

Detecção de Potenciais Evocados no Eletroencefalograma: Uma Abordagem Multivariada com Modelos Autoregressivos

Mateus Silva Ribeiro
Departamento de Engenharia Elétrica
Universidade Federal de Viçosa
Viçosa – MG, Brasil
mateus.s.ribeiro@ufv.br

Resumo—O eletroencefalograma (EEG) é amplamente reconhecido como uma ferramenta poderosa para a detecção de doenças neurológicas e certos tipos de deficiências. A partir da estimulação sensorial, o EEG permite a identificação de potenciais evocados, que são respostas cerebrais de baixa amplitude imersos em ruído. Os potenciais evocados desempenham um papel crucial no diagnóstico clínico. As técnicas de detecção de potenciais evocados são fundamentadas em métodos estatísticos, que são empregados para avaliar se há ou não uma resposta presente no EEG. Tradicionalmente, utiliza-se técnicas univariadas, usando apenas um canal para a detecção da resposta. No entanto, técnicas multivariadas têm sido amplamente estudadas e demonstrado desempenho, permitindo o uso simultâneo de múltiplos canais de EEG. Nesse cenário, é necessário considerar a correlação entre os sinais em diferentes canais. A correlação entre os canais do EEG desempenha um papel significativo no desempenho dos detectores multivariados. Portanto, o objetivo deste estudo é propor um método que utilize o modelo multivariado autorregressivo para ajustar os detectores e comparar com as técnicas consolidadas de correlação e espectro cruzado, com intuito aumentar a detecção dos potenciais evocados, ao extrair as características do modelo. Os resultados obtidos demonstraram a eficácia do método proposto. Ao utilizar o modelo para ajustar os detectores, observou-se um maior controle dos falsos positivos em comparação com métodos baseados em correlação. Essa abordagem mostrou-se particularmente vantajosa em cenários com baixa relação sinal-ruído e presença de outras componentes além da estimulação. A modelagem autoregressiva proporciona uma análise mais completa, já que é capaz de captar as características que são correlacionadas do próprio sinal e não apenas dos sinais vizinhos. Além disso o modelo pode ser utilizado em diferentes ordens e assim ser ajustado para obter o melhor desempenho, e manter ao máximo a confiabilidade dos resultados, oferecendo uma base sólida para a tomada de decisões clínicas. Em conclusão, a abordagem multivariada combinada com a modelagem autorregressiva para o ajuste dos detectores demonstrou ser uma estratégia promissora para a detecção de potenciais evocados no EEG. Esses avanços têm o potencial de impactar positivamente a prática clínica, auxiliando no diagnóstico precoce e no tratamento de doenças neurológicas e deficiências relacionadas.

Keywords—Modelos, multicanais, EEG, detecção, estímulo, covariância.

I. INTRODUÇÃO

As respostas evocadas são níveis de tensão elétrica da atividade neural que surgem após uma estimulação sensorial,

têm sido amplamente utilizadas na prática clínica para avaliar a integridade dos sistemas neurais. Embora sua aplicação primária seja na avaliação dos sistemas sensoriais, as respostas evocadas também encontram aplicações no monitoramento cirúrgico e na avaliação de doenças neurodegenerativas [1].

Durante o eletroencefalograma (EEG), as respostas evocadas, medidas por meio de eletrodos não invasivos, precisam ser detectadas em meio à atividade elétrica espontânea do cérebro, gerada pelos impulsos elétricos dos neurônios. O desafio reside no fato de que essas respostas são muito pequenas em comparação com a atividade espontânea [2].

Diferentes tipos de respostas podem ser obtidos no EEG, algumas pessoas podem sentir relaxamento, descontração ou até mesmo sonolência durante a realização do exame, enquanto outros podem relatar sensações mínimas ou até mesmo nenhum tipo de experiência. Tradicionalmente, a detecção de respostas evocadas é realizada de forma subjetiva por profissionais treinados, que avaliam o paciente durante o exame e realizam o diagnóstico de acordo com a reação de cada um. Atualmente a detecção de resposta tem sido realizada por meio de testes estatísticos, como o cálculo da média coerente em janelas do EEG sincronizadas com o início do estímulo. A suposição subjacente a essa abordagem é que a resposta evocada é invariante ao longo das janelas, enquanto a atividade espontânea do EEG varia e não está correlacionada com o estímulo-resposta ao longo do tempo [3].

No entanto, a detecção de respostas evocadas por inspeção visual, realizada por profissionais experientes, é considerada subjetiva e pode apresentar variações significativas entre os avaliadores. Em algumas aplicações clínicas, como triagem auditiva de recém-nascidos ou monitoramento durante cirurgias, uma detecção objetiva e binária (resposta presente ou ausente) é desejável. Nesses casos, técnicas objetivas de detecção de resposta são mais adequadas [4].

Os métodos para detecção objetiva de respostas evocadas, conhecidos como técnicas de detecção de resposta objetiva (ORD - Objective Response Detection), empregam análises estatísticas para reduzir a subjetividade da inspeção visual. Diversos índices, como coerência quadrada da magnitude (CSM), medida de sincronia de componentes (MSC) e teste F local (LFT), são estimados a partir das gravações para quantificar a força das respostas [5].

A detecção de respostas evocadas usando técnicas univariadas está bem estabelecida na literatura [6]. A extensão dessas técnicas para analisar respostas multicanal (ou multivariadas) tem recebido muita atenção recentemente ([8]; [9]; [11]; [16]; [17]; [19]).

As técnicas multivariadas permitem aumentar a sensibilidade na detecção de respostas evocadas sem a necessidade de aumentar a duração da estimulação. E para isso é necessário a aplicação de testes estatísticos mais complexos [1].

Uma abordagem promissora nesse sentido é a utilização de modelos autoregressivos, que descrevem a relação linear entre os sinais de diferentes canais ao longo do tempo. Esses modelos capturam a dinâmica temporal das interações entre os canais de EEG, permitindo uma análise mais precisa das respostas evocadas [7].

Além disso, simulações de Monte Carlo baseadas em suposições sobre os sinais podem ser empregadas para estimar as distribuições de amostragem e os valores críticos. No entanto, a suposição padrão de independência entre os canais de EEG não se justifica em registros multicanais, exigindo a utilização de métodos alternativos que considerem a correlação entre os canais.

II. REFERENCIAL TEÓRICO

A seguir serão descritas as técnicas de Detecção Objetiva de Resposta univariadas e multivariadas empregadas nestes estudos.

A. Técnicas Univariadas

Dentre as técnicas de Detecção Objetiva de Resposta (ORD - do inglês *Objective Response Detection*), uma das mais conhecidas é a Coerência do Quadrado da Magnitude (MSC - do inglês *Magnitude Squared Coherence*). Essa técnica pode ser estimada utilizando apenas o último sinal, uma vez que o primeiro sinal é cancelado durante o cálculo, desde que as épocas sejam selecionadas de forma que os estímulos sejam os mesmos em todas elas [17]. A Equação (1) define a estimativa de MSC para o sinal de EEG:

$$\hat{\kappa}_y^2(f) = \frac{|\sum_{i=1}^M Y_i(f)|^2}{M \sum_{i=1}^M |Y_i(f)|^2}, \quad (1)$$

onde $Y_i(f)$ representa a transformada de Fourier da i -ésima época de um sinal de EEG.

Por outro lado, a Medida de Sincronia de Componentes (CSM - do inglês *Component Sync Measurement*) utiliza informações de fase do sinal, ao contrário do MSC, que considera tanto informações de fase quanto de amplitude dos dados [15]. Este detector pressupõe que todas as janelas têm o mesmo módulo, e o CSM pode ser obtido conforme a Equação (2):

$$\hat{\rho}_y^2(f) = \left[\frac{1}{M} \sum_{i=1}^M \cos(\theta_i(f)) \right]^2 + \left[\frac{1}{M} \sum_{i=1}^M \sin(\theta_i(f)) \right]^2, \quad (2)$$

onde $\theta_i(f)$ representa o ângulo de fase na frequência f da transformada de Fourier da i -ésima época do sinal de EEG.

O Teste F Local (LFT - do inglês *Local F-Test*), por sua vez, é uma técnica que leva em consideração apenas informações de amplitude dos dados. Ele é definido como a razão entre a estimativa espectral em uma determinada frequência e o espectro médio nas frequências vizinhas [18]. Esse teste tem sido amplamente utilizado para detectar respostas evocadas e é definido conforme a Equação (3) [19]:

$$\hat{\phi}_y(f_o) = \frac{|Y(f_o)|^2}{\frac{1}{L} \sum_{i=0-L/2}^{0+L/2} |Y(f_i)|^2}, \quad (3)$$

$i \neq 0$

onde $Y(f_o)$ representa a transformada de Fourier de um determinado sinal de EEG ($y[k]$) avaliado na frequência f_o . $Y(f_i)$ ($i \neq 0$) são os valores da transformada de Fourier nas L frequências vizinhas mais próximas de f_o . É importante ressaltar que, ao contrário das estimativas de MSC e CSM, a transformada de Fourier em (3) é aplicada a todo o registro do EEG, e não a cada época.

B. Técnicas Multivariadas

A relação sinal-ruído (SNR - do inglês *Signal-to-Noise Ratio*) afeta significativamente as técnicas de detecção. Em geral, para uma determinada SNR, a taxa de detecção só pode ser melhorada aumentando o número de janelas (subdivisões do sinal - época), ou seja, aumentados o tempo de leitura dos dados. No entanto, isso compromete o tempo de processamento, o que pode ser problemático em casos de monitoramento cirúrgico, onde a rapidez é essencial. Para contornar esse desafio, técnicas multivariadas foram desenvolvidas com o objetivo de melhorar a detecção sem comprometer o tempo de processamento, realizando leituras simultâneas.

Uma dessas técnicas é a Coerência de Múltiplos Quadrados de Magnitude (MMSC - do inglês *Multiple Coherence of Squared Magnitude*), que foi proposta em [14]. O MMSC entre o sinal de estimulação e os sinais de EEG medidos é definido pela Equação (4):

$$\hat{\kappa}_N^2(f) = \frac{\mathbf{v}^H(f) \hat{\mathbf{S}}_{yy}^{-1}(f) \mathbf{v}(f)}{M}, \quad (4)$$

onde o símbolo "H" sobrescrito denota a transposição dos valores conjugados complexos de uma matriz ou vetor. Os termos $\hat{\mathbf{S}}_{yy}(f)$ e $\mathbf{v}(f)$ na Equação (5) são definidos como segue:

$$\hat{\mathbf{S}}_{yy}(f) = \begin{bmatrix} \hat{S}_{y_1y_1}(f) & \hat{S}_{y_1y_2}(f) & \dots & \hat{S}_{y_1y_N}(f) \\ \hat{S}_{y_2y_1}(f) & \hat{S}_{y_2y_2}(f) & \dots & \hat{S}_{y_2y_N}(f) \\ \vdots & \vdots & \ddots & \vdots \\ \hat{S}_{y_Ny_1}(f) & \hat{S}_{y_Ny_2}(f) & \dots & \hat{S}_{y_Ny_N}(f) \end{bmatrix}, \quad \mathbf{v}(f) = \begin{bmatrix} \sum_{i=1}^M Y_{1i}(f) \\ \sum_{i=1}^M Y_{2i}(f) \\ \vdots \\ \sum_{i=1}^M Y_{Ni}(f) \end{bmatrix}, \quad (5)$$

Os termos de espectro cruzado de $\hat{S}_{yy}(f)$ na Equação (6) podem ser calculados conforme a Equação (6):

$$\hat{S}_{yp,yq}(f) = \sum_{i=1}^M Y_{pi}^*(f) Y_{qi}(f) \quad , \quad (6)$$

Nessa equação, $Y_{ji}(f)$ representa a transformada de Fourier da i -ésima época do sinal $yj[k]$ ($j = p, q$), e o símbolo "*" indica o conjugado complexo.

Outra extensão multivariada é o *Component Sync Measurement* (MCSM), que utiliza o ângulo de fase médio de um conjunto de sinais. É definido pelas Equações (7), (8) e (9):

$$\hat{\rho}_N^2(f) = \left[\frac{1}{M} \sum_{i=1}^M \cos(\bar{\theta}_i(f)) \right]^2 + \left[\frac{1}{M} \sum_{i=1}^M \sin(\bar{\theta}_i(f)) \right]^2 \quad , \quad (7)$$

onde:

$$\bar{\theta}_i(f) = \begin{cases} \tan^{-1}(\bar{S}_i/\bar{C}_i) & \text{if } \bar{C}_i \geq 0 \\ \tan^{-1}(\bar{S}_i/\bar{C}_i) + \pi & \text{if } \bar{C}_i < 0 \end{cases} \quad , \quad (8)$$

com

$$\bar{C}_i = \frac{1}{N} \sum_{j=1}^N \cos\theta_{ij}(f), \quad \bar{S}_i = \frac{1}{N} \sum_{j=1}^N \sin\theta_{ij}(f) \quad , \quad (9)$$

Na Equação (9), $\theta_{ij}(f)$ representa o ângulo de fase da transformada de Fourier da i -ésima época ($i = 1, \dots, M$) do sinal de EEG $yj[k]$ ($j = 1, \dots, N$) na frequência f . Para obter um melhor desempenho dessa estimativa, é necessário que a resposta evocada não varie substancialmente entre os canais, de modo que seus ângulos de fase sejam semelhantes, e que os componentes de ruído estejam uniformemente distribuídos entre zero e 2π . Ao realizar a média entre os canais para obter o ângulo de fase médio, a variabilidade entre as épocas é reduzida em comparação com a estimativa univariada.

Também foi proposta uma extensão multivariada do Teste F Local (LFT), derivando a distribuição amostral desse detector para o caso em que as atividades de fundo não são correlacionadas entre si e exibem a mesma SNR [5]. É definido pela Equação (10):

$$\hat{\phi}_N(f_o) = \frac{\sum_{j=1}^N |Y_j(f_o)|^2}{\sum_{j=1}^N \left[\frac{1}{L} \sum_{i=0-L/2}^{0+L/2} |Y_j(f_i)|^2 \right]} \quad , \quad (10)$$

onde Y_j representa a transformada de Fourier dos dados de EEG.

Além disso, existem extensões multivariadas alternativas e mais simples que podem ser obtidas a partir das técnicas univariadas de MSC, CSM e LFT, realizando uma média aritmética ou geométrica simples. Essas extensões são mostradas na Equação (11):

$$\bar{\xi} = \frac{1}{N} \sum_{j=1}^N \xi_j \quad (11)$$

$$\underline{\xi} = \left(\prod_{j=1}^N \xi_j \right)^{\frac{1}{N}} \quad ,$$

onde o símbolo " ξ " representa as estimativas univariadas distintas de MSC, CSM ou LFT dos canais de EEG adquiridos simultaneamente durante a estimulação [9].

Durante todo o estudo serão adotados os símbolos dos detectores multivariados apresentados nesta sessão. Tanto para a MMSC, MCSM e MLFT, assim como os detectores de média aritmética e de média geométrica que usarão a mesma notação porem com o indicador do tipo de média (– abaixo da notação para geométrica e acima para aritmética).

C. Método de Correção com Correlação e Fatoração de Cholesky

Em estudos anteriores [9], foi proposto um método para corrigir os detectores multivariados com intuito de melhorar a detecção de resposta mantendo o FP controlado, levando em consideração o efeito da correlação entre os canais. O método proposto no estudo utiliza do coeficiente de correlação de Pearson, representado pela Equação (12), e a decomposição de *Cholesky* juntamente com simulações paramétricas *bootdstrap* para estimar o valor crítico. A Figura 1 ilustra um diagrama de blocos que resume o método.

$$R_{pq} = \frac{\sum_{k=0}^{T-1} y_p[k] y_q[k]}{\sqrt{\left(\sum_{k=0}^{T-1} y_p^2[k] \right) \left(\sum_{k=0}^{T-1} y_q^2[k] \right)}} \quad , \quad (12)$$

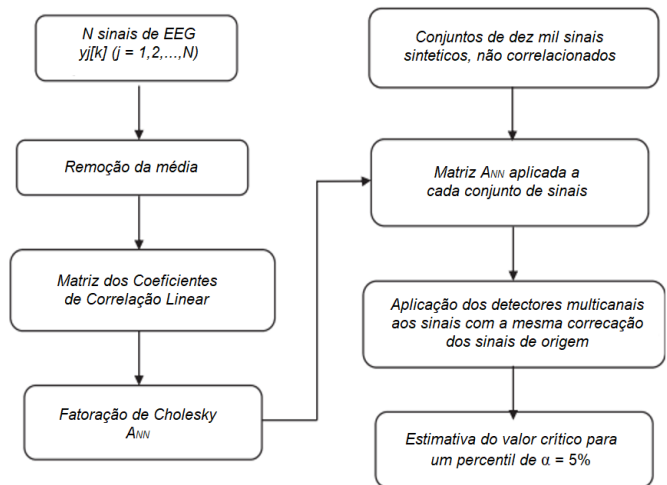


Figura 1: Diagrama de blocos do método de correção com correlação no domínio do tempo. [9]

Essa abordagem permite ajustar os detectores multivariados levando em conta a correlação entre os canais, melhorando a precisão e a confiabilidade dos resultados obtidos.

Em estudos mais recentes esse método foi adaptado para o domínio da frequência utilizando o espectro-cruzado dos dados [10].

D. Modelagem Autoregressiva

A modelagem autoregressiva é uma técnica estatística e matemática usada para analisar e prever séries temporais, que são conjuntos de dados organizados cronologicamente. Essa abordagem é amplamente aplicada em diversas áreas, como previsão do tempo, finanças, economia e engenharia, devido à sua eficácia na captura de tendências e padrões em dados.

O objeto de interesse a seguir é o modelo VAR(p) (modelo de vetor autoregressivo de ordem p),

$$y_t = v + y_{(t-1)}A_1 + \dots + y_{(t-p)}A_p + u_t \quad , \quad (10)$$

$$t = 0, \pm 1, \pm 2, \dots$$

onde $y_t = (y_{1t}, \dots, y_{kt})'$ é um vetor aleatório (1xN), os A_i são fixos (NxN) matrizes de coeficientes, $v = (v_1, \dots, v_N)'$ é um vetor fixo (1xN) de interceptação, termos que permitem a possibilidade de uma média diferente de zero $E(y_t)$. Finalmente, $u_t = (u_{1t}, \dots, u_{Nt})'$ é um ruído branco N-dimensional ou processo de inovação [6].

A estimativa da covariância é definida como:

$$\hat{C}_n[p] = \frac{1}{M} \sum_i y_i y_{i-p} \quad , \quad (10)$$

onde M é a duração da gravação e p é a ordem da covariância.

Uma vez que não estão correlacionados e têm média zero, o ruído branco u_t não é correlacionado com o sinal y , ou seja, $E(u_t) = 0$, $E(u_t u_s) = \Sigma u$ e $E(u_t u_s) = 0$ para $s \neq t$. [6].

III. OBJETIVOS

O objetivo deste estudo foi aprimorar as técnicas de detecção objetiva de resposta, levando em consideração os efeitos da covariância entre os canais do EEG. O foco foi ajustar os detectores multivariados existentes para melhor capturar e analisar as interações entre os canais do EEG, visando uma detecção mais precisa e confiável de respostas evocadas.

Foi desenvolvido um método paramétrico baseado em *bootstrap* que leve em consideração as estimativas de auto covariância entre canais para a detecção de respostas evocadas em registros multicanais de EEG. Esse método foi testado e comparado com abordagens tradicionais no domínio do tempo, da frequência e utilizando modelagem autorregressiva, bem como com os resultados de simulações de Monte Carlo em dados artificiais.

Em comparação espera-se obter um método capaz de ter uma melhor performance de detecção com o aumento do número de canais sem alterar a taxa de FP em relação aos métodos uni canais, já que o aumento do FP é um efeito comum quando se utiliza métodos multicanais sem correção.

IV. MATERIAIS E MÉTODOS

Os métodos paramétricos *bootstrap*, aliados a simulações de Monte Carlo, foram empregados na determinação do valor crítico. Para assegurar que o conjunto mantenha a mesma covariância dos dados reais, recorreu-se à modelagem autorregressiva, incorporando, assim, a auto covariância dos dados.

A. Método de correção com modelagem Autoregressiva

No presente estudo, propõe-se um método semelhante à [9], em que dados sintéticos são gerados a partir de dados reais. Os testes estatísticos são, então, empregados para a determinação do valor crítico.

O método proposto visa melhorar a taxa de detecção utilizando a modelagem AR para gerar os dados sintéticos, proporcionando uma quantidade significativa no cálculo do valor crítico. O modelo de estudo adotado é o modelo VAR(p), apresentado na seção II.D, e será explorado em conjunto com a covariância dos dados.

Na figura 2 segue um fluxo que descreve as etapas do método.

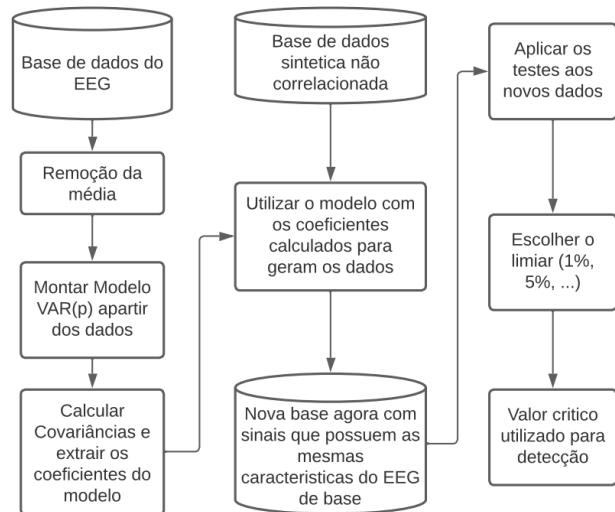


Figura 2: Diagrama de blocos do método de correção com modelagem VAR(p).

A partir da base de dados do EEG é montado o modelo de ordem p, o qual é extraído uma matriz N x N, para cada ordem utilizando a covariância entre os canais por meio da equação (10), a etapa de remoção da média é importante para a consideração de que o sinal possui média 0 (sob hipótese nula de inexistência de resposta).

O sinal é multiplicado por uma matriz do próprio sinal deslocado, assim é possível estimar a covariância dos dados e

extrair as matrizes do modelo (denotadas por A_1, A_2, \dots, A_p). Segue um exemplo para o modelo de ordem 2.

É multiplicado os termos $y_{(t-1)}$ e $y_{(t-2)}$ pela equação (10) obtendo duas equações:

$$y_{(t-1)}y_t = y_{(t-1)}y_{(t-1)}A_1 + y_{(t-1)}y_{(t-2)}A_2 + y_{(t-1)}u_t, \quad (11)$$

$$y_{(t-2)}y_t = y_{(t-2)}y_{(t-1)}A_1 + y_{(t-2)}y_{(t-2)}A_2 + y_{(t-2)}u_t, \quad (12)$$

Aplicando a Estimativa da autocovariância,

$$E\{y_{(t-1)}y_t\} = E\{y_{(t-1)}y_{(t-1)}A_1\} + E\{y_{(t-1)}y_{(t-2)}A_2\}, \quad (13)$$

$$E\{y_{(t-2)}y_t\} = E\{y_{(t-2)}y_{(t-1)}A_1\} + E\{y_{(t-2)}y_{(t-2)}A_2\}, \quad (14)$$

Os termos $E\{y_{(t-1)}u_t\}$ e $E\{y_{(t-2)}u_t\}$ são zerados por não serem correlacionados.

$$\hat{C}_n[1] = \hat{C}_n[0]A_1 + \hat{C}_n[1]'A_2, \quad (13)$$

$$\hat{C}_n[2] = \hat{C}_n[1]A_1 + \hat{C}_n[0]A_2, \quad (14)$$

Agora a partir das matrizes de covariância de ordem 0, 1 e 2 é possível calcular A_1 e A_2 , o mesmo raciocínio se aplica a ordens mais altas.

Na elaboração do modelo, os dados foram tratados de forma que o modelo pudesse ser construído com foco na frequência de estimulação (37,5 Hz). Para isso, os sinais foram divididos em 32 janelas e em cada janela, aplicou-se a Transformada de Fourier para obter o espectro do sinal ao longo do tempo. Dessa maneira, torna-se possível calcular as covariâncias com foco na frequência desejada.

Após obter as matrizes do modelo desejadas, o próximo passo é aplicar o modelo em dados sintéticos (Ruídos Gaussianos), para isso é gerado o sinal e para adequar se ao modelo ele é deslocado de acordo com a ordem utilizada. Assim a saída será um sinal com as mesmas características do EEG de base. A partir daqui é aplicado a um conjunto de 100 mil dados sintéticos os detectores multivariados, e a partir dos resultados foi escolhido o valor crítico.

B. Descrição dos dados

O conjunto de dados empregado neste estudo consistiu na obtenção da Resposta Auditiva de Estado Estacionário (ASSR, do inglês *Auditory Steady-State Response*) como resposta evocada. Foram realizados registros de sinais de EEG em cinco indivíduos (faixa etária: 21-29 anos) com audição normal. Os registros foram realizados em cinco sessões separadas em dias diferentes, utilizando o mesmo conjunto de dados EEG usado em [21]. A frequência portadora utilizada foi de 1000 Hz, com frequências de modulação de 37,5 Hz. Os sinais de EEG foram registrados utilizando um amplificador de sinal biológico BrainNET BNT-36 (EMSA, Brasil), com filtro passa-faixa variando de 1 Hz a 100 Hz e frequência de amostragem de 600

Hz. As derivações utilizadas foram F7, T3, T5, Fp1, F3, C3, P3, O1, F8, T4, T6, Fp2, F4, C4, P4, O2, Fz, Oz, Pz, A1 e A2, com terra em FPZ e referência em Cz, seguindo a norma 10-20. Os sinais de EEG foram divididos em janelas de 1024 pontos, correspondendo a aproximadamente 1,7 segundos cada, e armazenados em disco rígido para análise. As leituras foram realizadas em uma cabine acústica localizada no Núcleo Interdisciplinar de Análise de Sinais (NIAS/UFV), e o protocolo do estudo foi aprovado pelo Comitê de Ética Local (CEP/UFV nº 2.105.334).

C. Medidas de Desempenho

Para a análise dos resultados foi plotado a evolução da detecção e a taxa de falsos positivos (FP) com a aumento do número de canais, tanto para os modelos VAR propostos quanto para os modelos de estudos passados (Correção de *Cholesky* no Domínio do Tempo [9] e Correção de *Cholesky* no Domínio da Frequência [10]). Os valores de FP são comparados aos limites de confiança, que são calculados a partir do valor do primeiro canal (N=1) com um intervalo de confiança de 95%.

Além disso foi gerado a taxa de DR e de FP para diferentes ordens, a fim que comparar o efeito da escolha da ordem no método, as ordens escolhidas foram 1, 3 e 5. Para o cálculo taxa de DR é a porcentagem de detecção que o método teve ao ser aplicado na frequência de estimulação (37,5Hz). O cálculo de taxa de FP é igual ao de DR porém com o método aplicado a uma faixa fora da frequência de estimulação.

Para uma melhor análise dos resultados foi calculada a área sob a curva de detecção e também o desvio padrão médio para os dados de FP para todos os detectores e em cada método.

V. RESULTADOS

Os resultados de correlação no domínio da frequência [10] foram utilizados como referência para o estudo, onde foi empregada a correção de *Cholesky* no domínio da frequência. Uma vez que esse método obteve um desempenho superior em relação ao método no domínio do tempo [9].

A. VAR(1)

O primeiro resultado gerado foi para o modelo de ordem 1, o qual é mostrado na figura 3. É possível observar o valor da taxa de detecção (DR, do inglês *detection rate*) com o aumento do número de canais tanto para o modelo VAR(1) – linha continua em azul – quanto para o modelo de referência (FDCC - Correção de *Cholesky* no Domínio da Frequência) [10] – linha continua em vermelho – e também com os resultados *default*, que são os resultados dos detectores usando apenas sinais gaussianos sem nenhum tipo de correção – linha continua em preto. E o valor da taxa de falsos positivos mostrados em azul tracejado para VAR (1), vermelho tracejado para FDCC e em preto tracejado para os detectores sem correção.

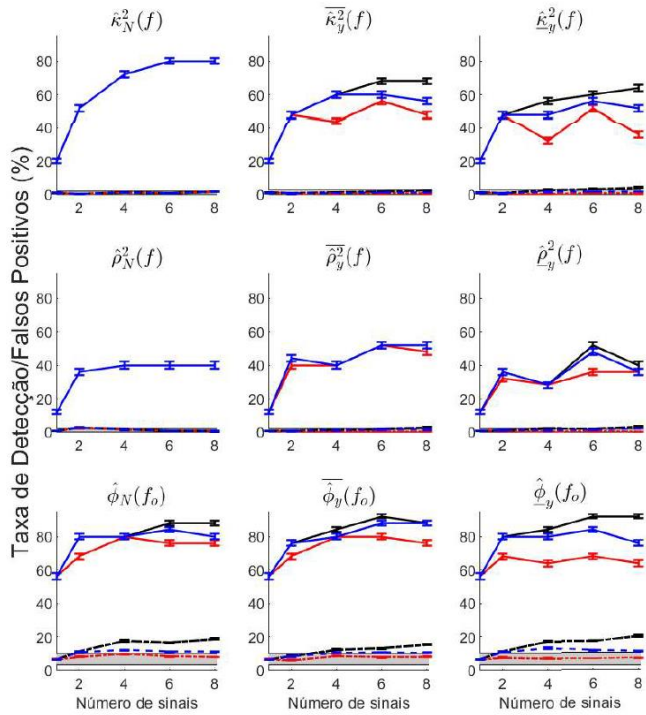


Figura 3 – Comparação dos resultados VAR(1) (linhas em azul), com os resultados da FDCC (linhas em vermelho) e *default* (linhas em preto).

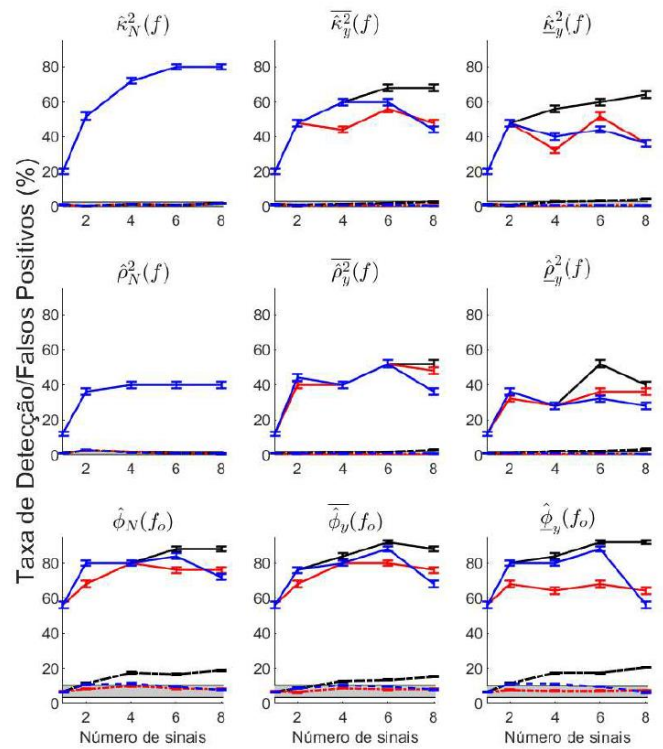


Figura 4 – Comparação dos resultados VAR(3) (linhas em azul), com os resultados da FDCC (linhas em vermelho) e *default* (linhas em preto).

Os valores de detecção obtidos a partir do método proposto foram superiores ao método de referência, porém o mesmo é válido para o FP que em alguns casos ficaram fora do intervalo de confiança.

Em todos os casos, com exceção dos detectores MMSC e MCSM os valores do modelo de ordem 1 apresentou melhores taxas de detecção de resposta em comparação método de FDCC o que é um ponto positivo, por outro lado a taxa de FP ficou fora do limite de confiança em alguns detectores, se aproximando do valor *default*, não obtendo o nível desejado.

B. VAR(3)

Para o modelo de ordem 3 os valores se comportaram de foram mais controlada em relação ao modelo de ordem 1, na figura 4 é possível observar o valor da taxa de DR com o aumento do número de canais tanto para o modelo VAR(3) – linha contínua em azul – quanto para o modelo de referência (Correção com Correlação e Fatoração de Cholesky) [10] – linha contínua em vermelho – e também com os resultados *default* – linha contínua em preto. E o valor da taxa de falsos positivos mostrados em azul tracejado para VAR (3), vermelho tracejado para FDCC e em preto tracejado para os detectores sem correção.

Os valores de DR obtidos a partir do modelo VAR(3) foram próximos ao do método de FDCC, sendo superior em alguns pontos e inferiores em outros, e o mesmo é válido para o FP que para a ordem 3 se manteve dentro do intervalo de confiança.

C. VAR(5)

Por último os resultados para o modelo de ordem 5 são apresentados na figura 5. Para essa ordem os valores de FP ficam ainda mais estáveis, e a taxa de DR foi a que menos desempenhou. As linhas em vermelhas e em pretas representam o método de referência e o valor *default* respectivamente. Valores da taxa de falsos positivos mostrados em azul tracejado para VAR (5), vermelho tracejado para FDCC e em preto tracejado para os detectores sem correção.

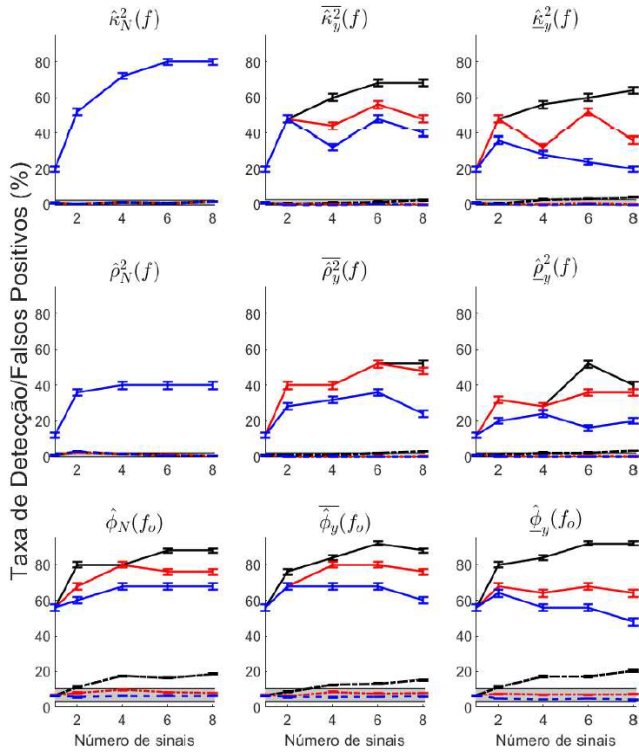


Figura 5 – Comparação dos resultados VAR(5) (linhas em azul), com os resultados da FDCC (linhas em vermelho) e default (linhas em preto).

Para uma melhor análise e comparação dos resultados foi gerada o valor da área sob a curva de detecção para cada detector. Os valores são mostrados na tabela 1.

Tabela 1 – Área sob a curdo de DR para cada detector

	Default	Cholesky	Var (1)	Var (3)	Var (5)
	DR	DR	DR	DR	DR
$\hat{\kappa}_N^2(f)$	472	472	472	472	472
$\bar{\kappa}_y^2(f)$	406	330	378	366	282
$\hat{\kappa}_y^2(f)$	378	286	342	286	188
$\hat{\rho}_N^2(f)$	260	260	260	260	260
$\bar{\rho}_y^2(f)$	302	298	308	292	208
$\hat{\rho}_y^2(f)$	254	218	248	208	136
$\hat{\phi}_N(f_0)$	572	518	556	548	458
$\bar{\phi}_y(f)$	582	526	566	546	462
$\hat{\phi}_y(f)$	592	458	552	540	396

Pode-se observar uma redução expressiva nos valores da tabela com o aumento da ordem do modelo, porém o mesmo é válido se for analisado os valores de FP.

Analisando a confiabilidade dos resultados é importante a medida de desvio padrão dos dados, essas medidas são mostradas na tabela 2.

Tabela 2 – Desvios padrão para o FP de cada detector

	Default	Cholesky	Var (1)	Var (3)	Var (5)
	σ_{FP}	σ_{FP}	σ_{FP}	σ_{FP}	σ_{FP}
$\hat{\kappa}_N^2(f)$	0,089	0,089	0,089	0,089	0,089
$\bar{\kappa}_y^2(f)$	0,120	0,074	0,113	0,092	0,037
$\hat{\kappa}_y^2(f)$	0,181	0,073	0,135	0,100	0,047
$\hat{\rho}_N^2(f)$	0,099	0,099	0,099	0,099	0,099
$\bar{\rho}_y^2(f)$	0,114	0,055	0,100	0,073	0,036
$\hat{\rho}_y^2(f)$	0,126	0,063	0,119	0,085	0,036
$\hat{\phi}_N(f_0)$	0,289	0,219	0,233	0,223	0,186
$\bar{\phi}_y(f)$	0,246	0,201	0,230	0,226	0,162
$\hat{\phi}_y(f)$	0,264	0,221	0,258	0,239	0,152

Para os modelos VAR(1) e VAR(3) pode-se observar uma média de detecção superior ao método de FDCC para a maioria dos detectores, o mesmo é válido quando se analisa a área abaixo da curva de DR. Os valores de FP são superiores para as duas ordens, porém para a ordem 3 o valor ainda permanece dentro do limite de confiança para todos os detectores. Já para o modelo VAR(5), esse foi o que teve melhores valores de FP, se mantendo com o menor desvio padrão.

VI. DISCUSSÃO E CONCLUSÃO

Com o aumento da ordem obteve-se um ganho de confiabilidade no resultado, uma vez que o FP fica mais controlado com cada aumento de ordem do modelo autoregressivo. Porém como ponto negativo se tem uma queda nos valores de DR com esse aumento de confiabilidade. Para os dados trabalhados o modelo teve bons desempenhos em ordens baixas para os detectores multivariados de MSC e CSM, uma vez que os valores de FP se mantem baixos e o nível de detecção superior ao método de FDCC. Para os detectores multivariados de LFT os níveis de FP foram mais elevados, nesses detectores percebe-se que o modelo com ordem 1 não foi eficaz para realizar a correção, uma vez que os dados de FP superam o limite de confiança de 95% estabelecido pelo valor de N=1, nesse caso o modelo com ordem 3 foi o que teve o melhor desempenho, com o FP em bons níveis de confiança e uma taxa de detecção superior ao FDCC.

Os detectores de MMSC e MCSM não tiveram variações para nenhum dos métodos, devido ao fato de já considerarem a correlação dos dados em seu método de cálculo. Mas para os demais detectores o ajuste é válido uma vez que se observa os valores de FP aumentando com o aumento do número de canais para os valores *default*, e com a correção isso não ocorre,

possibilitando uma melhora na detecção sem perder a confiabilidade do resultado.

Dentre todos os modelos testados o modelo de ordem 5 foi o que obteve menores valores de desvio padrão do FP, mantendo o mais próximo do valor inicial de $N=1$ para todos os detectores, tirando o MMSC e o MCSM que foi igual para todos os modelos. Isso se dá pelo fato de o modelo com uma ordem maior conseguir capturar melhor as características dos dados de EEG de origem, gerando sinais mais confiáveis para as simulações de Monte Carlo.

As curvas de detecção variam para cada detector e para cada método, comparando a área sob a curva de cada detector podemos ver que os valores que mais ficaram próximos do método de FDCC foi o modelo de ordem autorregressiva 3, sendo esse superior em alguns detectores e inferior em outros. Embora o modelo de ordem 1 tenha melhores valores de área sob a curva, ele não foi um método confiável em alguns detectores.

A respeito do processamento computacional dos métodos, é esperado que modelos com ordens maiores sejam mais complexos e assim exijam mais recurso computacional para a execução. No geral o método de FDCC é o que tem menor tempo de processamento.

No geral a utilização dos detectores multicanais com as correções é válida, uma vez que é possível em todos os detectores conseguir uma melhora na taxa de detecção e manter os FP controlado. Já a utilização desses detectores sem a correção não é interessante, uma vez que com o aumento do número de canais é comum o aumento do FP, fazendo com que o resultado perca confiabilidade.

Vale destacar que diferentes conjuntos de dados podem ter comportamentos diferentes, exigindo um diferente nível de correção. Nesse quesito o método proposto mostra-se interessante, uma vez que é possível ajustar a ordem do modelo VAR para um melhor desempenho.

Para estudos futuros é interessante um ajuste do método para que ele possa determinar a melhor ordem de aplicação para cada conjunto de dados, para assim obter o melhor resultado sem a necessidade de testar várias ordens e assim poupar tempo e recurso.

REFERÊNCIAS

- [1] Chiappa KH. Evoked potentials in clinical medicine. 3rd ed. Philadelphia: Lippincott-Raven; 1997.
- [2] Van Dun B, Verhulst S, Wouters J, Van de Heyning P. A logical sequence of recommendation for the clinical use of auditory steady-state responses. *Ear Hear.* 2007;28(2):285-298.
- [3] T. Rahne, J.L. Verhey, R. Mühler, Sorted averaging improves quality of auditory steady-state responses, *J. Neurosci. Methods.* 216 (1) (2013) 28–32, <https://doi.org/10.1016/j.jneumeth.2013.04.004>.
- [4] Santos MP, Rocha RB, Dias IA, et al. Objective response detection using the continuous wavelet transform. *Biomed Eng Online.* 2016;15(Suppl 1):82.
- [5] Rocha, RB, Pereira, A, Simas, ML. Performance analysis of objective response detection techniques for auditory evoked potentials in newborn hearing screening. *Biomed Eng Online.* 2016;15(Suppl 1):82.
- [6] DOBIE, R. A. and WILSON, M. J. (1998). Low-level steady-state auditory evoked potentials: effects of rate and sedation on detectability. *The Journal of the Acoustical Society of America*, 104(6):3482–3488.
- [7] LÜTKEPOHL, Helmut. *New Introduction to Multiple Time Series Analysis.* Germany: Springer, 2005. 764 p.
- [8] Jonas M. B. Haslbeck, Laura F. Bringmann & Lourens J. Waldorp (2021) A Tutorial on Estimating Time-Varying Vector Autoregressive Models, *Multivariate Behavioral Research*, 56:1, 120-149, DOI: 10.1080/00273171.2020.1743630
- [9] T. Zanotelli, Q.B. Soares, D.M. Simpson, A.M.F.L. Miranda de Sá, E.M.A.M. Mendes, L.B. Felix, Choosing multichannel objective response detectors for multichannel auditory steady-state responses, *Biomed. Signal Process. Control.* 68 (2021) 102599. <https://doi.org/10.1016/j.bspc.2021.102599>.
- [10] A.M.F.L. Miranda de Sá, T. Zanotelli, E.M.A.M. Mendes, L.B. Felix, D.M. Simpson, Considering the effect of correlation between the channels in multivariate detectors for evoked responses in the electroencephalogram, *Biomed. Signal Process. Control.* 71 (2022) 103111. <https://doi.org/10.1016/j.bspc.2021.103111>.
- [11] Zanotelli, Tiago and Ribeiro, Mateus and Felix, Leonardo Bonato and Mendes, Eduardo Mazoni Andrade Marçal and de Sá, Antonio Mauricio Ferreira Lei and Simpson, David Martin, Multichannel Detection of Evoked Responses Using Critical Values Corrected by Parametric Bootstrap: Frequency-Domain Cholesky Correction. Available at SSRN: <http://dx.doi.org/10.2139/ssrn.448207>
- [12] B. Van Dun, S.S. Member, J. Wouters, M. Moonen, S.S. Member, B. Van Dun, J. Wouters, M. Moonen, B. Van Dun, S.S. Member, J. Wouters, M. Moonen, S. S. Member, B. Van Dun, J. Wouters, M. Moonen, Improving Auditory Steady-State Response Detection Using Independent Component Analysis on Multichannel EEG Data, *IEEE Trans. Biomed. Eng.* 54 (2007) 1220–1230, <https://doi.org/10.1109/TBME.2007.897327>.
- [13] T.S. Santos, J.J. Silva, O.G. Lins, D.B. Melges, C.J. Tierra-Criollo, Detection efficiency of auditory steady state evoked by modulated noise, *Hear. Res.* 339 (2016) 125–131, <https://doi.org/10.1016/j.heares.2016.05.017>.
- [14] A.M.F.L. Miranda de Sá, L.B. Felix, A.F.C. Infantosi, A Matrix-Based Algorithm for Estimating Multiple Coherence of a Periodic Signal and Its Application to the Multichannel EEG During Sensory Stimulation, *IEEE Trans. Biomed. Eng.* 51 (7) (2004) 1140–1146, <https://doi.org/10.1109/TBME.2004.827952>.
- [15] A.M.F.L. Miranda de Sá, L.B. Felix, Multi-channel evoked response detection using only phase information, *J. Neurosci. Methods.* 129 (1) (2003) 1–10, [https://doi.org/10.1016/S0165-0270\(03\)00152-3](https://doi.org/10.1016/S0165-0270(03)00152-3).
- [16] P.F.F. Rocha, L.B. Felix, A.M.F.L. Miranda de Sá, E.M.A.M. Mendes, Multivariate evoked response detection based on the spectral F-test, *J. Neurosci. Methods.* 264 (2016) 113–118, <https://doi.org/10.1016/j.jneumeth.2016.03.005>.
- [17] A.M.F.L. Miranda de Sá, A Note on the Sampling Distribution of Coherence Estimate for the Detection of Periodic Signals, *IEEE Signal Process. Lett.* 11 (3) (2004) 323–325, <https://doi.org/10.1109/LSP.2003.821751>.
- [18] T.W. Picton, M.S. John, A. Dimitrijevic, D. Purcell, P. Korczak, J. Smart, R. Delgado, T.M. Strobel, C. Bradford, T.W. Picton, M.S. John, A. Dimitrijevic, D. Purcell, P. Korczak, J. Smart, R. Delgado, T.M. Strobel, C. Bradford, P. Korczak, J. Smart, R. Delgado, T.M. Strobel, C. Bradford, Human auditory steady-state responses, *J Am Acad Audiol.* 23 (2012) 177–219, <https://doi.org/10.3766/jaaa.23.3.3>.
- [19] A.M.F.L. Miranda de Sá, H.C. Thiengo, I.S. Antunes, D.M. Simpson, Assessing time and phase-locked changes in the EEG during sensory stimulation by means of spectral techniques, *IFMBE Proc.* (2009), <https://doi.org/10.1007/978-3-642-03882-2-567>.
- [20] Y.S. Sininger, L.L. Hunter, D. Hayes, P.A. Roush, K.M. Uhler, Evaluation of Speed and Accuracy of Next-Generation Auditory Steady State Response and Auditory Brainstem Response Audiometry in Children With Normal Hearing and Hearing Loss, *Ear Hear.* 39 (2018) 1207–1223, <https://doi.org/10.1097/AUD.0000000000000580>.
- [21] A.M.F.L. Miranda de Sa, A.F.C. Infantosi, D.M. Simpson, Coherence between one random and one periodic signal for measuring the strength of responses in the electro-encephalogram during sensory stimulation,

Med. Biol. Eng. Comput. 40 (1) (2002) 99–104,
<https://doi.org/10.1007/BF02347702>.

[22] F. Antunes, T. Zanotelli, D.M. Simpson, L.B. Felix, Multichannel search strategy for improving the detection of auditory steady-state response,

Med. Biol. Eng. Comput. 59 (2021) 391–399.
<https://doi.org/10.1007/s11517-021-02323-z>.

[23] Chen, R., Xiao, H., & Yang, D. (2021). Autoregressive models for matrix-valued time series. *Journal of Econometrics*, 222(1).
<https://doi.org/10.1016/j.jeconom.2020.07.01>