

APLICAÇÃO DE MÁQUINA DE VETORES DE SUPORTE EM MODO REGRESSÃO À PREVISÃO DE SURTOS EPILEPTICOS

APPLICATION OF SUPPORT VECTOR MACHINE IN REGRESSION MODE TO EPILEPTIC SEIZURES PREDICTION

Aliny Garcia Nunes¹

Sara Dereste dos Santos²

Ricardo Pires²

RESUMO

A previsão de surtos epiléticos vem sendo amplamente estudada na engenharia com a intenção de prover maior qualidade de vida aos milhões de pacientes detentores desse distúrbio cerebral. O avanço das técnicas de aprendizagem de máquina tem contribuído para a investigação de diferentes métodos para essa finalidade. Contudo, a maioria deles concentra-se em distinguir os períodos interictal (longe do surto) e pré-ictal (próximo ao surto) a partir dos sinais de eletroencefalograma (EEG) do paciente. Mas a possível indicação de um surto a partir de um método binário é imprecisa em relação ao tempo que falta para o surto acontecer. Por essa razão, neste trabalho, é investigado um método alternativo baseado em máquinas de vetores de suporte (SVM) no modo regressão (SVR), o qual permite à máquina aprender a relação entre duas funções do tempo e indicar um valor real em sua saída associado ao tempo restante para o surto. Para isso, foram testados quatro métodos de montagem de vetores da SVR, sendo eles: amostras temporais do EEG médio; análise espectral; Wavelet Haar e Wavelet Daubechies db4. Os três primeiros apresentaram baixa correlação entre a função de previsão e a função aprendida pela SVR. O quarto método, por outro lado, obteve correlações de até 100%, indicando a capacidade da SVR prever a proximidade de um surto, porém a acurácia não foi mantida quando o método foi aplicado em outros surtos do mesmo paciente, o que requer ainda novos aperfeiçoamentos em trabalho futuro.

Palavras-chave: EEG. Epilepsia. Previsão de surtos. Regressão. SVR.

¹ Graduanda do curso de Engenharia Eletrônica. Instituto Federal de Educação, Ciência e Tecnologia de São Paulo

² Docente do Departamento de Elétrica. Instituto Federal de Educação, Ciência e Tecnologia de São Paulo e-mail: sarad@ifsp.edu.br

ABSTRACT

Epileptic seizure prediction has been widely studied in engineering intending to provide greater quality of life to the millions of patients with this brain disorder. Advanced machine learning techniques have contributed to the investigation of different methods for this purpose. However, most of them focus on distinguishing the interictal (away from the seizure) and pre-ictal (close to the seizure) periods from the patient's electroencephalogram (EEG) signals. Nevertheless, the possible indication of an outbreak from a binary method is inaccurate in relation to the time left for the crisis to happen. For this reason, the objective of this paper is to investigate an alternative method based on support vector machines (SVM) in regression mode (SVR) which allows the machine to learn the relationship between two-time functions and indicate a real value in its output associated with the time left for the seizure. Four SVR vector assembly methods were tested, namely: temporal samples of average EEG; spectral analysis; Wavelet Haar and Wavelet Daubechies db4. The first three ones showed low correlation between forecasting function and the function learned by SVR. The fourth method, on the other hand, showed correlations of up to 100%, indicating the SVR's ability to predict the proximity of a seizure, but the accuracy was not maintained when the method was applied to other seizures of the same patient, which still requires further improvements in future researches.

Keywords: EEG. Epilepsy. Seizure prediction. Regression. SVR.

¹ Graduanda do curso de Engenharia Eletrônica. Instituto Federal de Educação, Ciência e Tecnologia de São Paulo

² Docente do Departamento de Elétrica. Instituto Federal de Educação, Ciência e Tecnologia de São Paulo e-mail: sarad@ifsp.edu.br

1 INTRODUÇÃO

Um grande desafio da área médica no que tange a neurociências e neurologia é a compreensão e análise dos fatores que desencadeiam surtos em portadores de epilepsia. Muito se tem estudado, porém, os resultados não demonstram uniformidade quanto à motivação para que o cérebro passe a desencadear as descargas elétricas que são verificadas no eletroencefalograma (EEG) (KOHRMAN, 2007). Diante de tais obscuridades, a união do conhecimento médico com a engenharia aplicada pode fornecer algumas respostas e preencher lacunas que até o momento têm mantido as discussões sobre o assunto inconclusivas.

A atividade elétrica do cérebro é medida na forma do chamado eletroencefalograma (EEG), usando-se, normalmente, mais de 20 eletrodos metálicos posicionados no couro cabeludo. Essa atividade deve-se à comunicação entre células cerebrais por meio de impulsos elétricos. O EEG, então, 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, 2020).

As atividades epiléticas em pacientes diagnosticados são classificadas em: período durante o surto (ictal), período imediatamente anterior ao surto (pré-ictal), período imediatamente posterior ao surto (pós-ictal) e período entre surtos (interictal). Os períodos são acompanhados e medidos de forma a avaliar a evolução do quadro nas análises do EEG durante o tratamento medicamentoso. No entanto, não há consenso sobre a duração de cada período, principalmente para o pré-ictal, o qual pode variar de poucos minutos a várias horas, dependendo do caso (MULA; MONACO, 2011).

Na literatura, encontram-se trabalhos com o objetivo de desenvolver sistemas para 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., 2015). Dessa forma, o usuário de um tal sistema seria advertido quando ocorresse a entrada de seu sinal EEG no período pré-ictal.

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 de análise espectral (Fourier (OPPENHEIM; SCHAFER, 2009), método de Welch (WELCH, 1969) ou 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 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).

Usman et al. (2019) fizeram um levantamento de trabalhos nesta área. Eles relataram que vários daqueles trabalhos incluíram uma etapa de pré-processamento do sinal EEG para a remoção de ruído. Uma das formas citadas de pré-processamento é a conversão de múltiplos canais de EEG em um único canal equivalente, por meio do cálculo do valor médio dos canais originais.

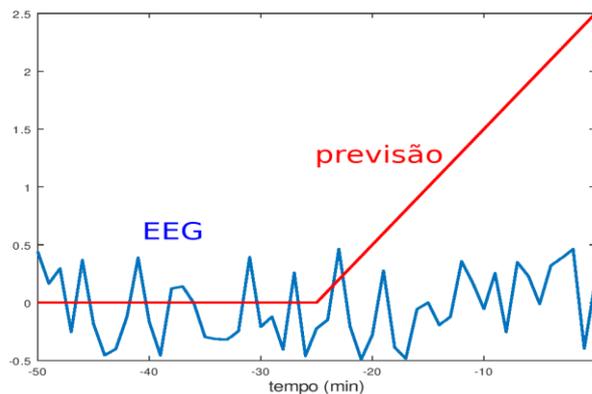
Na maioria daqueles trabalhos sobre previsão da ocorrência de surtos, o período pré-ictal é definido arbitrariamente como tendo uma certa duração, como, por exemplo, uma hora ou meia-hora. Uma exceção é o trabalho de Bandarabadi et al. (2015), em que se define o período pré-ictal como tendo características 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, indo de 5 minutos até 173 minutos nos experimentos realizados. Com isso, um sistema que advertisse seu usuário da entrada do sinal EEG no período pré-ictal seria útil, mas sua previsão teria grande incerteza quanto ao tempo restante até o surto.

Diferentemente do critério usado naqueles trabalhos, neste projeto, propõe-se investigar o uso de aprendizado de máquina de forma a, partindo-se de sinais EEG, fornecer uma indicação numérica relacionada a quanto tempo falta para a ocorrência do próximo surto, ao invés de indicar simplesmente em qual período de atividade cerebral está o sinal (interictal ou pré-ictal). Para isto, ao invés de se usar um sistema de aprendizado de máquina como classificador, o sistema será usado no modo regressão.

Uma análise de regressão simples estima a relação entre uma variável dependente e uma variável independente. Sistemas de aprendizado de máquina, no modo regressão, podem aprender a relação entre vetores e números reais (WANG et al., 2010). Neste trabalho, o objetivo é estimar a relação entre cada sinal do EEG e uma função linear do tempo que indicaria quanto tempo falta para ocorrer o próximo surto epiléptico, conforme a Figura 1. Assim, em períodos distantes do próximo surto, a função de previsão permaneceria com valor zero. Na

proximidade de um surto, o valor da função subiria continuamente. Quanto mais alto o valor da função, mais iminente estaria o próximo surto. Na literatura, não foi encontrado trabalho com proposta semelhante.

Figura 1. Sinal EEG hipotético (em azul) e função relacionada a quanto tempo falta para o próximo surto (em vermelho). O eixo do tempo apresenta uma espécie de contagem regressiva, em que o zero é o instante de início de um surto. Quanto mais iminente estiver o próximo surto, maior será o valor da função de previsão.



Fonte: Próprios Autores. 2021

Assim, o sistema terá de aprender a relação entre funções do tempo. Um modelo de aprendizado apropriado para esse uso é a Máquina de Vetores de Suporte (em inglês, *Support-Vector Machine*, SVM), no modo regressão (em inglês, *Support-Vector Regression*, SVR). A SVM foi concebida como um classificador (CORTES; VAPNIK, 1995) e adaptada posteriormente para uso também em regressão (DRUCKER et al., 1997). Como classificador, ela passa por uma fase de aprendizado, em que lhe são apresentados exemplos de vetores de dados e lhe são informadas suas classes correspondentes. Após o aprendizado, ela passa a inferir as classes às quais devem pertencer novos vetores que lhe forem apresentados. No modo regressão, na fase de aprendizado, são-lhe apresentados exemplos de vetores, cada um acompanhado de um valor real. A SVR aprende a relação, se houver, entre aqueles vetores e aqueles valores e, após o aprendizado, torna-se capaz de inferir um valor adequado para cada novo vetor que lhe for apresentado. Para aprender a relação entre duas funções do tempo, $x(t)$ e $y(t)$, a SVR poderá receber muitos vetores formados por subsequências contínuas de amostras destas funções e, para cada um destes vetores, deverá receber o valor da amostra de $y(t)$ que é gerada em resposta àquelas subsequências. Cada um destes vetores para aprendizado pode ter a forma:

$$(x_i, x_{i-1}, x_{i-2}, x_{i-3}, \dots, y_{i-1}, y_{i-2}, y_{i-3}, \dots) \quad (1)$$

em que os x_i e y_i são amostras das subsequências de $x(t)$ e de $y(t)$, respectivamente, e o índice i representa a posição (tempo) da amostra na subsequência. O número de elementos (tamanho das subsequências) é escolhido pelo usuário. No aprendizado, para cada vetor dessa forma, é apresentado o valor da amostra correspondente y_i de $y(t)$. Isso permite que a SVR consiga modelar o sistema ou processo que gera $y(t)$ a partir de $x(t)$. Ou seja, se for possível, a SVR aprende a generalizar o comportamento do sistema após ter conhecido muitos exemplos de correspondência entre y_i , amostras anteriores de $y(t)$ e amostras de $x(t)$ da mesma janela temporal, para muitas janelas temporais. Tanto a SVM quanto a SVR, no processo de aprendizado, podem usar uma chamada função *kernel*, para mapear o problema em questão para um espaço contendo mais dimensões do que o original, aumentando, com isso, a probabilidade de se encontrar uma solução (CORTES; VAPNIK, 1995). Na montagem dos vetores, em lugar de amostras diretas x_i do sinal $x(t)$, podem ser usados os chamados vetores de características, obtidos a partir de trechos de $x(t)$. Usman et al. (2019) apresentam vários métodos para a montagem desses vetores a partir de janelas temporais de sinais de EEG.

Além de fornecer à medicina ferramentas auxiliares nas análises neurológicas, é objetivo principal do projeto permitir a pacientes que sofrem de epilepsia, a possibilidade de ser informados sobre o tempo de antecedência ao próximo surto, com o propósito de evitar os grandes transtornos resultantes de surtos imprevistos, buscando um local adequado para se proteger, procurar auxílio médico ou até mesmo tomar um medicamento prescrito, que tenha a finalidade de minimizar ou anular os efeitos do surto.

2 METODOLOGIA E RESULTADOS

Nas subseções a seguir, é apresentado o banco de dados de sinais EEG de pacientes de epilepsia usado neste trabalho, são descritas as formas de montagem de vetores para a SVR e é apresentada a metodologia para seu treinamento e teste. A metodologia e os resultados estão numa única seção porque decisões de metodologia foram tomadas em função de resultados parciais obtidos. A implementação computacional de SVR usada neste trabalho foi a da biblioteca libsvm (CHANG; LIN, 2011), em linguagem de programação C++.

2.1 Banco de Dados

O banco de dados público Physionet CHB-MIT Scalp EEG Database, criado pelo Hospital Pediátrico de Boston, foi utilizado neste trabalho (SHOEB, 2009). Este conjunto de dados inclui registros de EEG do escalpo de crianças e adolescentes com epilepsia, que foram monitorados por vários dias após a retirada de medicamentos. Todos os sinais EEG foram amostrados em 256 Hz com resolução de 16 bits, gravados, em sua maioria, em 23 canais. O sistema internacional 10-20 foi usado para o posicionamento dos eletrodos do EEG e para a nomenclatura dos canais. Os sinais do paciente chb01 foram empregados ao longo deste projeto.

2.2 Montagem de Vetores: Primeira Forma, Amostras Temporais do EEG Médio

Os vetores montados para treino e teste da SVR seguem o formato dado na expressão (1) na Introdução. Como forma de pré-processamento, foi usada sempre aqui a conversão de múltiplos canais de EEG em um único canal equivalente, por meio do cálculo do valor médio dos canais originais. Um motivo para isso é a redução do custo computacional, em relação à montagem de vetores diretamente a partir de mais de 20 canais.

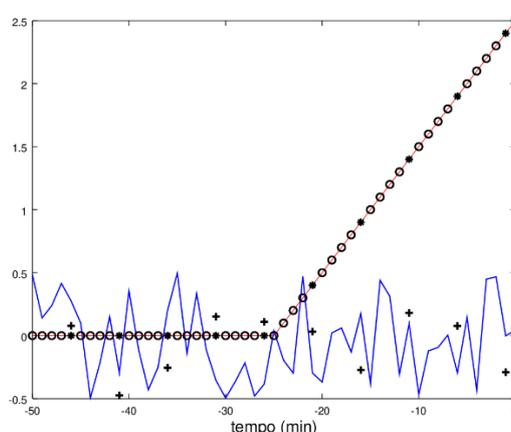
A forma mais simples para a montagem dos vetores neste trabalho, aqui chamada de primeira forma, é aquela em que os x_i são uma sequência de valores de amostras do EEG médio, obtidas diretamente no domínio do tempo, e em que não são usados, nos vetores, valores y_{i-k} previstos em passos anteriores. Nessa forma de montagem, ainda foram feitos experimentos em que os vetores passaram por um ajuste de escala, de forma a restringir cada um dos seus componentes a ocupar uma faixa de valores entre -1 e +1 (CHANG; LIN, 2011).

Arbitrariamente, decidiu-se inicialmente que cada vetor teria 20 amostras seguidas do canal médio do EEG. Em cada experimento, usando-se arquivos do paciente 01 que contivessem um surto, foram montados 1000 vetores, uniformemente distribuídos desde o início do arquivo até o início do surto. (No sinal de EEG médio, dessa forma, ficam intervalos não utilizados entre as janelas temporais de onde foram extraídos os vetores.)

No método proposto, além de haver liberdade na escolha do número de amostras por vetor, há liberdade na escolha do instante de início da subida da rampa de previsão da Figura 1, a ser aprendida pelo sistema. Nos primeiros experimentos, decidiu-se que essa rampa começaria a subir já no início do período analisado, ou seja, sem que houvesse o patamar constante em zero na função de previsão.

Em seguida, foi executado o treinamento da SVR, usando-se o programa *svm-train* da *libsvm*, entregando-se a ele aquele conjunto de vetores e definindo-se como rótulo para cada vetor um número proporcional à posição daquele vetor no tempo, dentro do período de EEG considerado (FIGURA 1). O treinamento pelo *svm-train* foi executado no modo de validação cruzada, com cinco partições. Dessa forma, ele foi executado cinco vezes, em cada vez usando $\frac{4}{5}$ dos vetores (800 vetores) e seus rótulos para aprendizado e aplicando-se, em seguida, sobre os vetores restantes ($\frac{1}{5}$, 200 vetores para teste), a SVR assim treinada, para se medir sua acurácia. Esta é medida na forma de correlação entre a sequência de rótulos esperados e a sequência de rótulos obtidos pela SVR treinada. Quando há perfeita coincidência entre os dois conjuntos de rótulos, essa correlação vale 1 (100%). No caso extremo oposto, quando não há aprendizado, a correlação vale 0. No processo de validação cruzada, obtém-se uma média das correlações calculadas (FIGURA 2). Nela, os círculos abertos correspondem aos pontos usados no treinamento da SVR e correspondem, portanto, ao maior conjunto de vetores disponíveis. Já os símbolos * e + indicam os pontos obtidos no teste de classificação da SVR durante a validação cruzada, utilizando-se os demais vetores. Os casos de alta correlação foram exemplificados com o símbolo * enquanto os casos com baixa correlação aparecem com o símbolo +. Esse processo de buscar uma correlação entre o sinal de EEG e o tempo restante para o surto foi investigado a partir de um único surto do paciente chb01. Além disso, esse experimento foi realizado tanto sem a aplicação de ajuste de escala aos vetores como com sua aplicação.

Figura 2: Exemplo de funcionamento do processo de validação cruzada a partir de um sinal hipotético de EEG (azul) e da função de previsão do tempo para o surto (vermelho). Círculos abertos correspondem aos pontos usados no treinamento da SVR. O símbolo * equivale ao teste da SVR com alta correlação enquanto o símbolo + equivale ao teste da SVR com baixa correlação.



As duas primeiras linhas da Tabela 1 mostram que, para vetores contendo, cada um, 20 amostras do EEG médio, com ou sem ajuste de escala nos vetores, sem o uso de amostras de saída anteriores nos vetores, com a rampa de previsão se iniciando no instante 0 (inicial) do período, a correlação obtida na validação cruzada foi próxima de 0, ou seja, a SVR não conseguiu aprender uma relação entre os instantes dos vetores e a rampa de previsão. O programa *svm-train* foi aplicado usando-se seus parâmetros padrão, incluindo-se o uso do *kernel* RBF (CORTES; VAPNIK, 1995).

Tabela 1. Resultados de experimentos usando a primeira forma de montagem de vetores.

Montagem dos vetores	Ajuste de escala	Núm. amostras de saída anteriores	Início da rampa	Correlação (valid. cruzada)
20 amostras no tempo		0	0	0,0082
20 amostras no tempo	x	0	0	0,0373
256 amostras no tempo		0	0	0,0082
256 amostras no tempo	x	0	0	0,0071

Fonte: Próprios Autores. 2021

Como há parâmetros a serem ajustados quando da aplicação de uma SVR (DRUCKER et al., 1997), todos eles disponibilizados no programa *svm-train* da *libsvm*, foram feitos novos experimentos, variando-se os valores desses parâmetros. No caso do *kernel* RBF, esses parâmetros são chamados de *epsilon* e *gamma*. Várias combinações de valores foram tentadas para eles, percorrendo várias ordens de grandeza, mas os resultados de correlação na validação cruzada permaneceram próximos a 0, similares aos dois resultados reportados nas duas primeiras linhas da Tabela 1.

Dado o insucesso no aprendizado usando-se vetores contendo 20 amostras temporais de EEG por vetor, foram realizados novos experimentos, agora montando-se vetores contendo 256 amostras temporais cada um. Os resultados para a correlação, usando-se validação cruzada com cinco partições e parâmetros padrão para o programa *svm-train*, com e sem ajuste de escala nos vetores, estão nas duas últimas linhas da Tabela 1. Vê-se que, novamente, a correlação ficou próxima a 0. Isso se repetiu em experimentos em que se variaram os valores dos parâmetros para o programa *svm-train*.

Não foram tentados experimentos usando-se outras funções de *kernel*, porque, usualmente, o *kernel* RBF, dentre os *kernels* mais comuns, é um dos que, usualmente, proporcionam os melhores resultados, o que faz com que ele seja o padrão no programa *svm-train* (HSU; CHANG; LIN, 2016). Ao invés disso, variou-se a forma de montagem de vetores, conforme a seção a seguir.

2.3 Montagem de Vetores: Segunda Forma, por Análise Espectral

A segunda forma de montagem de vetores os obteve por meio da análise espectral de cada janela temporal contendo 256 amostras da média dos canais de EEG usada no experimento anterior, forma esta apresentada em alguns dos trabalhos citados na introdução. Aqui, foi usado o método de Welch para a estimação de densidade espectral, implementado em linguagem Python na biblioteca scipy (VIRTANEN, 2020). O próprio método de Welch subdivide cada janela e obtém a média dos periodogramas dessas subjanelas (WELCH, 1969). Aqui, decidiu-se subdividir cada janela contendo 256 amostras em subjanelas contendo 16 amostras cada uma. Isso faz com que se tenha, neste caso, um bom compromisso entre a resolução da análise espectral (16 raias) e o número de periodogramas participantes de cada média ($256/16=16$ periodogramas).

Usando-se esses vetores, foi executado, então, o processo de treinamento e de teste da SVR com validação cruzada, como na subseção anterior (TABELA 2). Vê-se que, novamente, a correlação ficou muito baixa.

Tabela 2. Resultados de experimentos usando a segunda forma de montagem de vetores.

Montagem dos vetores	Ajuste de escala	Núm. amostras de saída anteriores	Início da rampa	Correlação (valid. cruzada)
pwelch, subjanela 16		0	0	0,0017
pwelch, subjanela 16	x	0	0	0,0369

Fonte: Próprios Autores. 2021

2.4 Montagem de Vetores: Terceira Forma, por Wavelet Haar

A terceira forma de montagem de vetores os obteve por meio da aplicação da transformada wavelet a cada janela temporal contendo 256 amostras da média dos canais de EEG usada nos experimentos anteriores. Cada vetor consistiu na sequência de coeficientes de detalhe da wavelet Haar. Eles foram obtidos por programa em Python usando a biblioteca PyWavelets (LEE, 2019). Na literatura, um exemplo de trabalho em que foram usados esses coeficientes é o de Elgohary; Eldawlatly; Khalil (2016).

Usando-se esses vetores, foi executado, então, o processo de treinamento e de teste da SVR com validação cruzada, como nas subseções anteriores (TABELA 3). Vê-se que, novamente, a correlação ficou muito baixa.

Tabela 3. Resultados de experimentos usando a terceira forma de montagem de vetores.

Montagem dos vetores	Ajuste de escala	Núm. amostras de saída anteriores	Início da rampa	Correlação (valid. cruzada)
wavelet Haar detalhe		0	0	0,0121
wavelet Haar detalhe	x	0	0	0,0073

Fonte: Próprios Autores. 2021

2.5 Montagem de Vetores: Quarta Forma, por Wavelet Daubechies db4

A quarta forma de montagem de vetores também os obteve por meio da aplicação da transformada wavelet a cada janela temporal contendo 256 amostras da média dos canais de EEG usada nos experimentos anteriores. Mas, nesta vez, cada vetor consistiu na sequência de coeficientes de detalhe da *wavelet Daubechies db4*. Eles foram obtidos por programa em Python usando a biblioteca *PyWavelets* (LEE et al., 2019). Na literatura, um exemplo de trabalho em que foram usados esses coeficientes é o de Indiradevi et al. (2008), com a justificativa de que a forma de onda db4 é semelhante à forma de eventos em EEG relacionados à epilepsia.

Usando-se esses vetores, foi executado, então, o processo de treinamento e de teste da SVR com validação cruzada, como nas subseções anteriores. Os resultados estão na Tabela 4.

Na primeira linha da Tabela 4, vê-se que a correlação, embora ainda baixa, foi muito superior às obtidas anteriormente em condições similares. Por isso, ao invés de se partir, como nos casos anteriores, para mais uma forma de montagem de vetores, decidiu-se continuar a explorar esta forma, com wavelet db4, variando-se outros parâmetros dos experimentos.

A segunda linha da Tabela 4 mostra o resultado de experimento no qual foi usado ajuste de escala nos vetores e no qual, pela primeira vez, usou-se uma saída anterior na montagem dos vetores. É o y_{i-1} da expressão (1). Dessa forma, no aprendizado, cada vetor contém um elemento indicando o resultado de previsão desejado para a janela anterior. Outro parâmetro modificado foi o de início da rampa, ajustado para 0,5. Isso significa que a curva a ser aprendida (FIGURA 1) permanece em zero nos primeiros 50% do tempo do experimento e sobe a partir de zero nos últimos 50%. Isso levou a uma correlação de cerca de 27% na validação cruzada, resultado significativamente diferente de zero, ao contrário daqueles dos experimentos das subseções anteriores. Na terceira linha de resultados da Tabela 4, vê-se que ajustando-se o momento de início da rampa da Figura 1 para 70% do tempo do experimento, a correlação sobe para cerca de 99%. Ela sobe ainda um pouco mais quando o início da rampa é ajustado para 90 (TABELA 4).

Tabela 4. Resultados de experimentos usando a quarta forma de montagem de vetores.

Montagem dos vetores	Ajuste de escala	Núm. amostras de saída anteriores	Início da rampa	Correlação (valid. cruzada)
wavelet db4 nív. 5 (detalhe)		0	0	0,0858
wavelet db4 nív. 5 (detalhe)	x	1	0,5	0,2718
wavelet db4 nív. 5 (detalhe)	x	1	0,7	0,9901
wavelet db4 nív. 5 (detalhe)	x	1	0,9	0,9968
wavelet db4 nív. 5 (detalhe)	x	3	0,5	0,7284
wavelet db4 nív. 5 (detalhe)	x	3	0,7	0,9952
wavelet db4 nív. 5 (detalhe)	x	3	0,9	0,9967
wavelet db4 nív. 5 (detalhe)	x	5	0,5	0,8659
wavelet db4 nív. 5 (detalhe)	x	5	0,7	0,9952
wavelet db4 nív. 5 (detalhe)	x	5	0,9	0,9965
wavelet db4 nív. 5 (detalhe)	x	10	0,5	0,9484
wavelet db4 nív. 5 (detalhe)	x	10	0,7	0,9946
wavelet db4 nív. 5 (detalhe)	x	10	0,9	0,9953

Fonte: Próprios Autores. 2021

Novos experimentos foram realizados (TABELA 4), variando-se o número de amostras de saída anteriores a serem incorporadas aos vetores e variando-se o momento do início da rampa. Vê-se que, para vários ajustes nesses parâmetros, a correlação se aproximou de 100%. Diante destes resultados procurou-se investigar a reprodutibilidade do método em novos surtos do paciente chb01. Como explicado anteriormente, todo o processo de validação cruzada foi feito para amostras do EEG anteriores a um único surto. Em uma aplicação real, espera-se que a SVR consiga, após o seu treinamento, identificar a mudança nas características do EEG que indiquem a proximidade de um novo surto. Assim, para a última SVR treinada, foram apresentados vetores referentes a surtos diferentes do mesmo paciente. O resultado, no entanto, apresentou baixa correlação em todos os casos. Isso significa que, apesar da alta correlação obtida em diversos casos da Tabela 4, quando um novo vetor montado a partir de janelas anteriores a surtos diferentes daquele usado no treino, a SVR não foi capaz de prever a saída adequadamente.

3 CONSIDERAÇÕES FINAIS

Neste trabalho, procurou-se explorar um novo método de previsão de surtos epiléticos baseado em máquinas de vetores de suporte no modo regressão. O uso da regressão para tal finalidade não tem sido explorado na literatura, o que motivou sua investigação. Uma vez que a maioria dos trabalhos de previsão atua na identificação da transição entre os períodos interictal e pré-ictal, buscou-se uma alternativa, através da SVR, que pudesse fornecer ao usuário desse

sistema um valor real que indicasse quão distante ele estaria de um possível surto. Para essa investigação foram analisados diferentes métodos de montagem de vetores de características extraídos a partir dos sinais de EEG. Esses são os vetores de entrada da SVR. Ao todo foram estudados quatro métodos distintos de montagem de vetores de características e, destes, três não apresentaram boa correlação: amostras temporais do EEG médio, análise espectral e o *Wavelet Haar*. O quarto e último método, baseado em características extraídas a partir da *Wavelet Daubechies db4*, apresentou correlações variadas desde apenas 8% até 100%, dependendo de ajustes da SVR tais como o número de amostras de saída anteriores incorporadas aos vetores e o momento do início da rampa. Este último mostrou-se de grande relevância no aumento da correlação, o que indica que a SVR tem maior facilidade de encontrar sua função de previsão quando se está próximo do surto. Porém, isso implica que o alerta emitido ao usuário poderia acontecer muito próximo do evento, o que invalida a proposta inicial. Apesar disso, todas as SVR treinadas que apresentaram alta correlação na validação cruzada foram testadas com novos vetores referentes a surtos distintos do mesmo paciente. No entanto, os resultados de correlação foram baixos, indicando que a SVR se ajustou muito bem apenas para o surto em que foi treinada. Portanto, novas investigações e aperfeiçoamentos deverão ser realizados em trabalho futuro.

REFERÊNCIAS

- BANDARABADI, M. et al. On the proper selection of preictal period for seizure prediction. *Epilepsy & Behavior*, Elsevier, v. 46, p. 158–166, 2015.
- 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.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, Springer, v. 20, n. 3, p. 273–297, 1995.
- DRUCKER, Harris et al. Support vector regression machines. *Advances in neural information processing systems*, v. 9, p. 155-161, 1997.
- 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). p. 1–6. 2016
- 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.

HSU, C. W.; CHANG, C. C.; LIN, C. J. A Practical Guide to Support Vector Classification. National Taiwan University, Taipei 106, Taiwan. 2016. Disponível em <https://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>. Acesso em 07/04/2021.

INDIRADEVI, K. P. et al. A multi-level wavelet approach for automatic detection of epileptic spikes in the electroencephalogram. *Computers in biology and medicine*, v. 38, n. 7, p. 805-816, 2008.

KOHRMAN, Michael H. What is epilepsy? Clinical perspectives in the diagnosis and treatment. *Journal of Clinical Neurophysiology*, v. 24, n. 2, p. 87-95, 2007.

LEE, Gregory et al. PyWavelets: A Python package for wavelet analysis. *Journal of Open Source Software*, v. 4, n. 36, p. 1237, 2019.

LIANG, Jian et al. Predicting seizures from electroencephalography recordings: a knowledge transfer strategy. In: 2016 IEEE international conference on healthcare informatics (ICHI). IEEE, 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). 2021. Disponível em <https://www.mayoclinic.org/tests-procedures/eeg/about/pac-20393875>. Acesso em 17/02/2021.

MULA, M.; MONACO, F. Ictal and peri-ictal psychopathology. *Behavioural neurology*, IOS, Press, v. 24, n. 1, p. 21–25, 2011.

OPPENHEIM, Alan V.; BUCK, John R.; SCHAFER, Ronald W. Discrete-time signal processing. Vol. 2. Upper Saddle River, NJ: Prentice Hall, 2001.

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.

SHOEB, Ali Hossam. Application of machine learning to epileptic seizure onset detection and treatment. 2009. Tese de Doutorado. Massachusetts Institute of Technology.

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.

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.

USMAN, Syed Muhammad et al. Using scalp EEG and intracranial EEG signals for predicting epileptic seizures: Review of available methodologies. *Seizure*, v. 71, p. 258-269, 2019.

VIRTANEN, P. et al. SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python. *Nature Methods*, 17(3), 261-272, 2020.

WANG, Ying et al. High-dimensional pattern regression using machine learning: from medical images to continuous clinical variables. *Neuroimage*, v. 50, n. 4, p. 1519-1535, 2010.

WELCH, P. The use of fast Fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms. *IEEE Transactions on audio and electroacoustics*, IEEE, v. 15, n. 2, p. 70–73, 1967.