

## USO DE MAPAS AUTO-ORGANIZÁVEIS NA PREVISÃO DE SURTOS EPILÉTICOS COM BASE NA ANÁLISE CONTÍNUA DO EEG <sup>1</sup>

**Victor Manuel Araujo de ALMEIDA**<sup>2</sup>

Graduando em Engenharia de Controle e Automação  
IFSP/ Câmpus São Paulo

**Miguel Angelo de Abreu de SOUZA**<sup>3</sup>

Doutor em Ciências/ USP  
Docente do Departamento de Elétrica  
IFSP/ Câmpus São Paulo

**Ricardo PIRES**<sup>4</sup>

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

**Sara Dereste dos SANTOS**<sup>5</sup>

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

### RESUMO

A epilepsia é um transtorno neurológico que, geralmente, causa convulsões frequentes naqueles afetados, inibindo-os de praticar atividades que requerem atenção constante ou completo controle, como dirigir ou nadar. A predição de surtos pode conferir maior segurança a esses pacientes, alertando-os sobre surtos iminentes. Neste trabalho, uma rede neural não supervisionada conhecida como Mapa Auto-Organizável (SOM, do inglês, *Self-Organizing Maps*) é utilizada para identificar e classificar intervalos dos sinais de Eletroencefalograma (EEG) de forma contínua com o objetivo de produzir um método de detecção de surtos de forma antecipada. Isso implica na distinção de características presentes nos sinais de EEG à medida que uma crise se aproxima. Os dados são pré-processados utilizando a transformada de *Wavelet* e usados para treinar um SOM. Três diferentes topologias de mapas são avaliadas assim como três diferentes quantidades de dados de treino. O método foi investigado em diferentes pacientes do banco de dados público *Physionet* - CHB-MIT e, nos melhores casos, obteve-se acurácia de 98,9%, sensibilidade de 100% e especificidade de 98,5%.

**Palavras-chave:** *Self-Organizing Maps* (SOM); Epilepsia; Predição; *Wavelet*.

---

<sup>1</sup> Trabalho resultante de Iniciação Científica. Orientadora Profa. Dra. Sara Dereste dos Santos.

<sup>2</sup> Endereço eletrônico: victormanuelalmeida98@gmail.com

<sup>3</sup> Endereço eletrônico: angelo@ifsp.edu.br

<sup>4</sup> Endereço eletrônico: ricardo\_pires@ifsp.edu.br

<sup>5</sup> Endereço eletrônico: sarad@ifsp.edu.br

## Introdução

A epilepsia é o distúrbio neurológico mais comum no planeta: 1,3% a 3,1% da população mundial é ou será diagnosticada com epilepsia (KOHRMAN, 2007). Esse distúrbio é causado pela emissão incorreta de sinais cerebrais e afeta o funcionamento normal do cérebro. Os surtos podem ser classificados pela área em que acontecem: surtos que estão limitados a uma região ou hemisfério do cérebro são chamados de parciais e surtos que afetam ambos os hemisférios são chamados de generalizados. Os sintomas apresentados durante um surto epilético estão relacionados principalmente com a percepção e controle corporal, como espasmos, alteração em um ou mais dos sentidos, sentimentos repentinos e anormais, e perda de consciência.

Na maioria dos casos, a causa para a epilepsia é desconhecida e os surtos podem acontecer a qualquer momento, mesmo que nenhum estímulo intenso aconteça. Além dos problemas gerados diretamente pela epilepsia, essas pessoas tendem a desenvolver distúrbios psiquiátricos, como a depressão, devido às dificuldades causadas pelos surtos. Em 70% dos pacientes, a condição pode ser curada com um longo período de tratamento, e, em 10% dos pacientes, remédios paliativos podem ser utilizados para controlar a condição; mas isso deixa 20% das pessoas afetadas por epilepsia sem um meio para controlarem os surtos, e esses casos são chamados de epilepsias refratárias. Além disso, os remédios existentes possuem efeitos colaterais graves, como ataxia, letargia, perda de densidade óssea, problemas gastrointestinais e ganho de peso (KOHRMAN, 2007). Como os surtos da epilepsia refratária são inevitáveis e podem acontecer a qualquer momento, as pessoas com essa variante da doença não podem realizar certas ações, como dirigir, e precisam estar sob constante vigilância caso um surto ocorra.

Mapas Auto-Organizáveis (SOM, do inglês, *Self-Organizing Maps*) são redes neurais que simplificam vetores de dados de muitas dimensões e são usadas para separar dados diferentes e agrupar dados semelhantes. O mapa resultante dessa rede neural apresenta a concentração de vetores em cada posição e informa visualmente a proximidade entre as regiões (KOHONEN, 2014). A SOM é uma rede com treinamento não assistido, no qual as saídas esperadas não são informadas, e é muito utilizada em

análise de dados financeiros (KIVILUOTO; BERGIUS, 1998), dados de controle (BARRETO; ARAUJO, 2004), e dados biomédicos, como é neste trabalho.

Um meio para prever um surto minutos antes de ele ocorrer permitiria uma maior autonomia para pacientes com epilepsia refratária, já que atividades que requerem atenção e controle poderiam ser realizadas e interrompidas se a pessoa fosse alertada sobre a possibilidade de um surto. O meio mais consistente de identificar um surto com antecedência é a identificação da alteração no Eletroencefalograma (EEG) (exame que consiste em mensurar impulsos nervosos através de eletrodos posicionados na cabeça) do paciente. Antes de um surto epilético, o paciente passa de um estado normal (conhecido como interictal) para um estado que antecede o surto (conhecido como pré-ictal) (SCARAMELLI, 2009).

Identificar e diferenciar os intervalos interictal e pré-ictal de forma contínua é o objetivo desse trabalho, já que essa identificação por meio de um método não assistido poderá servir como base para o desenvolvimento de equipamentos e programas para a previsão de surtos, permitindo maior liberdade e autonomia a pessoas com epilepsia refratária. Para esse objetivo geral, existem intermediários, entre eles: tratar os dados de EEG matematicamente através da transformada de *Wavelet*, selecionar os intervalos utilizados no treinamento do mapa, testar configurações diferentes para o mapa e treinar o mapa com os dados selecionados.

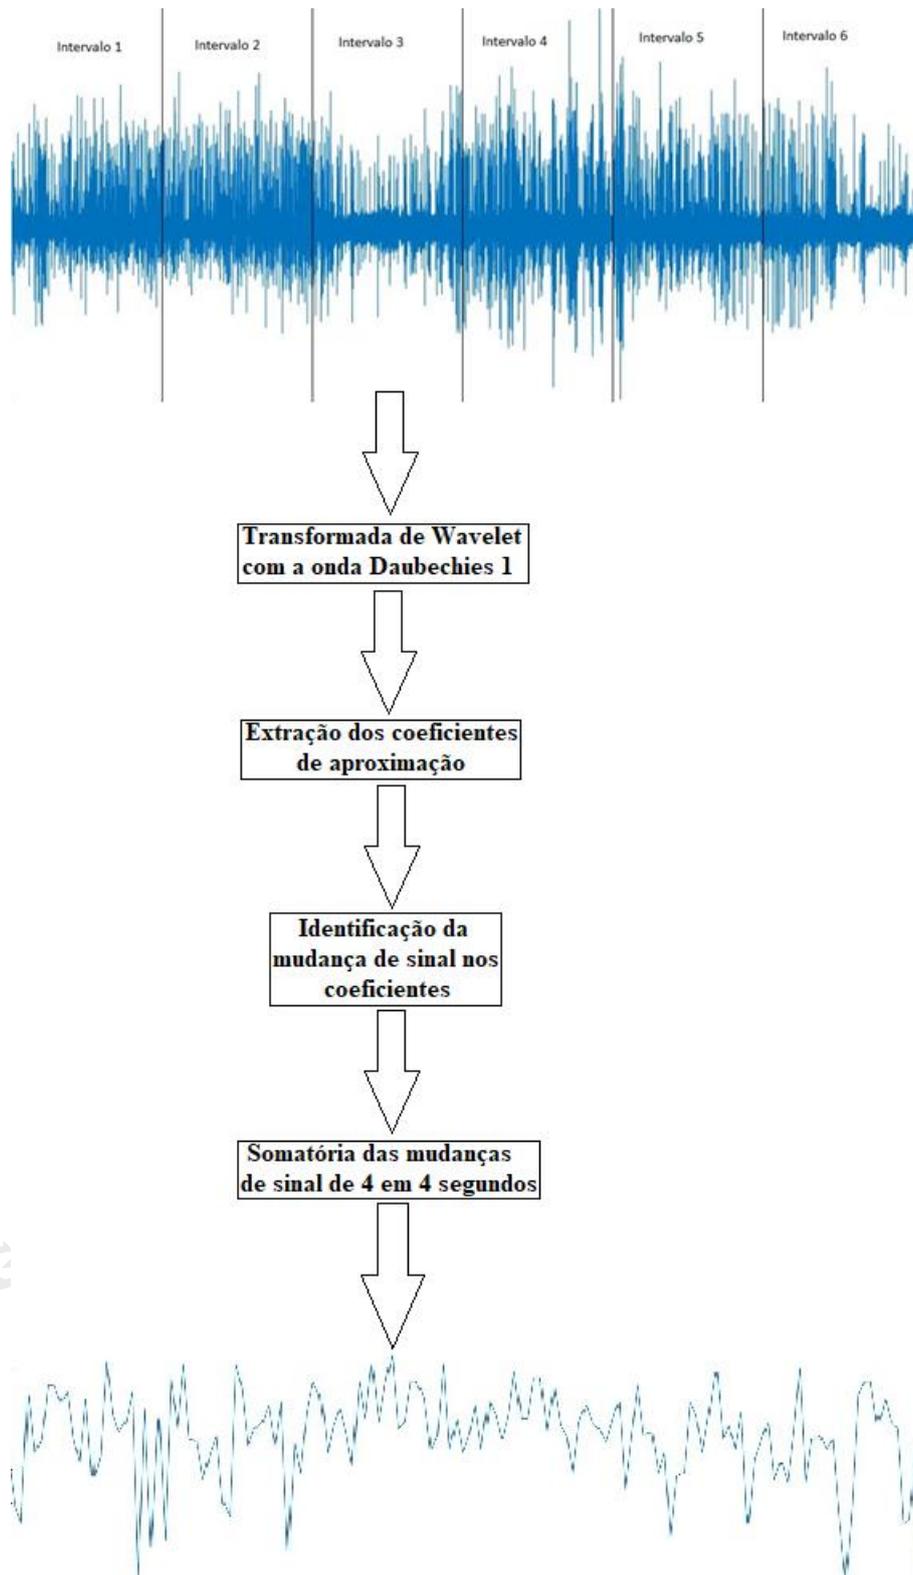
## Métodos

Os dados utilizados neste trabalho foram obtidos da base de dados *PhysioNet*, em particular a *CHB-MIT Scalp EEG Database*. Os dados podem ser baixados diretamente em formato *.mat* (SHOEB, 2009).

As etapas iniciais do trabalho consistiram em definir qual método seria utilizado para identificar os intervalos relacionados aos surtos. O método de classificação escolhido foi o mapa auto-organizável, com um pré-processamento dos sinais de EEG utilizando a transformada de *Wavelet*. O programa também foi selecionado neste estágio, e o *MatLab* foi o escolhido para o projeto, com três *toolboxes* sendo utilizadas: *SOM toolbox*, *Wavelet toolbox* e *Deep Learning toolbox*.

O pré-processamento dos sinais consiste em aplicar a transformada de *Wavelet* com a forma de onda *Daubechies* 1 em nível 5, em um intervalo de 10 minutos dos sinais de EEG. A tabela de coeficientes de aproximação é extraída, e uma matriz é criada a partir do sinal de cada valor, 0 representando um valor negativo e 1 representando um valor positivo. Uma operação XOR é realizada entre cada célula da matriz e o seu valor subsequente na linha. Essa operação resulta em uma tabela de contagem de cruzamentos por zero (do inglês, *zero-crossing*), com cada linha representando um canal do EEG. As colunas da tabela são somadas em grupos de 1024 para realizar uma contagem da quantidade de vezes que o valor muda de sinal em 4 segundos. O resultado desse pré-processamento é uma tabela de 23 linhas e 150 colunas, para os 23 canais e 150 intervalos de 4 segundos dentro de 10 minutos. Esse processo foi repetido a cada 10 minutos dos dados de EEG, realizando uma varredura completa dos sinais, como mostra a Figura 1. A varredura engloba completamente os dados de cada paciente, com um tempo total médio de 41 horas.

**Figura 1** — Exemplo de separação e pré-processamento dos intervalos de teste, cada intervalo tem duração de 10 minutos



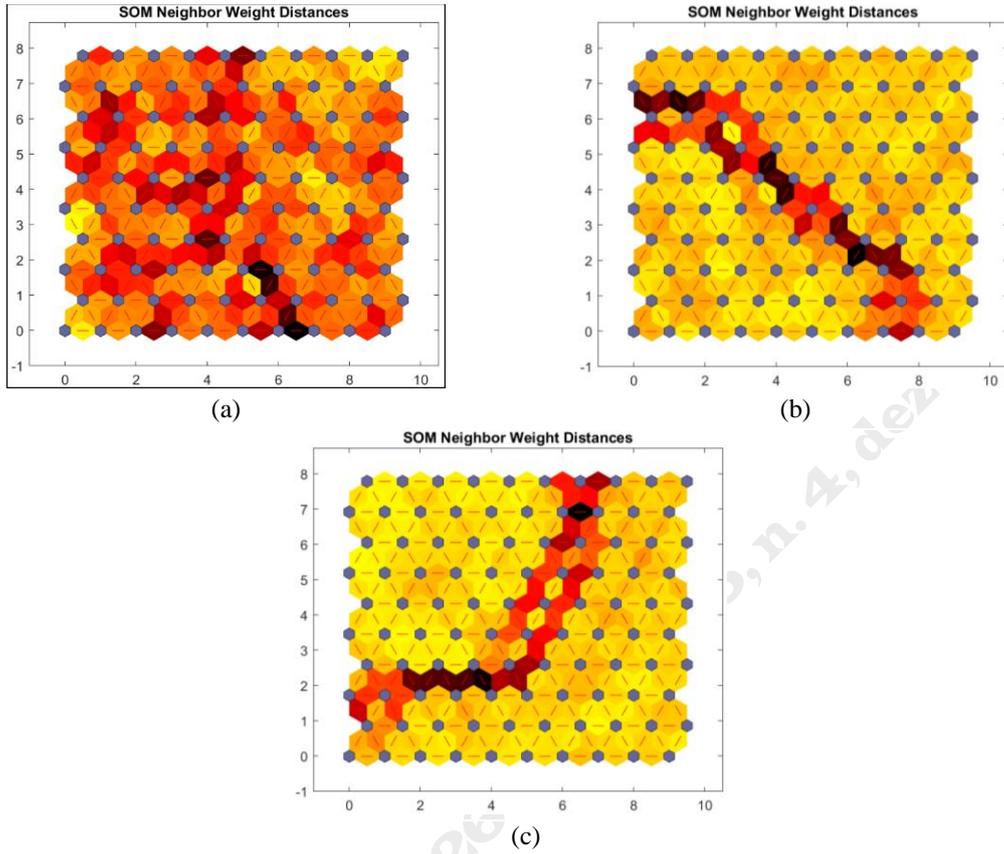
Fonte: Autores

A partir dos intervalos gerados pela varredura, foram selecionados aqueles que seriam utilizados para treinar o mapa. A separação dos intervalos de treinamento do SOM foi determinada de diferentes maneiras e todas foram analisadas quanto a sua capacidade de produzir intervalos claramente identificáveis no SOM. Para fazer a determinação da qualidade da separação, foi utilizada a matriz U do mapa. A matriz U é uma representação visual das distâncias entre neurônios adjacentes por meio de cores. Cores mais claras, como amarelo, representam curtas distâncias, e cores escuras, como vinho e preto, representam grandes distâncias.

Mapas com separações evidentes são aqueles que apresentam amontoados com cores mais claras, separados por regiões de cores escuras. Como pode ser observado na Figura 2 (a), intervalos interictais e pré-ictais próximos não são propriamente separados no mapa, mostrando que há grande semelhança entre eles. Por outro lado, como pode ser observado nas Figuras 2 (b) e 2(c), utilizar intervalos interictais distantes dos surtos resulta em separações mais distintas entre os intervalos interictais e os pré-ictais. Além disso, os dados de treino utilizados foram de diferentes horários para garantir maior abrangência em questão da variedade nos dados de treino. Outra razão para utilizar intervalos distantes é garantir que os dados selecionados possuam diferenças suficientes para serem classificados pelo mapa.

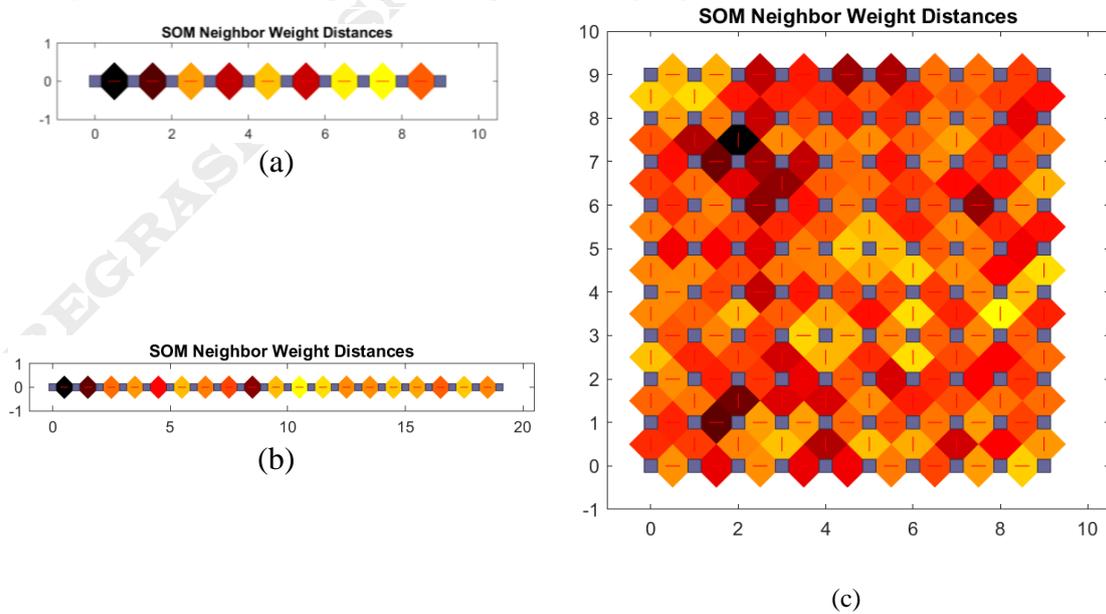
O próximo teste foi realizado para determinar a topologia do mapa. Mapas maiores permitem separações e classificações mais complexas e distintas, mas requerem maior tempo de processamento. No mapa 10x1 (Figura 3(a)), podem ser observadas regiões de neurônios agrupados (apresentadas na cor amarela) separadas por grandes distâncias (apresentadas na cor vinho), da mesma forma que ocorre no mapa 20x1 (Figura 3(b)). Por outro lado, o mapa 10x10 (Figura 3 (c)) aparenta ter-se distribuído quase uniformemente, sem separações evidentes, apresentando predominantemente regiões laranjas e vermelhas, que representam distâncias médias. O mapa ideal adotado, portanto, foi o 10x1.

**Figura 2** — (a) Matriz U para intervalos próximos; (b) matriz U para intervalos com 5 horas de separação e (c) matriz U para intervalos com 48 horas de separação



Fonte: Autores

**Figura 3** — Diferentes topologias de mapas nas configurações (a) 10x1; (b) 20x1 e (c) 10x10



Fonte: Autores

A última análise efetuada foi sobre a quantidade de dados utilizados no treino do mapa. Os testes foram realizados com intervalos de 16 minutos, 20 minutos e 100 minutos. Em todos os casos, metade dos dados foram provenientes de intervalos interictais e a outra metade, de intervalos pré-ictais.

Para determinar se um intervalo de 10 minutos é interictal ou pré-ictal, foi utilizado um sistema de votação. Durante a fase de treino, o mapa ajusta-se aos dados de treino, com parte deles aproximando-se de vetores retirados de intervalos pré-ictais e outros, de vetores de intervalos interictais. Ao fim do treinamento, os vetores que estão próximos dos vetores pré-ictais são identificados como neurônios pré-ictais, e o mesmo é válido para os neurônios que se aproximam de vetores interictais.

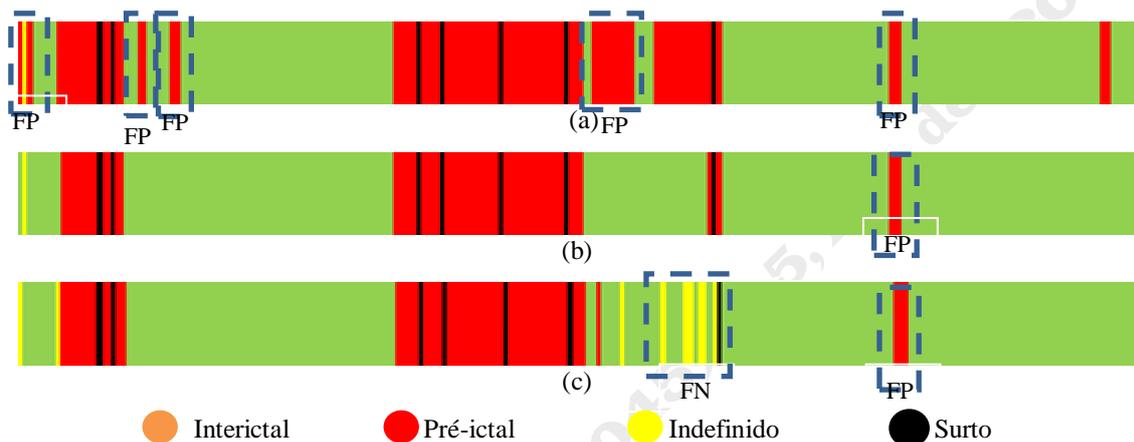
Com a topologia do mapa e seleção dos intervalos de treino definidas, foram realizados os testes de identificação dos intervalos. Em cada intervalo de 10 minutos, existem 150 vetores, cada um representando 4 segundos de dados pré-processados. Esses vetores são aplicados ao SOM já treinado, e são designados como pertencentes ao neurônio mais próximo. Caso esse neurônio seja pré-ictal, o vetor também é considerado pré-ictal; caso esse neurônio seja interictal, o vetor também é considerado interictal. Os 150 vetores são contabilizados, e o intervalo com maior número de votos determina a classificação. Esse sistema reduz falsos positivos, já que somente um vetor não é o suficiente para indicar um intervalo pré-ictal.

Na Figura 4, as colunas verdes representam períodos identificados como interictais, as colunas vermelhas representam intervalos pré-ictais, as colunas amarelas representam intervalos que são indeterminados (já que há a possibilidade de empate na votação) e as colunas pretas representam intervalos ictais (intervalos que contêm surtos).

A duração de treino de 20 minutos apresentou os melhores resultados, sem falsos negativos e somente um trecho como Falso Positivo (FP), também detectado nos outros testes. O treino com 16 minutos apresentou três outros momentos com falsos positivos, mas manteve-se a ausência de Falsos Negativos (FN). O treino de 100 minutos apresentou somente um intervalo com falso positivo, e um com falso negativo. Para o propósito desse trabalho, falsos negativos são mais relevantes do que falsos positivos, já que indicam que um surto não foi previsto.

É importante notar também que existe um intervalo semelhante ao pré-ictal que não foi considerado no treino, esse intervalo ocorre após o surto e tem o nome de pós-ictal. Por esse motivo, colunas vermelhas diretamente após o surto não são consideradas falsos positivos.

**Figura 4** — Resultados para o paciente chb01 com treinos de (a) 16 minutos, (b) 20 minutos e (c) 100 minutos com a identificação de trechos falsos positivos (FP) e falsos negativos (FN). Os dados apresentados totalizam 40 horas de sinais de EEG



Fonte: Autores

## Discussão

Elo et al. (2008) também utilizaram mapas auto-organizáveis com pré-processamento baseado em um filtro passa-baixa e identificação de máximos e mínimos locais para cada segmentação do sinal. A classificação não foi baseada em somente 2 intervalos. Nesse caso, o mapa classificou vetores do sinal em aproximadamente 370 padrões distintos, diferenciados pela probabilidade de um surto iminente. Esse método apresentou uma sensibilidade variando entre 83 e 100%, mas gerou uma grande quantidade de falsos positivos, com mais de 70% dos avisos de surto estando incorretos.

Jahankhani, Kodogiannis e Revett (2006) usou a transformada discreta de *Wavelet* para realizar o pré-processamento dos sinais de EEG, mas a transformada foi feita utilizando *Daubechies 2* em nível 4. Não houve contagem de *zero-crossing* para os vetores resultantes da transformada, e todos os coeficientes de detalhe e os coeficientes

de aproximação foram diretamente aplicados aos métodos de classificação. Foram utilizadas duas redes neurais para classificação dos dados, MLP e RBF. Ambos os métodos foram altamente eficazes, com uma acurácia de 97% e 98%, respectivamente. Apesar de não explicitamente dito, os dados foram amostrados, não englobando todos os dados disponíveis. Da mesma forma, Kitano et al. (2018) obtiveram resultados promissores (acurácia de 91%, sensibilidade de 98% e especificidade de 88%) com aprendizado não supervisionado e, a partir do que foi desenvolvido pelos autores neste trabalho, todos os dados disponíveis foram utilizados nos testes, com uma média de 31 horas por paciente. Os testes de Kitano et al. (2018) foram reproduzidos, obtendo-se resultados semelhantes. Entretanto, os intervalos não inclusos afetaram severamente os resultados.

Em Daoud e Bayoumi (2019), diversas redes neurais foram utilizadas para comparar a eficiência entre os diferentes métodos. O método que apresentou os melhores resultados foi DCAE+Bi-LSTM+CS, um método que combina *Deep Convolutional Autoencoder*, *Deep Convolutional Neural Network*, *Bidirectional Longo Short-Term Memory* e *Channel Selector*. Como a base de dados utilizada foi a mesma deste trabalho, a *CHB-MIT Scalp EEG Database* (SHOEB, 2009), os pacientes chb01 e chb20 podem ser utilizados para comparar os resultados quanto aos valores de acurácia, especificidade e sensibilidade. Em Daoud e Bayoumi (2019), os valores foram 99,72% para sensibilidade, 99,6% para especificidade e 99,66% para acurácia. Neste trabalho, os melhores resultados foram 100% para sensibilidade, 98,5% para especificidade e 98,9% para acurácia. O método de Daoud e Bayoumi (2019) não utiliza um pré-processamento para os dados, treinando as redes neurais diretamente com os dados de EEG, mas utiliza 5 redes neurais em sequência, sendo que uma delas é supervisionada (*Bidirectional Longo Short-Term Memory*) e a outra precisa ser pré-treinada (*Deep Convolutional Autoencoder*). Apesar disso, o tempo de treinamento é baixo, sendo somente 2,2 minutos.

Redes neurais são amplamente utilizadas para diagnosticar a epilepsia. Existem diferenças nos métodos utilizados quando o objetivo é o diagnóstico e não a predição de surtos. Em geral, o intervalo pré-ictal é ignorado no diagnóstico, e outros sinais são observados.

Em Nigam e Graupe (2004), o objetivo foi quantificar e denotar a amplitude de picos no intervalo interictal e utilizar esses valores para treinar uma rede neural conhecida como LAMSTAR (*Large-Memory Storage and Retrieval*) para fazer o diagnóstico. Um filtro e uma não linearidade foram empregados para reduzir sinais irrelevantes e acentuar os picos. Existe a possibilidade de analisar a ausência desses picos em intervalos pré-ictais, facilitando sua identificação caso essa ausência seja comprovada.

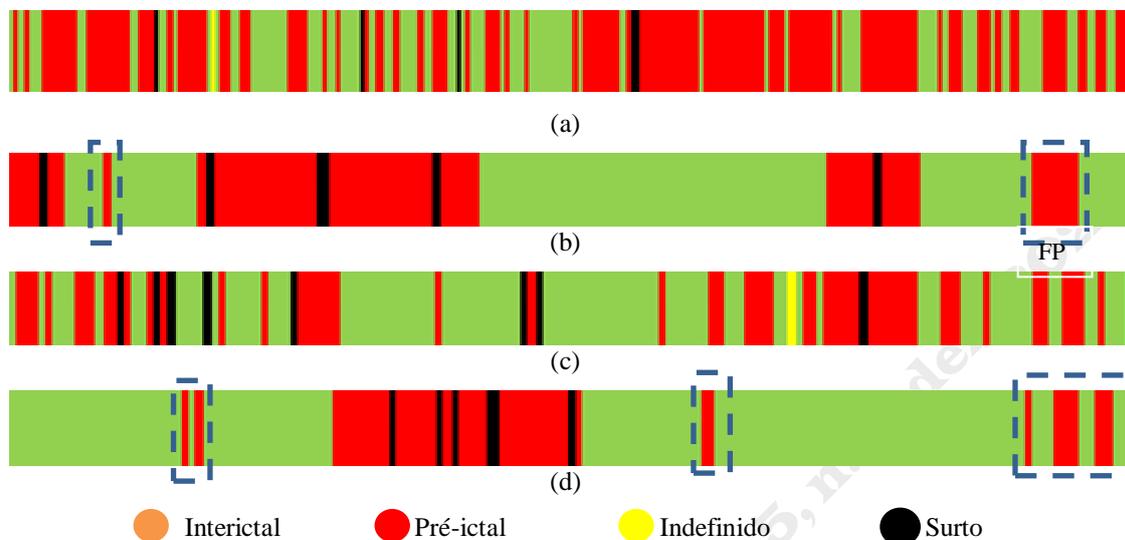
Em Srinivasan, Eswaran e Sriraam (2005), além do número de picos e amplitude dos picos, outros dados foram extraídos, como a frequência dominante. Neste caso, o objetivo foi identificar intervalos ictais para realizar o diagnóstico de epilepsia através de uma rede neural recorrente conhecida como *Elman Network*. Para extrair a frequência dominante, intervalos de 1 segundo eram separados e analisados como se o EEG fosse estacionário. Os resultados desse trabalho apresentam uma acurácia acima de 99,5%. Existe a possibilidade de analisar a frequência de intervalos pré-ictais para distinguí-los de intervalos interictais.

Em Ghosh-Dastidar, Adeli e Dadmehr (2008), foi utilizada a rede neural RBFNN (*Radial Basis Function Neural Network*), com tratamento de dados através de *Principal Component Analysis* (PCA). Esse método foi capaz de separar EEGs de pessoas saudáveis e intervalos interictais e ictais de pessoas com epilepsia. Esse método não apresenta grande relevância para separar intervalos interictais de pré-ictais, mas mostra que existem fatores no intervalo interictal que podem ser explorados para a predição de surtos.

## Resultados

Utilizando os parâmetros para treinamento do mapa descritos na seção “Métodos”, foi repetido o teste de classificação de intervalo por votação para outros quatro pacientes.

Figura 5 — Teste para os pacientes (a) chb05; (b) chb08; (c) chb14 e (d) chb20



Fonte: Autores

Como pode ser observado na Figura 5, a classificação não é eficaz para todos os pacientes, fato evidenciado pela classificação de intervalos interictais imediatamente precedendo surtos e a classificação de intervalos pré-ictais sem um surto relacionado a eles. O paciente chb08 obteve o segundo melhor resultado, depois do chb01, com somente dois falsos positivos e nenhum falso negativo, resultando em uma acurácia de 97%, sensibilidade de 100% e especificidade de 95%. O paciente chb05 resultou em um falso negativo e inúmeros falsos positivos, assim como o paciente chb14. O paciente chb20 apresentou cinco falsos positivos e um falso negativo. Não foi possível determinar valores de especificidade, sensibilidade e acurácia para os pacientes chb05, chb14 e chb20 já que os intervalos classificados como pré-ictais aparecem intermitentemente nos períodos que precedem os surtos. Como esses intervalos podem ter duração variada (SCARAMELLI, 2009), é difícil determinar exatamente quais classificações estão incorretas. Para os pacientes chb01 e chb08, os momentos classificados como pré-ictais são considerados corretos caso possuam um surto relacionado a eles, independentemente da duração. Seriam considerados falsos

negativos para os pacientes chb01 e chb08 caso um intervalo fosse classificado como interictal dentro de um período de 20 minutos precedendo ao surto.

Os dados utilizados foram um limitante para o desenvolvimento do trabalho. A base de dados *Physionet* é extensa e documentada. Entretanto, existem intervalos ausentes para muitos pacientes. Existem ainda picos gerados por problemas no equipamento, picos que podem ser descartados como erros por um médico experiente, mas que são levados em consideração em uma análise por uma rede neural (RAMANTANI, 2006).

Os valores de acurácia, sensibilidade e especificidade dos resultados não podem ser exatamente determinados, já que intervalos pré-ictais e pós-ictais não estão identificados na base de dados utilizada e, como ambos os intervalos possuem durações variáveis, geralmente inferior a 6 horas, mas podendo superar 48 horas (SCARAMELLI, 2009), o exato momento em que começam ou terminam precisa ser estimado.

## Conclusão

Neste trabalho, a predição de surtos epiléticos foi estudada a partir de um algoritmo de aprendizagem de máquina não supervisionado, o SOM, considerando todos os dados de EEG disponíveis de cada paciente. Muitos trabalhos reportam excelentes resultados na predição de surtos, tendo como base a distinção entre os períodos interictal e pré-ictal. No entanto, até onde se encontrou na literatura, isso é feito de forma amostrada, utilizando trechos do EEG bem definidos. Quando o sinal é continuamente processado e os dados são apresentados à rede, a quantidade de falsos positivos e falsos negativos torna-se significativa, diminuindo consideravelmente o desempenho do sistema. O uso do SOM, dada sua natureza auto-organizável, mostrou que é possível mapear os diferentes padrões existentes nos sinais de EEG em duas categorias: distante do surto (interictal) e próximo do surto (pré-ictal), não revelando, portanto, regiões intermediárias. A fase de teste, no entanto, foi fortemente prejudicada, provavelmente pelas características particulares de cada crise somadas à situação de cada paciente no momento em que os sinais foram coletados.

Para melhorar o desempenho da rede, novos métodos de pré e pós-processamento precisam ser investigados, além da possibilidade de associar a decomposição dos sinais de EEG a outros metadados que possam diminuir a ocorrência de falsos alarmes.

## Referências

BARRETO, G. A.; ARAUJO, A. F. R. Identification and control of dynamical systems using the self-organizing map. *IEEE Transactions on Neural Networks*, [s. l.], v. 15, n. 5, p. 1244-1259, 2004. Institute of Electrical and Electronics Engineers (IEEE).

DAOUD, Hisham; BAYOUMI, Magdy A. Efficient epileptic seizure prediction based on deep learning. *IEEE Transactions on Biomedical Circuits and Systems*, [s. l.], v. 13, n. 5, p. 804-813, 2019. Institute of Electrical and Electronics Engineers (IEEE).

ELO, Pekka et al. Classification of epileptic EEG by using self-organizing maps. *In: INTERNATIONAL CONFERENCE ON ARTIFICIAL NEURAL NETWORKS (ICANN1992)*, 1992, Brighton. *Anais [...]*. [S. l.]: Elsevier, 1992. p. 1147-1150. 1992. Elsevier.

GHOSH-DASTIDAR, S.; ADELI, H.; DADMEHR, N. Principal component analysis-enhanced cosine radial basis function neural network for robust epilepsy and seizure detection. *IEEE Transactions on Biomedical Engineering*, [s. l.], v. 55, n. 2, p. 512-518, 2008. Institute of Electrical and Electronics Engineers (IEEE).

JAHANKHANI, Pari; KODOGIANNIS, Vassilis; REVETT, Kenneth. EEG signal classification using wavelet feature extraction and neural networks. *In: IEEE JOHN VINCENT ATANASOFF 2006 INTERNATIONAL SYMPOSIUM ON MODERN COMPUTING (JVA'06)*, 2006, Sofia. *Anais [...]*. Los Alamitos: IEEE, 2006. p. 120-124. Institute of Electrical and Electronics Engineers (IEEE).

KITANO, Lucas Aparecido Silva et al. Epileptic seizure prediction from EEG signals using unsupervised learning and a polling-based decision process. *In: INTERNATIONAL CONFERENCE ON ARTIFICIAL NEURAL NETWORKS (ICANN 2018)*, 2018, Rodes. *Anais [...]*. Cham, Switzerland: Springer, 2018. v. 2. p. 117-126. Springer International Publishing.

KIVILUOTO, K.; BERGIUS, P. Exploring corporate bankruptcy with two-level self-organizing map. *In: INTERNATIONAL CONFERENCE COMPUTATIONAL FINANCE*, 5., 1997, Londres. *Anais [...]*. Boston: Springer, 1998. v. 2. p. 373-380, 1998.

KOHONEN, T. *MATLAB implementations and applications of the self-organizing map*. Helsinki: Unigrafia Ou, 2014.

KOHRMAN, Michael H. What is epilepsy? Clinical perspectives in the diagnosis and treatment. **Journal of Clinical Neurophysiology**, [s. l.], v. 24, n. 2, p. 87-95, 2007. Ovid Technologies (Wolters Kluwer Health).

NIGAM, Vivek Prakash; GRAUPE, Daniel. A neural-network-based detection of epilepsy. **Neurological Research**, [s. l.], v. 26, n. 1, p. 55-60, 2004. Informa UK Limited.

RAMANTANI, Georgia et al. MEG versus EEG: influence of background activity on interictal spike detection. **Journal of clinical neurophysiology**, [s.l.], v. 23, n. 6, p. 498-508, dez. 2006. Ovid Technologies (Wolters Kluwer Health).

SCARAMELLI, Alejandro et al. Prodromal symptoms in epileptic patients: clinical characterization of the pre-ictal phase. *Seizure*, [s.l.], v. 18, n. 4, p. 246-250, maio 2009. Elsevier BV.

SHOEB, Ali. **CHB-MIT Scalp EEG Database**. [S. l.]: National Institutes of Health, 2009. Disponível em: <https://archive.physionet.org/pn6/chbmit/>. Acesso em: 4 dez. 2019.

SRINIVASAN, V.; ESWARAN, C.; SRIRAAM, N. Artificial neural network based epileptic detection using time-domain and frequency-domain features. **Journal of Medical Systems**, [s. l.], v. 29, n. 6, p. 647-660, 2005.

### **USE OF SELF-ORGANIZING MAPS IN THE PREDICTION OF EPILEPTIC SEIZURES BASED ON CONTINUOUS EEG ANALISYS**

#### **ABSTRACT**

*Epilepsy is a neurological disorder that, generally, causes frequent convulsions in those affected, inhibiting them from performing activities that require constant attention or complete control, like driving or swimming. Seizure prediction could grant more safety to the patients, alerting them about imminent seizures. In this paper, a non-supervised neural network known as Self-Organizing Map (SOM) is utilized to continuously identify and classify intervals of Electroencephalogram (EEG) signals to generate an anticipated seizure detection method. This implies in the distinction of characteristics present in EEG signals as a seizures approach. The data is pre-processed utilizing Wavelet transform and the results are used in training the SOM. Three different map topologies and three different lengths of training data were evaluated for their efficiency. The method was investigated in several patients from the Physionet - CHB-MIT database. The best cases presented an accuracy of 98.9%, sensibility of 100%, and specificity of 98.5%.*

**Keywords:** *Self-Organizing Maps (SOM); Epilepsy; Prediction; Wavelet.*

**Envio: fevereiro/2020**

**Aceito para publicação: maio/2020**