

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA**

Christine Fredel Boos

**AVALIAÇÃO DE DESCRITORES MORFOLÓGICOS DE
EVENTOS EPILEPTIFORMES UTILIZANDO ANÁLISE DE
COMPONENTES PRINCIPAIS**

Florianópolis

2011

Christine Fredel Boos

**AVALIAÇÃO DE DESCRITORES MORFOLÓGICOS DE
EVENTOS EPILEPTIFORMES UTILIZANDO ANÁLISE DE
COMPONENTES PRINCIPAIS**

Dissertação submetida ao
Programa de Pós-Graduação em
Engenharia Elétrica da
Universidade Federal de Santa
Catarina para a obtenção do Grau
de Mestre em Engenharia Elétrica.
Orientador: Prof. Fernando Mendes
de Azevedo, Dr.
Co-orientador: Prof. Jefferson Luiz
Brum Marques, PhD.

Florianópolis

2011

Christine Fredel Boos

**AVALIAÇÃO DE DESCRITORES MORFOLÓGICOS DE
EVENTOS EPILEPTIFORMES UTILIZANDO ANÁLISE DE
COMPONENTES PRINCIPAIS**

Esta Dissertação foi julgada adequada para obtenção do Título de Mestre em Engenharia Elétrica, Área de Concentração Engenharia Biomédica, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina.

Florianópolis, 28 de Abril de 2011.

Prof. Roberto de Souza Salgado, PhD.
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica.

Banca Examinadora:

Prof. Fernando Mendes de Azevedo, D.Sc.
Orientador
Universidade Federal de Santa Catarina.

Prof. Jefferson Luiz Brum Marques, PhD.
Co-Orientador
Universidade Federal de Santa Catarina.

Banca Examinadora (continuação):

Prof. José Marino Neto, Dr.
Universidade Federal de Santa Catarina

Profa. Daniela Ota Hisayasu Suzuki, Dr.
Universidade Federal de Santa Catarina

Profa. Fernanda Isabel Marques Argoud, Dr.
Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina

AGRADECIMENTOS

A todos os meus familiares mas em especial aos meus pais, Luiz Carlos Boos e Griseldes Fredel Boos, e minha irmã, Melina Fredel Boos, pelo amor incondicional, pelo apoio, incentivo, motivação, compreensão, paciência e conselhos dados ao longo da minha vida, mas especialmente nestes últimos dois anos.

Aos professores Fernando Mendes de Azevedo e Jefferson Luiz Brum Marques por todo o apoio, paciência e orientação que foram fundamentais na realização deste trabalho.

À PGEEL, ao IEB-UFSC e à CAPES pela oportunidade e apoio financeiro para o desenvolvimento dos trabalhos realizados.

Aos amigos e colegas de laboratório que incentivaram, apoiaram e auxiliaram, mesmo que indiretamente, no desenvolvimento do trabalho.

RESUMO

O presente trabalho se insere na área de processamento de sinais de eletroencefalograma (EEG) com aplicação de técnicas de Inteligência Artificial para detecção automática de eventos epileptiformes. A proposta deste trabalho consiste na avaliação de descritores morfológicos desenvolvidos em estudos anteriores através de métodos estatísticos. Para a realização da avaliação dos descritores foi utilizada a Análise da Correlação e Análise de Componentes Principais (PCA). A utilização destas duas ferramentas estatísticas teve como objetivo eliminar a redundância de informação dentro do conjunto de descritores e diminuir sua dimensão através da exclusão de elementos ou transformação do conjunto através de PCA. O desenvolvimento da metodologia proposta foi realizado com o auxílio de software comercial de análise estatística e a validação foi realizada através da utilização de Redes Neurais Artificiais (RNA). As redes foram utilizadas para a verificação do desempenho do conjunto de descritores final em fornecer informação suficiente para que seja possível realizar a classificação, em eventos epileptiformes e não-epileptiformes, dos sinais de EEG apresentados à rede. Como resultado, obteve-se uma redução positiva da dimensão do conjunto de descritores sem que houvesse redução da representatividade do conjunto e, utilizando o conjunto reduzido, a rede neural apresentou 82% de sensibilidade, 85% de especificidade, eficiência de 83,5% e 4,5 falsos positivos por minuto. Sendo assim, comparando os resultados apresentados pelo conjunto de descritores original e reduzido, observa-se que a redução de dimensionalidade alcançada com a metodologia proposta não afeta, de modo significativo, o desempenho do classificador utilizado.

Palavras-chave: Sinal de eletroencefalograma, descritores morfológicos, Análise de Componentes Principais.

ABSTRACT

This work fits in the area of electroencephalogram (EEG) signal processing with application of Artificial Intelligence techniques for automatic detection of epileptiform events. This work's proposal involves the assessment of morphological descriptors developed in previous studies using statistical methods. To perform the descriptors' evaluation we used Correlation Analysis and Principal Component Analysis (PCA). The use of these two statistical analyses aimed to eliminate redundant information within the set of descriptors and reduce its size by either excluding items or transforming the set by applying PCA. The development of the proposed methodology was accomplished with the aid of commercial software for statistical analysis and the validation was carried out using Artificial Neural Networks (ANN). The validation consisted in verifying the performance of the descriptors ensemble in providing enough information for the classifier to accomplish the correct classification of EEG signals events presented. As a result we achieved the size reduction of the set of descriptors with no loss of the sets' representativeness and, using the reduced set, the ANN obtained a sensitivity value of 82%, 85% of specificity, efficiency of 83.5% and 4.5 false positives per minute. Thus, comparing the results of the original and reduced set of descriptors, it is observed that the dimensionality reduction achieved with the proposed methodology does not affect, in a significant way, the performance of the classifier used.

Keywords: Electroencephalogram signal, morphological descriptors, Principal Component Analysis

LISTA DE FIGURAS

Figura 1 – Exemplos de padrões eletrográficos presentes no sinal de EEG.....	26
Figura 2 – Diferenças apresentadas pelo sinal de EEG quando é utilizada uma (A) montagem bipolar e (B) unipolar ou referencial. Na montagem bipolar o sinal é resultado da diferença de potencial entre pares de eletrodos enquanto que para a montagem unipolar o sinal é obtido pela diferença de potencial entre um eletrodo e um ponto referencial único (para todos os eletrodos da montagem).	35
Figura 3 – Sistema 10/20 para o posicionamento de eletrodos.	36
Figura 4 – Morfologia dos principais eventos não-epileptiformes encontrados nos registros de sinais de EEG em análise.	37
Figura 5 – Morfologia apresentada pelos eventos epileptiformes presentes nos registros em análise devido à utilização de montagem bipolar.	38
Figura 6 – Descritores morfológicos relacionados à amplitude e duração, apresentados por um evento.....	38
Figura 7 – Amplitude máxima (Amax_pts), amplitude mínima (Bmin_pts), diferença entre as amplitudes extremas (Tdif_pts) e intervalo de tempo entre as amplitudes extremas (DifAB_pts), no segmento de 300ms.	39
Figura 8 – Ângulo de vértice positivo e negativo de um evento epileptiforme, calculado a partir da amplitude máxima e mínima, respectivamente.	40
Figura 9 – Descritores para a diferenciação entre eventos epileptiformes e artefatos presentes nos sinais.	40
Figura 10 – Resposta em frequência dos filtros utilizados.	41
Figura 11 – Resultado da interpolação de um evento epileptiforme.	42
Figura 12 – Valores médios das diferenças das amplitudes mínimas. ..	47
Figura 13 – Valores médios das diferenças das amplitudes máximas. ..	47
Figura 14 – Valores médios da distorção gerada pelo processo de interpolação.	48
Figura 15 – Gráfico da análise dos valores de correlação	55
Figura 16 – Resultados da Análise de Componentes Principais.	56
Figura 17 – Gráfico do treinamento da rede A.	58
Figura 18 – Gráfico do treinamento da rede B.	59

Figura 19 – Fluxograma do funcionamento do algoritmo desenvolvido para calcular o valor dos descritores morfológicos selecionados.....	75
Figura 20 – Forma dos sinais coletados pelo algoritmo para realização do cálculo dos descritores.....	76
Figura 21 – Tratamento de bordas do algoritmo de cálculo dos descritores.....	77
Figura 22 – Duração do evento presente na época em análise.....	78

LISTA DE TABELAS

Tabela 1 – Auto-valores e variâncias dos fatores obtidos com PCA do conjunto de descritores selecionado.	46
Tabela 2 – Matriz de correlação entre eventos epileptiformes (EPL) e não-epileptiformes (NEP) para os descritores morfológicos selecionados.	50
Tabela 3 – Parâmetros de configuração das duas redes neurais (rede A e rede B) utilizadas para a validação dos conjuntos de descritores. ..	57
Tabela 4 – Valores dos índices utilizados para analisar o desempenho do teste realizado nas redes neurais desenvolvidas.	60
Tabela 5 – Resumo dos valores dos descritores para os sinais analisados.	79
Tabela 6 – Auto-vetores dos fatores obtidos através da PCA para o conjunto de descritores e para todos os sinais selecionados.....	81
Tabela 7 – Resumo dos valores dos fatores calculados a partir de PCA e dos valores dos descritores morfológicos selecionados.	91
Tabela 8 – Métricas para avaliação do desempenho de redes neurais...	95

PRODUÇÃO ACADÊMICA

Capítulo de livro

BOOS, C. F.; AZEVEDO, F. M.; SCOLARO, G. R.; PEREIRA, M. C. V. Automatic Detection of Paroxysms in EEG Signals Using Morphological Descriptors and Artificial Neural Networks. *In: Biomedical Engineering, Trends in Electronics, Communications and Software*, LASKOVSKI, A. N. (Ed.), [S.l.]:InTech, 2011, p. 389-402. ISBN: 978-953-307-475-7. Available at: <<http://www.intechopen.com>>

Artigos apresentados e publicados em anais de congresso

BOOS, C. F.; PEREIRA, M. C. V.; ARGOUD, F. I. M.; AZEVEDO, F. M. Analysis and definition of morphological descriptors for automatic detection of epileptiform events in EEG signals with artificial neural networks. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER SCIENCE AND INFORMATION TECHNOLOGY, 3, 2010, Chengdu, China. *Proceedings of the 3rd IEEE International Conference on Computer Science and Information Technology*, v. 5, [S.l.]: IEEE Press, 2010, p. 349-353.

BOOS, C. F.; PEREIRA, M. C. V.; ARGOUD, F. I. M.; AZEVEDO, F. M. Morphological descriptors for automatic detection of epileptiform events. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 32, 2010, Buenos Aires, Argentina. *Proceedings of the 32nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. [S.l.]: IEEE Press, 2010, p. 2435-2438.

SUMÁRIO

1	Introdução	21
1.1	Objetivos	22
1.1.1	Objetivos específicos.....	22
2	Fundamentação Teórica	25
2.1	Sinal de eletroencefalografia e a epilepsia	25
2.2	Deteção automática de eventos epileptiformes.....	29
2.2.1	Histórico de pesquisas realizadas no IEB-UFSC	29
2.2.2	Abordagens baseadas em parametrização do sinal.....	30
2.3	Análise de Componentes Principais	31
3	Metodologia	35
3.1	Banco de sinais de EEG	35
3.2	Cálculo dos descritores morfológicos	36
3.3	Avaliação dos descritores.....	43
4	Resultados	47
5	Dicussão dos resultados e considerações finais.....	61
	Referências	65
	Apêndice A – Resumo dos elementos do conjunto de descritores morfológicos selecionados para esta pesquisa	73
	Apêndice B – Algoritmo para cálculo dos descritores morfológicos	75
	Apêndice C – Valores dos descritores morfológicos	79
	Apêndice D – Valor dos auto-vetores utilizados para o cálculo dos fatores obtidos através de Análise de Componentes Principais.	81
	Apêndice E – Valores dos fatores obtidos através de PCA.....	91
	Apêndice F – Fluxograma do processo de treinamento realizado para as redes neurais artificiais desenvolvidas	93
	Apêndice G – Métricas utilizadas para a avaliação do desempenho das Redes Neurais Artificiais	95

1 INTRODUÇÃO

Na investigação da epilepsia, a análise de sinais de eletroencefalograma (EEG) é uma importante ferramenta para a confirmação clínica do diagnóstico uma vez que a ocorrência de algumas manifestações eletrográficas neste sinal é um forte indicativo da patologia. Estes paroxismos são chamados “eventos epileptiformes”, sendo as espículas o mais frequente destes eventos presentes nos sinais de EEG de pacientes comprovadamente epiléticos.

Apesar da necessidade de automatização da análise dos sinais de EEG e de existirem muitos trabalhos desenvolvidos neste sentido, ainda não se dispõe de um sistema com ampla utilização e desempenho ótimo. Wilson e Emerson (2002) analisaram este fato em um estudo comparativo dos diversos métodos de detecção de espículas, registrados de 1976 a 2000, e apontaram que os melhores resultados são obtidos quando se utilizam métodos que empregam alguma forma de parametrização¹ dos sinais.

Os primeiros estudos relacionados à parametrização com o objetivo de detectar eventos epileptiformes em sinais de EEG foram publicados por Gotman e Gloor em 1976 e 1982. A tendência nos últimos anos é a utilização da Entropia e da Entropia junto à Transformada Wavelet, além da utilização de métodos estatísticos, como a aplicação da correlação, variância, análise da coerência ou mesmo uma combinação entre os três, para a extração de características.

Segundo a literatura, até o presente um dos métodos mais utilizados e bem sucedidos aplicados em sistemas de detecção automática de paroxismos é o de Gotman (HOEF *et al.*, 2010). Este método, de 1982, se baseia na modelagem de espículas através de parâmetros, que neste trabalho serão chamados de descritores morfológicos, previamente à detecção. A literatura possibilita o acesso a diversos estudos relativos à utilização de descritores morfológicos para a caracterização de sinais de EEG, no entanto faz-se necessária uma análise detalhada quanto à contribuição de cada descritor na detecção dos eventos.

Em contribuição a diversas pesquisas realizadas na linha de detecção automática de eventos em sinais de EEG e em continuidade aos diversos estudos desenvolvidos anteriormente no Instituto de

¹ Neste estudo, o termo parametrização refere-se à representação de do sinal de EEG por meio de parâmetros relacionados à suas características físicas e morfológicas.

Engenharia Biomédica da Universidade Federal de Santa Catarina (IEB-UFSC), este trabalho propõe-se a avaliar descritores morfológicos utilizados na identificação automática de eventos epileptiformes. Com base nas pesquisas desenvolvidas por Pereira (2003), foi selecionado um conjunto de descritores morfológicos no qual será realizada uma avaliação dos elementos deste conjunto para que, através da metodologia proposta, seja possível otimizá-lo.

A metodologia proposta para avaliação do conjunto de descritores selecionado consiste na utilização de métodos estatísticos, Análise da Correlação e Análise de Componentes Principais (PCA), para formar subconjuntos de descritores contendo apenas conteúdo realmente fundamental para a correta discriminação automática entre os eventos do sinal de EEG.

Os resultados da avaliação do conjunto de descritores são obtidos com o uso de ferramentas computacionais (*software*) de análise estatística e os resultados obtidos são utilizados para realização de uma reformulação no conjunto com o propósito de otimizá-lo.

Finalizando este processo, a metodologia aplicada passa por processo de teste e validação através de Redes Neurais Artificiais e estudo comparativo.

1.1 OBJETIVOS

O objetivo geral deste trabalho é avaliar um conjunto de descritores morfológicos utilizados na identificação automática de eventos epileptiformes com redes neurais artificiais, através de métodos estatísticos para possibilitar a otimização do conjunto necessário para a caracterização dos paroxismos do sinal de eletroencefalograma.

1.1.1 Objetivos específicos

Para alcançar o objetivo geral proposto é necessário completar alguns objetivos específicos como:

- Estudar e definir um conjunto de descritores para a análise;
- Definição do conjunto de sinais de eletroencefalograma para utilização no desenvolvimento, teste e validação da metodologia proposta;

- Definir a metodologia de avaliação dos descritores com base em Análise Estatística Multivariada;
- Desenvolver redes neurais para a detecção automática de paroxismos utilizando o conjunto de descritores como estímulo de entrada;
- Avaliar o desempenho dos descritores morfológicos na identificação automática de eventos;
- Validar a metodologia proposta.

2 FUNDAMENTAÇÃO TEÓRICA

A abordagem dos conceitos principais que dão sustentação ao presente trabalho são objeto desta seção, e permitem fundamentar a metodologia proposta e defendida neste trabalho.

2.1 SINAL DE ELETROENCEFALOGRAFIA E A EPILEPSIA

O primeiro registro de atividade cerebral na forma de sinais elétricos, através da utilização de um galvanômetro e inserção de dois eletrodos sob o escalpo de um indivíduo, foi realizado em 1875 pelo cientista inglês Richard Caton. Desde então o eletroencefalograma (EEG) tem sido utilizado para denotar a atividade neural elétrica do cérebro (SANEI & CHAMBERS, 2007).

A aquisição do sinal de EEG pode ser realizada através da introdução de eletrodos no interior do tecido cerebral (registro de profundidade), do posicionamento de eletrodos diretamente na superfície exposta do córtex cerebral (Eletrocorticograma – ECoG) ou do posicionamento de eletrodos, de forma não invasiva, na superfície do couro cabeludo (Eletroencefalograma de superfície – sEEG).

O EEG superficial (de escalpo) em humanos, no que diz respeito às suas características físicas, ocupa uma banda em frequência de 0 Hz a 100 Hz e uma faixa de amplitudes de 2 a 200 μV , no entanto, de forma geral, o sinal concentra-se entre 0,5 e 60 Hz com amplitude média de 50 μV (COIMBRA, 1994).

Estas características de amplitude e frequência do sinal são influenciadas pela localização em relação ao córtex cerebral a partir da qual foi adquirido o registro, bem como da idade, do estado físico (sono, vigília, coma, e outros.) e do estado comportamental (depressão, excitação, euforia, stress, entre outros.) do indivíduo. Além disso, o sinal pode também ser distorcido pela interferência de artefatos das mais diversas fontes como, por exemplo, potenciais elétricos extracerebrais do próprio paciente, os eletrodos e sistema de aquisição do sinal e interferências eletromagnéticas externas. Isto significa que os registros podem apresentar variabilidade entre pacientes mesmo sob circunstâncias idênticas e também apresentar variações em um mesmo paciente ao longo do tempo, o que contribui para dificultar muito uma

possível modelagem matemática dos padrões eletrográficos comumente presentes no EEG.

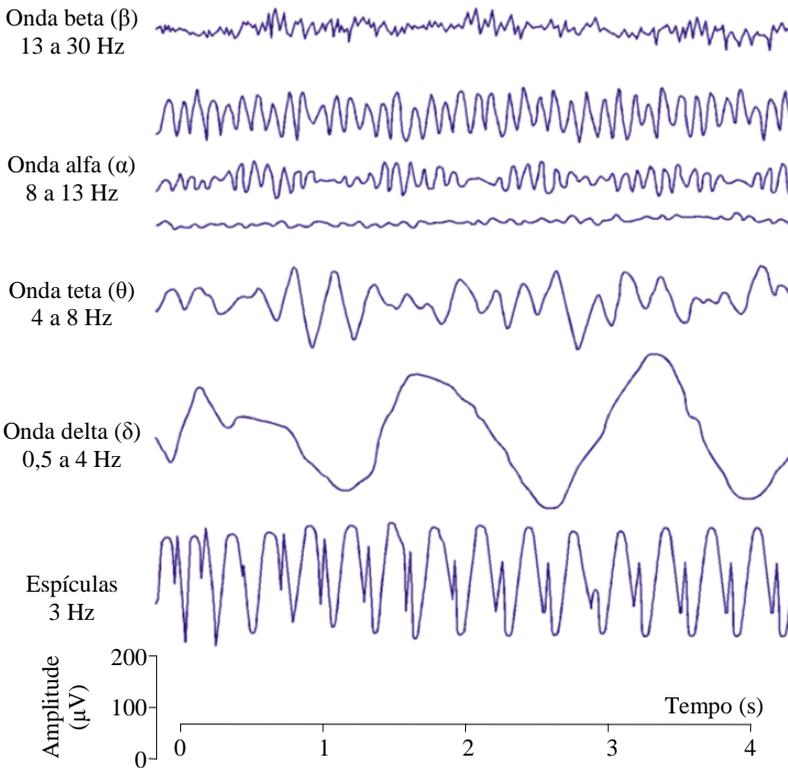


Figura 1 – Exemplos de padrões eletrográficos presentes no sinal de EEG.
Modificado de Sanei e Chambers (2007)

Apesar disso, estes padrões possuem uma relativa regularidade em frequência, morfologia e amplitude, ou seja, o espectro de frequências do EEG é normalmente subdividido em faixas de frequência que podem estar relacionadas a diversos estados físicos e comportamentais, que podem ser observados na Figura 1 e são, conforme Sanei e Chambers (2007), os seguintes:

- Banda Alfa (α) – 8 a 13 Hz – Ritmo comum em pacientes normais, e mais facilmente observável estando o indivíduo acordado, relaxado e com os olhos fechados;

- Banda Beta (β) – 13 a 22 Hz – Ritmo comum em pacientes adultos normais, durante o estado de vigília. Dominante na região pré-central do cérebro, mas aparece também em outras regiões cerebrais. Subdivide-se em: Beta I, de 13 a 17 Hz – presente durante intensa ativação do sistema nervoso central – e Beta II, de 18 a 22 Hz – diminui durante intensa ativação do sistema nervoso central;
- Banda Teta (θ) – 4 a 8 Hz – Ritmo frequente em crianças, nas regiões central e temporal. Típico de estágios iniciais do sono. Alguns transientes de componentes deste ritmo têm sido encontrados em pacientes adultos normais;
- Banda Delta (δ) – 0,5 a 4 Hz – Ritmo comum em crianças (principalmente em recém-nascidos) em estado de sono profundo. A presença desta onda em adultos sob estado de alerta pode indicar anormalidades.

O registro de EEG tem aplicabilidade, dentre outros, em monitoramento do estado de vigília, coma e morte encefálica, localização de áreas danificadas após traumatismo craniano, acidente vascular cerebral e tumor, realização de testes de vias aferentes, monitoramento da profundidade anestésica, investigação da fisiologia e distúrbios do sono, e na investigação de epilepsia e localização do foco das crises epiléticas (SANEI & CHAMBERS, 2007). Estes últimos – investigação da epilepsia e localização do foco das crises epiléticas - constituem-se em duas das principais aplicações finais da metodologia proposta no presente trabalho.

A epilepsia é uma doença do cérebro caracterizada por uma persistente predisposição a gerar crises epiléticas e pelas consequências neurobiológicas, cognitivas, psicológicas e sociais desta condição. A caracterização da epilepsia requer a ocorrência de, pelo menos, uma crise epilética, ou seja, uma ocorrência transitória de sinais e/ou sintomas devidos à atividade anormal excessiva ou síncrona de neurônios no cérebro (FISHER *et al.*, 2005).

Os neurologistas podem realizar um diagnóstico de epilepsia simplesmente através da anamnese, no entanto, a análise do sinal de EEG é uma ferramenta comumente utilizada e importante para a confirmação clínica do diagnóstico, no auxílio para a definição do tipo de síndrome epilética, para fornecer informação necessária ao planejamento da terapia medicamentosa e ainda auxiliar a tomada de decisão sobre viabilidade de intervenção cirúrgica.

A ocorrência de certas manifestações eletrográficas no sinal de EEG, denominadas eventos epileptiformes, é um forte indicador da presença desta patologia. Um evento epileptiforme, que pode ser tanto uma espícula como uma onda aguda, tem suas características morfológicas básicas relacionadas à sua amplitude e duração. As espículas possuem uma duração de 20 a 70 ms, enquanto que uma onda aguda possui duração de 70 a 200 ms, mas como ambas podem ser um evento epileptiforme, uma distinção entre elas não tem aplicação do ponto de vista clínico na detecção automática de eventos e, por isso, considera-se que a duração de um paroxismo pode variar de 20 a 200ms. Os valores das amplitudes de ambas (espículas e ondas agudas) são variados, porém considerando os eventos epileptiformes o valor da amplitude (em módulo) geralmente encontra-se entre 20 μV e 200 μV (NIEDERMEYER, 2005).

Um especialista na leitura de registros de EEG, os chamados eletroencefalografistas ou “EEGers”, gasta uma quantidade considerável de tempo para analisar cada registro, especialmente quando eles são adquiridos por longos períodos de tempo (mais de 24 horas) e com muitos canais – entre 24 e 128 derivações (PILLAY & SPERLING, 2006). Por exemplo, considerando a revisão de um registro de EEG referente ao monitoramento contínuo de três dias completos (72 horas) através de telas de 15 segundos teríamos 17280 telas para análise, o que demanda tempo além ser uma tarefa cansativa.

Na tentativa de facilitar a análise dos registros de EEG por neurologistas, ou outros especialistas, muitos estudos propuseram sistemas automatizados para esta análise. Porém, raros sistemas computacionais de revisão automática de EEG tiveram seu uso disseminado, até o momento, principalmente porque os sistemas disponíveis para a realização de detecção automática dos eventos epileptiformes tendem a erroneamente identificar como positivos um número muito grande de eventos não-epileptiformes, o que resulta em pouca ou nenhuma economia efetiva de tempo no processo (Wilson & Emerson, 2002). Portanto, a baixa especificidade dos sistemas mais recentes ainda desestimula os EEGers a delegar esta tarefa de análise meticulosa das milhares de telas, com até 128 sinais contínuos em cada uma, na busca por eventos cuja duração máxima não excede 200 ms e os valores de amplitude estão na faixa de microvolts (μV).

2.2 DETECÇÃO AUTOMÁTICA DE EVENTOS EPILEPTIFORMES

O Instituto de Engenharia Biomédica da Universidade Federal de Santa Catarina (IEB-UFSC) tem como uma de suas linhas de atuação e interesse, a aquisição, análise e processamento de sinais bioelétricos, em especial, os sinais de eletroencefalograma (EEG) e eletrocardiograma (ECG).

2.2.1 Histórico de pesquisas realizadas no IEB-UFSC

O IEB-UFSC, desde 1993, vem desenvolvendo pesquisas sobre o processamento de sinais de eletroencefalograma no âmbito de mestrado e doutorado. Estas pesquisas, além das respectivas dissertações e teses, originaram uma série de publicações em periódicos, capítulos de livros e apresentações e publicações em anais de congressos internacionais e nacionais.

Atualmente, na área de processamento de EEG, há duas linhas de pesquisa em andamento, ambas utilizando técnicas de Inteligência Artificial para detecção automática de eventos epileptiformes: uma aplica metodologias baseadas em Transformada Wavelet e a outra utiliza parametrização do sinal de EEG. Esta última é a que se aborda na presente dissertação.

Na primeira abordagem, diversos trabalhos – dentre os quais destacam-se Argoud *et al*, (1999, 2004a, 2004b; 2006), Argoud (2001), Pereira (2003) e Scolaro (2009) – utilizaram a Transformada Wavelet para desenvolver metodologias que realizassem um processamento dos sinais de EEG com intuito de permitir uma pré-seleção dos sinais apresentados ao classificador utilizado para identificar o tipo de evento presente no sinal em análise. Essas pesquisas fizeram uso do mesmo tipo de classificador, as Redes Neurais Artificiais, apresentando variações nas configurações, quantidade de redes utilizadas em cada um dos trabalhos e nos métodos de análise do desempenho do classificador.

Os resultados obtidos nesses trabalhos apresentaram valores de desempenho promissores, mas por falta de uma padronização nos métodos de análise de desempenho das metodologias desenvolvidas não é possível realizar uma comparação adequada dos resultados obtidos e, ainda, outra dificuldade reside no fato de que os estudos são, em alguns casos, apenas o desenvolvimento de metodologias de análise e, em outros, por se tratarem de sistemas completos de análise automatizada.

A segunda abordagem, que aplica a parametrização do sinal, utiliza descritores morfológicos para extrair características dos sinais de EEG que forneçam informação suficiente para que um classificador possa realizar a discriminação entre diferentes padrões de eventos presentes nos sinais. Os estudos desenvolvidos com esta abordagem centraram-se na produção de conjuntos de descritores morfológicos para aplicação em sistemas de detecção automática de eventos, a formulação de métodos de avaliação dos conjuntos desenvolvidos, a realização de comparações desta abordagem com outras ferramentas para a extração de características dos sinais e o desenvolvimento de sistemas de análise dos classificadores utilizados (PEREIRA, 2003; SOVIERSOSKI, 2009; BOOS *et al.*, 2011).

As pesquisas desenvolvidas com a parametrização do sinal de EEG demonstraram que é possível a utilização destas características para alimentar classificadores a fim de detectar automaticamente os eventos epileptiformes presentes nos sinais de EEG. No entanto, alguns aspectos da utilização dos descritores morfológicos, dentre os quais destaca-se a avaliação e otimização dos conjuntos desenvolvidos, não foram focados, dando margem a continuidade das pesquisas nesta linha de trabalho.

2.2.2 Abordagens baseadas em parametrização do sinal

Um estudo comparativo entre diversos algoritmos utilizados em métodos de detecção automática, realizado por Wilson e Emerson (2002), demonstrou que os métodos que utilizam alguma forma de parametrização do sinal de EEG geralmente obtêm bons resultados.

As primeiras pesquisas envolvendo a parametrização como ferramenta para detecção de eventos epileptiformes em registro de EEG foram publicados por Gotman e Gloor (GOTMAN, 1982; GOTMAN & GLOOR, 1976), seguidas pelas pesquisas de Webber (1994), Walczak & Nowack (2001), Litt (2001) e Tzallas *et al.* (2006), dentre outros que obtiveram resultados promissores.

Todavia, com os avanços de métodos matemáticos e o aumento da capacidade de processamento computacional, as pesquisas se direcionaram para a utilização de outras abordagens (HALFORD, 2009), como, por exemplo, a Transformada Wavelet, a entropia, os métodos estatísticos ou uma combinação entre estes e outros métodos, como os utilizados por Kaneko *et al.* (1999), Diambra (1999), Liu *et al.* (2002), Saab & Gotman (2005); Tzallas *et al.* (2006), Übeyli (2009) Kumar

(2010). Apesar dessas outras metodologias, o IEB-UFSC manteve suas pesquisas com a abordagem de parametrização, como se constata nos trabalhos desenvolvidos por Guedes *et al.* (2002), Pereira (2003), Pereira *et al.* (2003), Sovierzoski (2009) e Boos *et al.* (2010a, 2010b, 2011).

De acordo com a literatura, até o presente momento um dos mais utilizados e mais bem sucedidos métodos empregado em sistemas de detecção automática de paroxismos baseia-se no método de Gotman (HOEF *et al.*, 2010). Este método realiza a modelagem das espículas através de parâmetros que, neste trabalho serão chamados descritores morfológicos, antes da detecção. A pesquisa de Gotman trata do sinal EEG, dividindo-o em segmentos e sequências, tanto ascendentes e quanto descendentes, que são classificados por duração, amplitude absoluta e coeficiente de variação da duração (que fornece informação sobre a cadência do EEG). Neste sistema, a ocorrência da detecção de um paroxismo ocorre quando os valores dos descritores para cada época em análise exceder um limite pré-determinado.

Embora a literatura possibilite acesso a diversos estudos sobre a utilização de descritores morfológicos para caracterização do sinal EEG, faz-se necessária uma análise aprofundada da aplicabilidade, pertinência e eficácia do conjunto de descritores a ser utilizado. Esta análise torna-se importante uma vez que a apresentação do conjunto ao classificador utilizado é feita em um mesmo instante e por este motivo é preciso identificar a existência, ou não, de descritores que forneçam informação redundante sobre a morfologia ou descritores que se cancelam entre si, uma vez que essas duas situações podem influenciar negativamente o funcionamento do classificador e, por consequência, afetar o desempenho do sistema automatizado no qual este classificador está inserido.

2.3 ANÁLISE DE COMPONENTES PRINCIPAIS

A Análise de Componentes Principais (PCA) é um método estatístico de análise multivariada, comumente utilizado com o objetivo de redução da dimensionalidade de problemas aos quais é aplicado (RAYKOV & MARCOULIDES, 2008).

Na área de processamento de sinais de EEG, e mais especificamente na detecção automática de eventos epileptiformes, este método pode ser utilizado para, entre outros, diminuir o volume de

informação apresentado a ferramentas de inteligência artificial empregadas na construção desses sistemas de detecção automática. Alguns exemplos das aplicações de PCA nesta área de pesquisa são os trabalhos de:

- Ghosh-Dastidar *et al.* (2008), que utiliza a PCA para, além de redução de dimensionalidade, realizar o aprimoramento das 9 características baseadas em Transformada Wavelet e Teoria do Caos que são apresentadas a um classificador com o intuito de melhorar o desempenho deste classificador;
- Wang *et al.* (2010), onde a aplicação de PCA objetiva a redução do tamanho dos sinais de EEG utilizados na pesquisa e também realizar a extração de características desses sinais;
- Sezer *et al.* (2010), onde a PCA é empregada a redução da dimensão dos vetores de coeficientes da Transformada Wavelet que, neste caso, é utilizada para a extração de características dos sinais de EEG que posteriormente serão classificados;
- Subasi & Gursoi (2010), onde é apresentada uma comparação entre classificadores chamados Máquinas de Suporte Vetorial (*Support Vector Machines*), com a utilização da Transformada Wavelet em combinação com a Análise de Discriminantes Linear (LDA), a Análise de Componentes Independentes (ICA) e a Análise de Componentes Principais (PCA) para a extração de características e redução de dimensionalidade dos dados apresentados aos classificadores.

Em termos gerais, a Análise de Componentes Principais, conforme Myatt & Johnson (2009), é uma combinação linear de pesos das variáveis originalmente observadas no problema em análise e que possibilita um melhor entendimento do conjunto de dados observados e a redução do número de variáveis apresentadas.

A descrição e desenvolvimento matemático detalhado do funcionamento e da obtenção das componentes principais pode ser observado em diversos trabalhos, como Bilodeau & Brenner (1999), Härdle & Simar (2007), Raykov & Marcoulides (2008). No entanto, a síntese de como se realiza a PCA pode ser exemplificada, de acordo com a aplicação desejada neste trabalho, conforme segue:

- a partir de uma matriz de dados iniciais “ X ” formada por “ p ” descritores morfológicos obtidos de “ n ” sinais de EEG:

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{np} \end{bmatrix}$$

Eq. 1

- considera-se que o vetor aleatório “ x ” representa o conjunto de descritores selecionado para análise:

$$\vec{x} = [x_1, x_2, \dots, x_p]$$

Eq. 2

- calcula-se a matriz de covariância, ou correlação, para todos os descritores;
- e obtém-se através de desenvolvimento matemático da matriz calculada, seja ela de covariância ou correlação, os auto-valores “ λ ” e auto-vetores “ a ” de “ k ” componentes principais:

$$\lambda = [\lambda_1, \lambda_2, \dots, \lambda_k] \quad e \quad a = \begin{bmatrix} \vec{a}_1 \\ \vec{a}_2 \\ \vdots \\ \vec{a}_k \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1p} \\ a_{21} & a_{22} & \dots & a_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ a_{k1} & a_{k2} & \dots & a_{kp} \end{bmatrix}$$

Eq. 3

- os auto-vetores são vetores com os pesos das combinações lineares utilizadas para calcular o valor das componentes principais “ y ” e os auto-valores são o valor da variância de cada componente principal, ou seja, indicam a representatividade de cada componente calculada;

$$\begin{aligned} y_1 &= a_1 x = a_{11}x_1 + a_{12}x_2 + \dots + a_{1p}x_p \\ y_2 &= a_2 x = a_{21}x_1 + a_{22}x_2 + \dots + a_{2p}x_p \\ &\dots \\ y_k &= a_k x = a_{k1}x_1 + a_{k2}x_2 + \dots + a_{kp}x_p \end{aligned}$$

Eq. 4

Sendo assim, para o exemplo utilizado, após realizar PCA num determinado conjunto de descritores, obtém-se um novo conjunto de descritores composto de “ k ” elementos. E estes elementos são as “ k ” componentes principais, também denominadas fatores, cujo auto-valor “ λ_k ” é o valor da variância apresentada pelo fator “ y_k ” e o somatório dos auto-valores, $\sum_{i=0}^k \lambda_i$, é utilizado para indicar a representatividade do conjunto obtido.

3 METODOLOGIA

Esta seção dedica-se à apresentação dos registros e metodologias utilizadas, tanto para o cálculo do conjunto de descritores morfológicos, quanto para a realização dos experimentos utilizados como ferramenta de avaliação do conjunto proposto.

3.1 BANCO DE SINAIS DE EEG

Todos os sinais de EEG utilizados neste estudo foram os mesmos sinais utilizados por Argoud (2001), Pereira (2003) e Sovierzoski (2009) em suas teses de doutorado. São nove registros, adquiridos com frequência de amostragem de 100Hz e através de 24 canais (um registro) e 32 canais (oito registros). E ainda, durante o processo de aquisição os sinais passaram por filtragem analógica para isolamento da faixa de frequência de 0,5 a 40Hz.

A montagem de eletrodos utilizada foi a bipolar do tipo zigomática-temporal (Zygo-Db-Temp), como ilustra a Figura 2, com 25 eletrodos nas posições Zy1, Zy2, Fp1, Fp2, F3, F4, F7, F8, F9, F10, CZ, C3, C4, T3, T4, T5, T6, T9, T10, P3, P4, P9, P10, O1, O2 do sistema 10/20, visualizados na Figura 3 e dois eletrodos posicionados para aquisição do eletrooculograma (EOG).

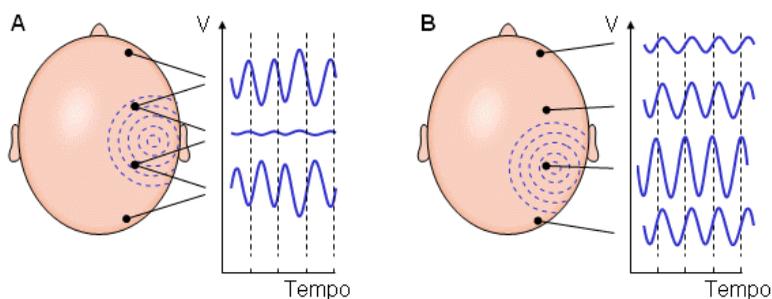


Figura 2 – Diferenças apresentadas pelo sinal de EEG quando é utilizada uma (A) montagem bipolar e (B) unipolar ou referencial. Na montagem bipolar o sinal é resultado da diferença de potencial entre pares de eletrodos enquanto que para a montagem unipolar o sinal é obtido pela diferença de potencial entre um eletrodo e um ponto referencial único (para todos os eletrodos da montagem).

Modificado de Malmivuo e Plonsey (1995).

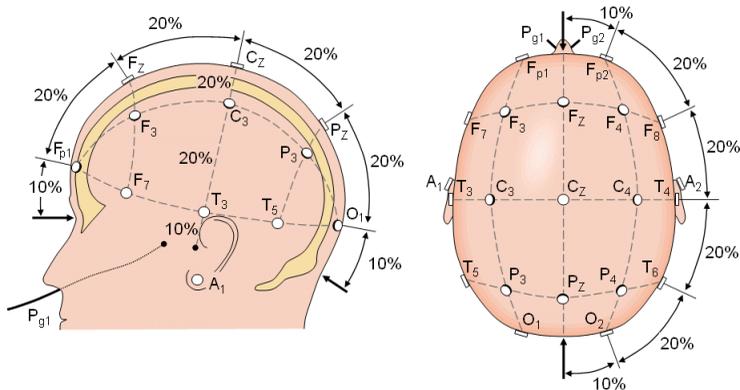


Figura 3 – Sistema 10/20 para o posicionamento de eletrodos.
Modificado de Malmivuo e Plonsey (1995).

Para as análises e simulações realizadas neste trabalho foram selecionados 600 segmentos de sinal com duração de 3 segundos, sendo que estes sinais foram escolhidos aleatoriamente dentre todos os registros de EEG disponíveis através de um algoritmo com uma única regra para a escolha dos sinais: os segmentos selecionados devem estar separados igualmente entre eventos epileptiformes e não-epileptiformes.

3.2 CÁLCULO DOS DESCRITORES MORFOLÓGICOS

A literatura sobre a detecção automática de eventos epileptiformes contém uma quantidade considerável de diferentes descritores morfológicos utilizados nas metodologias ou sistemas desenvolvidos.

Conforme descrito anteriormente, foi selecionado o conjunto de descritores propostos por Pereira (2003), que é composto por descritores já existentes na literatura e outros propostos por esta autora. Os elementos do conjunto extraídos da literatura são a amplitude máxima do evento, a duração do evento, o coeficiente de variação, o fator de crista e a entropia.

A amplitude máxima e duração do evento são consideradas na sua definição clássica. O coeficiente de variação, utilizado para medir a regularidade do sinal, é a razão entre o desvio padrão e o valor da média do sinal. O fator de crista é a diferença entre as amplitudes máxima e mínima, dividida pelo desvio-padrão (WEBBER *et al.*, 1994). Por sua

vez, a entropia, relatada em diversos estudos, como os de Quiroga (1998), Esteller (2000), Srinivasan *et al.* (2007) e Naghsh-Nilchi & Aghashahi (2010), fornece um valor para a complexidade do sinal em análise.

Os elementos do conjunto propostos por Pereira (2003) são descritores baseados nas características físicas ou morfológicas dos sinais em análise, levando em consideração as particularidades correspondentes ao tipo de montagem de eletrodos utilizada e com o objetivo de destacar ainda mais os eventos epileptiformes dos outros tipos de eventos presentes nos registros. Estes últimos, os eventos não-epileptiformes, estão representados, como mostra a Figura 4, nos sinais analisados por:

- (a) atividade de fundo normal do EEG;
- (b) ondas alfa;
- (c) piscadas;
- (d) ruídos (artefatos) de origem eletromiográfica (atividade muscular), interferência eletromagnética, entre outros.

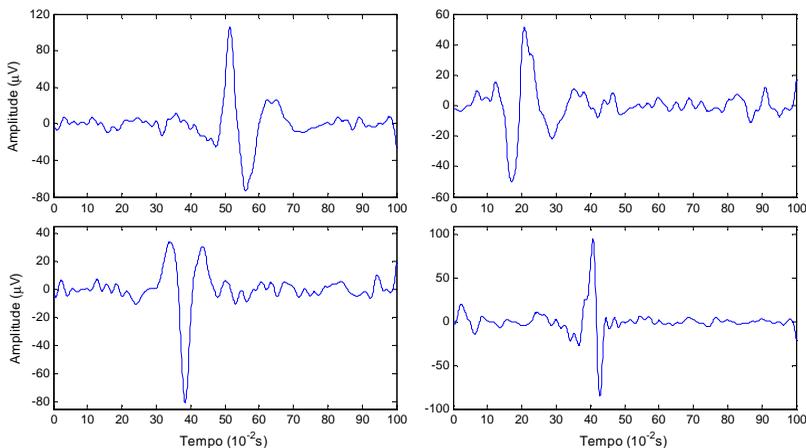


Figura 4 – Morfologia dos principais eventos não-epileptiformes encontrados nos registros de sinais de EEG em análise.

As particularidades relativas ao tipo de montagem referem-se ao fato de que observando os registros adquiridos pode-se notar que os eventos epileptiformes (espículas e/ou ondas agudas), devido à utilização da montagem bipolar (Figura 2), podem aparecer de quatro formas diferentes (Figura 5). Em outras palavras, por causa do tipo de

montagem as espículas e ondas agudas podem aparecer com picos de amplitude tanto eletronegativos como eletropositivos.

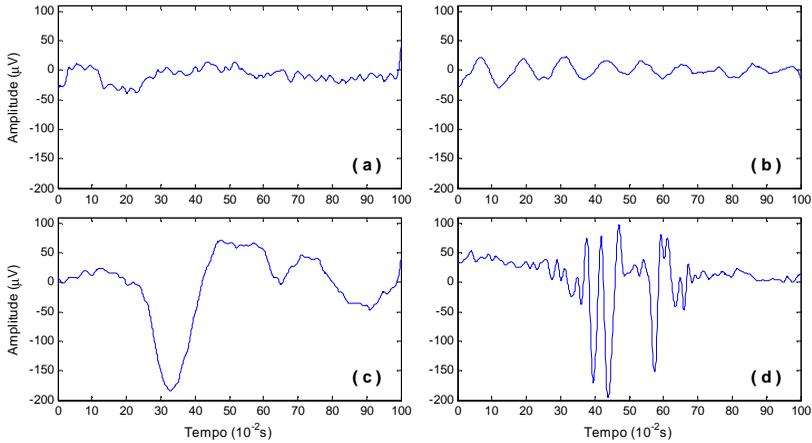


Figura 5 – Morfologia apresentada pelos eventos epileptiformes presentes nos registros em análise devido à utilização de montagem bipolar.

Os descritores morfológicos relacionados à amplitude e duração de um evento epileptiforme são, como demonstrado na Figura 6, os seguintes:

- amplitude máxima (A_{max});
- amplitude mínima (B_{min});
- intervalo de tempo entre A_{max} e B_{min} (T_{dif});
- diferença de amplitude entre A_{max} e B_{min} ($DifAB$).

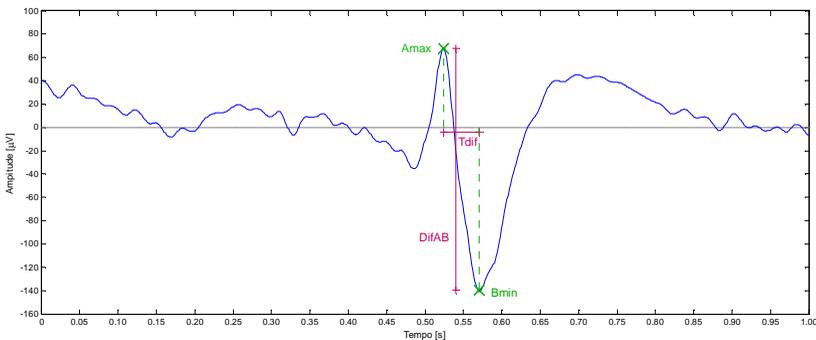


Figura 6 – Descritores morfológicos relacionados à amplitude e duração, apresentados por um evento.

Ainda em relação às amplitudes, dentro da época em análise, determina-se um segmento de 300ms centralizado no evento contido nessa época e, analisando este segmento, identificam-se os seguintes descritores:

- amplitude máxima (A_{max_pts});
- amplitude mínima (B_{min_pts});
- diferença de amplitude ($DifAB_pts$) entre os extremos de amplitude;
- intervalo de tempo ($Tdif_pts$) entre as amplitudes máxima e mínima.

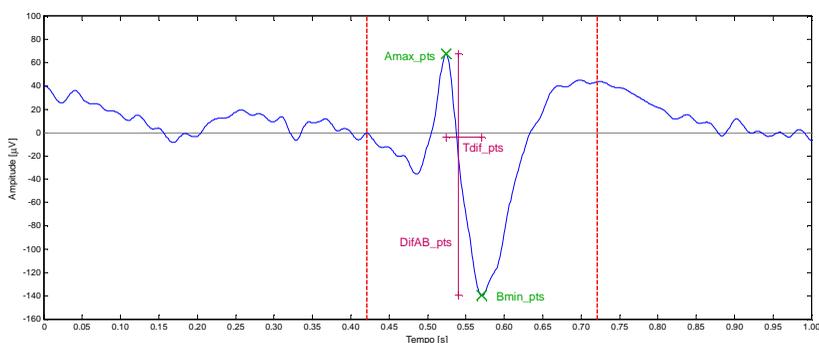


Figura 7 – Amplitude máxima (A_{max_pts}), amplitude mínima (B_{min_pts}), diferença entre as amplitudes extremas ($Tdif_pts$) e intervalo de tempo entre as amplitudes extremas ($DifAB_pts$), no segmento de 300ms.

Além dos descritores relacionados à amplitude e duração, o conjunto contém elementos referentes ao ângulo de vértice dos picos do evento (θ_p e θ_n). Os vértices dos picos são formados através das amplitudes máxima, mínima e dos pontos de cruzamento por zero adjacentes ao início e fim do evento. Derivados destes ângulos, como se mostra na Figura 8, estão os seguintes descritores:

- cateto oposto dos ângulos – representando a base dos triângulos formados com as respectivas retas de inclinação e amplitudes máximas (d_{pos} e d_{neg});
- ângulo do vértice do pico do evento analisado (θ);
- tangentes dos ângulos de picos (t_{gp} e t_{gn});
- retas de inclinação inicial e final do evento (trp e trn);
- base do evento ($dbase$).

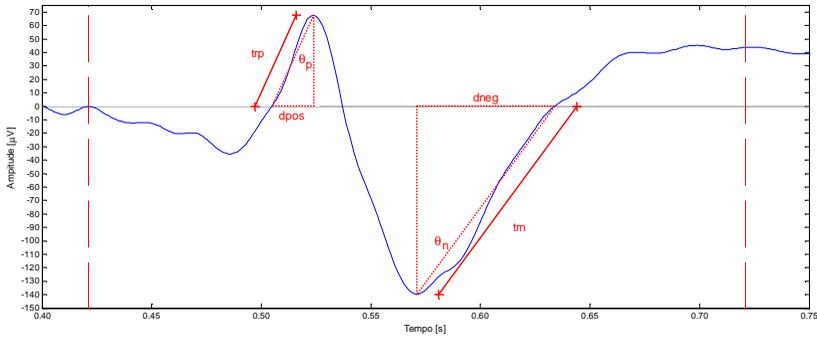


Figura 8 – Ângulo de vértice positivo e negativo de um evento epileptiforme, calculado a partir da amplitude máxima e mínima, respectivamente.

Pereira (2003) propôs, ainda, descritores baseados em relações de distâncias (intervalos de tempo) e diferenças de amplitude do sinal. Estes descritores são obtidos pela divisão do sinal contido na época sob análise em duas regiões (inicial e final) a partir do ponto de máxima amplitude absoluta do sinal. Uma vez determinadas estas regiões, têm-se, como demonstra a Figura 9, respectivamente os seguintes descritores:

- amplitude máxima e mínima da região inicial e final (A_{max_i} , B_{min_i} , A_{max_f} , B_{min_f});
- diferença de amplitude e intervalo de tempo entre A_{max} e A_{max_i} ($DifA_i$, tA_i) e entre A_{max} e A_{max_f} ($DifA_f$, tA_f);
- diferença de amplitude e intervalo de tempo entre B_{min} e B_{min_i} ($DifB_i$, tB_i) e entre B_{min} e B_{min_f} ($DifB_f$, tB_f).

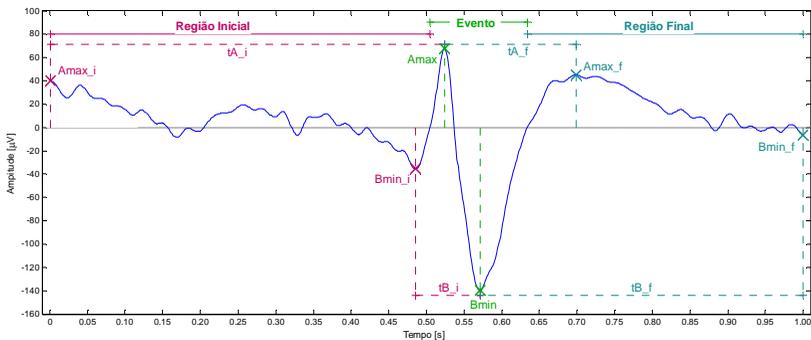


Figura 9 – Descritores para a diferenciação entre eventos epileptiformes e artefatos presentes nos sinais.

Completando o conjunto de descritores estão elementos com base nos índices estatísticos clássicos de média, desvio padrão e variância. Todos os descritores referentes aos índices estatísticos, o coeficiente de variação, o fator de crista e a entropia são calculados para a época sob análise (um segundo do sinal de EEG) e para o segmento de 300ms centrado no evento. Sendo assim, considerando todos os descritores apresentados anteriormente, o conjunto selecionado possui 45 descritores morfológicos que estão resumidamente descritos no quadro contido no Apêndice A.

Para realizar o cálculo dos descritores foi necessário o desenvolvimento de um algoritmo para otimizar este processo. O código foi escrito com base no conteúdo teórico dos descritores pertencentes ao conjunto escolhido e em oito segmentos de sinal, contendo exemplos dos principais eventos presentes nos registros disponíveis, que foram utilizados tanto para o desenvolvimento como para a realização de testes no algoritmo. No Apêndice B pode ser encontrado um fluxograma, e respectiva descrição, do funcionamento básico do código. Durante as etapas iniciais de desenvolvimento deste algoritmo, constatou-se a necessidade de realização de algumas etapas de processamento dos sinais de EEG para adequá-los às especificações teóricas dos descritores a serem calculados.

O processamento realizado foi, tão somente, uma operação de interpolação e filtragem do sinal. A filtragem do sinal foi em resposta à presença de grande quantidade de desvios da linha de base do sinal (frequência DC – 0 Hz) e para a eliminação de ruídos provocados por interferência da rede elétrica (60 Hz) e atenuação das atividades de baixa frequência presentes no sinal (até 5 Hz).

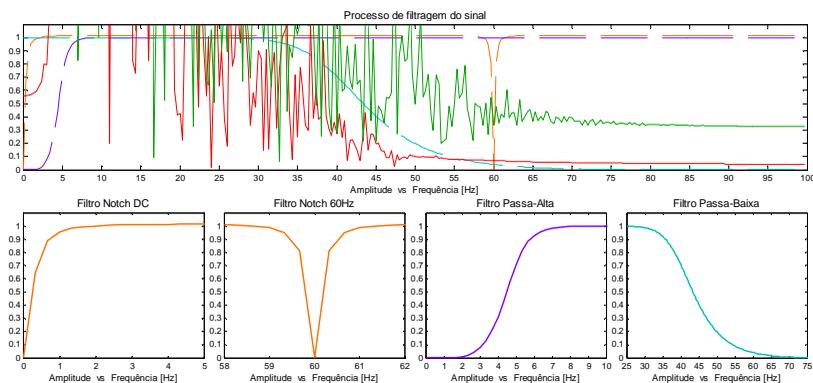


Figura 10 – Resposta em frequência dos filtros utilizados.

Os filtros utilizados, ilustrados na Figura 10, são dois filtros *notch* de 4ª ordem nas frequências 0 Hz e 60 Hz, um filtro *Butterworth* passa-alta de 5ª ordem com frequência de corte de 5 Hz e outro filtro *Butterworth* passa-baixa de 5ª ordem com frequência de corte de 40 Hz. A utilização do filtro *Butterworth* passa-baixa aconteceu pela constatação da presença prejudicial de frequências acima de 40 Hz durante o desenvolvimento do algoritmo de cálculo dos descritores.

A operação de interpolação do sinal foi realizada porque, com frequência de amostragem de apenas 100 Hz, uma época de sinal possuía uma quantidade muito pequena de amostras para representação dos eventos em análise.

A escolha do valor da frequência de interpolação foi feita com base na frequência que implicaria no sinal interpolado com as menores diferenças de amplitude em relação ao sinal original de 100 Hz. Esta análise foi realizada em segmentos de um segundo de sinal (tamanho de uma época) e para todo o banco de registros de EEG. Foram calculados dois parâmetros: amplitude máxima e amplitude mínima da época. Estes elementos foram escolhidos porque a grande maioria dos descritores pertencentes ao conjunto selecionado utiliza, de forma direta ou indireta, estes valores de amplitude para obtenção dos valores dos demais descritores.

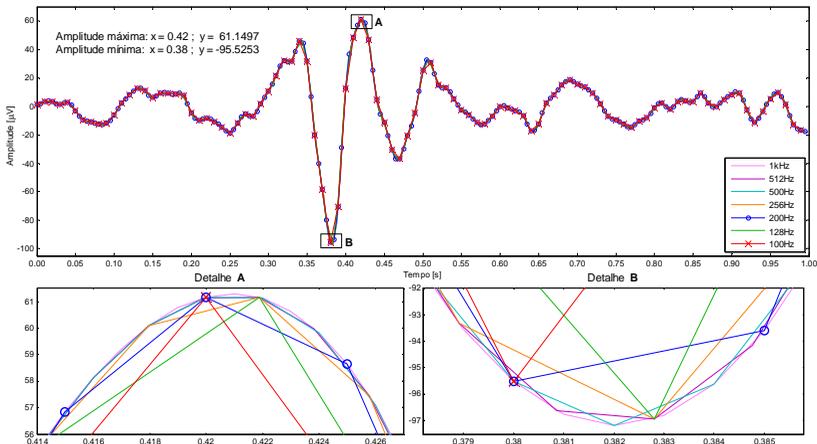


Figura 11 – Resultado da interpolação de um evento epileptiforme.

Os valores de amplitude encontrados para o sinal original e sinal interpolado, ilustrados na Figura 11, foram comparados e, a partir desta

comparação, calculou-se as diferenças de amplitude geradas pelas frequências de interpolação analisadas. O cálculo da diferença de amplitude (ΔAmp), tanto para as máximas positivas quanto para as negativas, foi realizado através da Eq. 5.

$$\Delta Amp = |Amplitude_{\text{sinial interpolado}} - Amplitude_{\text{sinial original}}| \quad \text{Eq. 5}$$

Analisou-se as diferenças de amplitude presentes para cada tipo de evento contido no banco de sinais (eventos epileptiformes, ondas alfa, atividades de fundo, artefatos, piscadas e eventos não-epileptiformes indefinidos) e para os sinais como um todo. Para essas análises foram observados os valores absolutos e médios das diferenças de amplitude, mas a escolha da frequência de interpolação foi baseada na análise da diferença de amplitude média ($\Delta Amp_{\text{média}}$), calculada através da Eq. 6.

$$\Delta Amp_{\text{média}} = \frac{1}{N} \cdot \sum_{i=1}^N \Delta Amp_i \quad \text{Eq. 6}$$

Onde N é a quantidade de sinais analisada e ΔAmp é o valor absoluto da diferença de amplitude.

Uma vez realizado o processamento do banco de registros de EEG e terminado o desenvolvimento do algoritmo, os descritores morfológicos foram calculados – um resumo dos valores encontrados pode ser observado no Apêndice C – e armazenados para serem utilizados na análise estatística.

3.3 AVALIAÇÃO DOS DESCRITORES

A avaliação dos descritores morfológicos foi realizada com o auxílio de um *software* para análise estatística: STATISTICA© versão 8.0.

A metodologia proposta para avaliação de descritores inicia-se com a análise da Matriz de Correlação entre os eventos de interesse para os descritores calculados. Para esta análise foi preparada uma tabela (matriz de dados) com todos os valores dos descritores devidamente identificados de acordo com o tipo de evento contido na época de sinal. Em outras palavras, os descritores foram dispostos em uma matriz

300x90 onde as linhas correspondem à quantidade de segmentos de sinal analisado para cada tipo de evento e as colunas correspondem aos 45 descritores para segmentos contendo eventos epileptiformes e os mesmos 45 descritores para segmentos contendo eventos não-epileptiformes.

Na sequência, com a matriz de dados para análise preparada, a análise da correlação foi realizada através da opção “*Correlation Matrices*” no menu “*Statistics*” do *software*. O próximo passo foi selecionar as duas listas de variáveis (descritores) entre as quais se deseja calcular a correlação e escolher um ou mais tipos de visualização para os valores calculados. Para esta pesquisa optou-se por visualização matricial dos valores da correlação. A matriz de correlação entre os descritores gerada pelo *software* pode ser observada na Tabela 2 e será analisada e comentada na próxima seção.

Por sua vez, a Análise de Componentes Principais (PCA) foi realizada com a utilização dos mesmos valores de descritores, mas com a tabela de dados iniciais organizada na forma de uma matriz 600x46.

Além dos 45 descritores (“*variables*”) para os 600 segmentos de sinal (“*cases*”) selecionados, foi necessária, em função dos requisitos do *software*, a adição de uma coluna extra contendo a identificação² do tipo de evento contido em cada segmento de sinal.

Para a continuação dos procedimentos para realização da PCA foi necessário realizar a seleção de algumas configurações iniciais. Primeiramente foi preciso selecionar as variáveis para análise (“*Variables for analysis*”) que, neste caso, correspondem aos 45 descritores morfológicos para todos os segmentos selecionados e a variável responsável pela identificação dos grupos em análise (“*Grouping variable*”), ou seja, a 46^a coluna adicionada à matriz de dados inicial.

Ainda em relação às variáveis para análise, não foram utilizadas variáveis suplementares (“*Supplementary variables*”), ou seja, segundo orientações da literatura relacionada ao software utilizado (StatSoft, 2008), optou-se por analisar todos os descritores como variáveis ativas. Além disso, todas as variáveis em análise (“*Variables with active cases*”) possuem apenas “*active cases*”, isto é, os valores de todos os segmentos foram analisados desde o início dos procedimentos realizados.

² A identificação utilizada foi “epilept” para os paroxismos e “nep” para os eventos não-epileptiformes.

Por fim, dois últimos parâmetros a serem ajustados são as configurações referentes ao ponto de partida da PCA, onde se optou por análise baseada na matriz de correlação (“*Analysis based on: Correlations*”) e em computar as variâncias com base na população total apresentada (“*Compute variances: as SS/N*”), ou seja, as variâncias são referentes à todos os segmentos apresentados na matriz de dados inicial.

Com o conjunto de parâmetros ajustados, deu-se sequência aos procedimentos computacionais para a obtenção dos resultados da análise que, de acordo com o objetivo desejado, podem ser analisados através de diversas modos conforme as opções disponibilizadas pelo *software*.

Para esta pesquisa o intuito é analisar a quantidade de fatores e sua correspondente qualidade de representação para que, a partir dos auto-vetores dos fatores escolhidos, seja possível realizar a redução da quantidade de elementos do conjunto de descritores. Para tanto, foi selecionada a visualização dos “*Eigenvalues*” e “*Eigenvectors*” que, respectivamente, indicam os valores referentes à importância de cada um dos fatores e os valores dos coeficientes dos auto-vetores.

Existem, de acordo com a literatura, duas formas de escolher as componentes principais a serem utilizadas: pela análise dos auto-valores, ou pela análise da representatividade. A escolha através dos auto-valores é feita selecionando-se as componentes principais que apresentarem auto-valor acima do valor unitário ($\lambda \geq 1,0$). No entanto, esta opção não garante a máxima representatividade das componentes selecionadas, pois, tomando a presente pesquisa como exemplo, seriam selecionadas 9 componentes principais uma vez que, como mostra a Tabela 1, a 10ª componente já apresenta auto-valor de 0,90193 mas o conjunto formado por essas explicaria apenas 85,12% da variância total dos dados analisados. Sendo assim, como nesta pesquisa o intuito é preservar ao máximo possível a alta variância, o critério de seleção das componentes principais adotado foi a análise dos valores da representatividade.

Os valores da representatividade analisados estão descritos na Tabela 1 como a porcentagem de variância acumulada e, a partir destes valores, foi escolhida a quantidade de fatores nos quais os descritores seriam transformados. Uma vez selecionada a quantidade de fatores, os auto-vetores correspondentes – cujos coeficientes podem ser observados em cada linha da Tabela 6 no Apêndice D, são utilizados para transformar o conjunto de descritores em um conjunto de fatores³.

³ Por uma questão de simplificação dos termos utilizados nesta pesquisa, a palavra fator será utilizada como sinônimo de componente principal.

Tabela 1 – Auto-valores e variâncias dos fatores obtidos com PCA do conjunto de descritores selecionado.

Fator	Auto-valor	% de variância	Auto-valor acumulado	% de variância acumulada
Fator 1	21,79024	48,42275	21,79024	48,42275
Fator 2	4,13002	9,17782	25,92026	57,60057
Fator 3	2,93583	6,52407	28,85609	64,12465
Fator 4	2,13756	4,75014	30,99365	68,87479
Fator 5	2,02890	4,50867	33,02255	73,38345
Fator 6	1,59491	3,54424	34,61746	76,92769
Fator 7	1,44701	3,21558	36,06447	80,14327
Fator 8	1,17421	2,60934	37,23868	82,75261
Fator 9	1,06651	2,37002	38,30518	85,12263
Fator 10	0,90193	2,00430	39,20712	87,12692
Fator 11	0,76935	1,70967	39,97647	88,83660
Fator 12	0,75851	1,68557	40,73498	90,52217
Fator 13	0,69001	1,53335	41,42498	92,05552
Fator 14	0,56558	1,25684	41,99056	93,31236
Fator 15	0,50030	1,11178	42,49086	94,42413
Fator 16	0,45517	1,01149	42,94603	95,43563
Fator 17	0,37814	0,84032	43,32417	96,27594
Fator 18	0,31702	0,70449	43,64119	96,98043
Fator 19	0,25531	0,56736	43,89651	97,54780
Fator 20	0,23779	0,52843	44,13430	98,07623
Fator 21	0,20372	0,45271	44,33802	98,52893
Fator 22	0,12179	0,27065	44,45981	98,79958
Fator 23	0,10592	0,23538	44,56573	99,03496
Fator 24	0,09865	0,21923	44,66439	99,25419
Fator 25	0,07781	0,17290	44,74219	99,42709
Fator 26	0,07391	0,16424	44,81610	99,59133
Fator 27	0,05212	0,11582	44,86822	99,70715
Fator 28	0,03744	0,08320	44,90566	99,79036
Fator 29	0,02878	0,06396	44,93444	99,85432
Fator 30	0,02641	0,05868	44,96085	99,91300
Fator 31	0,01847	0,04104	44,97932	99,95404
Fator 32	0,01308	0,02907	44,99240	99,98311
Fator 33	0,00530	0,01179	44,99770	99,99489
Fator 34	0,00109	0,00242	44,99879	99,99731
Fator 35	0,00088	0,00196	44,99967	99,99927
Fator 36	0,00015	0,00034	44,99983	99,99962
Fator 37	0,00013	0,00029	44,99996	99,99991
Fator 38	0,00003	0,00007	44,99999	99,99998
Fator 39	0,00001	0,00002	45,00000	100,00000

4 RESULTADOS

Os resultados obtidos com a análise das diferenças de amplitude geradas pelo processo de interpolação nos valores das amplitudes máximas e mínimas dos sinais podem ser observados, respectivamente, na Figura 12 e na Figura 13. Observando os gráficos, constata-se que os valores médios dessas diferenças, em termos da porcentagem que elas representam em relação ao sinal original, para cada tipo de evento apresentado pelos registros de EEG não passam de 6%. Analisando o tipo de evento de interesse, os eventos epileptiformes, observa-se que a máxima diferença de amplitude para a amplitude mínima ultrapassa ligeiramente os 2% e para a amplitude máxima esse valor não atinge 2%.

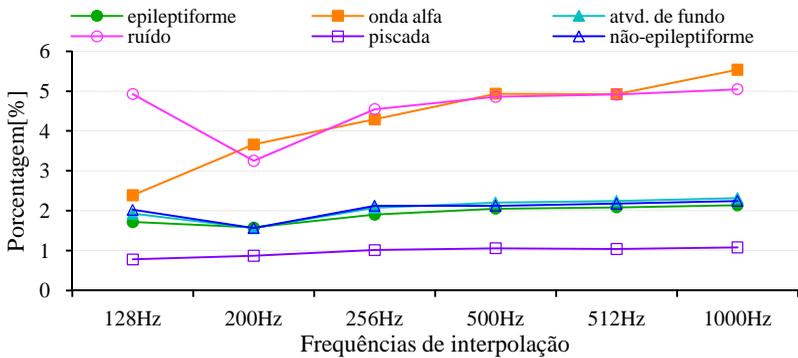


Figura 12 – Valores médios das diferenças das amplitudes mínimas.

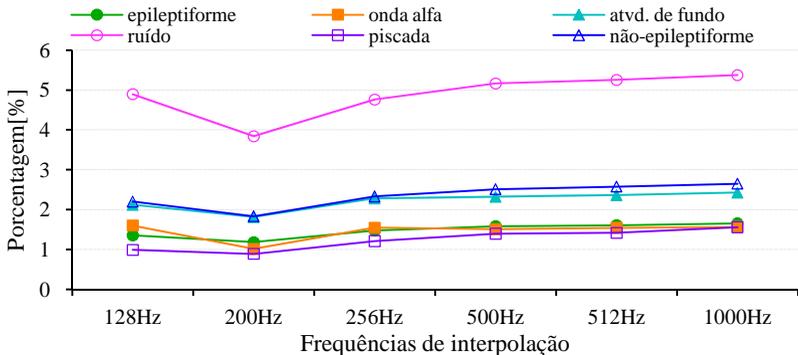


Figura 13 – Valores médios das diferenças das amplitudes máximas.

Em termos gerais, conforme ilustrado na Figura 14, o valor médio das diferenças de amplitude geradas pela operação interpolação, considerando todos os registros utilizados sem distinção de tipo de evento presente no sinal, é relativamente baixa e não ultrapassa valores de 2,45% tanto para amplitudes máximas quanto para amplitudes mínimas.

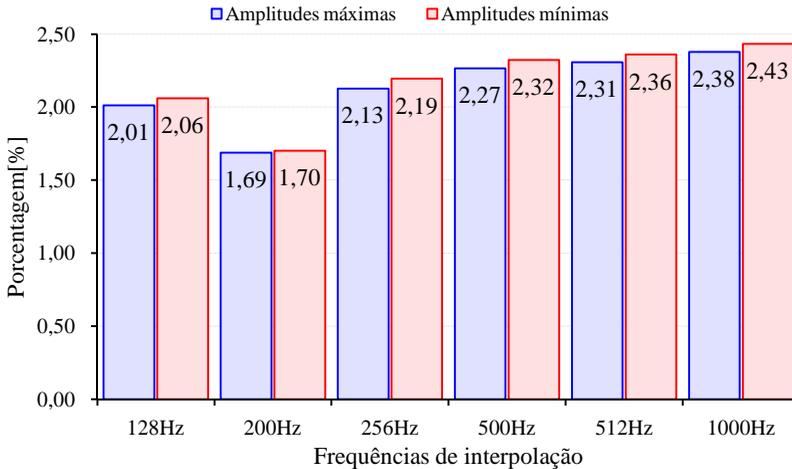


Figura 14 – Valores médios da distorção gerada pelo processo de interpolação.

Sendo assim, após análise dos resultados obtidos optou-se pela utilização de interpolação do sinal para uma frequência de 200Hz, uma vez que esta frequência apresenta valores de distorção do valor da amplitude máxima e mínima de 1,69% e 1,71%, respectivamente.

O desenvolvimento do algoritmo para cálculo dos descritores foi baseado em um exemplo de cada tipo de evento analisado. Com o código finalizado, estes exemplos de sinais foram também utilizados na inspeção de todos os cálculos realizados. No entanto, para garantir o correto funcionamento do código, fez-se necessária a realização de dois testes básicos aplicados a 600 segmentos de sinal.

O primeiro teste constituiu-se na conferência do funcionamento do tratamento de bordas aplicado aos sinais e o segundo na conferência dos valores calculados. Neste último teste foram conferidos os valores da amplitude máxima, mínima e duração dos eventos.

A análise dos valores tão somente de três descritores justifica-se pelo fato de serem os três cálculos básicos, e fundamentais, realizados

no início do algoritmo e que servem de base para o cálculo dos demais descritores morfológicos. A conferência dos descritores foi feita através da comparação entre os valores obtidos através do algoritmo de cálculo dos descritores e os valores indicados nas marcações dos registros de EEG utilizados nesta pesquisa, realizadas pelo sistema de aquisição dos registros e por três neurologistas.

Para auxiliar em ambos os testes foram elaborados outros dois algoritmos com o intuito de facilitar a verificação dos procedimentos implementados no algoritmo para o cálculo dos descritores. Após a realização das rotinas de teste constatou-se o correto funcionamento dos procedimentos implantados, uma vez que houve 100% de concordância entre os valores de amplitude e duração calculados e as marcações dos registros de EEG. E ainda, o tratamento de bordas aplicado, descrito no Apêndice B, pode ser validado após verificação do funcionamento da lógica desenvolvida.

Quanto à metodologia proposta, inicialmente foram analisados os resultados da matriz de correlação apresentada na Tabela 2, sendo excluídos do conjunto os descritores que apresentassem correlação, positiva ou negativa, superior a 35%. Para isso, nesta pesquisa os valores obtidos foram destacados⁴ em cinco faixas de acordo com a intensidade de correlação apresentada:

- -0,05 e 0,05: valores ótimos – correlação com valor contido no intervalo [-0,05 ; 0,05];
- ± (0,05 e 0,1): valores bons – correlação com valor contido no intervalo]-0,05 ; -0,10] ou]0,05 ; 0,10];
- ± (0,10 e 0,20): valores regulares – correlação com valor contido no intervalo]-0,10 ; -0,20] ou]0,10 ; 0,20];
- ± (0,20 e 0,30): valores altos – correlação com valor contido no intervalo]-0,20 ; -0,30] ou]0,20 ; 0,30];
- ± (0,30 e 0,35): valores críticos – correlação com valor contido no intervalo]-0,30 ; -0,35[ou]0,30 ; 0,35[;
- ± (0,35 e 1,00): valores excluídos – correlação com valor contido no intervalo [-0,35 ; -1,00] ou [0,35 ; 1,00].

⁴ Os valores de correlação alta e crítica encontram-se destacados na Tabela 2 através de formatação do estilo da fonte em **italico** e **negrito**, respectivamente.

Tabela 2 – Matriz de correlação entre eventos epileptiformes (EPL) e não-epileptiformes (NEP) para os descritores morfológicos selecionados.

EPL \ NEP	Amax	Bmin	Tdif	DifAB	Amax_pts	Bmin_pts	Tdif_pts	DifAB_pts	T
Amax	-0,164	0,148	0,087	-0,160	-0,167	0,151	0,117	-0,164	0,174
Bmin	<i>0,246</i>	<i>-0,212</i>	-0,044	<i>0,235</i>	<i>0,247</i>	<i>-0,225</i>	-0,074	<i>0,242</i>	-0,117
Tdif	0,030	-0,016	-0,024	0,024	0,038	-0,014	0,052	0,026	0,063
DifAB	<i>-0,245</i>	<i>0,215</i>	0,077	<i>-0,236</i>	<i>-0,248</i>	<i>0,224</i>	0,113	<i>-0,243</i>	0,172
Amax_pts	-0,160	0,148	0,073	-0,158	-0,164	0,151	0,114	-0,162	0,169
Bmin_pts	<i>0,235</i>	<i>-0,201</i>	-0,046	<i>0,224</i>	<i>0,234</i>	<i>-0,212</i>	-0,085	<i>0,230</i>	-0,113
Tdif_pts	0,181	-0,143	-0,063	0,166	0,191	-0,149	-0,025	0,175	-0,059
DifAB_pts	<i>-0,227</i>	<i>0,200</i>	0,068	<i>-0,220</i>	<i>-0,229</i>	<i>0,209</i>	0,114	<i>-0,225</i>	0,161
T	<i>0,217</i>	<i>-0,235</i>	-0,096	<i>0,232</i>	<i>0,216</i>	<i>-0,221</i>	-0,064	<i>0,225</i>	-0,108
dbase	<i>0,234</i>	-0,185	-0,040	<i>0,215</i>	<i>0,244</i>	<i>-0,203</i>	-0,045	<i>0,230</i>	-0,045
dpos	0,066	-0,032	-0,059	0,050	0,080	-0,042	0,012	0,063	0,021
dneg	<i>0,272</i>	<i>-0,267</i>	-0,036	<i>0,277</i>	<i>0,265</i>	<i>-0,255</i>	-0,066	<i>0,268</i>	-0,080
trp1	-0,159	0,148	0,072	-0,158	-0,162	0,151	0,117	-0,161	0,174
trn1	<i>-0,232</i>	0,198	0,047	<i>-0,221</i>	<i>-0,231</i>	<i>0,210</i>	0,085	<i>-0,227</i>	0,113
tgp	0,080	-0,055	0,009	0,069	0,068	-0,063	-0,001	0,067	-0,062
tgn	<i>0,238</i>	-0,180	0,091	<i>0,214</i>	<i>0,250</i>	<i>-0,206</i>	-0,112	<i>0,234</i>	-0,149
ang_pos	0,148	-0,109	-0,076	0,132	0,164	-0,130	-0,041	0,151	-0,105
ang_neg	<i>0,292</i>	<i>-0,236</i>	0,003	<i>0,271</i>	<i>0,299</i>	<i>-0,251</i>	-0,128	<i>0,283</i>	-0,162
ang_pico	<i>0,284</i>	<i>-0,221</i>	-0,036	<i>0,259</i>	<i>0,296</i>	<i>-0,255</i>	-0,123	<i>0,283</i>	-0,169
Amax_i	-0,140	0,099	-0,062	-0,122	-0,133	0,104	0,093	-0,122	0,173
Bmin_i	0,181	-0,149	-0,049	0,170	0,180	-0,155	-0,134	0,172	<i>-0,255</i>
DifA_i	-0,087	0,101	0,124	-0,097	-0,096	0,101	0,067	-0,102	0,075
tA_i	-0,091	0,076	-0,079	-0,086	-0,089	0,063	0,085	-0,078	<i>0,201</i>
DifB_i	0,146	-0,128	-0,021	0,140	0,146	-0,136	-0,017	0,145	0,020
tB_i	-0,127	0,106	-0,034	-0,119	-0,127	0,116	0,058	-0,125	0,101
Amax_f	-0,096	0,110	0,044	-0,106	-0,093	0,113	0,086	-0,106	0,163
Bmin_f	0,094	-0,081	0,005	0,090	0,091	-0,089	-0,056	0,093	-0,180
DifA_f	-0,127	0,106	0,058	-0,120	-0,134	0,108	0,081	-0,124	0,101
tA_f	0,134	-0,049	-0,018	0,094	0,144	-0,075	0,078	0,112	0,118
DifB_f	<i>0,221</i>	-0,189	-0,055	<i>0,211</i>	<i>0,221</i>	-0,198	-0,070	<i>0,216</i>	-0,041
tB_f	0,081	-0,030	-0,023	0,057	0,087	-0,068	0,028	0,080	0,088
desvio	-0,190	0,159	0,060	-0,179	-0,191	0,168	0,080	-0,184	0,121
desvioC	-0,193	0,164	0,030	-0,183	-0,191	0,174	0,106	-0,187	0,193
media	-0,163	0,131	0,057	-0,151	-0,163	0,141	0,055	-0,156	0,098
mediaC	-0,149	0,128	-0,011	-0,142	-0,148	0,138	0,107	-0,147	<i>0,227</i>
coef	<i>-0,223</i>	<i>0,207</i>	0,062	<i>-0,221</i>	<i>-0,225</i>	<i>0,206</i>	0,141	<i>-0,221</i>	0,151
coefC	<i>-0,243</i>	0,196	0,130	<i>-0,225</i>	<i>-0,238</i>	<i>0,206</i>	0,044	<i>-0,228</i>	-0,007
vari	-0,178	0,160	0,050	-0,173	-0,176	0,166	0,077	-0,176	0,093
variC	-0,175	0,152	0,049	-0,168	-0,170	0,158	0,070	-0,169	0,107
CF	<i>-0,244</i>	<i>0,233</i>	0,086	<i>-0,245</i>	<i>-0,247</i>	<i>0,225</i>	0,130	<i>-0,243</i>	0,194
CFC	<i>-0,250</i>	<i>0,217</i>	0,141	<i>-0,240</i>	<i>-0,261</i>	<i>0,223</i>	0,059	<i>-0,249</i>	0,044
entrop_logC	-0,125	0,118	-0,049	-0,125	-0,130	0,132	0,122	-0,134	<i>0,270</i>
entrop_norC	-0,152	0,131	-0,006	-0,146	-0,151	0,140	0,104	-0,150	<i>0,219</i>
entrop_log	-0,181	0,119	0,022	-0,154	-0,183	0,143	0,009	-0,168	0,042
entrop_nor	-0,165	0,134	0,058	-0,153	-0,165	0,143	0,054	-0,158	0,095

Tabela 2 – Matriz de correlação entre eventos epileptiformes (EPL) e não-epileptiformes (NEP) para os descritores selecionados. (continuação)

EPL \ NEP	dbase	dpos	dneg	trp	trn	tgp	tn	ang_pos	ang_neg
Amax	0,060	0,059	0,077	-0,168	-0,150	0,009	-0,060	0,171	0,145
Bmin	-0,063	-0,042	-0,068	0,244	0,224	0,011	0,017	-0,225	-0,255
Tdif	0,087	0,009	0,115	0,044	0,014	-0,146	0,001	-0,072	0,042
DifAB	0,073	0,060	0,086	-0,246	-0,223	-0,002	-0,045	0,236	0,239
Amax_pts	0,053	0,048	0,076	-0,166	-0,151	0,009	-0,061	0,164	0,144
Bmin_pts	-0,057	-0,031	-0,071	0,233	0,212	0,012	0,016	-0,200	-0,234
Tdif_pts	0,040	-0,012	-0,005	0,194	0,148	-0,029	0,000	-0,151	-0,121
DifAB_pts	0,063	0,045	0,084	-0,229	-0,209	-0,002	-0,044	0,209	0,218
T	0,000	-0,032	-0,012	0,222	0,220	-0,076	0,001	-0,183	-0,151
dbase	0,022	0,039	-0,028	0,245	0,202	-0,019	0,009	-0,192	-0,175
dpos	0,090	0,065	0,029	0,085	0,043	0,005	0,033	-0,042	0,002
dneg	-0,028	-0,025	-0,012	0,266	0,254	-0,043	-0,026	-0,210	-0,213
trp1	0,057	0,053	0,077	-0,163	-0,151	0,011	-0,061	0,163	0,143
trn1	0,056	0,029	0,073	-0,230	-0,209	-0,013	-0,016	0,197	0,232
tgp	-0,003	-0,003	-0,051	0,067	0,062	-0,002	0,004	-0,044	-0,065
tn	-0,083	-0,070	-0,054	0,243	0,205	-0,009	0,018	-0,231	-0,192
ang_pos	-0,013	-0,046	-0,039	0,159	0,129	-0,005	0,037	-0,180	-0,137
ang_neg	-0,090	-0,084	-0,057	0,292	0,251	-0,008	0,022	-0,269	-0,240
ang_pico	-0,075	-0,054	-0,089	0,291	0,254	-0,025	0,023	-0,286	-0,262
Amax_i	0,083	0,007	0,167	-0,134	-0,103	-0,018	0,035	0,057	0,115
Bmin_i	-0,076	-0,050	-0,186	0,181	0,153	-0,023	0,006	-0,123	-0,138
DifA_i	0,005	0,049	-0,026	-0,097	-0,102	0,022	-0,092	0,147	0,086
tA_i	0,060	0,051	0,174	-0,085	-0,061	0,017	-0,002	0,035	0,070
DifB_i	-0,019	-0,005	0,026	0,143	0,137	0,025	0,013	-0,140	-0,167
tB_i	0,019	0,031	0,132	-0,124	-0,113	-0,065	0,043	0,039	0,141
Amax_f	0,057	0,042	0,133	-0,089	-0,112	-0,025	-0,016	0,096	0,169
Bmin_f	-0,118	-0,102	-0,141	0,081	0,085	0,014	-0,045	-0,125	-0,138
DifA_f	0,029	0,031	0,013	-0,137	-0,109	0,024	-0,060	0,131	0,070
tA_f	0,130	0,139	0,002	0,151	0,077	-0,009	0,037	-0,048	-0,079
DifB_f	-0,008	0,015	-0,012	0,225	0,199	0,007	0,040	-0,166	-0,198
tB_f	-0,048	-0,016	0,045	0,080	0,070	-0,005	0,016	-0,118	-0,068
desvio	0,063	0,022	0,065	-0,191	-0,168	-0,015	-0,037	0,161	0,176
desvioC	0,093	0,043	0,138	-0,190	-0,172	-0,024	-0,026	0,155	0,196
media	0,062	0,011	0,060	-0,163	-0,141	-0,024	-0,036	0,130	0,151
mediaC	0,120	0,064	0,182	-0,144	-0,135	-0,035	-0,008	0,118	0,179
coef	0,006	0,067	0,022	-0,228	-0,206	0,054	-0,008	0,236	0,176
coefC	-0,034	-0,009	-0,079	-0,241	-0,209	0,034	-0,070	0,236	0,161
vari	0,032	-0,010	0,046	-0,182	-0,166	-0,003	-0,026	0,130	0,155
variC	0,038	-0,019	0,077	-0,175	-0,158	-0,018	-0,024	0,109	0,149
CF	0,009	0,095	0,079	-0,245	-0,224	0,048	-0,034	0,247	0,208
CFC	-0,020	0,059	-0,064	-0,258	-0,224	0,046	-0,055	0,290	0,201
entrop_logC	0,171	0,146	0,214	-0,116	-0,127	-0,044	0,016	0,152	0,216
entrop_norC	0,114	0,057	0,175	-0,148	-0,138	-0,035	-0,009	0,117	0,178
entrop_log	0,077	0,013	0,058	-0,174	-0,142	-0,061	-0,020	0,156	0,184
entrop_nor	0,058	0,007	0,057	-0,165	-0,143	-0,023	-0,035	0,129	0,150

Tabela 2 – Matriz de correlação entre eventos epileptiformes (EPL) e não-epileptiformes (NEP) para os descritores selecionados. (continuação)

EPL \ NEP	ang pico	Amax i	Bmin i	DifA i	tA_i	DifB i	tB_i	Amax f	Bmin f
Amax	0,146	-0,173	0,170	-0,069	-0,021	0,070	-0,025	-0,158	0,171
Bmin	-0,247	0,207	-0,212	0,167	0,024	-0,149	0,017	0,194	-0,166
Tdif	0,005	-0,018	-0,008	0,095	0,061	-0,014	-0,108	0,060	-0,031
DifAB	0,235	-0,227	0,228	-0,142	-0,026	0,131	-0,025	-0,210	0,200
Amax_pts	0,143	-0,177	0,174	-0,057	-0,034	0,067	-0,022	-0,157	0,166
Bmin_pts	-0,224	0,198	-0,203	0,157	0,038	-0,137	0,027	0,196	-0,160
Tdif_pts	-0,086	0,137	-0,153	0,163	-0,096	-0,086	-0,074	0,132	-0,130
DifAB_pts	0,211	-0,215	0,216	-0,124	-0,041	0,118	-0,028	-0,203	0,186
T	-0,143	0,193	-0,185	0,131	-0,092	-0,171	-0,030	0,217	-0,242
dbase	-0,170	0,223	-0,222	0,142	-0,083	-0,101	-0,028	0,189	-0,178
dpos	0,012	0,099	-0,082	0,011	-0,044	0,017	-0,018	0,046	-0,068
dneg	-0,222	0,193	-0,180	0,222	-0,076	-0,233	-0,023	0,254	-0,251
trp1	0,143	-0,174	0,171	-0,057	-0,037	0,068	-0,023	-0,156	0,164
trn1	0,222	-0,196	0,202	-0,155	-0,037	0,134	-0,027	-0,191	0,156
tgp	-0,042	0,063	-0,057	0,037	0,026	-0,045	0,032	0,069	-0,079
tgn	-0,223	0,233	-0,184	0,138	0,017	-0,147	0,101	0,246	-0,214
ang_pos	-0,123	0,190	-0,173	0,040	-0,019	-0,033	-0,005	0,131	-0,145
ang_neg	-0,266	0,257	-0,223	0,194	-0,002	-0,181	0,052	0,281	-0,251
ang_pico	-0,265	0,287	-0,278	0,149	-0,042	-0,128	0,024	0,240	-0,224
Amax_i	0,094	-0,111	0,113	-0,091	-0,050	0,053	-0,021	-0,085	0,100
Bmin_i	-0,115	0,194	-0,186	0,062	-0,046	-0,061	-0,006	0,149	-0,165
DifA_i	0,099	-0,126	0,121	-0,004	-0,004	0,040	-0,011	-0,121	0,121
tA_i	0,021	-0,101	0,092	-0,024	-0,003	0,007	-0,010	-0,082	0,083
DifB_i	-0,170	0,101	-0,110	0,129	0,063	-0,109	0,031	0,122	-0,077
tB_i	0,059	-0,099	0,123	-0,097	0,064	0,063	-0,078	-0,118	0,102
Amax_f	0,100	-0,121	0,107	-0,004	0,037	0,074	-0,042	-0,092	0,097
Bmin_f	-0,138	0,098	-0,086	0,033	-0,073	-0,056	-0,081	0,090	-0,094
DifA_f	0,106	-0,133	0,137	-0,062	-0,058	0,034	-0,002	-0,127	0,133
tA_f	-0,038	0,138	-0,103	0,074	-0,042	-0,016	0,010	0,123	-0,063
DifB_f	-0,188	0,177	-0,189	0,162	0,078	-0,128	0,070	0,179	-0,136
tB_f	-0,117	0,059	-0,080	0,078	0,034	-0,028	0,014	0,051	-0,004
desvio	0,181	-0,181	0,176	-0,101	-0,040	0,092	-0,022	-0,171	0,144
desvioC	0,181	-0,190	0,185	-0,089	-0,027	0,092	-0,031	-0,172	0,161
media	0,159	-0,160	0,150	-0,079	-0,035	0,075	-0,016	-0,150	0,121
mediaC	0,154	-0,165	0,157	-0,045	-0,004	0,062	-0,023	-0,141	0,147
coef	0,166	-0,175	0,203	-0,172	-0,029	0,126	-0,030	-0,186	0,197
coefC	0,194	-0,174	0,181	-0,197	-0,087	0,151	-0,067	-0,181	0,133
vari	0,153	-0,165	0,166	-0,096	-0,046	0,099	-0,021	-0,156	0,135
variC	0,138	-0,163	0,158	-0,088	-0,039	0,095	-0,023	-0,150	0,133
CF	0,165	-0,220	0,230	-0,150	-0,016	0,130	-0,036	-0,221	0,259
CFC	0,213	-0,206	0,212	-0,195	-0,012	0,146	-0,006	-0,196	0,210
entrop_logC	0,190	-0,146	0,151	-0,037	0,027	0,058	0,005	-0,133	0,144
entrop_norC	0,153	-0,166	0,158	-0,049	-0,006	0,065	-0,024	-0,143	0,147
entrop_log	0,214	-0,144	0,132	-0,139	0,026	0,098	0,013	-0,139	0,093
entrop_nor	0,158	-0,160	0,151	-0,082	-0,035	0,078	-0,015	-0,151	0,123

Tabela 2 – Matriz de correlação entre eventos epileptiformes (EPL) e não-epileptiformes (NEP) para os descritores selecionados. (continuação)

EPL \ NEP	DifA_f	tA_f	DifB_f	tB_f	desvio	desvio C	media	media C	coef
Amax	-0,103	0,020	0,047	0,000	-0,139	-0,163	-0,129	-0,166	-0,154
Bmin	0,205	-0,090	-0,171	-0,052	0,226	0,233	0,218	0,226	0,150
Tdif	-0,009	0,008	0,013	0,061	0,041	0,042	0,049	0,036	-0,023
DifAB	-0,184	0,066	0,132	0,031	-0,219	-0,237	-0,207	-0,234	-0,180
Amax_pts	-0,098	0,006	0,054	0,003	-0,140	-0,162	-0,130	-0,164	-0,148
Bmin_pts	0,178	-0,083	-0,158	-0,037	0,216	0,224	0,209	0,218	0,127
Tdif_pts	0,183	-0,026	-0,092	0,017	0,171	0,174	0,171	0,180	0,080
DifAB_pts	-0,159	0,052	0,123	0,023	-0,205	-0,222	-0,195	-0,220	-0,157
T	0,116	0,017	-0,079	-0,046	0,215	0,231	0,209	0,231	0,108
dbase	0,206	-0,046	-0,123	0,009	0,226	0,244	0,223	0,255	0,049
dpos	0,089	0,077	0,009	0,083	0,068	0,085	0,068	0,102	-0,028
dneg	0,160	-0,073	-0,123	-0,056	0,268	0,275	0,267	0,269	0,056
trp1	-0,095	0,011	0,055	0,009	-0,137	-0,158	-0,127	-0,159	-0,153
trn1	-0,178	0,083	0,159	0,035	-0,213	-0,220	-0,206	-0,215	-0,127
tgp	0,035	-0,053	-0,012	-0,058	0,060	0,072	0,058	0,079	0,051
tgn	0,140	-0,058	-0,087	-0,078	0,220	0,254	0,218	0,267	0,101
ang_pos	0,133	0,064	-0,045	0,020	0,137	0,169	0,132	0,188	0,110
ang_neg	0,186	-0,064	-0,118	-0,080	0,265	0,298	0,260	0,306	0,139
ang_pico	0,235	-0,034	-0,154	-0,026	0,258	0,293	0,248	0,310	0,172
Amax_i	-0,136	-0,025	0,053	-0,004	-0,090	-0,106	-0,075	-0,103	-0,192
Bmin_i	0,138	-0,011	-0,061	-0,071	0,135	0,157	0,121	0,156	0,164
DifA_i	-0,020	0,023	0,026	0,006	-0,098	-0,112	-0,097	-0,116	-0,039
tA_i	-0,057	0,087	0,006	0,078	-0,051	-0,067	-0,044	-0,072	-0,079
DifB_i	0,110	-0,080	-0,130	0,000	0,150	0,147	0,151	0,142	0,043
tB_i	-0,081	0,056	0,069	0,093	-0,117	-0,129	-0,113	-0,133	-0,033
Amax_f	-0,052	0,007	0,071	0,062	-0,090	-0,103	-0,083	-0,105	-0,086
Bmin_f	0,052	-0,011	-0,035	-0,021	0,067	0,088	0,056	0,088	0,149
DifA_f	-0,082	0,002	0,022	-0,031	-0,108	-0,126	-0,101	-0,127	-0,120
tA_f	0,106	-0,013	-0,049	-0,004	0,132	0,128	0,142	0,127	0,001
DifB_f	0,177	-0,089	-0,162	-0,032	0,212	0,212	0,210	0,205	0,072
tB_f	0,094	-0,013	-0,104	-0,020	0,081	0,081	0,085	0,085	0,039
desvio	-0,130	0,029	0,105	0,001	-0,166	-0,181	-0,157	-0,179	-0,135
desvioC	-0,129	0,039	0,095	0,033	-0,161	-0,181	-0,148	-0,180	-0,172
media	-0,106	0,014	0,088	-0,015	-0,138	-0,152	-0,129	-0,151	-0,119
mediaC	-0,090	0,009	0,054	0,023	-0,117	-0,144	-0,103	-0,148	-0,168
coef	-0,173	0,090	0,106	0,088	-0,212	-0,226	-0,210	-0,227	-0,117
coefC	-0,205	0,122	0,180	0,088	-0,226	-0,215	-0,223	-0,201	-0,129
vari	-0,122	0,035	0,112	-0,013	-0,165	-0,172	-0,159	-0,165	-0,102
variC	-0,119	0,040	0,102	-0,004	-0,153	-0,161	-0,145	-0,154	-0,116
CF	-0,169	0,093	0,067	0,082	-0,226	-0,251	-0,222	-0,257	-0,121
CFC	-0,229	0,094	0,118	0,035	-0,242	-0,249	-0,242	-0,248	-0,103
entrop_logC	-0,066	0,016	0,047	0,047	-0,099	-0,135	-0,085	-0,145	-0,162
entrop_norC	-0,094	0,011	0,058	0,021	-0,121	-0,146	-0,107	-0,149	-0,165
entrop_log	-0,159	0,034	0,123	0,032	-0,157	-0,162	-0,152	-0,165	-0,059
entrop_nor	-0,107	0,015	0,090	-0,017	-0,141	-0,154	-0,132	-0,153	-0,116

Tabela 2 – Matriz de correlação entre eventos epileptiformes (EPL) e não-epileptiformes (NEP) para os descritores selecionados. (continuação)

EPL \ NEP	coefC	vari	variC	CF	CFC	entrop_logC	entrop_norC	entrop_log	entrop_nor
Amax	-0,082	-0,119	-0,135	-0,159	-0,115	-0,147	-0,165	-0,124	-0,129
Bmin	0,194	0,167	0,178	0,135	0,166	0,226	0,224	0,213	0,214
Tdif	0,096	0,007	0,017	-0,004	-0,007	0,037	0,035	0,045	0,046
DifAB	-0,166	-0,171	-0,187	-0,174	-0,168	-0,223	-0,232	-0,202	-0,205
Amax_pts	-0,088	-0,119	-0,135	-0,146	-0,111	-0,145	-0,164	-0,126	-0,130
Bmin_pts	0,174	0,164	0,176	0,117	0,151	0,209	0,217	0,205	0,206
Tdif_pts	0,078	0,125	0,131	0,103	0,097	0,161	0,178	0,148	0,170
DifAB_pts	-0,151	-0,162	-0,179	-0,150	-0,150	-0,204	-0,219	-0,190	-0,194
T	0,115	0,176	0,189	0,113	0,130	0,212	0,230	0,200	0,209
dbase	0,103	0,204	0,204	0,056	0,081	0,219	0,255	0,198	0,222
dpos	-0,031	0,087	0,083	-0,043	-0,051	0,067	0,103	0,053	0,070
dneg	0,174	0,205	0,223	0,085	0,161	0,250	0,267	0,253	0,264
trp1	-0,092	-0,117	-0,133	-0,153	-0,117	-0,140	-0,159	-0,123	-0,127
trn1	-0,173	-0,161	-0,173	-0,118	-0,151	-0,206	-0,213	-0,202	-0,203
tgp	0,014	0,048	0,055	0,081	0,093	0,064	0,079	0,036	0,058
tgn	0,080	0,164	0,203	0,113	0,075	0,227	0,267	0,188	0,217
ang_pos	0,029	0,108	0,122	0,083	0,034	0,173	0,187	0,124	0,130
ang_neg	0,135	0,196	0,233	0,143	0,137	0,272	0,305	0,233	0,258
ang_pico	0,119	0,201	0,217	0,164	0,132	0,290	0,307	0,236	0,245
Amax_i	-0,063	-0,111	-0,116	-0,194	-0,122	-0,055	-0,107	-0,024	-0,079
Bmin_i	0,073	0,151	0,156	0,222	0,147	0,108	0,159	0,088	0,125
DifA_i	-0,057	-0,060	-0,075	-0,035	-0,043	-0,127	-0,113	-0,126	-0,094
tA_i	0,023	-0,068	-0,077	-0,156	-0,110	-0,025	-0,074	0,003	-0,048
DifB_i	0,140	0,088	0,099	0,002	0,077	0,158	0,139	0,164	0,146
tB_i	-0,031	-0,112	-0,115	-0,028	0,006	-0,105	-0,133	-0,079	-0,114
Amax_f	-0,033	-0,071	-0,082	-0,078	-0,077	-0,103	-0,104	-0,093	-0,083
Bmin_f	0,037	0,072	0,083	0,169	0,071	0,073	0,088	0,041	0,058
DifA_f	-0,081	-0,095	-0,106	-0,122	-0,082	-0,106	-0,127	-0,090	-0,101
tA_f	0,076	0,098	0,127	0,002	0,011	0,101	0,128	0,101	0,141
DifB_f	0,179	0,150	0,160	0,051	0,137	0,202	0,203	0,212	0,206
tB_f	0,071	0,039	0,054	0,053	0,030	0,087	0,083	0,086	0,083
desvio	-0,130	-0,135	-0,148	-0,117	-0,124	-0,164	-0,178	-0,153	-0,156
desvioC	-0,109	-0,141	-0,155	-0,161	-0,136	-0,156	-0,181	-0,133	-0,149
media	-0,109	-0,115	-0,126	-0,096	-0,101	-0,139	-0,151	-0,129	-0,128
mediaC	-0,052	-0,109	-0,122	-0,156	-0,090	-0,124	-0,148	-0,086	-0,104
coef	-0,137	-0,149	-0,168	-0,145	-0,165	-0,212	-0,224	-0,204	-0,207
coefC	-0,239	-0,169	-0,177	-0,116	-0,232	-0,191	-0,200	-0,213	-0,220
vari	-0,139	-0,139	-0,150	-0,094	-0,112	-0,146	-0,165	-0,154	-0,158
variC	-0,126	-0,140	-0,149	-0,112	-0,121	-0,130	-0,155	-0,134	-0,146
CF	-0,109	-0,163	-0,192	-0,175	-0,153	-0,237	-0,254	-0,219	-0,220
CFC	-0,195	-0,153	-0,173	-0,118	-0,166	-0,257	-0,243	-0,251	-0,236
entrop_logC	-0,022	-0,081	-0,094	-0,160	-0,059	-0,140	-0,143	-0,084	-0,084
entrop_norC	-0,059	-0,113	-0,126	-0,154	-0,094	-0,124	-0,150	-0,091	-0,108
entrop_log	-0,096	-0,125	-0,128	-0,037	-0,080	-0,167	-0,164	-0,145	-0,150
entrop_nor	-0,112	-0,118	-0,129	-0,094	-0,103	-0,140	-0,153	-0,132	-0,131

Os valores de correlação obtidos podem ser considerados relativamente baixos porque, como pode ser observado na Figura 15, a grande maioria (83,5%) dos valores de correlação são menores que $\pm 0,2$ e conforme a tabela citada anteriormente os maiores valores de correlação positiva e negativa são respectivamente 0,310 e -0,286.

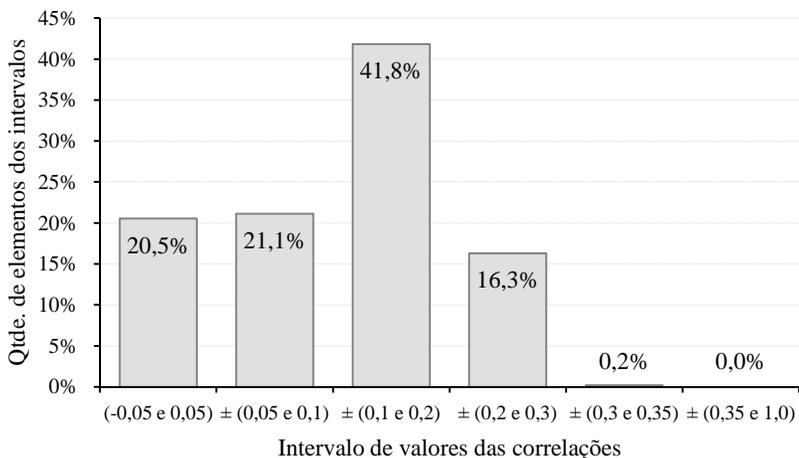


Figura 15 – Gráfico da análise dos valores de correlação

Sendo assim, por apresentar valores de correlação baixos, não foi necessário excluir nenhum dos elementos do conjunto de descritores. Terminada a análise inicial dos descritores, o próximo passo foi realizar a redução da dimensão do conjunto através da PCA.

Através de PCA foi possível transformar os 45 descritores em 39 fatores, o que corresponde a um conjunto com 86,67% do tamanho original sem perda de informação, pois os 39 fatores correspondem a 100% de qualidade na representação da população analisada (45 descritores para 600 segmentos de sinal).

Para permitir o trabalho com números inteiros, mantendo a maior representatividade possível, optou-se por trabalhar com apenas 36 dos 39 fatores, o que representa, como ilustrado na Figura 16, um conjunto com 80% do tamanho originalmente escolhido e qualidade de representação de 99,99962%.

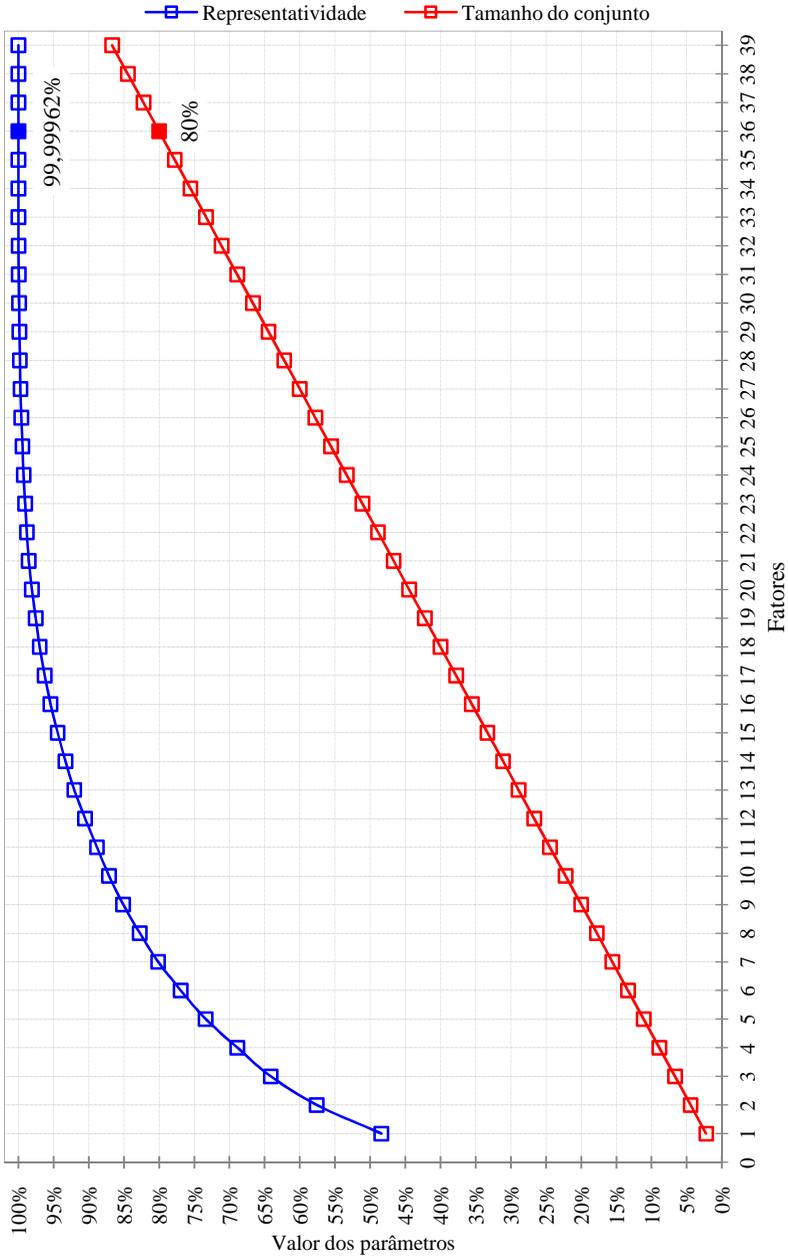


Figura 16 – Resultados da Análise de Componentes Principais.

A transformação dos descritores em fatores foi realizada utilizando os auto-vetores apresentados na Tabela 6, do Apêndice D, e os valores obtidos com esta operação podem ser observados, de forma resumida, na Tabela 7, do Apêndice E.

Uma vez constituído o “novo” conjunto de descritores morfológicos, foi necessário testar a validade deste conjunto. Para esta etapa de validação utilizou-se duas Redes Neurais Artificiais (rede A e rede B) para verificar se os conjuntos de descritores são capazes de fornecer informação suficiente para que um classificador artificial seja capaz de realizar discriminação entre paroxismos e evento não-epileptiformes. A escolha de redes neurais (EBERHART & DOBBINS, 1990; ZURADA, 1992; HAYKIN, 1998) como classificador deve-se ao fato de elas serem uma ferramenta de inteligência artificial comumente utilizada nos sistemas de detecção automática de paroxismos (HALFORD, 2009; ADELI *et al.*, 2010).

Para o treinamento e simulações com as duas redes neurais, os 600 sinais de entrada disponíveis foram divididos igual e aleatoriamente em três grupos: treinamento, teste e validação. Cada grupo ficou composto por 200 sinais, sendo 100 paroxismos e 100 eventos não-epileptiformes. A escolha dos parâmetros de configuração das redes foi feita após a realização de diversos testes de configuração sendo, finalmente, escolhidas as duas configurações apresentadas na Tabela 3. Os gráficos obtidos com o treinamento das redes podem ser observados na Figura 17 e Figura 18.

Tabela 3 – Parâmetros de configuração das duas redes neurais (rede A e rede B) utilizadas para a validação dos conjuntos de descritores.

Parâmetro	Rede A (45 descritores)	Rede B (36 descritores)
Quantidade de neurônios na camada de entrada / oculta / de saída	45 / 8 / 1 neurônios	36 / 8 / 1 neurônios
Função de ativação da camada de oculta	função (φ_1) tangente hiperbólica	função (φ_1) tangente hiperbólica
Função de ativação da camada de oculta	inclinação (k_1) 0,01	inclinação (k_1) 0,01
Função de ativação da camada de oculta	função (φ_2) logística	função (φ_2) logística
Taxa de aprendizagem	inclinação (k_2) 0,01	inclinação (k_2) 0,01
Coefficiente de momento	0,1	0,01
Quantidade de épocas no treinamento	0,9	0,9
Erro máximo da época	100000	100000
Distribuição dos pesos sinápticos iniciais	0,0001	0,0001
Atualização dos pesos sinápticos	entre -0,5 e +0,5	entre -0,5 e +0,5
Critério de parada do treinamento	por época	por época
	erro da época	erro da época

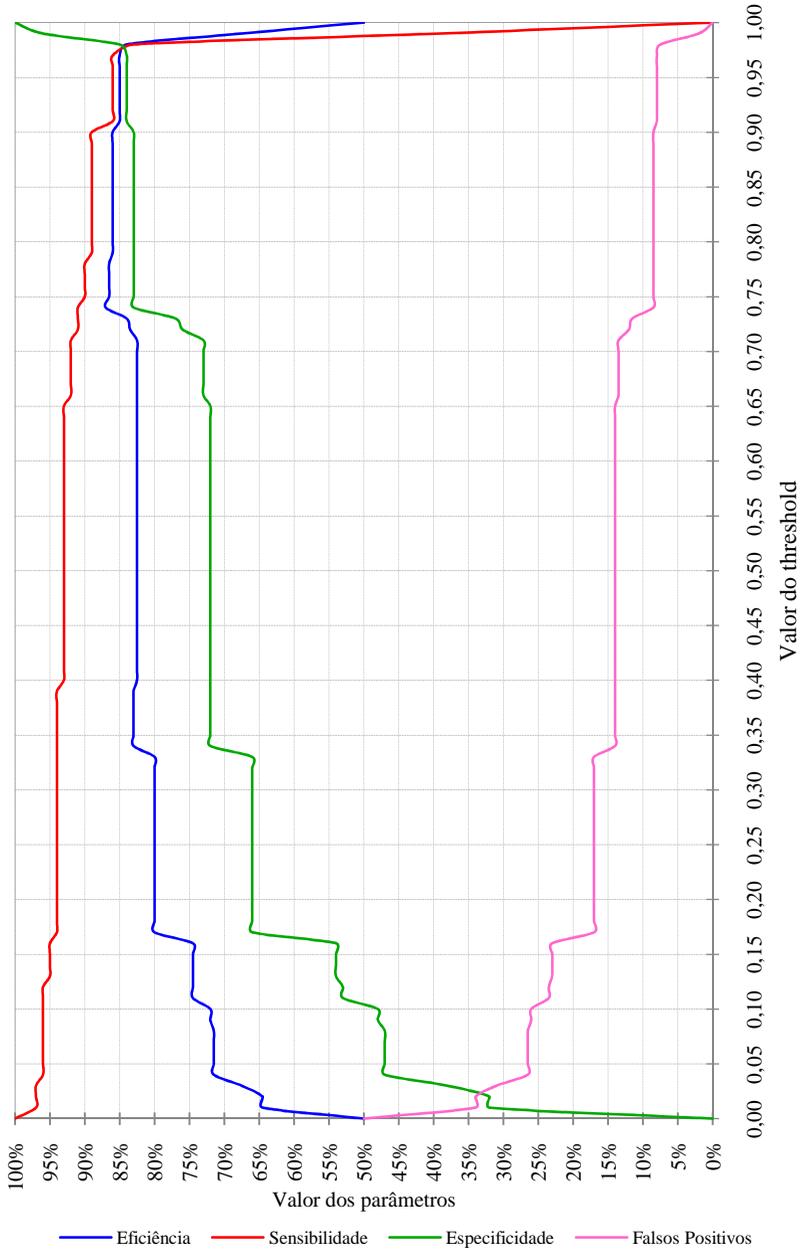


Figura 17 – Gráfico do treinamento da rede A.

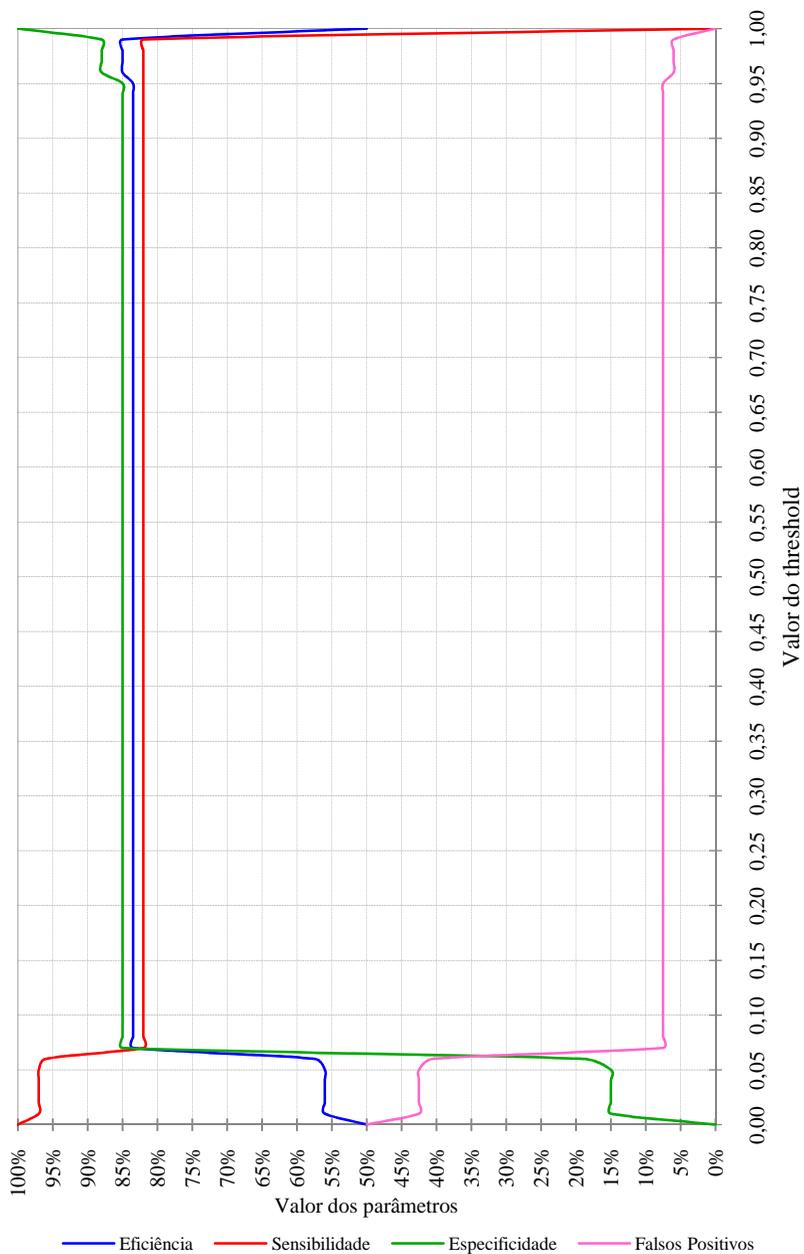


Figura 18 – Gráfico do treinamento da rede B.

O treinamento das redes foi realizado de acordo com o fluxograma apresentado no Apêndice F. As redes treinadas são todas *Feedforward Multilayer Perceptron* com algoritmo de retropropagação do erro, aprendizado supervisionado e utilização de validação cruzada. As redes foram todas treinadas por 100000 épocas, todos os parâmetros da rede foram armazenados (erros por época, por camada, pesos sinápticos, entre outros) e ao final do treinamento foram analisados os gráficos dos erros por época dos conjuntos de treinamento e validação para a escolha da melhor época treinamento.

A análise do desempenho das redes neurais foi feita através de da eficiência e de um conjunto de métricas apresentado por Casson *et al.* (2009). Uma breve descrição de cada uma das métricas, bem como as respectivas equações, podem ser encontradas no Apêndice G. Os resultados obtidos com os testes realizados estão descritos na Tabela 4 e são comentados na seção seguinte.

Tabela 4 – Valores dos índices utilizados para analisar o desempenho do teste realizado nas redes neurais desenvolvidas.

Índices estatísticos	Rede A (45 descritores)	Rede B (36 descritores)
Verdadeiro Positivo (VP)	91 0,455	82 0,410
Verdadeiro Negativo (VN)	83 0,415	85 0,425
Falso Positivo (FP)	17 0,085	15 0,075
Falso Negativo (FN)	9 0,045	18 0,090
Falsos positivos por minuto (FPM)	5,100	4,500
Eficiência (Ef)	0,870	0,835
Sensibilidade (S)	0,910	0,820
Especificidade (E)	0,830	0,850

5 DICUSSÃO DOS RESULTADOS E CONSIDERAÇÕES FINAIS

A apresentação de uma proposta de metodologia para avaliar conjuntos de descritores morfológicos utilizados para a realização de sistemas automáticos de eventos epileptiformes em sinais de EEG foi o objetivo fundamental do presente trabalho.

A metodologia proposta é composta por duas etapas. A primeira etapa consiste em analisar a os valores de correlação dos descritores selecionados entre os dois tipos de eventos de interesse para uma ferramenta de auxílio à comprovação clínica do diagnóstico de epilepsia. Uma vez analisados os valores de correlação, e excluídos do conjunto os eventuais descritores altamente correlacionados, a próxima etapa proposta é realizar redução na dimensionalidade do conjunto de descritores restantes através do método estatístico multivariado da Análise de Componentes Principais (PCA).

Os valores de correlação obtidos através da análise dos sinais de EEG disponíveis, conforme apresentado nas seções anteriores, são considerados relativamente baixos, uma vez que os maiores valores encontrados são 0,310 e -0,286. Como a correlação apresentada pelos descritores não foi motivo de exclusão de nenhum elemento do conjunto de descritores utilizados na pesquisa, a otimização do conjunto ficou por parte da PCA.

Os resultados obtidos com a PCA para o conjunto e sinais analisados podem ser considerados relativamente bons uma vez que a utilização deste método estatístico possibilitou uma redução da dimensionalidade do conjunto de descritores para um novo conjunto sem que houvesse nenhuma perda de conteúdo de informação do conjunto.

Para os testes realizados neste trabalho optou-se em realizar uma redução do conjunto em 20% para que a perda de informação pudesse ser considerada irrelevante, ou seja, para que a representatividade do conjunto sofresse apenas uma redução infinitesimal (0,00038%).

Com o novo conjunto de descritores, formados pelos 36 primeiros fatores obtidos através da PCA, foram realizadas as simulações para verificação da usabilidade do conjunto quando este é a base de informação de um classificador artificial para a realização de discriminação automática entre eventos epileptiformes e não-epileptiformes.

O classificador utilizado foi Redes Neurais Artificiais e as simulações realizadas fizeram uso de duas redes, rede A e rede B, para

testar os dois conjuntos de descritores disponíveis. A avaliação das redes foi feita através de métricas comumente utilizadas na avaliação do desempenho de redes neurais e, particularmente, métricas utilizadas quando se objetiva avaliar a detecção automática de eventos epileptiformes.

As redes desenvolvidas apresentaram resultados promissores. A rede A, utilizando 45 descritores morfológicos como estímulo de entrada da rede neural, apresentou valores de sensibilidade, especificidade e eficiência de 91%, 83% e 87%, respectivamente. A rede B, com 36 descritores obtidos através de PCA como estímulo de entrada da rede neural, obteve valores de 82% de sensibilidade, 85% de especificidade e 83,5% de eficiência.

Os valores de Falsos Positivos por minuto (FPM) obtidos pelas duas redes analisadas foram 5,1 para a rede A e 4,5 para a rede B. Considerando que a metade dos eventos utilizados nos teste era de eventos epileptiformes, pode-se transformar esta informação em uma taxa de 30 eventos epileptiformes por minuto. Então, analisando estes três valores de taxa por minuto constata-se o bom desempenho das redes e, por consequência, pode-se considerar válida a metodologia proposta.

Apesar dos bons resultados obtidos ainda há espaço para avanços. A continuidade deste estudo será feita através de testes da metodologia proposta em outros conjuntos de descritores, para verificação da aplicabilidade desta metodologia em conjuntos de descritores desenvolvidos a partir de outras características não contidas no conjunto analisado nesta pesquisa. Além disso, uma deficiência detectada nas pesquisas que abordam a avaliação de conjuntos de descritores é a aparente necessidade da utilização dos classificadores para a verificação do desempenho das metodologias. É possível que a utilização de algum tipo de ferramenta estatística possibilitaria uma melhor análise do desempenho das metodologias, sem que exista, mesmo que de forma indireta, a presença de interferência do desempenho do classificador nos resultados das avaliações realizadas.

Outro aspecto que pode ser abordado futuramente diz respeito à utilização de uma população de sinais de EEG em maior quantidade (registros contínuos completos) e diversidade (adquiridos a partir de diferentes montagens de eletrodos), ampliando assim a base de dados para o teste tanto dos descritores morfológicos como da metodologia de avaliação dos mesmos. A expansão da base de dados para testes pode fornecer a informação da viabilidade de utilização do conjunto e da metodologia proposta em sistemas de análise de sinais de EEG mais

genéricos, ou seja, que não dependam do tipo de configuração dos eletrodos utilizado na aquisição dos registros.

Ainda como projetos futuros, pretende-se analisar a viabilidade de utilização de classificadores mais robustos para que a metodologia proposta possa ser inserida em um sistema completo de detecção automática de eventos epileptiformes. No entanto, para que seja possível analisar e comparar diferentes classificadores, é necessário superar uma limitação percebida nesta pesquisa, e que dificultou a análise dos resultados com outros estudos realizados anteriormente, que se relaciona à falta de padronização nas métricas e métodos de validação das metodologias e sistemas.

Sendo assim, ainda que alguns aspectos deste trabalho possam ser discutidos com muito mais profundidade, e que não foram abordados por questões de dimensionamento da pesquisa, contata-se que os objetivos propostos foram alcançados, particularmente no que diz respeito à avaliação e otimização de um conjunto de descritores morfológicos necessário para a caracterização dos eventos presentes em um sinal de EEG para a utilização em detecção automática de eventos epileptiformes.

REFERÊNCIAS

ADELI, H.; GHOSH-DASTIDAR, S.; DADMEHR, N. *Automated EEG-Based Diagnosis of Neurological Disorders: Inventing the Future of Neurology*. Boca Raton: CRC Press, 2010. 423 p.

ARGOUD, F. I. M. *Contribuição à Automatização da Detecção e Análise de Eventos Epileptiformes em Eletroencefalogramas*. Tese de Doutorado (Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Instituto de Engenharia Biomédica, Universidade Federal de Santa Catarina, Florianópolis, 2001.

ARGOUD, F. I. M.; AZEVEDO, F. M.; MARINO NETO, J. Estudo Comparativo entre Funções Wavelet e suas Diferentes Aplicabilidades em Reconhecimento de Padrões Epileptogênicos em Eletroencefalograma. *Revista Brasileira de Engenharia Biomédica*, v. 20, n. 2, 2004, p. 49-59.

ARGOUD, F. I. M.; AZEVEDO, F. M.; MARINO NETO, J. Sistema de Detecção Automática de Paroxismos Epileptogênicos em Sinais de Eletroencefalograma. *SBA (Sociedade Brasileira de Automática)*, v. 15, n. 4, 2004, p. 467-475.

ARGOUD, F. I. M.; AZEVEDO, F. M.; MARINO NETO, J.; BITTENCOURT, P. C. T. Development of an automatic system of detection and classification of epileptiform events in EEG. *Medical & Biological Engineering & Computing*, v. 37, n.-, 1999, p. 490-491.

ARGOUD, F.I.M.; DE AZEVEDO, F.M.; MARINO NETO, J.; GRILLO, E. SADE3: an effective system for automated detection of epileptiform events in long-term EEG based on context information. *Medical & Biological Engineering & Computing*, v. 44, n. 6, p. 459-470, Jun. 2006.

BILODEAU, M.; BRENNER, D. *Theory of Multivariate Statistics*. New York: Springer, 1999. 288 p.

BOOS, C. F.; PEREIRA, M. C. V.; ARGOUD, F. I. M.; AZEVEDO, F. M. Analysis and definition of morphological descriptors for automatic detection of epileptiform events in EEG signals with artificial neural

networks. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER SCIENCE AND INFORMATION TECHNOLOGY, 3, 2010, Chengdu, China. *Proceedings of the 3rd IEEE International Conference on Computer Science and Information Technology*, v. 5, [S.l.]: IEEE Press, 2010a, p. 349-353.

BOOS, C. F.; PEREIRA, M. C. V.; ARGLOUD, F. I. M.; AZEVEDO, F. M. Morphological descriptors for automatic detection of epileptiform events. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 32, 2010, Buenos Aires, Argentina. *Proceedings of the 32nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. [S.l.]: IEEE Press, 2010b, p. 2435-2438.

BOOS, C. F.; AZEVEDO, F. M.; SCOLARO, G. R.; PEREIRA, M. C. V. Automatic Detection of Paroxysms in EEG Signals Using Morphological Descriptors and Artificial Neural Networks. In: *Biomedical Engineering, Trends in Electronics, Communications and Software*, LASKOVSKI, A. N. (Ed.), [S.l.]:InTech, 2011, p. 389-402. ISBN: 978-953-307-475-7. Available at: <<http://www.intechopen.com>>

CASSON, A. J.; LUNA, E.; RODRIGUEZ-VILLEGAS, E. Performance metrics for the accurate characterisation of interictal spike detection algorithms. *Journal of Neuroscience Methods*, v. 177, n. 2, mar. 2009, p. 479-487.

COIMBRA, A. J. F.; MARINO J.; FREITAS, C. G.; AZEVEDO, F. M., BARRETO, J. M. Automatic Detection of Sleep-Waking States Using Kohonen Neural Networks. *Anais do 1º Congresso Brasileiro de Redes Neurais*, Itajubá, 1994, p. 327-331.

DIAMBRA, L.; FIQUEIREDO, J.C.B.; MALTA,C.P.. Epileptic Activity Recognition in EEG Recording, *Physica A*, v. 273, n. 3, Nov. 1999, p. 495-505.

EBERHART, R & DOBBINS, R. *Neural Network PC Tools: A Practical Guide*. San Diego: Academic Press, 1990. 440 p.

ESTELLER, R. *Detection of Seizure Onset in Epileptic Patients from Intracranial EEG Signal*. PhD thesis, School of Electrical and Computer Engineering, Georgia Institute of Technology, 2000.

FISHER, R.S.; BOAS, W.E.; BLUME, W., ELGER, C.; GENTON, P.; LEE, P.; ENGEL JR, J. Epileptic Seizures and Epilepsy: Definitions Proposed by the International League Against Epilepsy (ILAE) and International Bureau for Epilepsy (IBE). *Epilepsia*, v. 46, n. 4, Mar 2005, p. 470-472.

GHOSH-DASTIDAR, S.; ADELI, H.; DADMEHR, N. Principal Component Analysis-Enhanced Cosine Radial Basis Function Neural Network for Robust Epilepsy and Seizure Detection. *IEEE Transactions on Biomedical Engineering*, v. 55, n.2, p. 512-518, fev. 2008.

GOTMAN, J. Automatic recognition of epileptic seizures in the EEG, *Electroencephalography and Clinical Neurophysiology*, v. 54, n. 5, Nov. 1982, p. 530-540.

GOTMAN, J.; GLOOR, P. Automatic recognition and quantification of interictal epileptic activity in the human scalp EEG. *Electroencephalography and Clinical Neurophysiology*, v. 41, n. 5, Nov. 1976, p. 513-529.

GUEDES, J. R.; PEREIRA, M. C.; AZEVEDO, F. M. Parameterization of the EEG Signal Applied to the Detection of Epileptiform Events. In: EUROPEAN MEDICAL AND BIOLOGICAL ENGINEERING CONFERENCE, 2, 2002, Vienna, Austria. *Proceedings of the 2nd European Medical and Biological Engineering Conference*, vol. 3(1), [S.l.]: IFMBE, 2002, p. 444-445.

HALFORD, J. J. Computerized epileptiform transient detection in the scalp electroencephalogram: Obstacles to progress and the example of computerized ECG interpretation. *Clinical Neurophysiology*, v. 120, n. 11, Nov. 2009, p. 1909-1915.

HÄRDLE, W.; SIMAR, L. *Applied Multivariate Statistical Analysis*. 2nd ed. New York: Springer, 2007. 458 p.

HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2nd ed. New Jersey: Prentice Hall, 1998. 842 p.

HOEF, L.; ELGAVISH, R.; KNOWLTON, R. C. Effect of Detection Parameters on Automated Electroencephalography Spike Detection

Sensitivity and False-Positive Rate. *Journal of Clinical Neurophysiology*, v. 27, n. 1, Feb. 2010, p. 12-16.

KANEKO, H.; SUZUKI, S. S.; AKAMATSU, M. Multineuronal Spike Classification Based on Multisite Electrode Recording, Whole-Waveform Analysis, and Hierarchical Clustering. *IEEE Transactions on Biomedical Engineering*, v. 46, n. 3, Mar. 1999, p. 280-290.

KUMAR, S. P.; SRIRAAM, N.; BENAKOP, P.G.; JINAGA, B.C. Entropies based detection of epileptic seizures with artificial neural network classifiers. *Expert Systems with Applications*, v. 37, n. 4, Apr. 2010, p. 3284-3291.

LITT, B. *et al.* Epileptic Seizures May Begin Hours in Advance of Clinical Onset: A Report of Five Patients, *Neuron*, v. 30, n. , April 2001, pp. 51-64, 0896-6273.

LIU, H.S.; ZHANG, T.; YANG, F.S. A multistage, multimethod approach for automatic detection and classification of epileptiform EEG. *IEEE Transactions on Biomedical Engineering*, v. 49, n. 12, Dec. 2002, p. 1557-1566.

MALMIVUO, J.; PLONSEY, R. *Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields*. New York: Oxford University Press, 1995. 512 p..

MYATT, G. J.; JOHNSON, W. P. *Making Sense of Data II: A practical Guide to Data Visualization, Advanced Data Mining Methods, and Applications*. Nova Jersey: Wiley, 2009. 291 p.

NAGHSH-NILCHI, A.R.; AGHASHAHI, M. Epilepsy seizure detection using eigen-system spectral estimation and Multiple Layer Perceptron neural network. *Biomedical Signal Processing and Control*, v. 5, n. 2, Apr. 2010, p. 147-157.

NIEDERMEYER, E.; SILVA F. L. *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. Philadelphia: Williams & Wilkins, 1993.

PEREIRA, M. C. V. Avaliação de técnicas de pré-processamento de sinais do EEG para detecção de eventos epileptogênicos utilizando redes

neurais artificiais. Tese de Doutorado (Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Instituto de Engenharia Biomédica, Universidade Federal de Santa Catarina, Florianópolis, 2003.

PEREIRA, M. C. V.; AZEVEDO, F.M.; ARGOU, F. I. M. Investigation About Pre-Processing in the Input of an Artificial Neural Network for Analysis of Epileptogenic Events in EEG Signals. *Proceedings of the World Congress on Medical Physics and Biomedical Engineering*, 2003, p.103-103.

PILLAY, J.; SPEARLING, M. R. Interictal EEG and the Diagnosis of Epilepsy. *Epilepsia*, v. 47, n. 1, Oct. 2006, p. 14-22.

QUIROGA, R. Q. *Quantitative Analysis of EEG Signals: Time-Frequency Methods and Chaos Theory*. PhD Thesis, Institute of Physiology, Medical University Lübeck and Institute of Signal Processing, Medical University Lübeck, 1998

RAYKOV, T.; MARCOULIDES, G. A. *An Introduction to Applied Multivariate Analysis*. New York: Routledge Academic, 2008. 496 p.

SAAB, M. E.; GOTMAN, J. A system to detect the onset of epileptic seizures in scalp EEG. *Clinical Neurophysiology*, v. 116, n. 2, Feb. 2005, p. 427-442.

SANEI, S.; CHAMBERS, J.A. *EEG Signal Processing*. West Sussex: Wiley, 2007. 312 p.

SCOLARO, G. R. *Classificação de eventos epileptiformes em sinais de EEG utilizando classificador neural*. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Instituto de Engenharia Biomédica, Universidade Federal de Santa Catarina, Florianópolis, 2009.

SEZER, E.; IŞIK, H.; SARACOĞLU, E. Employment and Comparison of Different Artificial Neural Networks for Epilepsy Diagnosis from EEG Signals. *Journal of Medical Systems: Online First™*, p. 1-16, abr. 2010.

SOVIERZOSKI, M. A. *Avaliação de descritores morfológicos na identificação de eventos epileptiformes*. Tese de Doutorado (Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Instituto de Engenharia Biomédica, Universidade Federal de Santa Catarina, Florianópolis, 2009.

SRINIVASAN, V.; ESWARAN, C. & SRIRAAM, N. (2007). Approximate Entropy-Based Epileptic EEG Detection Using Artificial Neural Networks. *IEEE Transactions on Information Technology in Biomedicine*, v. 11, n. 3, May 2007, p.288-295.

SUBASI, A.; GURSOY, M. I. EEG signal classification using PCA, ICA, LDA and support vector machines. *Expert Systems with Applications*, v. 37, n. 12, dez. 2010, p. 8659-8666.

TZALLAS, A.T. *et al.* A Method for Classification of Transient Events in EEG Recordings: Application to Epilepsy Diagnosis. *Methods of Information in Medicine*, v. 45, n. 6, Mar. 2006, p. 610-621.

ÜBEYLI, E. D. Statistics over features: EEG signals analysis. *Computers in Biology and Medicine*, v. 39, n. 8, Aug. 2009, p. 733-741.

VAN BELLE, G.; HEAGERTY, P. J.; FISHER, L. D.; LUMLEY, T. S. *Biostatistics: A Methodology For the Health Sciences*. 2nd ed. New Jersey: Wiley, 2004. 896 p. (Wiley Series in Probability and Statistics).

WALCZAK, S.; NOWACK, W. J. An Artificial Neural Network Approach to Diagnosing Epilepsy Using Lateralized Bursts of Theta EEGs. *Journal of Medical Systems*, v. 25, n. 1, Feb. 2001, p. 1-22.

WANG, C. *et al.* Feature extraction and recognition of epileptiform activity in EEG by combining PCA with ApEn. *Cognitive Neurodynamics*, v. 4, n. 3, p. 233-240, jun. 2010.

WEBBER, W. R. S.; LITT, B.; WILSON, K.; LESSER, R. P. Practical Detection of Epileptiform Discharges (EDs) in the EEG Using an Artificial Neural Network: a Comparison of Raw and Parameterized EEG Data. *Electroencephalography and Clinical Neurophysiology*, v. 91, n. 3, Sep. 1994, p. 194-204.

WILSON, S. B.; EMERSON, R. Spike Detection: a Review and Comparison of Algorithms. *Clinical Neurophysiology*, v. 113, n. 12, Dec. 2002, p. 1873-1881.

ZURADA, J. M. *Introduction to Artificial Neural Systems*. St. Paul: West Publishing Company, 1992.

Apêndice A – Resumo dos elementos do conjunto de descritores morfológicos selecionados para esta pesquisa

Identificação	Descrição
Amax, Bmin	amplitude máxima e mínima do sinal, respectivamente
Tdif	intervalo de tempo entre Amax e Bmin do sinal
DifAB	diferença entre Amax e Bmin do sinal
Amax_pts	amplitude máxima do segmento de 300ms
Bmin_pts	amplitude mínima do segmento de 300ms
Tdif_pts	intervalo de tempo entre Amax_pts e Bmin_pts
DifAB_pts	diferença entre Amax_pts e Bmax_pts
T	duração do evento
dbase	base do evento, relativa à sua máxima amplitude absoluta
dpos	lado oposto ao ângulo do pico positivo
dneg	lado oposto ao ângulo do pico negativo
trp	distância da amplitude máxima ao extremo do evento
trn	distância da amplitude mínima ao extremo do evento
tg _p , tg _n	tangente do ângulo positivo e negativo, respectivamente
ang_pos, ang_neg	ângulo do pico positivo e do pico negativo
ang_pico	ângulo do pico (vértice de maior amplitude absoluta)
Amax_i	amplitude máxima da região inicial do sinal
Bmin_i	amplitude mínima da região inicial do sinal
DifA_i	diferença em amplitude entre Amax e Amax_i
tA_i	diferença em distância entre Amax e Amax_i
DifB_i	diferença em amplitude entre Bmin e Bmin_i
tB_i	diferença em distância entre Amin e Amin_i
Amax_f	amplitude máxima da região final do sinal
Bmin_f	amplitude mínima da região final do sinal
DifA_f	diferença em amplitude entre Amax e Amax_f
tA_f	diferença em distância entre Amax e Amax_f
DifB_f	diferença em amplitude entre Bmin e Bmin_f
tB_f	diferença em distância entre Amin e Amin_f
desvio, desvioC	desvio padrão do sinal e do segmento de 300ms
media, mediaC	média do sinal e do segmento de 300ms
coef, coefC	coeficiente de variação do sinal e do segmento de 300ms
vari, variC	variância do sinal e do segmento de 300ms
CF, CFC	fator de crista do sinal e do segmento de 300ms
entrop_log	entropia (logarítmica) do sinal
entrop_nor	entropia (normalizada) do sinal
entrop_logC	entropia (logarítmica) do segmento de 300ms
entrop_norC	entropia (normalizada) do segmento de 300ms

Apêndice B – Algoritmo para cálculo dos descritores morfológicos

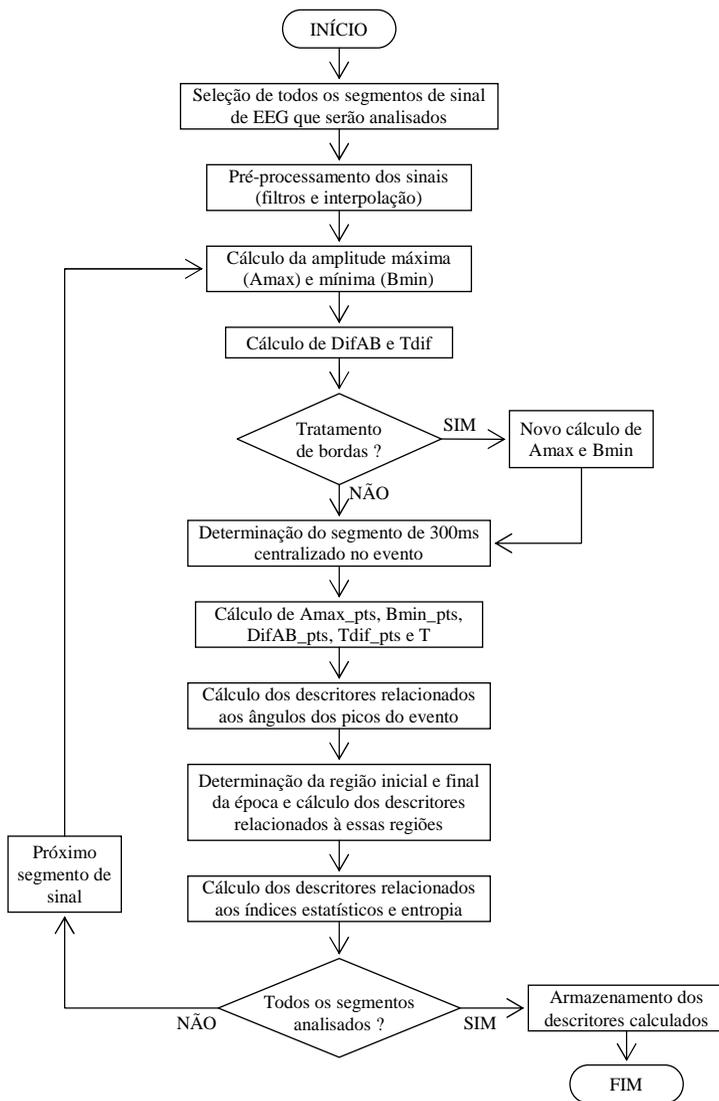


Figura 19 – Fluxograma do funcionamento do algoritmo desenvolvido para calcular o valor dos descritores morfológicos selecionados.

O algoritmo desenvolvido inicia com a seleção dos sinais que serão analisados. Todos os sinais analisados são segmentos de três segundos de sinal que são carregados a partir de uma lista fornecida pelo usuário onde consta a identificação dos sinais. Como os sinais analisados pertencem a um banco de registros de EEG as informações fornecidas foram o nome do arquivo, o número do canal e o ponto inicial do sinal dentro do registro.

O próximo passo consiste em realizar, de acordo com as especificações determinadas pelo usuário, os processos de filtragem e interpolação dos sinais. Para a análise realizada foi utilizada a interpolação do sinal para frequência de amostragem de 200Hz e filtragem para remoção de interferência de da rede elétrica (frequência de 60Hz), remoção de desvios na linha de base do sinal (frequência de 0Hz) e isolamento da faixa de frequência de interesse (5Hz a 40Hz).

Com o pré-processamento finalizado, o algoritmo inicia o cálculo dos descritores morfológicos para cada época de sinal, ou seja, dos três segundos de sinal coletados apenas o segundo central é analisado e os dois segundos adicionais funcionam, conforme observado na Figura 20, como margem de segurança para o tratamento de bordas.

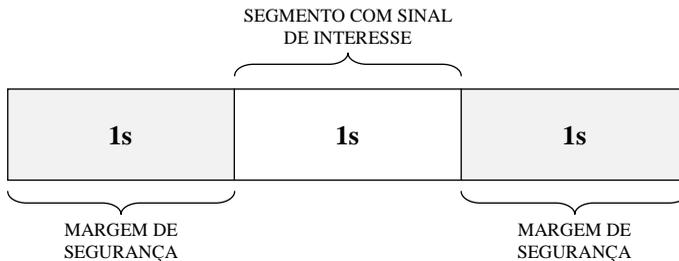


Figura 20 – Forma dos sinais coletados pelo algoritmo para realização do cálculo dos descritores.

Os dois primeiros descritores a serem calculados são a amplitude máxima e mínima do sinal representadas, respectivamente, pela identificação A_{max} e B_{min} . Depois deste cálculo é analisada a necessidade da aplicação do tratamento de bordas. O tratamento de bordas é aplicado se A_{max} ou B_{min} do evento estiverem nos primeiros ou últimos 150ms da época, conforme ilustrado pela Figura 21.

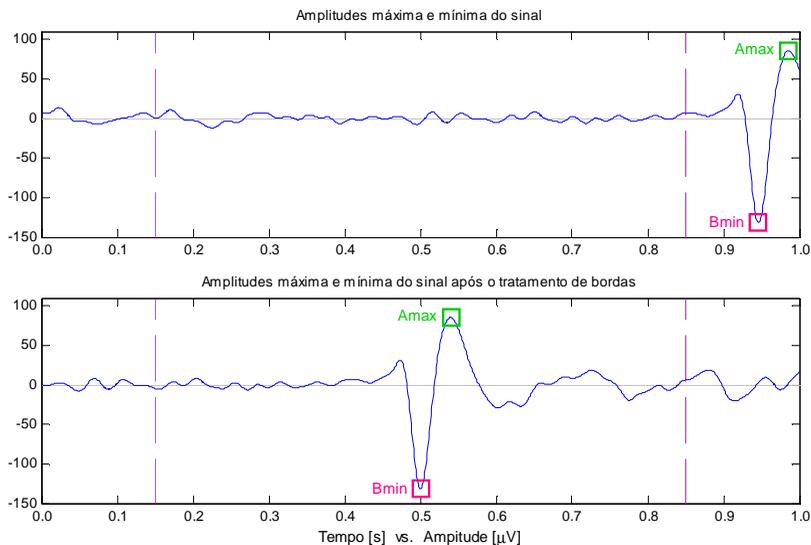


Figura 21 – Tratamento de bordas do algoritmo de cálculo dos descritores.

O tratamento de bordas aplicado é, tão somente, o deslocamento do sinal para que o evento analisado esteja centralizado na época e se este deslocamento for realizado, os valores de Amax e Bmin são recalculados. O valor dos próximos descritores, DifAB e Tdif, é obtido através da diferença de amplitudes e de pontos de ocorrência dessas amplitudes.

Para a determinação do segmento de 300ms centralizado no evento, e conseqüente cálculo dos descritores referentes a ele, o pico de maior amplitude absoluta é utilizado como ponto central do segmento. Isto é, a partir do pico com maior valor de amplitude, em módulo, são contados 150ms para cada lado e com base neste segmento de 300ms os descritores Amax_pts, Bmin_pts, DifAB_pts, Tdif_pts e T são calculados.

O cálculo da duração do evento, representada por T, é realizado com o auxílio dos pontos aproximados do início e fim do evento. Conforme Pereira (2003) a duração do evento é obtida, como ilustra a Figura 22, calculando-se a diferença entre o primeiro ponto de cruzamento pelo eixo das abscissas adjacente à Amax e Bmin no sentido do início e final do sinal, conforme a ordem em que as amplitudes apareçam.

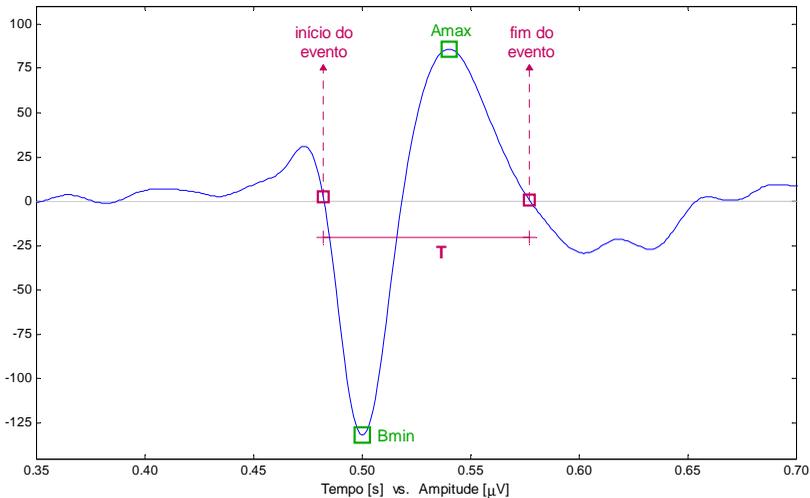


Figura 22 – Duração do evento presente na época em análise.

Após calcular, ainda utilizando o segmento de 300ms, os valores dos descritores referentes aos ângulos de pico do evento o algoritmo volta a analisar o sinal como um todo.

Para o cálculo do próximo grupo de descritores a época é dividida, a partir do ponto de maior amplitude absoluta do sinal, em duas regiões, a região inicial e a região final. A determinação destas duas regiões foi feita de modo que o evento analisado não pertencesse a nenhuma delas, ou seja, a região inicial é aquela entre o início da época e o início do evento e a região final se estende do final do evento ao final da época.

O cálculo do último grupo de descritores, relacionados à índices estatísticos e a entropia, é feito com duas referências. São calculados a média, desvio padrão, variância, fator de crista e entropia do sinal tanto para o 1s de sinal presente na época em análise como para os 300ms de sinal contidos no segmento determinado anteriormente.

Estes procedimentos de cálculo dos descritores são repetidos até que toda a lista de sinais seja analisada. Quando a obtenção dos valores é completada o algoritmo é finalizado com o armazenamento de todos os descritores para que estes sejam utilizados para posteriores análises.

Apêndice C – Valores dos descritores morfológicos

Tabela 5 – Resumo dos valores dos descritores para os sinais analisados.

Descritor	Valor máximo	Valor mínimo	Valor médio	Desvio padrão
Amax	239,5484	5,0967	48,4763	35,0649
Bmin	-4,8494	-233,0713	-50,3144	36,5152
Tdif	151,0000	3,0000	20,3900	24,0050
DifAB	403,2884	10,6273	98,7907	65,6683
Amax_pts	239,5484	4,9049	48,9121	35,1352
Bmin_pts	-3,0678	-233,0713	-51,1106	36,8399
Tdif_pts	45,0000	3,0000	11,3250	5,3213
DifAB_pts	403,2884	9,7443	100,0226	67,0550
T	50,0000	6,0000	23,3833	6,5057
dbase	46,0000	3,0000	12,4083	7,1996
dpos	46,0000	3,0000	14,4483	7,6432
dneg	44,0000	3,0000	11,5850	4,3724
trp1	241,1792	5,3646	50,7421	34,3815
trn1	233,0799	3,6621	51,7994	36,4602
tgp	10,5150	-42,6421	0,4560	2,6354
tgn	30,0754	-193,8565	0,1930	8,2066
ang_pos	106,1185	1,6686	25,9859	21,3705
ang_neg	122,4656	0,9833	22,1607	19,4875
ang_pico	106,1185	0,9833	20,2978	19,4170
Amax_i	173,0419	-13,2257	25,1884	22,3091
Bmin_i	5,3792	-139,6426	-25,1915	19,8929
DifA_i	172,4909	-83,0914	23,7237	26,9000
tA_i	148,0000	1,0000	45,9000	29,7053
DifB_i	73,0383	-205,0886	-25,9191	30,8906
tB_i	164,0000	5,0000	45,0217	30,1921
Amax_f	143,4351	-0,7333	25,7224	20,0125
Bmin_f	8,2891	-158,4847	-24,4082	19,8091
DifA_f	135,6785	-43,6066	23,1897	27,5257
tA_f	175,0000	1,0000	46,3317	30,0732
DifB_f	64,6840	-208,6879	-26,7023	30,0434
tB_f	164,0000	4,0000	48,7417	31,4681
desvio	85,5198	2,2993	22,7434	14,3696
desvioC	60,6707	2,2404	15,2767	8,8680
media	63,6186	1,8800	17,3402	10,6485
mediaC	44,1430	1,8077	10,4192	5,7526
coef	1,8075	1,1060	1,2976	0,1031
coefC	2,2471	1,1449	1,4370	0,1884
vari	3199,8109	1,6996	303,9704	406,5032
variC	1722,9147	1,5900	169,6716	216,1804
CF	6,4995	3,1018	4,3403	0,5591
CFC	11,1902	0,7490	6,1971	1,3303
entrop_logC	624,7368	33,6738	329,5803	107,1168
entrop_norC	13451,1480	394,9154	2808,8491	1719,4577
entrop_log	233,0375	0,9966	135,0839	45,9869
entrop_nor	6127,7736	125,2694	1487,0281	1000,4922

Nota: Os descritores referentes à amplitudes estão calculados em microvolts (μV) e os referentes à intervalos de tempo estão em segundos (s).

Apêndice D – Valor dos auto-vetores utilizados para o cálculo dos fatores obtidos através de Análise de Componentes Principais.

Tabela 6 – Auto-vetores dos fatores obtidos através da PCA para o conjunto de descritores e para todos os sinais selecionados.

Fator	Descr.	Amax	Bmin	Tdif	DifAB	Amax_pts
Fator 1		-0,19367	0,19405	0,06593	-0,21132	-0,19621
Fator 2		-0,02195	-0,03456	-0,11395	0,00749	-0,01679
Fator 3		0,03650	-0,02044	-0,15412	0,03086	0,04986
Fator 4		-0,24336	-0,21110	-0,09730	-0,01256	-0,23637
Fator 5		0,06518	-0,03106	0,11500	0,05207	0,06039
Fator 6		0,06210	0,04495	-0,00824	0,00817	0,06407
Fator 7		-0,07200	-0,12383	0,37841	0,03041	-0,06107
Fator 8		0,01358	-0,01662	0,19249	0,01650	0,01587
Fator 9		0,03206	0,02177	-0,00848	0,00501	0,02476
Fator 10		-0,01748	-0,04560	-0,16445	0,01602	-0,00514
Fator 11		-0,02538	-0,00512	-0,38737	-0,01070	-0,02455
Fator 12		0,00492	0,05562	-0,25535	-0,02830	0,02237
Fator 13		-0,02696	-0,04364	-0,35749	0,00987	-0,03451
Fator 14		-0,02041	-0,01735	-0,56718	-0,00125	-0,00491
Fator 15		-0,03022	-0,05704	0,13223	0,01558	-0,03176
Fator 16		0,07477	0,09011	-0,05926	-0,01018	0,08672
Fator 17		-0,00386	-0,00228	0,17626	-0,00079	-0,03312
Fator 18		-0,02951	-0,05370	0,01299	0,01410	-0,06339
Fator 19		0,05504	0,10539	0,08638	-0,02921	0,04349
Fator 20		-0,03653	0,22925	-0,03223	-0,14698	0,04993
Fator 21		-0,17449	0,00629	0,01054	-0,09667	-0,06720
Fator 22		0,07177	-0,00914	0,01838	0,04341	0,02235
Fator 23		0,08830	0,07718	0,01354	0,00423	0,09811
Fator 24		-0,05665	0,15288	0,01954	-0,11526	0,00312
Fator 25		-0,12782	-0,10892	-0,00142	-0,00769	-0,04115
Fator 26		0,05579	0,13266	-0,02954	-0,04397	0,06752
Fator 27		-0,16561	0,16741	0,01748	-0,18152	-0,09783
Fator 28		-0,00730	0,34917	0,01953	-0,19805	0,08628
Fator 29		0,34122	0,59406	-0,00834	-0,14813	-0,17841
Fator 30		-0,08856	-0,18873	-0,00499	0,05766	-0,02513
Fator 31		-0,11277	-0,09302	0,02065	-0,00849	0,01654
Fator 32		0,67519	-0,08920	-0,01359	0,41013	-0,14729
Fator 33		-0,04201	0,03578	0,00439	-0,04233	0,07821
Fator 34		0,06604	-0,04898	0,00101	0,06250	0,06116
Fator 35		0,03698	-0,01077	-0,00067	0,02573	-0,26046
Fator 36		-0,01335	-0,00498	-0,00138	-0,00436	0,02270
Fator 37		0,01271	0,00049	-0,00029	0,00651	-0,01345
Fator 38		-0,00156	0,00355	-0,00037	-0,00281	-0,00345
Fator 39		-0,00076	0,00233	-0,00006	-0,00170	0,00037

Tabela 6 – Auto-vetores dos fatores obtidos através da PCA para o conjunto de descritores e para todos os sinais selecionados. (continuação)

Fator	Descr.	Bmin_pts	Tdif_pts	DifAB_pts	T	dbase
Fator 1		0,19915	0,06170	-0,21222	0,05337	0,04314
Fator 2		-0,03692	-0,25755	0,01149	-0,19214	-0,18850
Fator 3		-0,02726	0,23908	0,04110	0,40719	0,26943
Fator 4		-0,19373	-0,00897	-0,01742	0,04056	0,03426
Fator 5		-0,02872	-0,02878	0,04742	-0,15340	0,37735
Fator 6		0,03913	0,09645	0,01207	0,09001	-0,00169
Fator 7		-0,12502	0,22986	0,03669	0,21619	-0,19464
Fator 8		-0,02897	-0,08879	0,02424	-0,17104	-0,11375
Fator 9		0,04003	-0,10599	-0,00902	0,07937	0,23637
Fator 10		-0,06191	0,00847	0,03132	-0,04859	-0,11867
Fator 11		0,00584	0,40829	-0,01607	0,15120	-0,01471
Fator 12		0,01341	-0,14722	0,00435	-0,00390	-0,10772
Fator 13		-0,04577	0,04902	0,00707	0,07663	-0,11136
Fator 14		0,00374	-0,36660	-0,00463	-0,09583	0,06086
Fator 15		-0,04782	-0,33661	0,00963	-0,12362	0,34862
Fator 16		0,07964	0,06382	0,00169	0,09728	-0,24151
Fator 17		0,06850	-0,22024	-0,05498	0,12413	0,01231
Fator 18		-0,04690	-0,07413	-0,00745	0,07910	-0,00894
Fator 19		0,03367	-0,40628	0,00429	0,27749	-0,33894
Fator 20		0,06525	0,07310	-0,00968	-0,09786	0,29107
Fator 21		-0,09738	-0,18105	0,01829	0,11710	0,05276
Fator 22		0,06162	-0,23666	-0,02214	0,56178	0,13458
Fator 23		0,00152	0,04938	0,05057	-0,15009	-0,16943
Fator 24		-0,04519	-0,13438	0,02647	0,20987	0,00952
Fator 25		0,02426	-0,09444	-0,03489	0,19564	-0,01455
Fator 26		0,00648	0,01526	0,03182	0,18450	0,02752
Fator 27		0,09248	0,05829	-0,10207	-0,16197	0,01922
Fator 28		-0,19533	-0,00135	0,15252	0,07853	-0,07490
Fator 29		-0,06280	-0,00061	-0,05898	-0,03662	-0,07875
Fator 30		0,17109	-0,01972	-0,10716	0,02023	-0,14494
Fator 31		0,02833	0,01288	-0,00689	-0,02505	-0,36577
Fator 32		0,00235	-0,00795	-0,07847	0,00050	0,00129
Fator 33		-0,07182	0,01184	0,08044	-0,01790	0,01300
Fator 34		-0,00858	-0,00766	0,03677	-0,00912	-0,01117
Fator 35		-0,04838	0,02468	-0,10990	0,04577	-0,00997
Fator 36		0,13534	0,00804	-0,06246	-0,00490	-0,00144
Fator 37		0,22556	0,01364	-0,13097	-0,00819	0,00098
Fator 38		0,00174	-0,00023	-0,00276	0,00430	0,00277
Fator 39		-0,00295	-0,00037	0,00181	0,00124	0,00041

Tabela 6 – Auto-vetores dos fatores obtidos através da PCA para o conjunto de descritores e para todos os sinais selecionados. (continuação)

Fator	Descr.	dpos	dneg	trp	trn	tgp
Fator 1		0,02562	0,03838	-0,19402	-0,19912	0,01964
Fator 2		-0,12722	-0,18316	-0,02224	0,03645	0,01493
Fator 3		0,18229	0,34714	0,05847	0,03086	0,01310
Fator 4		0,22616	-0,21368	-0,22970	0,19151	0,02903
Fator 5		0,46774	-0,23923	0,10510	0,02828	-0,02670
Fator 6		-0,02976	0,08771	0,05978	-0,03828	-0,08250
Fator 7		-0,18816	0,16007	-0,08187	0,12655	-0,03591
Fator 8		-0,19317	-0,07186	0,00659	0,03090	0,31032
Fator 9		0,12431	0,05231	0,02431	-0,03941	0,72867
Fator 10		-0,23213	0,04647	-0,02035	0,06648	0,52208
Fator 11		0,02381	0,09166	-0,04339	-0,00956	0,13787
Fator 12		0,14335	-0,26074	0,03546	-0,01550	0,05854
Fator 13		0,04108	-0,02625	-0,03354	0,04467	-0,09003
Fator 14		-0,13140	0,26243	0,01224	0,00293	-0,15426
Fator 15		-0,05153	0,28206	0,00135	0,05416	-0,12474
Fator 16		0,12765	-0,16519	0,08311	-0,07810	-0,01705
Fator 17		0,14531	0,12890	-0,03055	-0,06327	0,08062
Fator 18		0,00446	0,01477	-0,05291	0,05013	0,05488
Fator 19		0,34862	0,23216	0,07808	-0,01966	0,04693
Fator 20		-0,11086	-0,05153	0,03567	-0,07266	0,00754
Fator 21		0,01132	0,04804	-0,06520	0,10280	0,00438
Fator 22		-0,44326	-0,27759	-0,02140	-0,05955	-0,07395
Fator 23		-0,14907	0,11598	0,15519	-0,00955	0,02833
Fator 24		-0,02246	0,11672	0,00599	0,04919	0,00308
Fator 25		0,01183	-0,23320	-0,07653	-0,01508	0,02774
Fator 26		0,10226	-0,43087	0,02537	0,00658	-0,00925
Fator 27		-0,00758	0,06773	-0,06627	-0,10245	-0,00220
Fator 28		0,05290	-0,01752	0,07620	0,19658	-0,02010
Fator 29		0,01276	0,00922	-0,17993	0,06622	0,00644
Fator 30		0,04795	-0,00126	-0,00142	-0,17566	-0,00082
Fator 31		0,28704	0,13168	0,00593	-0,03193	0,00061
Fator 32		0,06043	0,02747	-0,19321	-0,00853	-0,00516
Fator 33		-0,00687	0,01825	0,00886	0,06683	0,00089
Fator 34		0,01346	0,02011	-0,15136	0,02192	-0,00666
Fator 35		-0,03887	-0,04162	0,84704	-0,03721	0,01029
Fator 36		-0,00285	0,00000	0,04012	0,50178	-0,00020
Fator 37		-0,00573	-0,00437	0,05045	0,71523	-0,00092
Fator 38		0,00147	0,00003	0,03129	0,02434	0,00036
Fator 39		-0,00059	-0,00007	-0,00078	-0,00287	0,00010

Tabela 6 – Auto-vetores dos fatores obtidos através da PCA para o conjunto de descritores e para todos os sinais selecionados. (continuação)

Fator	Descr.	tgn	ang_pos	ang_neg	ang_pico	Amax_i
Fator 1		-0,00402	0,15703	0,15834	0,15708	-0,15002
Fator 2		-0,00548	-0,06882	-0,08835	-0,11016	-0,16283
Fator 3		0,02469	0,07060	0,13072	0,13392	-0,17022
Fator 4		0,03870	0,13779	-0,16850	-0,00614	0,03132
Fator 5		-0,06368	0,34279	0,08373	0,32589	0,15520
Fator 6		0,04877	-0,01052	0,08275	0,03172	0,09249
Fator 7		-0,24365	0,02683	0,15109	-0,00597	0,02647
Fator 8		-0,59650	0,07086	0,21164	0,15419	0,03133
Fator 9		-0,17040	-0,11211	-0,16668	-0,05257	-0,16913
Fator 10		0,60255	0,07180	0,22737	0,14618	0,16025
Fator 11		-0,28186	-0,04670	-0,04488	-0,06789	0,29571
Fator 12		-0,11690	0,16539	-0,15131	-0,00865	0,05298
Fator 13		-0,06372	0,13008	0,04471	0,03731	-0,21459
Fator 14		-0,25590	-0,05585	0,22172	0,09362	0,10489
Fator 15		0,10673	-0,14930	0,14213	0,16339	0,05454
Fator 16		0,07403	0,13312	-0,00482	-0,11471	-0,01238
Fator 17		0,01227	-0,10140	-0,05149	-0,20971	0,33444
Fator 18		0,00609	0,14349	0,04609	0,09036	-0,22755
Fator 19		-0,00702	0,20712	0,10930	-0,21648	0,11124
Fator 20		-0,03935	-0,20776	-0,28581	-0,03786	0,14268
Fator 21		-0,04028	-0,04008	0,00392	0,01958	-0,24513
Fator 22		-0,00748	0,15149	-0,28128	0,27613	0,09386
Fator 23		0,01032	0,39803	-0,00740	0,33770	0,14826
Fator 24		-0,00327	0,01522	-0,16699	-0,04559	-0,00790
Fator 25		0,02682	-0,16654	0,22618	0,11571	-0,06938
Fator 26		-0,00346	-0,37144	0,55567	0,00550	0,09141
Fator 27		0,01339	0,13174	0,06521	-0,06188	-0,10864
Fator 28		0,00538	-0,11422	-0,06264	0,13184	0,15394
Fator 29		0,00388	-0,02306	0,01419	0,17604	-0,14539
Fator 30		-0,00041	-0,04066	0,03709	0,24336	0,03113
Fator 31		0,00291	-0,45232	-0,29323	0,56252	-0,01301
Fator 32		-0,00578	-0,09139	-0,04408	0,01036	-0,09277
Fator 33		-0,00275	-0,00389	-0,02507	-0,01373	0,03746
Fator 34		-0,00305	0,00313	-0,01776	0,02156	0,03993
Fator 35		-0,00298	-0,06662	-0,00405	-0,00889	-0,16776
Fator 36		-0,00146	-0,00234	-0,01472	0,00585	0,01475
Fator 37		-0,00106	0,00146	-0,00867	-0,00142	-0,00922
Fator 38		-0,00050	-0,01083	-0,00730	-0,00488	-0,00116
Fator 39		0,00001	0,00056	-0,00016	-0,00080	-0,00034

Tabela 6 – Auto-vetores dos fatores obtidos através da PCA para o conjunto de descritores e para todos os sinais selecionados. (continuação)

Fator	Descr.	Bmin_i	DifA_i	tA_i	DifB_i	tB_i
Fator 1		0,14415	-0,13186	0,04163	0,14467	0,01806
Fator 2		0,16141	0,11311	0,00017	-0,14797	0,02891
Fator 3		0,20799	0,20629	-0,12880	-0,16645	-0,16658
Fator 4		0,12279	-0,33471	-0,08053	-0,31012	0,16791
Fator 5		-0,01422	-0,04984	0,07893	-0,02510	0,07630
Fator 6		-0,13487	0,00698	0,54175	0,13352	0,41816
Fator 7		0,04065	-0,10172	0,16694	-0,17527	0,35449
Fator 8		0,00691	-0,00525	-0,13201	-0,03900	-0,19525
Fator 9		0,09938	0,17261	0,15238	-0,01626	0,27480
Fator 10		-0,03712	-0,13961	0,00731	-0,04993	-0,03519
Fator 11		-0,24417	-0,27730	-0,24629	0,16420	-0,08683
Fator 12		-0,23123	-0,01473	0,19073	0,16490	-0,03074
Fator 13		0,07840	0,13289	0,39665	-0,10508	-0,18555
Fator 14		0,10873	-0,09340	0,01205	-0,06555	0,29771
Fator 15		-0,14764	-0,08672	-0,21853	0,03805	0,12101
Fator 16		0,08450	0,12353	-0,45767	0,04056	0,56650
Fator 17		0,00203	-0,32061	0,23751	0,08038	-0,12169
Fator 18		-0,55779	0,10592	-0,12730	0,30327	0,09535
Fator 19		0,11996	-0,03546	-0,10716	-0,03710	-0,13533
Fator 20		0,20972	-0,05311	-0,06956	-0,05724	0,04345
Fator 21		-0,19815	0,11552	-0,03821	0,01147	-0,06725
Fator 22		0,06642	-0,04865	-0,03534	0,03071	-0,03487
Fator 23		0,12555	0,00519	0,00138	-0,07903	-0,02332
Fator 24		-0,08323	0,01063	0,01899	-0,00030	0,00366
Fator 25		0,03201	0,00379	-0,02958	0,00831	0,01471
Fator 26		0,04211	0,01238	0,01435	-0,01939	-0,04587
Fator 27		0,05099	-0,03768	0,02021	0,07746	-0,01012
Fator 28		-0,15618	-0,01497	0,03706	-0,13237	-0,00491
Fator 29		-0,00774	-0,11245	-0,01017	-0,06991	0,03844
Fator 30		0,10171	-0,05864	-0,00760	0,13854	0,00395
Fator 31		0,01532	0,03240	-0,00407	0,02392	0,00611
Fator 32		0,00284	-0,11544	-0,00944	0,00098	-0,00911
Fator 33		-0,03211	0,07108	0,00507	-0,06498	-0,01018
Fator 34		-0,00714	0,04678	0,00089	-0,00564	0,00074
Fator 35		-0,02550	-0,20108	0,00172	-0,04128	-0,00147
Fator 36		0,07421	0,01742	0,00217	0,11362	-0,00028
Fator 37		0,12362	-0,00992	0,00104	0,18940	-0,00077
Fator 38		0,00109	-0,00354	-0,00022	0,00137	-0,00032
Fator 39		-0,00261	0,00076	0,00000	-0,00184	-0,00019

Tabela 6 – Auto-vetores dos fatores obtidos através da PCA para o conjunto de descritores e para todos os sinais selecionados. (continuação)

Fator	Descr.	Amax_f	Bmin_f	DifA_f	tA_f	DifB_f
Fator 1		-0,14202	0,13954	-0,14719	0,02722	0,15219
Fator 2		-0,23511	0,19723	0,14950	-0,05679	-0,17531
Fator 3		-0,16808	0,18495	0,18585	-0,02104	-0,15537
Fator 4		-0,04946	-0,03612	-0,26576	-0,17051	-0,21375
Fator 5		-0,01114	-0,10256	0,08519	0,13209	0,03240
Fator 6		-0,04758	0,13513	0,11638	-0,45776	-0,04112
Fator 7		-0,05430	0,09947	-0,03847	0,28551	-0,21888
Fator 8		0,01380	-0,01784	0,01023	-0,32933	-0,02376
Fator 9		0,08066	-0,05011	-0,02703	0,05779	0,08212
Fator 10		-0,02397	-0,00026	0,01087	0,01933	-0,07574
Fator 11		-0,08914	-0,00773	0,03348	-0,14935	0,01226
Fator 12		-0,27228	0,38604	0,22651	0,07207	-0,23809
Fator 13		0,34141	-0,17510	-0,29227	-0,30735	0,05932
Fator 14		0,00941	-0,10201	-0,01311	0,34149	0,07185
Fator 15		-0,00493	0,12701	-0,03696	-0,43702	-0,14238
Fator 16		0,04444	-0,15396	0,07838	-0,21339	0,19917
Fator 17		-0,06375	-0,19295	0,00408	0,04020	0,21121
Fator 18		0,30349	0,13189	-0,30156	0,22462	-0,14447
Fator 19		0,18984	0,23650	-0,08251	-0,07241	-0,11465
Fator 20		0,31921	0,35441	-0,16835	0,00580	-0,15367
Fator 21		-0,26431	-0,29435	0,10639	-0,07906	0,07467
Fator 22		0,02056	-0,01761	0,01358	-0,04092	0,08717
Fator 23		0,07485	-0,01163	0,07082	0,02192	0,00954
Fator 24		-0,06373	-0,09825	0,05032	0,01722	0,00936
Fator 25		-0,12622	0,00208	0,03925	0,00787	0,02837
Fator 26		0,13031	0,07224	-0,00856	0,04147	-0,03969
Fator 27		-0,16383	0,05086	-0,00576	-0,03903	0,07987
Fator 28		0,08681	-0,20598	0,04702	0,03558	-0,10370
Fator 29		-0,13864	-0,04903	-0,12693	-0,00350	-0,04468
Fator 30		0,05743	0,12661	-0,07384	0,00961	0,12631
Fator 31		-0,00228	0,02459	0,02278	0,00240	0,01853
Fator 32		-0,11452	0,01637	-0,10475	-0,00292	-0,00791
Fator 33		0,03257	-0,03746	0,07615	0,00202	-0,06337
Fator 34		0,03497	-0,00301	0,05265	-0,00136	-0,00854
Fator 35		-0,16114	-0,03140	-0,21532	0,00089	-0,03863
Fator 36		0,01423	0,07592	0,01863	-0,00010	0,11590
Fator 37		-0,00906	0,12788	-0,01058	0,00020	0,19228
Fator 38		-0,00053	0,00119	-0,00401	-0,00020	0,00135
Fator 39		0,00000	-0,00227	0,00047	0,00021	-0,00212

Tabela 6 – Auto-vetores dos fatores obtidos através da PCA para o conjunto de descritores e para todos os sinais selecionados. (continuação)

Fator	Descr.	tB_f	desvio	desvioC	media	mediaC
Fator 1		0,04342	-0,20963	-0,20534	-0,20402	-0,18806
Fator 2		-0,10219	-0,04813	-0,12716	-0,09542	-0,20265
Fator 3		-0,02234	0,07841	-0,02570	0,07914	-0,09356
Fator 4		-0,21124	0,01404	-0,01475	0,03374	-0,02355
Fator 5		-0,00327	-0,01424	0,01203	-0,04935	-0,00935
Fator 6		-0,41700	0,00757	0,01106	0,00387	-0,00052
Fator 7		0,32031	0,00383	0,02939	-0,02764	0,01620
Fator 8		-0,08746	0,04818	-0,01015	0,06016	-0,05556
Fator 9		0,04994	-0,01013	-0,01303	-0,00453	0,04210
Fator 10		0,06349	0,00786	0,00262	-0,01225	-0,02277
Fator 11		-0,02283	-0,06906	0,00091	-0,09113	0,03056
Fator 12		0,40660	0,03361	0,02533	0,04307	0,02310
Fator 13		0,40548	-0,00496	0,01548	-0,01501	-0,00023
Fator 14		-0,09833	0,00849	0,00410	0,01084	0,01093
Fator 15		0,39469	-0,02185	-0,01237	-0,02913	0,01463
Fator 16		0,24102	0,01801	-0,00817	0,01408	-0,06133
Fator 17		0,16354	0,01072	-0,00101	0,00702	-0,10234
Fator 18		-0,16146	0,00875	-0,01377	0,00801	-0,07059
Fator 19		-0,17496	-0,02733	0,04159	-0,03863	0,11233
Fator 20		-0,01027	0,02831	0,06461	0,02698	0,01805
Fator 21		-0,10340	-0,00662	0,04835	-0,08356	-0,01968
Fator 22		-0,02691	-0,01229	-0,00695	-0,03503	0,03626
Fator 23		-0,04359	-0,05299	0,06865	-0,08730	0,05722
Fator 24		0,01791	-0,03004	-0,04105	0,02883	-0,11845
Fator 25		-0,01404	0,06375	0,21801	0,18933	0,30225
Fator 26		-0,01204	-0,07509	-0,06285	-0,12017	-0,07359
Fator 27		0,00783	0,14995	0,04708	0,24777	0,15292
Fator 28		0,01666	0,19417	-0,18597	0,23306	-0,15688
Fator 29		0,00111	-0,01080	0,09849	0,02427	0,08932
Fator 30		-0,01208	0,23605	-0,05381	0,33853	-0,28394
Fator 31		0,00727	-0,07178	0,03735	-0,13375	0,08319
Fator 32		-0,00152	0,03007	0,04283	0,05236	-0,08429
Fator 33		0,00040	-0,10243	0,08504	-0,01739	-0,22651
Fator 34		0,00507	-0,30588	-0,81070	0,09113	0,08808
Fator 35		-0,00143	-0,08421	-0,14840	0,03029	0,02050
Fator 36		0,00052	-0,67867	0,25104	0,20619	0,06195
Fator 37		0,00030	0,46027	-0,17699	-0,12389	-0,02632
Fator 38		0,00016	-0,04353	0,16740	-0,51079	-0,51191
Fator 39		-0,00020	0,12216	-0,10205	-0,52366	0,53112

Tabela 6 – Auto-vetores dos fatores obtidos através da PCA para o conjunto de descritores e para todos os sinais selecionados. (continuação)

Fator	coef	coefC	vari	variC	CF
Fator 1	-0,09803	-0,14060	-0,19269	-0,19291	-0,06901
Fator 2	0,32798	0,24236	-0,01020	-0,09524	0,28678
Fator 3	-0,04042	0,21199	0,08393	0,02840	-0,20823
Fator 4	-0,13838	0,01050	-0,01986	-0,02130	-0,14485
Fator 5	0,17633	-0,01047	0,14357	0,13897	0,25702
Fator 6	-0,01956	0,03115	0,01847	0,02634	-0,03590
Fator 7	0,18062	-0,00175	0,08215	0,05699	0,12006
Fator 8	-0,18268	0,02537	0,14318	0,13060	-0,16494
Fator 9	0,04794	-0,09946	-0,12480	-0,14176	0,05044
Fator 10	0,02992	-0,04730	0,17657	0,15459	0,01186
Fator 11	0,22681	-0,00438	-0,07921	-0,05128	0,29052
Fator 12	-0,15097	-0,02959	0,00923	-0,00489	-0,21371
Fator 13	0,10438	0,06311	0,01290	0,04257	0,10480
Fator 14	-0,05104	-0,05631	0,04307	0,05381	-0,09936
Fator 15	0,02920	-0,05768	-0,08490	-0,10427	0,08680
Fator 16	0,00287	0,12920	0,05472	0,07268	-0,12357
Fator 17	0,09136	0,47941	-0,01205	0,06238	-0,23954
Fator 18	0,06918	0,25323	-0,01929	0,02615	-0,07668
Fator 19	0,14347	-0,19195	-0,01607	0,00880	0,09722
Fator 20	0,14934	0,26031	0,04721	0,10870	0,01436
Fator 21	0,37204	0,15964	0,11500	0,03221	-0,03982
Fator 22	0,16466	-0,18248	0,07367	0,06745	-0,07519
Fator 23	0,04737	0,32919	-0,31182	-0,25688	0,06389
Fator 24	-0,49165	0,04118	0,10184	0,16067	0,61926
Fator 25	-0,12606	0,25571	-0,46848	-0,09985	0,17062
Fator 26	0,05886	-0,01071	0,07819	0,01478	0,03787
Fator 27	0,38634	-0,23419	0,02946	0,17230	0,04871
Fator 28	0,11511	-0,20618	-0,16645	-0,42111	-0,09436
Fator 29	-0,06638	0,19810	0,10907	0,20003	-0,00110
Fator 30	0,05066	0,07505	0,04339	0,05218	0,19006
Fator 31	0,03010	-0,07473	0,09361	0,11332	-0,06586
Fator 32	0,09994	-0,12537	-0,15420	-0,06444	0,05040
Fator 33	0,06376	-0,15314	-0,62520	0,63822	-0,09619
Fator 34	0,02925	0,11644	-0,06060	0,13976	-0,00234
Fator 35	0,00673	0,00279	-0,04913	0,06925	-0,01362
Fator 36	0,04313	-0,01895	0,08926	-0,09146	-0,02937
Fator 37	-0,02386	0,00885	-0,06918	0,07079	0,01836
Fator 38	-0,00509	-0,01959	-0,00396	-0,07921	-0,00888
Fator 39	-0,01055	0,01520	-0,04819	0,05037	-0,00051

Tabela 6 – Auto-vetores dos fatores obtidos através da PCA para o conjunto de descritores e para todos os sinais selecionados. (continuação)

Fator	Descr.	CFC	entrop logC	entrop norC	entrop log	entrop nor
Fator 1		-0,12218	-0,16168	-0,18921	-0,17021	-0,20425
Fator 2		0,32229	-0,18238	-0,20063	-0,08161	-0,09370
Fator 3		0,11018	-0,13055	-0,08840	0,04883	0,07914
Fator 4		-0,01203	0,07334	-0,02675	0,22576	0,02955
Fator 5		0,03773	-0,13006	0,00475	-0,21612	-0,03226
Fator 6		-0,03132	-0,03741	0,00191	-0,03999	0,00491
Fator 7		-0,05257	0,01862	0,01888	-0,05598	-0,01952
Fator 8		-0,05893	-0,20803	-0,04006	-0,06615	0,07235
Fator 9		0,10804	0,17443	0,02712	0,11845	-0,01785
Fator 10		-0,12107	-0,13059	-0,00759	-0,14891	0,00534
Fator 11		0,11006	0,06595	0,02690	-0,06585	-0,09360
Fator 12		-0,16992	0,08771	0,01786	0,06859	0,03943
Fator 13		0,00469	-0,08735	0,00673	-0,06049	-0,01041
Fator 14		-0,03210	-0,06624	0,01688	-0,01534	0,01494
Fator 15		0,10892	0,10837	0,00333	0,07776	-0,03821
Fator 16		-0,06692	-0,14638	-0,05286	-0,01856	0,01866
Fator 17		0,15402	-0,17813	-0,09311	0,09402	0,00293
Fator 18		0,14460	-0,18585	-0,05864	0,09465	0,00780
Fator 19		-0,07532	0,06951	0,11027	-0,12975	-0,03746
Fator 20		-0,40445	-0,13548	0,02375	-0,13072	0,03006
Fator 21		-0,56341	0,22626	-0,02984	-0,03164	-0,07990
Fator 22		0,15538	-0,01104	0,04375	0,03141	-0,02836
Fator 23		-0,13993	0,14193	0,03979	0,42296	-0,11223
Fator 24		-0,15930	-0,21142	-0,10585	0,24585	0,03618
Fator 25		-0,03618	-0,16675	0,31113	-0,25844	0,17196
Fator 26		-0,04480	0,09046	-0,07587	0,42712	-0,11974
Fator 27		0,06892	-0,28351	0,18841	0,45286	0,27498
Fator 28		-0,01437	-0,17704	-0,17900	-0,12289	0,21006
Fator 29		0,25742	0,32527	0,09829	-0,12696	0,03486
Fator 30		-0,03375	0,44105	-0,30451	-0,05168	0,35462
Fator 31		0,03230	-0,17835	0,09310	0,09059	-0,13230
Fator 32		-0,30204	-0,23958	-0,10835	0,09822	0,04757
Fator 33		0,02458	0,05808	-0,19221	-0,00802	-0,03987
Fator 34		-0,07662	0,06960	0,30766	-0,00026	0,20310
Fator 35		-0,02159	-0,00935	0,03048	-0,02161	0,02099
Fator 36		0,01096	-0,01386	-0,19216	0,00609	0,24071
Fator 37		-0,01041	0,00606	0,11163	-0,00014	-0,17217
Fator 38		0,00508	0,00790	0,41615	0,00206	0,51497
Fator 39		0,00163	-0,00837	-0,46909	0,00112	0,43929

Apêndice E – Valores dos fatores obtidos através de PCA.

Tabela 7 – Resumo dos valores dos fatores calculados a partir de PCA e dos valores dos descritores morfológicos selecionados.

Fator	Valor máximo	Valor mínimo	Valor médio	Desvio padrão
Fator 1	-64,9984	-5441,6739	-1126,0402	738,0883
Fator 2	-150,2537	-3719,2285	-824,3368	472,4641
Fator 3	195,6881	-574,9714	-106,1662	98,6325
Fator 4	100,5460	-337,8651	-11,7124	50,9785
Fator 5	657,5092	-41,2600	31,3789	71,1229
Fator 6	170,8419	-113,7556	19,6639	41,9292
Fator 7	572,8485	44,1351	144,4053	66,9219
Fator 8	610,4503	-188,3025	-34,5248	101,8216
Fator 9	200,0163	-347,7222	81,4473	64,3891
Fator 10	696,9857	-104,8838	22,7961	96,3629
Fator 11	126,8988	-636,7868	-116,2245	97,5074
Fator 12	568,4018	13,1451	165,1203	80,1899
Fator 13	97,7566	-90,6339	-0,3724	24,3416
Fator 14	534,5310	-23,3618	81,4220	64,9087
Fator 15	71,4638	-579,2727	-35,5278	77,3733
Fator 16	-13,1053	-441,0708	-137,8437	67,6431
Fator 17	-18,0520	-1249,4164	-300,6455	170,6842
Fator 18	-7,2778	-832,9139	-188,0359	110,3752
Fator 19	1211,5905	26,2951	242,5170	155,3019
Fator 20	593,6207	-59,7417	34,2914	81,6137
Fator 21	-15,0139	-489,5942	-118,3663	73,3320
Fator 22	770,8732	2,6334	112,3571	84,7692
Fator 23	151,4281	-1328,2121	-57,0411	203,7876
Fator 24	-46,4661	-784,1920	-229,3162	121,0183
Fator 25	3364,5065	143,3744	876,4336	502,6776
Fator 26	0,2164	-1317,8286	-275,5649	193,1110
Fator 27	4250,7747	107,0462	878,2558	575,3174
Fator 28	-49,7068	-2372,0533	-351,9624	260,1186
Fator 29	2198,7928	59,9851	438,6643	269,8314
Fator 30	206,9813	-1518,1492	-188,3409	225,4622
Fator 31	806,8442	-32,0216	52,5834	87,6046
Fator 32	-52,5630	-1721,5364	-319,1889	198,0225
Fator 33	-81,1026	-3629,7227	-646,1537	439,1831
Fator 34	5476,7523	149,9973	1194,9151	730,1735
Fator 35	517,8908	9,9991	112,2116	71,0576
Fator 36	147,8793	-1008,0822	-174,6506	158,5895
Fator 37	485,3644	-263,6416	53,8421	91,4372
Fator 38	8566,7774	229,1603	1911,2734	1175,9990
Fator 39	-126,8392	-3695,7089	-675,3004	463,1867

Apêndice F – Fluxograma do processo de treinamento realizado para as redes neurais artificiais desenvolvidas

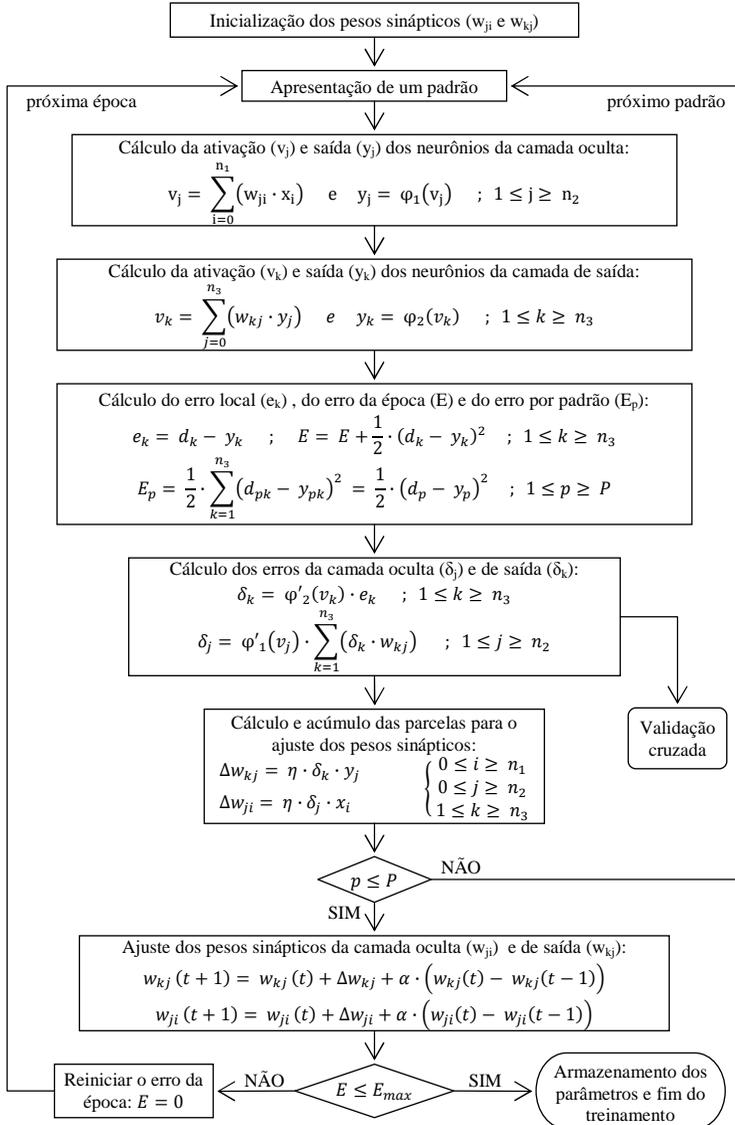


Figura 21 – Processo de treinamento das redes neurais artificiais.

Apêndice G – Métricas utilizadas para a avaliação do desempenho das Redes Neurais Artificiais

As métricas utilizadas para a avaliação do desempenho das redes neurais desenvolvidas são índices comumente utilizados e podem ser encontrados em Van Belle *et al.* (2004), Myatt & Johnson (2009), Casson *et al.* (2009), entre outros. Uma breve descrição, e respectivas equações, das métricas utilizadas podem ser observadas na Tabela 8.

Tabela 8 – Métricas para avaliação do desempenho de redes neurais.

Identificação	Descrição	Equação
Verdadeiro Positivo (VP)	quantidade de corretas identificações de paroxismos	–
Verdadeiro Negativo (VN)	quantidade de corretas identificações de eventos não-epileptiformes	–
Falso Positivo (FP)	quantidade de identificações incorretas de paroxismos	–
Falso Negativo (FN)	quantidade de identificações incorretas dos eventos não-epileptiformes	–
Sensibilidade	probabilidade de um paroxismo ser corretamente identificado	$S = \frac{VP}{VP + FN}$
Especificidade	probabilidade de um evento não-epileptiforme ser corretamente identificado	$E = \frac{VN}{VN + FP}$
Eficiência	probabilidade de todos os eventos serem corretamente identificados	$Ef = \frac{VP + VN}{VP + VN + FP + FN}$
Falsos positivos por minuto	quantidade de falsos positivos que ocorrem por unidade de tempo	$FPM = \frac{FP}{\Sigma t}$

* Para esta pesquisa a quantidade de tempo (Σt) utilizada para calcular o valor de FPM foi o somatório da duração dos sinais utilizados para teste das redes neurais.