

Detecção de Espículas em Registros de Eletroencefalograma utilizando um Mapa Auto-organizável

Jorge Roberto Guedes¹, Fernando Mendes de Azevedo¹

¹Instituto de Engenharia Biomédica (IEB-UFSC) - Departamento de Pós-graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina – UFSC, Florianópolis - Santa Catarina – SC
E-mails: guedes@ieb.ufsc.br, azevedo@ieb.ufsc.br

Abstract

This work describes a technique for spike detection on EEG records by using self-organizing maps. The EEG database was obtained from 7 patients and every record is 30 minutes long. These records own 32 channels at a sampling rate of 100 Hz. The analysis is made at intervals one second long. For each interval, an algorithm reckons the following parameters: maximum and minimum amplitudes, difference between the amplitudes, event duration, event angle, average, standard deviation, variance, crest factor and entropy. After that, the results are supplied as inputs for a self-organizing map, which was trained with parameters of signals containing spikes, alpha waves, background activity, blinks and noise. In the simulation, the self-organizing map distributes the parameters in clusters. By analyzing these clusters, an algorithm verifies the existence of spikes.

1. Introdução

A epilepsia atualmente esta sendo considerada mundialmente como um problema de saúde pública. Sua frequência e características produzem adversidades não somente ao paciente e sua família, mas também a sociedade como um todo. Estudos realizados pela Organização Mundial da Saúde (OMS) mostraram que a epilepsia atinge índices de aproximadamente 1,5% da população nos países de primeiro mundo e em torno de 3% nos países mais pobres[1]. Estes índices podem ser ainda superiores considerando-se dois aspectos: muitas pessoas não procuram os centros médicos com medo de sofrerem discriminação por parte da sociedade e muitos pacientes não são diagnosticados devido à falta de centros e equipamentos adequados, uma vez que estes possuem um elevado custo. Outro aspecto importante a ser considerado é o custo do tratamento de pacientes com epilepsia. Nos países desenvolvidos este custo pode exceder US\$ 7.000 por paciente ao ano, contudo este valor pode ser maior devido aos custos indiretos, como perda de produção econômica por desemprego, licença médica, subemprego ou morte precoce.

Devido a estes fatores, torna-se muito importante diagnosticar a epilepsia para prescrever o tratamento

necessário, melhorando assim a qualidade de vida do paciente, e reduzindo os custos indiretos.

A epilepsia consiste em um grupo de doenças que tem em comum crises epiléticas que ocorrem na ausência de doença tóxico-metabólica ou febril. Suas causas algumas vezes podem ser identificadas como tumores, traumas, disfunções metabólicas, infecções, doenças vasculares ou uma predisposição genética. Quando não é possível identifica-las são denominadas de idiopáticas.

O eletroencefalograma (EEG) tem sido uma ferramenta indispensável tanto no diagnóstico como no estudo da epilepsia. Estes registros após sua aquisição são analisados por um profissional devidamente habilitado que devido a grande quantidade de informação gerada, muitas vezes demora um longo período de tempo para efetuar seu parecer.

Este fator é responsável, na maioria das vezes, pelo elevado custo do exame e pela demora em emitir um laudo. Os sistemas automáticos de detecção possuem um elevado custo, devido a este fator existem poucos centros especializados operando com estes sistemas sendo que a grande maioria dos registros ainda é efetuada em papel.

Com o objetivo de automatizar o processo de detecção de epilepsia, reduzindo assim os seus custos, grande número de ferramentas e algoritmos e ferramentas matemáticas vêm sendo pesquisados para a detecção de atividades rítmicas e das formas de ondas características da epilepsia.

Considerando o caso de sinais de EEG, contendo eventos epileptiformes, os primeiros relatos de destaque são os trabalhos de Gotman[2,3]. Nesses trabalhos o sinal é dividido em segmentos e seqüências formando meia onda. Para um sinal de EEG, assim tratado, calcula-se a amplitude e a duração. Considera também a correlação entre canais. A detecção do evento epileptiforme é realizada quando os valores medidos ultrapassam certos valores limites. Estes limites são relacionados aos valores reais da duração e amplitude das espículas e ondas agudas. No segundo trabalho de Gotman é obtido juntamente com a amplitude e duração o coeficiente de variação. A detecção do evento acontece, quando esses valores estiverem dentro de limites pré-determinados, para mais de um canal da presente época ou das duas adjacentes.

Em seqüência vários trabalhos apresentaram as vantagens do uso da parametrização das características

dos sinais, principalmente quando aliada com as redes neurais. Merecendo destaque o trabalho de Weber[4], que relata o uso de sinais crus e parametrizados como entradas de redes neurais “feed-forward” com algoritmo de aprendizado “back-propagation”. Como resultado, obtiveram melhor taxa de acertos no caso onde utilizaram o sinal parametrizado.

2. Metodologia

Geralmente, um registro de EEG contendo eventos epileptiformes (espículas e ondas agudas) apresenta juntamente com esses eventos outros tipos de sinais como a atividade de fundo normal, ondas alfa e artefatos como ruídos e piscadas. Para destacar os eventos epileptiformes é necessário diferenciar suas características das características dos outros tipos de sinais que podem estar presentes. Assim para parametrizar intervalos de um sinal contendo uma espícula, por exemplo, é necessário destacar também as características dos sinais que podem estar juntamente presentes. Por essa razão os sinais apresentados para serem parametrizados nesse trabalho são obtidos de trechos de sinais de EEG contendo eventos epileptiformes, atividade de fundo de EEG normal, ondas alfa, ruídos e piscadas.

A base de dados utilizada neste trabalho foi a mesma utilizada por Argoud[5] que foi obtida de pacientes comprovadamente epiléticos, os quais incluem grande quantidade de espículas e ondas agudas. Os sinais foram amostrados em 100 Hz, em 32 canais e montagens bipolares do tipo zigomática-temporal. Os sinais foram pré-filtrados analogicamente em banda de 0,5-40 Hz. Esse banco de dados é dividido em 9 registros, correspondentes a 7 pacientes com dois deles oferecendo sinais em dois períodos diferentes.

Deste banco de dados extraiu-se 18 trechos de sinais contendo eventos epileptiformes, 18 trechos contendo ondas alfa, 18 trechos contendo ruídos, 18 trechos contendo piscadas e 18 trechos de sinais considerados normais. A época utilizada é de 1 segundo (100 pontos), pois épocas menores fornecem informações insuficientes, fragmenta demasiadamente o sinal levando aos problemas de borda, e épocas maiores diminuem a sensibilidade a ocorrência de eventos epileptiformes, que são de curta duração (20 a 200 ms)[5]. Quando se deseja destacar as características de uma espícula, por exemplo, as épocas de 1 segundo favorecem o isolamento de uma única espícula, enquanto em épocas maiores pode aparecer mais de uma espícula, prevalecendo as características da que melhor sobressair.

As características básicas de um evento epileptiforme são relacionadas a sua duração e amplitude. Uma espícula dura de 20 ms a 70 ms, a componente principal é geralmente negativa e a amplitude é alta e variável. Uma onda aguda dura de 70ms a 200 ms, a componente principal é negativa em relação às outras áreas. O crescimento de fase da onda

aguda é como a espícula, mas a fase decrescente é prolongada[6]. As amplitudes são variadas, mas em geral estão em torno de 20 μv e 500 μv , em média estão acima de 20 μv e abaixo de 200 μv .

Uma espícula pode apresentar-se, na maioria dos casos, de quatro formas, como mostra a Figura 1. Portanto, pode-se ter: somente um pico positivo e ondas negativas de baixa amplitude, somente um pico negativo e ondas positivas de baixa amplitude, parte positiva e negativa com o pico positivo aparecendo primeiro e parte negativa e positiva com pico negativo aparecendo primeiro.




Figura 1 – Formas típicas de uma espícula. Em a, parte positiva aparece primeiro. Em b, parte negativa aparece primeiro. Em c, parte negativa acentuada. Em d, parte positiva acentuada.

Após analisar as formas típicas que uma espícula poderia assumir, iniciou-se a programação de um algoritmo que pudesse extrair automaticamente os parâmetros deste sinal.

Para obter o primeiro parâmetro o algoritmo analisa a amplitude da espícula e obtém o valor da amplitude máxima e mínima deste evento. Para caracterizar uma espícula os valores devem estar acima de 20 μv e abaixo de 200 μv .

O segundo parâmetro é determinado calculando a diferença entre a amplitude máxima e mínima. Essa diferença mostra-se mais acentuada no caso de piscadas e ruídos contrastando com uma pequena diferença, quando trata de ondas alfa e atividades de fundo consideradas normais. Essa mesma diferença, no caso dos eventos epileptiformes, não é tão elevada quanto das piscadas (maior que 200 μv) nem tão pequena quanto das ondas alfa (menor que 40 μv). Devido a esse contraste define-se como um parâmetro relevante a diferença entre as amplitudes.

O terceiro parâmetro pode ser obtido através do cálculo da distância entre a amplitude máxima e a amplitude mínima. Este valor é muito pequeno no caso das espículas conforme pode ser observado na Tabela 1.

Tabela 1 – Valores médios obtidos para a distância entre a amplitude máxima e mínima.

Espículas	Atividades Normais	Ruídos	Piscadas	Ondas Alfa
0,6	0,25	0,60	0,17	0,44

O quarto parâmetro é duração do evento. Ele é obtido através do cálculo da distância entre o início e o término do evento. Para que seja caracterizado como uma espícula seu valor deve estar entre 20ms e 70ms.

O quinto parâmetro baseia-se no fato de que um evento epileptiforme apresenta picos mais acentuados quando comparados com os picos mais abertos apresentados pelas ondas alfa ou piscada. Para o mesmo intervalo de 1 segundo, centrado nos pontos de máximo e mínimo, o ângulo é obtido segundo a Equação 1.

$$\theta = 2 * [\arctan(DA) * 180 / \pi] \quad (1)$$

$$DA = \frac{\text{distância}(T_{\text{max}} - \text{início})}{A_{\text{max}}}$$

Onde: Amax é a amplitude máxima da espícula (positiva / negativa), TAmx: é o ponto onde ocorre a amplitude máxima.

O algoritmo também calcula parâmetros estatísticos os quais fornecem uma informação sucinta dos intervalos de EEG analisados. Neste algoritmo foi implementado o cálculo da média, do desvio padrão, da variância, do fator de crista.

O outro parâmetro que é calculado e vem se destacando é a entropia[7], principalmente em algoritmos para reconhecimento de atividades epileptiformes. Ela pode ser considerada como um quantificador de regularidade e complexidade. Assume que o sinal de EEG é uma sequência estroboscópica de N medidas feitas em um intervalo de tempo. É construída uma sequência de vetores usando uma coleção de coordenadas criando um vetor de m dimensões. Para o cálculo da distância entre os vetores define-se um fator r de tolerância da regularidade (ou frequência) de padrões similares.

Após o cálculo destes parâmetros e análise dos resultados obtidos, verificou-se a necessidade de utilizar um método que a partir dos parâmetros calculados, agrupasse os dados semelhantes. Isto permite verificar se o intervalo de EEG analisado apresenta parâmetros que podem ser classificados dentro do grupo das espículas.

Para realizar o agrupamento dos dados utilizou-se a rede SOM (Self-organizing maps) também conhecida como mapas auto-organizáveis. O SOM é caracterizado pela formação de um mapa topográfico dos padrões de entrada no qual as localizações espaciais dos neurônios na grade são indicadas das características estatísticas intrínsecas contidas nos padrões de entrada[8]. Dentro do SOM pode-se distinguir três processos essenciais responsáveis pela sua formação,

são eles a competição, cooperação e adaptação sináptica[9].

O algoritmo de treinamento desta rede realiza a inicialização escolhendo valores aleatórios para os pesos, retira uma amostra do espaço de entrada e em seguida entra em um looping onde permanece até que as características do mapa não sejam mais alteradas. Dentro deste looping, para cada padrão de treinamento é definido um vencedor usando o critério da distância euclidiana e os vetores de peso deste nodo e de seus vizinhos são atualizados.

Como dados de entrada para realizar o treinamento do SOM foram utilizados os parâmetros de 90 intervalos de EEG, sendo 18 intervalos com espículas, 18 intervalos contendo atividade de fundo normal, 18 intervalos contendo ondas alfa, 18 intervalos contendo ruídos e 18 intervalos contendo piscadas. Cada um destes intervalos é constituído de um grupo composto de 11 parâmetros (amplitude máxima e mínima, diferença entre amplitudes, duração do evento, ângulo do evento, média, desvio, variância, fator de crista e entropia).

O resultado do treinamento do SOM é fornecido a um algoritmo que armazena estas informações em um arquivo e plota os clusters na tela, identificando a qual grupo de sinal eles pertencem.

Para detectar a ocorrência de espículas a análise é realizada em intervalos de 1 segundo contendo 32 canais. O algoritmo desenvolvido calcula os parâmetros destes canais, fornece estes como entrada para a rede SOM treinada, que realiza a simulação e passa os resultados para um algoritmo. Este por sua vez, plota todos os clusters na tela identificando a qual grupo pertencem, baseado nas informações recebidas do treinamento da rede SOM.

3. Resultados

Após alguns testes com o SOM, optou-se pela utilização de vetores de peso e parâmetros normalizados, que permitiram a rede aumentar seu limiar e reduzir assim a chance de um nodo ser selecionado mais de uma vez. Esta alteração foi muito importante no trabalho uma vez que os pesos iniciais aleatórios não estavam conseguindo definir os clusters corretamente.

Para definir o grid da camada competitiva e o número de interações foram realizados vários testes com valores diferentes para cada um. O melhor resultado foi obtido utilizando um grid de 7x7 com 3000 interações. Os grids menores agruparam vários tipos de sinais diferentes no mesmo grupo e os maiores distribuíram estes sinais por todo o mapa não permitindo a formação de clusters que pudessem ser identificados. O número de interações foi escolhido baseado no fato de que a taxa de aprendizagem segundo a literatura[9] deve iniciar com valor próximo a 0,1 e permanecer acima de 0,01. Visualmente foi possível verificar que interações maiores não afetavam a distribuição dos clusters. A

partir destas definições, foi possível separar os sinais em três grupos distintos, sendo o primeiro grupo formado pelas piscadas e ruídos, o segundo pela atividade de fundo normal e ondas alfa e o terceiro pelas espículas, sendo que o grupo das espículas em todas as simulações subdividiu-se em dois grupos, um posicionado na parte superior e outro na parte inferior do mapa. (Figura 1).




Figura 1 – Resultado do treinamento do SOM. Os pontos agrupados a esquerda representam as piscadas e ruídos, os pontos agrupados no centro superior e inferior as espículas e os pontos agrupados a direita superior ondas alfa e atividade de fundo normal.

Para permitir uma melhor visualização de como foram agrupados os sinais (espículas, ondas alfa, ruído, piscada e atividade de fundo normal) após o treinamento, o algoritmo desenvolvido permite plotar a localização destes no mapa. Durante o treinamento do SOM, cada vez que existe um neurônio vencedor um algoritmo identifica sua posição no grid e o tipo de sinal a que ele pertence. A Figura 2, mostra a distribuição dos sinais no mapa após término do treinamento.




Figura 2 – Resultado do SOM após o treinamento. Esta tela permite visualizar em um grid a localização de cada sinal fornecido como entrada para a rede.

Após o treinamento do SOM, vários intervalos de EEG foram testados, e a rede conseguiu satisfatoriamente realizar o agrupamento dos sinais. A Figura 3 mostra o resultado da simulação efetuada com

1 segundo de EEG contendo apenas atividade de fundo normal em todos os 32 canais. Nesta figura pode-se observar que os sinais formaram clusters apenas na parte direita e nenhum sinal ficou na área central onde no treinamento ficaram os clusters das espículas. A Figura 4 mostra o resultado da simulação realizada com 1 segundo de EEG contendo espículas em 9 canais, e como pode ser visualizado nesta figura as espículas formaram um cluster na parte central superior e os outros 23 canais formaram um cluster na parte direita superior.




Figura 3 – Resultado da simulação com 1 segundo de EEG contendo atividade normal de fundo nos 32 canais.




Figura 4 – Resultado da simulação com 1 segundo de EEG contendo espículas em 9 dos 32 canais.

4. Discussões e Conclusões

Através deste trabalho verificou-se que é possível detectar espículas utilizando os mapas auto-organizáveis. Fornecendo como dados de entrada da rede os parâmetros ao invés do registro completo de EEG foi possível obter melhores resultados com menores recursos computacionais. Nos testes realizados utilizando o registro completo a rede não conseguiu separar os clusters de maneira que fosse possível efetuar o reconhecimento das espículas.

Outro fator importante a ser destacado é que através da escolha dos parâmetros corretos conseguiu-se isolar a espícula dos outros tipos de sinais presentes no EEG. A formação de dois clusters para as espículas deve-se ao fato dos quatro padrões diferentes que elas podem apresentar.

O algoritmo desenvolvido permite agilizar o processo de detecção uma vez que ele calcula os parâmetros de entrada necessários, envia estes dados para a entrada da rede e realiza a interpretação dos clusters formados.

Referências

- [1] SANDER, J.W.A.S.; SHORVON, S.D. Incidence and prevalence studies in epilepsy and their methodological problems: A review. *J. Neurol. Neurosurg. Psychiatr.* v.62, p.829-839, 1999
- [2] GOTMAN, J., GLOOR, P. Automatic Recognition of Epileptic Seizures in the EEG, *Electroencephalography and Clinical Neurophysiology*, vol.41, pp.513 – 529, 1976.
- [3] GOTMAN, J., Automatic Recognition of Epileptic Seizures in the EEG, *Electroencephalography and Clinical Neurophysiology*, vol.54, pp.530 – 540, 1982.
- [4] WEBBER, W. R. S., Litt, B., Wilson, K., Lesser, R. P., Practical Detection of Epileptiform Discharges (EDs) in the EEG Using an Artificial Neural Network: a Comparison of Raw and Parameterized EEG Data. *Electroencephalography and Clinical Neurophysiology*, vol.91, pp.194-204, 1994.
- [5] ARGOD, F. I. M., *Contribuição ao Estudo da Automatização da Detecção e Análise de Eventos Epileptiformes em Eletroencefalograma.*, Tese, Universidade Federal de Santa Catarina, Instituto de Engenharia Biomédica, Florianópolis, 2001.
- [6] NIEDERMEYER E.; SILVA F. L., *Electroencephalography Basic Principles, Clinical Applications, and Related Fields.* Williams & Wilkins, 1993.
- [7] QUIROGA, Q., ROSSO, O. A., BASAR, E., *Wavelet Entropy: a Measure of Order in Evoked Potentials.* *Physiological Neuroscience*, pp.298-302, 1999.
- [8] KOHONEN, T. *The self-organizing map.*, *Proceedings of the IEEE.*, vol.78, pp. 1464-1480, 1990.
- [9] HAYKIN, S. *Neural Network.*, 2 ed., 2001.References