

INFLUÊNCIA DA REDUÇÃO DO NÚMERO DE CANAIS DE EEG NA PREDIÇÃO DE SURTOS EPILÉPTICOS BASEADA EM MÁQUINAS DE VETORES DE SUPORTE ¹

Thiago KODAMA²

Graduando em Engenharia
IFSP/Câmpus São Paulo

Miguel Angelo de Abreu de SOUSA³

Doutor em Engenharia Elétrica/USP
Docente de Engenharia Elétrica
IFSP/Câmpus São Paulo

Sara Dereste dos Santos PERSEGHINI⁴

Doutora em Engenharia Elétrica/USP
Docente de Engenharia Elétrica
IFSP/Câmpus São Paulo

Ricardo PIRES⁵

Doutor em Sistemas Automáticos e Microeletrônicos/Université de Montpellier II
Docente de Engenharia Elétrica
IFSP/Câmpus São Paulo

RESUMO

A epilepsia é uma das doenças neurológicas mais comuns no mundo. É caracterizada por crises causadas por distúrbios na atividade elétrica do cérebro, a qual é medida na forma do chamado eletroencefalograma (EEG), usando-se, normalmente, mais de 20 canais. Há grande interesse no desenvolvimento de sistemas a serem usados pelos pacientes para a previsão da ocorrência das crises. Porém, um dispositivo apenas se tornaria viável se fosse pequeno, leve e pouco perceptível pelas demais pessoas. Em função disso, neste trabalho, é investigada uma forma de reduzir a quantidade de canais do EEG sem afetar a qualidade da previsão de um surto epilético. Através da técnica de Análise de Discriminante Linear (LDA), foi possível reduzir a quantidade de canais de 23 para apenas 4, mantendo a acurácia do sistema de classificação, que consiste em Máquinas de Vetores de Suporte (SVM), acima de 90% para a maioria dos casos avaliados. Também se verificou que pacientes podem apresentar crises incompatíveis entre si, o que dificulta, nesses casos, a previsão de um surto, mesmo com o uso de todos os canais do EEG.

Palavras-chave: Epilepsia; Predição; Redução de dimensionalidade; Análise de Discriminante Linear; Máquinas de Vetores de Suporte.

¹ Projeto resultante de Iniciação Científica com bolsa CNPq. Orientador: Prof. Dr. Miguel Angelo de Abreu Sousa.

² Endereço eletrônico: tk.thiago0.tk@gmail.com

³ Endereço eletrônico: angelo@ifsp.edu.br

⁴ Endereço eletrônico: sarad@ifsp.edu.br

⁵ Endereço eletrônico: ricardo_pires@ifsp.edu.br

Introdução

A epilepsia é uma das doenças neurológicas mais comuns no mundo, atingindo mais de 50 milhões de pessoas de todas as idades (EPILEPSY FOUNDATION, 2019; WORLD HEALTH ORGANIZATION, 2019). É diagnosticada após uma pessoa ter tido pelo menos duas crises que não foram causadas por alguma outra condição médica. As crises que ocorrem na epilepsia são causadas por distúrbios na atividade elétrica do cérebro. Elas podem estar relacionadas a lesões no cérebro ou a tendências familiares, mas, na maioria dos casos, a causa é desconhecida (SHAFER, 2014). As crises podem se manifestar como sendo desde pequenos lapsos de atenção ou estremezimento dos músculos até convulsões prolongadas. Podem variar em frequência desde menos do que uma por ano até várias por dia (WORLD HEALTH ORGANIZATION, 2019).

A atividade elétrica do cérebro é medida na forma do chamado eletroencefalograma (EEG), usando-se, normalmente, mais de 20 eletrodos metálicos (SEECK *et al.*, 2017). Usualmente, é empregado o chamado sistema 10-20 de posicionamento de eletrodos na superfície do crânio, sistema este padronizado internacionalmente e descrito por Malmivuo e Plonsey (1995). A atividade elétrica cerebral deve-se à comunicação, por meio de impulsos elétricos, entre células cerebrinas. 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, correspondente ao período de ocorrência de uma crise; pós-ictal, período imediatamente seguinte ao de uma crise; pré-ictal, instante imediatamente anterior a uma crise; e interictal, período distante das crises (MULA; MONACO, 2011).

As opções para tratamento da epilepsia são medicamentos ou, em casos mais raros, cirurgia. Esses medicamentos não são eficazes para uma grande parcela dos pacientes (GADHOUMI *et al.*, 2016). Por isso, há grande interesse no desenvolvimento de sistemas a serem usados pelos pacientes em suas vidas cotidianas para a previsão da

ocorrência das crises epiléticas. Se um tal sistema pudesse advertir seu usuário da iminência de uma crise epilética, com boa confiabilidade e boa antecedência; ao ser advertido, o usuário poderia se colocar em situação de segurança, por exemplo, deixando de dirigir um carro ou de caminhar na rua. Para aqueles a quem os medicamentos são eficazes, esses medicamentos poderiam ser administrados somente após o usuário receber as advertências feitas pelo sistema de previsão, o que seria interessante para os pacientes que têm crises raramente.

Nesse contexto, este projeto tem como objetivo o desenvolvimento de um sistema para previsão de crises que faça uso de poucos canais do EEG, a fim de tornar o protótipo mais atrativo para o usuário final.

Trabalhos relacionados

Na literatura, encontram-se muitos trabalhos cujo objetivo é o desenvolvimento de sistemas de previsão de crises epiléticas, eles buscam a diferenciação entre os estados interictal e pré-ictal. Como alguns exemplos desses trabalhos, têm-se Elgohary, Eldawlatly e Khalil (2016), Gadhoumi, Lina e Gotman (2012), Kitano (2018), Liang *et al.* (2016), Parvez e Paul (2016), Song e Zhang (2016), Truong *et al.* (2018). Em geral, neles, o sistema parte da obtenção do sinal EEG com mais de 20 canais, amostra-o em tempo discreto e divide-o 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 de análise espectral (Fourier ou Wavelet) 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 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. Naqueles trabalhos, o período pré-ictal é definido arbitrariamente como tendo uma certa duração, como, por exemplo, uma hora ou meia-hora.

Diferentemente daqueles trabalhos, Bandarabadi *et al.* (2015) definem o período pré-ictal não como tendo uma duração definida, mas como apresentando características

específicas no EEG. Com base nisso, aquele trabalho estabelece um método para a determinação da transição entre o período interictal e o pré-ictal e mostra que a duração do período pré-ictal varia muito entre crises de uma mesma pessoa. Na fase de treinamento, ao receber um sinal EEG antecedendo uma crise, o método varre exaustivamente (com passos de um minuto) possibilidades de duração do período pré-ictal. Para cada duração experimentada, é feita uma medida da semelhança entre histogramas das características de janelas do sinal no período provisoriamente definido como pré-ictal com os histogramas das janelas do período provisoriamente definido como interictal. Adota-se, ao final, como duração do pré-ictal, aquela duração para a qual a semelhança entre os histogramas dos dois períodos foi a mínima dentre todas as semelhanças medidas. Assim, encontra-se a duração que corresponde à maior diferença nas características do EEG de um período para o outro. Um sistema de previsão baseado nessa ideia, então, tenderia a ter maior acurácia ao indicar que um sinal EEG entrou no período pré-ictal do que aqueles sistemas baseados na ideia de duração fixa e arbitrária desse período.

Vários daqueles trabalhos sobre previsão de crises epiléticas têm reportado níveis de acurácia superiores a 90% na classificação quanto a cada janela de EEG estar no período interictal ou no período pré-ictal. Porém, seria inviável um dispositivo para uso cotidiano por um paciente de epilepsia requerer que mais de 20 eletrodos ficassem posicionados por toda a superfície do crânio do usuário ao longo do dia, enquanto este estivesse em suas atividades profissionais ou sociais. O dispositivo tornar-se-ia viável apenas se fosse pequeno, leve e pouco perceptível pelas demais pessoas. Para isso, ele deveria ter um número muito menor do que 20 canais, mas de forma a não comprometer sua acurácia. Guttag *et al.* (2009) solicitaram patente de um método e de um aparelho com reduzido número de eletrodos para medição de EEG com aplicação na detecção de crises epiléticas. Porém, o objetivo daquele método é detectar a entrada do sinal no período ictal, que é o da crise, enquanto seria de maior interesse para usuários a detecção da entrada no período pré-ictal, o que possibilitaria maior tempo disponível para uma ação antes da ocorrência da crise. O método de redução proposto naquele trabalho baseia-se em tentativas: de um conjunto inicial contendo N canais de EEG, retira-se um canal por vez, mede-se o resultado em cada caso com os $(N-1)$ canais restantes, efetua-se a retirada do canal que foi constatado ser o menos importante dentre

os N canais iniciais e repete-se o procedimento, partindo-se, agora, de um conjunto com os $(N-1)$ canais restantes, retirando-se um destes de cada vez e assim por diante, até se chegar a um número de canais reduzido, mas que não comprometa muito a acurácia. Ao invés de se usar um método baseado em tentativas, em problemas de classificação nos quais os dados são representados por vetores (n -uplas), para se avaliar a possibilidade de redução de dimensionalidade, pode-se empregar a Análise de Discriminante Linear.

Análise de Discriminante Linear – LDA

A Análise de Discriminante Linear (usualmente representada pela sigla LDA, do inglês *Linear Discriminant Analysis*) é uma técnica que se baseia nas variâncias dos conjuntos de vetores. Imaginando-se que os vetores associados ao problema sejam, originalmente, pontos, rotulados quanto a suas classes, em um espaço de N dimensões, sendo N o número de componentes de cada vetor; a LDA identifica a chamada direção principal para representação dos vetores como sendo aquela na qual a razão entre a variância entre classes e a variância intraclasses seja máxima. A segunda direção principal é, dentre as direções ortogonais à primeira principal, a direção para a qual aquela razão é máxima. A terceira direção principal é, dentre as direções ortogonais às direções principais anteriores, aquela para a qual aquela razão é máxima e assim por diante (WELLING, 2009). Para muitos problemas comuns, apenas umas poucas direções principais iniciais são suficientes a fim de representar os pontos originais em um espaço com número reduzido de dimensões, de forma que a informação essencial para sua classificação seja preservada. As variâncias que estavam naquelas direções do espaço inicial e que são abandonadas (ou seja, as últimas direções principais) podem ser devido a ruído ou a outros fatores que não contribuem para a classificação. Quando aplicada a um conjunto de vetores de um espaço N -dimensional, a LDA fornece, como resultado, uma lista das direções principais (autovetores), acompanhadas de seus autovalores. Os autovalores indicam a importância relativa de suas correspondentes direções principais. Assim, na redução de dimensionalidade, podem-se preservar apenas as primeiras P direções principais, usando-se o critério de que os P primeiros autovalores, somados, indiquem que aquelas P primeiras direções preservam, por exemplo, 95% da informação necessária para a classificação. A LDA é, portanto,

apropriada para a tentativa de redução no número de canais a serem usados para a previsão da ocorrência de crises epiléticas. Estando identificadas as direções principais no sistema N-dimensional original, podem ser identificados os canais originais do EEG mais importantes para a classificação de janelas do EEG, para cada paciente.

Transformada Wavelet

A transformada Wavelet é uma ferramenta matemática que decompõe um sinal em uma soma de termos que consistem em cópias de uma certa função $\psi(x)$ em várias escalas (níveis de resolução) e com vários deslocamentos (MALLAT, 1989). Cada um daqueles termos é do tipo

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

em que j é um número inteiro que determina o nível de resolução do termo, n é um inteiro que determina o deslocamento temporal do termo e $c_{j,n}$ é o tamanho da projeção do sinal analisado sobre a direção definida pelo termo num espaço vetorial multidimensional. Os valores de $c_{j,n}$ são chamados de coeficientes da decomposição. Quando se aplica a transformada Wavelet a uma função do tempo, como o EEG, os coeficientes com valores mais altos de j são aqueles correspondentes à presença do padrão da forma $\psi(x)$ com maior nível de detalhe na função analisada.

Aprendizagem de Máquina e Máquinas de Vetores de Suporte

Segundo Hao (2018), algoritmos com Aprendizagem de Máquina são aqueles que usam a Estatística para identificar padrões em vastos conjuntos de dados.

Máquinas de Vetores de Suporte (ou SVM, do inglês *Support-Vector Machines*) (CORTES; VAPNIK, 1995) são um exemplo de implementação de algoritmo de Aprendizagem de Máquina.

A SVM foi concebida como um classificador de dados para duas classes. Cada um desses dados deve estar na forma de uma tupla, isto é, uma sequência ordenada contendo n números reais. Dessa forma, um dado pode ser considerado como um ponto num espaço n -dimensional. Numa fase de treino, exemplos de dados das duas classes

são apresentados à SVM, bem como lhe é informada a classe à qual pertence cada exemplo. A SVM, então, calcula, naquele espaço, o hiperplano separador ótimo entre os pontos das duas classes. É considerado ótimo o hiperplano que mantenha a máxima distância possível (máxima margem) entre ele e os pontos das duas classes mais próximos à fronteira entre elas.

Após a fase de treino, novos dados são classificados pela SVM segundo o lado em que eles estão em relação àquele hiperplano separador. O critério da máxima margem minimiza a probabilidade de erro de classificação de novos dados (que não foram usados no treino). No treino, para os casos em que não é possível se encontrar um hiperplano separador entre as classes, devido à disposição dos exemplos de treino no hiperespaço n-dimensional, esses exemplos são mapeados de forma não linear sobre um espaço com mais dimensões, para se aumentar a probabilidade de lá se encontrar o hiperplano separador. Esse mapeamento é feito por meio das chamadas funções *kernel*. Nesses casos, novos dados a serem classificados devem, também, ser mapeados sobre aquele novo espaço (CORTES; VAPNIK, 1995).

Materiais e métodos

Os sinais EEG utilizados neste trabalho foram obtidos de vários indivíduos e estão disponíveis em PHYSIONET (2010) e Shoeb (2009). Cada indivíduo é identificado pela nomenclatura ChbXX, com XX referindo-se ao seu número.

Foram selecionadas crises epiléticas no banco de dados para serem usadas na fase de treinamento do sistema e separadas as demais crises para teste, com o cuidado de se terem, para cada paciente, crises para treino e para teste. Respeitou-se a ideia de que o sistema deve ser testado, a cada vez, recebendo dados do mesmo paciente para o qual foi treinado. Mas os dados de treino são sempre diferentes dos dados de teste.

As durações das janelas de EEG usadas (4 segundos) e a forma de montagem dos vetores de características a partir delas (usando a transformada Wavelet) foram aquelas apresentadas em Elgohary, Eldawlatly e Khalil (2016), por terem sido investigadas em detalhe por aqueles autores e por estarem em uso, com sucesso, em projetos do grupo de pesquisa onde este trabalho foi conduzido.

Como os sinais EEG de PHYSIONET têm 23 canais e o método de Elgohary, Eldawlatly e Khalil (2016) faz com que se obtenha um número para cada canal, cada vetor de características original, a princípio, ficou com 23 componentes. Para cada crise epilética usada no treinamento do sistema, foi aplicado o método de Bandarabadi *et al.* (2015) para a identificação da duração do período pré-ictal. Os vetores de características originais daquela crise foram, então, rotulados como pertencentes ao período interictal ou pré-ictal usando a duração encontrada pelo método. Para cada crise usada no treino, os vetores rotulados foram submetidos à LDA. Para isso, foi usada a biblioteca computacional scikit-learn (PEDREGOSA *et al.*, 2011), na linguagem Python. Como a aplicação da LDA requer um grande esforço computacional, que cresce rapidamente com o volume de dados envolvidos no cálculo, sua aplicação neste trabalho se deu por amostragem. Foram, então, escolhidos aleatoriamente alguns vetores, cujas quantidades são dadas para três pacientes na Tabela 1. Foi aplicada a LDA a eles, para a identificação das direções principais. As 23 direções originais foram classificadas em ordem de importância, da maior para a menor. Este processo foi repetido mil vezes para vetores de cada paciente, variando-se os vetores escolhidos aleatoriamente a cada vez, para se obter uma média da classificação de cada direção dentre as 23.

Tabela 1 — Quantidade de vetores escolhidos aleatoriamente comparado com o total de vetores⁶

Crise	Chb01		Chb02		Chb05	
	Escolhidos	Total	Escolhidos	Total	Escolhidos	Total
1	650	749	750	843	90	105
2	250	367	NU	NU	NU	NU
3	NU	NU	25	33	450	580
4	NU	NU	NU	NU	500	613
5	350	430	NU	NU	450	587

Fonte: Autores

⁶ “NU” indica “não utilizado”, devido ao fato de a crise não ser compatível com crises usadas no treino da SVM (conforme explicado na seção Resultados).

A partir desse ponto, testes de classificação de janelas de EEG que não foram usadas no treino foram feitos em duas versões: com vetores completos (23 componentes originais) e com vetores reduzidos. A classificação foi realizada usando-se Máquinas de Vetores de Suporte, comumente usadas nesse tipo de trabalho e implementadas na biblioteca LIBSVM (CHANG; LIN, 2011).

Resultados

Os resultados dos cálculos para a identificação das direções principais usando LDA, para os três pacientes de Physionet, estão na Tabela 2. Ela mostra a média da classificação de cada canal (direção) dentre os 23 canais originais. Quanto mais baixo for o valor da classificação, maior é a importância do canal. Por exemplo, para o paciente Chb01, vê-se que o canal 7 é o mais importante para se detectar se o estado é o interictal ou o pré-ictal, já que sua média de classificação foi 1,0 (primeiro colocado).

Tabela 2 — Média da classificação (importância) de cada canal dentre os 23 canais originais, obtida por meio de LDA

canal	Média de classificação		
	Chb01	Chb02	Chb05
1	11,49	20,12	20,08
2	13,30	1,00	3,67
3	16,31	5,88	21,59
4	8,33	18,99	22,51
5	6,00	21,94	10,90
6	22,12	9,01	16,27
7	1,00	14,36	8,31
8	7,82	10,98	9,40
9	22,76	6,36	16,02
10	13,71	2,00	11,54

11	3,00	3,00	15,97
12	21,11	23,00	2,00
13	17,88	8,00	5,08
14	4,90	4,12	13,82
15	4,10	12,59	7,00
16	2,00	16,61	3,33
17	19,92	20,49	8,80
18	15,85	17,36	17,73
19	16,27	5,64	21,63
20	18,76	17,49	13,18
21	7,85	14,50	19,15
22	10,72	10,01	1,00
23	10,79	12,55	7,04

Fonte: Autores

Nos experimentos realizados neste trabalho, verificou-se que, para alguns pacientes, uma SVM treinada usando-se vetores de períodos interictal e pré-ictal anteriores a uma crise obtinha alta acurácia na classificação de vetores anteriores a outras crises do mesmo paciente. Nestes casos, essas crises foram aqui chamadas de “crises compatíveis entre si”. Para outros pacientes, no entanto, não foram encontradas crises compatíveis entre si, ou seja, uma SVM treinada usando-se vetores anteriores a uma crise de um desses pacientes obtinha baixa acurácia ao tentar classificar vetores anteriores a outras crises dele. Estes casos foram marcados como NU (“não utilizado”) na Tabela 1. A Tabela 3 apresenta os quatro melhores canais (correspondentes às quatro primeiras direções principais) para cada paciente do Physionet para os quais foram encontradas crises compatíveis. Para aqueles pacientes, a Tabela 4 mostra as acurácias na classificação de vetores para crises compatíveis, em duas versões: “normal”, em que foram mantidos dados dos 23 canais originais nos vetores, e “reduzido”, em que foram mantidos somente os dados dos quatro melhores canais identificados pela LDA.

Tabela 3 — Pacientes com crises compatíveis e melhores canais

Paciente	Canal A	Canal B	Canal C	Canal D
Chb01	C3-P3	C4-P4	T8-P8	P8-O2
Chb02	F7-T7	F4-C4	C4-P4	F8-T8
Chb05	F7-T7	P4-O2	P8-O2	FT10-T8

Fonte: Autores

Tabela 4 — Comparação da média de acurácia entre vetores normais e reduzidos para três pacientes do banco de dados

	Chb01		Chb02		Chb05	
Crise	Normal	Reduzido	Normal	Reduzido	Normal	Reduzido
1	99%	97%	90%	89%	97%	95%
2	97%	83%	NU	NU	NU	NU
3	NU	NU	95%	90%	94%	70%
4	NU	NU	NU	NU	99%	95%
5	99%	98%	NU	NU	99%	94%

Fonte: Autores

Conclusão

Verificou-se experimentalmente que, com o método aqui utilizado, mesmo mantendo-se os 23 componentes originais dos vetores, uma SVM treinada se usando vetores de períodos interictal e pré-ictal anteriores a uma crise de um paciente nem sempre obtém alta acurácia na classificação de vetores anteriores a outras crises do mesmo paciente. As crises para as quais se obteve alta acurácia no processo de treino e teste foram aqui chamadas de “crises compatíveis entre si”. Para alguns pacientes, não foram encontradas crises compatíveis entre si.

Para as crises compatíveis entre si, verificou-se que uma redução no número de canais de 23 para apenas 4 causou, no pior caso, uma redução de 94% para 70% na acurácia na classificação. Como era esperado, devido à grande redução no número de canais, houve perda de acurácia em todos os casos testados. Mas, na maioria dos casos,

essa perda foi muito menor do que a do pior caso, conforme a Tabela 4. Em vários casos, mesmo após a redução de 23 para 4 canais, a acurácia manteve-se acima de 90%.

Verificou-se, na Tabela 3, que o conjunto dos 4 melhores canais variou entre os pacientes. Isso dificulta a construção de um aparelho padrão a ser usado por todos os pacientes. Uma alternativa para a continuação deste trabalho e para obtenção desse aparelho padrão seria que se escolhesse um conjunto uniforme, dentre todos os conjuntos possíveis formados por 4 canais, de forma que a pior acurácia dentre as de todos os pacientes fosse a maior possível nessa condição. Outra possibilidade seria que se admitisse o uso de mais do que 4 canais, escolhendo-se um subconjunto maior dentre os canais indicados na Tabela 3, contendo os melhores canais de vários pacientes.

Referências

BANDARABADI, M. *et al.* On the proper selection of preictal period for seizure prediction. **Epilepsy & Behavior**, [s. l.], v. 46, p. 158-166, 2015.

CHANG, C-C.; LIN, C. LIBSVM: A library for support vector machines. **ACM transactions on intelligent systems and technology**, [s. l.], v. 2, n. 3, p. 1- 27, 2011.

CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, v. 20, n. 3, p. 273-297, 1995.

ELGOHARY, S.; ELDAWLATLY, S.; KHALIL, M. I. Epileptic seizure prediction using zero-crossings analysis of EEG wavelet detail coefficients. *In*: IEEE CONFERENCE ON COMPUTATIONAL INTELLIGENCE IN BIOINFORMATICS AND COMPUTATIONAL BIOLOGY (CIBCB), 2016, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2016. p. 1-6.

EPILEPSY FOUNDATION. **Epilepsy**. [S. l.]: Epilepsy Foundation, c2019. Disponível em: <https://www.epilepsy.com/>. Acesso em: 18 abr. 2019.

FREE SOFTWARE FOUNDATION. **GSL**: GNU Scientific Library. Versão 2. 5. [S. l.]: Free Software Foundation, c2009. Disponível em: <https://www.gnu.org/software/gsl/>. Acesso em: 19 abr. 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**, [s. l.], v. 123, n. 10, p. 1906-1916, 2012.

GADHOUMI, K. *et al.* Seizure prediction for therapeutic devices: A review. **Journal of Neuroscience Methods**, [s. l.], v. 260, p. 270-282, 2016.

GUTTAG, J. V. *et al.* **Method and apparatus for reducing the number of channels in an EEG-based epileptic seizure detector**. U.S. Patent Application n. 12/196,690, 26 mar. 2009.

HAO, K. What is Machine Learning?. **MIT Technology Review**, [s. l.], 17 nov. 2018. Disponível em: <https://www.technologyreview.com/2018/11/17/103781/what-is-machine-learning-we-drew-you-another-flowchart/>. Acesso em: 1 jul. 2020.

KITANO, L. A. S. *et al.* Epileptic seizure prediction from EEG signals using unsupervised learning and a polling-based decision process. In: **ARTIFICIAL NEURAL NETWORKS AND MACHINE LEARNING – ICANN 2018**, 27., 2018, Rhodes. **Anais [...]**. Rhodes: Springer International Publishing, 2018. v. 2, p. 117-126.

LIANG, J. *et al.* Predicting seizures from electroencephalography recordings: A knowledge transfer strategy. In: **IEEE INTERNATIONAL CONFERENCE ON HEALTHCARE INFORMATICS (ICHI)**, 2016, Chicago. **Anais [...]**. Chicago: IEEE, 2016. p. 184-191.

MALLAT, S. G. A theory for multiresolution signal decomposition: the wavelet representation. **IEEE Transactions on Pattern Analysis & Machine Intelligence**, [s. l.], v. 11, n. 7, p. 674–693, 1989.

MALMIVUO, J.; PLONSEY, R. In: MALMIVUO, J.; PLONSEY, R. Electroencephalography. **Bioelectromagnetism: principles and applications of bioelectric and biomagnetic fields**. New York: Oxford University Press, 1995. cap. 13, p. 257-264. Disponível em: <http://www.bem.fi/book/13/13.htm#03>. Acesso em: 18 abr. 2019.

MAYO FOUNDATION FOR MEDICAL EDUCATION AND RESEARCH. **EEG (electroencephalogram)**. [S. l.]: Mayo Foundation for Medical Education and Research, 2019. Disponível em: <https://www.mayoclinic.org/tests-procedures/eeg/about/pac-20393875>. Acesso em: 18 abr. 2019.

MULA, M.; MONACO, F. Ictal and peri-ictal psychopathology. **Behavioural Neurology**, [s. l.], v. 24, n. 1, p. 21-25, 2011.

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**, v. 24, n. 1, p.158-168, 2016.

PEDREGOSA, F. *et al.* Scikit-learn: machine learning in Python. **Journal of Machine Learning Research**, [s. l.], v. 12, p. 2825-2830, 2011.

PHYSIONET. **CHB-MIT Scalp EEG Database**. Versão 1. 0. 0. [S. l.]: Physionet, 2010. Disponível em: <https://physionet.org/content/chbmit/1.0.0/>. Acesso em: 19 abr. 2019.

SEECK, M. *et al.* The standardized EEG electrode array of the IFCN. **Clinical Neurophysiology**, [s. l.], v. 128, n. 10, p. 2070-2077, 2017.

SHOEB, Ali Hossam. **Application of Machine Learning to Epileptic Seizure onset detection and treatment**. 2009. Tese (Doutorado em Filosofia em Engenharia Elétrica e Médica) —Massachusetts Institute of Technology, Cambridge, 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**, [s. l.], v. 257, p. 45-54, 2016.

TRUONG, N. D. *et al.* Convolutional neural networks for seizure prediction using intracranial and scalp electroencephalogram. **Neural Networks**, [s. l.], v. 105, p. 104-111, 2018.

WELLING, M. **Fisher Linear Discriminant Analysis**. [S. l.]: Welling, 2009. Disponível em <https://www.ics.uci.edu/~welling/teaching/273ASpring09/Fisher-LDA.pdf>. Acesso em: 19 abr. 2019.

WORLD HEALTH ORGANIZATION. Epilepsy. **World Health Organization**, [s. l.], 2 fev. 2019. Disponível em <https://www.who.int/news-room/fact-sheets/detail/epilepsy>. Acesso em: 18 abr. 2019.

INFLUENCE OF THE REDUCTION IN THE NUMBER OF EEG CHANNELS IN EPILEPTIC SEIZURES PREDICTION BASED ON SUPPORT VECTOR MACHINES

ABSTRACT

Epilepsy is one of the most common neurological diseases in the world. It is characterized by crises caused by disturbances in the brain's electrical activity, which is measured in the form of the so-called electroencephalogram (EEG), normally using more than 20 channels. There is great interest in the development of systems for predicting the occurrence of crises to be used by patients. However, a device would only become viable if it were small, light and barely noticeable to others. As a result, this work investigates a way to reduce the amount of EEG channels without affecting the quality of the prediction of an epileptic seizure. Based on Linear Discriminant Analysis (LDA) technique, it was possible to reduce the number of channels from 23 to just 4, maintaining the accuracy of the classification system, which consists of Support Vector Machines (SVM), above 90% for the most cases evaluated. It was also found that patients may present crises incompatible with each other, which makes it difficult, in these cases, to predict a seizure even with the use of all EEG channels.

Keywords: *Epilepsy; Prediction; Dimensionality reduction; Linear Discriminant Analysis; Support-Vector Machines.*

Envio: julho/2020
Aceito para publicação: agosto/2020