

resolvendo o problema da STFT com relação à resolução. As ferramentas analisadas foram divididas em dois grupos: lineares e não-lineares. A seguir, serão apresentadas as ferramentas utilizadas pelos pesquisadores ao longo da pesquisa bibliográfica com a divisão citada.

Extração de características com ferramentas lineares

Uma das ferramentas lineares mais utilizadas nos sistemas detectores de epilepsia é a “wavelet”, podendo ser combinada com outras ferramentas dependendo das necessidades do autor. As bases da transformada “wavelet” não são mais as senóides ortogonais de Fourier, mas um conjunto arbitrário de versões dilatadas (ou comprimidas) e transladadas no tempo, de uma função básica (“wavelet” mãe) escolhida [83], [98], [30], [60], [16], [99]. As “wavelet” mãe mais utilizadas estão apresentadas na Tabela 4.4.

“Wavelet”	
Família	Usabilidade(%)
Daubechies 4	47,8%
Coiflet 1	13,0%
Morlet	6,5%
Coiflet 3	4,3%
Dyadic	3,8%
Daubechies 2	2,2%
Daubechies 10	2,2%
Mellin	2,2%
Biorthogonal	2,2%
Lemarie	2,2%
Mexican hat	1,9%
Não descreve	10,9%

Tabela 4.4: WT mãe geral

As “wavelet” mães mais utilizadas pelos pesquisadores foram a Daubechi (Daub4), e a Coiflet(Coif1). Na maioria dos trabalhos, a escolha da “wavelet” mãe não é justificada, ou seja, ela é simplesmente citada. Um dos poucos trabalhos que justificaram a escolha [6]

,[72] da “Wavelet” mãe foi a Coif1. O número de pesquisas que não citaram a “wavelet” mãe gira em torno de 10,9%.

Após a escolha da “wavelet” mãe, o sinal é reconstruído nos seus respectivos níveis de decomposição e, logo em seguida, dependendo da metodologia empregada, são aplicados outros métodos para extração de parâmetros. Esses dados estatísticos são apresentados na Tabela 4.5.

Usabilidade da extração de características nos níveis de reconstrução da WT	
Descrição	Usabilidade (%)
Medidas de Energia	38,6%
Medidas de Entropia	28,1%
“Sharpness”	13,5%
Duração do evento	7,0%
Amplitude	5,3%
Média	3,6%
Potencia media	1,8%
Desvio padrão	1,8%
Media	1,8%
“Slope”	1,8%
“Harmonic wavelet”	1,8%
Complexidade	1,8%
Coefficiente DE variação	1,8%
Probabilidade condicional	1,8%
Medida de fase	1,8%

Tabela 4.5: Extração de características com WT

A análise dos resultados apresentados na Tabela 4.5 conduz às seguintes conclusões: primeiramente, a ferramenta mais utilizada para quantizar os sinais resultantes da aplicação da “Wavelet” foram as medidas de energia, com uma usabilidade de 38,6% [79]. A literatura apresenta algumas variações para medidas de energia, tais como: energia (26,3%), energia relativa (8,8%) e a energia acumulada (3,5%).

Outra ferramenta que apresentou uma grande usabilidade foi a medida de Entropia.

Assim como a energia, a entropia também apresenta variações: a entropia de Shannon tem uma usabilidade de 15,8% e isso se deve ao fato de ser uma das primeiras ferramentas de entropia. As outras ferramentas tiveram pouca representatividade, são elas: entropia Tsallis com 3,5%, entropia Scott-Tsallis com 3,5%, entropia normalizada com 3,5% e entropia Relativa com 1,8%.

A medida de *Sharpness* ou agudez tem uma representação de 13,5%. Essa medida quantiza o quanto agudo é um pico de uma onda.

A duração do evento é uma medida que busca quantificar o início e o fim de um evento epileptogênico. Em particular, na abrangência desse contexto, ela apresenta uma usabilidade de 7,0%.

Os valores obtidos no cálculo da amplitude buscam distinguir os pontos de máximo e mínimo do EEG de fundo com o EEG patológico. A representatividade dessa ferramenta no conjunto analisado é de 5,3%. Finalizando, as medidas que tiveram melhor representatividade, a média apresentou uma usabilidade de 3,6%.

Embora seja reconhecida a importância de todas as outras métricas para quantizar as características do sinal, essas medidas aparecem, pelo menos nesta pesquisa, com baixa usabilidade.

Ainda tangenciando o grande grupo das ferramentas lineares, embora outro ponto de vista, são apresentados, na sequência, os resultados de algumas metodologias que preferem extrair as características diretamente do sinal, deixando de utilizar a WT. Essas ferramentas, juntamente com a sua usabilidade, estão descritas na Tabela 4.6.

Usabilidade da extração de características diretamente do sinal			
Descrição	(%)	Descrição	(%)
FFT	6,6%	“Slope”	5,9%
Energia	5,3%	Duração do evento	5,3%
Amplitude mínima	5,3%	Amplitude máxima	5,3%
Variância 2º momento	5,3%	Ângulo	5,3%
Sexta potência	4,6%	Entropia espectral	3,3%
Média	3,3%	Duração média da onda	2,6%
“Hjorth-Complexi.”(HC)	2,6%	Diferença mín. e máx.	2,6%
Amplitude média da onda	2,6%	Pico de frequência (50 Hz)	1,9%
Desvio padrão	1,9%	“Hjorth”-Mobilidade (HM)	1,9%

Mediana	1,9%	Energia não linear	1,9%
Cruzamento por zeros	1,9%	Auto-correlação	1,9%
“Skewness” 3º momento	1,9%	Dipolo	1,3%
Derivativa	1,3%	Coefficiente de variação	1,3%
Curvatura	1,3%	Soma	1,3%
Comprimento da curva	1,3%	“Kurtosis” 4º Momento	1,3%
AR	0,6%	Distância entre pontos	0,6%
Comprimento da onda	0,6%	Integral	0,6%
Fator da crista	0,6%	“Skew”	0,6%
Faixa Freq. Delta 0,5 a 4 Hz	0,6%	Faixa Freq. Alfa 8 a 13 Hz	0,6%
Faixa Freq. Teta 4 a 8 Hz	0,6%	Faixa Freq. Beta 13 a 30 Hz	0,6%
Faixa Freq. Gama 30 a 48 Hz	0,6%	Auto-covariância	0,6%

Tabela 4.6: Extração de características diretamente no sinal.

A partir das informações obtidas sobre as ferramentas empregadas na extração de características diretamente do sinal, que se encontram na Tabela 4.6, é realizada uma análise global possibilitando a comprovação de que algumas das ferramentas utilizadas em conjunto com a WT, demonstradas na Tabela 4.5, também são utilizadas na extração direta do sinal.

A ferramenta que obteve maior usabilidade foi a FFT, em torno de 6,6%. Outra ferramenta bastante utilizada é o *Slope*, tendo como objetivo medir o declive do pico. Geralmente, uma espícula ou ondas agudas (espícula onda) possuem este declive mais acentuado quando comparados com o EEG de base. A usabilidade dessa medida foi 5,9%.

A duração do evento que obteve uma usabilidade de 5,30%, tem por finalidade verificar a duração de único evento, em que é possível constatar que a duração do evento epileptogênico é diferente do ruído que, por sua vez, distingue do EEG de base.

Tanto as medidas de amplitude mínima, quanto máxima obtiveram uma usabilidade de 5,3%. Essas medidas visam diferenciar os ruídos, que geralmente possuem amplitudes maiores, dos eventos epileptogênicos.

A variância obteve 5,3% de usabilidade. Ela indica quão longe, em geral, os seus

valores se encontram do valor esperado. Para o sinal EEG normal, essa variação é menor quando comparada com um sinal patológico.

O ângulo mede o grau de abertura de um pico. A sua usabilidade perante a literatura foi de 5,3%.

A entropia espectral aplica a entropia que é uma medida não linear sobre os resultados da FFT. De maneira geral, é uma medida de regularidade no sinal, sua usabilidade ficou em torno de 3,31%.

A aplicação da média no sinal EEG tem como objetivo encontrar as amplitudes médias do sinal EEG de base (normal) que devem ser menores quando comparadas com as médias do sinal patológico. A sua usabilidade foi de 3,31% nesta pesquisa.

Dando continuidade à extração de parâmetros, será retratada na seção seguinte uma outra vertente, os métodos não-lineares.

Extração de parâmetros com métodos não-lineares

Métodos não-lineares incluem uma série de métodos estatísticos para analisar o EEG nos domínios do tempo, frequência e tempo-frequência [50], [94], [95], [67].

A Tabela 4.7 apresenta o estudo estatístico realizado com as publicações embasadas em ferramentas não-lineares.

Metodos não lineares	
Descrição	Usabilidade(%)
Expoente de Lyapunov máximo (Lmax)	19,2%
Dimensão correlação efetiva(D*)	15,3%
Coerência da fase R	15,3%
Correlação cruzada Cmax	7,6%
“Gabor atom density”	7,6%
Fluxo local ($\wedge^*$)	3,8%
Algoritmo complexidade AC	3,8%
“Surrogate” (D , Lmax, $\wedge^*$, AC)	3,8%
Probabilidade condicional	3,8%
Medida de fase R	3,8%
Entropia de “Shannon”	3,8%
Energia não linear	3,8%

Fórmula Bayes	3,8%
“Logistic regression”	3,8%

Tabela 4.7: Extração de características com ferramentas não lineares diversas

Durante as crises de epilepsia, os sinais EEG apresentam oscilações de frequência e fase (medida de fase R-3,85%) de forma complexa. O sincronismo (acoplamento) entre componentes em frequência do sinal EEG tem um papel importante nas atividades cerebrais. Estatísticas de alta-ordem [63] (“high order statistics” - HOS) como a dimensão correlação efetiva (D^*), com usabilidade de 15,38%, descrevem o acoplamento entre fases.

Dentre os métodos não-lineares, ainda há as medidas caóticas, baseadas em dinâmica não-linear [61] [77]. Um destes métodos é o expoente Lyapunov máximo (L_{max}), que mede o grau de caos no sistema. Nessa pesquisa, a sua usabilidade foi 19,23%.

4.3.3 Métodos de detecção

Os métodos de detecção recebem os vetores de características e, a partir desses dados, tomam as suas respectivas decisões. Em se tratando de sistemas detectores de epilepsia, é verificada a possibilidade de caracterizar o sinal analisado como pertencente ao grupo de crise ou não crise. Os detectores podem ser embasados em técnicas de inteligência artificial [21], [74], [69], [104], [3], matemáticas ou limiares [41]. Na Tabela 4.8, são apresentados os métodos de reconhecimento mais comuns.

Métodos para detecção	
Descrição	Usabilidade (%)
Redes neurais	61,5%
Threshold	30,7%
Regras heurísticas	5,7%
Medidas de distância	1,9%

Tabela 4.8: Algoritmos para detecção de crises.

Ocasionalmente, algumas metodologias de detecção podem combinar mais de um

método, na tentativa de melhorar o resultado final. Entre essas combinações, as mais utilizadas são as redes neurais com regras heurísticas ou threshold [12]. De acordo com a Tabela 4.8, a maioria dos sistemas pesquisados utilizam redes neurais artificiais na etapa de detecção. Quando se fala em rede neural, existe uma quantidade variada de algoritmos [27]. Para facilitar a análise, a Tabela 4.9 ilustra as metodologias mais utilizadas.

Métodos para detecção com rede neural	
Descrição	Usabilidade (%)
“Backpropagation”	23,0%
MLP	15,3%
PNN	5,7%
RBF	3,8%
“Backpropagation time delay”	3,8%
ART	3,8%
SOM	1,9%
TDNN	1,9%

Tabela 4.9: Redes neurais mais utilizadas

A partir dos resultados apresentados na Tabela 4.9, é pertinente concluir que a rede neural mais utilizada foi a “backpropagation” com usabilidade de 23,0%. Já a MLP obteve um resultado de 15,3%. E por último, a PNN obteve uma usabilidade de 5,7%.

As outras redes neurais, muito embora os pesquisadores que as adotaram afirmassem que o sistema final consegue classificar bem os eventos, tiveram baixa usabilidade nesta pesquisa.

4.4 Análise específicas dos trabalhos associados à abordagem escolhida

Análise dos trabalhos que possuem maior semelhança foi realizada no sentido de ilustrar melhor a escolha da metodologia na qual o sistema desenvolvido se apóia, além de refinar os cálculos estatísticos dos dados obtidos na análise geral. Para esta análise, foram selecionados 25 artigos, levando em consideração as ferramentas utilizadas na extração de

características e o sistema reconhecedor utilizado. Os resultados serão apresentados.

4.4.1 Parâmetros para coleta do sinal

A estatística dos trabalhos semelhantes que apresentam as informações para coletar o sinal EEG estão descritas nas Tabelas 4.10 e 4.11.

Porcentagem dos dados informados	
Parâmetros	Valor médio informado
Número de pacientes	73,3%
Quantidade de canais	43,3%
Taxa de amostragem	76,6%
Quantidade de horas	56,6%
Tipo de epilepsia	30,0%
Tipo de janelamento	10,3%
Tamanho da janela	36,6%
Sobreposição do janelamento	6,6%

Tabela 4.10: Parâmetros específicos para aquisição

Média específica dos dados informados	
Parâmetros	Valor Médio
Número de pacientes	10
Número de canais	7
Taxa de amostragem	127 Hz
Quantidade de horas	3,8 h/paciente
Tamanho da janela	213 pontos (1,06 s)
Tempo médio de previsão	4,9 min

Tabela 4.11: Média específica dos dados informados

Comparando os dados obtidos na análise geral, apresentados na Tabela 4.2, com a análise específica demonstrada na Tabela 4.11, é possível concluir que o número médio de pacientes aumentou. Esse aumento é justificável devido ao grande número de pacientes

utilizados no trabalho de Webber et al. [102] e Lui et al. [54], que foram selecionados para a análise específica. O tamanho da janela diminuiu consideravelmente. Esse fato se deve à eliminação dos trabalhos que empregam ferramentas não lineares e, geralmente, utilizam janelas com maiores quantidades de pontos. Noutro aspecto do problema, a Tabela 4.12 aborda as medidas de desempenho que são utilizadas para quantificar os resultados dos trabalhos.

Média específica dos desempenhos	
Parâmetros	Valor Médio
Acerto	84,0%
Erro	9,0%
VP	63,1%
VN	28,2%
FP	9,6%
FN	10,6%
Sensibilidade	86,0%
Especificidade	89,8%

Tabela 4.12: Medidas de desempenho

Essas metodologias para medidas de desempenho foram matematicamente detalhadas no Capítulo 1.

4.4.2 Métodos de extração de características

Os métodos de extração de características também apresentaram diferenças estatísticas bastantes notáveis, veja as alterações a seguir.

Extração de características com ferramentas lineares

As “wavelets” mais utilizadas estão apresentadas na Tabela 4.13.

“wavelet”	
Família	Usabilidade (%)
Daubechies 4	38,9%

Coiflet 1	33,3%
Daubechies 2	5,6%
Daubechies 10	5,6%
Mellin	5,6%
Lemarie	5,6%
Não descreve	5,6%

Tabela 4.13: “Wavelet” mais utilizadas

A “wavelet” mãe mais utilizada pelos pesquisadores foi a Daubechi (Daub4). Mas existe uma grande quantidade de autores que utilizaram a Coiflet (Coif1). De acordo com os valores informados na Tabela 4.13, a usabilidade de ambas estão bem próximas. Os autores que não se preocuparam em esclarecer qual a “wavelet” mãe é utilizada permaneceu praticamente estável. Após escolher a “wavelet” mãe, o sinal é reconstituído nos seus respectivos níveis de decomposição e, logo em seguida, são aplicados outros métodos para extração de parâmetros. Esses dados estatísticos são apresentados na Tabela 4.5.

Extração de características diretamente da “wavelet”	
Ferramentas utilizadas	Usabilidade (%)
Medidas de energia	31,3%
Medidas de entropia	24,9%
Duração do evento	6,3%
Amplitude relativa	6,3%
Complexidade	3,1%
Média absoluta	3,1%
Potência média	3,1%
Desvio padrão	3,1%
Razão da média absoluta	3,1%
“Sharpness”	3,1%
“Slope”	3,1%
“Harmonic wavelet”	3,1%

Tabela 4.14: Ferramentas utilizadas

Analisando-se os dados que estão apresentados na Tabela 4.5, conclui-se que a energia obteve maior usabilidade que as outras ferramentas.

Existe uma grande diversidade de ferramentas que calculam a energia de uma sequência de sinal [32]. As variações encontradas estão apresentadas na Tabela 4.15.

Extração de características através da energia	
Ferramentas utilizadas	Usabilidade (%)
Energia	18,8%
Energia relativa	12,5%

Tabela 4.15: Variação da energia

Outra ferramenta que obteve uma grande usabilidade foi a entropia. Entretanto, essa ferramenta possui grande diversidade dos métodos para calcular.

A Tabela 4.16 apresenta algumas dessas variações e as suas usabilidades.

Extração de características com a entropia	
Ferramentas utilizadas	Usabilidade(%)
Entropia “Shannon”	12,5%
Entropia “Tsallis”	3,1%
Entropia “Scort-Tsallis”	3,1%
Entropia normalizada	3,1%
Entropia relativa	3,1%

Tabela 4.16: Variação da entropia

Apesar da variação nos resultados estatísticos, comparando-se as Tabelas 4.5 e 4.14, a energia continua sendo a ferramenta de extração de características com usabilidade mais acentuada. Logo em seguida a entropia, especificamente a entropia Shannon como observado na Tabela 4.16.

Nesta análise, a diferença entre essas ferramentas é bastante pequena. Além das ferramentas baseadas na WT, existem aquelas metodologias que extraem as características diretamente do sinal sem utilizar a WT.

Essas ferramentas estão descritas na Tabela 4.17.

Extração de características diretamente do sinal			
Ferramentas lineares	%	Ferramentas lineares	%
Máximo	7,3%	Ângulo	7,3%
Mínimo	7,3%	Duração do evento	6,1%
“Slope”	6,1%	Média	4,8%
Duração média da onda	4,8%	Desvio padrão	3,6%
Mediana	3,6%	Amplitude média	3,6%
Energia	3,6%	Diferença mín. e máx.	3,6%
Entropia espectral	3,6%	Dipolo	2,4%
Comprimento da curva	2,4%	Energia não linear	2,4%
Derivativa	2,4%	Curvatura	2,4%
Coeficiente de variação	2,4%	Cruzamento por zeros	2,4%
Soma	2,4%	Variância - 2º momento	2,4%
Pico frequência (50 Hz)	2,4%	“Hjorth”- mobilidade(HM)	2,4%
“Hjorth”-Complexidade(HC)	2,4%	“Skewness” 3º momento	1,2%
“Skew”	1,2%	Integral	1,2%
FFT	1,2%	Comprimento da onda	1,2%

Tabela 4.17: Extração de características com ferramentas lineares diversas

As ferramentas de extração de características que obtiveram maior usabilidade na pesquisa com publicações específicas foram: parâmetros relacionados ao Ângulo (7,3%), valores de máximo (7,3%), valores de mínimo (7,3%), duração do evento (6,1%) e Slope (6,1%). As outras ferramentas, apesar de terem certa representatividade nesta pesquisa, obtiveram uma baixa usabilidade.

A partir dos resultados atuais apresentados na Tabela 4.17, que é a análise específica dos trabalhos, conclui-se que os valores de usabilidade ficaram bem próximos, quando comparados com resultados anteriores, demonstrados na Tabela 4.6.

Extração de parâmetros com métodos não-lineares

Dentro do contexto, a seleção dos trabalhos foi conduzida de forma a contemplar diferentes ferramentas de extração de características. Mas após a seleção do grupo específico, as únicas características não-lineares que ainda continuaram a ser utilizadas foram a energia não linear e a entropia. Ambas apresentaram praticamente as mesmas usabilidades.

4.4.3 Métodos de detecção

As ferramentas utilizadas para detecção das características extraídas, anteriormente apresentadas na Tabela 4.8, quando comparadas com a Tabela 4.18, não apresentaram mudanças drásticas na ordem de usabilidade.

Na Tabela 4.18, são apresentados os métodos de reconhecimentos mais comuns para esta análise.

Métodos para detecção	
Descrição	Usabilidade (%)
Redes neurais	54,5%
“Threshold”	18,1%
Regras heurísticas	13,6%
Medidas de distância	9,1%

Tabela 4.18: Algoritmos para detecção de crises

Muito embora seja reconhecido que os algoritmos de redes neurais apresentem grande diversidade, no geral, essa ferramenta continua com grande taxa de usabilidade na etapa de detecção.

Para contextualizar melhor a diversidade das redes neurais, na Tabela 4.19 são apresentados os algoritmos mais utilizados.

Métodos para detecção com rede neural	
Descrição	Usabilidade (%)
“Backpropagation”	22,7%
MLP	18,1%
PNN	9,0%

RBF	4,5%
ART	4,5%

Tabela 4.19: Redes neurais mais utilizadas

Tal como anteriormente apresentado nas Tabelas 4.8 e 4.9, os resultados obtidos na análise específica, demonstrados nas Tabelas 4.18 e 4.19, embora apresentem algumas diferenças, analiticamente conclui-se que as redes neurais são a principal metodologia para detecção. Tendo-se como preferência a utilização do “backpropagation” (22,7%), seguido pela MLP (18,1%) e por último, a PNN com 9,0%. As outras metodologias tiveram baixa usabilidade.

A seguir, concluídas as análises estatísticas apresentadas anteriormente.

4.5 Conclusão

Apesar do grande avanço que as técnicas de EEG quantitativo (qEEG) vem alcançando, sua aplicação continua sendo limitada. Diversas ferramentas têm sido desenvolvidas para a análise do qEEG por meio de técnicas matemáticas que lidam com os dados nos domínios do tempo, frequência e tempo-frequência.

Cada domínio favorece a análise de um aspecto do sinal e encontra aplicação em um campo, como o diagnóstico de crises epiléticas por detecção de picos. A detecção de picos no sinal qEEG também envolve o desenvolvimento de algoritmos computacionais. O que muito se discute é a limitação de tais algoritmos, que, por falta de definição específica, não identificam alguns picos ou encontram picos inexistentes. Apesar disso, esses algoritmos facilitam o trabalho de análise dos especialistas, em alguns casos, sendo indispensáveis nos diagnósticos.

A partir dos resultados anteriores, os comentários a seguir são conclusivos para a construção do sistema detector de crises. No entanto, os sistemas dentro dos padrões da literatura atual, devem apresentar resultados semelhantes aos expostos na sequência.

Primeiramente, a análise dos resultados na Tabela 4.11 fornecem informações para a formação da base de dados, de acordo com os seguintes critérios:

- Número de pacientes: 10;

- Número de canais: 7;
- Taxa de amostragem: 127 Hz;
- Quantidade de horas: 3,8 h/paciente;
- Tamanho da janela: 213 pontos.

Quanto ao segundo aspecto, em que o objetivo é escolher a WT mãe com maior usabilidade, a Tabela 4.13 permite focar em duas funções básicas:

- Daubechies (Daub4);
- Coiflet (Coif1).

Na Tabela 4.14, foram apresentadas as principais ferramentas utilizadas para extrair características provenientes dos sinais resultantes da WT. Abaixo estão apresentadas as seguintes ferramentas relevantes:

- Medidas de energia;
- Medidas de entropia (Shannon);
- Duração do evento;
- Medidas de amplitude (máximo, mínimo, etc.).

Até o momento, foram apresentados os resultados da escolha da WT mãe, podendo ser aplicada em conjunto com outras ferramentas (energia, entropia, etc.). Ocasionalmente, pesquisadores podem extrair características diretamente do sinal. Essas ferramentas foram citadas na Tabela 4.17 e as principais estão descritas a seguir:

- Medidas de amplitude (máxima, mínima, etc.);
- Ângulo (entre a subida e descida do evento);
- Duração do evento;
- “Slope” (ângulo de descida do evento);
- Média;
- Desvio padrão;

- Energia;
- Diferença mín. e máx.

Com relação aos métodos utilizados para detectar os eventos patológicos, inicialmente a Tabela 4.18 ilustrou os métodos encontrados na literatura. A partir destes resultados, procedeu-se uma análise que resultam nos métodos com maior relevância:

- “Backpropagation”;
- PNN.

O desempenho médio dos sistemas para a análise geral é apresentado na Tabela 4.2 e para específica na Tabela 4.11. Para os dados específicos, os valores médios são: acerto de 84,0%, erro 9,0%, sensibilidade 86,0% e a especificidade 89,8%.

Nesse trabalho foi encontrada grande dificuldade para definir o número ideal de pacientes, quantidade de canais, horas de EEG a serem processadas e o tamanho do janelamento das épocas. Esses dados estão apresentados nas Tabelas 4.1 e 4.10. A Tabela de resultados específicos 4.10 informa os seguintes dados médios: 73,3% dos artigos citam o número de pacientes, apenas 43,3% informam a quantidade de canais utilizados, 76,6% comentam sobre a taxa de amostragem para adquirir os EEG, 56,6% relatam a quantidade de horas processadas, apenas 30,0% descrevem o tipo de epilepsia, com relação ao tipo de janelamento apenas 10,3%, 36,6% falam sobre o tamanho da janela.

Tendo em vista que esses dados são fundamentais para o início de qualquer pesquisa relacionada a processamento de sinais EEG, torna-se difícil estabelecer estudos comparativos e até mesmo reproduzir fielmente o trabalho da literatura considerado.

O tempo médio de previsão geral de crises é apresentado na Tabela 4.2, e o específico na Tabela 4.11. Esse tempo é variável de acordo com a técnica utilizada. Para metodologias mais simples, como por exemplo o modelo AR, o tempo situa-se em torno de segundos. Para técnicas híbridas, incluindo os sistemas detectores baseados em ferramentas não lineares, lineares e WT, esse tempo é refinado para ordem de minutos.

Os resultados ilustrados nesta seção objetivam esclarecer os aspectos da construção do sistema que será apresentado no próximo Capítulo. Visto que existe uma ampla gama de ferramentas para extração de características e algoritmos para detecção, de forma a identificar as mais relevantes, foram consideradas as pesquisas já citadas anteriormente.

Ou seja, as ferramentas de extração e detecção que foram citadas são utilizadas para construir os sistemas apresentados no Capítulo 5.

Capítulo 5

Desenvolvimento do projeto

Neste capítulo, serão apresentados os critérios para formação da base de dados, medidas de desempenho, estudo sobre os parâmetros utilizados e as metodologias desenvolvidas.

5.1 Base de dados

Os sinais de EEG utilizados para constituírem a base de dados e validar a pesquisa foram adquiridos tanto em pacientes com crises epiléticas quanto em pacientes normais [97]. A taxa de amostragem utilizada para adquirir os sinais é de 200 Hz, aplicando-se um pré-filtro passa baixa em 70 Hz com uma resolução de 12 bits. Os eletrodos utilizados para captação dos sinais possuem o formato de um disco, sendo compostos por uma liga de Ag-AgCl. Esse tipo de eletrodo é fixado no escalpo do paciente obedecendo ao sistema internacional (SI) 10-20 [58]. São fixados 19 eletrodos no escalpo e dois nas orelhas, podendo-se utilizar diversas configurações. Para este trabalho, escolheu-se a configuração bipolar e foram selecionados os seguintes canais para análise: F7-C3, F8-C4, T6-O2 e T5-O1, de acordo com Figura 5.1:

5.1.1 Janelamento do sinal

A partir dos sinais armazenados, visando avaliar o desempenho e o treinamento do classificador, foram selecionados 891 segmentos de EEG, para constituírem a base de dados. Os segmentos selecionados podem conter as seguintes características: descargas epiléticas provocadas por tumores, descargas irregulares de epilepsia, artefatos de Eletromiografia

(EMG), crises psicomotoras e crises de ausência.




Figura 5.1: Canais de EEG utilizados para análise

O tamanho de todos os segmentos foi fixado em 1 s, utilizando-se o janelamento retangular, como mostra a Figura 5.2:




Figura 5.2: Janelamento do sinal

O janelamento foi aplicado em cada parte dos respectivos canais de EEG, visando os pontos de interesse, de forma a manter em cada segmento as características necessárias para detecção de crises epiléticas. Os períodos de EEG patológicos geralmente possuem espículas com duração entre 20 a 70 ms e ondas agudas que variam entre 70 a 200 ms [58], e as manifestações das crises geralmente são registradas em EEG variando de 0,5 a 30 Hz [28]. Portanto 1 s de janelamento fornece todas as características necessárias para a identificação dos padrões epileptogênicos.

5.1.2 Formação da base de dados

A base de dados foi dividida em dois grupos: treinamento e teste, como mostrado na Figura 5.3:




Figura 5.3: Formação da base de dados

O conjunto de treinamento é formado por trechos que contém eventos epileptiformes, ruídos e sinais normais, com 556 segmentos apresentados na Figura 5.3, correspondendo a 60% de todos os sinais utilizados. Para o conjunto de teste utilizaram-se 335 segmentos, apresentados na Figura 5.3, sendo estes diferentes do conjunto de treinamento, contendo eventos epiléticos, ruídos e sinais normais, correspondendo a 40% de todos os sinais utilizados.

5.2 Estudo dos parâmetros utilizados

O estudo dos parâmetros visa a seleção do número adequado de ferramentas, eliminando-se os redundantes que não contribuem significativamente para o processo de reconhecimento. Para atingir tal meta, vários pesquisadores empregam estratégias distintas. Uma das estratégias empregadas é a correlação [72] entre os parâmetros obtidos do conjunto com EEG normal e com os demais sinais EEG. Considera-se que, quanto menor a correlação, mais distintas estão as características. Logo, a rede neural conseguirá classificá-las adequadamente. Outro procedimento a ser destacado é o teste estatístico T2 [72], que se baseia nas diferenças entre os parâmetros por meio de medidas de sua média e sua covariância.

Neste trabalho, optou-se em realizar uma análise visual dos parâmetros, levando em consideração a pesquisa realizada no Capítulo 4. Sendo assim eles foram divididos em cinco grupos: parâmetros wavelet, frequência, amplitude, ângulo e período, e estatísticos. Nas próximas seções, será detalhado cada um desses grupos, para tal finalidade, foi processada a parte da base de dados destinada ao teste, representando 40 % do total.

5.2.1 Parâmetros relacionados a frequência

As características dos potenciais elétricos cerebrais variam entre 20 a 500 uV e as suas oscilações são mais ou menos rítmicas, com uma banda de frequência variando entre 0,5 a 30 Hz.

Portanto, a extração de características nesse domínio ressalta as variações sofridas pelo sinal relacionadas à frequência. Um sinal patológico contendo crises epiléticas, apresenta uma ampla banda de frequência entre 2 e 25 Hz [45], dependendo do tipo de crise.

Os artefatos que são captados em conjunto com o sinal EEG, tendem a manifestar-se em frequências mais elevadas quando comparados às manifestações epiléticas.

Em uma primeira análise, esses parâmetros são sensíveis a alterações de frequências, podendo quantizar de forma eficiente essas variações.

Para calcular os parâmetros relacionados a frequências, primeiramente, utiliza-se a sobreposição de janelas. Como o sinal foi janelado em épocas de 1 s (200 amostras) e deseja-se calcular a FFT a cada 128 amostras, deve-se então aplicar uma sobreposição de 56 pontos, como representado na Figura 5.4.




Figura 5.4: Sobreposição de janelas e resultado do espectro

A formulação para calcular o espectro está representada na Equação 5.1.

$$X(k) = \sum_{n=1+(m-1)N-D}^{m(N-D)+D} x(n)\omega_N^{(n-1)(k-1)} \quad (5.1)$$

$$E(k) = \frac{1}{N} \sum_{k=1}^N |X(k)| \quad (5.2)$$

$$\omega_N = e^{(-2\pi i)/N} \quad (5.3)$$

Onde:

$X(k)$: Espectro de frequência;

m : Número de janelas aplicado na época (Para Figura 5.4 é 2);

N : Comprimento de dados da janela utilizada;

D : Número de pontos utilizados na sobreposição;

$E(k)$: Módulo do espectro médio.

Nos gráficos que seguem a cor azul (+) representa os dados de EEG basal, já a cor verde (*) os artefatos e a cor vermelha (o) as crises. As Figuras 5.5 e 5.6 apresentam a amplitude do módulo de $E(k)$ para os diferentes tipos de épocas, como demonstrado na Figura 5.4. Essas ferramentas apresentaram uma distinção satisfatória entre os sinais de crises e artefatos com os sinais de EEG basal.




Figura 5.5: Módulo do espectro médio $E(k)$ na primeira janela




Figura 5.6: Módulo do espectro médio $E(k)$ na segunda janela

A frequência dominante (ou máxima amplitude de $|X(k)|$) em cada janela está representada nas Figuras 5.7 e 5.8. A partir de uma análise visual, conclui-se que esses

parâmetros não conseguiram discernir adequadamente o EEG basal dos sinais patológicos e também dos artefatos.




Figura 5.7: Frequência dominante na primeira janela




Figura 5.8: Frequência dominante na segunda janela

A magnitude corresponde à quantidade de energia pode ser utilizada para fornecer indicadores do início das crises [26]. Considerando que $S(i)$ seja uma época do sinal janelado, matematicamente, a sua energia média Em é definida como sendo a média da potência de toda a janela, como representado na Equação 5.4.

$$Em = \frac{1}{N} \sum_{i=1}^N S(i)^2 \quad (5.4)$$

Onde:

N : Tamanho da janela em números de pontos (200 pontos);

i : Índice discreto no tempo;

S : Sinal janelado.

O resultado da energia está ilustrado na Figura 5.9.




Figura 5.9: Energia média

A energia não linear demonstra sensibilidade nas mudanças de amplitudes, como também nas de frequências, revelando informações sobre as alterações do conteúdo espectral do sinal. Dada uma sequência do sinal EEG $S(n)$, a sua energia não linear NE é encontrada de acordo com a Equação 5.5.

$$NE = \frac{1}{N} \sum_{i=1}^N S^2(i) - S(i-1)S(i+1) \quad (5.5)$$

A Figura 5.10 apresenta o resultado dos cálculos da energia não linear.




Figura 5.10: Energia não linear

A medida denominada comprimento da curva apresenta-se como um indicador para observar mudanças de amplitude e frequência, juntamente com a dimensionalidade do sinal [23]. O método para calcular o comprimento da curva (CDC) está representado matematicamente na Equação 5.6.

$$CDC = \sum_{i=1}^N |S(i-1) - S(i)| \quad (5.6)$$

Os resultados desses cálculos estão expressos na Figura 5.11.




Figura 5.11: Comprimento da curva

Os diferentes processos fisiológicos e patológicos são refletidos na atividade espectral em escalas com diferentes frequências presentes no sinal EEG. Embasando-se nesses processos, as bandas espectrais (delta, teta, alfa e beta) foram definidas de acordo com a análise clássica [59]. O espectro de potência relativo contido nessas bandas são definidos nas Equações 5.7, 5.8, 5.9, 5.10, 5.11, 5.12. As Figuras 5.12, 5.13, 5.14, 5.15, 5.16, 5.17, ilustram os resultados obtidos.

$$FaixaDelta = \frac{1}{P} \sum_{k=FreqInicial}^{FreqFinal} X(k) \quad (5.7)$$

- X : Espectro de potência;
- P : Quantidade de elementos;
- $FreqInicial$: Para a faixa delta vale 0,5 Hz;
- $FreqFinal$: Para a faixa delta vale 4 Hz.




Figura 5.12: Faixa de frequência Delta

$$FaixaTeta = \frac{1}{P} \sum_{k=FreqInicial}^{FreqFinal} X(k) \quad (5.8)$$

- *FreqInicial*: Para a faixa teta vale 4 Hz;
- *FreqFinal*: Para a faixa teta vale 8 Hz.




Figura 5.13: Faixa de frequência teta

$$FaixaAlfa = \frac{1}{P} \sum_{k=FreqInicial}^{FreqFinal} X(k) \quad (5.9)$$

- *FreqInicial*: Para a faixa alfa vale 8 Hz;
- *FreqFinal*: Para a faixa alfa vale 13 Hz.




Figura 5.14: Faixa de frequência alfa

$$FaixaBeta = \frac{1}{P} \sum_{k=FreqInicial}^{FreqFinal} X(k) \quad (5.10)$$

- *FreqInicial*: Para a faixa beta vale 13 Hz;
- *FreqFinal*: Para a faixa beta vale 30 Hz.




Figura 5.15: Faixa de frequência beta

$$FaixaRuido1 = \frac{1}{P} \sum_{k=FreqInicial}^{FreqFinal} X(k) \quad (5.11)$$

- *FreqInicial*: Para a faixa de ruído 1 vale 30 Hz;
- *FreqFinal*: Para a faixa de ruído 1 vale 60 Hz.




Figura 5.16: Faixa de frequência de ruído

$$FaixaRuido2 = \frac{1}{P} \sum_{k=FreqInicial}^{FreqFinal} X(k) \quad (5.12)$$

- *FreqInicial*: Para a faixa de ruído 2 vale 60 Hz;
- *FreqFinal*: Para a faixa de ruído 2 vale 100 Hz.




Figura 5.17: Faixa de frequência de ruído

5.2.2 Parâmetros relacionados à morfologia

Os parâmetros relacionados à morfologia captam as diferenciações entre as formas de onda do sinal patológico com os demais.

Geralmente, o EEG basal possui uma amplitude menor quando comparada com a amplitude de artefatos como, por exemplo, piscadas. O sinal epileptogênico também possui uma amplitude diferenciada. Na sequência, serão detalhados os parâmetros relacionados.

Aplica-se a sexta potência em um sinal de EEG para observar pequenas variações na amplitude, ressaltando um aumento nas diferenças em magnitude. Portanto, as pequenas amplitudes podem sofrer um decremento ou aumento menor que as amplitudes maiores, de acordo com a Equação 5.13.

Os resultados obtidos com esta ferramenta estão mostrados na Figura 5.18.

$$SP_D[n] = 1/N \sum_{i=1}^N S(i)^6 \quad (5.13)$$




Figura 5.18: Sexta potência

A localização dos picos de mínimo e máximo em um evento epileptogênico, represen-

tado na Figura 5.19, destaca alguns parâmetros da morfologia do sinal patológico.




Figura 5.19: Localização dos valores máximos e mínimos do sinal EEG

Os resultados obtidos com a localização das amplitudes máximas e mínimas são apresentados nas Figuras 5.20 e 5.21.




Figura 5.20: Amplitude máxima




Figura 5.21: Amplitude mínima

A partir dos pontos máximos e mínimos são extraídos outros parâmetros, tais como a duração entre estes pontos e a amplitude do evento. A Figura 5.22 representa a localização da amplitude entre os pontos de máximo e mínimo no sinal.




Figura 5.22: Localização da amplitude no evento

As resultantes das medidas de duração entre pontos e amplitude do evento estão expressas na Figura 5.23.




Figura 5.23: Amplitude entre os pontos de máximo e mínimo

o cálculo da duração do período nos eventos é importante para diferenciar os estados patológicos dos demais, visto que a duração da espícula permanece entre 20 a 70 ms e a onda aguda dura aproximadamente 70 a 200 ms. A Figura 5.24 representa a localização destas medidas no sinal.




Figura 5.24: Localização dos períodos nos pontos de máximo e mínimo

Os resultados obtidos com o cálculo dos períodos da crista positiva (A_{max}) estão representados na Figura 5.25.




Figura 5.25: Período do evento entre o pontos de máximo

Na Figura 5.26, estão representados os resultados obtidos com o cálculo dos períodos da crista negativa (Amin).




Figura 5.26: Período do evento entre o pontos de mínimo

5.2.3 Parâmetros Estatísticos

Os parâmetros estatísticos revelam informações preciosas nas análises dos sinais EEG. Para tal, as ferramentas utilizadas serão descritas na sequência, juntamente com a formulação.

A aplicação da média no sinal EEG, tem como objetivo encontrar as amplitudes médias do sinal EEG de base (normal) que devem ser menores quando comparadas com as médias do sinal patológico. A formulação matemática está descrita na Equação 5.14.

$$\bar{S} = \frac{1}{N} \sum_{i=1}^N S(i) \quad (5.14)$$

Onde:

$\bar{S}$: Média;

N : Tamanho da janela em números de pontos (200 pontos);

i : Índice discreto no tempo;

S : Sinal janelado.

Os resultados da aplicação da média nas épocas de EEG são apresentados na Figura 5.27.




Figura 5.27: Resultados da aplicação da média

A variância do sinal S é fornecida de acordo com a Equação 5.15, indicando quão longe em geral, os seus valores e encontram do valor esperado $\bar{S}$. Para o sinal EEG normal, essa variação é menor.

$$S^2 = \frac{1}{N} \sum_{i=1}^N S(i) - \bar{S} \quad (5.15)$$

Onde:

S^2 : Variância;

Os resultados da aplicação da variância nas épocas de EEG são apresentados na Figura 5.28.




Figura 5.28: Resultados da aplicação da variância

O desvio padrão é calculado de acordo com a Equação 5.17, fornecendo uma medida da dispersão do sinal EEG. Quando o trecho analisado for crise, a dispersão poder ser maior, comparando com trechos de sinais normais.

$$Dp = \sqrt{S^2} \quad (5.16)$$

Onde:

Dp : Desvio padrão ;

Os resultados da aplicação do desvio padrão nas épocas de EEG são apresentados na Figura 5.29.




Figura 5.29: Resultados da aplicação do desvio padrão

A entropia é uma medida da regularidade no sinal EEG, como mostra a Equação 5.17.

$$E = \sum_{k=1}^N S(k) \log_2 S(k) \quad (5.17)$$

Onde:

E : entropia;

Os resultados da aplicação da entropia nas épocas de EEG são apresentados na Figura 5.30.

Kurtosis é uma medida de achatamento da distribuição dos dados. Kurtosis negativo representa uma maior probabilidade de ocorrência de valores longe da média. Para medidas positivas, uma maior a probabilidade de valores próximos à média, como descrito na Equação 5.18.




Figura 5.30: Resultados da aplicação da entropia

$$k = \frac{\sum_{i=1}^N \left(\frac{S(i) - \bar{S}}{N} \right)^4}{\left[\sum_{i=1}^N \frac{(S(i) - \bar{S})^2}{N} \right]^2} - 3 \quad (5.18)$$

Os resultados da aplicação da kurtosis nas épocas de EEG são apresentados na Figura 5.31.




Figura 5.31: Resultados da aplicação da Kurtosis

Skewness é uma medida de simetria de dados da distribuição de probabilidade de uma variável. Uma curva normal apresenta skewness igual a 0. Um valor negativo indica que os dados estão deslocados para a direita (cauda negativa longa) e valores positivos indicam dados deslocados para a esquerda (cauda positiva longa). Matematicamente esta ferramenta está descrita na Equação 5.19.

$$sk = \frac{\sum_{i=1}^N \left(\frac{S(i) - \bar{S}}{N} \right)^3}{\left[\sum_{i=1}^N \frac{(S(i) - \bar{S})^2}{N} \right]^{3/2}} \quad (5.19)$$

Os resultados da aplicação do skewness nas épocas de EEG são apresentados na

Figura 5.32.




Figura 5.32: Resultados da aplicação do skeunewss

A mediana é uma outra forma de sumarizar dados em termos dos quartis ou percentis. Essas medidas são particularmente úteis para dados não simétricos. A mediana (ou percentil 50) é definida como o valor que divide os dados ordenados ao meio. Metade dos dados tem valores maiores do que a mediana. A outra metade tem valores menores do que a mediana. Os resultados da aplicação da mediana nas épocas de EEG são apresentados na Figura 5.33.




Figura 5.33: Resultados da aplicação do mediana

Adicionalmente, os quartis inferior e superior, Q1 e Q3, são definidos como os valores abaixo dos quais estão um quarto e três quartos, respectivamente, dos dados. Esses três valores são, com frequência, usados para resumir os dados juntamente com o mínimo e o máximo. Eles são obtidos ordenando os dados do menor para o maior e, então, conta-se o número apropriado de observações, ou seja, para o quartil inferior, mediana e quartil superior, respectivamente. Para um número par de observações, a mediana é a média dos valores do meio (e, analogamente para os quartis inferior e superior). A medida de dispersão denominada amplitude inter-quartis é a diferença entre o quartil superior e o inferior. Os resultados da aplicação da amplitude inter quartis nas épocas de EEG são

apresentados na Figura 5.34.




Figura 5.34: Resultados da aplicação da amplitude inter quartis

O cálculo da RMS é fornecido pela Equação 5.20, onde $\|S\|$ representa a distância euclidiana da época S .

$$RMS = \frac{\|s\|}{\sqrt{N}} \quad (5.20)$$

Os resultados da aplicação da RMS nas épocas de EEG são apresentados na Figura 5.35.




Figura 5.35: Resultados da aplicação da RMS

Os parâmetros para extração de características foram classificados em dois grupos de acordo com a capacidade de discernimento entre os dados que apresentam crises, artefatos e EEG basal. O grupo dos parâmetros essenciais é composto por aqueles que apresentaram uma distinção visual satisfatória entre os padrões analisados, são eles:

- módulo do espectro médio na primeira e segunda janela;
- energia média;
- energia não linear;

- comprimento da curva;
- faixas de frequência (delta, teta, alfa, beta, artefato1 e artefato2);
- sexta potência;
- amplitudes máxima e mínima;
- amplitude do evento (diferença entre a amplitude máxima e mínima);
- média; Variância; Entropia; Kurtosis;
- skeunewss
- mediana;
- amplitude inter-quartis;
- RMS.

No grupo dos parâmetros para extração de características considerados redundantes, ou apresentaram uma baixa distinção visual entre os padrões analisados, são:

- frequência predominante na primeira e segunda janela;
- período do evento entre os pontos de máximo e mínimo.

Portanto para os sinais EEG analisados existem 2 parâmetros de extração de características que são considerados redundantes e outros 21 parâmetros ditos essenciais. Devido a pesquisa realizada no Capítulo 4 o número de parâmetros redundantes encontrados foi bem reduzido.

5.3 Sistemas reconhecedores desenvolvidos

A tese desenvolvida nesta pesquisa consiste em detectar padrões epileptiformes (crise de ausência e generalizada) em sinais de EEG. Para tal finalidade, foram desenvolvidas quatro propostas.

Antes de iniciar a explanação dessas propostas, é importante ressaltar o tratamento das bordas nas épocas janeladas. Esse problema refere-se aos pontos no início ou no final da época com amplitudes muito elevadas, quando comparados com o restante do sinal.

Caso esse problema não seja solucionado, pode acarretar medidas errôneas para os parâmetros extraídos com a FFT (Transformada Rápida de Fourier), medidas estatísticas e morfologia do sinal. O problema de suavização de bordas está mostrado na Figura 5.36.




Figura 5.36: Problema de bordas

Para resolver essa situação, é proposto um algoritmo para suavização de bordas, verificando-se uma faixa de 20 ms no início e no final da época. Caso os valores dos pontos sejam maiores que a média deve ser aplicado o algoritmo apresentado na sequência. A correção com o algoritmo de suavização esta mostrada na Figura 5.37.




Figura 5.37: Correção com o algoritmo de suavização

O algoritmo de suavização é detalhado na sequência:

S = época janelada em 200 pts;

$NumMaxPtsPos$ = quantidade de pontos positivos na época S ;

$NumMaxPtsNeg$ = quantidade de pontos negativos na época S ;

$MediaPositiva = (sum(S(find(S > 0)))) / NumMaxPts$;

$MediaNegativa = (sum(S(find(S < 0)))) / NumMaxPts$;

for $i=1:4$

if ($S(i) < 0$) & ($S(i) < MediaNegativa$)

$S(i) = (MediaNegativa + S(i)) / 2$;

end

```

    if (S(NumMaxPts+1-i) < 0) & (S(NumMaxPts+1-i) < MediaNegativa)
        S(NumMaxPts+1-i)=(MediaNegativa+S(NumMaxPts+1-i))/2;
    end
end
for i=1:4
    if (S(i) > 0) & (S(i) > MediaPositiva)
        S(i)=(S(i)-MediaPositiva)/2;
    end
    if (S(NumMaxPts+1-i) > 0) & (S(NumMaxPts+1-i) > MediaPositiva)
        S(NumMaxPts+1-i)=(S(NumMaxPts+1-i)-MediaPositiva)/2;
    end
end
end

```

A função “sum” é utilizada para somar os dados de um vetor. A “find” procura em um vetor determinado padrão. Ambas são funções do software Matlab.

Nas próximas seções, serão detalhadas a metodologia de cada proposta.

5.3.1 Arquitetura com análise multi-resolução

Na metodologia denominada arquitetura com análise multi-resolução [71], [15], utiliza-se como ferramenta para extrair as características a transformada wavelet (WT). A metodologia dessa proposta é apresentada na Figura 5.38.

A análise muti-resolução faz uso da WT para extrair características no domínio tempo-frequência [85]. Diante da vasta quantidade de famílias WT, foram utilizadas as duas famílias mais populares, além de apresentar bons resultados em aplicações voltadas para extração de características no domínio tempo-frequência para sinais EEG: WT Coiflet e Daubechies. O sistema detector foi testado com três variações do algoritmo “backpropagation”.

Esse sistema é composto por quatro etapas: formação da base de dados, janelamento e extração de características, detecção dos eventos epiléticos, e tomada de decisão. A metodologia proposta classifica os eventos em crise, não crise ou indefinido. A formação da base de dados obedece a descrição realizada na seção 5.1. As outras etapas são descritas nas próximas seções.




Figura 5.38: Metodologia proposta: análise multi-resolução

Extração de características

Para se extrair as características de forma significativa, utilizou-se as WT mãe Coiflet(Coif-1) e a Daubechies(Daub-4), como mostradas na Figura 5.39.




Figura 5.39: Wavelet mãe: Coiflets(Coif-1) e Daubechies(Daub-4)

A utilização dessas ferramentas objetiva ressaltar as alterações do sinal, fornecendo informações tanto no domínio da frequência, quanto no tempo, resultando na detecção de transição entre os períodos: preictal, ictal e posictal. A WT decompõe o sinal S , em N níveis, como mostra a Figura 5.40.

Nessa metodologia o sinal foi decomposto em 3 níveis, observando-se as bandas patológicas definidas no EEG. A Figura 5.41 mostra dois sinais EEG patológicos.

Diante desse contexto, são utilizados os níveis de detalhe 1 (cD1) e detalhe 3 (cD3), tanto para a Coiflet, quanto para a Daubechies.

O cD3 foi utilizado para treinar a rede neural que será especialista em reconhecimento de eventos epileptiformes, contendo crise de ausência (aproximadamente 4 Hz) e tônico clônico (20-40 Hz) [107], [56], [28]. O cD1 foi utilizado para treinar a rede neural responsável em detectar os ruídos (artefatos de 60 Hz, EMG (50-150 Hz), etc).




Figura 5.40: Decomposição do sinal em três níveis com WT




Figura 5.41: Sinais patológicos

Os resultados da aplicação da WT em épocas contendo crise de ausência são apresentados nas Figuras 5.42 e 5.43.




Figura 5.42: Decomposição do sinal com WT Coif-1 em três níveis




Figura 5.43: Decomposição do sinal com WT Daub-4 em três níveis

Normalização das características extraídas

A extração de características com a WT gera vetores com 200 elementos. Para cada época utilizada no treinamento, é gerado um vetor de característica. Como a base de dados é composta de 566 épocas para o treinamento, logo a dimensão da matriz de características é 566, como representado na Figura 5.44.




Figura 5.44: Geração da matriz de treinamento

Após gerar a matriz de dados para o treinamento em cada nível (D1 e D3), o algoritmo de normalização deve ser aplicado. Este algoritmo está detalhado na sequência.

```

[MaxLinha MaxColuna] = size(MatrizTreinamento);
ValorMaximo=max(MatrizTreinamento);
ValorMinimo=min(MatrizTreinamento);
for C=1: MaxColuna
    for L=1: MaxLinha
        if MatrizTreinamento(L,C) > 0
            MatrizTreinamento(L,C) = MatrizTreinamento(L,C)/ValorMaximo;
        else
            MatrizTreinamento(L,C) = MatrizTreinamento(L,C)/ValorMinimo;
        end
    end
end
end

```

Os valores denominados *ValorMaximo* e *ValorMinimo*, são armazenadas para normalizar os vetores que são utilizados para testar a metodologia.

Detecção dos eventos epileptiformes

Vários pesquisadores estão utilizando redes neurais para solucionar problemas relacionados à medicina [18], [46], [8]. Nesta extensa faixa de aplicações, a epilepsia também pode ser detectada empregando-se estas ferramentas. A ferramenta que melhor se adequou ao EEG, visando à detecção de crises, foi o “backpropagation” [1].

O termo “backpropagation” refere-se à maneira como o gradiente é calculado para redes com várias camadas não-lineares. Existe um grande número de variações desse algoritmo. Neste trabalho foi utilizado a “toolbox” de redes neurais do MatLab 7.0.

Foram realizados testes com essa arquitetura, empregando-se algumas variações da função treinamento. São elas:

- gradiente descendente com momento e aprendizado adaptativo;;
- backpropagation resiliente;
- gradiente descendente em lote;

As funções de performance utilizadas neste proposta são:

- função de performance com erro médio quadrático;

- função de performance com erro médio quadrático e regularização;

Entre as funções de treinamento e performance, foram realizados testes objetivando encontrar as que oferecem o melhor desempenho.

Para todos os testes realizados, o treinamento das redes obedecem os seguintes critérios:

- três camadas;
- quantidade de neurônios na camada de entrada é igual ao tamanho do vetor características. Neste caso, vale 200;
- quantidade de neurônios na camada intermediária vale 70% dos neurônios de entrada;
- quantidade de neurônios de saída vale um;
- número máximo de ciclos para o treinamento igual a 60000.

Na arquitetura da rede, a função de transferência adotada para a saída é uma tangente sigmóide hiperbólica. Esta função foi escolhida devido a grande não linearidade apresentada. Possuindo limites de variação entre 0 e 1 como mostra a Figura 5.45.




Figura 5.45: Função de transferência na saída

De acordo com a Figura 5.38, as saídas das duas redes neurais estão conectadas às entradas do sistema especialista.

O sistema especialista é composto por uma base de regras heurísticas que analisa simultaneamente as saídas das duas redes neurais. A RNA1 é destinada a reconhecimento de eventos classificados como sendo crise e EEG basal. Já a RNA2 é destinada aos artefatos e EEG basal.

Define-se como detecção positiva do evento a saída da rede neural que apresentar um resultado superior a 0,7. A detecção é considerada negativa quando o valor presente na

saída da rede neural for menor que 0,3. Já a detecção é indefinida quando a saída da rede estiver entre 0,3 a 0,7. Esses valores foram obtidos de forma empírica, através de exaustivos testes realizados.

Levando-se em consideração esses parâmetros, a base de regras desempenha uma tomada de decisão. As regras propostas estão descritas abaixo:

```

if( $RNA1 \leq 0,3$ ) & ( $RNA2 \leq 0,3$ )
    Há crise;
elseif ( $0,3 > RNA1 < 0,7$ ) & ( $RNA2 \leq 0,3$ )
    Não há crise;
elseif ( $RNA1 \leq 0,3$ ) & ( $RNA2 > 0,7$ )
    Não há crise;
elseif ( $RNA1 > 0,7$ ) & ( $RNA2 \leq 0,3$ )
    Há crise;
elseif ( $0,3 < RNA1 < 0,7$ ) & ( $0,3 < RNA2 < 0,7$ )
    Indefinido;
elseif ( $RNA1 > 0,7$ ) & ( $RNA2 > 0,7$ )
    if  $RNA1 > RNA2$ 
        Há crise;
    else
        Não há crise;
end
elseif ( $RNA1 > 0,7$ ) & ( $0,3 < RNA2 < 0,7$ )
    Há crise;
elseif ( $RNA1 \leq 0,3$ ) & ( $0,3 < RNA2 < 0,7$ )
    Não há crise;
elseif ( $0,3 < RNA1 < 0,7$ ) & ( $RNA2 > 0,7$ )
    Não há crise;
End

```

Todas as épocas que constituem a base de dados para testes são submetidas à base de regras e classificadas como sendo um dos três eventos: crise, não crise e indefinido.

5.3.2 Arquitetura com ferramentas estatísticas

Na metodologia com ferramentas estatísticas [70], a detecção automática dos eventos epiléticos é realizada extraindo-se todas as características diretamente da época em questão. Para se extrair as características, foram utilizadas ferramentas estatísticas e a teoria da informação.

A arquitetura do projeto consiste nas seguintes etapas: base de dados, extração de características do sinal, detecção das épocas com redes neurais (crise, artefatos e indefinido) e sistema especialista. A arquitetura dessa metodologia está representada na Figura 5.46. Essas etapas serão detalhadas na sequência, com exceção da formação da base de dados que segue a descrição realizada na seção 5.1.




Figura 5.46: Metodologia proposta: ferramentas estatísticas

Extração de características

Os sinais de EEG captados no escalpo são altamente ruidosos, apresentando artefatos de movimento, eletromiografia, eletrooculografia, 60 Hz e outros. O conjunto de ferramentas utilizadas para extração de características é fundamental para a obtenção de resultados relevantes do sistema detector como um todo. Com esse objetivo, foi utilizado um conjunto com 11 ferramentas. São elas:

- Média;
- Variância;

- Desvio padrão;
- Skewness;
- Energia não linear;
- Kurtosis;
- Comprimento da curva;
- Entropia;
- Amplitude máxima;
- Amplitude mínima; e
- Quarta potência.

Todas essas ferramentas foram detalhadas anteriormente na seção 5.2. Na sequência, serão apresentados os resultados dessas ferramentas no sinal EEG.

As Figuras 5.47, 5.48, 5.49, 5.50, 5.51, 5.52, 5.53, 5.54, 5.55, 5.56, 5.57, apresentam os resultados da aplicação de cada uma dessas ferramentas sobre o sinal EEG.




Figura 5.47: Resultados obtidos com a média

Normalização das características

A extração de características com as ferramentas estatísticas gera vetores com 11 elementos, ou seja, o número de ferramentas utilizadas. Para cada época utilizada no




Figura 5.48: Resultados obtidos com a variância




Figura 5.49: Resultados obtidos com o desvio padrão




Figura 5.50: Resultados obtidos com o Skewness




Figura 5.51: Resultados obtidos com a energia não linear




Figura 5.52: Resultados obtidos com a Kurtosis




Figura 5.53: Resultados obtidos com o comprimento da curva




Figura 5.54: Resultados obtidos com a entropia




Figura 5.55: Resultados obtidos com a amplitude máxima




Figura 5.56: Resultados obtidos com a amplitude mínima




Figura 5.57: Resultados obtidos com a quarta potência

treinamento, é gerado um vetor de característica. Como a base de dados é composta de 566 épocas para o treinamento, a dimensão da matriz de características é 11x566, como representado na Figura 5.58.




Figura 5.58: Geração da matriz de treinamento

Após gerar a matriz de dados para o treinamento, em que as linhas representam as ferramentas de extração e as colunas a quantidade de épocas utilizadas para o treinamento, deve-se aplicar o algoritmo de normalização. A normalização é feita levando-se em consideração o resultado de cada ferramenta separadamente (linha da matriz). O algoritmo proposto será detalhado na sequência.

```
[TotalFerramentasUtilizadas TotalEpocasTreinamento]=size(MatrizEntrada);
```

```
for L=1: TotalFerramentasUtilizadas
```

```

VetorMaximo(L)=max(max((MatrizEntrada(L,:)));
VetorMinimo(L)=min(min((MatrizEntrada(L,:)));
for C=1:TotalEpocasTreinamento
    if MatrizEntrada(L,C) > 0
        MatrizNormalizada(L,C)=MatrizEntrada(L,C)/VetorMaximo(L);
    else
        MatrizNormalizada(L,C)=MatrizEntrada(L,C)/abs(VetorMinimo(L));
    end
end
end
end

```

Para se normalizar os vetores da etapa de teste, são utilizados os valores contidos nos vetores denominados *VetorMaximo* e *VetorMinimo*.

Detecção dos eventos epileptiformes

O sistema é composto por duas redes neurais, cada uma delas obedece a arquitetura apresentada na Figura ??, uma especializada em reconhecer crises epiléticas (Crises generalizadas e ausência) e a outra especializada em reconhecer ruídos (artefatos de movimentos, EMG, ruído de 60 Hz, etc.). O processo de aprendizado das redes neurais é composto por duas etapas: treinamento e teste. Na etapa de treinamento, utilizou-se o primeiro conjunto contendo EEG com crises e sinal de base. Todos os segmentos de sinais contidos no conjunto em análise devem passar pelos métodos de extração de características. A rede é treinada com 11 entradas e uma única saída. Se o segmento analisado for de EEG patológico, a rede responsável por detectar crise (RNA1) recebe o alvo 1 e a outra rede (RNA2), alvo 0.

Quando inserido um segmento contendo EEG com artefatos (EMG, 60Hz e movimento), a rede responsável em detectar crises recebe o alvo 0 e outra rede alvo 1. Assim, cada segmento do sinal EEG, independente de ser composto de crise, EEG de base ou ruído, deve ser avaliado nas duas redes neurais. Na etapa de teste cada saída da rede é normalizada de acordo com o algoritmo seguinte:

```

if SaidaRedeNeural >= 0.7
    SaidaRN=1;
elseif SaidaRedeNeural <= 0.3

```

SaidaRN=0;

else

SaidaRN=2;

End

Caso a saída da rede for taxada como sendo 1 ($SaidaRN = 1$), significa que a rede em questão (RN1-Crise e RN2-Artefato) conseguiu identificar a época para qual foi treinada. Quando a saída for 0, as redes conseguiram detectar a época analisada como EEG de base, ou seja, sinal normal. E quando a saída for 2, a rede não conseguiu identificar a época.

O sistema especialista é composto por regras heurísticas capazes de avaliar os resultados oferecidos pelas duas redes neurais, classificando cada época do sinal em três possíveis respostas: o sinal retrata uma crise, não crise (sinal de base) ou indefinido. O algoritmo é mostrado na seqüência.

if (RN1==0) & (RN2==0)

Saida=0;

elseif (RN1==2) & (RN2==0)

Saida=0;

elseif (RN1==0) & (RN2==1)

Saida=0;

elseif (RN1==1) & (RN2==0)

Saida=1;

elseif (RN1==2) & (RN2==2)

Saida=2;

elseif (RN1==1) & (RN2==1)

if SaidaRN1 > SaidaRN2

Saida=1;

else

Saida=0;

end

elseif (RN1==1) & (RN2==2)

Saida=1;

elseif (RN1==0) & RN2==2)

```

    Saida=0;
elseif (RN1==2) & RN2==1)
    Saida=0;
end

```

Para interpretar a saída do sistema especialista, é realizada a seguinte análise:

- saída igual a 1, o sinal de EEG possui crise;
- saída igual a 0, o sinal de EEG não possui crise;
- saída igual a 2, o sinal está indefinido, ou seja, o sistema não conseguiu identificá-lo.

Os resultados dessa proposta serão apresentados e discutidos no Capítulo 6.

5.3.3 Arquitetura com análise multi-resolução e modelos auto-regressivos

O sinal de EEG possui uma ampla faixa de frequências. Entretanto, quando se trata de padrões patológicos (epilepsia), essa faixa se reduz a 0,5-30 Hz [81]. Mas há de se considerar, que a captação do sinal armazena também alguns ruídos, como artefatos de 60 Hz, movimentos, piscadas, entre outros. Esses artefatos apresentam-se em uma faixa de frequência elevada, quando comparados com o sinal epileptogênico. De acordo com essas informações, foi observada a necessidade de se aplicar a análise multi-resolução, embasando-se na transformada “wavelet”, com a finalidade de separar a parte patológica do ruído. Na sequência, a saída da WT é inserida diretamente no modelo auto-regressivo (AR). Sendo o AR um dos modelos paramétricos mais frequentemente utilizados, seu sucesso está relacionado ao fato de que a estimação dos seus parâmetros pode ser facilmente calculados resolvendo equações lineares. A sua saída fornece os coeficientes do sinal modelado. Vale enfatizar que a dimensionalidade do vetor de características, tanto das patologias quanto dos ruídos, é um aspecto bastante relevante. Admitindo-se que a minimização deste vetor é desejável, são utilizados para tal finalidade os modelos auto-regressivo. Face à situação apresentada, a metodologia deste trabalho está ilustrada na Figura 5.59.

A Figura 5.60 fornece as minúcias da decomposição do sinal EEG por meio da análise multi-resolução. Esta metodologia é utilizada na Figura 5.59. Observando-se a Figura




Figura 5.59: Análise multi-resolução e modelos auto-regressivos

5.60, nota-se que após a captação dos sinais EEG no escalpo, eles são janelados (Hamming) em épocas de 1 s (200 pontos). A WT decompõe o sinal, em cinco níveis (D1, D2 $\dots$ D5). As resultantes que foram utilizadas são: D2 e D4, inseridas diretamente nas entradas do modelo auto-regressivo (AR), que reduz a dimensionalidade dos vetores oriundos da WT.




Figura 5.60: Aplicação Daub4 com 5 escalas

Entretanto, o D2 foi utilizado para extrair características relacionadas aos ruídos. Pois a maioria dos artefatos presentes no sinal estão nessa banda de frequência, tal como os artefatos EMG, são caracterizados por uma faixa aproximada de 50-150 Hz [88]. Prosseguindo na análise, como observado na Figura 5.61, o D5 é composto por frequências que estão entre 3 e 6 Hz. Sendo assim, é ideal para extração de características relacionadas à identificação de crises. Já o sistema de reconhecimento e detecção está embasado na rede neural, possuindo como saídas valores entre +1 e -1. O sistema especialista tem como finalidade analisar a saída das duas redes neurais, fornecendo um resultado de acordo com as regras heurísticas implementadas. Nas próximas seções, será detalhada as etapas do diagrama da metodologia do sistema.

Modelo AR

Dentre os métodos lineares, há aqueles para análise no domínio da frequência, do tempo e de tempo-frequência. No domínio do tempo, há os métodos paramétricos, como o modelo auto-regressivo (AR), que modela o sinal EEG por meio de um somatório de expressões matemáticas com coeficientes a serem aproximados [29], [68]. Na análise com o modelo AR, uma época do sinal EEG é considerada como um processo estacionário. Com base nesta informação, pode-se aplicar o modelo AR, que representa a série EEG, ilustrado na Equação 5.21.

$$x(n) = a_1x(n-1) + a_2x(n-2) + \dots + a_vx(n-v) + r(n) \quad (5.21)$$

Onde:

- $x(n)$: sinal EEG;
- a_k : coeficiente do modelo;
- v : ordem do modelo;
- $r(n)$: ruído branco com variância igual a σ^2 .

A Equação 5.21 representa as diferenças finitas do modelo AR. Portanto, faz-se necessário comentar algumas características: o valor atual do sinal depende da combinação linear (soma dos valores dos produtos pelos respectivos coeficientes), do valor do próprio

sinal em instantes passados e do valor atual do sinal ruído branco de entrada. A modelagem consiste em obter um conjunto de coeficientes tal que a diferença (erro) entre o sinal gerado pelo modelo e o sinal real seja mínima. Os coeficientes podem ser estimados de diversas maneiras, sendo o mais usual a resolução de uma equação matricial (inversão) formulada em torno da matriz de correlação ou de covariância, para minimizar o erro quadrático. Uma vez estimados os coeficientes, calcula-se a função de densidade espectral de potência (PSD) do processo AR, sendo uma característica fundamental para análise do sinal. A modelagem matemática da PSD para o processo AR está ilustrada na Equação 5.22:

$$P_{AR}(f) = \frac{\sigma^2}{\left[1 + \sum_{k=1}^v a_k e^{-j2\pi f k}\right]} \quad (5.22)$$

Onde:

- σ^2 : Variância do ruído branco;
- v : Número de parâmetros a_k .

Com o objetivo de obter estabilidade e alta performance, alguns fatores devem ser levados em consideração [46], [90], [46], tais como:

- Escolha da ordem do modelo AR;
- Máxima quantidade de dados na janela (época);
- Grau de estacionariedade do sinal a ser modelado.

Existem vários métodos para estimar esses parâmetros. Para esta proposta, são utilizados os seguintes modelos: “Yule-Walker” e “Burg”. O método “Yule-Walker”, também chamado método de autocorrelação, aplica o janelamento no sinal de entrada, minimizando o erro de predição no sentido “forward”. Já o método “Burg” não aplica o janelamento do sinal, mas minimiza (“least squares”) os erros de predição no sentido “forward” e “backward”.

De acordo com as explicações anteriores, foi afirmado que o nível D2 deve ser utilizado para verificar ruídos e o D5 para detectar crises de ausência. Essas certezas foram confirmadas analisando a teoria sobre WT [83] e observando a resposta em cada nível (D1 e D5). A Figura 5.61 mostra a aplicação da PSD diretamente no sinal EEG, verificando

toda a banda de frequência presente nele, iniciando em aproximadamente 0,5 Hz até 65 Hz.




Figura 5.61: Banda espectral do sinal patológico

Já a Figura 5.62 ilustra o resultado da PSD após a aplicação da WT Daubechies (Daub4) no sinal, utilizando o nível de detalhe 2 (D2). É importante ressaltar que nesta escala, a faixa de frequência varia entre 25 a 50Hz de acordo com a Figura 5.60. Sendo assim, a resposta do AR espectral torna-se ideal para captar artefatos (musculares, piscadas, movimentos, etc.).




Figura 5.62: Banda espectral da escala D2

A Figura 5.63 ilustra o resultado da PSD utilizando a escala 5 (D5). Fazendo uso da Figura 5.60. É possível concluir que a faixa de frequência esperada para esta escala varia entre 3 e 6 Hz. Tendo em vista que as crises de ausência possuem banda espectral entre 0,6 e 5 Hz, a resposta da PSD nessa escala permite a detecção e identificação desta patologia.




Figura 5.63: Banda espectral da escala D5

Classificador

Para classificar as características extraídas da DWT-AR, são utilizadas redes neurais com algoritmo de treinamento “backpropagation”, e o sistema especialista, interpretando as saídas das duas redes.

O sistema proposto é composto de duas redes: RNA1, destinada a reconhecer sinais epileptogênicos e RNA2, para reconhecer ruídos. Os parâmetros fixados para testar e treinar o sistema são:

- Arquitetura da rede: “backpropagation feed-forward”;
- Algoritmo de treinamento: gradiente descendente com momento e aprendizado adaptativo;
- Função de performance: erro médio quadrático;
- Função transferência camada entrada: tangente hiperbólica;
- Função transferência camada saída: tangente hiperbólica;
- Ciclos de treinamento: 60.000.

É importante salientar que a função de transferência em ambas as camadas é a tangente hiperbólica. Assim, a saída da rede pertence a um intervalo entre -1 e 1. Nesse contexto, com o intuito de interpretar os valores da saída da rede e objetivando reconhecer e identificar os sinais da entrada do sistema, houve a necessidade de se definir a certeza da saída de cada rede, como ilustrado na Figura 5.64. Caso a saída seja $> +0,7$ ou $< -0,7$,

a saída da rede não é contestada. Se a saída estiver entre $+0,7$ e $-0,7$, indica uma saída duvidosa.




Figura 5.64: Arquitetura das redes neurais utilizadas

Para a RNA1, a saída é analisada da seguinte maneira:

- se a saída x estiver entre $+0,7 \leq x \leq +1$, então representa um evento epileptogênico;
- se a saída x estiver entre $-0,7 \leq x \leq -1$, então representa um evento normal (EEG de base);
- se a saída x estiver entre $+0,7 < x < -0,7$, então representa um evento indefinido.

Seguindo esta tendência, para a RNA2, têm-se as seguintes análises:

- se a saída x estiver entre $+0,7 \leq x \leq +1$, então representa um artefato;
- se a saída x estiver entre $-0,7 \leq x \leq -1$, então representa um evento normal (EEG de base);
- se a saída x estiver entre $+0,7 < x < -0,7$, então representa um evento indefinido.

Realizada a classificação inicial do sinal, descrita anteriormente, na sequência é aplicado o sistema especialista. O sistema especialista leva em consideração o conhecimento dos profissionais da área (EEGers), traduzindo esta idéia para a análise das saídas das redes. Cada rede é treinada para uma especialidade. A RNA1 é treinada para reconhecer sinais de crise e a RNA2 para reconhecer sinais de artefatos. As regras heurísticas utilizadas traduzem o grau de certeza de cada rede neural. Vale ressaltar então que caso a RNA1 aponte uma época como crise, não há dúvida de que ela será classificada como

tal. Diante desse raciocínio, a RNA2 aponta as épocas que são artefatos. O algoritmo utilizado para o sistema especialista está apresentado abaixo.

```

If RNA1 == EEG De Base & RNA2 == EEG De Base
    Saida = EEG De Base
Elseif RNA1 == Indefinido & RNA2 == EEG De Base
    Saida = EEG De Base
Elseif RNA1 == EEG De Base & RNA2 == Artefato
    Saida = EEG De Base
Elseif RNA1 == Epileptogênico & RNA2 == EEG De Base
    Saida = Epileptogênico
Elseif RNA1 == Indefinido & RNA2 == Indefinido
    Saida = Indefinido
Elseif RNA1 == Epileptogênico & RNA2 == Artefato
    Saida = Epileptogênico
Elseif RNA1 == Epileptogênico & RNA2 == Indefinido
    Saida = Epileptogênico
Elseif RNA1 == EEG De Base & RNA2 == Indefinido
    Saida = EEG De Base
Elseif RNA1 == Indefinido & RNA2 == Artefato
    Saida = Artefato
end

```

Os resultados obtidos com essa proposta serão apresentados no Capítulo 6.

5.3.4 Arquitetura híbrida

A construção da arquitetura híbrida, almeja otimizar os resultados em sistemas de detecção automática de eventos epiléticos com sinais EEG, captados no escalpo. Para realizar a extração de características, utilizam-se as ferramentas de análise da multi-resolução, de morfologia do sinal, relacionadas à frequência, não paramétricas, de teoria da informação e estatísticas. A metodologia dessa proposta é composta de algumas etapas, estando representadas na Figura 5.65.

Na sequência, serão detalhadas as partes que compõem a metodologia: extração de características diretamente do sinal (morfologia do sinal), análise da multi-resolução do




Figura 5.65: Metodologia híbrida

signal, extração de características por meio dos níveis de recomposição “wavelet”, formação do vetor de características, redes neurais e sistema especialista.

Características extraídas diretamente do sinal

A grande dificuldade em diferenciar um sinal patológico dos demais sinais encontrados no EEG está na semelhança da morfologia entre eles. A morfologia de uma espícula pode se assemelhar a de ruídos. As ferramentas utilizadas para extrair características buscam diferenciar o sinal patológico dos demais (EEG basal, artefatos, etc.). As características extraídas diretamente do sinal são divididas em frequência e morfologia.

A extração de características no domínio da frequência está relacionada diretamente com a aplicação da FFT (transformada rápida de Fourier). A maioria dos trabalhos [72] que utilizam essa ferramenta, geralmente não fazem distinção entre bandas de frequência. O espectro médio de potência é calculado de acordo com a Equação 5.2.

Levando em consideração que o sinal EEG foi adquirido a 200 Hz, logo a sua frequência de Nyquist será 100 Hz. Portanto, para as análises no domínio da frequência, é considerado que o sinal de EEG possui uma banda entre 0-100 Hz. Inicialmente, aplica-se a FFT sobre

as épocas de 1 s (200 pontos), obtendo o seu espectro de potência, representado na Figura 5.66.




Figura 5.66: Espectro de potência. (a) Sinal com crise epiléptica, (b) EEG basal e (c) artefato de EMG

É importante observar a banda espectral em cada um dos sinais EEG. No sinal EEG (a) mostra-se um sinal de crise, com banda espectral aproximada de 4 Hz. Já o sinal EEG (b) apresenta o EEG basal, com banda espectral de potência em aproximadamente 2 Hz. E por último, o sinal EEG (c) apresenta uma banda espectral diversificada, sendo claramente observado o artefato de EMG, ressaltado na faixa entre 56 - 67 Hz.

De acordo com essas análises, fica evidenciado que o EEG registra várias frequências, sendo as mais comuns beta, alfa, teta e delta. Sendo assim, observou-se a necessidade de empregar ferramentas compatíveis com as bandas espectrais clássicas, que foram delimitadas pelos EEGers. Diante desse fato, foi proposto o cálculo do espectro de potência nessas bandas clássicas. O início dessa análise está representado na Figura 5.67.




Figura 5.67: Divisão das bandas espectrais: (1) Delta, (2) Teta, (3) Alfa, (4) Beta, (5) e (6) Artefatos

Os cálculos das bandas espectrais, são realizados de acordo com as Equações 5.7, 5.8, 5.9, 5.10, 5.11, 5.12, apresentadas anteriormente, foi desenvolvido o seguinte algoritmo:

$N = \text{Tamanho da Janela}(200);$

$\text{ValorInicialFaixaDelta} = 0,5;$

```

ValorFinalFaixaDelta= 4;
Contador = SomaFaixa = 0;
Espectro = FFT(Sinal Janelado);
For i=ValorInicialFaixaDelta:ValorFinalFaixaDelta
    SomaFaixa = SomaFaixa + Espectro( i );
    Contador=Contador + 1;
End
FaixaDelta = SomaFaixa/Contador;

```

O algoritmo é aplicável nas outras bandas. Basta substituir o *ValorInicialFaixaDelta* e *ValorFinalFaixaDelta* para a banda que está sendo analisada.

Sendo assim, foram calculados seis parâmetros relacionados às bandas espectrais de frequência.

Por outro lado, o estudo da morfologia do sinal busca extrair as formas que acentuam os aspectos que possam ressaltar os padrões desejados em um determinado evento. Para essa finalidade, são levados em consideração amplitudes, o pico máximo e mínimo, etc.

A extração de parâmetros embasados na morfologia dos sinais EEG vem sendo utilizada há muito tempo para obter uma forma de classificar os eventos presentes no sinal. Alguns desses trabalhos [102] foram pesquisados para direcionar este estudo.

Inicialmente, o estudo é realizado verificando-se a amplitude, a qual é importante para realizar uma distinção dos padrões epiléticos do EEG basal. A Figura 5.68 apresenta dois sinais patológicos. Vale ressaltar a alteração da amplitude presente.




Figura 5.68: Sinal patológico

Na Figura 5.69, é demonstrado o resultado obtido com a análise das amplitudes no sinal EEG.

A partir dos valores de máximo e mínimo são calculados outros parâmetros, tais como a amplitude máxima do sinal, que está representa na Figura 5.19.

Além da amplitude, outro parâmetro relevante é a duração do evento. Uma espícula




Figura 5.69: Resultados obtidos com valores de máximo e mínimo

possui um período de 20 - 70 ms, a onda aguda entre 70 a 200 ms. Em contra partida, a duração da maioria dos ruídos é bem maior. Para quantificar esta característica, são propostos os parâmetros período de pico positivo e período de pico negativo, representados na Figura 5.70.




Figura 5.70: Localização dos períodos para os valores máximo e mínimo

O algoritmo desenvolvido para calcular esses dois parâmetros será descrito na sequência. Existem duas referências a serem levadas em consideração: a crista positiva e negativa.

Tomando a crista positiva como referência (período Amax, na Figura 5.70)

S = época analisada;

ta = localização do ponto de máximo dentro da época;

$DistanciaPCZD$ = Distância entre ta até o primeiro cruzamento do sinal com o eixo zero a esquerda;

$DistanciaPCZC1$ = Distância entre ta até o primeiro cruzamento do sinal com o eixo zero a direita;

DistanciaPCZC2=Distância entre t_a +DistanciaPCZC1 até o primeiro cruzamento do sinal com o eixo zero a direita;

DistanciaPCZD=PrimeiroCruzamentoZeroDecrescente(t_a, S);

if DistanciaPCZD > 0

Tpa= t_a -DistanciaPCZD;

InicioPrimeiroSemiCiclo=Tpa;

DistanciaPCZC1=PrimeiroCruzamentoZeroCrescente(t_a, S);

FimPrimeiroSemiCiclo= t_a +DistanciaPCZC1;

InicioSegundoSemiCiclo=FimPrimeiroSemiCiclo;

DistanciaPCZC2=PrimeiroCruzamentoZeroCrescente(t_a +DistanciaPCZC1, S);

FimSegundoSemiCiclo=InicioSegundoSemiCiclo+DistanciaPCZC2;

if ($DistanciaPCZC2 \simeq 0$) & ($DistanciaPCZC1 \simeq 0$)

Tpb= t_a +DistanciaPCZC1+DistanciaPCZC2;

else

if DistanciaPCZC1 > 0

Tpb= t_a +DistanciaPCZC1;

DistanciaPCZD1=PrimeiroCruzamentoZeroDecrescente(t_a, S);

DistanciaPCZD2=PrimeiroCruzamentoZeroDecrescente(t_a - DistanciaPCZD1, S);

Tpa= t_a -DistanciaPCZD1-DistanciaPCZD2;

InicioPrimeiroSemiCiclo=Tpa;

FimPrimeiroSemiCiclo= t_a +DistanciaPCZC1;

InicioSegundoSemiCiclo=FimPrimeiroSemiCiclo;

FimSegundoSemiCiclo=Tpb;

else

Tpb= t_a -DistanciaPCZD;

DistanciaPCZD1=PrimeiroCruzamentoZeroDecrescente(Tpb, S);

DistanciaPCZD2=PrimeiroCruzamentoZeroDecrescente(Tpb - DistanciaPCZD1, S);

Tpa= Tpb -DistanciaPCZD1-DistanciaPCZD2;

InicioPrimeiroSemiCiclo=Tpa;

FimPrimeiroSemiCiclo= t_a +DistanciaPCZC1;

InicioSegundoSemiCiclo=FimPrimeiroSemiCiclo;

FimSegundoSemiCiclo=Tpb;

```

end
end
Periodo=Tpb-Tpa;
else
    DistanciaPCZC=PrimeiroCruzamentoZeroCrescente(ta,S);
    Tpa=ta+DistanciaPCZC;
    DistanciaPCZC1=PrimeiroCruzamentoZeroCrescente(Tpa,S);
    DistanciaPCZC2=PrimeiroCruzamentoZeroCrescente(Tpa+DistanciaPCZC1,S);
    Tpb=Tpa+DistanciaPCZC1+DistanciaPCZC2;
    InicioPrimeiroSemiCiclo=Tpa;
    FimPrimeiroSemiCiclo=ta+DistanciaPCZC1;
    InicioSegundoSemiCiclo=FimPrimeiroSemiCiclo;
    FimSegundoSemiCiclo=Tpb;
end
Periodo=Tpb-Tpa;

```

É observado que os artefatos provenientes de piscadas ou movimentos não apresentam constância em suas amplitudes. Porém, quando o sinal EEG apresenta múltiplas espículas (crise) existe essa constância. O EEG basal embora apresente uma certa constância, a sua amplitude é muito baixa quando comparada à crise ou ao artefato. A Figura 5.71 mostra alguns sinais de EEG. As marcações nas épocas (artefato, EEG basal e crise) demonstram os pontos de máximo e mínimo.




Figura 5.71: Sinais: artefato, EEG basal e crise

Para extrair as características citadas acima, são propostos quatro métodos que ressaltam as diferenças entre esses padrões:

1. Amplitude relativa à esquerda do ponto de máximo;

2. Amplitude relativa à direita do ponto de máximo;
3. Amplitude relativa à esquerda do ponto de mínimo;
4. Amplitude relativa à direita do ponto de mínimo.

O algoritmo utilizado para localização da amplitude relativa nas cristas positivas é apresentado a seguir:

```

PontosDireita = Localiza os pontos de máximo a direita;
For i=1: NumeroMaximoPontosDireita
    Soma = Soma + (Amplitude Máxima - PontosDireita);
End
AmplitudeRelativaMaximaDireita = Soma/ NumeroMaximoPontosDireita;

PontosEsquerda = Localiza os pontos de máximo a esquerda;
For i=1: NumeroMaximoPontosEsquerda
    Soma = Soma + (Amplitude Máxima - PontosEsquerda(i));
End
AmplitudeRelativaMaximaEsquerda = Soma/ NumeroMaximoPontosEsquerda;

```

Na Figura 5.72, está representada a idealização desses métodos




Figura 5.72: Amplitude relativa aos eventos de máximo e mínimo

Localização da amplitude relativa nas cristas negativas:

```

PontosDireita = Localiz os pontos de mínimo a direita;
For i=1: NumeroMaximoPontosDireita

```

```

    Soma = Soma + (Amplitude Mínima - PontosDireita);
End
AmplitudeRelativaMínimaDireita = Soma / NumeroMaximoPontosDireita;
PontosEsquerda = Localiza os pontos de mínimo a esquerda;
For i=1: NumeroMaximoPontosEsquerda
    Soma = Soma + (Amplitude Mínima - PontosEsquerda);
End
AmplitudeRelativaMinimaEsquerda = Soma / NumeroMaximoPontosEsquerda;

```

Características provenientes da análise multi-resolução

O sinal de EEG possui uma ampla faixa de frequências. Entretanto, quando se trata de padrões patológicos (epilepsia), essa faixa se reduz a 0.5-30 Hz [3]. Mas há de se considerar que a captação do sinal armazena também alguns ruídos, como artefatos de 60 Hz, movimentos, piscadas, entre outros.

De acordo com essas informações, foi observada a necessidade de se aplicar a análise multi-resolução embasando-se na transformada “wavelet”, com a finalidade de separar a parte patológica do ruído. Na Figura 5.73, estão representadas as escalas utilizadas.




Figura 5.73: Níveis de decomposição do sinal EEG

Cada nível de decomposição possui sua faixa de frequência. A utilização desses níveis

leva em consideração as informações das bandas patológicas [28], [88], [58] definidas pelos EEGers, como segue:

- D1 (50,0-100,0 Hz): caracteriza artefatos, tais como, eletromiografia (EMG) (sua energia dominante se concentra na faixa entre 50-150 Hz), e de 60 Hz, proveniente da rede elétrica;
- D2 (25,0-50,0 Hz): foi utilizado para caracterizar crise tônico clônico (20 - 40 Hz);
- D3 (12,5-25,0 Hz): caracteriza crise tônica (10-20 Hz);
- D4 (6,2-12,5 Hz): artefato de ponta onda positiva a 6 Hz (não é crise) e crise de ausência(3-5 Hz);
- D5 (3,1-6,2 Hz): artefato de movimento e ponta onda positiva 6 Hz (não é crise);
- A5 (0,0-3,1 Hz): EEG basal.

Portanto, a rede neural RNA1 deve ser treinada com as características extraídas dos níveis D2, D3, D4 e A5, ficando a responsabilidade de detectar os eventos relacionados à crise. Já a RNA2 é treinada com as características dos níveis D1, D4, D5 e A5, sendo responsável em detectar artefatos.

Os níveis D4 e A5 são comuns para ambas as redes. Para o D4 esse fato é justificável devido à grande semelhança entre a crise de ausência e os artefatos de movimento. O A5 representa o EEG basal que é utilizado para treinar ambas as redes.

A Figura 5.74 apresenta a decomposição de uma época de 1000 pontos de um sinal normal (EEG basal). A evidência dessa época é bastante representativa em A5.

Na Figura 5.75, está expressa a representação do artefato EMG. Sua representatividade pode ser notada em D1.

Para cada nível (D1 $\cdots$ A5) foram extraídas características estatísticas e relacionadas à frequência, listadas abaixo:

- entropia WT, definida pela Equação 5.17;
- energia WT, representada pela Equação 5.4;
- espectro de potência da primeira janela, representado na Equação 5.2;




Figura 5.74: Decomposição do sinal EEG basal




Figura 5.75: Decomposição do sinal EEG com artefato de EMG

- pico frequência da primeira janela, utiliza-se na Equação 5.1 par encontrar a frequência com maior representação espectral;
- espectro de potência da segunda janela, esta representada Equação 5.2;
- pico frequência da segunda janela, utiliza-se na Equação 5.1 par encontrar a frequência com maior representação espectral;
- energia não linear WT, calculada de acordo com a Equação 5.5;

- comprimento da curva WT, está representado matematicamente na Equação 5.6;
- média WT, formulação matemática esta descrita na Equação 5.14;
- mediana WT, definida na Seção 5.2.3;
- amplitude inter quartis WT, esta denido na Seção 5.2.3;
- variância WT, é fornecida de acordo com a Equação 5.15;
- desvio padrão WT, calculado de acordo com a Equação 5.17;
- “skewness” WT, matematicamente está ferramenta esta descrita na Equação 5.19;
- “kurtosiss” WT, escrito na Equação 5.18;
- rms WT, é fornecido pela Equação 5.20.

Normalização das características

A extração de características para a proposta híbrida envolve uma série de ferramentas. São gerados vetores com o mesmo número de características, para a RNA1 e RNA2, distinguindo-se dos níveis (D1 $\dots$ A5) WT utilizados. A matriz de características é representada na Figura 5.76.

Após gerar a matriz de dados para o treinamento, em que as linhas representam as ferramentas de extração e as colunas a quantidade de épocas utilizadas para o treinamento, deve-se aplicar o algoritmo de normalização. A normalização é feita levando-se em consideração o resultado de cada ferramenta separadamente (linha da matriz). O algoritmo utilizado para normalização foi descrito na Seção 5.3.2 e o classificador foi apresentado na Seção 5.3.3.

5.4 Conclusão

O estudo visual dos parâmetros apresentou apenas dois deles redundantes: frequência predominante na primeira e segunda janela e o período do evento entre os pontos de máximo e mínimo. Esses parâmetros não distinguem adequadamente o EEG de base das crises ou EEG de base dos artefatos. Não foi realizada a analogia entre EEG contendo crises e




Figura 5.76: Geração da matriz de treinamento

artefatos, porque o sistema é composto de duas redes neurais. Uma delas responsável em reconhecer crises e a outra destinada a reconhecer artefatos.

Embora o sinal EEG seja muito ruidoso, são utilizadas ferramentas de extração de características visando capturar os pontos intrínsecos para o ruído, crise e EEG basal.

O objetivo é propor metodologias utilizando técnicas de inteligência artificial, e diante desta meta foram propostos quatro arquiteturas.

Na arquitetura com análise multi-resolução, os dados são extraídos diretamente com WT, gerando um vetor de características com 200 elementos. Esse vetor é inserido diretamente nas entradas da rede neural.

Já na arquitetura com ferramentas estatísticas, foi realizada a extração de características diretamente no sinal, com 11 ferramentas estatísticas. O vetor gerado com a aplicação dessas ferramentas é inserido na rede neural.

A arquitetura com análise multi-resolução e modelo AR, é uma arquitetura inovadora diante das pesquisas realizadas, sendo construída para reconhecer crises utilizando a WT empregada na primeira arquitetura. Para reduzir a dimensão do vetor característica, foi utilizado o modelo AR.

Por último, a arquitetura híbrida, que é uma proposta inovadora, utilizando parâme-

tros do domínio da frequência, tempo (morfologia do sinal) e tempo-frequência (WT). Mesmo com todas essas ferramentas para extração de características a redução do vetor é significativa quando comparada à primeira arquitetura.

Os resultados obtidos com essas arquiteturas serão descritos no Capítulo 6.

Capítulo 6

Resultados obtidos

Neste capítulo, serão apresentados os resultados obtidos com as arquiteturas propostas e serão realizadas avaliações comparativas com outras descritas no Capítulo 5.

6.1 Definições

Todas as arquiteturas propostas utilizam a rede neural com topologia “feedforward”, com algoritmo de aprendizado “backpropagation” e com o treinamento é supervisionado tendo de início, uma meta a ser alcançada (alvo) para cada entrada apresentada à rede. A quantidade de neurônios na entrada da rede é variável conforme o vetor de características extraídos do sinal. Para a arquitetura análise multi-resolução tem-se um vetor características de 200×1 , logo, as redes têm 200 neurônios de entrada. Já na arquitetura com ferramenta estatística tem-se um vetor característica de 11×1 . Portanto, tem 11 neurônios na camada de entrada. Na arquitetura com análise multi-resolução e modelo AR, a dimensão do vetor característica é variável de acordo com a ordem, como apresentado nas Tabelas 6.5 e 6.6. A arquitetura híbrida apresenta um vetor de características com dimensão 89×1 . Logo, essa arquitetura possui 89 neurônios de entrada.

A quantidade de neurônios na camada intermediária foi estabelecida empiricamente por meio de testes. Ficou estabelecido que o seu valor é 70% dos neurônios da entrada. E a saída sempre possui um neurônio. Os parâmetros comuns às redes são preliminarmente definidas:

- A função de ativação das camadas ocultas é a tangente hiperbólica, e da camada de saída é a sigmóide (para as propostas 1 e 2);

- Função de ativação das camadas ocultas e de saída é a tangente hiperbólica (para as propostas 3 e 4));
- Ciclos máximo de treinamento igual a 60.000 ciclos;
- Meta para o desempenho igual a 10^{-15} ;
- Momento igual a 0,9;
- Taxa de aprendizagem igual a 0,01.

6.2 Arquitetura com análise multi-resolução

Nessa arquitetura, o objetivo é verificar a WT que melhor se adapte ao sinal EEG, em conjunto com a rede neural. A escolha da WT e da rede neural teve como embasamento as pesquisas realizadas no Capítulo 4. Para extrair as características foram utilizadas as WT mãe:

- WT1: coiflet (Coif-1);
- WT2: daubechies (Daub-4).

Foram realizados testes empregando algumas variações da função treinamento:

- T1: gradiente descendente com momento e aprendizado adaptativo;
- T2: backpropagation resiliente;
- T3: gradiente descendente em lote;

Foram utilizadas duas funções de performance, verificando a sua eficiência:

- P1: função de performance com erro médio quadrático;
- P2: função de performance com erro médio quadrático e regularização;

Os resultados são apresentados nas Tabelas 6.1 e 6.2.

Treinamento	Performance	WT	Acerto	Erro	Indefinidos
T1	P1	Daub-4	71,6%	28,3%	0%
T2	P1	Daub-4	69,6%	30,3%	0%
T3	P1	Daub-4	55,1%	44,2%	0,5%
T1	P1	Coif-1	64,1%	35,8%	0%
T2	P1	Coif-1	63,0%	36,9%	0%
T3	P1	Coif-1	54,4%	45,1%	0,3%
T1	P2	Daub-4	70,1%	29,8%	0%
T2	P2	Daub-4	72,1%	24,7%	0%
T3	P2	Daub-4	55,1%	44,6%	0,2%
T1	P2	Coif-1	63,5%	36,4%	0%
T2	P2	Coif-1	62,5%	37,5%	0%
T3	P2	Coif-1	51,4%	46,9%	1,6%
Valores médios			62,7%	36,7%	0,2%

Tabela 6.1: Resultados da análise multi-resolução

Treinamento	Performance	WT	Sensibilidade	Especificidade	Precisão
T1	P1	Daub-4	83,3%	70,5%	76,9%
T2	P1	Daub-4	75,6%	67,4%	71,6%
T3	P1	Daub-4	40,8%	58,2%	49,5%
T1	P1	Coif-1	54,1%	67,5%	60,8%
T2	P1	Coif-1	63,8%	62,7%	63,2%
T3	P1	Coif-1	30,9%	67,0%	48,9%
T1	P2	Daub-4	77,7%	67,5%	72,6%
T2	P2	Daub-4	85,4%	67,5%	76,4%
T3	P2	Daub-4	21,5%	65,5%	43,5%
T1	P2	Coif-1	52,0%	67,5%	59,7%
T2	P2	Coif-1	47,9%	67,5%	57,7%
Valores médios			55,6%	66,3%	60,9%

Tabela 6.2: Resultados da análise multi-resolução

Para essa arquitetura, o melhor resultado conseguido obteve uma taxa de acerto de 71,6%. Já a sensibilidade ficou em torno de 83,3%, a especificidade 70,5% e a precisão 76,9%. Comparando esses valores obtidos com os valores médios da literatura apresentados no Capítulo 4, que são em torno de 84%, eles ficaram um pouco abaixo. Esse fato deve-se a quantidade de níveis de decomposição utilizados, que são apenas dois. Geralmente, as arquiteturas que usam somente WT como ferramenta de extração de características decompõem o sinal em mais de três níveis, necessitando ter uma quantidade maior de redes neurais para o reconhecimento. Diante desses resultados, ficou comprovado que a WT Daub-4, o algoritmo de treinamento “T1” e a função de performance “P1” obtiveram o melhor resultado.

6.3 Arquitetura com ferramentas estatísticas

Para esta arquitetura foi realizada a extração de características diretamente no sinal, com 11 ferramentas estatísticas, como apresentado no Capítulo 5. Assim como na arquitetura anterior, foram realizados testes empregando algumas variações da função treinamento:

- T1: gradiente descendente com momento e aprendizado adaptativo;;
- T2: backpropagation resiliente;
- T3: gradiente descendente em lote;

Foram utilizadas duas funções de performance, verificando a sua eficiência:

- P1: função de performance com erro médio quadrático;
- P2: função de performance com erro médio quadrático e regularização;

Os resultados são mostrados nas Tabela 6.3 e 6.4.

Comparando os resultados conseguidos com a média na literatura, essa arquitetura obteve um ótimo resultado. A melhor taxa de acerto ficou em torno de 85,3%, o erro obtido foi de 14,3% e os indefinidos em torno de 1%. A sensibilidade foi de 97,4%, a especificidade 82,1% e a precisão 89,7%. Para esse resultado é observado que a função de treinamento utilizada foi a “T1” e a performance “P1”.

Treinamento	Performance	Acerto	Erro	Indefinidos
T1	P1	85,3%	14,3%	1,0%
T2	P1	83,0%	16,1%	0,0%
T3	P1	81,7%	12,2%	5,9%
T1	P2	83,2%	13,1%	3,0%
T2	P2	82,0%	12,8%	5,0%
T3	P2	79,4%	8,6%	11,9%
Valores médios		82,5%	12,9%	4,5%

Tabela 6.3: Resultados obtidos com as ferramentas estatísticas

Treinamento	Performance	Sensibilidade	Especificidade	Precisão
T1	P1	97,4%	82,1%	89,7%
T2	P1	98,7%	79,4%	89,0%
T3	P1	71,8%	91,3%	81,5%
T1	P2	95,9%	83,5%	89,7%
T2	P2	97,2%	82,2%	89,7%
T3	P2	69,5%	95,3%	82,4%
Valores médios		88,4%	85,6%	87,0%

Tabela 6.4: Resultados obtidos com as ferramentas estatísticas

6.4 Arquitetura com análise multi-resolução e modelos auto-regressivos

Essa arquitetura foi construída com a junção de duas ferramentas para extração de características: a WT que obteve o melhor resultado na análise multi-resolução e modelos auto-regressivos. Resultando em uma arquitetura inovadora. Para essa arquitetura foi utilizada a rede neural que obteve melhor taxa de acerto na arquitetura estatística. Os

dois modelos AR utilizados são: “Yule-Walker” e o “Burg”. Os resultados são apresentados nas Tabelas 6.5 e 6.6.

AR Yule-Walker						
Ordem	Acerto	Erro	Indefinidos	Especificidade	Sensibilidade	Precisão
3	81,9%	7,8%	10,2%	90,2%	90,1%	90,1%
5	81,9%	9,6%	8,4%	89,1%	90,3%	89,7%
7	83,1%	10,2%	6,6%	88,6%	91,5%	90,1%
10	87,9%	7,2%	4,8%	92,3%	92,5%	92,4%
20	86,1%	9,6%	4,2%	89,6%	92,8%	91,2%
40	85,3%	7,8%	6,8%	91,7%	91,2%	91,4%
70	81,9%	7,2%	10,8%	92,5%	91,4%	91,9%
100	81,9%	7,2%	10,8%	91,7%	90,8%	91,2%
Valores médios	83,8%	8,4%	7,9%	90,7%	91,4%	91,1 %

Tabela 6.5: Resultados obtidos com o AR Yule-Walker

AR Burg						
Ordem	Acerto	Erro	Indefinidos	Especificidade	Sensibilidade	Precisão
3	83,3%	6,4%	10,2%	94,8%	85,7%	90,2%
5	84,3%	5,4%	10,2%	94,8%	87,2%	91,0%
7	88,5%	8,4%	3,0%	91,1%	90,8%	91,0%
10	87,9%	7,8%	4,2%	91,7%	92,8%	92,2%
20	87,3%	10,1%	2,5%	88,5%	92,7%	90,6%
40	81,3%	10,2%	8,4%	88,4%	92,2%	90,3%
70	80,1%	10,8%	9,0%	87,5%	90,7%	89,1%
100	78,9%	7,2%	13,8%	92,2%	85,7%	88,9%
Valores médios	84,0%	8,3%	7,7%	91,2%	89,7%	90,5%

Tabela 6.6: Resultados obtidos com o AR Burg

A Tabela 6.5 mostra que a melhor taxa de acerto para o modelo AR “Yule-Walker” ficou em torno de 87,9%, com ordem 10. Já a Tabela 6.6 apresenta os resultados do

modelo “Burg”. A melhor taxa de acerto foi de 88,5% com ordem 7.

6.5 Arquitetura híbrida

Por último emprega-se, a quarta arquitetura que utiliza parâmetros do domínio da frequência (FFT), tempo (morfologia do sinal) e tempo-frequência (WT). Mesmo com todas essas ferramentas para extração de características, a redução do vetor é significativa quando comparada com a arquitetura análise multi-resolução. A WT utilizada obedece a que obteve melhor resultado na análise multi-resolução que é a Daub-4. A rede neural utilizada foi escolhida a que obteve melhor taxa de acerto na arquitetura estatística. A Tabela 6.7 apresenta os resultados obtidos.

Arquitetura híbrida					
Acerto	Erro	Indefinidos	Especificidade	Sensibilidade	Precisão
95.1%	2.9%	1,0%	96,6%	90,2%	93,4%

Tabela 6.7: Resultados obtidos com a arquitetura híbrida

6.6 Simulação comparativa

Foram selecionadas duas metodologias apresentadas no Capítulo 4 com o objetivo de validar as metodologias propostas. A necessidade de simular é justificável devido a grande diversidade existente entre as bases de dados. Elas são adquiridas a partir de eletrodos invasivos, com pacientes dormindo, eletrodos não invasivos, etc. Os resultados obtidos com a arquitetura denominada redes neurais com entradas parametrizadas [73], apresentada na seção 4.2.2, é mostrada na Tabela 6.8.

Redes neurais com entradas parametrizadas					
Acerto	Erro	Indefinidos	Especificidade	Sensibilidade	Precisão
90,4 %	4,1%	5,5%	91,8%	90,5%	91,15%

Tabela 6.8: Resultados obtidos com a arquitetura redes neurais com entradas parametrizadas

A outra arquitetura simulada, denominada detecção automática de eventos epilépticos [112], foi apresentada na seção 4.2.1. Os resultados são apresentados na Tabela 6.9.

Reconhecimento de sinais baseando-se em WT e RN					
Acerto	Erro	Indefinidos	Especificidade	Sensibilidade	Precisão
64,9 %	35,1%	0%	66,9%	57,8%	62,3%

Tabela 6.9: Resultados obtidos com a arquitetura wavelet e redes neurais

Conclusão

A base de dados utilizada para treinamento e teste das metodologias é oriunda da Universidade de Tampere - Finlândia [97]. A Tabela 6.10 aborda os principais dados.

Descrição	Valor
Número de pacientes	9
Quantidade de canais	4
Taxa de amostragem	200 Hz
Quantidade de horas	27 minutos
Tamanho da janela	200 pontos (1 s)

Tabela 6.10: Informações da base de dados

De acordo com a pesquisa bibliográfica realizada no Capítulo 4, a Tabela 4.11 apresenta os dados médios utilizados pela literatura. Ficou estabelecido que o número médio de pacientes é 7, a quantidade média de canais vale 17, a taxa de amostragem é 200 Hz, a quantidade média de horas é 7,7 horas e o tamanho médio da janela é 794 pontos (4 s).

Fazendo um comparativo com a base de dados utilizada na tese, é observado que a diversidade biológica (número de pacientes) da base está acima da média, enquanto que a quantidade de canais é menor. A taxa de amostragem é semelhante.

A quantidade de horas utilizadas e a janela é menor. Para detecção de crises, os quatro canais, utilizados conjuntamente com uma pequena quantidade de horas, demonstrou ser suficiente para gerar resultados razoáveis, conforme foi observado pelos resultados das simulações. O tamanho da janela foi reduzido para 1 s, levando em consideração a duração

da espícula (20 a 70 ms) e da onda aguda (70 a 200ms), obtendo-se maior precisão no processamento.

Nos resultados obtidos através das simulações realizadas ficou mostrado que a “wavelet” Daub-4 apresenta melhores resultados que Coif-1. Essa melhora é atribuída a morfologia da “wavelet” mãe Daubechies, apresentada no Capítulo 5. O algoritmo de treinamento da rede neural que apresentou melhor resultado foi o gradiente descendente com momento e aprendizado adaptativo com a função de performance erro médio quadrático. Essa melhora atribuída ao algoritmo de treinamento denominado gradiente descendente com momento e aprendizado adaptativo, quando comparado com os outros algoritmos é atribuída a função de atualização dos pesos, sendo diferenciada para cada um dos algoritmos de treinamento apresentados no Capítulo 5.

Os resultados obtidos com a análise multi-resolução demonstraram que apenas a WT como ferramenta de extração de características é inviável para reconhecimento de sinais EEG não invasivos. Tanto a capacidade de reconhecer eventos epiléticos (sensibilidade) quanto a capacidade de reconhecer outros eventos (especificidade) foi a menor obtida nas arquiteturas.

Já os resultados obtidos com a arquitetura estatística apresentou uma melhora, quando comparada com a análise multi-resolução. A capacidade de detectar eventos epiléticos ficou em torno de 97,4%, mas a capacidade em detectar artefatos ficou em torno de 82,1%. Esse fato é atribuído à grande diversidade de ruídos existentes na base de dados.

Na arquitetura denominada análise multi-resolução com modelo auto-regressivo é observado uma melhora de aproximadamente 3% na taxa de acerto, quando comparada com a arquitetura estatística. A melhoria no reconhecimento é justificável devido a capacidade em decompor os sinais em uma análise com vários níveis de resolução tempo-freqüência e a estimação dos coeficientes do modelo, a partir dos resultados da WT, com o AR.

A arquitetura denominada híbrida, foi utilizada diversas ferramentas para extração de características. Essa proposta conseguiu uma melhora significativa na taxa de acerto, mediante as arquiteturas propostas nesta tese até o momento. É importante notar que foram extraídas 89 características no total, mas a capacidade de reconhecimento eventos epiléticos foi aumentada (sensibilidade 90,2%) em conjunto com a capacidade de reconhecimento de artefatos (especificidade 96,6%).

Comparando a arquitetura híbrida proposta com as duas simuladas na literatura, a

arquitetura híbrida apresenta resultados que quantificaram melhor os eventos de crises e artefatos .

Capítulo 7

Conclusões gerais e trabalhos futuros

Neste último capítulo, serão analisadas as contribuições deste trabalho, e apresentadas sugestões para trabalhos futuros.

7.1 Conclusões gerais

O objetivo deste trabalho foi desenvolver um sistema detector de crises epilépticas por meio de atividades elétricas corticais colhidas no escalpo, utilizando o sistema internacional 10-20. Inicialmente realizou-se o estudo dos processos fisiológicos envolvidos na geração dos sinais elétricos cerebrais, dos fundamentos das epilepsias, das principais técnicas de extração de características, das técnicas de inteligência artificial (redes neurais e sistema especialista) para reconhecimento e sistemas para detecção de epilepsia.

Com base na pesquisa bibliográfica realizada, e levando em conta as particularidades da pesquisa desenvolvida pelos autores consultados; apresentam-se logo abaixo os valores médios dos parâmetros de simulação bem como as melhores opções de características representativas do EEG. Ou seja, os parâmetros do sistema detector de crises ótimo, segundo a literatura está definido logo abaixo.

A formação da base de dados deve obedecer aos seguintes critérios:

- Número de pacientes: 10;
- Número de canais: 7;
- Taxa de amostragem: 127 Hz;
- Quantidade de dados: 3,8 h/paciente;

- Tamanho da janela: 213 pontos.

Quanto à WT mãe com maior usabilidade, tem-se: Daubechies e Coiflet.

As principais ferramentas utilizadas para extrair características provenientes dos sinais resultantes da WT são apresentadas na seqüência: medidas de energia, medidas de entropia (Shannon), duração do evento, medidas de amplitude (máximo, mínimo, etc.). Ocasionalmente, pesquisadores podem extrair características diretamente do sinal, tais como: medidas de amplitude (máxima, mínima, etc.), ângulo (entre a subida e descida do evento), duração do evento, “slope” (ângulo de descida do evento), média, desvio, padrão, energia, diferença mínimo e máximo. Já os métodos utilizados para detectar os eventos patológicos são “Backpropagation” e PNN.

As arquiteturas desenvolvidas nesta tese são: análise multi-resolução, ferramentas estatísticas, análise multi-resolução com modelo AR e a arquitetura híbrida.

Na análise multi-resolução, as características são extraídas diretamente do sinal utilizado a WT, resultando em 200 características. A melhor taxa de acerto foi 76,9%. A arquitetura com ferramentas estatísticas utiliza 11 técnicas de extração de características e a taxa de acerto ficou em torno de 85,3%. Já a arquitetura de análise multi-resolução com modelo AR possui duas etapas de extração de características: a WT seguida do modelo AR. Para esta arquitetura foram utilizados dois modelos AR de ordem 7. Estimados a partir da metodologia “Yule-Walker”, gerando 88,5% de acerto. A última arquitetura utiliza 78 ferramentas de extração de características, sendo calculadas diretamente do sinal ou através da WT. Nessa arquitetura a taxa de acerto ficou em 95,1%.

Das quatro arquiteturas, a híbrida apresentou melhores resultados para detecção de crises. Esse fato é atribuído a grande diversidade de ferramentas utilizadas para extrair as características: domínio do tempo (morfologia do sinal), frequência (FFT), tempo-frequência (wavelet), informação (entropia), não lineares (energia não linear) e estatísticas (kurtosis). Nessa arquitetura também foi proposto a extração de várias características provenientes da resultante da recomposição do sinal com a transformada wavelet (WT): entropia, energia, espectro médio, pico máximo de frequência, energia não linear e ferramentas estatísticas.

7.2 Contribuições

Nesse trabalho foram propostos duas novas arquiteturas denominadas análise multi-resolução com modelos auto-regressivos e a arquitetura híbrida.

Como pôde ser observado, foi estudada a fisiologia associada ao EEG, juntamente com as crises epilépticas. Poucos trabalhos da literatura fornecem uma explanação dos processos fisiológicos que envolvem essa patologia. Este trabalho pôde ainda contribuir com a criação de novas ferramentas de extração de características, utilizadas na arquitetura híbrida, tais como:

- amplitude relativa máxima direita;
- amplitude relativa máxima esquerda;
- amplitude relativa mínima direita;
- amplitude relativa mínima esquerda;
- período do pico máximo;
- período do pico mínimo.

As duas novas arquiteturas desenvolvidas consideram uma grande variedade de ferramentas para extração de características. Para facilitar o treinamento e teste das mesmas, foram desenvolvidas plataformas gráficas para esses sistemas reconhecedores.

Foi implementado um software que permitiu a construção da base de dados, disponibilizando a visualização e o janelamento dos registros de EEG épocas de tamanho desejado.

7.3 Trabalhos futuros

A epilepsia não é um fenômeno recente, mas mesmo sendo abordada e investigada há tempos, ainda hoje é tratada como um problema de saúde pública, apesar dos avanços no desenvolvimento de métodos para diagnóstico, prevenção e tratamento. Para possibilitar aplicações clínicas ou outros projetos com as arquiteturas desenvolvidas, alguns trabalhos podem ser desenvolvidos, tais como:

- estudar minuciosamente os melhores parâmetros para detecção de epilepsia;

- integrar os sistemas a um eletroencefalógrafo digital para a aquisição e processamento dos dados eletroencefalográficos em tempo real;
- testar os sistemas com dados EEG invasivos;
- utilizar essas metodologias propostas para análise de neuro “biofeedback”;
- testar as arquiteturas com sinais oriundos de modelo animal.

Referências Bibliográficas

- [1] ACIR, N.; KUNTALP, I. O. M.; BAKLAN, B. & GUZELIS, C. Automatic detection of epileptiform events in eeg by a three-stage procedure based on artificial neural networks. *Biomedical Engineering*, vol. 52, no. 1, Jan. 2005.
- [2] AIRES, M. M. *Fisiologia Básica*. Endereço : Editora Guanabara Koogan S.A., 1985.
- [3] AKIN, M.; ARSERIM, M. A.; KIYMIK, M. K. & TURKOGLU, I. A new approach for diagnosing epilepsy by using wavelet transform and neural networks. *Engineering in Medicine and Biology Society on Annual International Conference of the IEEE*, vol. 2, no. 6, Oct. 2001.
- [4] AL-NASHASH, H. A.; PAUL, J. S. & THAKOR, N. V. Wavelet entropy method for eeg analysis: application to global brain injury. *Conference on neural engineering*, vol. 1, no. 3, March 2003.
- [5] ARGOUD, F. I. M. *Contribuição à automatização da detecção e análise de eventos epileptiformes em eletroencefalograma*. Tese de Doutorado, Universidade Federal de Santa Catarina, Junho 2001.
- [6] ARGOUD, F. I. M. & AZEVEDO, F. M. Contribuição à automatização da detecção e análise de eventos epileptiformes em eletroencefalogramas. *Revista Brasileira de Engenharia Biomédica*, vol. 18, no. 1, jan/abr 2002. SBEB - Sociedade Brasileira de Engenharia Biomédica.
- [7] BAS, E.; DEMIRALP, T.; SCHURMANN, M.; BASAR-EROGLU, C. & ADEMOGLU, A. Oscillatory brain dynamics, wavelet analysis, and cognition. *Clinical Neurophysiology*, vol. 110, no. 1, February 1999.

- [8] BATES, R. R.; SUN, M.; SCHEUER, M. L. & SCLABASSI, R. J. Seizure detection by recurrent backpropagation neural network analysis. *Fourth international symposium on uncertainty Modeling and Analysis on Computer society*, vol. 320, no. 3, Sept. 2003.
- [9] BERNARDI, A. Filtros de kalman no levantamento de características do sinal de eeg. Dissertação de Mestrado, ESCOLA FEDERAL DE ENGENHARIA DE ITAJUBÁ, 1999.
- [10] BIZIERE, K. & CHAMBON, J. P. Animal models of epilepsy and experimental seizures. *Rev Neurol Paris*, vol. 143, no. , Janeiro 1987.
- [11] BLUM, D. E. Computer-based electroencephalography: technical basics, basis for new applications, and potential pitfalls. *Electroencephalography and Clinical Neurophysiology*, vol. 106, no. 2, February 1988.
- [12] BROWNE, M. & CUTMORE, T. R. H. Low-probability event-detection and separation via statistical wavelet thresholding an application to psychophysiological denoising. *Clinical Neurophysiology*, vol. 113, no. 9, September 2002.
- [13] BUTTON, V. L. S. N. *Eletroencefalógrafos e monitores de EEG*. Campinas : Editora Unicamp, 2000.
- [14] CARDOSO, R. R. Uma estratégia de modelagem tridimensional para mampeamento de eeg de superfície. Dissertação de Mestrado, Universidade Federal de Uberlândia, 2005.
- [15] CHEN, B. H.; WANG, X. Z.; YANG, S. H. & MCGREAVY, C. Application of wavelets and neural networks to diagnostic system development, 1, feature extraction. *Computers and Chemical Engineering*, vol. 23, no. 7, July 1999.
- [16] CHEN, H.; ZHONG, S. & YAO, D. Detection singularity value of character wave in epileptic eeg by wavlet. *Communications, Circuits and Systems and West Sino Expositions, International Conference on IEEE*, vol. 2, no. 24, July 2002.
- [17] CLEMENS, B.; SZIGETI, G. & BARTA, Z. Eeg frequency profiles of idiopathic generalised epilepsy syndromes. *Epilepsy Research*, vol. 42, no. 3, December 2000.

- [18] D'ALESSANDRO, M.; VACHTSEVANOS, G.; ESTELLER, R.; ECHAUZ, J.; CRANSTOUN, S.; WORRELL, G.; PARISH, L. & LITT, B. A multi-feature and multi-channel univariate selection process for seizure prediction. *Clinical Neurophysiology*, vol. 116, no. 3, March 2005.
- [19] DENIS, M. *Prática da Medicina do Sono*. Rua do Estilo Barroco, 755, São Paulo SP : Editora BYK, 1999.
- [20] DORON, R. P. *Dicionário de psicologia*. São Paulo : Editora Ática, 1998.
- [21] EBERHART, R. C. & WEBBER, W. R. S. Neural network design considerations for eeg spike detection. *Bioengineering Conference*, vol. Fifteenth Annual Northeast-IEEE, no. , March 1989.
- [22] ELGER, C. E.; MORMANN, F.; KREUZ, T.; ANDRZEJAK, R. G.; RIEKE, C.; SOWA, R.; FLORIN, S.; DAVID, P. & LEHNERTZ, K. Characterization the spatio-temporal dynamics of the epileptogenic process with nonlinear eeg analyses. *Clinical Neurophysiology*, vol. 11, no. 1, December 2002.
- [23] ESTELLER, R. *Detection of Seizure Onset in Epileptic Patients from Intracranial EEG Signals*. Tese de Doutorado, School of Electrical and Computer Engineering Georgia Institute of Technology, 1999.
- [24] ESTELLER, R.; ECHAUZ, J.; D'ALESSANDRO, A.; VACHTSEVANOS, G. & LITT, B. Feature parameter optimization for seizure detection/prediction. *Engineering in Medicine and Biology Society*, vol. 2, no. 25, October 2001.
- [25] FLANAGAN, D.; AGARWAL, R.; WANG, Y. H. & GOTMAN, J. Improvement in the performance of automated spike detection using dipole source features for artefact rejection. *Clinical Neurophysiology*, vol. 114, no. 1, January 2003.
- [26] GIGOLA, S.; ORTIZ, F.; D'ATTELLIS, C. E.; SILVA, W. & KOCHEN, S. Prediction of epileptic seizures using accumulated energy in a multiresolution framework. *Journal of Neuroscience Methods*, vol. 138, no. 5, March 2004.
- [27] GLOVER, J. R.; KTONAS, P. Y.; SHASTRY, M.; KUMAR, A. T. & MUKTEVI, V. M. Methodology and system architecture for automated detection

- of epileptic seizures in the neonatal eeg. *Engineering in Medicine and Biology on Annual Conference and the Annual Fall Meeting of the Biomedical Engineering Society*, vol. 1, no. 24, November 2002.
- [28] GUERREIRO, C. A. M.; GUERREIRO, M. M.; CENDES, F. & CENDES, I. L. *Epilepsia*. São Paulo : Editora Lemos, 2000.
- [29] GULER, I.; KIYMIK, M. K.; AKIN, M. & ALKAN, A. Ar spectral analysis of eeg signals by using maximum likelihood estimation. *Computers in Biology and Medicine*, vol. 31, no. 6, November 2001.
- [30] GUTIÉRREZ, J.; ALCÁNTARA, R. & MEDINA, V. Analysis and localization of epileptic events using wavelet packets. *Medical Engineering and Physics*, vol. 23, no. 9, November 2002.
- [31] GUYTON, A. C. *Tratado de Fisiologia Médica*. Rio de Janeiro : Editora Guanabara Koogan S.A., 10 ed., 2002.
- [32] HARRISON, M. A. F.; FREI, M. G. & OSORIO, I. Accumulated energy revisited. *Clinical Neurophysiology*, vol. 116, no. 3, March 2005.
- [33] HASSANPOUR, H.; MESBAH, M. & BOASHASH, B. Eeg spike detection using time-frequency signal analysis. *Acoustics, Speech, and Signal Processing*, vol. 5, no. , May 2004.
- [34] HAUSER, W. A. & HESDORFFER, D. C. *Epilepsy:Frequency, Causes and consequences*. New York : New York Demos, 1990.
- [35] HESE, P. V.; BOON, P.; VONCK, K.; LEMAHIEU, I. & WALLE, R. V. D. A new method for detection and source analysis of eeg spikes. *Engineering in Medicine and Biology Society*, vol. 3, no. 14, Sept. 2003.
- [36] HOEVE, M. J.; JONES, R. D.; CARROLL, G. J. & GOELZ, H. Automated detection of epileptic seizures in the eeg. *Engineering in Medicine and Biology Society*, vol. 23, no. 25, October 2001.
- [37] HOJJAT, A.; ZIQIN, Z. B. & NAHID, D. Analysis of eeg records in an epileptic patient using wavelet transform. *Journal of Neuroscience Methods*, vol. 123, no. 1, February 2003.

- [38] HOMERO, R.; ABÁSOLO, D. E. & ESPINO, P. Use of wavelet entropy to compare the eeg background activity of epileptic patients and control subjects. *Engineering in Medicine and Biology Society*, vol. 3, no. 17, Jan. 2003.
- [39] HULATA, E.; SEGEV, R. & BEN-JACOB, E. A method for spike sorting and detection based on wavelet packets and shannon's mutual information. *Journal of Neuroscience Methods*, vol. 117, no. , May 2002.
- [40] IASEMIDIS, L. D. Epileptic seizure prediction and control. *Biomedical Engineering*, vol. 50, no. 5, May 2003.
- [41] JAIN, A. K.; DUIN, R. P. W. & JIANCHANG, M. Statistical pattern recognition: a review. *Pattern Analysis and Machine Intelligence*, vol. 22, no. 1, Jan. 2000.
- [42] JAMES, C. J.; JONES, R. D.; BONES, P. J. & CARROLL, G. J. Athe self-organising feature map in the detection of epileptiform transients in the eeg. *Engineering in Medicine and Biology Society*, vol. 3, no. 18, Nov. 1996.
- [43] JOUNY, C. C.; FRANASZCZUK, P. J. & BERGEY, G. K. Characterization of epileptic seizure dynamics using gabor atom density. *Clinical Neurophysiology*, vol. 114, no. 3, March 2003.
- [44] KALAYCI, T.; OZDAMAR, O. & ERDOL, N. The use of wavelet transform as a preprocessor for the neural network detection of eeg spikes, 1994.
- [45] KHAN, Y. U. & GOTMAN, J. Wavelet based automatic seizure detection in intracerebral electroencephalogram, clinical neurophysiology. *Clinical Neurophysiology*, vol. 114, no. , May 2003.
- [46] KIYMIK, M. K.; SUBASI, A. & OZCALIK, H. R. Neural networks with periodogram and autoregressive spectral analysis methods in detection of epileptic seizure. *Journal of Medical Systems*, vol. 28, no. 6, December 2004.
- [47] KRYMIK, M. K.; GULER, I.; DIZIBUYUK, A. & AKIN, M. Comparison of stft and wavelet transform methods in determining epileptic seizure activity in eeg signals for real-time application. *Computers in Biology and Medicine*, vol. 35, no. , October 2005.

- [48] LÜDERS, H. & LESSER, R. P. *Epilepsy Electroclinical Syndromes*. Springer Verlag Berlin Heidelberg, 1987.
- [49] LÜDERS, H. O. & SHOHEYL, N. *Atlas e Classificação em eletroencefalografia*. São Paulo : Editora Lemos, 2000.
- [50] LEHNERTZ, K. Non-linear time series analysis of intracranial eeg recordings in patients with epilepsy an overview. *International journal of psychophysiology*, vol. 34, no. 1, October 1999.
- [51] LENT, R. *Cem Bilhões de Neurônios: conceitos fundamentais de neurociência*. São Paulo : Editora Atheneu, 2004.
- [52] LITT, B. Engineering devices to treat epilepsy: A clinical perspective. *Engineering in Medicine and Biology Society-IEEE*, vol. 4, no. 23, October 2001.
- [53] LITT, B. & ECHAUZ, J. Prediction of epileptic seizure. *The Lancet Neurology*, vol. 1, no. 1, May 2002.
- [54] LUI, H. S.; ZHANG, T. & YANG, F. S. A multistage, multimethod approach for automatic detection and classification of epileptiform eeg. *IEEE-Transactions on biomedical engineering*, vol. 49, no. 12, December 2002.
- [55] MACHADO, A. B. M. *Neuroanatomia funcional*. São Paulo : Editora Atheneu, 2003.
- [56] MARINO-JÚNIOR, R. *Epilepsias*, vol. 1. São Paulo : Editora Savier, 1983.
- [57] MENG, L.; FREI, M. G.; OSÓRIO, I.; STRANG, G. & NGUYEN, T. Q. Gaussian mixture models of ecog signal features for improved detection of epileptic seizures. *Medical Engineering and Physics*, vol. 26, no. 5, June 2004.
- [58] MONTENEGRO, M. A. & CENDES, F. *EEG na prática clínica*. Lemos Editorial, 2001.
- [59] 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*, vol. 116, no. 3, March 2005.

- [60] MUTHUKUMARASWAMY, S. D. & JOHNSON, B. W. Primary motor cortex activation during action observation revealed by wavelet analysis of the eeg. *Clinical Neurophysiology*, vol. 115, no. 5, March 2004.
- [61] NAVARRO, V.; MARTINERIE, J.; QUEN, M. L. V.; CLEMENCEAU, S.; ADAM, C.; BAULAC, M. & VARELA, F. Seizure anticipation in human neocortical partial epilepsy. *Journal of brain Methods*, no. 125, May 2002.
- [62] NIEDERHAUSER, J. J.; ESTELLER, R.; ECHAUZ, J.; VACHTSEVANOS, G. & LITT, B. Detection of seizure precursors from depth-eeg using a sign periodogram transform. *Biomedical Engineering, IEEE Transactions*, vol. 50, no. 4, May 2003.
- [63] NOTLEY, S. V. & ELLIOTT, S. J. Efficient estimation of a time-varying dimension parameter and its application to eeg analysis. *Biomedical Engineering, IEEE Transactions*, vol. 50, no. 5, May 2003.
- [64] OOMORI, Y.; YANO, F.; NINOMIJA, S. P.; KODAMA, H.; FUJINO, T. & WADA, J. A. A computer-assisted spike detecting system using normalized method for epilepsy diagnosis. *System Sciences*, vol. 4, no. , Jan 1988.
- [65] OPPENHEIM, A. V. & WILLSKY, A. S. *Signals and Systems*. Prentice Hall, second ed., 1996.
- [66] PANG, C. C. C.; UPTON, A. R. M.; SHINE, G. & KAMATH, M. V. Epileptic seizure prediction and control. *Biomedical Engineering*, vol. 50, no. 2, April 2003.
- [67] PARDALOS, P. M.; SACKELLARES, J. C.; IASEMIDIS, L. D.; YATSENKO, V.; YANG, M. C. K.; SHIAU, D.-S. & CHAOVALITWONGSE, W. Statistical information approaches for the modelling of the epileptic brain. *Computational Statistics and Data Analysis*, vol. 43, no. 1, May 2003.
- [68] PARDEY, J.; ROBERTS, S. & TARASSENKO, L. A review of parametric modelling techniques for eeg analsis. *Medical Engineering and Physics*, vol. 18, no. 1, January 1996.

- [69] PARK, H. S.; LEE, Y. H.; LEE, D. S. & KIM, S. I. Detection of epileptiform activity using wavelet and neural network. *Engineering in Medicine and Biology society on Annual International Conference of the IEEE*, vol. 3, no. 2, Nov. 1997.
- [70] PARREIRA, F. J.; YAMANAKA, K.; DESTRO-FILHO, J. B. & ALLENCA, M. U. Automatic detection of seizures by using neural networks and a specialist system. *World Congress on Computer Science, Engineering and Technology Education*, March 2006.
- [71] PARREIRA, F. J.; YAMANAKA, K.; DESTRO-FILHO, J. B.; SÁ, N. A. D.; BERTUCCI, A.; NAVES, E. L. M.; BERNADINO, G. & BARROS, K. R. D. Estudo comparativo de sistemas de detecção automática de epilepsia utilizando duas famílias wavelet, coiflets e daubechies, e redes neurais artificiais. *CBRN-Congresso brasileiro de redes neurais*, 2005.
- [72] PEREIRA, M. C. V. *Tratamento de sinais bioelétricos para processamento por redes neurais artificiais*. Tese de Doutorado, Universidade Federal de Santa Catarina, 2003.
- [73] PEREIRA, W. F. *Perspectivas Clínico-Terapêuticas baseadas na Engenharia Neural*. Tese de Doutorado, Universidade Federal de Uberlândia, Uberlândia, 2004.
- [74] PETROSIAN, A.; PROKHOROV, D.; HOMAN, R.; DASHEI, R. & WUNSCH, D. An approach to seizure detection using an artificial neural network. *Electroencephalography and Clinical Neurophysiology*, vol. 98, no. 4, April 2000.
- [75] QIN, D.; HOUCHINS, B.; PARTEN, M. E.; PARKER, N.; HOMAN, R. & PETROSIAN, A. A comparison of techniques for the prediction of epileptic seizures. *Computer-Based Medical Systems*, YEAR =.
- [76] QU, H. & GOTMAN, J. A patient-specific algorithm for the detection of seizure onset in long-term eeg monitoring: possible use as a warning device. *IEEE Transactions On Biomedical Engineering*, vol. 44, no. 2, Feb. 1997.
- [77] QUYEN, M. L. V.; MARTINERIE, J.; ADAM, C. & VARELA, F. J. Nonlinear analyses of interictal eeg map the brain interdependences in human focal epilepsy. *Physica D: Nonlinear Phenomena*, vol. 127, no. 3, March 1999.

- [78] RAMABHADRAN, B.; FROST, J. D. J.; GLOVER, J. R. & YKTONAS, P. An automated system for epileptogenic focus localization in the electroencephalogram. *Journal of Clinical Neurophysiology*, vol. 16, no. 1, January 1999.
- [79] ROSSO, O. A.; BLANCO, S. & RABINOWICZ, A. Wavelet analysis of generalized tonic-clonic epileptic seizures. *Signal Processing*, vol. 83, no. 6, June 2003.
- [80] ROSSO, O. A.; MARTIN, M. T. & PLASTINO, A. Evidence of self-organization in brain electrical activity using wavelet-based informational tools. *Physica A: Statistical and Theoretical Physics*, vol. 347, no. 2, March 2005.
- [81] SAAB, M. E. & GOTMAN, J. A system to detect the onset of epileptic seizures in scalp eeg. *Clinical Neurophysiology*, vol. 116, no. 2, February 2005.
- [82] SACKELLARES, J. C.; IASEMIDIS, L. D.; SHIAU, D. S.; GILMORE, L. R. & ROPER, S. N. Epilepsy-whem chaos fails. *World Scientific*, March 2000.
- [83] SAMAR, V. J.; BOPARDIKAR, A.; RAO, R. & SWARTZ, K. Wavelet analysis of neuroelectric waveforms: A conceptual tutorial. *Brain and Language*, vol. 66, no. 1, January 1999.
- [84] SAMAR, V. J.; SWARTZ, K. P. & RAGHUVeer, M. R. Multiresolution analysis of event-related potentials by wavelet decomposition. *Brain and Cognition*, vol. 27, no. 3, April 1995.
- [85] SARTORETTO, F. & ERMANI, M. Automatic detection of epileptiform activity by single-level wavelet analysis. *Clinical Neurophysiology*, vol. 110, no. 2, February 1999.
- [86] SENHADJI, L. & WENDLING, F. Epileptic transient detection: wavelets and time-frequency approaches. *Neurophysiol. Clin.*, no. 32, April 2002.
- [87] SHOB, A.; CONNOLLY, H. E. J.; BOURGEOIS, B.; TREVES, S. T. & GUTTAG, J. Patient-specific seizure onset detection. *Epilepsy and Behavior*, vol. 5, no. 4, August 2004.

- [88] SOUZA, A. P. R. D. Uma proposta de metodologia para determinação de envelope de atividade eletromiográfica. Dissertação de Mestrado, Universidade Federal de Uberlândia, 2005.
- [89] SUBASIA, A. & ERCELEBI, E. Classification of eeg signals using neural network and logistic regression. *Computer Methods and Programs in Biomedicine*, vol. 78, no. , May 2005.
- [90] SUBASIA, A.; ERÇELEBI, E.; ALKAN, A. & KOKLUKAYA, E. Comparison of subspace-based methods with ar parametric methods in epileptic seizure detection. *Computers in Biology and Medicine*, vol. 36, no. , February 2006.
- [91] SUN, M. & J, S. R. Precise determination of starting time of epileptic seizures using subdural eeg and wavelet transforms. *Time-Frequency and Time-Scale Analysis Proceedings of the IEEE-SP International Symposium*, vol. 14, no. 106, Oct. 1988.
- [92] SZILÁGY, L.; BENYÓ, Z. & SZILÁGYI, S. M. A new method for epileptic waveform recognition using wavelet decomposition and artificial neural networks. *Proceedings of the Joint EMBS/BMES-IEEE*, 2002.
- [93] TARASSENKO, L.; KHAN, Y. U. & HOLT, M. R. G. Identification of interictal spikes in the eeg using neural network analysis. *Science, Measurement and Technology, IEE Proceedings*, vol. 145, no. 6, Nov 1988.
- [94] THAKOR, N. V. & TONG, S. Advances in quantitative electroencephalogram analysis methods. *Annual Review of Biomedical Engineering*, vol. 6, no. , Aug 2004.
- [95] TIRSCH, W. S.; SCHERB, H. & KEIDEL, M. Temporal order of nonlinear dynamics in human brain. *Brain Research Reviews*, vol. 45, no. , May 2004.
- [96] TURNER, M. *Bases de electroencefalografia clinica*. Editorial Paidós, 1971.
- [97] UNIVERSIDADE-TAMPERE. Laboratório de processamento de sinais universidade de tampere - finlândia, banco de dados de eeg. <ftp://sigftp.cs.tut.fi/pub/eeg-data>, Acessado em: 10 janeiro 2006.

- [98] UNSER, M. & ALDROUBI, A. A review of wavelets in biomedical applications. *Proceedings of the IEEE*.
- [99] URSINO, M.; MAGOSSO, E.; GARDELLA, E.; RUBBOLI, G. & TASSINARI, C. A. A wavelet based analysis of energy redistribution in scalp eeg during epileptic seizures. *Engineering in Medicine and Biology Society on Annual International Conference EMBC*, vol. 26, no. 5, Sept. 2004.
- [100] VIELA, A. L. M. *Anatomia e fisiologia humanas*. www.afh.bio.br/basicos/Nervoso1.html : última consulta em 10 janeiro, 2006.
- [101] WEBBER, W. R. S.; FISHER, R. S. & LESSER, R. P. Automatic eeg spike detection: what should the computer look for. *Annual international conference for the IEEE Engineering in Medicine and biology society*, vol. 13, no. 3, 1991.
- [102] WEBBER, W. R. S.; LESSER, R. P.; RICHARDSON, R. T. & WILSON, K. An approach to seizure detection using an artificial neural network. *Electroencephalography and Clinical Neurophysiology*, vol. 98, no. , April 1996.
- [103] WILSON, S. B. & EMERSON, R. Spike detection: a review and comparison of algorithms. *Clinical Neurophysiology*, vol. 113, no. 12, December 2002.
- [104] WILSON, S. B.; SCHEUER, M. L.; EMERSON, R. G. & GABOR, A. J. Seizure detection: evaluation of the reveal algorithm. *Clinical Neurophysiology*, vol. 115, no. 12, June 2004.
- [105] WITTE, H.; IASEMIDIS, L. D. & LITT, B. Special issue on epileptic seizure prediction. *IEEE Transactions on Biomedical Engineering*, vol. 50, no. 5, May 2003.
- [106] WU, L. & GOTMAN, J. Segmentation and classification of eeg during epileptic seizures. *Electroencephalography and clinical neurophysiology*, vol. 14, no. 106, Nov 1988.
- [107] YACUBIAN, E. M. T.; GARZON, E. E. & SAKAMOTO, A. C. *Vídeo-eletroencefalografia fundamentos e aplicação na investigação das epilepsias*. Lemos, 1999.

- [108] YAMAGUCHI, C. Fourier and wavelet analyses of normal and epileptic eletroencephalogram(eeg). *Neural Engineering on International IEEE EMBS Conference*, vol. 1, no. 1, March 2003.
- [109] YORDANOVA, J.; KOLEV, V.; ROSSO, O. A.; SCHÜRMANN, M.; SAKOWITZ, O. W.; ÖZGÖREN, M. & BASAR, E. Wavelet entropy analysis of event-related potentials indicates modality-independent theta dominance. *Journal of Neuroscience Methods*, vol. 1, no. 117, May 2002.
- [110] ZHANG, Y.; GUO, Z.; WANG, W.; HE, S.; LEE, T. & LOEW, M. A comparison of the wavelet and short-time fourier transforms for doppler spectral analysis. *Medical Engineering and Physics*, vol. 25, no. 7, September 2003.
- [111] ZHONG, Z.; HIROAKI, K. & ZHI-QIANG, L. Electroencephalogram analysis using fast wavelet transform. *Computers in Biology and Medicine*, vol. 31, no. 6, November 2001.
- [112] ZWE-LEE, G. Wavelet-based neural network for power disturbance recognition and classification. *Power Delivery*, vol. 19, no. 4, Oct. 2004.