

Previsão de surtos epiléticos usando *Self-Organizing Maps* executados diretamente em *hardware*

Alan Belem Santos¹, Kenny Shogo Nakamura¹, Sara Dereste Santos¹, Ricardo Pires¹ e Miguel Angelo de Abreu de Sousa¹

Instituto Federal de Educação, Ciência e Tecnologia São Paulo (IFSP)
01109-010– São Paulo – SP – Brazil

a.belem@aluno.ifsp.edu.br, kenny.nakamura@aluno.ifsp.edu.br,
sarad@ifsp.edu.br, ricardo_pires@ifsp.edu.br, angelo@ifsp.edu.br

Abstract. *Epilepsy is a neurological condition that affects the brain and makes patients more susceptible to recurrent unprovoked seizures. This work aimed to implement a logic circuit in FPGA (Field Programmable Gate Array) which, through the use of Self-Organizing Maps (SOM), was able to predict epileptic seizures using electroencephalogram (EEG) signals. Albeit similar, the processing steps executed in hardware are not necessarily identical to those executed in software. The obtained results were compared to a previous work, which implemented Self-Organizing Maps in software, reaching similar accuracy. The proposed logic circuit reached an accuracy of 94,53%.*

Resumo. *A epilepsia é uma condição neurológica que afeta o cérebro e torna os pacientes mais suscetíveis a convulsões recorrentes. Este trabalho tem como objetivo implementar um circuito lógico em FPGA (Field Programmable Gate Array) para execução de Self-Organizing Maps (SOM) aplicado na previsão de surtos epiléticos a partir de sinais de eletroencefalograma (EEG). Embora similares, as etapas de processamento executadas em hardware não são necessariamente idênticas às executadas em software. Os resultados obtidos foram comparados ao trabalho anterior, o qual implementou os Self-Organizing Maps em software. Os resultados foram similares e o circuito proposto atingiu uma acurácia de 94,53%.*

1. Introdução

A epilepsia é uma das doenças cerebrais mais comuns, afetando por volta de 70 milhões de pessoas ao redor do mundo [Duncan et al. 2006]. A epilepsia pode ser definida como um grupo de condições cerebrais crônicas caracterizadas por crises recorrentes. Cada crise é um evento geralmente autolimitado, o produto de descarga excessiva ou hipersíncrona de uma população neuronal no cérebro. Suas manifestações clínicas são variadas, geralmente têm início e término repentinos e são acompanhadas de alteração no estado de consciência [Torres et al. 2014]. As causas da epilepsia podem ser genéticas, estruturais ou desconhecidas [Freitag 2019] e a predisposição em gerar ataques epiléticos espontâneos tem consequências neurológicas, cognitivas e sociais [Duncan et al. 2006]. Assim como a epilepsia pode gerar problemas sociais associados a estigmas e preconceitos, ela também está relacionada a problemas econômicos, podendo ser considerada um importante problema de saúde pública [Fernandes et al. 2006].

Quase 80% das pessoas com epilepsia vivem em países de renda baixa e média e estão sujeitas à falta de tratamentos adequados. Nesses países, mais de três quartos das

peças com epilepsia ativa não são tratadas e isso constitui uma grande lacuna terapêutica [Thijs et al, 2019]. O eletroencefalograma (EEG) é um exame capaz de detectar diversas doenças através de sinais cerebrais dos pacientes. Destas, a epilepsia ocupa uma posição privilegiada, uma vez que esta afecção neurológica está frequentemente associada com alterações neuronais, que resultam em potenciais eletromagnéticos detectáveis por eletrodos de escalpo (descargas epileptiformes) [Silva e Geovany 2008]. Por ser um exame de execução relativamente fácil e de baixo custo, o EEG (Figura 1) se constitui em um dos mais importantes auxílios diagnósticos para a epilepsia [Dantas et al. 2005].




Figura 1: Representação dos sinais de Eletroencefalograma. Figura gerada com o software EDFbrowser a partir da base de dados do Boston Children's Hospital

O tratamento de epilepsia é feito atualmente com base em medicamentos antiepiléticos que permitem ao paciente uma melhor qualidade de vida. Porém, esses medicamentos não são eficientes para todos os pacientes [LIGA BRASILEIRA DE EPILEPSIA] e podem causar reações adversas. Em um estudo realizado em Bogotá, foram avaliados 173 relatos de eventos adversos e problemas relacionados ao uso de drogas antiepiléticas na população. Além disso, em relação à avaliação da gravidade da reação, a maioria dos relatos (43%) correspondeu a reações adversas moderadas [Torres et al. 2014].

Neste trabalho, com o objetivo de colaborar com a situação apresentada, a partir do trabalho anterior [Kitano et al. 2018], foi desenvolvido um circuito eletrônico para execução de *Self-Organizing Maps* aplicado à previsão da ocorrência de surtos epiléticos, com o objetivo de verificar a eficácia dos testes em *hardware*, sendo uma etapa importante no desenvolvimento de um protótipo, para proporcionar ao paciente maior segurança e qualidade de vida, alertando-o com antecedência sobre a ocorrência de uma crise.

Na seção 2 será abordada a fundamentação teórica do *Self-organizing Maps*, e do chip FPGA (*Field Programmable Gate Array*), *hardware* de implementação da rede neural. Na seção 3, serão abordadas as metodologias utilizadas no trabalho. As seções 4 e 5 abordarão os resultados e a conclusão, respectivamente.

2. Fundamentação Teórica

Para implementar o *Self-Organizing Maps*, utilizou-se o circuito integrado FPGA, que irá executar um circuito lógico aplicado à previsão de surtos epiléticos.

2.1. Self-Organizing Maps

Baseadas no sistema biológico humano, as redes neurais artificiais constituem uma importante técnica de Inteligência Artificial [Oja et al. 2003]. Entre as redes neurais existentes, o *Self-Organizing Maps*, conhecido pela sigla SOM, foi utilizado neste trabalho. O SOM é um tipo de rede neural artificial baseada em aprendizado competitivo não supervisionado, sendo capaz de mapear um conjunto de dados de alta dimensionalidade, através de um conjunto finito de neurônios organizados normalmente em arranjos bidimensionais [Zuchini et al. 2003]. O aprendizado ocorre com a identificação do neurônio vencedor, ou seja, aquele que possui maior similaridade entre seu vetor de peso e o vetor do dado apresentado à entrada da rede. Em seguida, escolhe-se o neurônio com a menor distância em relação ao dado (neurônio vencedor), este neurônio possui um indexador que o nomeia para que seja possível saber qual é o neurônio vencedor. Por fim, são reajustados os pesos dos neurônios vencedores [Sousa, 2018].

A Figura 2 representa o SOM mapeando uma distribuição de dados ilustrados por círculos azuis.

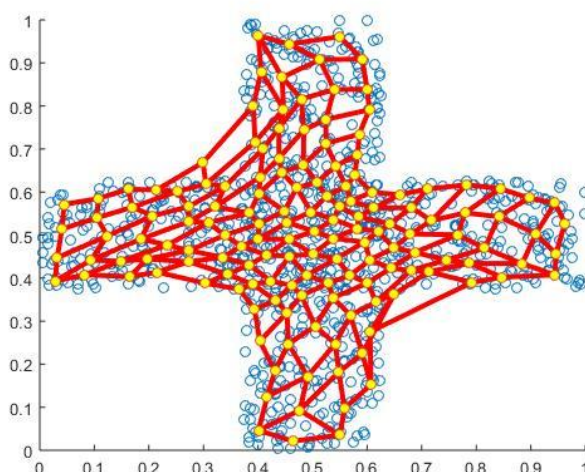


Figura 2: SOM após a etapa de aprendizagem. Os pontos em amarelo representam os neurônios, enquanto os azuis representam as entradas do problema.

Alguns parâmetros importantes do SOM são a taxa de aprendizado, que é o parâmetro que visa controlar a intensidade de ajuste de pesos, e quantidade de neurônios da rede. Tais parâmetros são obtidos empiricamente durante da etapa de treinamento. Na etapa de teste, os parâmetros são fixados e a rede é utilizada a fim de obter os resultados requeridos. O cálculo de ajuste de pesos, realizado na etapa de treinamento, é realizado a partir da Equação 1.

$$W_{atual}^{(v)} = W_{anterior}^{(v)} + \sigma \cdot \eta \cdot (x^{(k)} - W_{anterior}^{(v)}) \quad (1)$$

Onde $W^{(v)}$ denota o vetor de pesos do neurônio vencedor, o parâmetro η define a taxa de aprendizagem e o parâmetro σ , a função de vizinhança. O parâmetro função de vizinhança corresponde à intensidade de ajuste de pesos do neurônio vencedor. Quanto mais distante do neurônio vencedor os neurônios vizinhos forem, menor a intensidade de ajuste destes neurônios [Sousa 2018].

Para a aplicação em previsão de surtos epiléticos, como saída, os *Self-Organizing Maps* mostram os neurônios ativados em suas devidas regiões anteriormente mapeadas como próximas ou distantes do surto.

2.2. FPGA (*Field Programmable Gate Array*)

O chip reprogramável FPGA permite que suas funções lógicas internas sejam configuradas dinamicamente. O dispositivo possui como sua principal característica a execução paralela de suas operações. Ambas as características tornam o FPGA um dispositivo adaptado para execução direta de redes neurais artificiais, devido ao paralelismo inerente aos modelos conexionistas de processamento de dados. Desta forma, os parâmetros da rede podem ser processados concomitantemente, o que reduz o tempo necessário para execução da rede [Sousa 2018].

Neste trabalho, foi utilizado o *software* Vivado para a criação do circuito lógico de execução do SOM. O Vivado é um software desenvolvido pela Xilinx, que utiliza as linguagens VHDL e Verilog para sintetizar circuitos lógicos [Churiwala 2016].

3. Metodologia

O presente trabalho configura-se como a continuação da pesquisa anteriormente publicada, na qual as etapas de processamento foram ensaiadas através da utilização de diferentes programas [Kitano et al, 2018]. Este trabalho descreve a aplicação do SOM para previsão de surtos epiléticos executado em *hardware* e apresenta a comparação dos resultados obtidos com os resultados da execução em *software* reportados pelo referido trabalho. Tal comparação é importante porque, embora semelhantes, as computações utilizadas na implementação do algoritmo neural em FPGA não são idênticas às computações realizadas em *software*. Diferem-se os cálculos, implementados em ponto fixo ao invés de ponto flutuante, e a utilização da distância de Manhattan para definição do neurônio vencedor, ao invés da distância Euclidiana [Sousa et al. 2020].

Para utilizar os sinais de EEG dos pacientes, realizou-se o pré-processamento do sinal, etapa na qual as características dos dados são extraídas para serem mapeadas pelo SOM. Durante o pré-processamento (apresentado na seção 3.1), fez-se o uso da transformada *Wavelet* [Adeli et al. 2007] e a contagem da quantidade de cruzamentos por zero dos coeficientes de detalhe.

A frequência de amostragem do sinal de EEG é de 256Hz, o arquivo é dividido em j janelas de t segundos. A quantidade de janelas de um arquivo depende da quantidade de tempo de EEG selecionado (ou quantidade de amostras), seguindo a fórmula apresentada na Equação 2. Os dados de EEG usados para previsão dos surtos foram segmentados em janelas de 4 segundos.

$$j = \frac{(\text{TempodeEEGselecionadoem[s]})}{t} \quad (2)$$

3.1. Pré-processamento

Para testar a técnica SOM aplicada à previsão de surtos epiléticos, foi utilizado o banco de dados do Hospital Infantil de Boston (*Boston Children's Hospital*), o qual fornece dados dos EEGs de pacientes com epilepsia [Goldberger et al. 2000]. O banco de dados pode ser acessado pelo endereço: <https://physionet.org/content/chbmit/1.0.0/>. Os dados de EEG contêm 23 dimensões, relacionadas aos 23 canais de captação de sinal cerebral do paciente. Ao todo, dos 24 pacientes 9 foram selecionados, pelo fato de terem tido,

pelo menos 5 surtos registrados, para que se tenha dados suficientes para realizar o treinamento e teste da rede. Os pacientes que tiverem menos de 5 surtos registrados foram descartados.

O pré-processamento consiste nos procedimentos ilustrados na Figura 3, seguindo a proposta publicada em [Kitano et al. 2018].




Figura 3: Procedimentos do pré-processamento do sinal de EEG.

Para o processamento dos dados de EEG, foram extraídos intervalos de tempo imediatamente antes do surto (chamados pré-ictal) e durante um período sem surtos (chamados interictal) para serem categorizados pelo SOM. Os intervalos escolhidos foram idênticos aos coletados no trabalho anteriormente publicado sobre o uso do SOM para previsão de epilepsia [Kitano et al. 2018].

3.2. SOM em VHDL

Com o auxílio do *software* Vivado, deu-se início a etapa de construção do circuito responsável por executar o SOM em VHDL. O SOM foi dividido em blocos funcionais (Figura 4), sendo eles: cálculo de distância, determinação do neurônio vencedor e ajuste de pesos.




Figura 4: Fluxograma do SOM implementado em VHDL.

Cada bloco compõe uma função específica segundo apresentado na seção 2.1, e o conjunto inteiro constitui o processamento do SOM. Contudo, neste projeto, o algoritmo utilizou diretamente os parâmetros obtidos através do treinamento em *software* [Kitano et al. 2018], para que se possam comparar ambas as execuções, em *software* e em *hardware*. Sendo assim, computaram-se apenas as ativações dos neurônios de saída em relação aos dados de EEG de entrada.

4. Resultados

Os testes da implementação em FPGA foram feitos com a plataforma de simulação Vivado. Os testes se baseiam em verificar a taxa de acertos nas etapas préictal e interictal do SOM executado em FPGA e compará-las com as taxas obtidas pelo trabalho anteriormente publicado [Kitano et al. 2018].

A Tabela 1 contém os resultados obtidos com o processamento em *hardware* nos testes para apenas um paciente. A primeira coluna indica a quantidade de janelas analisadas e o tempo correspondente, as demais colunas indicam a quantidade de janelas classificadas de forma correta, a quantidade total de janelas e a taxa de acerto do estado do EEG (preictal ou interictal).

Tabela 1: Taxa de acerto para o paciente 05 com a execução do SOM em FPGA.

Quantidade de janelas analisadas	Tempo correspondente	Preictal	Interictal	Total
1	4s	423/605 (69,91%)	714/752 (94,94%)	1137/1357 (83,79%)
5	20s	424/601(70,55%)	554/598 (92,64%)	978/1199 (81,58%)
15	1min	423/591 (71,57%)	554/588 (94,22%)	977/1179 (82,87%)
45	3min	385/561(68,63%)	525/558 (94,08%)	910/1119 (81,32%)
90	6min	356/516 (68,99%)	513/513 (100%)	869/1029 (84,45%)
135	9min	374/471 (79,40%)	468/468 (100%)	842/939 (89,68%)
180	12min	376/426 (88,26%)	423/423 (100%)	799/849 (94,11%)
225	15min	303/381 (79,52%)	378/378 (100%)	681/759 (89,72%)
270	18min	268/336 (79,76%)	333/333 (100%)	601/669 (89,83%)

A Tabela 2 contém a porcentagem de acertos para todos os 9 pacientes testados, segundo a quantidade de janelas. Na tabela, a identificação dos pacientes ChbXX segue a informação original da base de dados.

Tabela 2: Taxa de acertos nas previsões dos surtos para todos os pacientes testados.

Janelas	Chb01 (%)	Chb03 (%)	Chb05 (%)	Chb06 (%)	Chb08 (%)	Chb10 (%)	Chb11 (%)	Chb20 (%)	Chb23 (%)
1	99,80	91,18	83,79	97,29	83,60	71,87	80,68	94,78	93,71
5	100	87,05	81,57	97,56	83,87	88,33	78,40	95,33	94,33
15	100	91,09	82,87	100	86,66	92,75	82,82	98,13	93,99
45	100	94,42	81,32	100	87,93	94,24	82,12	100	97,75
90	100	97,91	84,45	100	88,29	94,88	95,96	100	99,41
135	100	100	89,67	100	88,78	96,13	99,31	100	100
180	100	100	94,11	100	89,02	98,70	100	100	100
225	100	100	89,72	100	89,45	100	100	100	100
270	100	100	89,84	100	89,91	100	100	100	100

A Figura 5 mostra a curva da média de acertos para todos os pacientes da base de dados, tanto para o processamento em *software* quanto em *hardware*. Em geral, ambas tiveram resultados satisfatórios, a discrepância pode ter sido originada pelo método de cálculo da distância utilizado em *hardware*. Na implementação em *software*, a distância utilizada foi a Euclidiana, enquanto em *hardware* utilizou-se a distância de Manhattan. Tradicionalmente, utiliza-se a distância Euclidiana para a computação dos neurônios vencedores do SOM [Da Silva et al. 2010]. Implementações em *hardware* beneficiam-se do cálculo da distância de Manhattan por não necessitarem de divisões e de radiciações [Sousa 2018]. Entretanto, alguns trabalhos matemáticos sugerem que, em

tarefas de agrupamento de dados (como as executadas pelo SOM), a distância de Manhattan realiza melhores avaliações da relevância de pequenas distâncias com o aumento do número de dimensões do vetor analisado [Sousa et al. 2020].

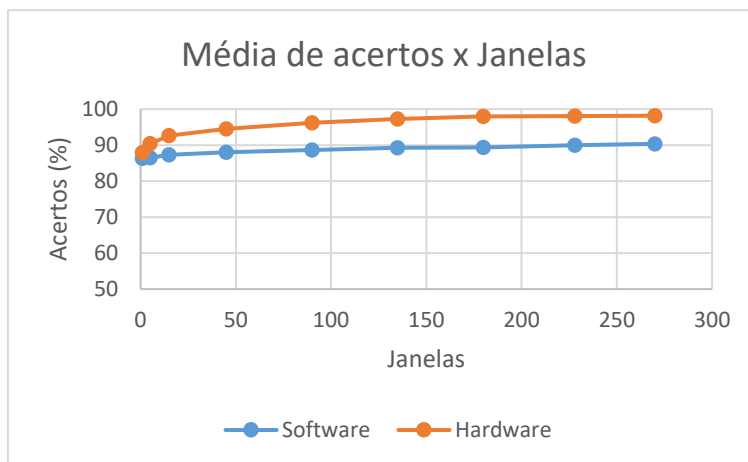


Figura 5: Curva média de acertos para SOM em *software* e *hardware*.

5. Conclusão

Através do uso de inteligência artificial, mais precisamente a técnica SOM, elaborou-se um sistema aplicado à previsão de surtos epiléticos com o potencial de melhorar a qualidade de vida dos pacientes. Devido à necessidade de utilizar o processamento em *hardware* para futuros equipamentos de previsão de surtos epiléticos, neste projeto, o SOM foi desenvolvido em um chip FPGA.

Os resultados obtidos em *hardware* se mostraram próximos aos resultados obtidos em *software*, exceto para dois pacientes, os quais apresentaram melhores resultados para o processamento em *hardware*, devido a isso, a curva da média em *hardware* obteve melhor resultado.

Para trabalhos futuros, pretende-se implementar as etapas de pré-processamento também em *hardware*, assim como realizar a coleta dos dados em tempo real, através de um dispositivo que acompanhará o paciente durante seu cotidiano, dando um passo importante na construção de um protótipo e, posteriormente, de um produto para previsão de surtos epiléticos.

6. Referências

- Adeli, H., Ghosh-Dastidar, S., & Dadmehr, N. (2007). A wavelet-chaos methodology for analysis of EEGs and EEG subbands to detect seizure and epilepsy. *IEEE Transactions on Biomedical Engineering*, 54(2), 205-211.
- Churiwala, S., & Hyderabad, I. (2017). *Designing with Xilinx® FPGAs*. Springer.
- Da Silva Zanin, L. G. (2008). AOSE-Analisador de Ocorrência de Surtos Epiléticos (*Doctoral dissertation, Universidade Positivo*).
- Dantas, F. G., Medeiros, J. L. A., Nogueira, B. N. F., & Figueiredo, A. R. D. (2005). Papel do EEG em casos de suspeita ou diagnóstico de epilepsia. *Journal of Epilepsy and Clinical Neurophysiology*, 11(2), 77-78.

- De Sousa, M. A. D. A., Pires, R., & Del-Moral-Hernandez, E. (2020). SOMprocessor: A high throughput FPGA-based architecture for implementing Self-Organizing Maps and its application to video processing. *Neural Networks*.
- Duncan, J. S., Sander, J. W., Sisodiya, S. M., & Walker, M. C. (2006). Adult epilepsy. *The Lancet*, 367(9516), 1087-1100.
- Freitag, H. (2019). Neuropsychology of depression in people with epilepsy. *Swiss Archives of Neurology, Psychiatry and Psychotherapy*, 170(06).
- Fernandes, P. T., & Li, L. M. (2006). Percepção de estigma na epilepsia. *Journal of epilepsy and clinical neurophysiology*, 12(4), 207-218
- Goldberger, A. L., Amaral, L. A., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., ... & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *circulation*, 101(23), e215-e220.
- Kitano, L. A. S., Sousa, M. A. A., Santos, S. D., Pires, R., Thome-Souza, S., & Campo, A. B. (2018, October). Epileptic seizure prediction from EEG signals using unsupervised learning and a polling-based decision process. *In International Conference on Artificial Neural Networks* (pp. 117-126). Springer, Cham.
- Liga Brasileira de Epilepsia. O que é Epilepsia. *LBE 2020*. Disponível em <https://epilepsia.org.br/> Acesso em 24/06/2020
- Oja, M., Kaski, S., & Kohonen, T. (2003). Bibliography of self-organizing map (SOM) papers: 1998–2001 addendum. *Neural computing surveys*, 3(1), 1-156.
- Silva, I. D., Spatti, D. H., & Flauzino, R. A. (2010). Redes neurais artificiais para engenharia e ciências aplicadas. *São Paulo: Artliber*, 23(5), 33-111.
- Sousa, M. A. D. A. D. Metodologias para desenvolvimento de mapas auto-organizáveis de Kohonen executados em FPGA (*Doctoral dissertation, Universidade de São Paulo*).
- Thijs, R. D., Surges, R., O'Brien, T. J., & Sander, J. W. (2019). Epilepsy in adults. *The Lancet*, 393(10172), 689-701.
- Torres, N. M. C., & Rodríguez, J. J. Q. (2014). Notificación de las reacciones adversas a los medicamentos antiepilépticos en Bogotá (Colombia, 2008–2012). *Revista Cubana de Neurología y neurocirugía*, 4(2), 117-123.
- Zuchini, M. H. (2003). Aplicações de mapas auto-organizáveis em mineração de dados e recuperação de informação. *Dissertação (Mestrado) Universidade de Campinas. Campinas*, 277.