tônica se inicia depois de mioclonias representada no EEG por descargas de polispícula-onda, destacada após a linha vermelha, na imagem o ritmo ictal é obscurecido por artefatos da contração muscular. Já a crise epilética do paciente CBH06,

<sup>5</sup> Termo médico que se refere a sinal ou sintoma específico de uma determinada doença, diferenciando-a das outras.




apresentada na Figura 22, começa em 1724 segundos e consiste no achatamento do sinal EEG em todos os canais continuado pelo surgimento de um ritmo de banda beta nos canais F3-C3, C3-P3. Ao longo de alguns segundos, a amplitude desse ritmo aumenta à medida que sua frequência diminui e se instala dentro da banda *theta* ( $\theta$ ).

Figura 21 – Exemplo de crise epilética paciente CBH01.



Fonte: do autor.

Figura 22 – Exemplo de crise epilética paciente CBH06.




Fonte: do autor.

Na Figura 23, é apresentada a crise epilética do paciente CBH010, que começa aos 6313 segundos e, no seu início, apresenta uma ritmo *theta* ( $\theta$ ). Ritmo proeminente observado nos canais F7-T7, T7-P7. Nos outros canais EEG também exibem uma mudança após o início

da crise. O canal C3-P3 desenvolve um ritmo *theta* ( $\theta$ ), enquanto o canal FP2-F8 desenvolve um ritmo *delta* ( $\delta$ ). Entre as convulsões (período interictal), o EEG de um indivíduo com epilepsia pode exibir atividade rítmica ou descargas anormais. As características espaciais e espectrais dessas descargas variam entre os pacientes. Embora essas descargas possam ser observadas com frequência no EEG paciente, elas não são acompanhadas pelos sintomas físicos associados à convulsão do paciente. Conseqüentemente, um sistema detector projetado para reagir às crises desse paciente não deve produzir um alarme após o início de uma dessas descargas. Já em outro paciente, esse tipo de atividade pode estar associado a sintomas físicos.

Figura 23 – Exemplo de crise epilética paciente CBH10.



Fonte: do autor.

## 2.3 Conclusão

Neste capítulo, foram destacados os princípios básicos da neurofisiologia, destacando os potenciais elétricos produzidos nos neurônios piramidais do cortex resultando na atividade elétrica cerebral. Foram discutidos os aspectos básico de EEG, exame cuja finalidade é captar a atividade elétrica do cérebro, destacando as suas principais características que serão importantes do decorrer deste trabalho, como a taxa de amostragem e a importância do números de bits na digitalização, sistemas 10-20, grafoelementos e artefatos.

Em seguida, foram apresentados os ritmos cerebrais, que são de fundamental importância para a análise do comportamento normal anormal do cérebro. Foi discutido um breve relato sobre a Epilepsia e as crises epiléticas (objeto de estudo deste trabalho), destacando suas causas, tipos e classificação. Posteriormente, verificaram alguns padrões de atividades

epileptiformes que são associadas com as crises epiléticas. E o capítulo foi finalizado destacando o desafio de que se realizar uma diagnóstico de Epilepsia e o destaque que o EEG tem nesse procedimento. Por fim, foram apresentados alguns exemplos de crises epiléticas de três pacientes diferentes com intuito de apresentar três padrões distintos de atividade anormal no período ictal.

No capítulo seguinte, serão discutidas as características do sinal do EEG e o métodos de extração de atributos, etapa de fundamental importância em que busca-se extrair características dos sinais de entrada que podem ser usadas para a discriminação das classes na classificação.



### 3 EXTRAÇÃO DE ATRIBUTOS

Como discutido anteriormente, o EEG é um exame amplamente utilizado no diagnóstico precoce e detecção de crises epiléticas. Porém, o procedimento é realizado através de uma inspeção visual do EEG do paciente, tornando a tarefa demorada e não apresentando uma boa sensibilidade e especificidade. Dessa forma, é proposto nesse trabalho um sistema de auxílio a diagnósticos baseados em aprendizado de máquinas. Porém, a qualidade da informação produzida é extremamente dependente da qualidade dos dados de entrada (números de casos clínicos, presença de ruídos, número de atributos utilizados ou ausentes). Esse sistema é composto basicamente por duas partes: extrator de características e algoritmo de classificação por algum método supervisionado (RAMGOPAL *et al.*, 2014). Esse capítulo será dedicado à extração de atributos.

A etapa de extração de atributos consiste na utilização de técnicas de transformação do sinal original do EEG em uma representação matemática que permita a identificação de um dado comportamento, como um fenômeno epileptiforme. Portanto, o sinal é geralmente representado por um conjunto de vetores de características que podem então ser utilizados com mais eficiência na etapa de classificação. Essa etapa deve proporcionar uma redução no espaço (dimensionalidade) de dados para análise sem perda significativa de informação útil e necessária para se obter a qualidade desejada da informação gerada pelo classificador.

De forma mais abrangente, o capítulo abordará as características do sinal do EEG, como sua alta não estacionariedade e não linearidade, e os métodos de extração incluindo métodos lineares no tempo e na frequência, descritores não lineares e medidas estatísticas. Resumidamente:

- na seção de métodos lineares no domínio da frequência, será destacado o método convencional de análise espectral do EEG através da Transformada de Fourier e as técnicas de estimação e suavização da densidade espectral de potência;
  - no domínio do tempo, será apresentada a análise a partir do método de codificação linear preditiva cujo objetivo é encontrar  $p$  coeficientes, onde  $p$  é a ordem do filtro de predição linear;
  - será apresentado o conceito de *cepstrum* e serão introduzidos os conceitos dos coeficientes mel-cepstrais que são a representação do espectro de potência de curto prazo de um sinal, baseado na Transformada Discreta do cosseno em uma escala não linear de frequência.
- Por fim, apresentar-se-á

- um método de análise estatística em que se utiliza diretamente a matriz de covariância espacial do EEG como uma característica do sinal que pode ser utilizado em um classificador.

### 3.1 Características do EEG

Da mesma forma como há uma complexidade no diagnóstico clínico da Epilepsia (manifestações clínicas, etiologia, padrões de propagação e evolução da epilepsia com o envelhecimento etc), o tratamento e uso dos sinais eletrofisiológicos do EEG também é um grande desafio. O EEG é um sinal complexo, cujas propriedades estatísticas dependem do tempo e do espaço (SCHOMER, 2010). O sinal EEG pode ser considerado um sinal aleatório gerado por um processo estocástico não linear e não estacionário, e pode ser representado, após a digitalização, como uma sequência de amostras temporais (SANEI; CHAMBERS, 2007).

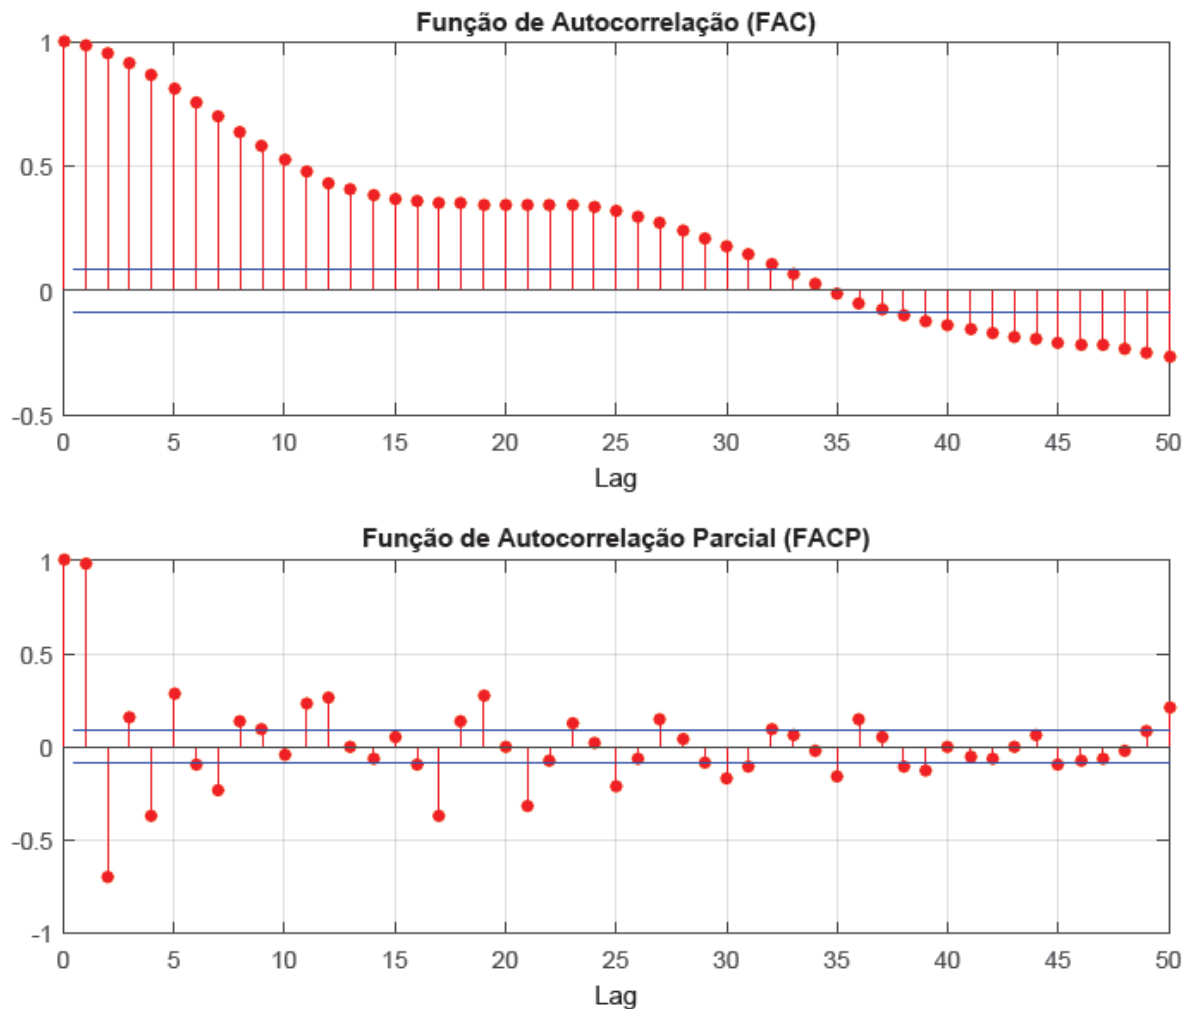
Em geral, os sinais biomédicos são: não estacionários, não lineares e ruidosos. A não estacionariedade surge também por causa de diferentes escalas de tempo envolvidas no processo dinâmico - parâmetros dinâmicos são sensíveis às escalas de tempo e, portanto, no estudo do cérebro é preciso identificar todas as escalas de tempo relevantes envolvidas no processo para obter uma visão no funcionamento do cérebro (INDIC *et al.*, 1999). É extremamente importante que os métodos não lineares auxiliem no processamento de não estacionariedades nos sinais analisados. Métodos lineares, como a FFT, não detectam tão facilmente componentes não estacionários (AL-ANI *et al.*, 2010).

Características do EEG, tais como ondas agudas, espículas ou descargas de ondas (poliespículas que são características do EEG no período ictal), ou como alternância de intervalos relativamente homogêneos com diferentes características estatísticas (por exemplo, com diferente amplitude ou variância), são comportamentos típicos de sinais não estacionários. As não estacionariedades no EEG também são devidas a alterações patológicas, por exemplo convulsões epiléticas, ou a alterações do estado fisiológico, por exemplo, passando de um estágio do sono para outro. A presença de atividades epileptiformes, instâncias de comportamento de ruptura, comportamento de frequência dependente da amplitude e existência de harmônicos de frequência, estão entre o longo catálogo de propriedades típicas de sistemas não lineares.

Pode-se avaliar a estacionariedade de uma série temporal através de métodos estatísticos, como o teste de Dickey-Fuller Aumentado e o teste KPSS (HARRIS, 1992; KWI-ATKOWSKI *et al.*, 1992). Uma forma geral para analisar este fato é fazendo um estudo da

existência de alguma raiz dos operadores de retardos dentro do círculo unitário, denominada simplesmente por raiz unitária. Outra forma de se avaliar esse comportamento é visualmente. Como normalmente não se tem o modelo de série temporal e sim os dados, esta é a forma mais eficiente e prática de se verificar a não estacionariedade do sinal. Observando os gráficos da função de autocorrelação (FAC) e a função de autocorrelação parcial (FACP), Figura 24, a inclinação descendente do gráfico indica um processo de raiz unitária. Os comprimentos dos segmentos de linha no gráfico FAC decaem gradualmente e continuam esse padrão para aumentar os atrasos. Esse comportamento indica uma série não estacionária.

Figura 24 – Função de autocorrelação (FAC) e função de autocorrelação parcial (FACP) de um intervalo de 5s de um canal do EEG.



Fonte: o autor.

Vários pesquisadores forneceram evidências de que o EEG do cérebro epilético é um sinal não linear com propriedades determinísticas e talvez caóticas (MORMANN *et al.*, 2005). Fenômenos não estacionários presentes no EEG geralmente são encontrados na forma

de eventos transitórios. Os fenômenos transitórios têm um padrão específico que possibilita identificá-los facilmente por inspeção visual na maioria dos casos, enquanto a identificação dos segmentos homogêneos do EEG requer uma certa base teórica.

A seguir, serão descritos os quatro métodos de extração de atributos que foram utilizados na elaboração dos experimentos.

### 3.2 Análise Espectral

A análise espectral é o processo pelo qual será estimado o conteúdo energético de uma função variável no tempo (ou sinal) em função da frequência. As variações na resolução de frequência dos espectros são devidas a diferentes comprimentos de janela. À medida que o sinal se torna mais complexo (em termos de conteúdo de frequência), o espectro de energia se assemelha a uma função contínua.

A análise harmônica de um processo aleatório produzirá algumas informações de frequência. Esse espectro de energia é uma ferramenta útil na análise de um processo aleatório, onde verifica-se quais informações podem ser obtidas do espectro de energia. O espectro de energia tem quatro usos principais: (1) apresenta periodicidades que são ocultas no domínio do tempo; (2) obtêm estatísticas descritivas (distribuição, média, moda, largura de banda do espectral) de um sinal aleatório; (3) obter uma visão geral das frequências de um sinal; (4) na obtenção de estimação de parâmetros e/ou extração de características, por exemplo, ritmos cerebrais de um EEG para testes de classificação (LESSARD; ENDERLE, 2006).

O sinal EEG pode ser representado de várias maneiras, incluindo os domínios de tempo e frequência. A análise utilizando a Transformada de Fourier é o processo no qual se decompõe um sinal em seus componentes de frequência. É um método extremamente poderoso que pode ser usado para revelar informações que não podem ser vistas facilmente no domínio do tempo. A transformada de Fourier utiliza funções sinusoidais ou sinais exponenciais complexos como funções básicas para representar os sinais de entrada. A TF de um sinal aperiódico contínuo em tempo real  $x(t)$  é definida como:

$$\mathcal{F}\{x(t)\} = \mathcal{X}(\omega) = \int_{-\infty}^{\infty} x(t)e^{-j\omega t} dt, \quad (3.1)$$

em que  $\omega = 2\pi f$  é a frequência angular em radianos e  $\mathcal{F}$  é o operador de Fourier.

Como o processamento de sinal EEG atualmente é realizado usando computadores, o sinal  $x(t)$  de um canal é amostrado com uma frequência de  $f_s = \omega_s/2\pi = 1/T_s$ , em que  $T_s$  é

denominado o tempo de amostragem. O processo de amostragem gera a sequência de dados discreta  $x(n)$ , em que  $n$  denota o tempo discreto da amostra. A transformada de Fourier em tempo discreto (DTFT) de um sinal de tempo discreto  $x(n)$  é definida como:

$$DTFT\{x(n)\} = \mathcal{X}(e^{j\omega}) = \sum_{n=-\infty}^{\infty} x(n)e^{-j\omega n}. \quad (3.2)$$

Para uma sequência finita de tamanho  $N$  e com a frequência angular ( $\omega$ ) sendo representada por variáveis discretas em função de  $N$  a Equação (3.2) é reduzida para:

$$DFT\{x(n)\} = \mathcal{X}(k) = \sum_{n=0}^{N-1} x(n)e^{-j\frac{2\pi}{N}kn}, \quad (3.3)$$

para  $n = 0, 1, \dots, N-1$  e  $k = 0, 1, \dots, N-1$  e  $N$  é o número de amostras em um período do espectro.

Como os sinais são determinísticos no tempo discreto, a análise de Fourier desempenha um papel importante no estudo de processos aleatórios. Então é possível desenvolver uma representação de Fourier se o processo for estacionário no sentido amplo. Dessa forma a sequência de autocorrelação ( $r_{xx}$ ) desse processo é uma sequência determinística, e sua transformada de Fourier é dada como:

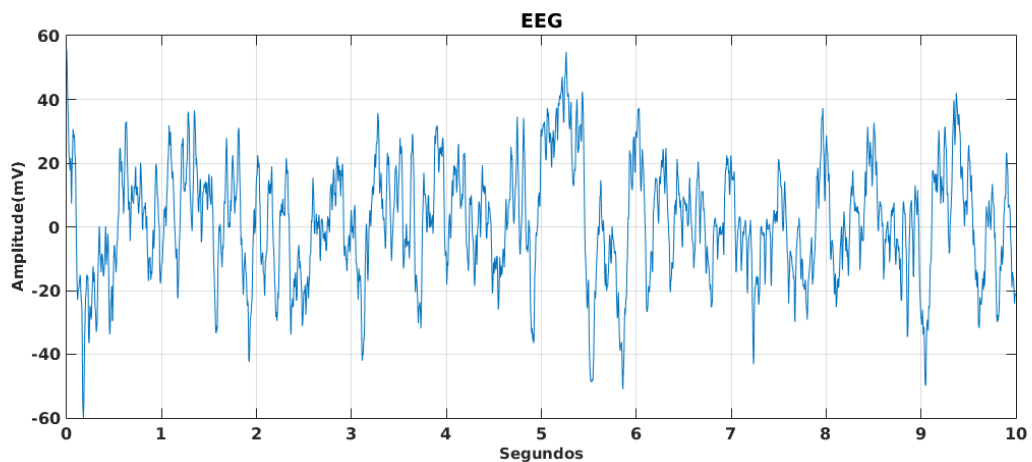
$$\mathcal{S}(e^{j\omega}) = \sum_{k=-\infty}^{\infty} r_{xx}(k)e^{-j\omega k}, \quad (3.4)$$

em que  $\mathcal{S}(e^{j\omega})$  é chamada de densidade espectral de potência. A estimativa da PSD usando o DFT é conhecida como *periodograma*, que pode ser facilmente calculado usando o método transformada rápida Fourier (FFT). A PSD é expressa em unidades de potência por radianos por amostra. A Equação (3.4) é conhecida como o teorema de Wiener-Khinchine, e  $\mathcal{S}(e^{j\omega})$  é uma função/saída real pelas propriedades da transformada discreta de Fourier de funções reais com simetria par, caso da função de autocorrelação (AGUIRRE, 2015).

Assume-se que o sinal do EEG seja estacionário em um pequeno intervalo de tempo suficiente para a estimativa eficiente das diferentes funções médias, como a autocovariância ou autocorrelação no domínio do tempo e a densidade do espectro de potência no domínio da frequência. Para se estimar a autocovariância ou autocorrelação de processos aleatórios, é necessário calcular a média em um número de realizações de um conjunto. No entanto, se o processo for estacionário e ergódico, a sequência de autocovariância ou autocorrelação pode ser obtida através da média temporal. Isso é de extrema importância pois para a estimativa de PSD, pois uma matriz/função de autocorrelação não positiva definida pode levar a uma estimativa de energia negativa.

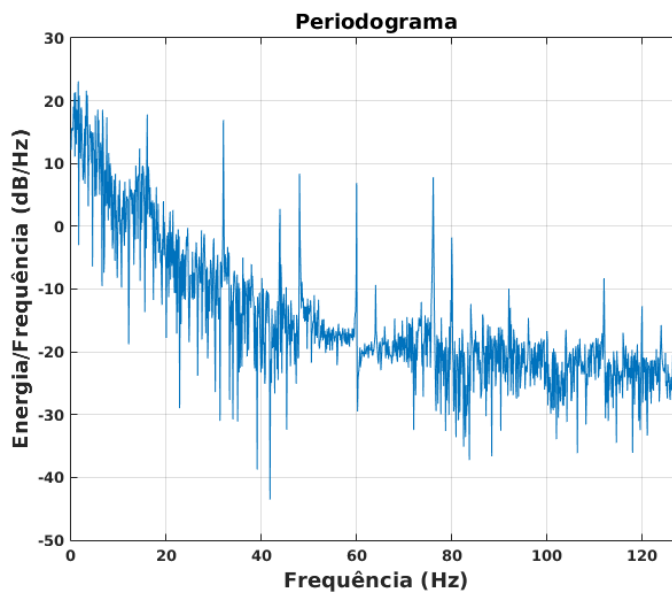
Na Figura 25, é apresentado um sinal de duração de 10 segundos do canal Fp1-F7 do paciente *CHB01*, com uma taxa de amostragem de 256 Hz. Sua densidade espectral de potência é apresentada na Figura 26. Pelo teorema de Nyquist, a frequência máxima será a metade da frequência de amostragem. A dispersão espectral é causada por descontinuidades criadas pelo uso de um número não inteiro de períodos do sinal original, e pode ser melhorada pelo uso do janelamento. O janelamento reduz a amplitude das descontinuidades nas bordas de cada sequência finita adquirida pelo digitalizador.

Figura 25 – Exemplo de 10 s de sinal do EEG.



Fonte: o autor.

Figura 26 – Densidade Espectral de Potência, utilizando a FFT.



Fonte: o autor.

### 3.2.1 Janelamento

Como o sinal do EEG é não estacionário, o que significa que seu espectro e propriedades estatísticas mudam com o tempo, tal sinal pode ser aproximado como sendo estacionário por partes, através de uma sequência de segmentos estacionários independentes. Entretanto, a segmentação ou truncamento no domínio do tempo é equivalente à multiplicação do sinal EEG completo por uma janela retangular de tempo finito. Como a multiplicação no tempo é equivalente à convolução em frequência, a transformada de Fourier do sinal após o janelamento é mais complexa e vazará ou se estenderá por uma faixa de frequência mais ampla que o sinal original. A transição abrupta dos valores do sinal no caso de uma janela retangular resulta no aparecimento de ondulações na transformada discreta de Fourier. Essas ondulações podem ser reduzidas usando funções de janela alternativas. Muitas funções da janela estão disponíveis na literatura (LESSARD; ENDERLE, 2006). Os exemplos a seguir representam quatro das funções de janelas mais comumente utilizadas:

- Retangular:

$$w_R[n] = \begin{cases} 1, & |n| < N \\ 0, & \text{caso contrário} \end{cases} \quad (3.5)$$

- Bartlett:

$$w_B[n] = \begin{cases} \frac{N - |n|}{N}, & |n| < N \\ 0, & \text{caso contrário} \end{cases} \quad (3.6)$$

- Hamming:

$$w_H[n] = \begin{cases} 0.54 - 0.46 \cos\left(\frac{2\pi|n|}{N-1}\right), & |n| < N \\ 0, & \text{caso contrário} \end{cases} \quad (3.7)$$

- Hanning:

$$w_N[n] = \begin{cases} \frac{1}{2} \left[ 1 - \cos\left(\frac{2\pi|n|}{N-1}\right) \right], & |n| < N \\ 0, & \text{caso contrário} \end{cases} \quad (3.8)$$

O janelamento do sinal reduz as ondulações e tende a reduzir as variações acentuadas ou a resolução da transformada discreta de Fourier. A escolha da janela apropriada e seu tamanho

dependem da aplicação em questão. De forma geral, a janela de Hanning é satisfatória na maioria dos casos. Ela oferece boa resolução em frequência e dispersão espectral reduzida. É bom sempre comparar o desempenho de diferentes funções de janela, para encontrar a melhor para a sua aplicação. A seguir, serão apresentadas as principais janelas utilizadas e os método de Welch, proposto para suavizar a curva da PSD.

### 3.2.2 Estimação da PSD pelo método de Welch

A aplicação direta da transformada de Fourier não é o ideal para processos aleatórios, como o EEG, porque o sinal pode conter descontinuidades. Se usarmos energia em vez da amplitude do sinal como uma função de frequência, então essa função espectral existirá. O espectro de potência ou a densidade espectral de potência de um sinal aleatório  $x(n)$  é definido como a transformada de Fourier da função de autocorrelação. em que a função de autocorrelação é dada por:

$$r_{xx}(m) = \mathbb{E}[x(n)x(n+m)] = \frac{1}{N} \sum_{N-|m|-1}^{n=0} [x(n)x(n+m)] \quad (3.9)$$

em que  $\mathbb{E}$  é o operador esperança.

Usando a convolução, a PSD é dada como:

$$S(\omega) = \frac{1}{N} [\mathcal{X}_N(e^{j\omega}) \mathcal{X}_N^*(e^{j\omega})] = \frac{1}{N} |X_N e^{j\omega}|^2. \quad (3.10)$$

Pode-se concluir que o periodograma é proporcional ao quadrado da magnitude da transformada de Fourier de um sinal janelado. Comumente, são usados outros tipos de janelamento diferentes do retangular, destacando-se as janelas de Bartlett, Hanning, Hamming, Blackman, Flattopwin, Gaussiana e Taylorwin, algumas das quais apresentadas na seção anterior. Dessa forma, o periodograma modificado ( $\mathcal{S}_M(\omega)$ ) é calculado da seguinte forma:

$$\mathcal{S}_M(\omega) = \frac{1}{NU} \left[ \sum_{n=-(N-1)}^{N-1} x(n)w(n)e^{-j\omega n} \right], \quad (3.11)$$

em que  $U$  é dado pela média quadrática da magnitude da janela  $w(n)$ , ou seja,

$$U = \frac{1}{L} \sum_{n=0}^{L-1} w^2(n). \quad (3.12)$$

Se aumentarmos o número de amostras ( $N$ ), o valor médio do periodograma convergirá para a verdadeira PSD. Para reduzir a variação do periodograma, é utilizada a média do



conjunto. O espectro de energia resultante é chamado de periodograma médio. Um dos métodos mais populares para calcular o periodograma médio é o método de Welch, no qual segmentos sobrepostos em janelas são usados (LESSARD; ENDERLE, 2006).

O método periodograma proposto por de Welch, a princípio, foi baseado no método de Bartlett. O método de periodograma de Bartlett produz uma estimativa do espectro de potência. A motivação para este método vem da observação de que o valor esperado do periodograma converge para  $\mathcal{S}(e^{j\omega})$  à medida que o comprimento do registro de dados ( $N$ ) vai para o infinito, ou seja,

$$\lim_{N \rightarrow \infty} \mathbb{E}\{\hat{\mathcal{S}}_{per}(e^{j\omega})\} = \mathcal{S}(e^{j\omega}). \quad (3.13)$$

Pela Equação (3.13) é possível encontrar a média da estimativa do periodograma. Seja,  $x_i(n)$  com  $i$  variando de 1 até  $K$ , onde se têm  $K$  realizações de um processo não correlacionado de um processo aleatório  $x(n)$  sobre o intervalo  $0 < n \leq L$ . Sabe-se que a estimativa do periodograma de  $x_i(n)$  é dada por

$$\hat{\mathcal{S}}_{per}^{(i)}(e^{j\omega}) = \frac{1}{L} \left[ \sum_{n=0}^{L-1} x_i(n) e^{-jn\omega} \right], i = 1, 2, \dots, k, \quad (3.14)$$

e a média vertical para  $K$  realizações é dada por:

$$\hat{\mathcal{S}}_x(e^{j\omega}) = \frac{1}{K} \sum_{i=1}^K \hat{\mathcal{S}}_{per}^{(i)}(e^{j\omega}). \quad (3.15)$$

Calculando o valor esperado para  $\hat{\mathcal{S}}_x(e^{j\omega})$ , temos

$$\mathbb{E}\{\hat{\mathcal{S}}_x(e^{j\omega})\} = \mathbb{E}\{\hat{\mathcal{S}}_{per}^{(i)}(e^{j\omega})\} = \frac{1}{2\pi} \mathcal{S}_x(e^{j\omega}) * W_B(e^{j\omega}), \quad (3.16)$$

no qual  $W_B(e^{j\omega})$  é a transformada de Fourier da janela de Bartlett no intervalo de  $[-L, L]$ .

Assumindo que os dados são não correlacionados, a variância de  $\hat{\mathcal{S}}_x(e^{j\omega})$  é dado por

$$\text{Var}\{\hat{\mathcal{S}}_x(e^{j\omega})\} = \frac{1}{K} \text{Var}\{\hat{\mathcal{S}}_{per}^{(i)}(e^{j\omega})\} \approx \frac{1}{K} \mathcal{S}_x^2(e^{j\omega}). \quad (3.17)$$

Porém, essa abordagem, na prática, é complexa, pois normalmente não se tem  $K$  realizações de um processo e sim uma única realização com  $N$  amostras. Então Bartlett propôs que  $x(n)$  seja particionado em  $K$  sequências não sobrepostas de tamanho  $L$ , onde  $N = LK$  e a estimativa da densidade espectral de potência de Barlett com essa proposta é dada por:

$$\hat{\mathcal{S}}_B(e^{j\omega}) = \frac{1}{N} \sum_{i=0}^{K-1} \left[ \sum_{n=0}^{L-1} x(n+iL) e^{-jn\omega} \right]^2, \quad (3.18)$$

em que  $x_i(n) = x(n + iL)$  para  $n = 0, 1, \dots, K$  e  $i = 0, 1, \dots, K - 1$ .

WELCH (1967) propôs em seu trabalho duas alterações no método de Barlett. A primeira proposta de modificação é permitir que a sequência de dados  $x_i(n)$  se sobreponham e a segunda proposta é permitir que o janelamento dos dados  $w(n)$  seja aplicado à cada sequência. Desta forma, produz-se um conjunto de periodogramas modificados que devem ser calculados pela média.

Com um sinal  $x_i(n)$ , esse sinal é formado por sucessiva sequências de *offset*  $D$  ao longo de  $L$  pontos na sequência, ou seja,  $x_i(n) = x(n + iD)$  para  $i = 0, 1, \dots, L - 1$ . Então a quantidade de amostras sobrepostas entre  $x_i(n)$  e  $x_{1+i}(n)$  é  $L - D$  pontos.

O cálculo da densidade espectral de potência estimada de Welch é dada por:

$$\hat{\mathcal{S}}_w(e^{j\omega}) = \frac{1}{KLU} \sum_{i=0}^{K-1} \left[ \sum_{n=0}^{L-1} w(n)x(n+iD)e^{-jn\omega} \right]^2, \quad (3.19)$$

em que  $U$  é dado pela Equação (3.12).

O valor esperado da estimativa do método de Welch é dado por:

$$\mathbb{E}\{\hat{\mathcal{S}}_w(e^{j\omega})\} = \frac{1}{2\pi LU} \mathcal{S}_x(e^{j\omega}) * |W(e^{j\omega})|^2, \quad (3.20)$$

em que  $W(e^{j\omega})$  é a transformada de Fourier da janela escolhida.

O procedimento computacional para calcular o PSD de uma determinada sequência de  $N$  pontos de dado a seguir:

1. divida o sinal em  $k$  segmentos de  $m$  amostras cada;
2. compute o periodograma de cada segmento com janelas usando o algoritmo FFT, usando a Equação (3.19)

$$S_i(\omega) = \frac{1}{MD} \left| \sum_{n=0}^{M-1} x_i(n)w(n)e^{-j\omega n} \right|^2 \quad 1 \leq i \leq k, \quad (3.21)$$

em que  $D$  é a potência média da janela usada, calculada como:

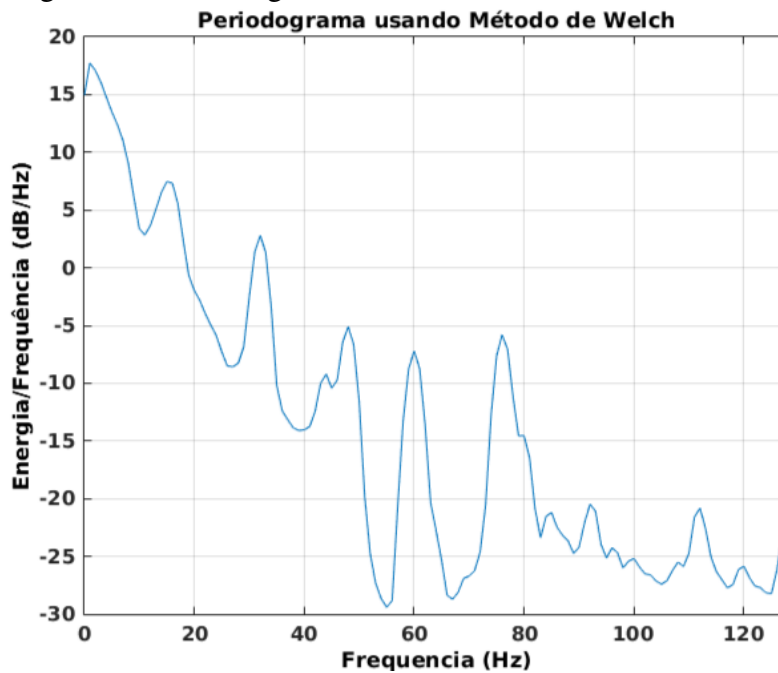
$$D = \frac{1}{M} \sum_{n=0}^{M-1} w^2(n); \quad (3.22)$$

3. o periodograma médio é então estimado a partir da média do conjunto de  $k$  periodogramas, ou seja,

$$S(\omega) = \frac{1}{k} \sum_{i=1}^k S_i(\omega). \quad (3.23)$$

O sinal de entrada  $x(n)$  é segmentado em comprimentos iguais, podendo ou não haver sobreposição. Normalmente os algoritmos utilizam uma sobreposição de cerca de 50%.

Figura 27 – Periodograma de Welch.



Fonte: o autor.

### 3.3 Codificação Linear Preditiva

Outra forma de se analisar o sinal do EEG e obter atributos é através da Codificação Linear Preditiva. O LPC é uma técnica de parametrização amplamente utilizada no reconhecimento de voz e de locutor, permitindo uma representação do sinal por um número relativamente pequeno de parâmetros.

Durante um período de tempo em que considera-se o sinal estacionário, pode-se modelar qualquer sinal de caráter aleatório como uma aproximação por um modelo ARMA. Nesse modelo, a função de transferência  $H(z)$  é denominada de função de transferência do ruído, pois quantifica o quão o processo aleatório (gerado pelo ruído branco) afeta a saída predita pelo modelo. Os modelos ARMA são comumente usados como modelos de séries temporais, em situações em que somente se tem o sinal de entrada (AGUIRRE, 2015).

Normalmente se utiliza um modelo mais simples para a tarefa da extração de características de um sinal temporal como o EEG, ECG ou voz. Este modelo corresponde ao filtro autorregressivo (AR), filtro constituído somente de pólos (*all-pole*). Sua função de transferência é dada por:

$$H(z) = \frac{1}{1 - \sum_{i=1}^p a(i)z^{-i}}, \quad (3.24)$$

em que  $p$  é a ordem do modelo e  $a(i)$  são os coeficientes de autorregressão. A vantagem em se de

utilizar os modelos AR é a simplificação analítica. Dessa forma, podem-se desenvolver métodos mais eficientes e simples para estimar os parâmetros do modelo. Se houver interesse somente em codificar e armazenar o sinal, o modelo AR, que leva em conta somente o espectro da magnitude, não o de fase, é completamente aceitável e útil para extrair as informações necessárias.

A função de transferência é uma combinação linear de seus  $p$  valores passados somado a excitação  $u(n)$ , apresentada na Equação (3.24). Portanto:

$$y(n) = \sum_{i=1}^p a(i)y(n-i) + Gu(n), \quad (3.25)$$

em que  $y(n)$  é a saída do modelo,  $a(i)$  são os coeficientes do modelo,  $p$  é a ordem do preditor,  $G$  é um fator de ganho associado à excitação  $u(n)$ . Considera-se o ganho unitário e sabe-se que, nas aplicações de processamento digital de sinais, o termo  $u(n)$  é um termo “desconhecido”, pois não se tem acesso ao valor de  $u(n)$ , embora suas estatísticas sejam conhecidas.

Os processos AR podem ser utilizados como modelos se for razoável assumir que o valor atual de uma série temporal depende do seu passado imediato mais um erro aleatório. Sendo assim, a análise LPC parte do pressuposto que o sinal pode ser representado pela combinação linear das amostras atrasadas. O valor estimado do sinal  $\hat{y}(n)$  é dado por:

$$\hat{y}(n) = \sum_{i=1}^p \hat{a}(i)y(n-i). \quad (3.26)$$

Determinar os coeficientes de predição do modelo AR,  $\hat{a}(i)$ , é problema básico na análise de sinais utilizando o LPC. Os métodos mais comumente utilizados para calcular os coeficientes são Burg, Yule-Walker e Mínimos Quadrados. Neste trabalho será utilizado o método da equação de Yule-Walker, que será abordado no tópico seguinte.

### 3.3.1 Estimação dos Coeficientes pelo Método de Yule-Walker

Projetar o filtro finito, de comprimento  $M + 1$ , com a restrição de  $a(0) = 1$ , é minimizar erro quadrático médio entre o valor desejado,  $y(n)$ , e o valor estimado  $\hat{y}(n)$  (ALKAN; YILMAZ, 2007). Dessa forma a função custo  $J(n)$  é dada por:

$$\begin{aligned} J(n) &= \mathbb{E}[(y(n) - \hat{y}(n))^2] = \mathbb{E}\left[\left(y(n) - \sum_{i=1}^p \hat{a}(i)y(n-i)\right)^2\right] \\ &= \mathbb{E}[y^2(n)] - \mathbb{E}\left[2y(n) \sum_{i=1}^p \hat{a}(i)y(n-i)\right] + \mathbb{E}\left[\left(\sum_{i=1}^p \hat{a}(i)y(n-i)\right)^2\right] \\ &= \mathbb{E}[y^2(n)] - 2 \sum_{i=1}^p \hat{a}(i)\mathbb{E}[y(n)y(n-i)] + \mathbb{E}\left[\left(\sum_{i=1}^p \hat{a}(i)y(n-i)\right)^2\right]. \end{aligned} \quad (3.27)$$

Como a função custo  $J(n)$  é quadrática, o ponto de mínimo global é dado quando o vetor gradiente dessa função é nulo, ou seja,

$$\nabla \mathbf{J}(n) = 0 = \frac{\partial J}{\partial \hat{a}(i)}. \quad (3.28)$$

Dessa forma, aplicando o gradiente na Equação (3.27) para cada  $\hat{a} + l$ ,  $1 \leq l \leq p$  tem-se:

$$0 = -2\mathbb{E}[y(n)y(n-l)] + 2\mathbb{E}\left[\sum_{i=1}^p \hat{a}(i)y(n-i)\right]y(n-l). \quad (3.29)$$

Organizando os termos da Equação (3.29), obtemos:

$$\mathbb{E}[y(n)y(n-l)] = \sum_{i=1}^p \hat{a}(i)\mathbb{E}[y(n-i)y(n-l)], \quad (3.30)$$

ou, de forma matricial, escreve-se:

$$\mathbf{c}_y = \hat{\mathbf{a}}\mathbf{C}_y, \quad (3.31)$$

em que  $c_y(i) = \mathbb{E}[y(n)y(n-l)]$  denota a autocovariância temporal do sinal  $y(n)$  e  $\mathbf{C}_y = \mathbb{E}[y(n-i)y(n-l)]$  é a matriz de covariância. Usando uma interpretação diferente dos limites na minimização de erros, forçando que todos os dados utilizados estejam dentro da janela a ser usado utilizada, pode-se calcular a solução para a equação de predição linear usando o método da autocorrelação<sup>1</sup>. Portanto pode-se reescrever a Equação (3.31) como:

$$\begin{bmatrix} 1 & r(1) & \dots & r(p-1) \\ r(1) & 1 & \dots & r(p-2) \\ \vdots & \vdots & \ddots & \vdots \\ r(p-1) & r(p-2) & \dots & 1 \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} r(1) \\ r(2) \\ \vdots \\ r(p) \end{bmatrix} \quad (3.32)$$

de forma matricial pode-se reescrever

$$\mathbf{r}_y = \hat{\mathbf{a}}\mathbf{R}_y \quad (3.33)$$

em que  $r_s(i) = \mathbb{E}[y(n)y(n-l)]$  é a autocorrelação do sinal com atraso  $l$  e sabendo que a FAC é par, ou seja,  $r(\tau) = r(-\tau)$  e em  $r(0) = 1$ . Para encontrar os coeficiente do filtro basta inverter a matriz de autocorrelação  $\mathbf{R}_y$ , ou seja,

$$\hat{\mathbf{a}} = \mathbf{R}_y^{-1}\mathbf{r}_y. \quad (3.34)$$

A Equação (3.34) é conhecida como equação de Yule-Walker. O problema da inversão da matriz  $\mathbf{R}_y$  é simplificado devido ao fato da matriz de autocorrelação ser do tipo Toeplitz<sup>2</sup>.

<sup>1</sup> Relação entre a matriz de covariância e a de correlação:  $\mathbf{R}_x = \mathbf{C}_x + \boldsymbol{\mu}_x\boldsymbol{\mu}_x^H$

<sup>2</sup> Matriz Toeplitz - cada diagonal descendente da esquerda para a direita possui o mesmo valor.

### 3.4 Coeficientes Cepstrais

Assim como o LPC, os Coeficientes Cepstrais são amplamente utilizados para modelar a voz, que é composta de uma excitação convolvida com a resposta do trato vocal. O EEG, apesar de apresentar uma frequência bem menor que a voz, apresenta características similares no contexto do comportamento, como a não estacionariedade, vibrações lentas (invólucro) e variações rápidas (pulso/picos). Esta relação pode ser representada por

$$s(n) = u(n) * h(n), \quad (3.35)$$

em que  $s(n)$  é o sinal de entrada (por exemplo: voz ou EEG),  $u(n)$  é a excitação e  $h(n)$  é a resposta impulsiva do trato vocal ou do ativações do EEG.

Segundo Deller *et al.* (1999), geralmente a separação dessas duas fontes é uma tarefa difícil, pois a representação no domínio da frequência ainda não seria suficiente para separar as duas componentes. Deves-se lembrar que, no domínio da frequência, as duas fontes são multiplicadas:  $S(\omega) = U(\omega)H(\omega)$ . Nesse contexto, surgiram os coeficientes *cepstrais* ou *cepstrum*. O cepstrum de um sinal  $x(n)$  é definido como como a Transformada Inversa Discreta de Fourier (IDFT - *Inverse Discrete Fourier Transform*) do logaritmo da amplitude espectral de um sinal (FURUI, 2000), conforme apresentado a seguir:

$$c[n] = \frac{1}{2\pi} \int_{-\pi}^{\pi} \log |\mathcal{X}(e^{j\omega})| e^{j\omega n} d\omega. \quad (3.36)$$

Em um sistema homomórfico, o princípio generalizado de superposição é obedecido. A representação real depende da operação de interesse. No caso, trata-se da convolução (OPPENHEIM *et al.*, 1968). Um sistema característico para a deconvolução homomórfica usando DTFT é apresentado na Figura 28. Vale lembrar que uma transformação homomórfica é uma transformação que converte uma convolução em uma soma.

Portanto, utilizando as propriedades de uma transformação homomórfica da DFFT e as propriedades do logaritmos, pode-se reescrever a Equação (3.35) como


$$\log |S(\omega)| = \log |U(\omega)| + \log |H(\omega)|, \quad (3.37)$$

e cepstrum do sinal pode ser expresso da seguinte forma:

$$c_s(k) = c_u(k) + c_h(k). \quad (3.38)$$

No domínio cepstral as componentes são somadas, a variável independente  $k$  do cepstrum é chamada de “quefrência”, que corresponde a um parâmetro no domínio do tempo pois

Figura 28 – Sistema característico para o sistema homomórfico usando DTFT.



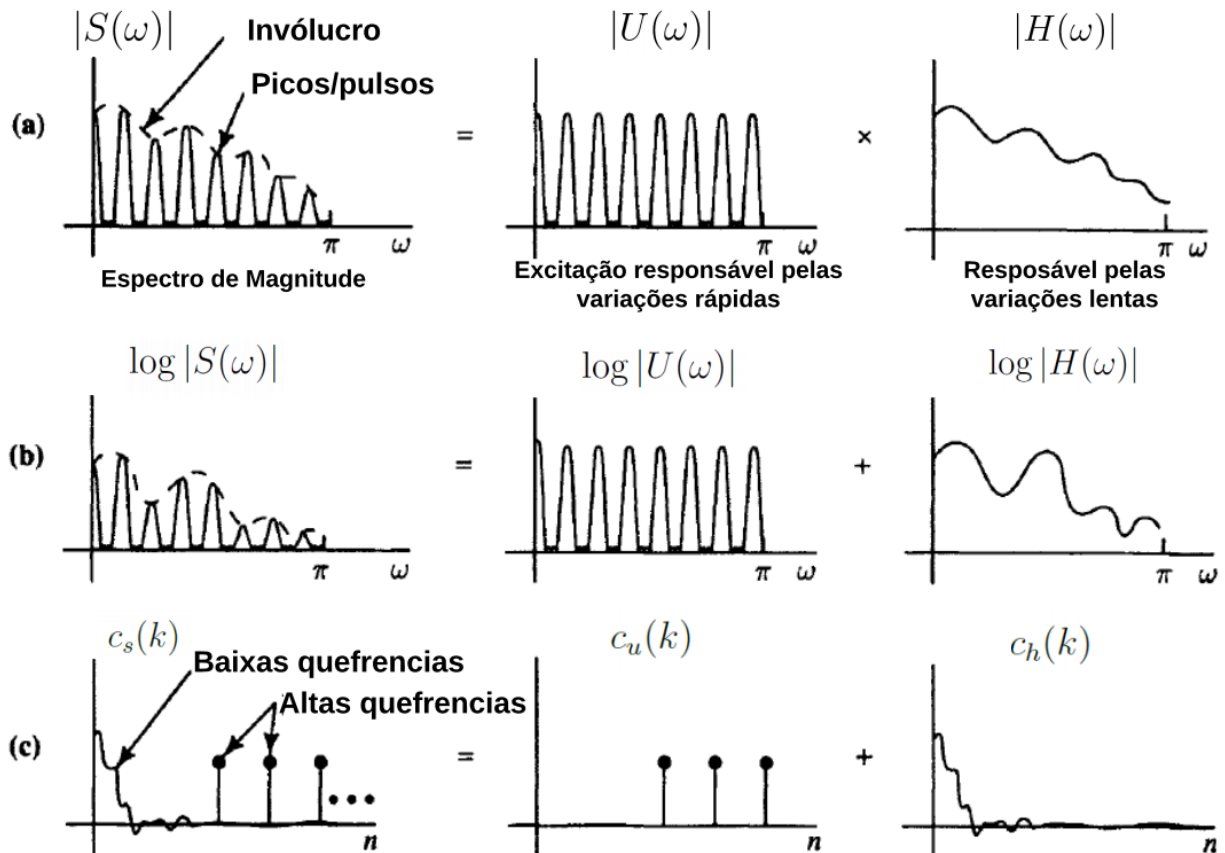
Fonte: do autor.

é formado a partir da inversa da transformada discreta de Fourier. Portanto,  $c_u(k)$  é o componente que situa-se em baixas *quefrências* e  $c_h(k)$  de altas *quefrências* (FURUI, 2000). Conclui-se que a propriedade básica do cepstrum é permitir a separação do invólucro espectral da estrutura fina, composta por picos rápidos.

Figura 29 – Domínio Cepstral. Em (a) têm-se  $|S(\omega)| = |U(\omega)| * |H(\omega)|$ , combinação não linear.

Em (b) as componentes são somadas, solucionando o problema da não linearidade.

Em (c) Representação dos componentes do sinal no domínio *cepstral*.



Fonte: Adaptado de Deller *et al.* (1999).

### 3.4.1 Coeficientes Mel Cepstrais

As medidas de distância dos cepstrum ponderadas têm uma interpretação diretamente equivalente em termos de distância no domínio da frequência. Baseados em uma análise de frequência realizada internamente no ouvido humano, Davis e Mermelstein (1980) formularam um novo tipo de representação *cepstrum* que se tornou amplamente utilizada no processamento de sinais da fala, e tem por base os Coeficientes Mel Cepstrais (MFCC, do inglês *Mel-Frequency Cepstrum Coefficients*).

Destaca-se a utilização do MFCC em outras áreas de processamentos de sinais além do voz, como a utilização em diagnósticos médicos de patologias respiratórias utilizando sinais acústicos pulmonares (PALANIAPPAN *et al.*, 2014), na identificação e diagnóstico de Disartria<sup>3</sup> (THOPPIL *et al.*, 2017) e na detecção do transtorno depressivo usando características acústicas vocais (TAGUCHI *et al.*, 2018). Nesse trabalho será explorado o potencial de extração de características do sinal de voz no sinal do EEG, que apresenta características similares em menor frequência.

A ideia básica do MFCC é calcular uma análise de frequência baseada em um banco de filtros com espaçamento de banda aproximadamente igual aos dos filtros e larguras de banda. O MFCC é uma representação definida como o cepstrum real de um sinal de curto prazo em janela derivado da FFT desse sinal. A diferença do cepstrum real é que é utilizada uma escala de frequência não linear, que se aproxima do comportamento do sistema auditivo.

Seja a DFT de um sinal

$$X_a[k] = \sum_{n=0}^{N-1} x(n)e^{-j2\pi nk/N}, \quad 0 \leq k < N, \quad (3.39)$$

e seja definido um banco de filtros com  $M$  filtros, ( $m = 1, 2, M$ ), onde cada filtro  $m$  é um filtro triangular dado por:

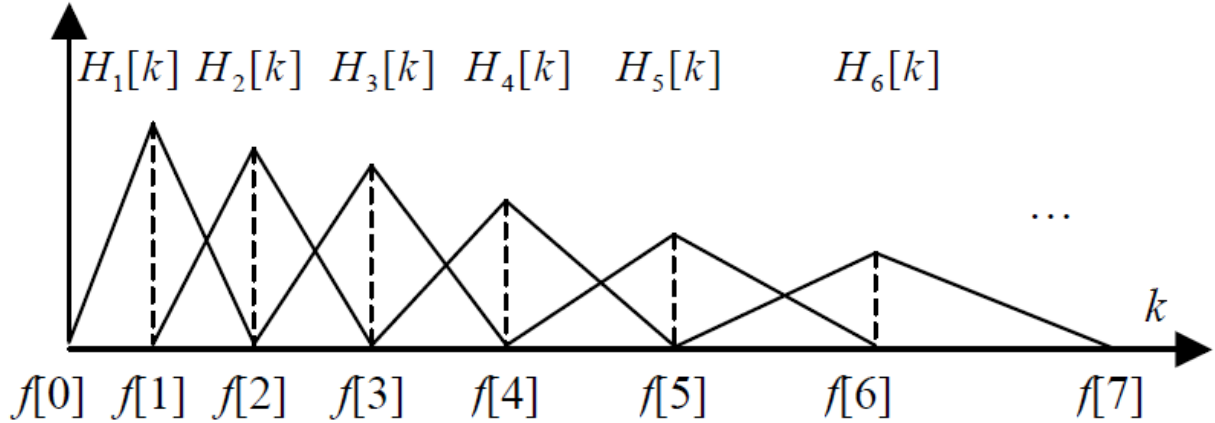
$$H_m[k] = \begin{cases} 0, & k < f[m-1], \\ \frac{2(k - f[m-1])}{(f[m+1] - f[m-1])(f[m] - f[m-1])}, & f[m-1] \leq k \leq f[m], \\ \frac{2(f[m+1] - k)}{(f[m+1] - f[m-1])(f[m+1] - f[m])}, & f[m] \leq k \leq f[m+1], \\ 0, & k > f[m+1]. \end{cases} \quad (3.40)$$

<sup>3</sup> Refere-se a um grupo de distúrbios decorrentes de distúrbios no controle muscular sobre o mecanismo de fala devido a danos no sistema nervoso central ou periférico.



A função desses filtros é calcular o espectro médio em torno de cada frequência central com larguras de banda crescentes, conforme apresentado na Figura 30.

Figura 30 – Filtros triangulares usados no cálculo do MFCC.



Fonte: Huang *et al.* (2001).

Sejam  $f_l$  e  $f_h$ , respectivamente as frequências mais baixas e mais altas do banco de filtros,  $F_s$  a frequência de amostragem,  $M$  o número de filtros e  $N$  o tamanho da FFT. Os pontos de fronteira  $f[m]$  estão uniformemente espaçados na escala de mel, dados por

$$f[m] = \left(\frac{N}{F_s}\right) B^{-1} \left( B(f_l) + m \frac{B(f_h) - B(f_l)}{M+1} \right) \quad (3.41)$$

em que  $B$  é a escala melódica e  $B^{-1}$  é sua inversa calculada como

$$B^{-1}(b) = 700(e^{(b/1125)} - 1). \quad (3.42)$$

Para se calcular o logaritmo da energia da saída de cada filtro tem-se:

$$S[m] = \ln \left[ \sum_{k=0}^{N-1} |X_a[k]|^2 H_m[k] \right], \quad 0 \leq m < M \quad (3.43)$$

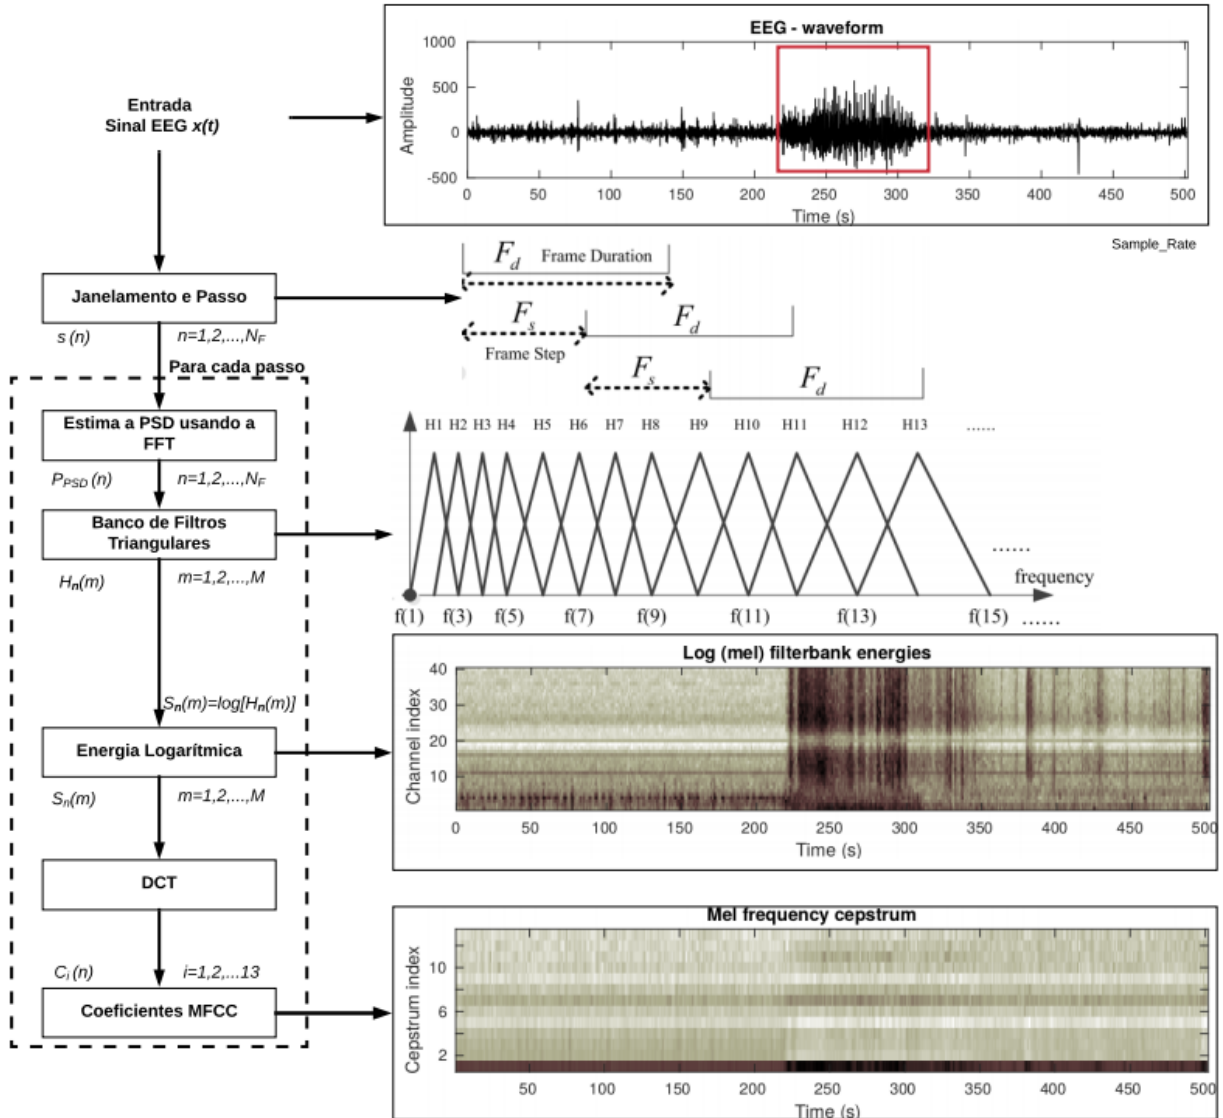
Então, a frequência mel cepstral é a transformada discreta do cosseno (DCT - Discrete Cosine Transform) das saídas do filtro  $M$ , escrito da seguinte forma:

$$c_{mel}[n] = \sum_{m=0}^{M-1} S[m] \cos \left[ \frac{\pi n(m+0.5)}{M} \right], \quad 0 \leq n < M \quad (3.44)$$

Na prática, a representação MFCC é aproximadamente homomórfica para filtros que apresentam uma função de transferência suave. A vantagem da representação MFCC usando a Equação (3.43) é que as energias de filtro são mais robustas aos erros de estimativa de ruído e espectral, o que é de grande interesse para o problema de interesse desta dissertação.

Esse algoritmo tem sido usado extensivamente como um vetor de recursos para sistemas de reconhecimento de fala e será utilizado para a detecção de crises epiléticas. Normalmente apenas os 12 primeiros coeficientes são utilizados (YUAN *et al.*, 2015).

Figura 31 – Passos e exemplo a aplicação do MFCC no EEG.



Fonte: do autor.

Na Figura 31, é apresentado um exemplo de aplicação do MFCC em um canal do EEG, em um sinal do paciente *CHB03* com cerca de 500 segundos. A seguir são descritos os passos necessários para o cálculo dos coeficientes MFCC.

1. enquadrar o sinal em pequenos quadros ou *frames*, cuja duração será denominada de  $F_d$ ;
2. utilizar uma janela deslizante que pode ou não ser sobreposta. Normalmente se utiliza 50% de sobreposição, no qual é definido o passo do *frame* ( $F_p$ );
3. em seguida, para cada *frame*, é calculado o periodograma (PSD);

4. após calcular a PSD em cada *frame*, é necessário aplicar o banco de filtros no espectro de potência e somar a energia em cada filtro  $H_m[k]$ ;
5. o próximo passo é calcular o logaritmo de todas as energias do banco de filtros;
6. aplicar a DCT em cada banco de filtros de energia;
7. selecionar os 12 primeiros coeficientes.

### 3.5 Matriz de Covariância como Extrator de Características

Os sinais do EEG são frequentemente analisados em segmentos de curta duração chamados de épocas, e normalmente é analisado apenas um canal por vez. Como descrito anteriormente, as crises epiléticas podem ser locais ou generalizadas, portanto é importante conhecer o comportamento de todos os canais simultaneamente. Então, seja uma matriz  $\mathbf{X}_p \in \mathbb{R}^{N_c \times T}$ , em que  $N_c$  representa o número de canais e  $T$  a duração do intervalo expresso em números de amostragem. Para cada  $\mathbf{X}_p$ , pode-se estimar a matriz espacial de covariância do sinal aleatório do EEG de acordo com:

$$\mathbf{C}_p = \frac{1}{T-1} \mathbf{X}_p \mathbf{X}_p^\top, \quad (3.45)$$

$$\mathbf{C}_p = \begin{bmatrix} C_{1,1} & C_{1,2} & C_{1,3} & \dots & C_{1,N_c} \\ C_{2,1} & C_{2,2} & C_{2,3} & \dots & C_{2,N_c} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ C_{N_c,1} & C_{N_c,2} & C_{N_c,3} & \dots & C_{N_c,N_c} \end{bmatrix}, \quad (3.46)$$

em que  $\mathbf{C}_p$  é a matriz espacial de covariância. Pode-se constatar que  $C_{ij} = C_{ji}$ , já que  $\mathbb{E}[(X_i - \mu_i)(X_j - \mu_j)^\top] = \mathbb{E}[(X_j - \mu_j)(X_i - \mu_i)^\top]$ , portando a matriz  $\mathbf{C}_p$  é do tipo simétrica e positiva definida<sup>4</sup> de dimensões  $N_c \times N_c$ .

Note que, a matriz  $\mathbf{C}_p$  é sensível a *outliers*, de modo que técnicas de estimativa de covariância robusta ou regularização podem ser aplicadas para melhorar o estimador (LEDOIT; WOLF, 2004). Em trabalhos onde se estuda a interface cérebro-computador (BCI - *Brain Computer Interfaces*) é muito comum usar a filtragem espacial para reduzir a dimensão e melhorar a relação de variância entre os testes de EEG provenientes de diferentes classes motoras (WU *et al.*, 2018). Lembrando que para uma amostra de 2 segundos de um EEG com

<sup>4</sup> Uma matriz simétrica  $\mathbf{A}$  é dita positiva definida se e somente se  $\mathbf{x} \mathbf{A} \mathbf{x}^\top > 0$ , para qualquer  $\mathbf{x} \neq \mathbf{0}$ .

23 canais a uma taxa de amostragem de  $F_s = 256Hz$  será formada uma matriz de dados com  $23 \times 256 = 11776$  elementos, já sua matriz espacial de covariância apresentará  $23 \times 23 = 529$  elementos.

O uso do logarítmico da variância dos sinais filtrados, geralmente obtidos com análise discriminante linear (LDA - *Linear Discriminant Analysis*) e os padrões espaciais comuns (CSP - *Common Spatial Patterns*) são aplicados com sucesso para extrair características relevantes para a classificação EEG registrados durante duas tarefas de imagens motoras distintas (RAMOSER *et al.*, 2000). Essa técnica visa simultaneamente a diagonalização das duas matrizes de covariância intra-classe obtidas nas duas condições diferentes. Essa observação motivou Barachant *et al.* (2013) a investigar o uso direto da matriz de covariância espacial como a *features* de entrada para a classificação do sinal de EEG em aplicações de BCI. É nessa motivação que será utilizado para distinguir os eventos relacionados a crises epiléticas.

Devido a matriz  $\mathbf{C}_p$  ser simétrica, pode-se considerar um operador que realiza uma meia-vetorização, o qual irá utilizar a matriz triangular superior ou inferior ( $\mathbf{C}_{ut}$ ) e posteriormente empilhar cada elemento em um vetor. Essa operação resultará em um vetor contendo  $N_c(N_c + 1)/2 + 1$  elementos.

$$\mathbf{C}_{ut} = \begin{bmatrix} C_{1,1} & \cdots & \cdots & \cdots & C_{1,N_c} \\ & C_{2,2} & \cdots & \cdots & C_{2,N_c} \\ & & \ddots & \cdots & \vdots \\ & & & \ddots & \vdots \\ & & & & C_{N_c,N_c} \end{bmatrix} \quad (3.47)$$

Dessa forma, será definido um operador  $\text{vect}(\mathbf{C}_p)$  que transformará um espaço de alta dimensão em uma forma vetorial da matriz de covariância ( $\mathbf{C}_p$ ). Porém, será necessário aplicar um coeficiente de ajuste ( $\sqrt{2}$ ) em todos os elementos não pertencentes a diagonal principal da matriz  $\mathbf{C}_{ut}$  com o objetivo de conservar a igualdade entre as normas de  $\|\mathbf{C}_p\|_F = \|\text{vect}(\mathbf{C})\|_2$ , em que  $\|\cdot\|_F$  denota a norma de Frobenius<sup>5</sup>. Dessa forma,  $\text{vect}(\mathbf{C}_p)$  é representado como:

$$\text{vect}(\mathbf{C}_p) = [C_{1,1}; \sqrt{2}C_{1,2}; C_{2,2}; \sqrt{2}C_{1,3}; \sqrt{2}C_{2,3}; C_{3,3}; \dots; C_{N_c,N_c}] \quad (3.48)$$

<sup>5</sup> Seja a  $p$ -norma  $\|A_{n \times m}\|_p = \left( \sum_{i=1}^m \sum_{j=1}^n |a_{ij}|^p \right)^{1/p}$ , para  $p = 2$  tem-se a norma de Frobenius.

### 3.6 Conclusão

Nesse capítulo foram apresentadas as características do sinal do EEG e os métodos de extração de características que serão utilizados para a construção dos vetores de atributos a serem utilizados na etapa de classificação. Os métodos propostos foram apresentados brevemente e a principal razão para o não aprofundamento na complexidade dos algoritmos é que, em geral, eles apresentam parâmetros bem diferentes, e a forma de como os vetores de atributos foram montados. Mais detalhes da metodologia serão apresentados no Capítulo 5.

Foi ainda apresentado o método da estimação de densidade espectral de potência no qual foi realizado uma revisão destacando o periodograma e o método de Welch. Em seguida destacou-se os coeficientes de uma codificação preditiva linear a partir de um modelo autorregressivo utilizando a expressão de Yule-Walker e os métodos dos momentos. Finalmente foi exposto o conceito de *cepstrum* e os coeficientes do MFCC, que apesar de serem técnicas aplicadas em sua maioria à problemas de áudio/fala podem contribuir na detecção de crises epiléticas. E por fim foi apresentado o método de extração no qual a abordagem é a vetorização da matriz de covariância espacial.

No capítulo seguinte, serão apresentadas os algoritmos de classificação que serão utilizadas para detecção de crises epiléticas.

## 4 CLASSIFICADORES

Neste capítulo será abordado o problema da classificação e os algoritmos que serão utilizados nas comparações deste trabalho. No contexto do processamento de sinais biomédicos, especialmente com a aplicação a sinais de EEG, a classificação de padrões é frequentemente necessária. Por exemplo, as latências dos canais no EEG podem ser utilizadas não apenas para diagnosticar o Alzheimer, mas também determinar o estágio da doença neuro-degenerativa. Outro exemplo, são as aplicações na área da BCI (*Brain-Computer Interface*) onde o tempo, a frequência e as características espaciais precisam ser classificadas. O objetivo da classificação é traçar um limite entre duas ou mais classes e rotulá-las com base em seus recursos medidos e em um espaço de recurso multidimensional. Segundo Duda *et al.* (2001), reconhecimento de padrões é o ato de tomar dados brutos e tomar uma ação ou decisão baseada na categoria do padrão.

Nos últimos tempos, a aplicação IA ou RP no diagnóstico médico é uma nova tendência cada vez sendo mais utilizada. Em sistemas de decisão assistida por computador (CAD), métodos de tecnologia da informação são adotados para ajudar um médico a diagnosticar a doença de um paciente. Entre as várias tarefas realizadas por um sistema de diagnóstico a auxílio, a classificação é a mais comum. Assim, o problema de classificação do banco de dados médico pode ser categorizado como uma classe de problema de otimização complexa com o objetivo de garantir o auxílio de diagnóstico com precisão.

Em um problema de classificação, o objetivo é construir ou aprender uma superfície de decisão que mapeia com precisão um espaço de recurso de entrada (atributos) para um espaço de saída de rótulos de classe. O desenvolvimento de classificadores envolve postular alguma forma geral de modelo, ou forma do classificador, e usar padrões de treinamento para aprender ou estimar os parâmetros desconhecidos do modelo. A aprendizagem refere-se a alguma forma de algoritmo para reduzir o erro em um conjunto de dados de treinamento. No campo da medicina, vários pesquisadores tentaram aplicar diversas técnicas para melhorar a precisão da classificação de dados, técnicas de classificação cuja precisão fornecerá informações suficientes para identificar os potenciais pacientes e, assim, melhorar a precisão do diagnóstico (BABU; SURESH, 2013; JIANG *et al.*, 2017).

Comumente se faz uso de classificadores clássicos, como rede perceptron multicamadas (*multilayer perceptron* - MLP) (RUIZ-GÓMEZ *et al.*, 2018) e SVM (LI *et al.*, 2018) para aplicações de reconhecimento de padrões em problemas nos quais as classes apresentam sobrepo-

sição. Porém, o uso desses algoritmos exigem um grande esforço computacional, principalmente na etapa de treinamento, inviabilizando o seu uso para aplicações embarcadas ou com baixo poder computacional. Devido ao grande volume dos conjuntos de dados que são utilizados nos problemas com EEG, será investigado o uso de classificadores aleatorizados como alternativa visando a otimização da velocidade da decisão e principalmente da etapa de treinamento.

Dessa forma, destacam-se os três classificadores que apresentam características aleatórias:

- baseado em Redes Neurais: Máquina de Aprendizado Extremo (HUANG *et al.*, 2015);
- baseado em métodos de *Kernel*: *Random Kitchen Sinks* (RAHIMI; RECHT, 2008b), e;
- classificador baseado em regressão de distâncias: máquina de aprendizado mínimo (SOUZA *et al.*, 2015).

A escolha desses classificadores aleatorizados partiu da hipótese de que se eles apresentarem um desempenho similar ao da SVM, eles serão candidatos a serem utilizados posteriormente em aplicações embarcadas ou que necessite de um treinamento rápido, eficiente e que possa ser usado tanto em uma classificação *on-line*, com resposta rápida, quanto em situações *off-line*.

Inicialmente, é importante definir alguns termos que serão amplamente utilizados durante este trabalho:

- **atributo**: uma característica do sistema a ser tratado, que serve de entrada para os classificadores;
- **amostra**: se refere a um vetor de atributos, descrevendo um objeto a ser classificado;
- **parâmetro**: uma variável do classificador, que é ajustada durante o treinamento;
- **hiperparâmetros**: uma variável do classificador, que deve ser definida antes do treinamento, para que este classificador se adapte ao problema ao qual ele se propõe a solucionar;
- **treinamento**: etapa na qual os parâmetros de um classificador são ajustados;
- **iteração de treinamento**: por iteração, entende-se o instante de apresentação de uma amostra de treinamento para ajustar os parâmetros de um classificador;
- **época de treinamento**: ocorre após todas as amostras de treinamento terem sido apresentadas (uma única vez cada) a um classificador, de modo a atualizar os parâmetros deste;
- **validação**: etapa na qual o algoritmo é aplicado a dados não utilizados durante o treinamento, e as estatísticas de desempenho do classificador são geradas;

- **realização:** quando finaliza-se as etapas de treinamento e teste, e valida-se o classificador com os dados restantes, ocorre uma realização do classificador, e;
- **generalização:** é a característica mais desejada de um classificador, visto que, quanto maior a capacidade de generalização deste, maior será sua taxa de acerto para novos dados (dados de validação).

#### 4.1 O problema da classificação

Muitos problemas no mundo dos negócios, ciência, indústria e medicina podem ser tratados como problemas de classificação. Exemplos incluem previsão de falências, reconhecimento de caracteres manuscritos, diagnóstico médico, controle de qualidade, detecção de falhas e reconhecimento de fala (ZHANG, 2000). Os métodos supervisionados de aprendizado de máquinas para regressão e classificação foram projetados principalmente para tipos de dados que se encontram em espaços vetoriais, ou seja, variáveis de saída (isto é, respostas) e/ou preditor (entradas) são frequentemente organizadas em vetores de dimensionalidade predefinida.

Formalmente, neste tipo de problema, assume-se de posse de um conjunto de  $N$  pares  $\{\mathbf{x}_n, C_n\}_{n=1}^N$ , em que o vetor coluna  $\mathbf{x}_n \in \mathbf{R}$  representa a  $n$ -ésima amostra de entrada e  $C_n$  é a classe à qual pertence  $\mathbf{x}_n$ . Assume-se ainda que se tem um número finito e pré-definido de  $K$  classes ( $K \ll N$ ), i.e.  $C_n \in \{C_1, C_2, \dots, C_K\}$ . Por fim, seja  $n_i$  o número de exemplos da  $i$ -ésima classe (i.e.  $C_i$ ), tem-se  $N = n_1 + n_2 + \dots + n_K = \sum_{i=1}^K n_i$ .

Dependendo do problema, há várias formas de codificar os rótulos das classes. Nesta dissertação, escolheu-se um vetor coluna  $d_n \in R^K$ , no qual a posição referente a classe à qual o dado de entrada pertence tem o valor +1 e as demais posições tem o valor -1. Como exemplo, se um problema tem 3 classes, e a amostra atual pertence à classe 2, seu rótulo será:  $d_n = [-1 + 1 - 1]^T$ . Assim, o problema aqui estudado possui  $N$  pares  $\{\mathbf{x}_n, \mathbf{d}_n\}_n^N = 1$ . O problema em questão pode ser tratado como binário ou multiclass. Se os dados forem rotulados em intervalos interictais e ictais, o problema em questão se torna binário ( $\pm 1$ ). Porém, se considerarmos os instantes rotulados como pré-ictais e pós-ictais o problema, é tratado como multiclass.

No restante do presente capítulo, tanto os algoritmos utilizados para o desenvolvimento deste trabalho como alguns conceitos importantes são explicados. Visando todas as vantagens dos classificadores aleatorizados, tais como rapidez de projeto e execução, escolhemos três deles: ELM, MLM e RKS. Para referenciar o experimento e comparar a performance desses



classificadores aleatorizados com classificadores já consagrados na literatura, optou-se pelo SVM. Além desses, o classificador linear MQ será utilizado.

## 4.2 Máquina de Aprendizado Extremo

Diferentemente da rede perceptron multicamadas, a Máquina de Aprendizado Extremo tem os pesos entre as camadas de entrada e oculta escolhidos aleatoriamente, enquanto os pesos entre as camadas oculta e de saída são determinados analiticamente. De acordo com (HUANG *et al.*, 2006), a rede ELM tem como objetivos alcançar uma alta precisão, com baixa intervenção humana (poucos parâmetros) e alta velocidade de treinamento. Com essas características, a ELM é uma rede neural de aprendizagem em tempo real (*Real-Time Learning*), que apresenta rápida velocidade de aprendizagem e de fácil implementação, sendo bastante utilizada em diversos problemas de classificação de padrões.

Vários autores têm aplicado a rede ELM (e as suas variantes) a uma amplo leque de problemas complexos de classificação de padrões e regressão (DING *et al.*, 2014; NEUMANN; STEIL, 2013). Destacam-se os trabalhos que utilizam a ELM para a detecção automática de epilepsia (SONG *et al.*, 2016; LI *et al.*, 2016). A ELM também foi utilizada na tarefa de identificação/classificação de padrões de classificação de imagens juntamente com a atividade cerebral, através do EEG (PENG; LU, 2016). Por fim, destaca-se uma aplicação que utiliza a ELM para o diagnóstico do transtorno do deficit de atenção com hiperatividade (PENG *et al.*, 2013).

Assumem-se  $N$  pares de dados  $\{(\mathbf{x}_n, \mathbf{d}_n)\}$ , em que  $\mathbf{x}_n \in \mathbb{R}^{p+1}$  é o  $n$ -ésimo padrão de entrada (atributos) e  $\mathbf{d}_n \in \mathbb{R}^K$  é o rótulo da classe alvo correspondente, sendo que  $K$  denota o número de classe. Observe que  $\mathbf{x}_n$  apresenta dimensão  $p + 1$  pela inclusão do limiar (*bias* ou viés). A partir do conjunto de dados, selecionam-se aleatoriamente  $N_1$  pares de dados, ( $N_1 < N$ ), e organizam-se os vetores em colunas. Dessa forma serão obtidas as matrizes  $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{N_1}]$  e  $\mathbf{D} = [\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_{N_1}]$ , que respectivamente representam a matriz de dados de entrada ( $(p + 1) \times N_1$ ) e de rótulos ( $K \times N_1$ ) do treinamento.

Portanto, para uma rede com  $p + 1$  entradas,  $q$  neurônios ocultos e  $K$  saídas, a  $i$ -ésima saída, para o  $n$ -ésimo padrão de entrada  $\mathbf{x}_n$ , é dada por:

$$\mathbf{y}_{i,n} = \mathbf{w}_i^\top \mathbf{h}_n, \quad (4.1)$$

em que  $\mathbf{w}_i \in \mathbb{R}^q$ ,  $i = 1, \dots, K$ , é o vetor que corresponde os pesos que conecta os neurônios

ocultos ao  $i$ -ésimo neurônio de saída, e  $\mathbf{h}_n \in \mathbb{R}^q$  é o vetor de saídas dos neurônios ocultos para um dado padrão de entrada  $\mathbf{x}(t) \in \mathbb{R}$ . O vetor de ativação dos neurônios ocultos na iteração  $n$ ,  $\mathbf{h}_n$ , é dado por:

$$\mathbf{h}_n = \phi(\mathbf{M}\mathbf{x}_n). \quad (4.2)$$

O vetor de ativação é composto por:

$$\mathbf{h}_n = [\phi(\mathbf{m}_1^\top \mathbf{x}_n + b_1), \dots, \phi(\mathbf{m}_q^\top \mathbf{x}_n + b_q)] \quad (4.3)$$

em que  $b_l, l = 1, \dots, q$ , é o limiar (*bias* ou viés) do  $l$ -ésimo neurônio oculto,  $\mathbf{m}_l \in \mathbb{R}^{p+1}$  é o vetor de pesos do  $l$ -ésimo neurônio oculto e  $\phi(\cdot)$  é uma função de ativação não linear. Os vetores de pesos  $\mathbf{m}_l$  são inicializados com valores aleatórios normalmente distribuídos de média nula e variância  $\sigma^2$ , ou seja  $w_{ij} = \mathcal{N}(0, \sigma^2)$ . Geralmente, a função de ativação ( $\phi$ ) assume geralmente as formas da função logística (4.4) ou tangente hiperbólica (4.5), dadas a seguir:

$$\phi_i(\mathbf{h}_i(n)) = \frac{1}{1 + \exp[-h_i(n)]}, \quad (4.4)$$

$$\phi_i(\mathbf{h}_i(n)) = \frac{1 - \exp[-h_i(n)]}{1 + \exp[-h_i(n)]}, \quad (4.5)$$

Finalizando a etapa de treinamento, define-se uma matriz  $\mathbf{Z} = [\mathbf{z}(1), \mathbf{z}(1), \dots, \mathbf{z}(N_1)]$  de dimensão  $q \times N_1$ , na qual as  $N_1$  colunas são os vetores de saída da camada oculta  $\mathbf{z}_n \in \mathbb{R}^q$ . E, de forma análoga, define-se a matriz  $\mathbf{W}$  ( $K \times q$ ), cuja  $i$ -ésima linha é o vetor de pesos  $\mathbf{w}_i^\top$  que é associado ao  $i$ -ésimo neurônio de saída. Portanto, o mapeamento linear entre essas matrizes é relacionado com a matriz de entrada  $\mathbf{D}$  e é dado por:

$$\mathbf{D} = \mathbf{W}\mathbf{Z}, \quad (4.6)$$

em que as matrizes  $\mathbf{D}$  e  $\mathbf{X}$  são conhecidas. É necessário estimar a matriz de pesos  $\mathbf{W}$ . Solucionado o sistema linear baseado no método dos mínimos quadrados, a matriz  $\mathbf{W}$  é dada por:

$$\mathbf{W} = \mathbf{D}\mathbf{Z}^\top (\mathbf{Z}\mathbf{Z}^\top)^{-1}, \quad (4.7)$$

em que a  $k$ -ésima linha da matriz  $\mathbf{W}$  corresponde ao vetor de pesos do  $k$ -ésimo neurônio de saída.

### 4.3 Máquina de Aprendizado Mínimo

Inicialmente projetada para problemas de regressão, a máquina de aprendizado mínimo é um algoritmo recente de aprendizado supervisionado que pressupõe a existência de um mapeamento entre as configurações geométricas de pontos no espaço de entrada e as configurações geométricas dos respectivos pontos no espaço de saídas. Mapeamento este que é representado por matrizes de distância de entrada e saída que são calculadas com respeito aos padrões de entrada e saídas desejadas e dois conjuntos de pontos de referência tomados nos espaços de entrada e saída, respectivamente. Assim, a capacidade de generalização destes modelos vem do mapeamento linear entre estas matrizes de distância (SOUZA *et al.*, 2015).

Como a MLM é um classificador do tipo supervisionado, é necessário primeiramente separar o banco de dados em conjunto de treinamento e conjunto de teste. No conjunto de treinamento, deve-se escolher aleatoriamente  $R$  pontos de referências, onde cada amostra possui suas entradas (atributos) e saídas (rótulos). O número de pontos de referência,  $R$ , é o único hiperparâmetro desse classificador.

Seja um conjunto de  $N$  pontos de entrada  $X = \{\mathbf{x}_i\}_{i=1}^N$ , em que  $\mathbf{x}_i \in \mathbb{R}^D$  e seus respectivos rótulos  $Y = \{\mathbf{y}_i\}_{i=1}^N$  e  $\mathbf{y}_i \in \mathbb{R}^S$ . Assume-se a existência de um mapeamento contínuo  $g: \mathcal{X} \rightarrow \mathcal{Y}$  entre os dados de entrada e o espaço de saída. O objetivo é estimar função a  $g(\cdot)$  a partir dos dados como um modelo de resposta múltipla. O algoritmo do MLM é composto por duas etapas distintas. A primeira é para reconstruir o mapeamento existente entre as distâncias de entrada e saída. E a segunda é estimar a resposta a partir da configuração dos pontos de saída.

O algoritmo possui duas etapas para a classificação: treinamento e teste. A etapa de treinamento é iniciada calculando a matriz  $\mathbf{D}_x \in \mathbb{R}^{N \times K}$ , na qual cada coluna  $k$  contém as distâncias  $d(\mathbf{x}_i, \mathbf{m}_k)$ , em que a distância  $d(\mathbf{x}_i, \mathbf{m}_k)$  representa a distância entre os  $N$ -pontos de entrada  $\mathbf{x}_i$  e os  $k$ -pontos de referência  $\mathbf{m}_k$ . O segundo passo dessa etapa é, de forma análoga a anterior, calcular a matriz  $\Delta_y \in \mathbb{R}^{N \times K}$  em que cada coluna  $k$  contém as distâncias  $\delta(\mathbf{y}_i, \mathbf{t}_k)$ , que representa a distância entre os  $N$ -pontos de saída  $\mathbf{y}_i$  e os  $k$ -pontos de referência da saída.

De posse das matrizes de distâncias  $\mathbf{D}_x$  e  $\Delta_y$ , o mapeamento  $g(\cdot)$  pode ser estimado através de um modelo de regressão linear, dada por:

$$\Delta_y = \mathbf{D}_x \mathbf{B} + \mathbf{E}, \quad (4.8)$$

em que  $\mathbf{E}$  corresponde aos resíduos e  $\mathbf{B} \in \mathbb{R}^{K \times K}$  é uma matriz que deve ser estimada a partir dos dados.

A estimação da matriz  $\mathbf{B}$  é feita através do método dos mínimos quadrados, sendo então a estimativa  $\hat{\mathbf{B}}$  dada por

$$\hat{\mathbf{B}} = (\mathbf{D}_x^\top \mathbf{D}_x)^{-1} \mathbf{D}_x^\top \Delta \mathbf{y}. \quad (4.9)$$


A etapa de teste consistem em, para cada amostra de teste  $\mathbf{x}_i$ , calcular um vetor  $\mathbf{d} \in \mathbb{R}^{1 \times K}$ , em que cada elemento desse vetor representa a distância entre a saída dos pontos de referência e da amostra  $\mathbf{x}_i$ . Em seguida estima-se as distâncias entre as saídas da amostra  $\mathbf{x}_i$  e dos pontos de referência, através da relação

$$\hat{\delta}(\mathbf{y}, \mathbf{t}_k) = \mathbf{d} \hat{\mathbf{B}}, \quad (4.10)$$

em que cada elemento de  $\hat{\delta}(\mathbf{y}, \mathbf{t}_k) \in \mathbb{R}^{1 \times K}$  é a representação a distância entre os pontos referência e a da amostra  $\mathbf{x}_i$ .

A estimação da saída  $\hat{\mathbf{y}}$  a partir dos pontos fixos e das distâncias entres estes pontos e a saída consiste em um problema de multilateração (SOUZA *et al.*, 2013). Que no ponto de vista geométrico, a localização de  $\mathbf{y} \in \mathbb{R}^S$  equivale a resolver o conjunto determinado de  $K$  de equações não lineares correspondentes às hipersferas de dimensão  $S$  centradas em  $\mathbf{t}_k$  e passando através da saída  $\mathbf{y}$ . Na Figura 32 é apresentado um exemplo para  $S = 2$ .

Figura 32 – Problema da multilateração na estimação da saída.



Fonte: Souza *et al.* (2015).

Observa-se que o raio de cada esfera é igual à  $\hat{\delta}(\mathbf{y}, \mathbf{t}_k)$ , dessa forma:

$$(\mathbf{y} - \mathbf{t}_k)^\top (\mathbf{y} - \mathbf{t}_k) = \hat{\delta}^2(\mathbf{y}, \mathbf{t}_k). \quad (4.11)$$

A saída é estimada pela minimização da seguinte função custo:

$$J(\mathbf{y}) = \arg \min_{\mathbf{y}} \left[ \sum_{k=1}^K \left( (\mathbf{y} - \mathbf{t}_k)^\top (\mathbf{y} - \mathbf{t}_k) - \hat{\delta}^2(\mathbf{y}, \mathbf{t}_k) \right) \right]. \quad (4.12)$$


Várias estratégias podem ser usadas para resolver um problema de multilateração (NAVIDI *et al.*, 1998). Neste trabalho, foi utilizado o algoritmo de Levenberg-Marquardt. Este algoritmo é capaz de solucionar um sistema de equações não lineares.

#### 4.4 Random Kitchen Sinks

Esta seção descreve os conceitos matemáticos envolvidos no algoritmo *Random Kitchen Sinks*. Os métodos de *kernel* fornecem uma abordagem elegante, teoricamente bem fundamentada para tratar problemas de aprendizagem. Algoritmos tradicionais requerem o cálculo de uma matriz de *kernel* de dimensão  $N \times N$  para solucionar problemas de aprendizagem para  $N$  vetores de entrada, porém, a aplicação desses métodos para conjuntos de dados de grande escala, contendo milhares de observações tem provado ser um desafio.

O método *kernel* contém uma função denominada função *kernel*. Essa função mapeia o espaço de entrada separável não linear em um espaço de característica separável linear de dimensional maior, conforme é apresentado graficamente na Figura 33.

Figura 33 – Representação da transformação de kernel.



Fonte: Rahimi e Recht (2008a).

Rahimi e Recht (2008a) deram início a uma abordagem que faz uma aproximação a uma *kernel* invariante ao deslocamento. Seja a função  $\phi(\mathcal{X} \times \mathcal{X}) \rightarrow \mathbb{R}$ , na qual:

$$\phi(\mathbf{x}, \mathbf{y}) = \langle \phi(x), \phi(y) \rangle \approx z(\mathbf{x}^\top)z(\mathbf{y}), \quad (4.13)$$

em que  $z: \mathcal{X} \rightarrow \mathbb{R}^D$ . Portanto, o método primal em  $\mathbb{R}^D$  pode ser usado, permitindo a resolução da maioria dos problemas de interesse em tarefas de aprendizagem de máquinas (SUTHERLAND; SCHNEIDER, 2015).

Para aproximar o RKHS (*Reproducing kernel Hilbert space*) induzido pelo kernel Gaussiano

$$\begin{aligned} \phi(\mathbf{x}, \mathbf{x}_i) &= \exp \left[ -\frac{\|\mathbf{x} - \mathbf{x}_i\|^2}{\sigma^2} \right] \\ &= \exp \left[ -\frac{1}{2}(\mathbf{x} - \mathbf{x}_i)^\top \Sigma^{-1}(\mathbf{x} - \mathbf{x}_i) \right], \end{aligned} \quad (4.14)$$

em que  $(\Sigma)$  a matriz de covariância. O *kernel* pode ser expresso como uma função de densidade de probabilidade gaussiana. Como  $(\Sigma)$  é uma matriz diagonal, a função de densidade gaussiana pode ser escrita como produto de  $n$  funções gaussianas e, portanto, as variáveis associadas são independentes quando o *kernel* é interpretado como uma função de densidade de probabilidade.

Seja  $\mathbf{x} - \mathbf{x}_i = \mathbf{z}$ , então a função de *kernel* pode ser escrita como

$$f(\mathbf{z}) = \exp \left[ -\frac{1}{2}\mathbf{z}^\top \Sigma^{-1}\mathbf{z} \right] \quad (4.15)$$

e a sua transformada de Fourier  $F(\Omega)$ . Dessa forma,  $F(\Omega)$  é uma função gaussiana multivariada com variância  $\sigma^2$  e é interpretada como uma função de densidade Gaussiana. Portanto a função de *kernel* é a transformada inversa de Fourier  $F(\Omega)^{-1} = \langle \phi(\mathbf{x}), \phi(\mathbf{x}_i) \rangle$ , que é apenas uma densidade gaussiana multivariada com média nula e matriz de covariância  $2\sigma^2 I$ . Uma consequência direta dessa abordagem é que o classificador RKS se torna muito semelhante em estrutura à rede ELM.

Assim, para cada vetor de entrada  $x_n$ , é calculado o mapeamento aproximado (ANEESH *et al.*, 2015), dado por:

$$\mathbf{h}_n = \phi(\mathbf{M}\mathbf{x}_n) = [\phi(\mathbf{m}_1^\top \mathbf{x}_n + b_1), \dots, \phi(\mathbf{m}_q^\top \mathbf{x}_n + b_q)]^\top \quad (4.16)$$

em que  $\mathbf{m}_i \sim \mathcal{N}(\mathbf{0}, 2\gamma\mathbf{I})$  e  $b_i \sim \mathcal{U}(-\pi, \pi)$ .

A saída da função de *kernel*, nesse método é dada por:

$$f(\mathbf{x}) = \sum_{i=1}^{\infty} \alpha_i k(x; x_i), \quad (4.17)$$

que é equivalente a uma superfície linear de decisão (hiperplano)  $f(\mathbf{x}) = \langle w_i, \phi(\mathbf{x}) \rangle$ .


#### 4.5 Máquina de Vetor de Suporte

Considere um problema linearmente separável, apresentado na Figura 34, em que as soluções deste podem ser representadas, matematicamente, pela equação de um hiperplano, dada por:

$$\mathbf{w}^\top \mathbf{x}_n + b = 0, \quad (4.18)$$

em que  $\mathbf{w}$  é um vetor de peso,  $b$  é o *bias* ou viés, e  $\mathbf{x}_n$  é uma amostra de entrada.

Figura 34 – Os hiperplanos descrevem possíveis soluções para um problema linearmente separável.



Fonte: do autor.

Caso um hiperplano consiga agrupar todas as amostras em uma determinada classe em posição oposta ao da outra, este hiperplano irá ser uma solução para o problema em estudo. Dessa forma, o hiperplano que pode ser solução para o sistema deve obedecer as seguintes restrições:

$$\begin{aligned} \mathbf{w}^\top \mathbf{x}_i + b &\geq a \rightarrow d_i = +1, \\ \mathbf{w}^\top \mathbf{x}_i + b &\leq -a \rightarrow d_i = -1, \end{aligned} \quad (4.19)$$

em que  $a > 0$ , e  $\mathbf{x}_i$  representa a  $i$ -ésima amostra de treinamento. Neste problema, existem infinitos hiperplanos que podem dividir as amostras de entrada em dois espaços multidimensionais

distintos.

Dentre todos os possíveis hiperplanos, deve-se escolher como solução aquele hiperplano que possua a máxima distância em relação aos padrões mais próximos de treinamento, ou seja, possua a maior margem de separação. Este hiperplano é definido como ótimo e representado pela equação:

$$\mathbf{w}_o^\top \mathbf{x}_i + b_o = 0. \quad (4.20)$$

Para problemas de classificação binários, o classificador SVM pode ser descrito através da seguinte função discriminante:

$$g(\mathbf{x}) = \text{sign}(\mathbf{w}_o^\top \mathbf{x}_i + b_o), \quad (4.21)$$

dessa forma,

$$\begin{aligned} \mathbf{w}^\top \mathbf{x}_i + b < 0 &\rightarrow f(\mathbf{x}) = -1, \\ \mathbf{w}^\top \mathbf{x}_i + b \geq 0 &\rightarrow f(\mathbf{x}) = +1. \end{aligned} \quad (4.22)$$

A obtenção do hiperplano ótimo, cujo intuito é encontrar os valores de  $\mathbf{w}_o$  e  $b_o$  a partir dos dados de treinamento, é à Equação (4.20) as seguintes restrições:

$$\begin{aligned} \mathbf{w}^\top \mathbf{x}_i + b \leq -1 &\rightarrow d_i = -1, \\ \mathbf{w}^\top \mathbf{x}_i + b \geq +1 &\rightarrow d_i = +1, \end{aligned} \quad (4.23)$$

assim, as amostras de treinamento que satisfazem a igualdade na equação anterior são denominadas vetores de suporte e são as que possuem a menor distância ao hiperplano ótimo.

Durante o treinamento dos classificadores SVM, busca-se maximizar a margem de separação. Isto é conseguido através da minimização da norma do vetor de pesos representada pela função

$$J(\mathbf{w}) = \frac{1}{2} \mathbf{w}^\top \mathbf{w} = \frac{1}{2} \|\vec{w}\|^2, \quad (4.24)$$

em que  $J(\mathbf{w})$  é a função a ser minimizada (VAPNIK, 1999).

Logo, pode-se apresentar o problema clássico de obtenção dos parâmetros ótimos como o seguinte problema de otimização:

$$\begin{aligned} \min J(\mathbf{w}) &= \min \frac{1}{2} \mathbf{w}^\top \mathbf{w} \\ \text{sujeito a } d_i[\mathbf{w}^\top \mathbf{x}_i + b] &\leq 1, i = 1, \dots, n \end{aligned} \quad (4.25)$$



O problema de otimização com restrição anteriormente citado é conhecido como problema primal, e pode ser solucionado pelo método de Lagrange, utilizando a seguinte função Lagrangiana:

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2} \mathbf{w}^\top \mathbf{w} - \sum_{i=1}^N \alpha_i (d_i [\mathbf{w}^\top \mathbf{x}_i + b] - 1), \quad (4.26)$$

em que  $\alpha_i > 0$  são denominados os multiplicadores de Lagrange.

A solução deste problema de otimização é determinada pelo ponto de sela da função lagrangiana (minimizada em relação a  $w$  e  $b$  e maximizada em relação ao vetor de coeficientes de Lagrange). Nestas condições, desenvolvendo-se a equação anterior, chega-se ao problema de otimização dual, dado por:

$$\begin{aligned} \max L(\alpha) = \max \left\{ \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j d_i d_j \mathbf{x}_i^\top \mathbf{x}_j \right\}, \\ \text{sujeito a } \sum_{j=1}^n \alpha_j d_j; \\ \alpha_i \geq 0, \forall i. \end{aligned} \quad (4.27)$$

Essa minimização é feita ao substituir os resultados das derivadas parciais da Equação (4.26) por  $w$  e  $b$  nesta própria equação. Ou seja,

$$\frac{\partial L(\mathbf{w}, b, \alpha)}{\partial \mathbf{w}} = 0 \quad \text{e} \quad (4.28)$$

$$\frac{\partial L(\mathbf{w}, b, \alpha)}{\partial b} = 0, \quad (4.29)$$

que resultam respectivamente em

$$\mathbf{w} = \sum_{i=1}^n \alpha_i d_i \mathbf{x}_i, \quad \text{e} \quad (4.30)$$

$$\sum_{i=1}^n \alpha_i d_i \mathbf{x}_i = 0. \quad (4.31)$$

Ao solucionar este problema, encontram-se os multiplicadores de Lagrange ótimos. Por fim, através dos multiplicadores de Lagrange ótimos, calculam-se o hiperplano ótimo  $\mathbf{w}_o$  e  $b_o$  liminar ótimo pelas Equações (4.30) e (4.31).

Portanto, reescrevendo a função discriminante definida anteriormente e usando os resultados  $\mathbf{w}_o$  e  $b_o$ , tem-se que:

$$g(\mathbf{x}) = \text{sign}\left(\sum_{i=1}^N \alpha_i^o d_i \mathbf{x}_i \mathbf{x} + b_o\right). \quad (4.32)$$

No problema de otimização primal desenvolvido até o momento, conhecido como SVM de margem rígida, considera que existe um hiperplano que separa totalmente as duas classes. No entanto, nos dados reais, na maioria das vezes, há sobreposição entre alguns padrões pertencentes a classes distintas, ou mesmo pela presença de *outliers* no dados.

Para contornar esse problema na classificação, é necessário fazer uma flexibilização da margem de separação. Esse procedimento, durante o treinamento é realizado no intuito de reduzir erros. Portanto, alguns erros serão permitidos de modo a reduzir a complexidade da função discriminante e melhorar o desempenho para o conjunto de teste.

Posta a motivação, a formulação a seguir permite um relaxamento das restrições, ou seja:

$$d_i[\mathbf{w}^\top \mathbf{x}_i + b] \leq 1 - \xi_i, i = 1, \dots, n, \quad (4.33)$$

em que  $\xi_i$  é denominados de variáveis de folga.

O problema de otimização primal dos classificadores SVM de margem flexível pode ser definido como:

$$\begin{aligned} \min J(\mathbf{w}, \xi) &= \min \frac{1}{2} \mathbf{w}^\top \mathbf{w} + C \sum_{i=1}^n \|\xi\|_i, \\ \text{sujeito a } d_i[\mathbf{w}^\top \mathbf{x}_i + b] &\leq 1, i = 1, \dots, n; \\ \xi_i &\geq 0, i = 1, \dots, n, \end{aligned} \quad (4.34)$$

em que  $C$  é a constante responsável pela regularização entre o primeiro e o segundo termo da função a ser otimizada. Esta constante é um hiperparâmetro dos classificadores SVM de margem flexível. A partir do problema formulado anteriormente, pode-se perceber que tanto se tenta maximizar a margem de separação entre as classes (através da minimização de  $\frac{1}{2} \mathbf{w}^\top \mathbf{w}$ ) como tenta-se minimizar os valores das variáveis de folga ( $\xi_i$ ).

De forma análoga à anterior, será usada a função lagrangiana para solucionar esse problema de otimização, formulado como:

$$L(\mathbf{w}, b, \xi, \alpha, \beta) = \frac{1}{2} \mathbf{w}^\top \mathbf{w} + C \sum_{i=1}^N \xi_i - \sum_{i=1}^N \alpha_i [d_i(\mathbf{x}_i^\top \mathbf{w}) - 1 + \xi_i] - \sum_{i=1}^N \beta_i \xi_i \quad (4.35)$$

em que  $\alpha$  e  $\beta$  são os multiplicadores de Lagrange.


Desenvolvendo a Equação (4.35), o problema de otimização dual para o classificador SVM de margem flexível é dado por:

$$\begin{aligned} \max L(\alpha) = \max \left\{ \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j d_i d_j \mathbf{x}_i^\top \mathbf{x}_j \right\}, \\ \text{sujeito a } \sum_{i=1}^n \alpha_i d_i = 0; \\ 0 \leq \alpha_i \leq C, i = 1, \dots, n. \end{aligned} \quad (4.36)$$

Observa-se que a diferença entre este problema dual e o da Equação (4.27) é a restrição aplicada aos multiplicadores de Lagrange  $\alpha_i$ . Assim, tanto o classificador de margem rígida, como o de margem flexível, são formatados para solucionar problemas linearmente separáveis. No entanto, existem inúmeros problemas reais no qual a separação linear dos dados entre classes não é possível.

Por isso, para tratar do problema citando anteriormente, são utilizadas funções de *kernel*  $\phi(\mathbf{x}; \mathbf{x}_i)$  aos classificador SVM, para que os dados possam ser mapeados em um espaço de características de dimensão superior, fazendo com que, neste novo espaço, o problema se torne linear. As representações dos espaços de entrada, de características e de *kernel* podem ser visualizados na Figura 35. Ao utilizar estas funções, evita-se o uso explícito de um espaço de características de elevada dimensão, trabalhando-se indiretamente neste (SCHÖLKOPF *et al.*, 2002).

Figura 35 – Truque do *Kernel*.



Fonte: Schölkopf *et al.* (2002).

Ademais, para qualquer função contínua e simétrica  $K(x,y)$  que satisfaça o teorema

de Mercer (HAYKIN, 2007), existem um espaço de Hilbert  $H$ , no qual há um mapeamento  $\phi : R^N \rightarrow H$  e um número  $\beta_i > 0$ , no qual

$$K(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^M \beta_i \tilde{\phi}_i(\mathbf{x}) \tilde{\phi}_i(\mathbf{y}), \quad (4.37)$$

em que  $M$  é a dimensionalidade do espaço de Hilbert (SCHÖLKOPF *et al.*, 2002). Definindo  $\phi_i(\cdot) = \tilde{\phi}_i(\cdot) \sqrt{\beta_i}$ , desenvolvendo a Equação (4.37) e substituindo o valor de  $\phi_i(\cdot)$ , obtém-se

$$K(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^M \phi_i(\mathbf{x}) \phi_i(\mathbf{y}), \quad (4.38)$$

no qual  $K(\mathbf{x}, \mathbf{y})$  pode ser representado como um produto interno dos vetores no espaço de características, portanto:

$$K(\mathbf{x}, \mathbf{y}) = \phi_i^\top(\mathbf{x}) \phi_i(\mathbf{y}). \quad (4.39)$$

Esse procedimento, e a Equação (4.39), é denominado truque do *kernel*. Dentre os tipos de *kernels* destacam-se: o linear, o polinomial, e o gaussiano (HAYKIN, 2007). Neste trabalho, utilizaremos o kernel gaussiano, dado por:

$$\phi(\mathbf{x}, \mathbf{x}_i) = \exp \left[ -\frac{\|\mathbf{x} - \mathbf{x}_i\|^2}{\sigma^2} \right], \quad (4.40)$$

em que  $\sigma^2$  é um hiperparâmetro a ser definido e  $\|\mathbf{x} - \mathbf{x}_i\|^2$  é a distância euclidiana entre as amostras. Portanto, o problema de otimização dual torna-se:

$$\begin{aligned} \max L(\alpha) = \max \left\{ \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j d_i d_j \phi(\mathbf{x}_i^\top \mathbf{x}_j) \right\}, \\ \text{sujeito a } \sum_{i=1}^n \alpha_i d_i = 0; \\ 0 \leq \alpha_i \leq C, i = 1, \dots, n. \end{aligned} \quad (4.41)$$

Então, sua função discriminante é dada por:

$$g(\mathbf{x}) = \text{sign} \left( \sum_{i=1}^N \alpha_i^o d_i \phi(\mathbf{x}_i, \mathbf{x}) + b_o \right). \quad (4.42)$$

## 4.6 Conclusão

Neste capítulo, foram apresentadas as definições e a formalização do problema de classificação. Também foram apresentados os classificadores utilizados para detecção de crise epilética nesta dissertação, iniciando com os aleatorizados (ELM, MKM e RKS), entradas e

saídas dos mesmos, assim como a notação matemática utilizada no problema de classificação. E finalmente foi apresentado o classificador SVM. Após a descrição de cada algoritmo de aprendizado de máquina e das técnicas utilizadas, juntamente com estes, para a detecção de crises epiléticas, no próximo capítulo serão detalhadas os procedimentos experimentais adotados nesse trabalho.

## 5 METODOLOGIA DOS EXPERIMENTOS

Neste capítulo, serão descritos todos os procedimentos realizados para realização dos testes de classificação e obtenção dos resultados. Serão apresentadas toda a preparação do banco de dados, a montagem dos vetores de atributos, as configurações e estimação dos hiperparâmetros dos classificadores e as técnicas de comparação dos diversos cenários a serem avaliados nesta dissertação.

### 5.1 Banco de Dados de EEG

Os registros de EEG (*EEG Data Set*) que foram utilizados neste trabalho constituem a base de dados CHB-MIT<sup>1</sup> (GOLDBERGER *et al.*, 2000), dados utilizado no trabalho de Shoeb (2009). Os dados são públicos e estão disponíveis no PhysioNet. O conjunto de dados contém 23 pacientes pediátricos do Hospital Infantil de Boston e um paciente adulto proveniente do *Beth Israel Deaconess Medical Center*.

Os pacientes apresentavam idade entre 1,5 e 24 anos, sendo 6 do gênero masculino e 17 do gênero feminino, e os exames foram realizados após a retirada de medicação para avaliação de cirurgia de remoção de foco epilético. Os exames de EEG foram realizados com uma taxa de amostragem ( $F_s$ ) de 256 Hz, com resolução de 16-bits e montagem bipolar de entre 10 a 18 eletrodos (23 canais, ou mais em alguns casos) de acordo com a montagem bipolar do padrão internacional 10-20 de disposição dos eletrodos, conforme mostrado na Figura 14, no Capítulo 2.

O conjunto de dados consiste em 916 horas de EEG contínuo. Enquanto as gravações estavam sendo feitas, ocorreram 173 eventos que foram julgados como convulsões ocasionadas por crise epilética por especialistas. Para cada crise clínica, um especialista indicou a alteração mais precoce do EEG associada à convulsão rotulando os dados. Os dados foram segmentados, normalmente, em registros de uma hora de duração e chegando até a arquivos com 4 horas de duração. A Tabela 5 apresenta um resumo dos dados dos pacientes desse banco de dados destacando o número de crises e o intervalo médio de duração da crise (em segundos).

### 5.2 Preparação dos Arquivos

Nesta seção, será apresentado o procedimento adotado para a organização, separação e testes com os arquivos. Considere o exemplo do paciente CHB01 apresentado na Tabela 6, que

<sup>1</sup> CHB-MIT Scalp EEG Database disponível em <https://physionet.org/physiobank/database/chbmit/>

Tabela 5 – Resumo dos dados dos pacientes diagnosticados com epilepsia.

Paciente	Gênero	Idade	Número de Crises	Intervalo Médio das Crises (s)
chb01	F	11	7	63,14
chb02	M	11	3	57,33
chb03	F	14	7	57,43
chb04	M	22	4	94,50
chb05	F	7	5	111,60
chb06	F	1,5	10	15,30
chb07	F	14,5	3	108,33
chb08	M	3,5	5	183,80
chb09	F	10	4	98,25
chb10	M	3	7	63,86
chb11	F	12	3	268,67
chb12	F	2	40	36,95
chb13	F	3	12	44,58
chb14	F	9	8	21,13
chb15	M	16	20	99,60
chb16	F	7	10	8,40
chb17	F	12	3	97,67
chb18	F	18	6	52,83
chb19	F	19	3	78,67
chb20	F	6	8	36,75
chb21	F	13	4	49,75
chb22	F	9	3	68,00
chb23	F	6	7	60,57
chb24	M	24	16	31,88

Fonte: o autor.

apresenta ao todo sete crises epiléticas com uma duração total de 442 segundos.

Tabela 6 – Exemplo de separação dos arquivos para testes do paciente CHB01.

-	Arquivo	Horário	Nº Crises	Início	Fim	Duração
<b>A</b>	chb01_03.edf	13:43:04 14:43:04	1	2996	3036	40
<b>B</b>	chb01_04.edf	14:43:12 15:43:12	1	1467	1494	27
<b>C</b>	chb01_15.edf	01:44:44 02:44:44	1	1732	1772	40
<b>D</b>	chb01_16.edf	02:44:51 03:44:51	1	1015	1066	51
<b>E</b>	chb01_18.edf	04:45:06 05:45:06	1	1720	1810	90
<b>F</b>	chb01_21.edf	07:33:46 08:33:46	1	327	420	93
<b>G</b>	chb01_26.edf	12:34:22 13:13:07	1	1862	1963	<b>101</b>

Fonte: o autor.

Todos os arquivos foram, a princípio, visualizados para verificar a presença de dados inconsistentes, artefatos ou outros tipos de ruídos que possam comprometer a extração de atributos e, conseqüentemente, os testes de classificação. Para tal tarefa, foi utilizada a

*Toolbox* EEGLAB (DELORME; MAKEIG, 2004). Para cada arquivo, foram realizados os quatro procedimentos de extração de atributos propostos neste trabalho.

O contexto no qual se enquadra o fenômeno da crise epiléptica no tocante à classificação é de um grande desbalanceamento das classes. Ainda observando a Tabela 6, nota-se que de um total de mais de seis horas e meia (06:38:45) de dados somente 442 segundos são rotulados como crise, correspondendo a menos de 2%. Para contornar esse problema, foi adotado o seguinte procedimento, descrito a seguir:

- para a realização o do teste de longa duração, foi separado somente o arquivo que apresente a maior duração de crise, no exemplo o arquivo **G**. A realização dos testes utilizará dados não utilizados para o treinamento.
- os intervalos rotulados como ictais dos outros arquivos (**A** ao **F**) foram concatenados e separados gerando um arquivo apenas com a crises do paciente CHB01, totalizando um tempo de intervalos ictais ( $t_{ic}$ ) de 341 segundos;
- para o treinamento, foi escolhido de forma aleatória um trecho contínuo (entre os arquivos **A** até **F**), totalizando uma quantidade de intervalos interictais ( $t_{iic}$ ) de quatro vezes  $t_{ic}$ , de forma que se mantenha a proporção de no mínimo 75%, reduzindo assim o desbalanceamento na etapa de treinamento.

### 5.3 Montagem dos Vetores de Características

Como destacado anteriormente, no Capítulo 3 seção 3.1, o sinal do EEG é extremamente não-estacionário. Da forma como os vetores de atributos são construídos, é necessário primeiramente definir um intervalo mínimo no qual será considerado o sinal de EEG estacionário. Assumindo que a duração de um intervalo estacionário mínimo geralmente não seja menor do que 2 segundos, como relatado em McEwen e Anderson (1975), o procedimento de segmentação de EEG em fragmentos estacionários consistiria em alguns estágios. No primeiro estágio, um sinal do EEG é dividido em segmentos elementares, denominados de épocas ( $L$ ), com 2 segundos de comprimento cada.

No segundo estágio, cada segmento é representado por um certo conjunto de características, por exemplo, estimativas espectrais. No terceiro estágio, usando um dos procedimentos estatísticos multivariados, os segmentos elementares de EEG são atribuídos a uma dentre as várias classes, de acordo com suas características. Assim, o registro do EEG é transformado em uma série de segmentos dentro dos quais os parâmetros do EEG permanecem relativamente



constantes. Cada um desses segmentos estacionários é caracterizado por sua duração específica e características tipológicas. Se o número de tipos de segmento no EEG real não for muito alto, a ideia de organização estacionária do EEG por partes oferecerá vantagens explícitas sobre o conceito primário alternativo do EEG como um processo estocástico estacionário contínuo.


### 5.3.1 PSD Método de Welch

A maioria dos estudos em humanos utilizando EEG, realizados como parte da avaliação pré-cirúrgica em pacientes com epilepsia intratável, relatam uma faixa de frequência limitada entre 0,1–30 Hz de atividade de EEG (WORRELL *et al.*, 2004). Esta faixa de frequência limitada pode refletir o fato de que oscilações com frequências acima de 30 Hz são de amplitude relativamente baixa e são obscurecidas por atividades de menor frequência. A maioria dos sistemas EEG comerciais emprega filtros *low-pass* com frequências de corte de 70 a 100 Hz e somado a isso o comportamento do período ictal ser normalmente característico de oscilações de baixa frequência. Já segundo (SHOEB, 2010) a redistribuição de energia espectral é causada pelo sincronismo de neurônios em uma crise epiléptica consiste no surgimento ou desaparecimento de componentes de frequência dentro da banda 0-25 Hz. Neste trabalho será limitado à frequência de 30Hz.

Após o início da maioria das convulsões, os canais de EEG que registram a atividade cerebral dentro das regiões envolvidas na convulsão exibem atividade rítmica. A estrutura espectral dessa atividade rítmica pode ser composta de múltiplos componentes de frequência. Como exemplo, a Figura 36 ilustra a PSD de um evento de crise epiléptica comparado com a PSD de um momento interictal. Para essa crise, a atividade rítmica no canal FP1 - F7 e a principal componente de frequência situa-se entre 0-5Hz. Nota-se uma sobreposição da frequência após cerca de 10Hz.

Usando um exemplo de outro paciente, CBH02, em que se observa um comportamento distinto, porém mantendo a característica em que na média o valor da densidade espectral de potência é sempre maior no período ictal do que no interictal. De fato, é o que se espera, pois a crise epiléptica é a descarga síncrona anormal de um conjunto de neurônios, gerando uma maior liberação de energia. No entanto, cada paciente apresentará um comportamento distinto, tanto no período ictal quanto no interictal. No exemplo a seguir, Figura 37, nota-se que no período ictal há uma componente espectral dominante entre 2-9 Hz. A frequência dominante de uma convulsão pode estar sobrepondo-se à frequência de uma atividade de atividade não convulsiva,


Figura 36 – Comparação entre as PSD em intervalos ictais e interictais.  
Segmento de 2s do paciente CHB01 canal FP1-F7.



Fonte: do autor.

mas é distinguida pela presença ou ausência dos componentes espectrais dominantes (SHOEB, 2009).

Figura 37 – Comparação entre as PSD em intervalos ictais e interictais.  
Segmento de 2s do paciente CHB02 canal FP1-F7.




Fonte: do autor.

Por fim, é apresentado um terceiro exemplo (Figura 38) retirado do canal F3-C3 do paciente CBH03 em que é possível observar que toda a faixa de frequência do período ictal fica

destacado acima do período interictal. Esse paciente teve uma crises com espículas de ondas generalizadas, ou seja em todos os canais.

Figura 38 – Comparação entres as PSD em intervalos ictais e interictais. Segmento de 2s do paciente CHB03 canal FP1-F7.



Fonte: do autor.

Esse três exemplos apresentados demonstram o quanto podemos obter de informação através da análise do espectro de potência. Porém, é necessário reunir toda essa informação em um vetor de característica, no qual o mesmo possa ser usado como entrada no classificador.

Dessa forma o vetor de características construído através do periodograma pode ser obtido através dos seguintes passos:


- **Passo 1** - para a época atual de EEG, é aplicado o método de periodograma de Welch para todos os  $N$  canais do EEG;
- **Passo 2** - aplique uma escala logarítmica aos valores PSD resultantes para convertê-los em decibéis (dB);
- **Passo 3** - segmente a PSD resultante (em dB) em  $M$  bandas de frequência linearmente espaçadas cobrindo o intervalo de 0,5 a 30Hz e, em seguida, compute a energia média dentro de cada banda. Para o canal  $N$ , este procedimento leva ao cálculo de  $M$  atributos organizados como  $x_{1;N}, x_{2;N}, \dots, x_{M;N}, e;$
- **Passo 4** - em cada época de 2 segundos de EEG no tempo, concatene as energias das  $M$  bandas extraídas de cada um dos  $N$  canais. Esse processo forma um vetor de atributos  $X_W$  de

dimensão  $M \times N$ , definido como:

$$\mathbf{X}_T = [x_{1;1}, x_{2;1}, \dots, x_{M;1}; \dots; x_{1;N}, x_{2;N}, \dots, x_{M;N}]^T \quad (5.1)$$

Alguns especialistas na área médica consideram como crise epilética uma leitura de EEG anormal que persista por períodos mínimos de 6 a 10 segundos (LOGAR *et al.*, 1994; FISHER *et al.*, 2014). Porém, como neste trabalho um dos objetivos é uma detecção rápida, será considerada a evolução dos vetores de atributos ao longo de uma época, graficamente apresentada na Figura 39.

Figura 39 – Procedimento para construção dos vetores de atributos a partir do método de Welch dos  $N$  canais de EEG.



Fonte: do autor.

### 5.3.2 Codificação Linear Preditiva

Foi discutido, no Capítulo, 3 seção 3.3, que a estimação do parâmetros de um modelo LPC retorna um vetor de coeficientes obtido através da Equação (3.34). De forma análoga ao procedimento anterior, a construção do vetor de atributos usando coeficientes LPC também envolve segmentos de épocas. Entretanto, em vez de especificar o número  $M$  de bandas de frequência sobre as quais calculamos a energia por época de EEG, precisamos especificar a ordem  $p$  do modelo  $AR(p)$ .

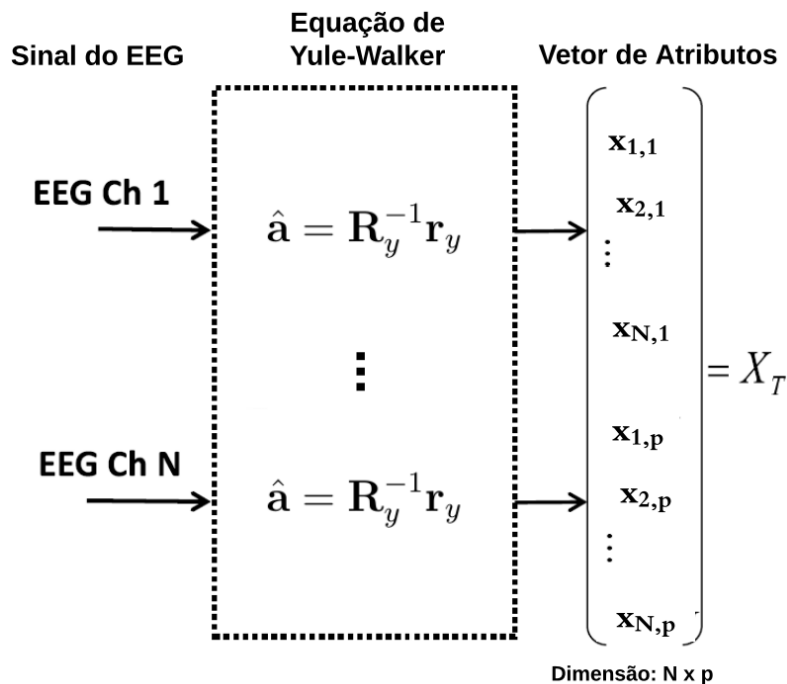
Dessa forma, os vetores de atributos construídos por meio do método LPC são obtidos através dos seguinte passos:

- **Passo 1** - para a época atual de EEG, aplique a equação de Yule-Walker para estimar os coeficientes de  $p$  correspondentes do modelo AR. Repita-o para todos os  $N$  canais;
- **Passo 2** - em cada época, concatenar os  $p$  coeficientes estimados para cada um dos  $N$  canais.

Este processo forma um vetor de recurso

$$\mathbf{X}_L = [a_{1;1}, a_{2;1}, \dots, a_{1;p}; \dots; a_{N;1}, a_{N;2}, \dots, a_{N;p}]^T \quad (5.2)$$

Figura 40 – Procedimento para construção dos vetores de atributos a partir do método de LPC com  $p$  e  $N$  canais.



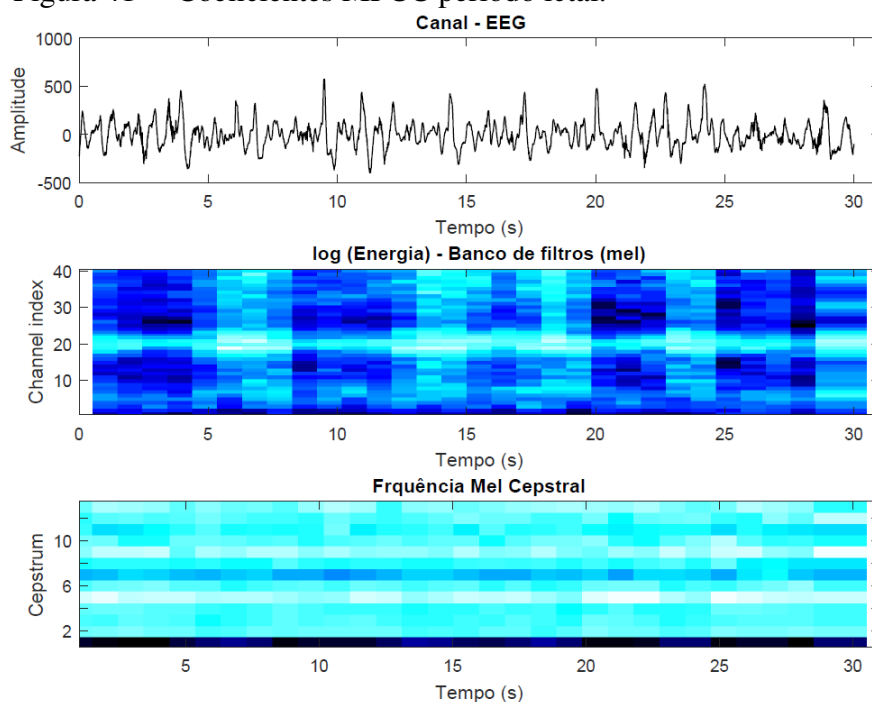
Fonte: do autor.

### 5.3.3 Coeficientes Mel-Cepstrais

Como foi descrito, no Capítulo 3, seção 3.4.1, os coeficientes Mel-Cepstrais realizam uma análise do espectro de frequência em um banco de filtros. Os valores dos coeficientes são computados a partir da Equação (3.44).


De forma ilustrar o comportamento desse método de extração, foram selecionados dois períodos, um ictal (Figura 41) e outro interictal (Figura 42), gerados a partir de segmentos de 30s do EEG paciente CBH01 canal FP1-F3. É possível observar, na energia no banco de filtros (espectrograma), que há uma maior concentração no período ictal, conforme esperado e já discutido anteriormente. Porém, usar diretamente os valores de energia irá produzir um vetor com  $M$  filtros para cada canal.

Figura 41 – Coeficientes MFCC período ictal.



Fonte: do autor.

Figura 42 – Coeficientes MFCC período interictal.



Fonte: do autor.

No entanto, o objetivo é utilizar apenas os coeficientes  $c[n]$  do MFCC. Dessa forma o procedimento de criação do vetor a ser adotado será o seguinte:

- **Passo 1** - para a época atual de EEG, estimar os  $c$  coeficientes MFCC. Repita-o para todos os  $N$  canais;

- **Passo 2** - em cada época, concatenar os  $c$  coeficientes estimados para cada um dos  $N$  canais. Este processo forma um vetor de recurso

$$\mathbf{X}_F = [c_{1;1}, c_{2;1}, \dots, c_{1;N}; \dots; c_{N;1}, c_{N;2}, \dots, c_{N;c}]^T \quad (5.3)$$

Serão utilizado 5 ( $c = 4$ ) coeficientes para a montagem do vetor de atributos.

### 5.3.4 Vetor de atributos com a matriz de covariância

Os métodos de extração anteriores tinham a característica de serem aplicados em cada canal do EEG separadamente e, posteriormente, seus atributos eram concatenados ou empilhados em um vetor. Diferentemente dos demais, a extração de atributos utilizando a matriz de covariância visa verificar o comportamento de todos os canais de forma simultânea. Diversos estudos de natureza linear multivariada são encontrados na literatura, como o uso dos modelos autorregressivos multivariados que visa identificar a dinâmica da atividade cerebral como um todo (PAGNOTTA; PLOMP, 2018; HÖLLER *et al.*, 2019).

Conforme apresentado na seção 3.5, foi adotado um operador vect que denota a operação de vetorização da matriz de correlação de um determinado conjunto de dados espacialmente distribuídos, de acordo com a Equação (3.48). Portanto, para cada época do EEG, será calculada um matriz de correlação  $\mathbf{C}_p$  de dimensões  $N \times N$ , em que  $N$  é o número de canais.

Como a matriz de correlação é calculada diretamente com os valores da amplitude do sinal, que no caso do EEG podem variar consideravelmente, esse método de extração poderá apresentar em seu vetor de atributos com valores diferenciando em até cinco ordens de grandeza. Essa variação abrupta de valores dos dados no vetor de características pode ocasionar problemas de mal condicionamento, sendo fonte de erros de ordem numérica e consequentemente podendo inviabilizar o uso desse em algoritmos de classificação que necessitam a inversão de um matriz.

Para contornar esse possível mal condicionamento, nesse método de extração será utilizada em cada época a normalização de score padronizado (*Z-Score*) (ZHANG *et al.*, 2013). É uma estratégia bastante utilizada em dados estatísticos, a qual mede a distância de uma amostra do dado a partir da média do desvio padrão. O conjunto de dados normalizado apresentará média nula ( $\mu_Z = 0$ ) e desvio padrão ( $\sigma_Z = 1$ ), mantém as propriedades de forma do conjunto de dados origina. A expressão a seguir representa a transformação dos dados:

$$z_i = \frac{x_i - \bar{x}}{\sigma_x}, \quad (5.4)$$

em que  $z_i$  é o dado normalizado,  $x_i$  é uma amostra do dado original,  $\bar{x}$  e  $\sigma_x$  são a média e o desvio padrão da variável a ser normalizada respectivamente.

Após o cálculo da matriz  $C_p$ , aplica-se o operador  $\text{vect}(C_p)$ , retornando um vetor com  $N(N+1)/2 + 1$  elementos. Por fim, é aplicada a normalização *Z-Score* em cada vetor. Portanto, o vetor característico para cada época será representado por:

$$\mathbf{X}_C = \text{vect}(C_p) = [C_{1,1}; \sqrt{2}C_{1,2}; C_{2,2}; \sqrt{2}C_{1,3}; \sqrt{2}C_{2,3}; C_{3,3}; \dots; C_{N_c, N_c}]^T \quad (5.5)$$

### 5.3.5 Configuração dos Métodos de Extração

Nessa seção, serão apresentadas as configurações realizadas nos parâmetros de cada método de extração. O uso da matriz de correlação como vetor de atributos não exige nenhuma configuração, pois apenas é realizado o cálculo da própria matriz no período de um época.

Para a estimação da PSD através do método de Welch a configuração adotada para a extração com esse método foi um janelamento do tipo Gaussiano de tamanho 128 e 256 pontos na DTF, sem sobreposição. Lembrando que a frequência de amostragem do sinal é de 256 Hz.

No método LPC, em cada época a estimação dos parâmetros dos filtros, optou por um modelo com  $p = 4$ .

Por fim, para cada época do método de extração, utilizando os coeficientes mel-cepstrais a configuração adotada será apresentada a seguir:

- Duração do *frame* ou passo de 4000 ms com sobreposição de 50%, ou seja, o passo ou *frame shift* de 2000 ms. Portanto foi considerada a época de 2 segundos como os demais métodos ;
- O número de bancos utilizado foi  $M = 40$ , configuração *default* em diversas aplicações.
- $L = 20$  número de coeficiente do filtro;
- $L_F = 0.5$  limite de menor frequência;
- $L_U = 40$  limite de maior frequência;

## 5.4 Avaliação dos Classificadores

O problema de classificação proposto nesse trabalho é binário (+1 ictal / -1 interictal). Portanto, é importante fazer o uso de métricas de desempenho para avaliar os cenários propostos de forma a facilitar a compreensão e a avaliação dos resultados obtidos. No contexto de classificação binária é comum utilizar as medidas de acerto (acurácia ou precisão) sejam



apresentadas em uma tabela comparativa, expressando apenas contagens brutas do número de vezes que cada marcador previsto está associado a cada classe real, ou pode ser expresso em termos relativos.

Porém, as características de um teste, como o aplicado neste trabalho, exigem a apresentação de métricas além da precisão. O primeiro passo é verificar os dados da matriz de confusão, apresentada na Tabela 7, em que:

- VP - número de predições verdadeiro positivas;
- VN - número de predições verdadeiras negativas;
- FP - número predições falso positivos;
- FN - número de diagnósticos falso negativo, e;
- $(\hat{y}, \Phi)$  - em que  $\hat{y}$  é a predição do classificador e  $\Phi$  é o padrão ouro ou valor de referência.

Tabela 7 – Matriz de Confusão

-	Crise Presente	Crise Ausente
<b>Teste Positivo</b>	VP (1,1)	FP (-1,1)
<b>Teste Negativo</b>	FN (1,-1)	VN (-1,-1)

Fonte: o autor.

A partir dos dados gerados pela matriz de confusão, é possível obter as possíveis métricas de comparação:

- Acurácia (*AC*): ou precisão de um teste é a capacidade de diferenciar o paciente e os casos saudáveis corretamente. Utilizada para calcular proporção de verdadeiros positivos e verdadeiros negativos em todos os casos avaliados;
- Sensibilidade: (*SB*) é a proporção de casos positivos que são corretamente previstos positivamente, ou seja, a capacidade do sistema em prever corretamente a condição para casos que realmente a tem a crise epilética;
- Especificidade (*EP*): é proporção de verdadeiros negativos, ou seja, a capacidade do sistema em prever corretamente a ausência da condição para casos que realmente não a têm. A especificidade de um teste avalia se os casos da ausência de crises foram preditos corretamente, evitando falsos positivos;
- Valor Preditivo Positivo (*VPP*) e Negativo (*VPN*) é a proporção de verdadeiros positivos em relação a todas as predições positivas e a proporção de verdadeiros negativos em relação a todas as predições negativas respectivamente. Estas medidas são altamente suscetíveis a desbalanceamentos do conjunto de dados e pode facilmente induzir a uma conclusão

errada sobre o desempenho do sistema.

- Coeficiente de Correlação de Matthews ( $\phi_M$ ), e uma medida de qualidade de duas classificações binárias que pode ser usada mesmo se as classes possuem tamanhos bastante diferentes.

A métrica do coeficiente de correlação Matthews foi introduzida pela primeira vez por B.W. Matthews para avaliar o desempenho da predição da estrutura secundária da proteína (MATTHEWS, 1975). Desde então, torna-se uma medida de desempenho amplamente utilizada na pesquisa biomédica (BOUGHORBEL *et al.*, 2017). Retorna um valor entre (-1) e (+1), em que um coeficiente de (+1) representa uma predição perfeita, (0) representa uma predição aleatória média, e (-1) uma predição inversa. O MCC é uma medida eletiva que visa alcançar um consenso sobre as melhores práticas para desenvolvimento e validação de modelos preditivos para medicina personalizada. Esse coeficiente, que visa dar medida de qualidade de classificações binárias, pode ser visto como uma discretização da correlação de Pearson para variáveis discretas. Na Tabela 8 são apresentadas as formulações para a calculo das métricas citadas.

Tabela 8 – Métricas de Comparação entre os cenários.


<b>Métrica</b>	<b>Símbolo</b>	<b>Formulação</b>
Acurácia	AC	$\frac{VP + VN}{VP + FN + FP + VN}$
Sensibilidade	SB	$\frac{VP}{VP + FN}$
Especificidade	EP	$\frac{VN}{VN + FP}$
Valor Predito Positivo	VPP	$\frac{VP}{VP + FP}$
Valor Predito Negativo	VPN	$\frac{VN}{VN + FN}$
MCC	$\phi_M$	$\frac{[(VP)(VN) - (FP)(FN)]}{\sqrt{(VP + FP)(VP + FN)(VN + FP)(VN + FN)}}$

Fonte: o autor.

Como o resultado da classificação geralmente são contínuos, ou seja, produzem um valor situado dentro de um determinado intervalo contínuo, como [0,1] ou [-1,1], é necessário definir um ponto de corte, ou um limiar de decisão, para se classificar e contabilizar o número de predições positivas e negativas, como diagnósticos verdadeiros e falsos no caso de ocorrência de uma patologia. Como este limiar pode ser selecionado arbitrariamente, a melhor prática para se

comparar o desempenho de diversos sistemas é estudar o efeito de seleção de diversos limiares sobre a saída dos dados. Para cada ponto de corte são calculados valores de sensibilidade e especificidade, que podem então serem dispostos em um gráfico denominado curva ROC, que apresenta no eixo das ordenadas os valores de sensibilidade e nas abscissas o complemento da especificidade, ou seja, o valor (1-especificidade). Uma interpretação mais geral é que, dados os resultados do teste, a probabilidade de que, para um par selecionado aleatoriamente de casos com ou sem a condição, o paciente que apresente a condição (crise epilética, por exemplo) tenha um resultado indicando maior suspeita.

Figura 43 – Exemplo de Curva ROC.

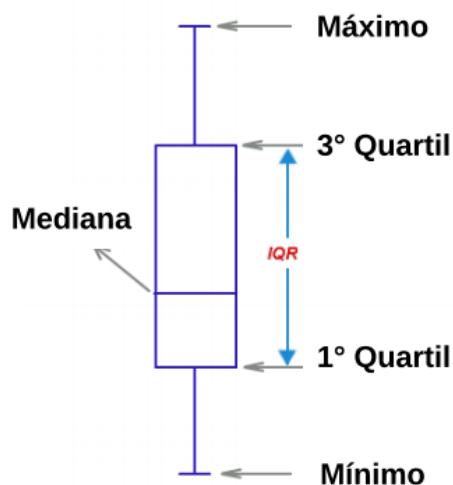


Fonte: Søreide (2009).

Cada regra de classificação, ou nível de corte, gera um ponto no gráfico. Quanto mais próxima a curva segue a borda esquerda e, em seguida, a borda superior do espaço ROC, mais preciso é o teste. Como exemplo, apresentado na Figura 43, são apresentados três testes e suas respectivas áreas sob a curva (AUC - *area under the curve*). A acurácia diagnóstica do marcador C (área branca) é melhor que a de B e A, como a AUC de  $C > B > A$ . A AUC pode variar de 0,5 (chance aleatória, ou nenhuma capacidade preditiva; refere-se à linha de 45 graus na parcela ROC) a 1 (perfeita discriminação / precisão). A AUC é uma medida da precisão diagnóstica geral do teste, e o valor de corte que fornece a sensibilidade e especificidade mais

altas é calculado.

Figura 44 – Diagrama de Caixas.



Fonte: do autor.

Outra ferramenta de comparação é a utilização do diagramas de caixas ou *BoxPlot*. O *Boxplot* é uma ferramenta bastante útil para para visualizar e comparar o desempenho entre classificadores, visto que, através destes, como por exemplo pode-se verificar a distribuição da taxa de acerto para um conjunto de realizações de cada algoritmo, evidenciando informações úteis, tais como *outliers* (desempenhos atípicos). Além disso, cada quartil, mediana, máximo e mínimo desta distribuição podem ser observados, conforme apresentado na Figura 44.

## 5.5 Seleção do Modelo

Esta etapa só está presente se o algoritmo de classificação em questão possuir hiperparâmetros que devem ser ajustados antes do treinamento. No caso da rede ELM, por exemplo, um dos hiperparâmetros a serem ajustados é o número de neurônios da camada oculta. Esta seleção ocorre apenas com os dados separados para treinamento. Isto se deve ao fato de que o modelo do classificador também carrega informações dos dados, e para que se meça a capacidade de generalização deste classificador, não deve haver interferência dos dados de teste.

Quanto às amostras do banco de dados para o treinamento, dividimos aleatoriamente as instâncias disponíveis por paciente em 2 subgrupos: treinamento (70%) e validação do treinamento (30%). O conjunto de treinamento será utilizado para a etapa de aprendizado do classificador, o de validação será utilizado para verificar a eficiência da rede quanto a sua capacidade de generalização durante o treinamento e o conjunto de teste um arquivo de longa duração simulando um dado real, o qual será utilizado para verificar o desempenho de cada

conjunto classificador / método de extração para novos dados.

Com isso, esta etapa de seleção do modelo consiste em uma busca em grade (*grid search*) na qual define-se uma faixa de valores para determinados parâmetros de um classificador. A partir disso, são fornecidas, ao passo seguinte, todas as combinações possíveis de valores dos parâmetros. O conjunto de valores de parâmetros que obtiverem a maior taxa de acerto médio é selecionado para a próxima etapa. Primeiramente, levando em conta todos os classificadores, estes possuem os seguintes hiperparâmetros, dados na Tabela 9.

Tabela 9 – Hiperparâmetros dos classificadores avaliados.

Classificador	Hiperparâmetro	Definição
ELM	$q$	Quantidade de Neurônios na camada oculta
MLM	$R$	Quantidade de pontos de Referência
SVM	$C$	Termo de Regularização
	$\sigma^2$	Escalonamento do <i>kernel</i> gaussiano
RKS	$D$	Dimensão do mapeamento do RKS
	$\sigma^2$	Escalonamento do <i>kernel</i> gaussiano
OLS	-	-

Fonte: o autor.

O classificador do método dos mínimos quadrados ordinários (OLS - ordinary least squares) não possui hiperparâmetro, como é apresentado no Apêndice C. No *grid search* o número de neurônios ocultos  $q$  foi variado no intervalo entre 5 e 300. Já no SVM o parâmetro de regularização e o hiperparâmetro do *kernel* tiveram, para a busca em grade, respectivamente os seguintes valores:  $C = [0.5 \ 5 \ 10 \ 15 \ 25 \ 50 \ 100 \ 250 \ 500 \ 1000]$  e  $\sigma^2 = [0.01 \ 0.05 \ 0,1 \ 0,5 \ 1 \ 5 \ 10 \ 50 \ 100 \ 500]$ . No classificador RKS o hiperparâmetro  $D$  foi variado no intervalo entre 5 e 300, e o  $\sigma^2$  com os mesmo valores do SVM. E por fim, número de pontos de referência  $R$  foi variado no intervalo entre 2 e 400.

## 5.6 Treinamento e Testes dos Classificadores

Após a seleção dos modelos, cada algoritmo é treinado com todos os dados separados para treinamento, de modo que os parâmetros sejam atualizados. Nesta etapa, como todos os algoritmos utilizados nesta dissertação possuem o treinamento supervisionado, os rótulos das amostras são utilizados. Levando em conta todos os classificadores, estes possuem os parâmetros listados na Tabela 10. A partir desta tabela, pode-se notar que existem muitos parâmetros que são vetores ou matrizes. Para quantificar o total de parâmetros, deve-se saber a dimensão destes

vetores e matrizes. Em resumo, a quantidade total de parâmetros é calculado a seguir.

- MMQ -  $K \times (p + 1)$  referente a matriz de pesos  $W$ ;
- ELM - dado um problema  $ELM(p, q, K)$ , a quantidade de parâmetros se resume a  $(p + 1) \times q + (q \times K)$ ;
- SVM - a quantidade total de parâmetros deste classificador depende dos vetores de suporte selecionados durante o treinamento. Assim, esta quantidade é de:  $n_{sv} \times (1 + p)$ , onde o  $n_{sv}$  corresponde à quantidade de multiplicadores de Lagrange se refere aos multiplicadores de Lagrange e o  $p$  se refere às amostras de treinamento que devem ser armazenadas.
- MLM - a quantidade de parâmetros deste classificador depende do hiperparâmetro  $R$ . Definido este, esta quantidade se torna  $(R \times R) + (R \times p)$ .
- RKS -  $W$  de dimensão  $D \times p$  e  $\alpha$  de dimensão  $1 \times p$ , que respectivamente representa a matriz de transformação e o vetor de mapeamento de treinamento.

Tabela 10 – Lista de Parâmetros

Classificador	Parâmetro	Definição
ELM	$W$	Matriz de pesos da camada oculta
	$M$	Matriz de pesos da camada de saída
MLM	$M_k$	Matriz de entrada dos pontos de referência
	$B$	Matriz de transformação
SVM	$n_{sv}$	Numero de vetores de suporte
	$\alpha$	Multiplicadores de Lagrange
	$X$	Matriz com vetores de suporte
RKS	$W$	Matriz de transformação
	$\alpha$	Vetor de mapeamento de treinamento
OLS	$W$	Matriz de Pesos

Fonte: o autor.

Finalmente, após cada rodada de teste, usaram-se 100 rodadas de treinamento para cada classificador, os parâmetros de treinamento que obtiveram os melhores resultados são exportados para a etapa de teste. Etapa que consiste em apresentar o arquivo de teste, arquivo este que foi separado por conter o maior intervalo de crise rotulado. Para cada cenário proposto serão calculadas todas as métricas de comparação, destacadas na seção 5.4.

## 5.7 Conclusão

Neste capítulo, foram descritos o banco de dados a ser utilizado e a forma como os dados foram organizados. Também foram apresentados todos os passos de montagem dos

vetores de atributos de cada métodos de extração. Em seguida, destacou-se os como os cenários serão avaliados e comparados e as ferramentas utilizadas juntamente com os classificadores. No capítulo a seguir, serão discutidos os resultados gerais deste trabalho.

## 6 RESULTADOS

Visando o objetivo deste trabalho, será verificado se algum método de extração se sobressai (isto é, produza melhores resultados) para todos os classificadores. Dessa forma, a princípio, serão investigados os métodos de extração que obtiveram os melhores desempenhos, baseados na métricas de comparação propostas e destacadas no capítulo anterior.

Para análise dos métodos de extração de características e de classificação de eventos epiléticos, de cada paciente foram gerados 20 cenários distintos em classificadores e métodos de extração. De forma a facilitar a compreensão dos resultados, foram escolhidos alguns que apresentem a consistência adotada nos experimentos realizados e que melhor representem qualitativamente as interpretações. Sendo assim, para ilustrar os resultados gerais obtidos, separamos os resultados dos experimentos submetidos ao paciente CHB03, que apresentou comportamentos semelhantes à maioria.

Por uma questão de completude dos resultados e visando a organização e fluidez na leitura do texto, os demais resultados das simulações discutidas, representados em diagrama de blocos, são apresentados no Apêndice A.

sectionAnálise dos Resultados

### 6.0.1 *Paciente CHB03*

O paciente cujos resultados serão apresentados nessa seção foi o que apresentou um comportamento característico médio equivalente à maioria dos pacientes utilizados nos experimentos. Portanto, a apresentação dos resultados gerais para esse paciente responde alguns questionamentos das hipóteses levantadas nesse trabalho. Os arquivos, número de crises e intervalos referentes ao paciente CHB03 são apresentados na Tabela 11. O arquivo no qual será realizada a etapa de teste será o arquivo C por apresentar o maior intervalo de crise. O teste é realizado de forma contínua simulando uma aplicação hospitalar.

Na Figura 45, são apresentadas as curvas ROC de um dos testes realizados. Como apresentado anteriormente, a curva ROC é uma ferramenta utilizada para a visualização que auxilia na seleção de cenários de classificação baseados no seu desempenho. Na sua interpretação, buscam-se as curvas mais próximas aos eixos, que representam uma alta sensibilidade e especificidade.

Sendo assim, pode-se afirmar que, a partir dos resultados, o uso dos coeficientes




Tabela 11 – Crises catalogadas do paciente CHB03.


-	Arquivo	Horário	Nº Crises	Início	Fim	Duração
A	chb03_01.edf	13:23:26 14:23:26	1	362	414	52
B	chb03_02.edf	14:23:29 14:23:29	1	731	796	65
<b>C</b>	<b>chb03_03.edf</b>	<b>15:23:47 16:23:47</b>	<b>1</b>	<b>432</b>	<b>501</b>	<b>69</b>
D	chb03_04.edf	16:23:54 17:23:54	1	2162	2214	52
E	chb03_34.edf	01:51:23 02:51:23	1	1982	2029	47
F	chb03_35.edf	02:51:30 03:51:30	1	2592	2656	64
G	chb03_36.edf	04:51:45 05:51:45	1	1725	1778	53

Fonte: o autor.


Figura 45 – Curva ROC para os cenários - Paciente CHB03.




(a) PSD



(b) LPC



(c) MFCC



(d) Covariância

Fonte: do autor.

mel-cepstrais apresentaram o melhor resultado, pois todos os classificadores obtiveram resultados superiores ao ser comparado com os outros métodos de atributos propostos. Note que, para melhorar a visualização a curva ROC referente ao MFCC, Figura 46c, foi necessário dar um *zoom* nos eixos do gráfico. Na Tabela 12 são apresentados os valores médios extraídos das cem rodadas para cada métrica de performance utilizada. Na Figura 53 (apresentada no Apêndice A)

são apresentados os diagramas de caixa da sensibilidade, especificidade, coeficiente de Matthews e área sobre a curva ROC.

O excelente resultado constatado no método de extração de características através dos coeficientes mel-cepstrais. A escala de mel, que é linear em baixas frequências e logarítmica em altas frequências, é uma boa candidata para representar essas não estacionariedades. O resultado é o uso de mais filtros em regiões de baixa frequência e menos filtros em regiões de alta frequência. A saída de cada filtro corresponde à energia total nas frequências que estão dentro do intervalo desse filtro. Ou seja, esse método assimila de forma eficiente as características de natureza não lineares do sinal representados no domínio *cepstral*.

No processo de obtenção dos coeficientes MFCC, é usada diretamente a Transformada Discreta de Cosseno, devido a suas propriedades homomórficas ocasionam uma descorrelação dos dados extraídos. Essa descorrelação em seu vetor de características acarreta em uma baixa dimensionalidade, portanto os vetores MFCC tendem a se espalhar pelo espaço de características, otimizando a etapa de classificação.

Tabela 12 – Média dos resultado para o método MFCC do paciente CHB03.

-	Acurácia	Sensibilidade	Especificidade	$\phi_M$	AUC	VPP	VPN
<b>ELM</b>	99.94	98.26	100	0.990	0.99975	99.91	99.94
<b>MLM</b>	99.92	99.65	99.93	0.988	0.99985	98.12	99.99
<b>RKS</b>	99.98	99.34	100	0.997	0.99981	100	99.98
<b>OLS</b>	99.90	97.14	100	0.985	0.99985	100	99.90
<b>SVM</b>	99.90	100	99.89	0.984	0.99981	97	100

Fonte: o autor.

O segundo melhor método de extração, a partir dos resultados, foi o uso dos coeficientes LPC. Como destacado na metodologia foram usados quatro coeficientes ( $p = 4$ ). A escolha de um modelo com  $p = 4$  se dá pelo fato de que valores maiores não melhoram o desempenho do teste, porém, valores menores comprometem seu desempenho apresentando um comportamento pior. Sendo assim, esse método apresentou resultados significativos, conforme pode ser observado na Figura 46b. Para facilitar a visualização, foi feito um *zoom* na curva ROC e observa-se que todos os classificadores obtiveram resultados próximos, sendo que a MLM obteve desempenho pior.

O aprendizado através da MLM consiste em reconstruir o mapeamento existente entre as matrizes de distância de entrada e saída e, em seguida, explorar o arranjo geométrico dos pontos de saída para estimar a resposta. Baseado em nossos experimentos, esse modelo foi capaz

de reconstruir o mapeamento existente entre as matrizes de distância mencionadas anteriormente, porém, como o MLM tem apenas um hiperparâmetro, a busca em grade de parâmetro deverá ser otimizada. Somado a isso, há um desbalanceamento dos dados de treinamento que pode ter sido mais prejudicial ao MLM com esse vetor de atributos.

A média dos resultados obtidos nas cem rodadas de teste é apresentada na Tabela 13 e seus comportamentos de distribuição podem ser visualizado no diagrama e caixas apresentado na Figura 53 (Apêndice A). Dos classificadores de natureza aleatória, o melhor desempenho foi registrado no RKS, apresentando uma sensibilidade média acima do classificador SVM.

Tabela 13 – Média dos resultados para o método LPC do paciente CHB03.

-	Acurácia	Sensibilidade	Especificidade	$\phi_M$	AUC	VPP	VPN
<b>ELM</b>	99.31	84.25	100	0.913	0.99583	99.97	99.28
<b>MLM</b>	98.50	71.24	99.88	0.821	0.99152	96.67	98.56
<b>RKS</b>	99.90	<b>97.17</b>	100	0.985	0.99813	99.97	99.89
<b>OLS</b>	99.28	83.04	100	0.907	0.99639	99.97	99.26
<b>SVM</b>	99.75	93.14	100	0.964	0.99778	100	99.74

Fonte: o autor.

O uso dos elementos da matriz de covariância no vetor de características apresentou um desempenho razoável porém inferior quando comparada com os dois métodos expostos anteriormente. Esse método é o que apresenta mais elementos em seu vetor de atributos, sendo necessária uma investigação de se a redução de dimensionalidade como o PCA não poderia melhorar o desempenho dos resultados. Ao observarmos a sua curva ROC, Figura 46d, nota-se que, conforme esperado, o classificador SVM obteve o melhor desempenho e, entre os classificadores aleatorizados, o MLM apresentou desempenho superior aos demais. O RKS obteve uma performance aquém dos demais classificadores, inclusive ficando abaixo do classificador linear.

Como discutido a matriz de covariância representa a dispersão do sinal no entorno do valor médio (nulo), ou seja, ela representa a energia do sinal. Porém, o uso direto da informação da matriz de covariância no classificador, após aplicado a vetorização e normalização, não demonstrou-se efetivo em ressaltar características dos sinais do EEG das classes distintas. Portanto, é recomendado utilizar a técnica que é conhecida na literatura como padrões espaciais comuns (CSP - *Common Spatial Pattern*) (RAMOSER *et al.*, 2000).

Este filtro é utilizado para realçar propriedades nos sinais de EEG realizando um contraste entre duas classes. Ao aplicar uma transformação linear no sinal de EEG, o filtro CSP

determina direções em que a variância de uma classe é máxima, e simultaneamente é mínima para a outra classe. A ausência de graus de liberdade ou parâmetro de regularização parece ser a principal dificuldade na direção de melhorar ainda mais as taxas de sucesso dessa técnica de extração.

Na Tabela 14, é apresentada a média dos resultados obtidos para esse método. Na Figura 55, são apresentados os diagramas de caixa para as principais métricas de comparação.

Tabela 14 – Média dos resultado para o uso da matriz de covariância.

-	Acurácia	Sensibilidade	Especificidade	$\phi_M$	AUC	VPP	VPN
<b>ELM</b>	95.45	43.37	99.47	0.584	0.72184	85.06	95.81
<b>MLM</b>	98.42	<b>74.10</b>	99.42	0.772	0.81114	82.94	98.95
<b>RKS</b>	88.34	20.10	99.37	0.374	0.71197	83.58	88.50
<b>OLS</b>	96.25	48.33	99.28	0.598	0.83041	79.36	96.83
<b>SVM</b>	95.67	44.05	99.85	0.632	0.82197	95.79	95.66

Fonte: o autor.

Por fim, foi utilizada PSD estimada a partir do método de Welch e com vetor de características formado pela média dos canais divididos em oito faixas de frequência. Os resultados observados apontaram para a pior desempenho entre os demais métodos, conforme pode ser observado na curva ROC, Figura 46a. Ao observamos os seus respectivos resultados, apresentados na Tabela 15, nota-se que esse método de extração obteve uma péssima sensibilidade no teste de longo período. Quando analisados os segmentos utilizados no treinamento, selecionados aleatoriamente, é observado um comportamento similar. Ao todo, foram utilizados oito filtros ( $M = 8$ ) e foram realizados testes com demais valores, porém, para  $M > 8$  os resultados se mantiveram similares, não ocasionando uma melhora gradual de performance, e, para valores  $M < 8$ , os resultados foram inferiores, conforme esperado.

Tabela 15 – Média dos resultado para a PSD para o paciente CHB03.

	Acurácia	Sensibilidade	Especificidade	$\phi_M$	AUC	VPP	VPN
<b>ELM</b>	84.80	21.88	99.05	0.373	0.74413	82.36	84.91
<b>MLM</b>	75.82	9.94	97.34	0.151	0.71013	54.55	76.81
<b>RKS</b>	66.27	13.11	98.19	0.229	0.61503	81.15	65.32
<b>OLS</b>	77.79	10.76	97.42	0.166	0.76409	54.76	78.85
<b>SVM</b>	79.94	17.91	99.78	0.365	0.61503	96.27	79.18

Fonte: o autor.


O comportamento dos resultados para esse método de extração é apresentado na Figura 56, no Apêndice A. Uma investigação sobre a forma como o vetor de atributos foi montado

poderá responder o questionamento sobre os resultados desse método (PSD) ser inferior aos demais. Uma hipótese é que o uso de todos os canais para esse paciente não seja a melhor forma de verificar seu comportamento espectral, pois no método há o cálculo da média de potência de todos os canais em uma faixa de frequência. O uso de técnicas de seleção de canais é indicado para o uso deste método de extração e algumas dessas técnicas podem ser combinadas com o extrator de característica, reduzindo o tamanho do vetor de atributos e eliminando informações redundantes (ALOTAIBY *et al.*, 2015).

A partir dos resultados gerais desse paciente, que representou o comportamento médio dos resultados obtidos, pode-se observar que o uso dos Coeficientes Mel-Cepstrais como vetor de atributos apresentou um desempenho superior aos demais métodos utilizados na comparação. O MFCC apresentou a melhor sensibilidade em todos os algoritmos de classificação testados, com um melhor coeficiente de correlação de Matthews e maior AUC. Esse comportamento foi repetido nos demais testes com outros pacientes.

Na Figura 46, é apresentado um comparativo da qualidade da classificação ( $\phi_M$ ) em todos os cenários propostos. Observa-se que o método de extração que obteve os melhores resultados foi o uso dos Coeficientes Mel-Cepstrais. Nota-se uma baixa dispersão dos resultados e o sucesso em todos os classificadores. Em segundo lugar os coeficientes do LPC em que se destaca o uso do classificador RKS entre as propostas de caráter aleatório. Em terceiro lugar ficou o método que considera a vetorização da matriz que covariância, método este de menor complexidade computacional, e o classificador MLM obteve os melhores resultados nesse método de extração. Por fim, o uso da densidade espectral de potência não gerou resultado esperado.

Figura 46 – Qualidade da classificação em todos os cenários do paciente CHB03.



Fonte: do autor.

Os principais desafios em se detectar as crises epiléticas são a complexidade do EEG de natureza não linear, a robustez dos atributos devido à quantidade de dados, canais distribuídos geometricamente pelo escalpo, diversos padrões epileptiformes e a presença de ruídos. Observando os resultados das simulações com o uso dos coeficientes do MFCC e do LPC como vetores de características, nota-se que esses métodos contribuíram fortemente para a obtenção de resultados com uma alta sensibilidade e especificidade.

Os valores dos hiperparâmetros selecionados para o treinamento e testes do paciente CHB03 são apresentados na Tabela 16.

Tabela 16 – Hiperparâmetros utilizados para o paciente CHB03.

	ELM		MLM		RKS		SVM	
	$q$	$R$	$D$	$\sigma^2$	$C$	$\sigma^2$		
<b>MFCC</b>	200	30	200	0.01	300	0.005		
<b>LCP</b>	225	50	380	0.5	305	0.005		
<b>COV</b>	300	100	400	0.05	1000	0.01		
<b>PSD</b>	325	80	450	0.09	1000	0.05		

Fonte: o autor.

Em seguida, serão apresentados alguns resultados atípico encontrados no teste e um exemplo de aplicação no qual foi realizado um teste em um arquivo de 4 horas.

### 6.0.2 Resultados do Paciente CHB02 e CHB05

Essa seção será dedicada a apresentar os resultados referentes aos pacientes CHB02 e CHB05. Foi separado apenas os resultados referentes ao uso do MFCC como vetor de atributos para exemplificar o comportamento atípico encontrado nesses pacientes, já que os outros métodos obtiverem desempenho inferiores na maioria dos cenários. Os hiperparâmetros selecionados para os testes com esse dois pacientes são apresentados na Tabela 17.

Tabela 17 – Hiperparâmetros utilizados nos pacientes CHB02 e CHB05.


	ELM		MLM		RKS		SVM	
	$q$	$R$	$D$	$\sigma^2$	$C$	$\sigma^2$		
<b>CHB02</b>	80	40	400	0.025	500	0.02		
<b>CHB05</b>	300	35	400	0.001	480	0.06		

Fonte: o autor.

Na Figura 47 é apresentada a curva ROC e na Tabela 18 os resultados médios para as

cem realizações de teste. Observa-se que para esse paciente apenas o classificador SVM apresentou um comportamento similar ao apresentado no paciente CHB03 em relação à sensibilidade. Os outros classificadores apresentaram uma sensibilidade baixa e consequentemente obtiveram uma baixa qualidade na classificação.

Figura 47 – Curva ROC para o método do Coeficientes Mel-Cepstrais - Paciente CHB02.



Fonte: do autor.

Tabela 18 – Média dos resultado utilizando o coeficiente MFCC - Paciente CHB02

-	Acúrcia	Sensibilidade	Especificidade	$\phi_M$	AUC	VPP	VPN
<b>ELM</b>	88	29.71	99.77	0.479	0.93288	92.51	87.90
<b>MLM</b>	93.67	33.64	99.75	0.526	0.93878	90.27	93.75
<b>RKS</b>	97.84	51.14	99.88	0.687	0.9445	94.80	97.91
<b>OLS</b>	96.21	37.58	99.90	0.588	0.93334	96.02	96.22
<b>SVM</b>	99.82	100	99.82	0.958	0.99667	92.12	100

Fonte: o autor.

Para esse paciente o melhor entre o classificadores com proposta aleatória com foi o RKS, porém obtendo uma sensibilidade de apenas 51.14%. Portanto, para esse paciente em específico, a configuração dos classificadores aleatorizados utilizados não gerou os resultados esperados. Demais resultados desse paciente são apresentados no Apêndice A, Figura 57.

O comportamento apresentado pelo paciente CHB05 é de uma baixa sensibilidade e de alta especificidade na classificação, conforme pode ser observado na Tabela 19. A sua alta especificidade e o grande número de amostra apresentam uma curva ROC com a característica dada na Figura 48. Porém quando observamos a qualidade a classificação é observado que todos os classificadores obtiveram resultados inferiores ao serem comparados com o paciente CHB03.


Investigando a fonte de erros nesse paciente em específico notou-se que a maioria

Tabela 19 – Média dos resultado para os testes realizados utilizando o coeficiente MFCC - Paciente CHB05

-	Acurácia	Sensibilidade	Especificidade	$\phi_M$	AUC	VPP	VPN
<b>ELM</b>	90,31	27,45	100,00	0,491	0,69538	100,00	90,00
<b>MLM</b>	93,13	35,85	100,00	0,570	0,68542	100,00	92,91
<b>RKS</b>	88,95	22,33	100,00	0,445	0,78752	100,00	88,59
<b>OLS</b>	91,39	27,46	100,00	0,499	0,68610	100,00	91,11
<b>SVM</b>	92,35	29,99	100,00	0,524	0,76752	100,00	92,09

Fonte: o autor.

Figura 48 – Curva ROC para o método do Coeficientes Mel-Cepstrais - Paciente CHB05.



(a) Curva ROC

(b) Zoom Curva ROC

Fonte: do autor.


dos falsos alarmes ocorridos nesse teste eram provenientes de intervalos próximos de cerca de vinte ou trinta segundos. Analisando visualmente os dados foi possível detectar uma fonte de erros causadas por artefatos ocasionados principalmente nos canais F7-T7, T7-P7, T8-P8, P8-O2, conforme apresentado na Figura 49. Esse comportamento é encontrado em outros trechos ocasionando a baixa taxa de sensibilidade apresentada no teste.

Outros casos semelhantes como o detectado no paciente CHB05 ocorreram. Uma possível solução seria uma inspeção visual e o corte dos dados prejudiciais. Porém, em se tratando de uma aplicação voltada para o uso hospitalar que busca otimizar o diagnóstico é necessário filtrar esse artefatos ou até mesmo modelá-los para serem reconhecidos e, se necessário descartados da classificação com intuito de não gerar falsos alarmes. Como exemplo, observe a Figura 50, em média a cada um segundo há a presença de um artefato generalizado em todos os canais. A característica desse artefato não é biológico pela sua periodicidade, sendo possível ser alguma falha de instrumentação.

O fenômeno mostrado na Figura 50 não se encontra catalogado no banco de dados e é




Figura 49 – Fonte de erros causados por artefatos no EEG do paciente CHB05.



Fonte: do autor.

Figura 50 – Presença de artefatos nos dados paciente CHB03.



Fonte: do autor.

encontrado em cerca de 25% de um arquivo do paciente CHB03, que fora excluído por apresentar esse comportamento. Todos os conjuntos de métodos de extração e classificadores detectaram esse tipo de comportamento como período ictal, por apresentarem um aumento significativo da energia do sinal, gerando um baixo desempenho. Essa queda de performance foi o fator providencial para a verificação visual dos dados e perceber os que estavam comprometidos nesse trecho. Portanto, os métodos empregados são suscetíveis a esses tipos de artefatos ou ruídos. Outro detalhe importante é que quando o paciente apresenta uma crise epiléptica de carácter motor há sempre a possibilidade de um ou mais eletrodos, fixados no couro cabeludo, se desprenderem e o sinal ficar nulo ou apresentar interferências. Nesse banco de dados não foi verificado esse detalhe, porém é possível sua ocorrência.

### 6.0.3 Resultados do Paciente CHB07

Por fim, é apresentado o resultado do paciente CHB07. O EEG é um procedimento que normalmente, dependendo da necessidade do diagnóstico, pode durar horas ou até mesmo dias de monitoramento. Portanto é importante aplicar os modelos de extração e classificação propostos em EEG de longa duração. Para tal tarefa foi escolhido o paciente CHB07 que apresenta cerca de 9 horas de gravação divididos em dois arquivos de 4 horas e um de cerca de uma hora, totalizando 325 segundos de período ictal.

Tabela 20 – Arquivos utilizados para o paciente CHB07.

-	Arquivo	Horário		Nº Crises	Início	Fim	Duração
<b>A</b>	chb07_12.edf	07:46:22	11:46:22	1	4920	5006	86
<b>B</b>	chb07_13.edf	11:46:29	12:48:35	1	3285	3381	96
<b>C</b>	chb07_19.edf	08:12:32	08:44:44	1	13831	13831	<b>143</b>

Fonte: do autor.

Conforme discutido na metodologia o arquivo de maior intervalo de crises epiléticas será o arquivo de teste, que será o arquivo **C** com 4 horas de duração. A curva ROC do teste realizado, apresentada na Figura 52a, novamente comprova a eficiência da classificação quando se utiliza como vetor de atributos os coeficientes Mel-Cepstrais. Na Figura 52b é possível verificar o comportamento dos classificadores, e percebe-se que todos os classificadores obtiveram resultados similares corroborando com o resultado obtido anteriormente. Os hiperparâmetros selecionados para esse teste são apresentados na Tabela 21.


Tabela 21 – Hiperparâmetros utilizados no paciente CHB07.

	ELM	MLM	RKS		SVM	
	$q$	$R$	$D$	$\sigma^2$	$C$	$\sigma^2$
<b>CHB07</b>	50	30	140	0.075	1000	0.05

Fonte: do autor.

Na Tabela 22 observamos que o classificador que apresentou a maior sensibilidade média foi o RKS, entre os de propostas aleatórias. As distribuições dos resultados podem ser visualizadas nos diagramas de caixa apresentados na Figura Apêndice A, Figura 59. Os resultados para uma arquivo longo, de 4 horas. apresentaram uma excelente performance conforme proposto nos objetivos deste trabalho.

Figura 51 – Curva ROC para o método do Coeficientes Mel-Cepstrais - Paciente CHB07.



(a) Curva ROC

(b) Zoom Curva ROC

Fonte: do autor.

Tabela 22 – Média dos resultado para os testes realizados utilizando o coeficiente MFCC - Paciente CHB07.

-	Acurácia	Sensibilidade	Especificidade	$\phi_M$	AUC	VPP	VPN
<b>ELM</b>	98.87	58.48	99.93	0.722	0.97152	93.43	98.94
<b>MLM</b>	99.35	66.50	99.95	0.791	0.98412	95.57	99.40
<b>RKS</b>	99.66	83.99	99.85	0.851	0.99503	86.62	99.81
<b>OLS</b>	91.97	12.94	100	0.342	0.99613	100	91.88
<b>SVM</b>	99.74	89.19	99.85	0.879	0.99503	87	99.88

Fonte: do autor.

## 6.1 Comparação do Tempo de Processamento

Um dos objetivos específicos deste trabalho é encontrar, a partir das ferramentas utilizadas, o cenário que apresente o menor tempo de treinamento com a maior sensibilidade. Todos os algoritmos (extração e classificação) e testes foram desenvolvidos e executados no MATLAB 2015a, em um computador Intel(R) Core(TM)i7-5500 2.40GHz 16GB de memória.

Os resultados referentes o tempo de extração obtidos são apresentados na Tabela 23. Conforme esperado, o algoritmo mais rápido é da utilização da matriz de covariância, pois o mesmo utiliza apenas de operações matriciais e vetorização. O LPC, o segundo mais rápido, é uma excelente opção para os casos em que seja necessário uma extração de atributos rápida e eficiente. Lembrando que o LPC é aplicado canal por canal e esses resultados são referentes a todos os canais em sequência.

Quando são observados os valores referentes ao uso dos coeficientes Mel Cepstrais nota-se que o método, que apresentou os melhores resultados em sensibilidade e acurácia,


Tabela 23 – Média do tempo de extração para cada época, em segundos.

<b>PSD</b>		<b>LPC</b>		<b>MFCC</b>		<b>COV</b>	
0.0632	$\pm 0.0020$	0.0085	$\pm 0.0004$	0.2032	$\pm 0.0062$	0.0005	$\pm 0.0001$

Fonte: do autor.

apresenta o maior tempo de execução. Como apresentado anteriormente, para a obtenção os coeficientes do MFCC são necessário alguns passos, dentre os quais têm-se a aplicação da transformada rápida de Fourier, a transforma inversa do cosseno e a criação de banco de filtros. Esses passos de natureza não linear demandam custo computacional.

Figura 52 – Diagrama de Bloco dos tempos de extração em cada época.



Fonte: do autor.

Já em relação ao tempo de treinamento, foi calculado a média entre todos os pacientes testados e os resultados são apresentados na Tabela 24. O classificador RKS obteve o menor tempo de treinamento entre todos os aleatorizados.

Tabela 24 – Tempo de treinamento dos algoritmos de aprendizagem, em segundos.

<b>ELM</b>		<b>MLM</b>		<b>RKS</b>		<b>SVM</b>		<b>OLS</b>	
0.2015	$\pm 0.0045$	1.2550	$\pm 0.1528$	0.088	$\pm 0.001$	4.2634	$\pm 0.3801$	0.0185	$\pm 0.0025$

Fonte: do autor.

A complexidade computacional assume um papel importante no processo decisório de seleção de método apropriado. A este respeito, um aspecto essencial para o treinamento mais rápido da MLM é o número de pontos de referência, ou mais especificamente, a propriedade de

que o número de pontos de referência ótimo não cresce na mesma taxa do número de pontos de aprendizagem (tamanho do conjunto de dados) (SOUZA *et al.*, 2015).

No trabalho de Iosifidis *et al.* (2015) os autores apresentam que a rede ELM apresenta a complexidade computacional  $\mathcal{O}(NLD)$  para o cálculo da matriz de saída da camada oculta e  $\mathcal{O}(L^3 + L^2N + LNC)$  para o cálculo da matriz de saída, onde  $L$  é o número de camadas,  $N$  o número de vetores de treinamento ou teste,  $D$  é a dimensão do vetor e  $C$  é o número de classes. Portanto a complexidade total é  $\mathcal{O}(L^3 + L^2N + LN(C + D))$ , como foi utilizada apenas uma camada oculta a maior parte da complexidade computacional provém da quantidade de dados de treinamento e a dimensão dos vetores de entrada.

O RKS apresenta uma complexidade computacional semelhante ao da ELM na etapa de treinamento. A complexidade é dada por  $\mathcal{O}(T^3 + T^2N + DTN)$ , em que  $D$  é a dimensão do mapeamento e  $T$  é dimensão do vetor de características. O três termos da soma da complexidade computacional referem-se respectivamente as etapas de inversão da matriz de covariância, multiplicação da função de *kernel* e a geração da matriz de pesos. Porém, no teste não há a etapa de inversão da matriz (RAHIMI; RECHT, 2008b). O que provavelmente acarreta o fato do RKS apresentar uma etapa de treinamento menor é o fato do algoritmo de inversão da matriz utilizado ser mais eficiente que as etapas de processamento dos pesos na rede ELM.

Portanto, para aplicações que necessitem de um treinamento rápido e eficiente, o classificador RKS somado ao atributos extraídos do LPC apresentam uma excelente especificidade.

## 7 CONCLUSÃO

Este último capítulo apresenta as conclusões, considerações finais e um resumo das contribuições científicas, e identifica trabalhos futuros relacionados com os assuntos abordados nesta tese.

### 7.1 Objetivo Geral

Neste trabalho, avaliamos técnicas de extração de atributos do EEG e de classificação para o auxílio ao diagnóstico da Epilepsia, mais especificamente na detecção de períodos ictais em uma crise epilética. Comparamos os desempenhos de quatro métodos de extração de atributos na tarefa de detecção de crises convulsivas epiléticas através dos sinais EEG obtidos em um banco de dados de acesso público. Paralelamente, foram comparados o desempenho de três classificadores randomizados (ELM, MLM e RKS) com o de classificadores “tradicional”: classificador linear dos mínimos quadrados e o SVM.

A partir dos resultados obtidos nesta dissertação de mestrado, pode-se inferir as seguintes conclusões:

1. O uso vetor de atributos formado a partir dos coeficientes Mel-Cepstrais (MFCC) obteve uma excelente desempenho na classificação, independentemente do classificador utilizado.
2. O método LPC obteve um rendimento inferior ao MFCC, porém obteve uma sensibilidade de acordo com o proposto no trabalho usando os classificadores randomizados;
3. O uso da matriz de covariância demonstrou ser uma possibilidade de baixo custo computacional e apresentou um resultado excelente ao ser utilizado em conjunto com o classificador MLM.
4. O vetor formado pela PSD não obteve resultados satisfatórios em todos os pacientes e em todos os classificadores. Métodos lineares, como FFT, não detectam tão facilmente componentes não estacionários dos sinais do EEG.
5. Cada paciente apresenta um comportamento diferente, sendo necessário um estudo para otimizar os método de extração para cada um em específico.
6. Os desempenhos dos classificadores randomizados, em média, são sempre inferiores ao SVM, conforme esperado, independentemente do método de extração de recurso utilizado. Porém, em alguns cenários específicos houve casos em que um classificador randomizado obteve desempenho melhor.

7. A ELM e o RKS apresentaram o menor custo computacional para treinamento.
8. O uso da época de dois segundos otimizou a classificação, e caso seja utilizado de forma *on-line* monitorando um paciente o alarme gerado pela crise epilética será praticamente em tempo real. Esse curto período de detecção, pode gerar uma intervenção clínica quase de imediato, melhorando a qualidade de vida do paciente.

Um detalhe que foi observado é que quando se compara a curva ROC e com o coeficiente de Matthews, nota-se que o MCC é estatística resumida da matriz de confusão que apresenta um comportamento que melhor representa os cenários mesmo com problema apresentando classes desbalanceadas. O MCC é mais estável em relação a diferentes classes em comparação com as curvas ROC. Por definição, uma curva ROC está construindo o desempenho sobre todos os possíveis cortes / condições para os cenários.

Pode-se afirmar que os desempenhos dos algoritmos randomizados com o uso do MFCC são sempre equivalentes ao classificador SVM. Entre os classificadores randomizados, houve alta variabilidade entre os resultados, sendo que desempenho do classificador RKS utilizando o vetor de atributos com os coeficiente do MFCC apresentou uma excelente sensibilidade e oferece a vantagem adicional de treinamento mais rápido, sendo assim uma boa alternativa.

Conforme apresentado anteriormente, um dos maiores desafios do diagnóstico da Epilepsia era obter uma alta taxa de sensibilidade e de especificidade da identificação de um evento epilético no EEG devido inúmeras causas, já apresentadas. Uma das possíveis causas é o fato do EEG conter longos períodos no qual o profissional realiza o diagnóstico de longa duração. Neste trabalho esta tarefa foi realizada com êxito, como visto nos resultados.

## 7.2 Objetivos Específicos

Todos os objetivos específicos foram atingidos com êxito, visto que foi selecionado um banco de dados de EGG que apresentava longos trechos para serem analisados. Muitos trabalhos citados nas referências, que se propõem a realizar a mesma tarefa, utilizam arquivos de teste de curta duração. O uso de arquivos de curta duração para a realização de testes não condiz com a realidade de um paciente em uma unidade de monitoramento ou de uma ferramenta de auxílio à diagnóstico. Como exemplo, pode-se citar os dados da Universidade de Bonn que apresentam apenas de 23.6 s de duração (ANDRZEJAK *et al.*, 2002)<sup>1</sup>.

Foi realizada a implementação dos algoritmos dos métodos de extração e dos clas-

---

<sup>1</sup> <<https://bit.ly/2VFHrTG>>

sificadores (cinco algoritmos distintos) proposto. A implementação desse algoritmos facilita a otimização dos mesmos e os ajustes necessários em cada aplicação. Para verificar a eficácia e qualidade da classificação de cada método de extração e classificadores foram utilizadas ferramentas estatísticas, tais como: matriz de confusão, a curva ROC e coeficiente de correlação de Matthews.

### 7.3 Trabalhos Futuros

Dentre as possíveis continuidades ou contribuições adicionais a este trabalho destacam-se:

1. Utilizar outros banco de dados que apresentem características similares no tocante à duração e catalogação do dados. Dentre os quais podem-se citar: *Temple University Hospital EEG (TUH EEG)*<sup>2</sup> ou *European Epilepsy Database*<sup>3</sup>. Ou utilizar um banco de dados regional, através de parcerias com hospitais locais e neurologistas.
2. Testar o desempenho de outros métodos de atributos, como por exemplo: Transformada de Wavelet, Entropia, cumulantes de ordem superior, Expoente de Lyapunov entre outros citados na literatura.
3. Investigar e identificar o período pré-ictal.
4. Otimização dos resultados com os classificadores randomizados;
5. A estratégia convencional de ajustar os parâmetros via busca em grade não foi viável, pois requer um grande número de ensaios para obter uma solução ótima conjunta. Assim, indica-se incorporar um método de otimização Bayesiana.
6. Criar e integrar uma ferramenta de classificação de períodos ictais em um software de análise ou na *Toolbox EEGLAB*, e ;
7. Classificação do tipo de crises a partir do EEG.

---

<sup>2</sup> Disponível em: <<https://bit.ly/2RQ8KMf>>, acesso publico.

<sup>3</sup> Disponível em <<http://epilepsy-database.eu/>>, acesso pago.



## REFERÊNCIAS

- ACHARYA, J. N.; HANI, A. J.; CHEEK, J.; THIRUMALA, P.; TSUCHIDA, T. N. American clinical neurophysiology society guideline 2: guidelines for standard electrode position nomenclature. **The Neurodiagnostic Journal**, Taylor & Francis, v. 56, n. 4, p. 245–252, 2016.
- ACHARYA, U. R.; FUJITA, H.; SUDARSHAN, V. K.; BHAT, S.; KOH, J. E. Application of entropies for automated diagnosis of epilepsy using eeg signals: A review. **Knowledge-Based Systems**, v. 88, p. 85 – 96, 2015. ISSN 0950-7051. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0950705115003081>>.
- ACHARYA, U. R.; SREE, S. V.; ALVIN, A. P. C.; SURI, J. S. Use of principal component analysis for automatic classification of epileptic eeg activities in wavelet framework. **Expert Systems with Applications**, v. 39, n. 10, p. 9072 – 9078, 2012. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417412002849>>.
- ACHARYA, U. R.; SREE, S. V.; SURI, J. S. Automatic detection of epileptic eeg signals using higher order cumulant features. **International journal of neural systems**, v. 21 5, p. 403–14, 2011.
- AGUIRRE, L. **Introdução à Identificação de Sistemas – Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais**. Editora UFMG, 2015. ISBN 9788570415844. Disponível em: <<https://books.google.com.br/books?id=f9IwE7Ph0fYC>>.
- AL-ANI, T.; DROUOT, X.; HUYNH, T. T. T. Non-linear eeg analysis of idiopathic hypersomnia. In: ELMOATAZ, A.; LEZORAY, O.; NOUBOUD, F.; MAMMASS, D.; MEUNIER, J. (Ed.). **Image and Signal Processing**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010. p. 297–306. ISBN 978-3-642-13681-8.
- ALAM, S. M. S.; BHUIYAN, M. I. H. Detection of seizure and epilepsy using higher order statistics in the emd domain. **IEEE Journal of Biomedical and Health Informatics**, v. 17, n. 2, p. 312–318, March 2013. ISSN 2168-2194.
- ALKAN, A.; YILMAZ, A. S. Frequency domain analysis of power system transients using welch and yule-walker ar methods. **Energy Conversion and Management**, v. 48, n. 7, p. 2129 – 2135, 2007. ISSN 0196-8904. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S019689040700009X>>.
- ALOTAIBY, T.; EL-SAMIE, F. E. A.; ALSHEBEILI, S. A.; AHMAD, I. A review of channel selection algorithms for eeg signal processing. **EURASIP Journal on Advances in Signal Processing**, v. 2015, n. 1, p. 66, Aug 2015. ISSN 1687-6180. Disponível em: <<https://doi.org/10.1186/s13634-015-0251-9>>.
- ALTUNAY, S.; TELATAR, Z.; EROGUL, O. Epileptic eeg detection using the linear prediction error energy. **Expert Syst. Appl.**, Pergamon Press, Inc., Tarrytown, NY, USA, v. 37, n. 8, p. 5661–5665, ago. 2010. ISSN 0957-4174. Disponível em: <<http://dx.doi.org/10.1016/j.eswa.2010.02.045>>.
- ANDRZEJAK, R. G.; LEHNERTZ, K.; MORMANN, F.; RIEKE, C.; DAVID, P.; ELGER, C. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. **Physical review. E, Statistical, nonlinear, and soft matter physics**, v. 64, p. 061907, 01 2002.

ANEESH, C.; HISHAM, P.; KUMAR, S. S.; MAYA, P.; SOMAN, K. Variance based offline power disturbance signal classification using support vector machine and random kitchen sink. **Procedia Technology**, v. 21, p. 163 – 170, 2015. ISSN 2212-0173. SMART GRID TECHNOLOGIES. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S2212017315003126>>.

ASANO, E.; PAWLAK, C.; SHAH, A.; SHAH, J.; LUAT, A. F.; AHN-EWING, J.; CHUGANI, H. T. The diagnostic value of initial video-eeg monitoring in children—review of 1000 cases. **Epilepsy Research**, v. 66, n. 1, p. 129 – 135, 2005. ISSN 0920-1211. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0920121105001671>>.

BABU, G. S.; SURESH, S. Meta-cognitive rbf network and its projection based learning algorithm for classification problems. **Applied Soft Computing**, v. 13, n. 1, p. 654 – 666, 2013. ISSN 1568-4946. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1568494612004206>>.

BARACHANT, A.; BONNET, S.; CONGEDO, M.; JUTTEN, C. Classification of covariance matrices using a riemannian-based kernel for bci applications. **Neurocomputing**, v. 112, p. 172 – 178, 2013. ISSN 0925-2312. Advances in artificial neural networks, machine learning, and computational intelligence. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231213001574>>.

BEAR BARRY W. CONNORS, M. A. P. M. F. **Neuroscience: Exploring the Brain**. Third. [S.l.]: Lippincott Williams & Wilkins, 2006. ISBN 0781760038,9780781760034.

BENBADIS, S. R.; LAFRANCE, W. C.; PAPANDONATOS, G. D.; KORABATHINA, K.; LIN, K.; KRAEMER, H. C. Interrater reliability of eeg-video monitoring. **Neurology**, Wolters Kluwer Health, Inc. on behalf of the American Academy of Neurology, v. 73, n. 11, p. 843–846, 2009. ISSN 0028-3878. Disponível em: <<http://n.neurology.org/content/73/11/843>>.

BERG, A. T.; BERKOVIC, S. F.; BRODIE, M. J.; BUCHHALTER, J.; CROSS, J. H.; BOAS, W. V. E.; ENGEL, J.; FRENCH, J.; GLAUSER, T. A.; MATHERN, G. W.; MOSHÉ, S. L.; NORDLI, D.; PLOUIN, P.; SCHEFFER, I. E. Revised terminology and concepts for organization of seizures and epilepsies: Report of the ilae commission on classification and terminology, 2005–2009. **Epilepsia**, v. 51, n. 4, p. 676–685, 2010. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1528-1167.2010.02522.x>>.

BLUME, W. T.; HOLLOWAY, G. M.; KAIBARA, M.; YOUNG, G. B. **Blume's Atlas of Pediatric and Adult Electroencephalography**. 1. ed. [S.l.]: Lippincott Williams & Wilkins, 2010. ISBN 1605476056,9781605476056.

BOUGHORBEL, S.; JARRAY, F.; EL-ANBARI, M. Optimal classifier for imbalanced data using matthews correlation coefficient metric. **PLOS ONE**, Public Library of Science, v. 12, n. 6, p. 1–17, 06 2017. Disponível em: <<https://doi.org/10.1371/journal.pone.0177678>>.

BOUTON, C. E.; SHAIKHOUNI, A.; ANNETTA, N. V.; BOCKBRADER, M. A.; FRIEDENBERG, D. A.; NIELSON, D. M.; SHARMA, G.; SEDERBERG, P. B.; GLENN, B. C.; MYSIW, W. J.; MORGAN, A. G.; DEOGAONKAR, M.; REZAI, A. R. Restoring cortical control of functional movement in a human with quadriplegia. **Nature**, Nature Publishing Group, a division of Macmillan Publishers Limited. All Rights Reserved. SN, v. 533, p. 247 EP, Apr 2016. Disponível em: <<http://dx.doi.org/10.1038/nature17435>>.

BRASIL. Ministério da Saúde. **Banco de Dados do Sistema Único de Saúde-DATASUS, Sistema de Informação da Atenção Básica (SIAB)**. 2018. Disponível em: <<http://www2.datasus.gov.br/SIAB/>>. Acesso em: 22 agosto 2018.

BURG, J. P. Maximum entropy spectral analysis. In: **37<sup>th</sup> Annual International Meeting, Soc. of Explor. Geophys., Oklahoma City, Okla., Oct. 31, 1967**. [S.l.: s.n.], 1967.

CHEN, D.; WAN, S.; XIANG, J.; BAO, F. S. A high-performance seizure detection algorithm based on discrete wavelet transform (dwt) and eeg. **PLOS ONE**, Public Library of Science, v. 12, n. 3, p. 1–21, 03 2017. Disponível em: <<https://doi.org/10.1371/journal.pone.0173138>>.

CHOWDHURY, F. A.; NASHEF, L.; ELWES, R. D. C. Misdiagnosis in epilepsy: a review and recognition of diagnostic uncertainty. **European Journal of Neurology**, v. 15, n. 10, p. 1034–1042, 2008. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1468-1331.2008.02260.x>>.

DAS, A. B.; BHUIYAN, M. I. H. Discrimination and classification of focal and non-focal eeg signals using entropy-based features in the emd-dwt domain. **Biomedical Signal Processing and Control**, v. 29, p. 11 – 21, 2016. ISSN 1746-8094. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1746809416300465>>.

DAVIS, S.; MERMELSTEIN, P. Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences. **IEEE Transactions on Acoustics, Speech, and Signal Processing**, v. 28, n. 4, p. 357–366, August 1980. ISSN 0096-3518.

DELLER, J. R.; HANSEN, J. H. L.; PROAKIS, J. G. **Discrete-Time Processing of Speech Signals (IEEE Press Classic Reissue)**. [S.l.: s.n.], 1999. ISBN 0780353862,9780780353862.

DELORME, A.; MAKEIG, S. Eeglab: an open source toolbox for analysis of single-trial eeg dynamics including independent component analysis. **Journal of neuroscience methods**, Elsevier, v. 134, n. 1, p. 9–21, 2004.

DING, S.; XU, X.; NIE, R. Extreme learning machine and its applications. **Neural Computing and Applications**, v. 25, n. 3, p. 549–556, Sep 2014. ISSN 1433-3058. Disponível em: <<https://doi.org/10.1007/s00521-013-1522-8>>.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. 2nd ed. ed. [S.l.]: Wiley, 2001. ISBN 9780471056690,0471056693.

ENGEL, J. **Epilepsy: Global Issues For The Practicing Neurologist : World Federation of Neurology, Seminars in Clinical Neurology**. [S.l.: s.n.], 2005. v. 2.

FARINA, D.; VUJAKLIJA, I.; SARTORI, M.; KAPELNER, T.; NEGRO, F.; JIANG, N.; BERGMEISTER, K.; ANDALIB, A.; PRINCIPE, J.; ASZMANN, O. C. Man/machine interface based on the discharge timings of spinal motor neurons after targeted muscle reinnervation. **Nature Biomedical Engineering**, Macmillan Publishers Limited, part of Springer Nature. SN -, v. 1, p. 0025 EP –, Feb 2017. Article. Disponível em: <<http://dx.doi.org/10.1038/s41551-016-0025>>.

FAUST, O.; ACHARYA, U. R.; MIN, L. C.; SPUTH, B. H. C. Automatic identification of epileptic and background eeg signals using frequency domain parameters. **International Journal of Neural Systems**, v. 20, n. 02, p. 159–176, 2010. PMID: 20411598. Disponível em: <<https://doi.org/10.1142/S0129065710002334>>.

FERGUS, P.; HIGNETT, D.; HUSSAIN, A.; AL-JUMEILY, D.; ABDEL-AZIZ, K. Automatic epileptic seizure detection using scalp eeg and advanced artificial intelligence techniques. **Biomed Res Int**, Hindawi Publishing Corporation, v. 2015, p. 986736, Jan 2015. ISSN 2314-6133. Disponível em: <<http://www.ncbi.nlm.nih.gov/pmc/articles/PMC4325968/>>.

FISHER, R. S.; ACEVEDO, C.; ARZIMANOGLU, A.; BOGACZ, A.; CROSS, J. H.; ELGER, C. E.; ENGEL, J.; FORSGREN, L.; FRENCH, J. A.; GLYNN, M.; HESDORFFER, D. C.; LEE, B.; MATHERN, G. W.; MOSHÉ, S. L.; PERUCCA, E.; SCHEFFER, I. E.; TOMSON, T.; WATANABE, M.; WIEBE, S. Ilae official report: A practical clinical definition of epilepsy. **Epilepsia**, v. 55, n. 4, p. 475–482, 2014. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/epi.12550>>.

FISHER, R. S.; BOAS, W. V. E.; BLUME, W.; ELGER, C.; GENTON, P.; LEE, P.; ENGEL, J. Epileptic seizures and epilepsy: Definitions proposed by the international league against epilepsy (ilae) and the international bureau for epilepsy (ibe). **Epilepsia**, v. 46, n. 4, p. 470–472, 2005. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.0013-9580.2005.66104.x>>.

FISHER, R. S.; CROSS, J. H.; D'SOUZA, C.; FRENCH, J. A.; HAUT, S. R.; HIGURASHI, N.; HIRSCH, E.; JANSEN, F. E.; LAGAE, L.; MOSHE, S. L.; PELTOLA, J.; PEREZ, E. R.; SCHEFFER, I. E.; SCHULZE-BONHAGE, A.; SOMERVILLE, E.; SPERLING, M.; YACUBIAN, E. M.; ZUBERI, S. M. Instruction manual for the ilae 2017 operational classification of seizure types. **Epilepsia**, v. 58, n. 4, p. 531–542, 2017. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/epi.13671>>.

FURUI, S. **Digital speech processing: synthesis, and recognition**. [S.l.]: CRC Press, 2000.

GÜLER, N. F.; ÜBEYLI, E. D.; GÜLER İnan. Recurrent neural networks employing lyapunov exponents for eeg signals classification. **Expert Systems with Applications**, v. 29, n. 3, p. 506 – 514, 2005. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417405000679>>.

GOLDBERGER, A. L.; AMARAL, L. A. N.; GLASS, L.; HAUSDORFF, J. M.; IVANOV, P. C.; MARK, R. G.; MIETUS, J. E.; MOODY, G. B.; PENG, C.-K.; STANLEY, H. E. Physiobank, physiotoolkit, and physionet. **Circulation**, v. 101, n. 23, p. e215–e220, 2000. Disponível em: <<https://www.ahajournals.org/doi/abs/10.1161/01.CIR.101.23.e215>>.

GOTMAN, J. Automatic recognition of epileptic seizures in the eeg. **Electroencephalography and Clinical Neurophysiology**, v. 54, n. 5, p. 530 – 540, 1982. ISSN 0013-4694. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0013469482900384>>.

GUO, L.; RIVERO, D.; DORADO, J.; MUNTEANU, C. R.; PAZOS, A. Automatic feature extraction using genetic programming: An application to epileptic eeg classification. **Expert Systems with Applications**, v. 38, n. 8, p. 10425 – 10436, 2011. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417411003253>>.

GUORONG, W.; DAOQIANG, Z.; LUPING, Z. **Machine Learning in Medical Imaging: 5th International Workshop, MLMI 2014, Held in Conjunction with MICCAI 2014, Boston, MA, USA, September 14, 2014. Proceedings**. 1. ed. [S.l.]: Springer International Publishing, 2014. (Lecture Notes in Computer Science 8679 Image Processing, Computer Vision, Pattern Recognition, and Graphics). ISBN 978-3-319-10580-2, 978-3-319-10581-9.

GUPTA, V.; PRIYA, T.; YADAV, A. K.; PACHORI, R. B.; ACHARYA, U. R. Automated detection of focal eeg signals using features extracted from flexible analytic wavelet transform. **Pattern Recognition Letters**, v. 94, p. 180 – 188, 2017. ISSN 0167-8655. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167865517300934>>.

HARRIS, R. Testing for unit roots using the augmented dickey-fuller test: Some issues relating to the size, power and the lag structure of the test. **Economics Letters**, v. 38, n. 4, p. 381 – 386, 1992. ISSN 0165-1765. Disponível em: <<http://www.sciencedirect.com/science/article/pii/016517659290022Q>>.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. Artmed, 2007. ISBN 9788577800865. Disponível em: <<https://books.google.com.br/books?id=bhMwDwAAQBAJ>>.

HÖLLER, Y.; BATHKE, A. C.; UHL, A. Age, sex, and pathology effects on stability of electroencephalographic biometric features based on measures of interaction. **IEEE Transactions on Information Forensics and Security**, v. 14, n. 2, p. 459–471, Feb 2019. ISSN 1556-6013.

HÖLLER, Y.; BUTZ, K.; THOMSCHEWSKI, A.; SCHMID, E.; UHL, A.; BATHKE, A. C.; ZIMMERMANN, G.; TOMASI, S. O.; NARDONE, R.; STAFFEN, W.; HÖLLER, P.; LEITINGER, M.; HÖFLER, J.; KALSS, G.; TAYLOR, A. C.; KUCHUKHIDZE, G.; TRINKA, E. Reliability of eeg interactions differs between measures and is specific for neurological diseases. **Frontiers in Human Neuroscience**, v. 11, p. 350, 2017. ISSN 1662-5161. Disponível em: <<https://www.frontiersin.org/article/10.3389/fnhum.2017.00350>>.

HUANG, G.; HUANG, G.-B.; SONG, S.; YOU, K. Trends in extreme learning machines: A review. **Neural Networks**, v. 61, p. 32 – 48, 2015. ISSN 0893-6080. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0893608014002214>>.

HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: Theory and applications. **Neurocomputing**, v. 70, n. 1, p. 489 – 501, 2006. ISSN 0925-2312. Neural Networks. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231206000385>>.

HUANG, X.; ACERO, A.; HON, H.-W.; REDDY, R. **Spoken language processing: A guide to theory, algorithm, and system development**. [S.l.]: Prentice hall PTR Upper Saddle River, 2001. v. 1.

INDIC, P.; PRATAP, R.; NAMPOORI, V. P. N.; PRADHAN, N. Significance of time scales in nonlinear dynamical analysis of electroencephalogram signals. **International Journal of Neuroscience**, Taylor & Francis, v. 99, n. 1-4, p. 181–194, 1999. Disponível em: <<https://doi.org/10.3109/00207459908994323>>.

IOSIFIDIS, A.; TEFAS, A.; PITAS, I. On the kernel extreme learning machine classifier. **Pattern Recognition Letters**, v. 54, p. 11 – 17, 2015. ISSN 0167-8655. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167865514003705>>.

JAIN, A. K.; DUIN, R. P. W.; MAO, J. Statistical pattern recognition: a review. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n. 1, p. 4–37, Jan 2000. ISSN 0162-8828.

JIANG, F.; JIANG, Y.; ZHI, H.; DONG, Y.; LI, H.; MA, S.; WANG, Y.; DONG, Q.; SHEN, H.; WANG, Y. Artificial intelligence in healthcare: past, present and future. **Stroke and Vascular**

**Neurology**, BMJ Specialist Journals, v. 2, n. 4, p. 230–243, 2017. ISSN 2059-8688. Disponível em: <<https://svn.bmj.com/content/2/4/230>>.

KHEDHER, L.; RAMIREZ, J.; GORRIZ, J.; BRAHIM, A.; SEGOVIA, F. Early diagnosis of alzheimer's disease based on partial least squares, principal component analysis and support vector machine using segmented mri images. **Neurocomputing**, v. 151, p. 139–150, 2015. ISSN 0925-2312. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231214013137>>.

KRUMIN, M.; SHOHAM, S. Multivariate Autoregressive Modeling and Granger Causality Analysis of Multiple Spike Trains. **Computational Intelligence and Neuroscience**, v. 2010, p. 9, 2010. Disponível em: <10.1155/2010/752428>.

KWIATKOWSKI, D.; PHILLIPS, P. C.; SCHMIDT, P.; SHIN, Y. Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root? **Journal of Econometrics**, v. 54, n. 1, p. 159 – 178, 1992. ISSN 0304-4076. Disponível em: <<http://www.sciencedirect.com/science/article/pii/030440769290104Y>>.

LEDOIT, O.; WOLF, M. A well-conditioned estimator for large-dimensional covariance matrices. **Journal of Multivariate Analysis**, v. 88, n. 2, p. 365 – 411, 2004. ISSN 0047-259X. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0047259X03000964>>.

LESSARD, C.; ENDERLE, J. **Signal processing of random physiological signals**. 1. ed. [S.l.]: Morgan & Claypool Publishers, 2006. (Synthesis Lectures on Biomedical Engineering). ISBN 159829038X,9781598290387.

LEWIS, B.; REICHEL, L. Arnoldi–tikhonov regularization methods. **Journal of Computational and Applied Mathematics**, v. 226, n. 1, p. 92 – 102, 2009. ISSN 0377-0427. Special Issue: The First International Conference on Numerical Algebra and Scientific Computing (NASCO6). Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0377042708002252>>.

LI, D.; XIE, Q.; JIN, Q.; HIRASAWA, K. A sequential method using multiplicative extreme learning machine for epileptic seizure detection. **Neurocomputing**, v. 214, p. 692 – 707, 2016. ISSN 0925-2312. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231216307299>>.

LI, M.; CHEN, W.; ZHANG, T. Classification of epilepsy eeg signals using dwt-based envelope analysis and neural network ensemble. **Biomedical Signal Processing and Control**, v. 31, p. 357 – 365, 2017. ISSN 1746-8094. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1746809416301343>>.

LI, Y.; CUI, W.; LUO, M.; LI, K.; WANG, L. Epileptic seizure detection based on time-frequency images of eeg signals using gaussian mixture model and gray level co-occurrence matrix features. **International journal of neural systems**, World Scientific, p. 1850003, 2018.

LOGAR, C.; WALZL, B.; LECHNER, H. Role of long-term eeg monitoring in diagnosis and treatment of epilepsy. **European Neurology**, v. 34(suppl 1), n. Suppl. 1, p. 29–32, 1994. ISSN 0014-3022. Disponível em: <<https://www.karger.com/DOI/10.1159/000119506>>.

MALMIVUO, J.; PLONSEY, R. *et al.* **Bioelectromagnetism: principles and applications of bioelectric and biomagnetic fields**. [S.l.]: Oxford University Press, USA, 1995.

MARTIS, R. J.; ACHARYA, U. R.; TAN, J. H.; PETZNICK, A.; YANTI, R.; CHUA, C. K.; NG, E. Y. K.; TONG, L. Application of empirical mode decomposition (emd) for automated detection of epilepsy using eeg signals. **International Journal of Neural Systems**, v. 22, n. 06, p. 1250027, 2012. PMID: 23186276. Disponível em: <<https://doi.org/10.1142/S012906571250027X>>.

MATTHEWS, B. Comparison of the predicted and observed secondary structure of t4 phage lysozyme. **Biochimica et Biophysica Acta (BBA) - Protein Structure**, v. 405, n. 2, p. 442 – 451, 1975. ISSN 0005-2795. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0005279575901099>>.

MCEWEN, J. A.; ANDERSON, G. B. Modeling the stationarity and gaussianity of spontaneous electroencephalographic activity. **IEEE Transactions on Biomedical Engineering**, BME-22, n. 5, p. 361–369, Sep. 1975. ISSN 0018-9294.

MELGES, D. B.; INFANTOSI, A. F. C.; FERREIRA, F. R.; ROSAS, D. B. Using the discrete hilbert transform for the comparison between tracé alternant and high voltage slow patterns extracted from full-term neonatal eeg. In: MAGJAREVIC, R.; NAGEL, J. H. (Ed.). **World Congress on Medical Physics and Biomedical Engineering 2006**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 1111–1114. ISBN 978-3-540-36841-0.

MORMANN, F.; KREUZ, T.; RIEKE, C.; ANDRZEJAK, R. G.; KRASKOV, A.; DAVID, P.; ELGER, C. E.; LEHNERTZ, K. On the predictability of epileptic seizures. **Clinical Neurophysiology**, v. 116, n. 3, p. 569 – 587, 2005. ISSN 1388-2457. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1388245704004638>>.

MORMANN, F.; LEHNERTZ, K.; DAVID, P.; ELGER, C. E. Mean phase coherence as a measure for phase synchronization and its application to the eeg of epilepsy patients. **Physica D: Nonlinear Phenomena**, Elsevier, v. 144, n. 3-4, p. 358–369, 2000.

NAVIDI, W.; MURPHY, W. S.; HEREMAN, W. Statistical methods in surveying by trilateration. **Computational Statistics & Data Analysis**, v. 27, n. 2, p. 209 – 227, 1998. ISSN 0167-9473. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167947397000534>>.

NEUMANN, K.; STEIL, J. J. Optimizing extreme learning machines via ridge regression and batch intrinsic plasticity. **Neurocomputing**, v. 102, p. 23 – 30, 2013. ISSN 0925-2312. Advances in Extreme Learning Machines (ELM 2011). Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231212005619>>.

NUWER, M.; COMI, G.; EMERSON, R.; FUGLSANG-FREDERIKSEN, A.; GUÉRIT, J.; HINRICHS, H.; IKEDA, A.; LUCCAS, F.; RAPPELSBERGER, P. Ifcn standards for digital recording of clinical eeg. the international federation of clinical neurophysiology. **Electroencephalography and clinical neurophysiology. Supplement**, Elsevier BV, v. 52, p. 11–14, 1999. ISSN 0424-8155.

OPPENHEIM, A. V.; SCHAFER, R. W.; STOCKHAM, T. G. Nonlinear filtering of multiplied and convolved signals. **Proceedings of the IEEE**, v. 56, n. 8, p. 1264–1291, Aug 1968. ISSN 0018-9219.

PAGNOTTA, M. F.; PLOMP, G. Time-varying mvar algorithms for directed connectivity analysis: Critical comparison in simulations and benchmark eeg data. **PLOS ONE**, Public Library of Science, v. 13, n. 6, p. 1–27, 06 2018. Disponível em: <<https://doi.org/10.1371/journal.pone.0198846>>.

PALANIAPPAN, R.; SUNDARAJ, K.; SUNDARAJ, S. A comparative study of the svm and k-nn machine learning algorithms for the diagnosis of respiratory pathologies using pulmonary acoustic signals. **BMC bioinformatics**, BioMed Central, v. 15, n. 1, p. 223, 2014.

PANAYIOTOPOULOS, C. P. **A Clinical Guide to Epileptic Syndromes and their Treatment**. Springer London, 2010. ISBN 978-1-84628-643-8,978-1-84628-644-5. Disponível em: <<http://gen.lib.rus.ec/book/index.php>>.

PENG, X.; LIN, P.; ZHANG, T.; WANG, J. Extreme learning machine-based classification of adhd using brain structural mri data. **PLOS ONE**, Public Library of Science, v. 8, n. 11, p. 1–12, 11 2013. Disponível em: <<https://doi.org/10.1371/journal.pone.0079476>>.

PENG, Y.; LU, B.-L. Discriminative manifold extreme learning machine and applications to image and eeg signal classification. **Neurocomputing**, v. 174, p. 265 – 277, 2016. ISSN 0925-2312. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231215011704>>.

POLAT, K.; GüNEŞ, S. Classification of epileptiform eeg using a hybrid system based on decision tree classifier and fast fourier transform. **Applied Mathematics and Computation**, v. 187, n. 2, p. 1017 – 1026, 2007. ISSN 0096-3003. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0096300306012380>>.

RAGHU, S.; SRIRAAM, N.; KUMAR, G. P. Classification of epileptic seizures using wavelet packet log energy and norm entropies with recurrent elman neural network classifier. **Cognitive Neurodynamics**, v. 11, n. 1, p. 51–66, Feb 2017. ISSN 1871-4099. Disponível em: <<https://doi.org/10.1007/s11571-016-9408-y>>.

RAHIMI, A.; RECHT, B. Uniform approximation of functions with random bases. In: **2008 46th Annual Allerton Conference on Communication, Control, and Computing**. [S.l.: s.n.], 2008. p. 555–561.

RAHIMI, A.; RECHT, B. Weighted sums of random kitchen sinks: replacing minimization with randomization in learning. **Advances in Neural Information Processing Systems (NIPS)**, v. 2, p. 1316–1323, 01 2008.

RAMGOPAL, S.; THOME-SOUZA, S.; JACKSON, M.; KADISH, N. E.; FERNÁNDEZ, I. S.; KLEHM, J.; BOSL, W.; REINSBERGER, C.; SCHACHTER, S.; LODDENKEMPER, T. Seizure detection, seizure prediction, and closed-loop warning systems in epilepsy. **Epilepsy & Behavior**, v. 37, p. 291 – 307, 2014. ISSN 1525-5050. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1525505014002297>>.

RAMOSER, H.; MULLER-GERKING, J.; PFURTSCHELLER, G. Optimal spatial filtering of single trial eeg during imagined hand movement. **IEEE Transactions on Rehabilitation Engineering**, v. 8, n. 4, p. 441–446, Dec 2000. ISSN 1063-6528.

REHME, A. K.; VOLZ, L. J.; FEIS, D.-L.; BOMILCAR-FOCKE, I.; LIEBIG, T.; EICKHOFF, S. B.; FINK, G. R.; GREFKES, C. Identifying neuroimaging markers of motor disability in acute stroke by machine learning techniques. **Cerebral Cortex**, v. 25, n. 9, p. 3046–3056, 2015. Disponível em: <<http://dx.doi.org/10.1093/cercor/bhu100>>.

RUIZ-GÓMEZ, S. J.; GÓMEZ, C.; POZA, J.; GUTIÉRREZ-TOBAL, G. C.; TOLA-ARRIBAS, M. A.; CANO, M.; HORNERO, R. Automated multiclass classification of spontaneous eeg activity in alzheimer’s disease and mild cognitive impairment. **Entropy**, Multidisciplinary Digital Publishing Institute, v. 20, n. 1, p. 35, 2018.



SANEI, S.; CHAMBERS, J. A. **EEG signal processing**. [S.l.]: John Wiley & Sons, 2007. ISBN 0470025816,9780470025819.

SCHÖLKOPF, B.; SMOLA, B.; SMOLA, A.; SCHOLKOPF, M.; PRESS, M.; BACH, F. **Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond**. MIT Press, 2002. (Adaptive computation and machine learning). ISBN 9780262194754. Disponível em: <<https://books.google.com.br/books?id=y8ORL3DWt4sC>>.

SCHOMER, F. H. L. d. S. D. L. **Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, and Related Fields**. Sixth. [S.l.]: LWW, 2010. ISBN 0781789427,9780781789424.

SHARMA, M.; DHERE, A.; PACHORI, R. B.; ACHARYA, U. R. An automatic detection of focal eeg signals using new class of time–frequency localized orthogonal wavelet filter banks. **Knowledge-Based Systems**, v. 118, p. 217 – 227, 2017. ISSN 0950-7051. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0950705116304816>>.

SHOEB, A. **CHB-MIT Scalp EEG Database**. [S.l.]: physionet.org, 2010.

SHOEB, A. H. **Application of machine learning to epileptic seizure onset detection and treatment, PhD Theses**. [S.l.]: Massachusetts Institute of Technology, 2009.

SONG, J.-L.; HU, W.; ZHANG, R. Automated detection of epileptic eegs using a novel fusion feature and extreme learning machine. **Neurocomputing**, v. 175, p. 383 – 391, 2016. ISSN 0925-2312. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231215015295>>.

SØREIDE, K. Receiver-operating characteristic curve analysis in diagnostic, prognostic and predictive biomarker research. **Journal of Clinical Pathology**, BMJ Publishing Group, v. 62, n. 1, p. 1–5, 2009. ISSN 0021-9746. Disponível em: <<https://jcp.bmj.com/content/62/1/1>>.

SOUZA, A. H.; CORONA, F.; BARRETO, G. A.; MICHE, Y.; LENDASSE, A.; SIMULA, O. Minimal learning machine: A new distance-based method for supervised learning. In: ROJAS, I.; JOYA, G.; GABESTANY, J. (Ed.). **Advances in Computational Intelligence**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. p. 408–416. ISBN 978-3-642-38679-4.

SOUZA, A. H.; CORONA, F.; BARRETO, G. A.; MICHE, Y.; LENDASSE, A. Minimal learning machine: A novel supervised distance-based approach for regression and classification. **Neurocomputing**, v. 164, p. 34 – 44, 2015. ISSN 0925-2312. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231215003021>>.

STROINK, H.; SCHIMSHEIMER, R.-J.; WEERD, A. W.; GEERTS, A. T.; ARTS, W. F.; MC, E.; PEETERS, E. A.; BROUWER, O. F.; PETERS, A. B.; DONSELAAR, C. A. Interobserver reliability of visual interpretation of electroencephalograms in children with newly diagnosed seizures. **Developmental Medicine & Child Neurology**, v. 48, n. 5, p. 374–377, 2006. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1017/S0012162206000806>>.

STROINK, H.; V, C. D.; GEERTS, A.; PETERS, A.; BROUWER, O.; ARTS, W. The accuracy of the diagnosis of paroxysmal events in children. **Neurology**, Wolters Kluwer Health, Inc. on behalf of the American Academy of Neurology, v. 60, n. 6, p. 979–982, 2003. ISSN 0028-3878. Disponível em: <<http://n.neurology.org/content/60/6/979>>.

SUBASI, A.; GURSOY, M. I. Eeg signal classification using pca, ica, lda and support vector machines. **Expert Systems with Applications**, v. 37, n. 12, p. 8659 – 8666, 2010. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417410005695>>.

SUTHERLAND, D. J.; SCHNEIDER, J. G. On the error of random fourier features. **CoRR**, abs/1506.02785, 2015. Disponível em: <<http://arxiv.org/abs/1506.02785>>.

TAGUCHI, T.; TACHIKAWA, H.; NEMOTO, K.; SUZUKI, M.; NAGANO, T.; TACHIBANA, R.; NISHIMURA, M.; ARAI, T. Major depressive disorder discrimination using vocal acoustic features. **Journal of affective disorders**, Elsevier, v. 225, p. 214–220, 2018.

TEIXEIRA, W. A. Imitadores da epilepsia: as crises não-epilépticas fisiológicas. **Journal of Epilepsy and Clinical Neurophysiology**, scielo, v. 13, p. 15–23, 2007. ISSN 1676-2649.

THOPPIL, M. G.; KUMAR, C. S.; KUMAR, A.; AMOSE, J. Speech signal analysis and pattern recognition in diagnosis of dysarthria. **Ann Indian Acad Neurol**, Medknow Publications & Media Pvt Ltd, v. 20, n. 4, p. 352–357, 2017. ISSN 0972-2327. 29184336[pmid]. Disponível em: <<https://www.ncbi.nlm.nih.gov/pubmed/29184336>>.

THURMAN, D. J.; BEGHI, E.; BEGLEY, C. E.; BERG, A. T.; BUCHHALTER, J. R.; DING, D.; HESDORFFER, D. C.; HAUSER, W. A.; KAZIS, L.; KOBAY, R.; KRONER, B.; LABINER, D.; LIOW, K.; LOGROSCINO, G.; MEDINA, M. T.; NEWTON, C. R.; PARKO, K.; PASCHAL, A.; PREUX, P.-M.; SANDER, J. W.; SELASSIE, A.; THEODORE, W.; TOMSON, T.; WIEBE, S. a. Standards for epidemiologic studies and surveillance of epilepsy. **Epilepsia**, v. 52, n. s7, p. 2–26, 2011. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1528-1167.2011.03121.x>>.

TONG, N. V. T. S. **Quantitative EEG analysis methods and clinical applications**. 1 har/cdr. ed. [S.l.]: Artech House, 2009. (Artech House series engineering in medicine and biology). ISBN 159693204X,9781596932043,9781596932050.

VAPNIK, V. **The Nature of Statistical Learning Theory**. Springer New York, 1999. (Information Science and Statistics). ISBN 9780387987804. Disponível em: <<https://books.google.com.br/books?id=sna9BaxVbj8C>>.

WEBB, A. R.; COPSEY, K. D. **Statistical Pattern Recognition**. 3rd edition. ed. [S.l.]: Wiley, 2011. ISBN 978-0-470-68227-2.

WELCH, P. D. **The Use of Fast Fourier Transform for the Estimation of Power spectre: A Method Based on Time Averaging Over Short, Modified Periodograms**. **IEEE Trans. Audio and Electroacoust**, AU-15, 1967. pp. 70-73.

WORLD HEALTH ORGANIZATION. WHO. **Epilepsy**. 2018. Disponível em: <<http://www.who.int/en/news-room/fact-sheets/detail/epilepsy>>. Acesso em: 21/08/2018.

WORRELL, G. A.; PARISH, L.; CRANSTOUN, S. D.; JONAS, R.; BALTUCH, G.; LITT, B. High-frequency oscillations and seizure generation in neocortical epilepsy. **Brain**, v. 127, n. 7, p. 1496–1506, 2004. Disponível em: <<http://dx.doi.org/10.1093/brain/awh149>>.

WU, D.; KING, J.; CHUANG, C.; LIN, C.; JUNG, T. Spatial filtering for eeg-based regression problems in brain–computer interface (bci). **IEEE Transactions on Fuzzy Systems**, v. 26, n. 2, p. 771–781, April 2018. ISSN 1063-6706.

WU, G. R.; CHEN, F.; KANG, D.; ZHANG, X.; MARINAZZO, D.; CHEN, H. Multiscale causal connectivity analysis by canonical correlation: Theory and application to epileptic brain. **IEEE Transactions on Biomedical Engineering**, v. 58, n. 11, p. 3088–3096, Nov 2011. ISSN 0018-9294.

YAMATOOGI, Y.; OHTAHARA, S. Multiple independent spike foci and epilepsy, with special reference to a new epileptic syndrome of “severe epilepsy with multiple independent spike foci”. **Epilepsy Research**, v. 70, p. 96 – 104, 2006. ISSN 0920-1211. Epileptic Syndromes in Infancy and Early Childhood. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0920121106001768>>.


YUAN, X.-C.; PUN, C.-M.; CHEN, C. P. Robust mel-frequency cepstral coefficients feature detection and dual-tree complex wavelet transform for digital audio watermarking. **Information Sciences**, v. 298, p. 159 – 179, 2015. ISSN 0020-0255. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S002002551401130X>>.

ZHANG, G. P. Neural networks for classification: a survey. **IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)**, v. 30, n. 4, p. 451–462, Nov 2000. ISSN 1094-6977.


ZHANG, R.; XU, P.; GUO, L.; ZHANG, Y.; LI, P.; YAO, D. Z-score linear discriminant analysis for eeg based brain-computer interfaces. **PLoS one**, Public Library of Science, v. 8, n. 9, p. e74433, 2013.

## APÊNDICE A – DEMAIS RESULTADOS


Figura 53 – Método MFCC - CBH03 - Resultados em Diagrama de Caixas.




(a) Sensibilidade




(b) Especificidade



(c) Coeficiente de Matthews




(d) Acurácia




(e) AUC da curva ROC

Fonte: do autor.


Figura 54 – Método LPC - CBH03 - Resultados em Diagrama de Caixas.




(a) Sensibilidade




(b) Especificidade



(c) Coeficiente de Matthews




(d) Acurácia




(e) AUC da curva ROC

Fonte: do autor.


Figura 55 – Método da vetorização da Matriz de Covariância - CBH03 - Resultados em Diagrama de Caixas.




(a) Sensibilidade




(b) Especificidade



(c) Coeficiente de Matthews




(d) Acurácia




(e) AUC da curva ROC

Fonte: do autor.


Figura 56 – Método de Extração PDS - CBH03 - Resultados em Diagrama de Caixas.




(a) Sensibilidade




(b) Especificidade



(c) Coeficiente de Matthews




(d) Acurácia




(e) AUC da curva ROC

Fonte: do autor.


Figura 57 – Método de Extração MFCC - CBH02 - Resultados em Diagrama de Caixas.



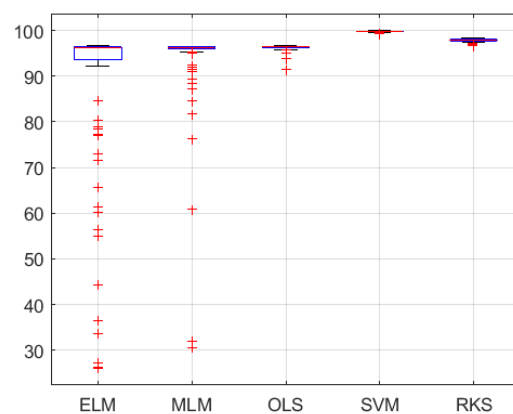
(a) Sensibilidade




(b) Especificidade



(c) Coeficiente de Matthews



(d) Acurácia




(e) AUC da curva ROC


Fonte: do autor.




Figura 58 – Método de Extração MFCC - CBH05 - Resultados em Diagrama de Caixas.




(a) Sensibilidade




(b) Especificidade



(c) Coeficiente de Matthews




(d) Acurácia




(e) AUC da curva ROC

Fonte: do autor.


Figura 59 – Método de Extração MFCC - CBH07 - Resultados em Diagrama de Caixas.




(a) Sensibilidade




(b) Especificidade



(c) Coeficiente de Matthews



(d) Acurácia




(e) AUC da curva ROC

Fonte: do autor.


## APÊNDICE B – ALGUNS PADRÕES EPILEPTIFORME

Figura 60 – Espículas Rolândicas. Paciente de 3 anos de idade. Sonolento. Proeminente deflexão principal descendente desses pontos indica que eles ocupam um campo positivo (FP2 – F4 – F8) e um campo negativo (C4 – P4 – T6).




Fonte: Blume *et al.* (2010).

Figura 61 – Espículas frontais. Idade do paciente, 11 anos. Acordado. Picos ocorrem repetidamente no F4.




Fonte: Blume *et al.* (2010).

Figura 62 – Espículas occipitais. Paciente de 2 anos. Sono leve. O grau de propagação anterior (P4) e contralateral dos pontos occipitais de caráter variável.




Fonte: Blume *et al.* (2010).

Figura 63 – Espículas temporais anterior-mesiais em uma montagem frontal polar-central coronal. Observe o envolvimento principal de F8-A2-T4.




Fonte: Blume *et al.* (2010).

Figura 64 – Poliespículas temporais esquerdas. Paciente de 40 anos. As poliespículas podem ser um pouco mais difíceis de reconhecer do que picos únicos, já que eles não emergem de forma tão intensa da atividade em segundo plano. Estes aparecem principalmente na região médio-temporal esquerda (T3) com disseminação contígua para a região temporal anterior-inferior esquerda (F7).




Fonte: Blume *et al.* (2010).

Figura 65 – Espículas de ondas generalizadas. Idade do paciente, 9 anos. Acordado. Olhos fechados. Após 3 a 4 segundos a descarga de onda espícula envolve todos os eletrodos.



Fonte: Blume *et al.* (2010).

Figura 66 – Ondas de espículas lentas. Paciente, 55 anos. Acordado. Olhos abertos. Essas ondas de pico sincronizadas de 2 Hz são caracteristicamente mais abundantes em um único registro do que as ondas de pico de maior frequência. São observados “vales” eletropositivos proeminentes entre os componentes de ponta e onda.



Fonte: Blume *et al.* (2010).

## APÊNDICE C – CLASSIFICADOR LINEAR DE MÍNIMOS QUADRADOS

Considere  $N$  pares de dados  $\{(\mathbf{x}_\mu, \mathbf{d})\}_{\mu=1}^N$ , em que  $\mathbf{x}_\mu \in \mathbb{R}^{p+1}$  seja o  $\mu$ -ésimo padrão de entrada, lembrando que primeira componente é igual a  $+1$  para poder incluir o *bias* como parâmetro a ser estimado. E  $\mathbf{d}_\mu \in \mathbb{R}^K$  é o rótulo da classe alvo correspondente, com  $K$  denotando o número de classes. Nos classificadores lineares, o objetivo é obter um mapeamento linear entre os dados de entrada (vetores de atributos), e os dados de saída correspondentes

Na etapa de treinamento deve-se selecionar aleatoriamente  $N_1$  pares de dados,  $N_1 < N$ , a partir do conjunto de dados e organizá-los ao longo de colunas de matrizes  $\mathbf{D}$  e  $\mathbf{X}$ , como segue:

$$\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_1, \dots, \mathbf{x}_{N_1}] \quad \text{e} \quad \mathbf{D} = [\mathbf{d}_1, \mathbf{d}_1, \dots, \mathbf{d}_1] \quad (\text{C.1})$$

Dado que tanto os vetores de atributos como os rótulos das classes são vetores coluna, este mapeamento pode ser realizado matematicamente pela equação:

$$\mathbf{d}_n = \mathbf{W}\mathbf{x}_n, \quad (\text{C.2})$$

em que  $\mathbf{W} \in \mathbb{R}^{K \times (p+1)}$  é a matriz responsável pela transformação, e em que cada elemento  $d_{ni}$  do vetor  $\mathbf{d}_n$  corresponde ao resultado da função discriminante na  $i$ -ésima classe. Com isso, a função discriminante destes classificadores consiste na multiplicação do vetor de entrada da amostra atual pela matriz  $\mathbf{W}$ , obtendo um vetor de saída. Então, esta amostra é atribuída à classe  $C_j$ , em que  $C_j$  corresponde à posição do vetor de saída no qual é encontrado o componente de máximo valor.

Não se sabe o valor dos elementos da matriz  $\mathbf{W}$ , mas existem várias técnicas, durante o treinamento dos classificadores, para estimar os pesos desta matriz, com o objetivo de minimizar os erros de atribuições das entradas às classes. A seguir será apresentado uma destas técnicas, que é através do método dos mínimos quadrados ordinários.

Agrupando-se estes vetores em matrizes, tem-se que  $\mathbf{X}$  é a matriz das amostras de entrada, e  $\mathbf{D}$  é a matriz dos rótulos de saída. Assim, a partir destas matrizes, a representada matricialmente por

$$\mathbf{D} = \mathbf{W}\mathbf{X}. \quad (\text{C.3})$$

Caso a matriz  $\mathbf{X}$  seja quadrada a matriz  $\mathbf{W}$  pode ser obtida através da relação abaixo:

$$\mathbf{W} = \mathbf{D}\mathbf{X}^{-1}. \quad (\text{C.4})$$

Nos problemas práticos de classificação, tem-se uma quantidade bem superior de amostras comparada ao número de atributos. Portanto, a matriz  $\mathbf{X}$  não pode ser invertida diretamente. Se faz necessário o uso da matriz pseudoinversa (*Moore-Penrose Pseudoinverse*) conhecida como técnica dos mínimos quadrados ordinários (*Ordinary Least Squares - OLS*). Com isso, visa-se minimizar a soma quadrática dos erros na aproximação do mapeamento.

Assim, temos que:

$$\mathbf{W} = \mathbf{D}\mathbf{X}^\top (\mathbf{X}\mathbf{X}^\top)^{-1}. \quad (\text{C.5})$$

Após o cálculo da matriz  $\mathbf{W}$ , pode-se testar o desempenho do classificador OLS para as amostras que não foram utilizadas para treinamento, comparando a saída estimada pelo classificador,

$$\vec{y} = \vec{w}\vec{x}_i. \quad (\text{C.6})$$

A matriz  $\mathbf{X}\mathbf{X}^\top$  a ser invertida pode estar mal condicionada ou até ser singular, e isto pode levar a resultados numericamente instáveis, o que não é desejável. É recomendado avaliar o posto da o qual é, no máximo, igual ao número de linhas ou colunas (o menor deles). Ou seja, o posto é uma medida do número de linhas ou colunas linearmente independentes de uma matriz.

Para evitar problema de ordem numérica por conta do mal-condicionamento da matriz, pode-se utilizar a regularização de Tikhonov (LEWIS; REICHEL, 2009). Portanto, a estimativa da matriz  $\mathbf{W}$  é dada por:

$$\mathbf{W} = \mathbf{D}\mathbf{X}^\top (\mathbf{X}\mathbf{X}^\top + \gamma\mathbf{I})^{-1} \quad (\text{C.7})$$

em que  $\gamma > 0$  é a contante de regularização e  $\mathbf{I}$  é a matriz de identidade de dimensões igual da matriz  $\mathbf{W}$ ,  $(p + 1) \times (p + 1)$ .