

COMPARAÇÃO ENTRE MÉTODOS DE EXTRAÇÃO DE CARACTERÍSTICAS PARA SISTEMA DE PREVISÃO DE SURTOS EPILÉPTICOS¹

Thiago Hideo Xavier KODAMA²
Graduando em Engenharia Eletrônica
IFSP/ *Campus* São Paulo

Miguel Angelo de Abreu de SOUSA³
Doutor em Ciências/ USP
Docente do Departamento de Elétrica
IFSP/ *Campus* São Paulo

Sara Dereste dos SANTOS³
Doutora em Ciências/ USP
Docente do Departamento de Elétrica
IFSP/ *Campus* São Paulo

Ricardo PIRES³
Doutor em Sistemas Automáticos e Microeletrônicos/
Université Montpellier II
Docente do Departamento de Elétrica
IFSP/ *Campus* São Paulo

RESUMO

A epilepsia é uma doença caracterizada pela ocorrência de surtos causados por distúrbios na atividade elétrica do cérebro, medida na forma do eletroencefalograma (EEG). Na literatura, verifica-se grande interesse no desenvolvimento de sistemas usando Inteligência Artificial para a previsão da ocorrência dos surtos epiléticos, a fim de serem usados pelos pacientes em suas vidas cotidianas. Naqueles trabalhos, busca-se identificar se o sinal EEG está em um período iminente ou distante de um surto. Uma particularidade de cada trabalho foi a escolha do método de extração de características dos sinais EEG para a montagem de vetores para um classificador automático. Porém, além das variações na escolha dos métodos de extração de características, há também diferenças nos métodos usados nas etapas seguintes do processo de classificação e nos seus parâmetros, o que impossibilita que se chegue a uma conclusão segura sobre o melhor método de extração de características para tal finalidade. Por essa razão, o objetivo geral deste projeto é o de comparar métodos de montagem de vetores de características para um sistema de previsão de surtos epiléticos usando Inteligência Artificial e avaliar o impacto de cada um deles na acurácia da previsão dos surtos. As transformadas Wavelet e Fourier foram empregadas e apresentaram resultados muito distintos: com a primeira, obteve-se acurácia maior do que 90% para diferentes formas de onda e níveis de detalhe, enquanto a segunda mostrou-se inviável usando-se o sistema aqui proposto. A forma como se determina os chamados estados interictal e pré-ictal provou ser uma etapa limitante na escolha do método a ser empregado para a construção dos vetores de características.

Palavras-chave: Epilepsia; inteligência artificial; previsão de surtos; extração de características; montagem de vetores.

Introdução e Fundamentação Teórica

¹ Projeto resultante de Iniciação Científica com bolsa CNPq. Orientador: Prof. Dr. Ricardo Pires

² tk.thiago0.TK@gmail.com

³ {angelo; ricardo_pires; sarad}@ifsp.edu.br

A epilepsia é uma das doenças neurológicas mais comuns mundialmente, atingindo mais de 70 milhões de pessoas de todas as idades (THIJS et al., 2019). É diagnosticada após uma pessoa ter tido pelo menos dois surtos que não foram causados por alguma outra condição médica. Os surtos que ocorrem na epilepsia são causados por distúrbios na atividade elétrica do cérebro. Eles podem estar relacionados a lesões no cérebro ou a tendências familiares mas, na maioria dos casos, a causa é desconhecida (OSBORNE, 2014). Os surtos podem se manifestar como sendo desde pequenos lapsos de atenção ou estremecimento dos músculos até convulsões prolongadas. Podem variar, em frequência, desde menos do que um por ano até vários por dia (WORLD HEALTH ORGANIZATION, 2019).

A atividade elétrica do cérebro é medida através do eletroencefalograma (EEG), usando-se, normalmente, mais de 20 eletrodos metálicos (SEECK et al., 2017). Usualmente, é empregado o sistema 10-20 de posicionamento de eletrodos na superfície do crânio, sistema este padronizado internacionalmente e descrito por Malmivuo e Plonsey (1995). Aquela atividade elétrica deve-se à comunicação entre células cerebrais por meio de impulsos elétricos. O EEG, portanto, manifesta-se como ondas ao longo do tempo, uma para cada eletrodo. Cada um desses eletrodos e sua onda correspondente é chamado de canal. O EEG é usado nos principais testes de diagnósticos para a epilepsia, além de ser usado no diagnóstico de outros distúrbios cerebrais (MAYO FOUNDATION FOR MEDICAL EDUCATION AND RESEARCH, 2019). Neste contexto, os períodos de atividade elétrica cerebral de um paciente com epilepsia são definidos como: ictal, o qual corresponde ao período de ocorrência de um surto; pós-ictal, período imediatamente seguinte ao de um surto; pré-ictal, instantes imediatamente anteriores a um surto e interictal, período distante dos surtos (CAVANNA; MULA; MONACO, 2011).

As opções para tratamento da epilepsia incluem medicamentos ou, em casos mais raros, cirurgia. Esses medicamentos não são eficazes para uma grande parcela dos pacientes, além de causarem efeitos colaterais diversos (GADHOUMI, 2016). Por isso, há grande interesse no desenvolvimento de sistemas para a previsão da ocorrência dos surtos epiléticos que possam ser usados pelos pacientes em suas vidas cotidianas. O alerta emitido pelo sistema, com boa confiabilidade e boa antecedência, serviria para que seu usuário pudesse se colocar em uma situação de segurança ou ainda, que medicações pudessem ser administradas.

Neste sentido, muitas pesquisas têm sido conduzidas buscando desenvolver um sistema capaz de prever a aproximação de um novo surto a partir dos sinais EEG dos pacientes. É importante ressaltar que aqui são estudados os sinais EEG obtidos do escalpo,

denotados sEEG, não contemplando os casos de EEG intracranianos (ou iEEG), que é uma outra vertente também explorada na comunidade científica, como o caso, por exemplo, do trabalho de Iasemidis et al. (2003). Considerando os casos de sEEG, há diversos trabalhos na literatura cujo objetivo é o desenvolvimento de sistemas de previsão de surtos epiléticos. Eles buscam identificar se, num dado momento, o sinal EEG do paciente está no período interictal ou no período pré-ictal (GADHOUMI; LINA; GOTMAN, 2012; SONG; ZHANG, 2016; PARVEZ; PAUL, 2015; LIANG et al., 2016; ELGOHARY; ELDAWLATLY; KHALIL, 2016; TRUONG et al., 2018; BANDARABADI et al., 2015a). Assim, quando o sistema identifica a mudança do sinal de interictal para pré-ictal, o usuário é advertido sobre a aproximação de um surto.

Em geral, naqueles trabalhos, o sistema parte da obtenção do sinal EEG com mais de 20 canais, amostra-o em tempo discreto e o divide em janelas temporais contendo, cada uma, centenas ou milhares de amostras de cada canal. Tipicamente, cada janela contém entre 1 e 10 segundos de EEG. De cada janela, é montado um vetor de características, por meio da Transformada de Fourier (OPPENHEIM; SCHAFER, 2009), ou da Transformada Wavelet (MALLAT, 1989), ou por meio do cálculo de energia total em cada canal naquela janela. Finalmente, os vetores de características são entregues a um sistema de aprendizado de máquina, para treino usando esses vetores e, mais tarde, no uso regular do sistema, para classificação de novas janelas como estando no período interictal ou no período pré-ictal. É consenso que um sistema treinado usando EEG de um paciente só tem bom desempenho quando usado em outras janelas de EEG do mesmo paciente (ELGOHARY; ELDAWLATLY; KHALIL, 2016).

Gadhoumi et al. (2016) realizaram um extenso levantamento sobre trabalhos de pesquisa em previsão de surtos epiléticos e observaram que o que mais particularizou cada trabalho foi a escolha do método de extração de características dos sinais EEG para a montagem dos vetores para um classificador. Porém, além de haver variação no método de extração de características, houve, também, diferenças, de um trabalho para outro, nos métodos usados nas etapas seguintes do processo de classificação e diferenças nos seus parâmetros, o que impossibilita que se chegue a uma conclusão segura sobre qual é o melhor método de extração de características. Isso requer que apenas o método de extração de características seja variado, mantendo-se constantes as etapas seguintes do processo. Outros dois aspectos que também variaram de um trabalho para outro foram os bancos de dados de sinais EEG utilizados, o que também contribui para comprometer a comparação entre os

métodos de extração de características usados naqueles trabalhos com base nos resultados neles obtidos, e a duração do estado pré-ictal, que será explicado mais adiante.

Dentre os parâmetros a serem ajustados na etapa de montagem de vetores de características, estão a duração das janelas temporais de EEG às quais corresponderão os vetores e a duração do intervalo de tempo entre elas.

Vetores de características podem ser montados por meio de análise de espectro de frequências. Neste caso, de cada sequência de amostras $x[n]$ obtidas de um canal de EEG num certo intervalo de tempo (numa janela temporal), pode-se obter uma sequência $X[k]$ por meio da transformada de Fourier de tempo discreto, sendo (OPPENHEIM; SCHAFER, 2009):

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-i\left(\frac{2\pi}{N}\right)kn} \quad (1)$$

em que n é um índice para as amostras no domínio do tempo, N é o número de amostras por janela temporal e k é um índice para a sequência de amostras do espectro obtidas no domínio da frequência. Um vetor de características pode consistir numa subsequência da sequência $X[k]$ assim obtida, subsequência esta escolhida levando-se em conta qual é a parte do espectro com maior poder de discriminação para o problema de classificação considerado. Usando-se a transformada de Fourier de tempo discreto para a montagem de vetores, portanto, têm-se, como parâmetros a serem ajustados, o número de elementos de $X[k]$ a serem trazidos para o vetor de características e os índices k dos elementos escolhidos.

Uma outra opção à montagem de vetores por meio da transformada de Fourier é o uso da transformada Wavelet. Esta é uma transformada do tipo multirresolução, ou seja, ela decompõe um sinal em uma soma de termos que consistem em cópias de uma certa função $\psi(x)$ em várias escalas de tempo (níveis de resolução) e com vários deslocamentos temporais (MALLAT, 1989), com cada termo da decomposição sendo do tipo:

$$c_{j,n} \sqrt{2^j} \psi(2^j x - n) \quad (2)$$

em que j é um número inteiro que determina o nível de resolução, n é um inteiro que determina o deslocamento temporal e $c_{j,n}$ é o tamanho da projeção do sinal analisado sobre a componente $(2^j x - n)$. Há várias formas permitidas para a função $\psi(x)$, desde que elas satisfaçam a certas propriedades, dentre as quais a de componentes do tipo dado em (2), para quaisquer séries de j e n inteiros, formarem uma base ortogonal. Isso permite que se escolha

uma forma para $\psi(x)$ que se assemelhe a algum padrão de interesse no sinal a ser analisado. No caso da análise de EEG em epilepsia, Indiradevi et al. (2008) propuseram o uso da wavelet Daubechies 4, por ela se assemelhar a espículas presentes nos EEG dos pacientes. Por sua vez, Elgohary, Eldawlatly e Khalil (2016) tiveram sucesso usando a wavelet Haar. Disso se depreende que, além da escolha de quantos e quais coeficientes $c_{j,n}$ serão usados na montagem de vetores de características, ainda há a escolha da forma de onda $\psi(x)$ quando se usa a transformada Wavelet.

Também é possível a montagem de vetores de características no domínio do tempo. Fasil e Rajesh (2019) argumentam que isso é vantajoso, devido ao seu menor tempo computacional em comparação ao do uso de alguma transformada. Eles propõem uma forma de medição da energia, no domínio do tempo, para a extração de características do EEG. Técnicas no domínio do tempo não foram exploradas neste trabalho, devido a limitação no cronograma para sua execução.

Na maioria daqueles trabalhos sobre previsão da ocorrência de surtos, o período pré-ictal foi definido arbitrariamente como tendo uma certa duração, como, por exemplo, uma hora ou meia-hora. Uma exceção é o trabalho de Bandarabadi et al. (2015a), em que se define o período pré-ictal como tendo características no EEG muito diferentes daquelas do período interictal e em que se mostra que o período pré-ictal assim definido tem duração muito variável de surto para surto do mesmo paciente, indo de 5 minutos até 173 minutos nos experimentos realizados. Neste trabalho, o método de Bandarabadi será utilizado e seus detalhes serão apresentados na seção de metodologia.

Um classificador muito usado nos trabalhos de previsão de surtos epiléticos é a Máquina de Vetores de Suporte (em inglês, *Support-Vector Machine*, SVM) (CORTES; VAPNIK, 1995; ZHANG; PARHI, 2015; CHO et al., 2016; DIREITO et al., 2017). Em seu uso, a SVM passa por uma fase de aprendizado, em que lhe são apresentados exemplos de vetores de dados e lhe são informadas suas classes correspondentes (neste projeto, interictal ou pré-ictal). Após o aprendizado, ela passa a inferir as classes às quais devem pertencer novos vetores que lhe forem apresentados.

Dessa forma, este projeto tem como objetivo avaliar a melhor forma de se criar vetores de características para se realizar a previsão de surtos epiléticos tendo como classificador uma SVM.

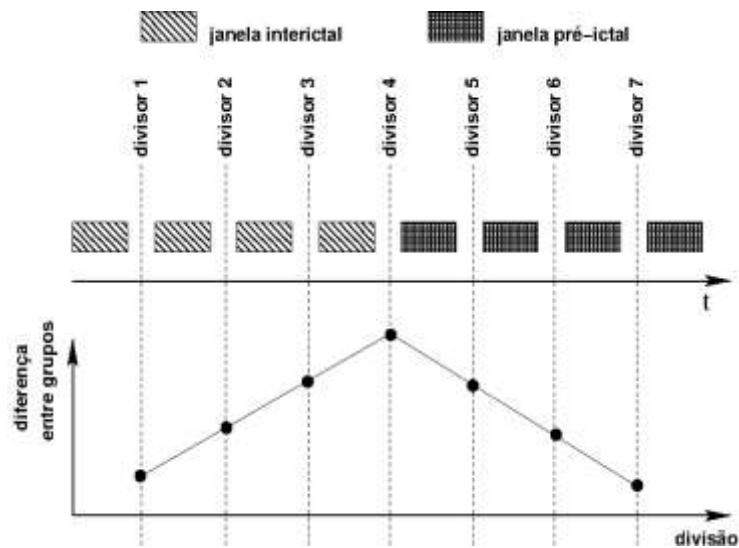
Metodologia

Os sinais EEG utilizados neste trabalho foram obtidos no banco de dados PHYSIONET (2010) (SHOEB, 2009), sendo um banco de dados largamente explorado na comunidade científica (TSIOURIS et al., 2018; ZHANG; PARHI, 2015; BEHNAM; POURGHASSEM, 2016). Os dados utilizados nesse experimento são do paciente lá identificado pela nomenclatura Chb01.

Foram realizados experimentos com a transformada Wavelet. Nesse caso, diferentes níveis de detalhe e diferentes famílias (wavelet Haar e wavelet Daubechies (db2 e db4)) foram investigados, a fim de determinar as combinações que resultassem nas maiores acurácias. Os vetores foram construídos contendo tanto cada canal individual de EEG quanto a média dos valores de todos os canais, condensando-os em uma espécie de único canal médio. Um programa, em Python, foi desenvolvido para separar esses vetores nas duas classes de interesse: pré-ictal e interictal. Para realizar a separação, inicialmente, o programa divide os vetores em dois grupos, um contendo apenas o primeiro vetor e o segundo com os demais vetores. Calcula-se o centro de massa dos dois grupos e mede-se a distância entre eles. Em seguida, o primeiro vetor é removido do segundo grupo, adicionado ao primeiro e, novamente, calculam-se os centros de massa e as distâncias entre os grupos resultantes. O programa segue fazendo isso até que o segundo grupo fique com apenas um único vetor. Por fim, as distâncias são comparadas entre si e o tempo correspondente ao maior valor é retornado. Dessa forma, é possível obter o instante de separação ideal entre os dois grupos. Como resultado desse programa, além de ele retornar as classes, ele também retorna um gráfico indicando o pico, ou seja, o ponto de maior distância entre os dois grupos. Esse critério de separação de classes foi proposto por Bandarabadi et al. (2015a) e adotado neste trabalho. A Figura 1 é um exemplo didático de gráfico obtido a partir desse procedimento. Cada divisor representa os estágios de comparação realizados pelo programa. Pode-se notar um pico posicionado no divisor 4, separando as duas classes, pré-ictal e interictal. Este é um exemplo onde as classes estão igualmente divididas, o que é ideal para o classificador, que precisa de muitas amostras de cada classe para aprender a distinguir entre uma classe e outra. No entanto, há casos em que o pico aparece muito próximo de um dos extremos do gráfico, o que significa que existirão poucas amostras de uma determinada classe para serem utilizadas no treinamento. Isso pode indicar, também, que não há distinção nítida entre períodos interictal e pré-ictal antes do surto.

Além da transformada Wavelet e com base no trabalho de Bandarabadi (2015b), foi utilizada a transformada de Fourier em janelas de 4 segundos antecedendo cada surto. O resultado da transformada de Fourier foi dividido em faixas de frequência, sendo elas a Delta (0,5-4 Hz), a Theta (4-8 Hz), a Alpha (8-12 Hz), a Beta (15-30 Hz) e a Gamma (30-128 Hz). Utilizando a média dos módulos das raias em cada faixa, foram montados os vetores de características contendo, assim, 5 elementos cada um. O critério de Bandarabadi para separação das classes também foi utilizado.

Figura 1: Exemplo didático de gráfico obtido a partir do critério de separação de classes.



Como classificador, para os dois métodos de montagem de vetores estudados, foi utilizada a SVM, construída como um objeto da classe svm da biblioteca em Python scikit-learn (PEDREGOSA ET AL, 2011), com os seguintes valores para seus parâmetros: $C=1$, $\text{coef0}=0.0$, $\text{gamma}='scale'$, $\text{kernel}='rbf'$, $\text{max_iter}=-1$. Esses hiperparâmetros são comumente usados e, por essa razão, não foram alterados ao longo do trabalho. Foram separados 200 vetores aleatórios anteriores ao surto para teste e os restantes foram utilizados integralmente para treino. Os testes foram repetidos 100 vezes.

Resultados

As análises resultantes da transformada Wavelet estão resumidas na Tabela 1. Nela, pode-se notar o comportamento de alguns canais individualmente além da média de todos os canais do EEG. Em um trabalho prévio (KODAMA et al., 2020) foram estudados os canais de maior relevância para o processo de ocorrência de um surto a partir de Análise Discriminante Linear (do inglês, *Linear Discriminant Analysis*, LDA). A partir desse estudo, foram selecionados para o presente trabalho os canais 7, 11, 15 e 16, do paciente chb01.

Pode-se notar que os canais selecionados bem como a média de todos os canais resultaram em elevada acurácia para praticamente todas as formas de onda investigadas bem como diferentes níveis de detalhe. Ou seja, a SVM foi capaz de identificar, na maioria das vezes, se os vetores de teste pertenciam a um período distante do surto (interictal) ou próximo do surto (pré-ictal). De modo geral, no entanto, os casos identificados na tabela como ND (Não Definido), ao serem submetidos ao critério de Bandarabadi et al. (2015a), não apresentaram distinção adequada entre as duas classes, o que significa que o pico de separação de máxima distância entre classes ficou próximo a um dos extremos, como pode ser observado na Figura 2. Tal comportamento afeta diretamente a quantidade de vetores disponíveis para treinamento da SVM. Se as classes ficam muito desbalanceadas, a SVM acaba aprendendo a identificar muito bem apenas uma delas e, mesmo classificando errado os vetores da classe não aprendida, isso não é suficiente para diminuir a acurácia geral.

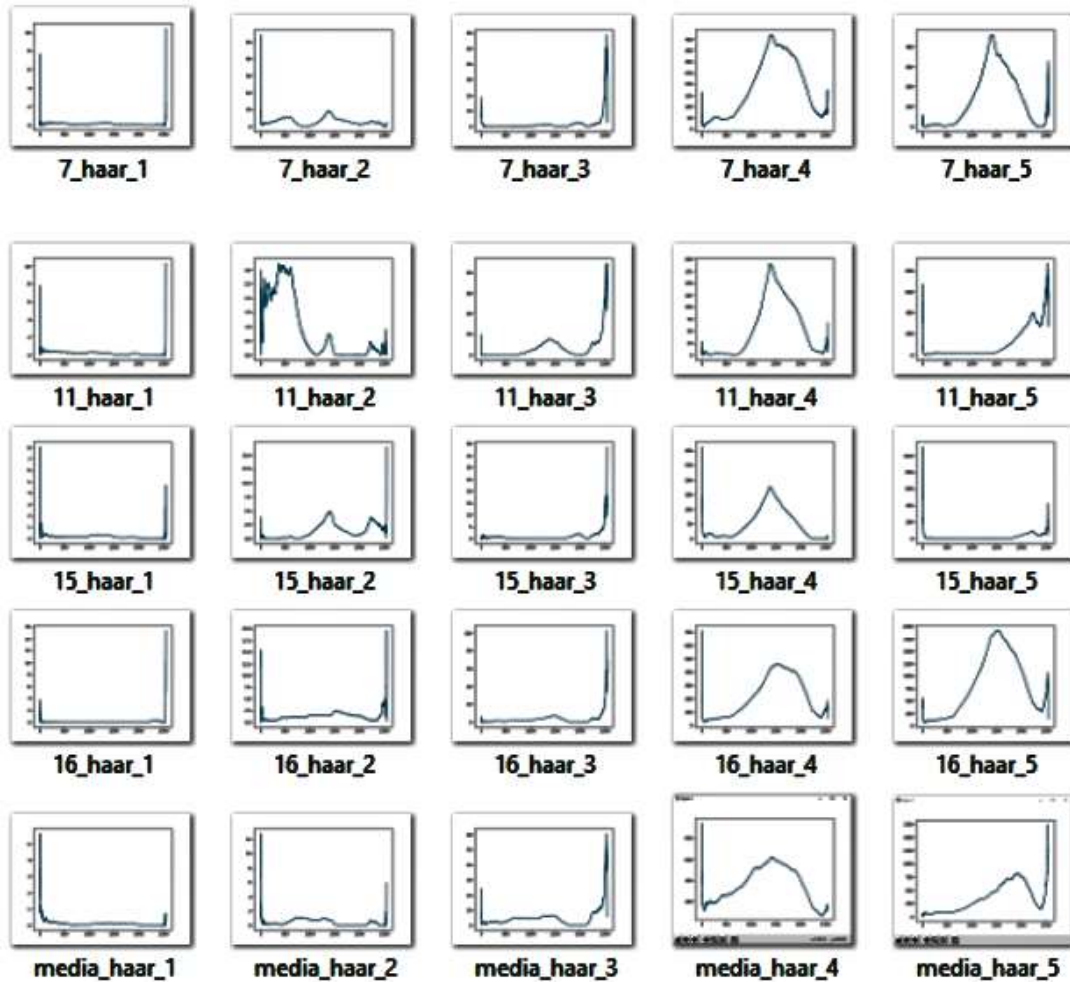
Tabela 1: Acurácia da SVM para os canais 7, 11, 15, 16 e todos os canais condensados em função de diferentes formas de onda de Wavelet e níveis de detalhe.

| Canal | 7 | | | | | |
|---------------------------|--------------------------|-------------|-------------|-------------|-------------|-------------|
| Forma de onda | Haar | | db2 | | db4 | |
| Nível de detalhe | 4 | 5 | 4 | 5 | 4 | 5 |
| Acurácia média (%) | 91,9 | 91,8 | ND | 79,4 | 99,9 | 77,5 |
| Canal | 11 | | | | | |
| Forma de onda | Haar | | db2 | | db4 | |
| Nível de detalhe | 4 | 5 | 4 | 5 | 4 | 5 |
| Acurácia média (%) | 91,0 | ND | ND | ND | ND | ND |
| Canal | 15 | | | | | |
| Forma de onda | Haar | | db2 | | db4 | |
| Nível de detalhe | 4 | 5 | 4 | 5 | 4 | 5 |
| Acurácia média (%) | ND | ND | 90,0 | ND | ND | ND |
| Canal | 16 | | | | | |
| Forma de onda | Haar | | db2 | | db4 | |
| Nível de detalhe | 4 | 5 | 4 | 5 | 4 | 5 |
| Acurácia média (%) | ND | 94,0 | 94,0 | ND | ND | ND |
| Canal | Média de todos os canais | | | | | |
| Forma de onda | Haar | | db2 | | db4 | |
| Nível de detalhe | 4 | 5 | 4 | 5 | 4 | 5 |
| Acurácia média (%) | 99,0 | 99,0 | 98,0 | ND | ND | 98,0 |

A partir da análise da Figura 2, onde cada janela corresponde a um gráfico da máxima diferença entre grupos em função da divisão, percebe-se que a separação dos períodos interictal e pré-ictal usando-se o critério de Bandarabadi não é claramente bem definida para

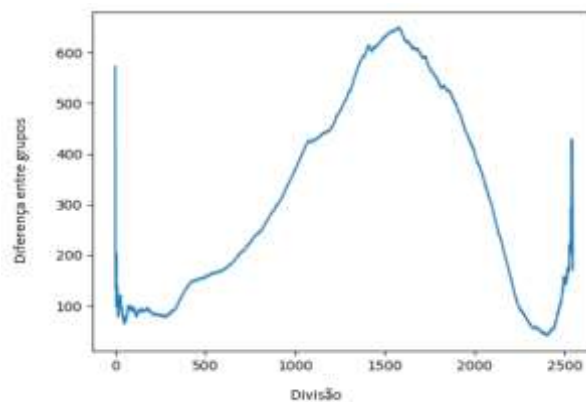
diversos casos, em especial para o nível de detalhe 1 (primeira coluna), razão pela qual este tenha sido abortado dos demais experimentos. Um exemplo de uma janela onde a divisão entre grupos é bem definida pode ser visto na Figura 3 com maior resolução. Portanto, o fato de nem sempre haver uma distinção entre os períodos sugere que o método de Bandarabadi nem sempre irá proporcionar uma clara distinção entre as classes, o que demonstra que os sinais de EEG podem não apresentar uma mudança significativa entre um estado e outro. Essa característica é de extrema relevância, pois afeta diretamente o processo de aprendizado de uma SVM ou de uma rede neural qualquer. Por outro lado, é importante reforçar que, para a maioria dos trabalhos de previsão de surtos, a duração de cada período é definida de forma arbitrária, o que também compromete o comportamento geral do sistema. Dessa forma, uma possível solução seria um sistema com capacidade de testar inicialmente a existência de uma separação nítida entre classes para, a partir desse ponto, seguir com o processo de treinamento do classificador. Assim, para os casos em que o gráfico de máxima diferença apresentasse um resultado semelhante ao da Figura 3, o treinamento seria beneficiado graças à proporção semelhante de janelas de cada uma das classes.

Figura 2: Exemplos de gráficos da máxima diferença entre grupos em função da divisão obtido pelo critério de Bandarabadi para os canais 7, 11, 15 e 16, considerando a wavelet Haar com níveis de detalhe 4 e 5.



Fonte: Autores


Figura 3: Um gráfico de Bandarabadi de máxima diferença entre grupos utilizando transformada Wavelet.



Fonte: Autores

O segundo método de montagem de vetores baseou-se na transformada de Fourier, conforme explicado na seção anterior. Contudo, a divisão dos grupos pelo critério de Bandarabadi resultou sempre em gráficos semelhantes ao da Figura 4.

Figura 4: Um gráfico de máxima diferença entre grupos utilizando transformada de Fourier.



Fonte: Autores

Como pode ser observado na Figura 4, não há distinção entre grupos, o que significa que a média das diferentes raías usadas para compor cada vetor apresenta valores similares na medida em que se aproxima do surto, impossibilitando a distinção entre um estado e outro. Consequentemente, o processo de treinamento da SVM foi afetado pelo desbalanceamento dos vetores e isso impediu a verificação do desempenho da máquina. Dessa forma, ficou demonstrado que, pelo critério de divisão dos estados proposto por Bandarabadi, os vetores montados a partir da média da transformada de Fourier aplicada a todos os canais do EEG não permitiram o adequado treinamento da SVM. Uma possibilidade de investigação, ainda envolvendo esses métodos, seria a de avaliar a montagem dos vetores para alguns canais individualmente, evitando o uso da média de todos os canais.

Conclusão

Métodos para montagem de vetores de características foram explorados neste trabalho, a fim de analisar o impacto dessas mudanças no processo de aprendizagem de uma máquina de vetores de suporte (SVM) para a classificação de janelas de EEG como estando em período interictal ou período pré-ictal. Considerando a complexidade para comparar trabalhos na literatura, em função das diferenças de cada método, optou-se pela investigação sobre a influência da etapa inicial, referente à montagem dos vetores de características, na acurácia do sistema. As transformadas Wavelet e Fourier foram empregadas e apresentaram comportamentos muito distintos. Enquanto a primeira proporcionou resultados maiores do que 90% de acurácia, a segunda foi inviável usando-se o sistema aqui proposto. Isso porque, nesta, o critério de determinação dos estados interictal e pré-ictal não foi capaz de distinguir, de forma balanceada, a transição entre as duas classes, impossibilitando o correto treinamento

da SVM. Dessa forma, pode-se concluir que a escolha do método para extração das características do sinal EEG é muito afetada pela forma como os estados serão definidos. Além disso, é importante salientar que um sistema originado a partir desse estudo seria capaz de prever a aproximação de um surto e emitir um alerta ao paciente que o estivesse utilizando. Isso é possível a partir da transição dos estados interictal e pré-ictal e, por isso, a definição desses estados torna-se um gargalo importante do sistema. Tal objetivo se contrapõe aos sistemas para auxílio ao diagnóstico da epilepsia, pois esses normalmente buscam determinar o estado ictal no EEG do paciente, sendo, portanto, necessário que esse estado faça parte do processo de treinamento do sistema.

Referências

- BANDARABADI, Mojtaba et al. On the proper selection of preictal period for seizure prediction. *Epilepsy & Behavior*, v. 46, p. 158-166, 2015a.
- BANDARABADI, Mojtaba et al. Epileptic seizure prediction using relative spectral power features. *Clinical Neurophysiology*, v. 126, n. 2, p. 237-248, 2015b.
- BEHNAM, Morteza; POURGHASSEM, Hossein. Real-time seizure prediction using RLS filtering and interpolated histogram feature based on hybrid optimization algorithm of Bayesian classifier and Hunting search. *Computer methods and programs in biomedicine*, v. 132, p. 115-136, 2016.
- CHANG, C.-C.; LIN, C.-J. LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, v. 2, p. 27:1–27:27, 2011.
- CHO, Dongrae et al. EEG-based prediction of epileptic seizures using phase synchronization elicited from noise-assisted multivariate empirical mode decomposition. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 25, n. 8, p. 1309-1318, 2016.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, Springer, v. 20, n. 3, p.273–297, 1995.
- DIREITO, Bruno et al. A realistic seizure prediction study based on multiclass SVM. *International journal of neural systems*, v. 27, n. 03, p. 1750006, 2017.
- EATON, J. W. et al. GNU Octave version 3.8.1 manual: a high-level interactive language for numerical computations. CreateSpace Independent Publishing Platform, 2014. ISBN 1441413006. Disponível em: <<http://www.gnu.org/software/octave/doc/interpreter>>.
- EDFBROWSER. EDFbrowser. 2020. Disponível em: <https://www.teuniz.net/edfbrowser/>. Acesso em 23/04/2020.
- ELGOHARY, S.; ELDAWLATLY, S.; KHALIL, M. I. Epileptic seizure prediction using zero-crossings analysis of EEG wavelet detail coefficients. In: IEEE. 2016 IEEE conference on computational intelligence in bioinformatics and computational biology (CIBCB). [S.l.], 2016. p. 1–6.
- EPILEPSY FOUNDATION. Epilepsy Foundation. 2019. Disponível em: <https://www.epilepsy.com>. Acesso em 23/04/2020.

- FASIL, O.; RAJESH, R. Time-domain exponential energy for epileptic EEG signal classification. *Neuroscience letters*, Elsevier, v. 694, p. 1–8, 2019.
- GADHOUMI, K.; LINA, J.-M.; GOTMAN, J. Discriminating preictal and interictal states in patients with temporal lobe epilepsy using wavelet analysis of intracerebral EEG. *Clinical neurophysiology*, Elsevier, v. 123, n. 10, p. 1906–1916, 2012
- GADHOUMI, K. et al. Seizure prediction for therapeutic devices: A review. *Journal of neuroscience methods*, Elsevier, v. 260, p. 270–282, 2016.
- IASEMIDIS, Leonidas D. et al. Adaptive epileptic seizure prediction system. *IEEE transactions on biomedical engineering*, v. 50, n. 5, p. 616-627, 2003.
- INDIRADEVI, K. et al. A multi-level wavelet approach for automatic detection of epileptic spikes in the electroencephalogram. *Computers in biology and medicine*, Elsevier, v. 38, n. 7, p. 805–816, 2008.
- KODAMA, T.; Sousa, M.; Santos, S; Pires, R. Influência da redução do número de canais de EEG na predição de surtos epiléticos baseada em máquinas de vetores de suporte. *Revista para Graduandos (REGRASP)*, v.6, Editora IFSP, 2021.
- LEE, G. et al. Pywavelets: A python package for wavelet analysis. *Journal of Open Source Software*, *The Open Journal*, v. 4, n. 36, p. 1237, 2019. Disponível em: <<https://doi.org/10.21105/joss.01237>>.
- LIANG, J. et al. Predicting seizures from electroencephalography recordings: a knowledge transfer strategy. In: *IEEE. 2016 IEEE International Conference on Healthcare Informatics (ICHI)*. [S.l.], 2016. p. 184–191.
- MALLAT, S. G. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, Ieee, n. 7, p. 674–693, 1989.
- MAYO FOUNDATION FOR MEDICAL EDUCATION AND RESEARCH. EEG (electroencephalogram). 2019. Disponível em <https://www.mayoclinic.org/tests-procedures/eeeg/about/pac20393875>. Acesso em 23/04/2020.
- MULA, M.; MONACO, F. Ictal and peri-ictal psychopathology. *Behavioural neurology*, IOS Press, v. 24, n. 1, p. 21–25, 2011.
- OLIPHANT, T. E. *A guide to NumPy*. [S.l.]: Trelgol Publishing USA, 2006. v. 1.
- OPPENHEIM, A. V.; SCHAFER, R. W. *Discrete-Time Signal Processing*. 3rd. ed. Upper Saddle River, NJ, USA: Prentice Hall Press, 2009. ISBN 0131988425, 9780131988422.
- OSBORNE, P. *About Epilepsy: The Basics*. 2014. Disponível em <https://www.epilepsy.com/learn/about-epilepsy-basics>. Acesso em 23/04/2020.
- PARVEZ, M. Z.; PAUL, M. Epileptic seizure prediction by exploiting spatiotemporal relationship of EEG signals using phase correlation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 24, n. 1, p. 158–168, 2015.
- Physionet. CHB-MIT Scalp EEG Database. 2010. Disponível em: <https://physionet.org/content/chbmit/1.0.0/>. Acesso em 23/04/2020.
- SHOEB, A. H. Application of machine learning to epileptic seizure onset detection and treatment. Tese (Doutorado) — Massachusetts Institute of Technology, 2009.

SONG, Y.; ZHANG, J. Discriminating preictal and interictal brain states in intracranial EEG by sample entropy and extreme learning machine. *Journal of neuroscience methods*, Elsevier, v. 257, p. 45–54, 2016.

THIJS, R. D.; SURGES, R.; O'BRIEN, T. J.; SANDER, J. W. Epilepsy in adults. *The Lancet*, v. 393, n. 10172, p. 689-701, 2019.

TSIOURIS, Kostas M. et al. A long short-term memory deep learning network for the prediction of epileptic seizures using EEG signals. *Computers in biology and medicine*, v. 99, p. 24-37, 2018.

TRUONG, N. D. et al. Convolutional neural networks for seizure prediction using intracranial and scalp electroencephalogram. *Neural Networks*, Elsevier, v. 105, p. 104–111, 2018.

WORLD HEALTH ORGANIZATION. Epilepsy. 2019. Disponível em <https://www.who.int/newsroom/fact-sheets/detail/epilepsy>. Acesso em 23/04/2020.

ZHANG, Zisheng; PARHI, Keshab K. Low-complexity seizure prediction from iEEG/sEEG using spectral power and ratios of spectral power. *IEEE transactions on biomedical circuits and systems*, v. 10, n. 3, p. 693-706, 2015.