




## Detecção automática de epilepsia generalizada através da análise espectral singular multivariada

 <https://doi.org/10.56238/levv15n39-016>

**Carlos Alberto Orge Pinheiro**

Doutor em Modelagem Computacional e Tecnologia Industrial

Universidade do Estado da Bahia – Uneb

E-mail: [capinheiro@uneb.br](mailto:capinheiro@uneb.br)

---

### RESUMO

A coleta e a interpretação dos sinais do eletroencefalograma (EEG) são atividades trabalhosas e demoradas, necessitando de um especialista treinado para realizá-las. A detecção automática da epilepsia pode ser uma solução. No entanto, as pesquisas sobre o assunto têm se concentrado na detecção de epilepsias específicas e não generalizadas em uma população maior de pacientes. Decomposição de sinais, através de análise de espectro singular, de registros de pacientes com epilepsia para posterior verificação do limite de energia. Esses registros estavam disponíveis em um banco de sinais de acesso público. A utilização de diferentes pesos para cálculo de médias e desvios padrão das séries de energia e diferentes extensões amostrais contribuíram para melhorar o diagnóstico.

**Palavras-chave:** Epilepsia, Detecção Automática Generalizada, Análise Espectral Singular Multivariada.

## 1 INTRODUÇÃO

Classificada como uma desordem neurológica que afeta o cérebro, a epilepsia atinge cerca de 50 milhões de pessoas em todo o mundo conduzindo a redução da produtividade e impondo restrições na vida diária (BERGIL; YILDIZ, 2016). Seu diagnóstico dado por neurofisiologistas apoia-se na análise visual das flutuações rítmicas do cérebro descritas pelo eletroencefalograma (EEG).

Acontece que, conforme descrito em Bajaj e Pachori (2013) e Scolaro (2014), o diagnóstico dos padrões anormais do EEG através da análise visual é uma atividade trabalhosa e demorada. Isso porque exige a leitura de até 21 canais que são visualizados em telas de 10 segundos. Além de trabalhosa e demorada também pode, por conta da subjetividade, apresentar diferentes análises quando realizada por neurofisiologistas experientes (SCOLARO, 2014).

Visando reduzir a carga de trabalho, algumas técnicas (OROSCO et al., 2009; BAJAJ; PACHORI, 2013; SCOLARO, 2014; BERGIL; YILDIZ, 2016) sobre detecção automática dos padrões anormais no EEG são propostas em estudos sobre o assunto. Através de diferentes metodologias fazem uso de modelos de decomposição de sinal, que tratam as flutuações rítmicas do cérebro, a partir das quais as componentes tendência, harmônica e ruído sejam extraídas. Em seguida, classificadores das características dessas componentes fazem a identificação dos padrões. A importância destes modelos é vista na descrição da aplicação da transformada discreta de wavelet (TDW), decomposição em valor singular (DVS), decomposição em modo empírico (DME) além da análise de componentes principais (ACP) (ALOTAIBY et al., 2014).

Não há dúvida sobre a contribuição dos modelos de decomposição de sinal para detecção automática dos padrões EEG anormais, no entanto, o uso da análise espectral singular (AES) em investigações (SHAHID et al., 2013; PARVEZ; PAUL, 2014; THANARAJ; CHITRA, 2014) para a detecção dos padrões EEG anormais, cujas epilepsias são classificadas como generalizadas, não apresentou os melhores desempenhos quando comparadas com o uso dos modelos DME e TDW (OROSCO et al., 2009; BAJAJ; PACHORI, 2013; BERGIL; YILDIZ, 2016).

Com base em buscas realizadas em periódicos nacionais e internacionais, não foram encontradas investigações sobre a identificação de padrões de EEG anormais, cujas epilepsias sejam classificadas como generalizadas, através do modelo análise espectral singular multivariada (AESM).

Embora as características dos sinais através da AES sejam extraídas, correspondendo aos fenômenos fisiológicos subjacentes, ao considerar a análise multivariada identificam-se as harmônicas comuns garantindo informação mais consistente sobre a frequência (SANEI; HASSANI, 2016). Com isso, espera-se que pelo seu uso sejam identificados os padrões anormais no EEG das epilepsias classificadas como generalizadas, úteis ao processo de detecção automática, através das manifestações da maior variabilidade dos sinais.

Portanto, buscando contribuir com investigações sobre identificação dos padrões anormais no EEG cujas epilepsias sejam classificadas como generalizadas, aplica-se o modelo de análise espectral singular multivariada aos registros do EEG e, em seguida, procede-se o cálculo do limite de energia de mínima duração com o intuito de melhorar o desempenho da identificação destes padrões.

## 2 ANÁLISE ESPECTRAL SINGULAR MULTIVARIADA

As primeiras investigações sobre o modelo AESM foram feitas com dados associados ao clima e representados por localidades ou regiões próximas num mapa (KEPPENNE; GHIL, 1993; PLAUT; VAUTARD, 1994). Em seguida, os trabalhos realizados foram aplicados sobre dados da economia, a exemplo de Patterson et al. (2011), bem como sobre a produção de diferentes segmentos industriais, conforme Hassani e Mahmoudvand (2013) além de Pinheiro e Senna (2015).

Em sua apresentação o modelo de análise multivariada consiste nos estágios complementares: decomposição e reconstrução (HASSANI; MAHMOUDVAND, 2013). O primeiro estágio complementar é formado pelos passos incorporação e DVS, e o estágio reconstrução é dado pelo passo agrupamento, responsável por agrupar as componentes do sinal excluindo-se o ruído, além do passo média diagonal.

O passo incorporação pode ser considerado como um mapeamento que transfere um conjunto  $M$  de sinais, com comprimento  $N$  ou quantidade de observações no período investigado, unidimensionais  $Y^{(i)} = y_1^{(i)}, \dots, y_N^{(i)}$ , para uma matriz multidimensional  $[X_1^{(i)}, \dots, X_K^{(i)}]$ . Seus vetores  $x_j^{(i)} = (y_j^{(i)}, \dots, y_{j+L}^{(i)})^T \in R^{L_i}$ , onde  $i = 1, \dots, M$ , com  $L$  correspondendo ao comprimento da janela e  $K = N - L + 1$  ao número de colunas da matriz trajetória  $X^{(i)}$ . Os vetores  $x_j^{(i)}$  são chamados de vetores defasados.

Por utilizar um conjunto  $M$  de sinais, conforme descrito em Hassani e Mahmoudvand (2013), o comprimento da janela  $L$  pode ser um número inteiro  $L = N + 1 / (M + 1)$ . O resultado do passo incorporação é a formação do bloco de matrizes trajetórias  $X_V$ , conforme:

$$X_V = \begin{bmatrix} X^{(1)} \\ \vdots \\ X^{(M)} \end{bmatrix} \quad (01)$$

o bloco de matrizes trajetórias  $X_V$  representa um formato vertical, ou seja, as matrizes trajetórias são dispostas verticalmente, uma abaixo da outra. Na literatura elas também são dispostas horizontalmente ou lado a lado, no entanto, para Hassani e Mahmoudvand (2013) o formato vertical considera melhor o efeito da correlação cruzada e questões de ortogonalidade, sendo por isso aplicado nesta investigação.

Na DVS para  $X_V X_V^T$  denota-se por  $\lambda_{V_1}, \dots, \lambda_{V_{M \times L}}$  os autovalores de  $X_V X_V^T$  em ordem decrescente de magnitude ( $\lambda_{V_1} \geq \dots \geq \lambda_{V_{M \times L}} \geq 0$ ) e por  $U_{V_1}, \dots, U_{V_{M \times L}}$  os autovetores ortogonais. A matriz  $X_V X_V^T$ , de dimensão  $(ML \times ML)$ , é dada conforme:

$$X_V X_V^T = \begin{bmatrix} X^{(1)} X^{(1)T} & X^{(1)} X^{(2)T} & \dots & X^{(1)} X^{(M)T} \\ X^{(2)} X^{(1)T} & X^{(2)} X^{(2)T} & \dots & X^{(2)} X^{(M)T} \\ \vdots & \vdots & \ddots & \vdots \\ X^{(M)} X^{(1)T} & X^{(M)} X^{(2)T} & \dots & X^{(M)} X^{(M)T} \end{bmatrix} \quad (02)$$

Considerando que:  $E_{V_i} = \sqrt{\lambda_{V_i}} U_{V_i} V_{V_i}^T$

$$X_V = E_{V_1} + \dots + E_{V_D} \quad (03)$$

onde  $E_{V_i} = \sqrt{\lambda_{V_i}} U_{V_i} V_{V_i}^T$  representa um bloco de matrizes elementares,  $V_{V_i} = X_V^T U_{V_i} / \sqrt{\lambda_{V_i}}$ , o conjunto  $\sqrt{\lambda_{V_i}}, U_{V_i}, V_{V_i}$  como autotripla e  $D = \max\{i \mid \lambda_{V_i} > 0\}$ , ou seja, o número de autovalores de  $X_V X_V^T$  diferentes de zero.

O passo agrupamento corresponde em dividir as matrizes dos blocos de matrizes elementares  $E_{V_1}, \dots, E_{V_D}$  em grupos disjuntos somando-as dentro de cada grupo. O desdobramento do conjunto de índices  $J = \{1, \dots, D\}$  em subconjuntos disjuntos  $I_1, \dots, I_m$  corresponde a representação:

$$X_V = E_{V_{I_1}} + \dots + E_{V_{I_m}} \quad (04)$$

com  $E_{V_{I_1}}, \dots, E_{V_{I_m}}$  definidos como blocos de matrizes resultantes.

Como um caso simples, para o domínio da frequência, que apresenta as componentes do sinal, são utilizados dois grupos de índices, conforme  $I_1 = \{1, \dots, a\}$  e  $I_2 = \{a+1, \dots, D\}$ , o primeiro grupo associado a tendência e harmônica e o segundo ao ruído, com  $a$  um inteiro maior que 1. Assim, as matrizes do bloco de matrizes resultantes devem ser posteriormente convertidas a um vetor  $\tilde{y}_N^{(i)}$  através do passo média diagonal.

Se considerarmos o sinal unidimensional  $Y^{(i)} = [y_1^{(i)}, \dots, y_N^{(i)}]^T$  o mesmo será dado por:

$$X^{(i)} = \begin{bmatrix} y_{1,1}^{(i)} & y_{1,2}^{(i)} & y_{1,3}^{(i)} & \cdots & y_{1,K}^{(i)} \\ y_{2,1}^{(i)} & y_{2,2}^{(i)} & y_{2,3}^{(i)} & \cdots & y_{2,K}^{(i)} \\ y_{3,1}^{(i)} & y_{3,2}^{(i)} & y_{3,3}^{(i)} & \cdots & y_{3,K}^{(i)} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ y_{L,1}^{(i)} & y_{L,2}^{(i)} & y_{L,3}^{(i)} & \cdots & y_{L,K}^{(i)} \end{bmatrix} \quad (05)$$

com  $y_{1,1}^{(i)}$  representando a primeira observação do sinal ( $i$ ) disposta na primeira linha e coluna e  $y_{L,1}^{(i)}$  a observação  $L$  do sinal ( $i$ ) disposta na linha  $L$  e primeira coluna. Ainda na mesma matriz  $y_{1,2}^{(i)}$  que indica ocupar a primeira linha e segunda coluna é a segunda observação do sinal ( $i$ ), também disposta em  $y_{2,1}^{(i)}$  uma vez que as observações são apresentadas de modo defasado. Assim, a média diagonal será obtida conforme:

$$\tilde{x}^{(i)} = \begin{bmatrix} y_{1,1}^{(i)} \\ \frac{y_{1,2}^{(i)} + y_{2,1}^{(i)}}{2} \\ \frac{y_{1,3}^{(i)} + y_{2,2}^{(i)} + y_{3,1}^{(i)}}{3} \\ \vdots \\ \vdots \\ y_{L,K}^{(i)} \end{bmatrix} \quad (06)$$

Mais informações sobre o modelo podem ser vistas em Hassani e Mahmoudvand (2013).

### 3 MATERIAIS E MÉTODO

O conjunto de dados usado neste estudo foi extraído de 171 arquivos com um total de 181 eventos epiléticos. Estes eventos foram identificados por neurofisiologistas experientes e disponíveis no banco de dados do Institute for Signal and Information Processing (ISIP).

Aos sinais foi utilizado o filtro *butterworth* com largura de faixa de 0,5 a 25 Hz, por ser esta a faixa de frequência patológica (RUNARSSON; SIGURDSSON, 2005; PARREIRA, 2006; YOO et al. 2013; SCOLARO, 2014). A aplicação do filtro é definida na literatura como pré-processamento. Em seguida, os sinais (amostragem em 256 Hz) pré-processados foram decompostos através do modelo AESM.

A metodologia proposta é dada em três etapas: ajuste preliminar, treinamento e teste.

Para fins da investigação a decomposição multivariada dos sinais foi obtida calculando as matrizes elementares para cada canal. Após ajuste preliminar, concluiu-se que as 10 primeiras matrizes elementares (convertidas em 10 sub sinais através da média diagonal) contribuíram para a detecção dos padrões EEG anormais, e assim foram utilizadas. Isso deve-se ao fato de que as primeiras matrizes conseguem explicar a maior variabilidade do sinal (GOLYANDINA; KOROBEYNIKOVA, 2013).

Considerando que  $\tilde{y}_N^{(i)}$  representa um sub sinal obtido a partir da matriz elementar cada um deles será utilizado para o cálculo da energia, conforme:

$$E_{seg_j} = \frac{1}{H} \sqrt{\sum_{H/2-f+(j-1)*H-(j-1)*2}^{f+H/2-1} (\tilde{y}_N^{(i)})^2} \quad (07)$$

com  $seg$  o número do segmento sendo um inteiro dado no intervalo  $j = 1, 2, \dots, sr \times ti / (H/2) - 1$ ,  $sr$  a taxa de amostragem,  $ti$  o intervalo de tempo utilizado em segundos,  $H$  a extensão em amostras da janela sobreposta móvel para o cálculo da energia e  $f$  dado por  $((H/2) - 1) * j$ .

Para efeito ilustrativo, considerando  $ti$  igual a 10 segundos ou 2560 amostras, são formados 101 segmentos. O primeiro segmento definido pelas amostras 1 a 50, o segundo segmento de 26 a 75 e assim sucessivamente para definição da energia em (07) para cada um dos 101 segmentos.

Na investigação  $H$  corresponde a 20,3125% da amostragem em 256 Hz, com a intenção de capturar os efeitos dos padrões EEG anormais (ondas agudas e espículas), uma vez que estes padrões situam-se em intervalos de 80 a 200 milissegundos.

Com base na energia o limite de energia de mínima duração para cada segmento (OROSCO et al., 2009) é dado por:

$$Thr = 1,0 \times mean(E_{seg}) + 1,5 \times standard\ deviation(E_{seg}) \quad (08)$$


com  $mean(E_{seg})$  e  $standard\ deviation(E_{seg})$  correspondendo a média e ao desvio padrão da  $ith$  série da energia, do canal do EEG analisado, enquanto que 1 e 1,5 os respectivos pesos.

Após a definição da energia com base na janela sobreposta móvel um evento será tido como epiléptico (BAJAJ; PACHORI, 2013), como parte da série da energia que ultrapassa  $Thr$ . Os autores buscaram determinar os eventos presentes na energia de cada canal para, em seguida, identificar se a energia ultrapassou o limite dado em (08).

Também na etapa de ajuste preliminar verificou-se que quando a energia obtida ultrapassar esse limite em pelo menos 8 sub sinais dos 10 primeiros escolhidos o intervalo analisado apresenta padrões

EEG anormais. Na Figura 1 pode-se verificar quando a energia de um dos sub sinais investigados é superior a  $Thr$ , definida pela linha tracejada.

Figura 1 – Detecção de evento epilético através do limite de energia de mínima duração definido pela linha tracejada



Em seguida é realizada uma decisão intercanal, ou seja, são escolhidos os canais em que o limite de energia de mínima duração foi superado em pelo menos 8 sub sinais. Baseado na metodologia aplicada em Orosco et al. (2009), que busca identificar o mesmo comportamento (energia superior ao limite de energia de mínima duração) entre canais, também na etapa de ajuste preliminar desta investigação, verificou-se que quando este comportamento ocorre em pelo menos 3 canais dos canais disponíveis, o intervalo é dado como epilético.

Ao contrário do limite de energia ser definido por pesos fixos para média e desvio-padrão, conforme (08), os pesos para média e desvio-padrão foram definidos para faixas de amplitude do canal do EEG analisado. Isto deve-se ao fato que a correta definição dos limiares exerce papel importante no desempenho da detecção automática dos padrões EEG anormais.

A definição dos pesos por faixas de amplitude, na etapa de treinamento, é dada pela aplicação de um otimizador com mecanismo evolucionário (pacote Solver no Programa R) levando em conta uma função com objetivo de maximizar o número de verdadeiro-positivo (PV), tendo como variáveis de decisões os pesos e como restrição que o índice de sensibilidade (o índice de sensibilidade indica a habilidade da metodologia proposta em identificar os padrões EEG anormais quando os mesmos estão presentes) fosse superior a 95%, ou seja, identificar os padrões EEG anormais quando os mesmos estão presentes.

Do banco de dados disponível foi escolhido 50% dos intervalos nos quais sabe-se da existência dos padrões EEG anormais, devidamente identificados e descritos no banco de dados.

Após esta etapa de treinamento com proposta de melhoria, para a etapa de teste foi usando os outros 50% do banco de dados e todos os eventos marcados como eventos epiléticos feitos por neurofisiologistas e disponíveis no banco de dados. O uso deste conjunto permite verificar a generalização da metodologia proposta.

Para efeito de comparação entre os desempenhos obtidos também foram utilizados pesos fixos para a média e o desvio-padrão no cálculo da energia de mínima duração, conforme descrito em (08).

Na literatura o índice de especificidade indica a habilidade em identificar os padrões EEG normais quando presentes. Desta maneira, os achados da metodologia foram confrontados com as marcações feitas pelos neurofisiologistas.

#### 4 RESULTADOS E DISCUSSÕES

Na Tabela 1 podem ser vistos os pesos, obtidos na fase de treinamento com proposta de melhoria, responsáveis pelos maiores índices de sensibilidade e especificidade.

Tabela 1 – Pesos por faixa de amplitude

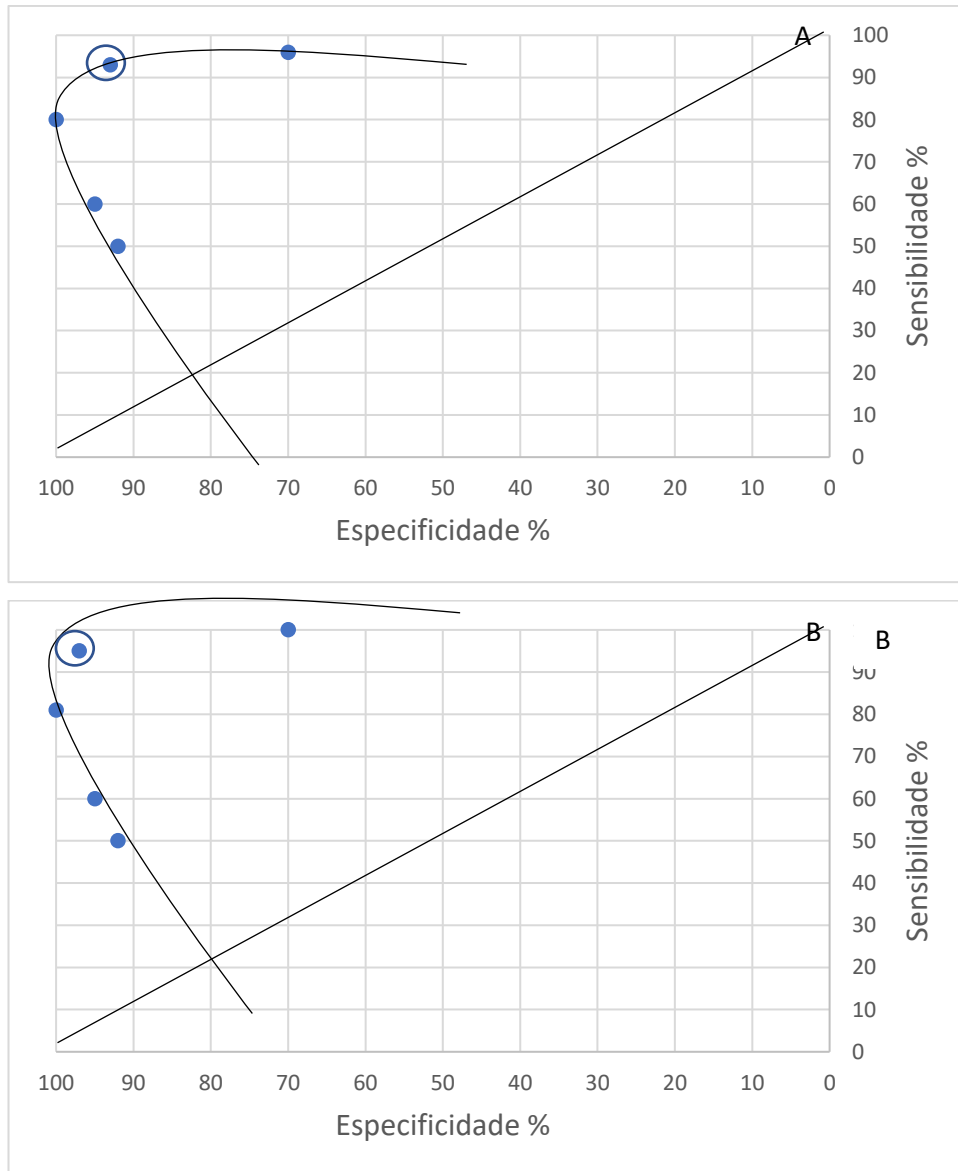
Faixa de Amplitude em $\mu\text{V}$	Peso média	Peso Desvio Padrão
-20 a 0	6.0	2.6
-40 a -20	5.2	4.0
-60 a -40	7.8	2.9
-80 a -60	8.3	5.4
-100 a -80	1.2	7.7
-120 a -100	2.7	8.9
-140 a -120	6.7	0.8
-160 a -140	6.5	2.0
-180 a -160	1.7	5.9
-200 a -180	8.0	3.1
-220 a -200	5.9	0.0
-240 a -220	0.0	8.0
-260 a -240	5.0	6.6
-280 a -260	4.4	8.0
-300 a 280	3.0	7.4
-320 a -300	4.0	6.3
-340 a -320	1.8	4.5
-360 a -340	4.7	8.6
-380 a 360	3.8	3.8
-400 a -360	7.1	4.0
abaixo de -400	9.5	4.3

$\mu\text{V}$  - milionésimo de volt

Na Figura 2 são representadas as curvas Receiver Operating Characteristic (ROC) para as versões com pesos fixos (painel A) e pesos por diferentes faixas de amplitude (painel B). Através das curvas é possível identificar o poder de discriminação da metodologia de diagnóstico proposta cujo melhor valor corresponde a 0,96.



Figura 2 – Curvas ROC com pesos por valores fixos e pesos por faixa de amplitude, respectivamente de cima para baixo, sendo possível identificar nas curvas os pares ordenados que descrevem o comportamento dos índices de diagnóstico, sendo a combinação ótima de sensibilidade e especificidade localizado na parte superior e à esquerda das figuras.



Além da Figura 2, na Tabela 2 os índices de diagnóstico ajudam a confirmar o melhor desempenho para a investigação proposta com base nos pesos por faixas de amplitude com 97% de sensibilidade e 95% de especificidade quando comparado com aqueles obtidos com base em pesos fixos. Com pesos de 1 para média e 1,5 para o desvio-padrão, em qualquer faixa de amplitude, os resultados obtidos foram de 93% de sensibilidade, 94% de especificidade e AUC de 0,94.

Tabela 2 – Resultados obtidos pelo método proposto e em outras investigações

Índices de desempenho	Método proposto pesos por faixas de amplitude	Método proposto pesos fixos	Orosco et al (2009)	Bajaj e Pachori (2013)	Bergil e Yildiz (2016)
Sensibilidade	97%	93%	42%	90%	91%
Especificidade	95%	94%	80%	88%	92%
ROC	0,96	0,94	0,55	0,92	0,91

ROC – Receiver Operating Charac

O modelo AESM e uso de pesos para média e desvio-padrão, em diferentes faixas de amplitude para definição da energia e do limite de energia de mínima duração na detecção dos padrões EEG anormais foram aplicados nesta investigação. O modelo de decomposição de sinais AESM por ser não paramétrico e indicado para sinais não estacionários contribui na resolução da análise de sinais não estacionários, sendo capaz de extrair padrões dos sinais (SANEI; HASSANI, 2016). Ao levar em consideração as relações existentes entre os canais também foi útil para a identificação dos padrões EEG anormais no EEG das epilepsias classificadas como generalizadas.

Na metodologia proposta o principal argumento para o uso de pesos por faixas de amplitude é que a correta definição dos limiares exerce papel importante na identificação da maior variabilidade do sinal. Isto é visto ao serem confrontados os resultados obtidos pela investigação quando fez uso de pesos por faixa de amplitude ou quando os mesmos foram fixos conforme pesquisas já realizadas (OROSCO et al., 2009; BAJAJ; PACHORI, 2013; BERGIL; YILDIZ, 2016).

Assim, uma vez que os padrões EEG anormais são responsáveis por elevada energia, através da alteração dos pesos da média e do desvio-padrão para definição do limite de energia de mínima duração, foi possível obter o melhor desempenho no processo de detecção automática.

Ainda que os pesos da média e do desvio-padrão sejam fixos a metodologia proposta conseguiu capturar os padrões EEG anormais apresentando potencial para auxiliar na detecção automática em relação às investigações de Orosco et al. (2009) e Bajaj e Pachori (2013) que também fizeram uso de pesos fixos para definição do limite de energia de mínima duração e uso do modelo DME ou da investigação que faz uso das características entropia e energia (BERGIL; YILDIZ, 2016) com aplicação da TDW. Diferente da investigação proposta, todas estas pesquisas foram baseadas em análise univariada.

Desta maneira, sobre as vantagens da metodologia proposta sobressai-se seu carácter multivariado, quando comparada com os modelos DME ou aplicação da TDW. No entanto, para a investigação os intervalos utilizados são de 10 segundos, conforme o padrão adotado por alguns neurofisiologistas e, desta maneira, fazendo uso de um menor número de amostras.

Este melhor desempenho do modelo AESM foi possível ao verificar outras possibilidades de pesos fixos frente aos obtidos por DME e TDW e deve-se também ao fato de que a análise multivariada



é capaz de identificar as harmônicas (variabilidade) entre um conjunto de sinais garantindo informação mais consistente sobre a frequência (SANEI; HASSANI, 2016).

## 5 CONCLUSÕES

Diante do exposto na presente pesquisa, fica evidente que o uso da AESM na metodológica proposta demonstrou-se capaz de identificar os padrões EEG anormais das epilepsias classificadas como generalizadas. A aplicação de diferentes pesos para média e desvio padrão da *ith* série da energia em faixas de amplitude melhorou o desempenho da detecção destes padrões anormais.

Em futuras pesquisas seria interessante aplicar a metodologia proposta em sinais de EEG por aplicação de eletrodos colocados diretamente sobre a superfície exposta do cérebro durante uma cirurgia ou num maior número de canais, promover alterações no valor da extensão em amostras da janela sobreposta móvel para o cálculo da energia com objetivo de verificar melhoria na identificação dos padrões EEG além de revisar ou aperfeiçoar as decisões tomadas na etapa de ajustes preliminares.



## REFERÊNCIAS

- ALOTAIBY, T. N. et al. EEG seizure detection and prediction algorithms: a survey. *EURASIP Journal on Advances in Signal Processing*, v. 2014, n. 1, p. 1-22, 2014.
- BAJAJ V. PACHORI, R. B. Epileptic seizure detection based on the instantaneous area of analytic intrinsic mode functions of EEG signals. *Biomedical Engineering Letters*. v. 3, n. 1, p. 17–21, 2013.
- BERGIL, E; YILDIZ, M. Comparison of seizure detection performances of features based on wavelet transform and empirical mode decomposition. *Journal of New Results in Science*, v. 16, n. 6, p. 288-297, 2016.
- GOLDBERGER, A. L. et al. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation*, 2000; v. 101, n. 23, p. 215-20, 2000.
- GOLYANDINA, N; KOROBEYNIKONA, A. Basic Singular Spectrum Analysis and forecasting with R. *Computational Statistics & Data Analysis*, v. 22, p. 1-40, 2013.
- HASSANI, H; MAHMOUDVAND. R. Multivariate singular spectrum analysis: a general view and new vector forecasting approach. *International Journal of Energy and Statistics*, v. 1, n. 1, p. 55–83, 2013.
- KEPPENNE C. L; GHIL, M. Adaptive filtering and prediction of noisy multivariate signals: an application to subannual variability in atmospheric angular momentum. *International Journal of Bifurcation and Chaos*, v. 3, n. 3, p. 625-34, 1993.
- OROSCO, L. et al. An epileptic seizures detection algorithm based on the empirical mode decomposition of EEG. In: *Proceedings of the International Conference of the IEEE EMBS; 2009*, Minneapolis, Minnesota. Anais... Minneapolis, Minnesota: IEEE Publisher; 2009. p. 2651-2654.
- PARREIRA, F. J. Detecção de crises epilépticas a partir de sinais eletroencefalográficos 2006. 100f. Tese (Doutorado em Engenharia). Universidade Federal de Uberlândia; Uberlândia, 2006.
- PATTERSON, K; HASSANI, H; HERAVI, S; ZHIGLJAVSKY, A. Multivariate singular spectrum analysis for forecasting revisions to real-time data. *Journal of Applied Statistics*, v. 38, n. 10, p. 2183-2211, 2011.
- PINHEIRO, C. A. O; SENNA, V. Previsão da produção industrial por meio da análise espectral multivariada. *Exacta*, v. 13, n. 1, p. 27–43, 2015.
- PLAUT, G; VAUTARD, R. Spells of low-frequency oscillations and weather regimes in the Northern Hemisphere. *Journal of the Atmospheric Sciences*, v. 51, n. 2, p. 210-36, 1994.
- RUNARSSON, T. P; SIGURDSSON, S. On-line detection of patient specific neonatal seizures using support vector machines and half-wave attribute histograms. In: *International Conference on Computational Intelligence for Modelling, Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCA-IAWTIC'06)*, 2005, Viena. Anais... Viena: IEEE Publisher; 2005. p. 673-677.
- SANEI, S; HASSANI, H. *Singular spectrum analysis of biomedical signals*. Boca Raton: Taylor & Francis Group; 2016.



SCOLARO, G. R. Sistema computacional automatizado para a identificação e contagem de eventos epileptiformes em sinais de eletroencefalografia de longa duração. 2014. 100 f. Tese (Doutorado em Engenharia) Universidade Federal de Santa Catarina, Santa Catarina, 2014.

YOO, J. et all. An 8-channel scalable EEG acquisition SoC with patient-specific seizure classification and recording processor. *Journal of Solid-State Circuits*, v. 48, n. 1, p. 214-28, 2013.