

Eliminação do artefato de piscamento em sinais de eletroencefalograma via filtragem estocástica

Rebecca Fernandes Ribeiro* Victor Baptista Frencl**
Leonardo Abdala Elias¹, João Bosco Ribeiro do Val***

* Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, SP, (e-mail: rebecca_ribeiro@outlook.com).

** Departamento Acadêmico de Eletrotécnica, Universidade Tecnológica Federal do Paraná, PR, (e-mail: vbfrencl@utfpr.edu.br).

*** Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, SP, (e-mails: [leolias,jbosco]@unicamp.br).

Abstract: The presence of physiological artifacts in electroencephalogram (EEG) signals is common and detrimental to medical analysis. In the present paper, we developed an algorithm based on stochastic filtering for the removal of blink artifacts, in which system modeling was defined by autoregressive models (AR). It was possible to remove blink artifacts from single-channel EEG recordings, as long as the electrooculogram (EOG) signal was available. The devised method was applied to real and simulated artifacts, and the performance was evaluated using the estimation of the power spectral density (PSD). The results demonstrate that the proposed method could remove blink artifacts without introducing large distortions in the EEG signal.

Resumo: A presença de artefatos fisiológicos em sinais de eletroencefalograma (EEG) é bastante comum e prejudicial para análise médica. Neste artigo desenvolvemos um algoritmo baseado em filtragem estocástica para a remoção de artefatos de piscamento, em que a modelagem dos sistemas foi definida por modelos autorregressivos (AR). Foi possível eliminar estes artefatos a partir do registro de um único canal de sinal EEG, dado que o registro do sinal ocular, eletrooculograma (EOG), estava disponível. O método desenvolvido foi aplicado a artefatos reais e simulados, e o desempenho foi avaliado a partir da estimativa da densidade espectral de potência dos sinais. Os resultados mostram que o método proposto remove artefatos de piscamento introduzindo pequenas distorções no sinal de EEG.

Keywords: Blink artifact; EEG modeling; EOG modeling; Stochastic filtering; Kalman filter.

Palavras-chaves: Artefato de piscamento; Modelagem matemática; EEG; EOG; Filtragem estocástica; Filtro de Kalman.

1. INTRODUÇÃO

O eletroencefalograma (EEG) é um sinal biológico que registra a atividade elétrica de circuitos de neurônios corticais durante diferentes comportamentos de um indivíduo. Entretanto, devido à baixa intensidade do sinal registrado pelos eletrodos posicionados no escalpo, há uma grande susceptibilidade desse sinal à ocorrência de interferência de sinais indesejados, denominados artefatos. Os artefatos podem ser causados por ruídos do ambiente, erros experimentais e, principalmente, por atividades fisiológicas involuntárias, como atividade cardíaca, muscular e o movimento ocular (Jiang et al., 2019).

O artefato ocular é um distúrbio não-neural gerado pela movimentação ocular ou pelo piscamento dos olhos. Esse sinal é irregular e, geralmente, tem amplitude maior que o próprio sinal captado pelo EEG (Hamal and bin Abdul Rehman, 2013).

O sinal ocular pode ser observado pela gravação do eletrooculograma (EOG) concomitantemente ao registro do EEG, e sua interferência pode ser observada, principalmente, nos registros dos eletrodos posicionados na região frontal do crânio, devido à propagação do campo elétrico gerado pelo movimento ocular ou piscamento (Wallstrom et al., 2004). Buscando uma alternativa para a remoção desses artefatos, alguns estudos descartam os intervalos em que eles ocorrem, mas esse descarte resulta na perda de dados do sinal original (Cohen, 2014). Em Anderer et al. (1999), houve a tentativa de evitar a ocorrência de artefatos, porém, a demanda cognitiva do indivíduo é afetada, prejudicando a análise do sinal e EEG.

Existem alguns métodos para remoção de artefatos em sinais neurais. Shahabi et al. (2012) divide-os em dois grupos. O primeiro é caracterizado por utilizar apenas o EEG no processo de correção por análise de componentes independentes (ICA, do inglês *Independent Component Analysis*). Essa metodologia requer o registro de vários eletrodos, trazendo dificuldades para algumas aplicações, como quando existe restrição de número de eletrodos

¹ Pesquisador no Laboratório de Pesquisa em Neuroengenharia, Centro de Engenharia Biomédica, Universidade Estadual de Campinas, SP.

2. DADOS

disponíveis (Noureddin et al., 2008). O segundo grupo é caracterizado por técnicas baseadas em regressões e filtros adaptativos, com base nas informações dos sinais de EEG e EOG. Esse grupo de métodos é viável para outras aplicações, pois não há necessidade de registros de um conjunto relativamente grande de eletrodos para garantir sua funcionalidade.

Existem algumas aplicações de métodos estocásticos para a eliminação de artefatos nesse grupo, como Torse and Desai (2016), que propõe um algoritmo adaptativo NLMS (do inglês, *Normalized Stochastic Least Mean Square*). O NLMS foi projetado devido à estabilidade que métodos estocásticos aplicados a sinais não estacionários. Mohammadpour et al. (2017), por sua vez, propõe um método de eliminação de artefatos de EEG que utiliza o HMM (do inglês, *Hidden Markov Model*). Esse método consiste em uma máquina de estados estocásticos finitos que prevê a distribuição de probabilidade de observar uma sequência.

Nesse artigo, o método proposto para eliminação de artefatos de piscamento presentes em sinais de EEG integra o segundo grupo apresentado por Shahabi et al. (2012). O algoritmo proposto é baseado em filtragem estocástica e a modelagem dos sistemas é apresentada a partir de técnicas baseadas em regressões. Os artefatos podem ser eliminados a partir do registro de um único canal de sinal EEG, desde que o sinal EOG esteja disponível.

Na Seção 2, os dados reais e simulados utilizados para aplicação do método são apresentados. Na Seção 3, a estrutura do modelo AR utilizado para descrição do sinal de EEG a ser filtrado é apresentada. Na Seção 4, a aplicação da filtragem estocástica é descrita, e, por fim, as simulações, resultados e análise de desempenho do método encontram-se na Seção 5.

O conjunto de dados utilizado (Elias et al., 2017) foi coletado de acordo com protocolos experimentais aprovados por um Comitê de Ética em Pesquisa (CAAE 17082313.6.000.5391). Antes da coleta, os participantes da pesquisa assinaram um Termo de Consentimento Livre e Esclarecido. O conjunto de dados é composto por gravações de sinais de EEG e EOG de sujeitos saudáveis durante a realização de tarefas motoras. Os dados foram coletados em eletrodos pontuais em FCz, Cz, CPz, C1 e C2, segundo o sistema internacional 10–10 (Society et al., 2006).

Os eletrodos de referência foram posicionados nos lóbulos de cada orelha dos sujeitos. Todos os sinais foram amplificados, filtrados (filtro passa-faixa de 0,1–100 Hz) e digitalizados a uma taxa de 5 kHz, durante 60 segundos aproximadamente. A Figura 1 ilustra um exemplo de registros de EEG e EOG, em eletrodos pontuais (FCz, Cz, CPz, C1 e C2), para um sujeito participante da pesquisa. A Figura 2 ilustra a montagem dos eletrodos com destaque para os eletrodos pontuais utilizados.

Em busca de uma eliminação de artefatos consistente (Urigüen and Garcia-Zapirain, 2015), um artefato simulado é acrescentado aos sinais registrados. Adotou-se uma representação matemática simples para a simulação do artefato, que é a resposta ao impulso de um típico sistema de segunda ordem criticamente amortecido (Eq. 1):

$$H(s) = -\frac{1}{s^2 + 6s + 1}, \quad (1)$$

em que s é a variável Laplaciana e o sinal negativo é considerado para equação devido à amplitude negativa dos piscamentos registrados nos dados selecionados.

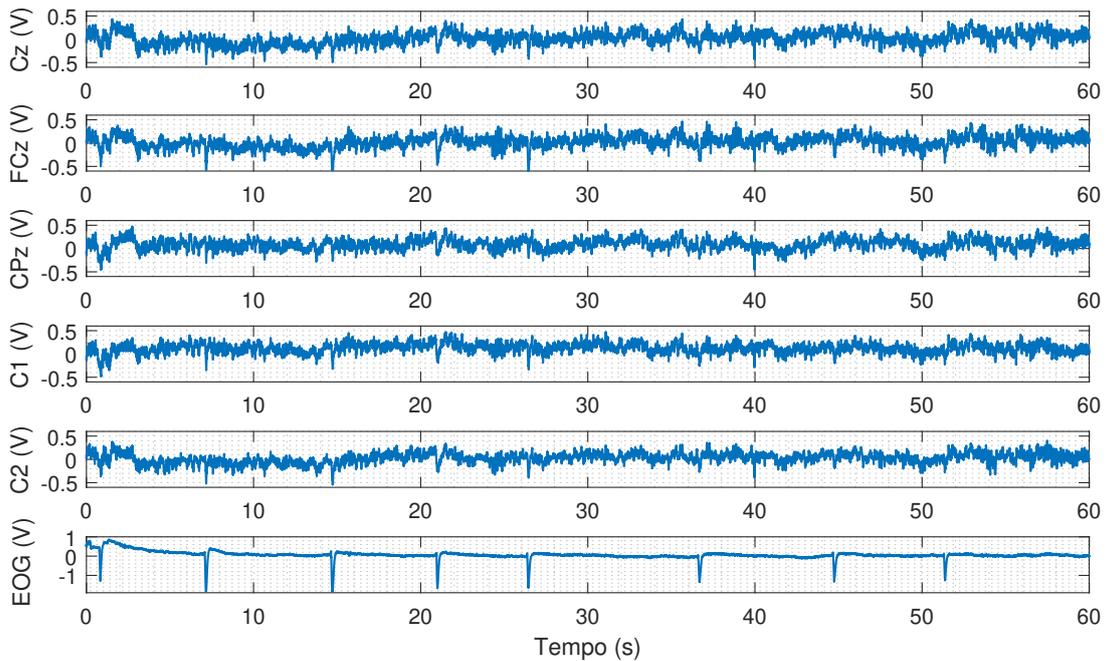


Figura 1. Exemplo de registros de sinais de EEG e EOG coletados em eletrodos pontuais em FCz, Cz, CPz, C1 e C2.

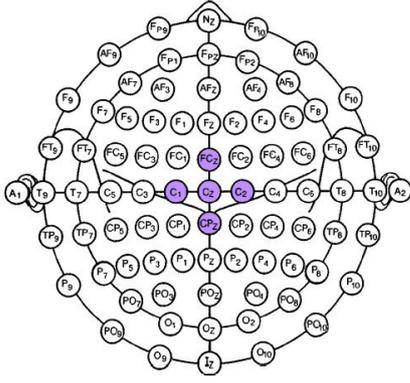


Figura 2. Montagem segundo sistema internacional 10–10, com destaque para os eletrodos pontuais em FCz, Cz, CPz, C1 e C2, modificada de Seeck et al. (2017).

O decurso temporal da representação matemática definida tem características semelhantes aos artefatos de piscamento reais observados nos registros de EOG. A Figura 3 ilustra o artefato simulado pelo método descrito com os parâmetros originais da função de transferência (Eq. 1).

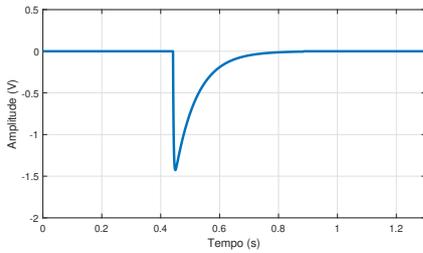


Figura 3. Representação de um piscamento simulado.

A partir da gravação do sinal EOG foi possível separar um trecho de um determinado registro em que não há artefato, entre $t=35$ s e $t=36$ s, aproximadamente. A este trecho, o artefato simulado foi somado em cada um dos canais, conforme apresentado na Figura 4. A soma integral do artefato simulado, representado na Figura 3, é feita apenas no sinal EOG, para os canais do sinal de EEG somente 35% do artefato simulado é considerado. Além disso, na Figura 4 um artefato real é apresentado entre $t=36$ s e $t=37$ s, para comparação. É possível observar que o artefato simulado foi bem representado, tanto para os canais de EEG quanto para o canal de EOG.

3. MODELO MATEMÁTICO

A abordagem para a modelagem matemática do problema é uma versão modificada da técnica apresentada em Shahabi et al. (2012), considerando modelos autorregressivos (AR) e a inclusão das informações contidas no sinal de EOG. O sinal de EEG real pode ser descrito como uma soma entre o sinal de EEG verdadeiro e o sinal de EOG:

$$eeg_c(n) = eeg_v(n) + eog(n), \quad (2)$$

em que, $eeg_c(n)$ representa o sinal EEG real, contaminado pelo artefato, $eeg_v(n)$ representa o sinal EEG verdadeiro, livre do artefato ocular, e $eog(n)$ representa o sinal registrado pelo EOG, considerando que $n \in \mathbb{N}$. Por hipótese, $eeg_v(n)$ e $eog(n)$ são decorrelacionados. Em Jansen (1985), afirma-se que modelos AR descrevem adequadamente os sinais neurais. Com isso, o modelo para o sinal EEG verdadeiro pode ser descrito como um modelo AR sem entrada (Aguirre, 2007):

$$eeg_v(n) = \frac{1}{A_E(q)} w_E(n-1), \quad (3)$$

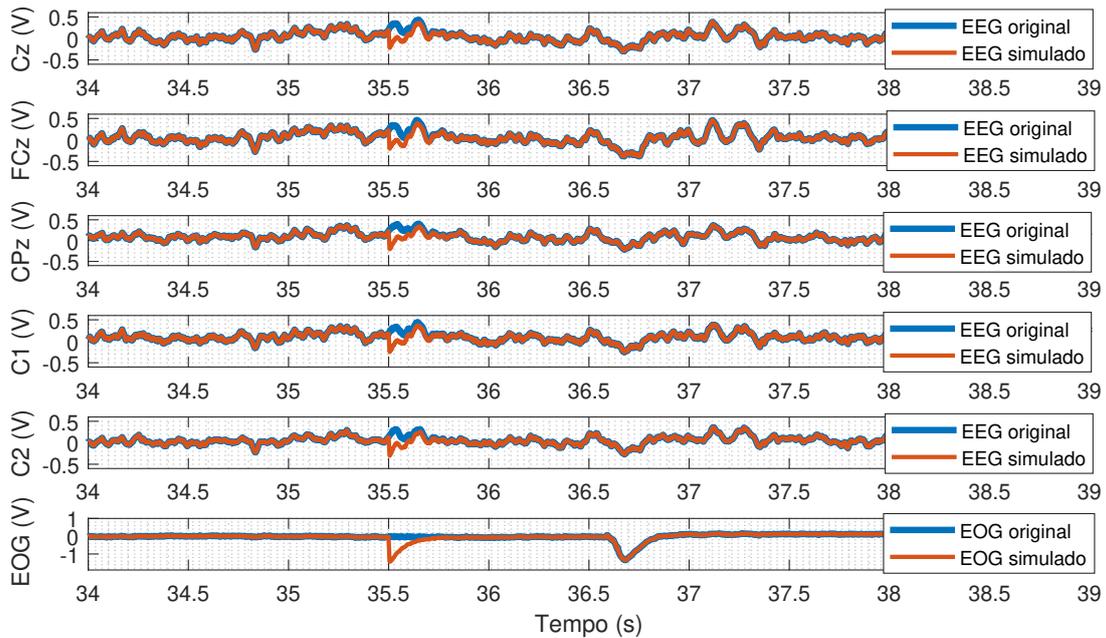


Figura 4. Registro de sinais EEG (Cz, FCz, CPz, C1 e C2) e EOG, com um artefato simulado adicionado em todos os canais, entre $t=35$ s e $t=36$. Entre $t=36$ s e $t=37$ s há um artefato de piscamento real para fins de comparação.

em que, $w_E(n)$ representa um ruído Gaussiano branco de variância $\sigma_{q_E}^2$. O polinômio $A_E(q)$ descreve as partes determinística e estocástica do sistema:

$$A_E(q) = 1 + a_1q^{-1} + a_2q^{-2} + \dots + a_{N_a^E}q^{-N_a^E}, \quad (4)$$

em que, a_i , com $i = 1, 2, \dots, N_a^E$, são os coeficientes do polinômio, N_a^E é a ordem do polinômio e q é o operador de atraso em tempo discreto. A representação em espaço de estados é, nesse caso, dada por:

$$\begin{cases} \mathbf{x}_E(n) = \mathbf{A}_E \mathbf{x}_E(n-1) + \mathbf{c}_E w_E(n-1) \\ eeg_v(n) = \mathbf{h}_E \mathbf{x}_E(n) + v_E(n) \end{cases}, \quad (5)$$

em que, $\mathbf{x}_E \in \mathbb{R}^{N_a^E}$ representa o vetor de estados do sinal, a matriz $\mathbf{A}_E \in \mathbb{R}^{N_a^E \times N_a^E}$ representa a matriz dinâmica do estado e $\mathbf{c}_E \in \mathbb{R}^{N_a^E}$ mapeia o ruído $w_E \in \mathbb{R}$ presente no vetor de estados. $\mathbf{h}_E \in \mathbb{R}^{N_a^E}$ representa o vetor de observação e o ruído de medida é dado por $v_E \in \mathbb{R}$, sendo v_E um ruído Gaussiano branco, de variância $\sigma_{r_E}^2$. A seguir, a especificação matricial:

$$\mathbf{x}_E(n) = [x_E(n) \ x_E(n-1) \ \dots \ x_E(n-N_a^E+1)]^T, \quad (6)$$

$$\mathbf{A}_E = \begin{bmatrix} -a_1 & -a_2 & \dots & -a_{N_a^E-1} & -a_{N_a^E} \\ 1 & 0 & \dots & 0 & 0 \\ 0 & 1 & \dots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \dots & 1 & 0 \end{bmatrix}, \quad (7)$$

$$\mathbf{c}_E = [1 \ 0 \ \dots \ 0 \ 0]^T, \quad (8)$$

$$\mathbf{h}_E = [1 \ 0 \ \dots \ 0 \ 0]. \quad (9)$$

Em Shahabi et al. (2012), a parcela do sinal EOG é dada por um modelo de erro na saída, considerando um sinal de piscamento simulado como entrada. Aqui, a parcela do sinal EOG será descrita por um modelo AR sem entrada:

$$eog(n) = \frac{1}{A_B(q)} w_B(n-1), \quad (10)$$

em que, $w_B(n)$ representa um ruído Gaussiano branco de variância $\sigma_{q_B}^2$. O polinômio $A_B(q)$ que é descrito por:

$$A_B(q) = 1 + a_1q^{-1} + a_2q^{-2} + \dots + a_{N_a^B}q^{-N_a^B}, \quad (11)$$

representa as partes determinística e estocástica do sistema, a ordem do polinômio é dada por N_a^B e os seus coeficientes são a_i , com $i = 1, 2, \dots, N_a^B$. Finalmente, a representação em espaço de estados, nesse caso, é dada por:

$$\begin{cases} \mathbf{x}_B(n) = \mathbf{A}_B \mathbf{x}_B(n-1) + \mathbf{c}_B w_B(n-1) \\ eog(n) = \mathbf{h}_B \mathbf{x}_B(n) + v_B(n) \end{cases}, \quad (12)$$

em que, o vetor de estados do sinal é $\mathbf{x}_B \in \mathbb{R}^{N_a^B}$. A matriz dinâmica do estado é representada por $\mathbf{A}_B \in \mathbb{R}^{N_a^B \times N_a^B}$, o ruído $w_B \in \mathbb{R}$ presente no vetor de estados é mapeado por $\mathbf{c}_B \in \mathbb{R}^{N_a^B}$, o vetor de observação por $\mathbf{h}_B \in \mathbb{R}^{N_a^B}$ e o ruído de medida por $v_B \in \mathbb{R}$, sendo este um ruído Gaussiano branco de variância $\sigma_{r_B}^2$. A especificação matricial destes termos é apresentada nas Equações (13)–(16):

$$\mathbf{x}_B(n) = [x_B(n) \ x_B(n-1) \ \dots \ x_B(n-N_a^B+1)]^T, \quad (13)$$

$$\mathbf{A}_B = \begin{bmatrix} -a_1 & -a_2 & \dots & -a_{N_a^B-1} & -a_{N_a^B} \\ 1 & 0 & \dots & 0 & 0 \\ 0 & 1 & \dots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \dots & 1 & 0 \end{bmatrix}, \quad (14)$$

$$\mathbf{c}_B = [1 \ 0 \ \dots \ 0 \ 0]^T, \quad (15)$$

$$\mathbf{h}_B = [1 \ 0 \ \dots \ 0 \ 0]. \quad (16)$$

Entretanto, buscando representar a parcela do sinal EOG com maior precisão, propõe-se aqui uma alteração para o vetor de observação (16). Devido à disponibilidade do sinal EOG, propõe-se que a informação nele contida seja incluída na modelagem. Desta forma, o vetor usual de observação será substituído por:

$$\mathbf{h}_B = [eog(n) \ 0 \ \dots \ 0 \ 0]. \quad (17)$$

A inclusão dessa informação permite a identificação da ocorrência dos artefatos de piscamento com exatidão. Para descrever o sistema por completo, as representações em (5) e (12) são acopladas. Nesse caso, a representação em espaço de estados é dada por:

$$\begin{cases} \mathbf{x}(n) = \mathbf{A} \mathbf{x}(n-1) + \mathbf{C} \mathbf{w}(n-1) \\ \mathbf{z}(n) = \mathbf{H} \mathbf{x}(n) + \mathbf{v}(n) \end{cases}. \quad (18)$$

Para descrever os termos do sistema completo, adotou-se $N = N_a^E + N_a^B$. O vetor de estados $\mathbf{x}(n) \in \mathbb{R}^N$ é formado pela concatenação do vetor de estados referente ao sinal EEG, $\mathbf{x}_E(n)$, em (6), com o vetor de estados referente ao sinal EOG, $\mathbf{x}_B(n)$, em (13). Desta forma, tem-se:

$$\mathbf{x}(n) = \begin{bmatrix} \mathbf{x}_E(n) \\ \mathbf{x}_B(n) \end{bmatrix}. \quad (19)$$

A matriz dinâmica $\mathbf{A} \in \mathbb{R}^{N \times N}$ de (18) é uma combinação bloco diagonal das matrizes dinâmicas do estado A_E e A_B , apresentadas em (7) e (14). O complemento dessa matriz é dado por matrizes nulas $\mathbf{0}_{EB} \in \mathbb{R}^{N_a^E \times N_a^B}$ e $\mathbf{0}_{BE} \in \mathbb{R}^{N_a^B \times N_a^E}$:

$$\mathbf{A} = \begin{bmatrix} \mathbf{A}_E & \mathbf{0}_{EB} \\ \mathbf{0}_{BE} & \mathbf{A}_B \end{bmatrix}. \quad (20)$$

$\mathbf{C} \in \mathbb{R}^{N \times 2}$ é a matriz que mapeia os ruídos presentes no vetor de estados. Essa matriz é composta pelos vetores \mathbf{c}_E e \mathbf{c}_B , definidos em (8) e (15), e dois vetores nulos $\mathbf{0}_E \in \mathbb{R}^{N_a^E}$ e $\mathbf{0}_B \in \mathbb{R}^{N_a^B}$:

$$\mathbf{C} = \begin{bmatrix} \mathbf{c}_E & \mathbf{0}_E \\ \mathbf{0}_B & \mathbf{c}_B \end{bmatrix}. \quad (21)$$

O vetor de medida $\mathbf{z}(n) \in \mathbb{R}^{2 \times 1}$, em (18), é composto pela concatenação do sinal EEG real, denominado como $eeg_c(n)$ em (2), com o sinal registrado pelo EOG, $eog(n)$:

$$\mathbf{z}(n) = \begin{bmatrix} eeg_c(n) \\ eog(n) \end{bmatrix}. \quad (22)$$

Finalmente, a matriz $\mathbf{H} \in \mathbb{R}^{2 \times N}$ é composta pelos vetores de observação descritos em (9) e (17), e complementada pelo vetor nulo $\mathbf{0}_E^T$:

$$\mathbf{H} = \begin{bmatrix} \mathbf{h}_E & K_1 \mathbf{h}_B \\ \mathbf{0}_E^T & K_2 \mathbf{h}_B \end{bmatrix}, \quad (23)$$

em que, K_1 e K_2 são fatores de escala, considerados junto ao vetor de observações (17), que estabelecem a influência exercida pelo sinal EOG nos sinais EEG registrados.

O ruído de processo $\mathbf{w} \in \mathbb{R}^2$ é dado pela concatenação dos ruídos w_E e w_B :

$$\mathbf{w}(n-1) = \begin{bmatrix} w_E(n-1) \\ w_B(n-1) \end{bmatrix}. \quad (24)$$

O ruído de medida $\mathbf{v} \in \mathbb{R}^2$ por sua vez, é dado pela concatenação dos ruídos de medida v_E e v_B :

$$\mathbf{v}(n) = \begin{bmatrix} v_E(n) \\ v_B(n) \end{bmatrix}. \quad (25)$$

4. FILTRAGEM ESTOCÁSTICA

A eliminação do artefato de piscamento é proposta com base na utilização de técnicas de filtragem estocástica sobre o sinal EEG. Para Bar-Shalom et al. (2004) a filtragem estocástica de um vetor de estados de um sistema linear dinâmico estocástico pode ser feita a partir do Filtro de Kalman (FK) (Kalman, 1960). Considerando a natureza estocástica dos sinais de EEG e os modelos lineares construídos que os representam, o FK é aplicado como base para eliminar os artefatos de piscamento. Genericamente, o FK pode ser aplicado a um sistema linear dinâmico discreto no tempo, descrito por:

$$\begin{cases} \mathbf{x}(n+1) = \mathbf{A}(n)\mathbf{x}(n) + \mathbf{C}(n)w(n) \\ \mathbf{z}(n) = \mathbf{H}(n)\mathbf{x}(n) + v(n) \end{cases}, \quad (26)$$

em que $\mathbf{x}(n)$ é o vetor de estados de dimensão n_x , $\mathbf{A}(n)$ é uma matriz conhecida que descreve a dinâmica do sistema. O ruído $w(n)$ é o ruído Gaussiano branco do processo, de covariância $\mathbf{Q}(n)$. A matriz $\mathbf{C}(n)$ é uma matriz conhecida que relaciona o ruído de processo $w(n)$. O vetor de medidas é dado por $\mathbf{z}(n)$, a matriz de observação é $\mathbf{H}(n)$ e por fim, $v(n)$ é o ruído Gaussiano branco de medida, de covariância $\mathbf{R}(n)$. As matrizes \mathbf{A} , \mathbf{C} , \mathbf{H} , \mathbf{Q} e \mathbf{R} podem ou não ser variantes no tempo. A modificação introduzida para a estrutura da matriz $\mathbf{H}(n)$ de observação, em (23), considera a natureza impulsiva do artefato ocular, permitindo o reconhecimento dos artefatos na aplicação da filtragem estocástica. O desenvolvimento do FK pode ser consultado no Apêndice A.

5. SIMULAÇÕES E RESULTADOS

O método proposto é viável a partir do registro de um único canal EEG apenas ou de um conjunto de canais, desde que o sinal EOG também esteja disponível. Neste artigo, optou-se pela utilização do canal Cz do sinal de EEG. As simulações aqui apresentadas foram realizadas no *software* MATLAB. A seguir, as especificações para as simulações, os resultados obtidos e a análise de desempenho do método proposto são apresentadas.

5.1 Identificação dos modelos AR

A identificação dos modelos AR foi realizada a partir da *toolbox* de identificação de sistemas no MATLAB (*System Identification Toolbox*), utilizando trechos selecionados dos sinais de EEG e EOG sem artefato de piscamento presente. Para a definição da ordem dos modelos, uma das métricas de qualidade disponibilizadas pela *toolbox* foi utilizada, o *FitPercent*. Essa métrica expressa em porcentagem, a NRMSE (do inglês, *Normalized Root Mean Squared Error*)

entre os valores medidos e os valores previstos pelo modelo estimado, conforme a equação:

$$FitPercent = 100 \left(1 - \frac{\|y_{med} - y_{mod}\|}{\|y_{med} - \bar{y}_{med}\|} \right), \quad (27)$$

em que, y_{med} representa os dados de saída medidos, \bar{y}_{med} representa a média destes dados, y_{mod} é a resposta prevista pelo modelo e $\|\cdot\|$ indica a norma 2 de um vetor.

O valor resultante da métrica pode variar de $-\infty$ a 100%, indicando desde ajuste incorreto a ajuste perfeito, respectivamente. Considerando o percentual mínimo de 99% de ajuste e buscando manter a simplicidade do modelo, a ordem foi definida como sendo $N_a^E=5$ para o modelo (3) e ordem $N_a^B=3$ para o modelo (10). Além disso, os fatores de escala, apresentados em (23), são definidos empiricamente como $K_1=5$ e $K_2=5 \times 10^{-4}$.

5.2 Parâmetros do FK

A partir da definição completa do modelo (18), aplicou-se o FK, apresentado na Seção 4. As matrizes de covariância do ruído de processo \mathbf{Q} e do ruído de medida \mathbf{R} são:

$$\mathbf{Q} = \begin{bmatrix} \sigma_{q_E}^2 & 0 \\ 0 & \sigma_{q_B}^2 \end{bmatrix}, \quad (28)$$

$$\mathbf{R} = \begin{bmatrix} \sigma_{r_E}^2 & \sigma_{r_B}^2 \\ \sigma_{r_B}^2 & \sigma_{r_E}^2 \end{bmatrix}. \quad (29)$$

A calibração dessas matrizes foi definida empiricamente, considerando a remoção do artefato de piscamento e a análise de desempenho do sinal:

$$\sigma_{q_E} = 1 \times 10^{-5}, \quad (30)$$

$$\sigma_{q_B} = 1 \times 10^{-5}, \quad (31)$$

$$\sigma_{r_E} = 1 \times 10^{-2}, \quad (32)$$

$$\sigma_{r_B} = 1 \times 10^{-5}, \quad (33)$$

em que, σ_{q_E} e σ_{q_B} representam os desvios padrões dos ruídos de processo w_E e w_B , respectivamente, e σ_{r_E} e σ_{r_B} representam os desvios padrões dos ruídos de medida v_E e v_B . Com a aplicação do filtro, o primeiro elemento do estado estimado, $\hat{\mathbf{x}}$, será utilizado como o sinal EEG verdadeiro:

$$\widehat{eeg}_t(n) = \mathbf{H}\hat{\mathbf{x}}_E(n). \quad (34)$$

5.3 Resultados da filtragem

A aplicação do FK levou a resultados que são apresentados nessa seção. Na Figura 5, um trecho filtrado de 30 segundos do canal Cz é apresentado.

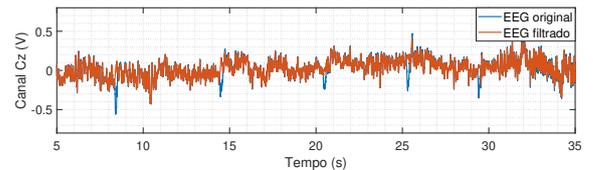


Figura 5. Trecho do sinal de EEG original e filtrado.

Por inspeção visual, no trecho entre $t=19$ s e $t=22$ s, destacado na Figura 6, observa-se que a estimativa do sinal EEG filtrado remove apenas os picos negativos em que o artefato de piscamento ocorre.

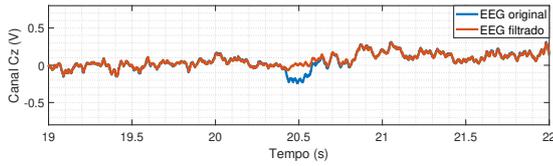


Figura 6. Trecho do sinal de EEG original e filtrado em destaque.

Recortando um trecho do sinal apresentado na Figura 5, de $t=5$ s a $t=18$ s, e observando o sinal de EOG no mesmo intervalo, a atuação do filtro pode ser melhor observada na Figura 7.

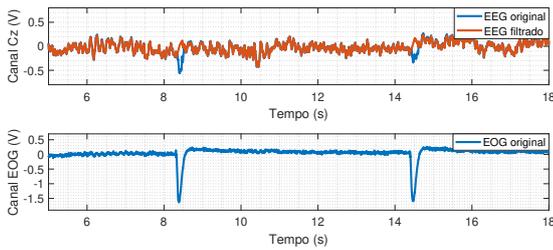


Figura 7. Trecho do sinal de EEG (painel superior) original e filtrado em destaque e trecho do sinal de EOG correspondente (painel inferior).

Apesar do sinal de EEG original apresentar pontos com amplitude e características semelhantes a trechos contaminados por artefato ocular, como por exemplo o intervalo de $t=10$ s a $t=11$ s, nota-se visualmente que a estimativa se mantém fiel às medidas registradas. A partir do sinal de EOG, no mesmo intervalo, percebe-se que não houve piscamento. O filtro reconhece corretamente que durante este período não houve piscamento devido à estrutura proposta para o modelo matemático, que inclui de forma adequada a informação contida no sinal de EOG.

A consistência da eliminação de artefatos é visualizada principalmente no resultado obtido no trecho em que o artefato simulado (apresentado na Seção 2) foi adicionado.

Inspecionando visualmente a Figura 8, nota-se que o sinal de EEG filtrado reproduz o sinal de EEG original de forma fidedigna e com isso, a avaliação do desempenho do método proposto para eliminação de artefatos de piscamento pode ser feita de forma consistente. A aplicação do FK para a eliminação de artefatos de piscamento presentes nos sinais EEG ocorreu, portanto, com sucesso.

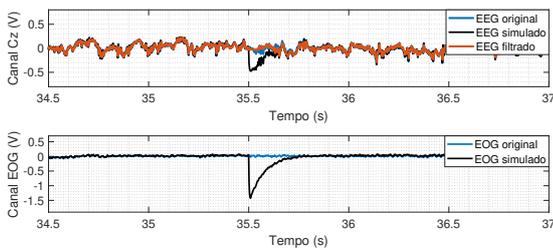


Figura 8. Trecho do sinal de EEG (painel superior) original, simulado e filtrado em destaque e trecho do sinal de EOG correspondente (painel inferior).

5.4 Análise de desempenho

A eliminação dos artefatos é evidente a partir de uma simples inspeção visual, tanto para artefatos reais, presentes nas gravações dos sinais, quanto para artefatos simulados, adicionados aos dados coletados. Entretanto, o ideal é que o método seja avaliado quantitativamente. Para tal, a densidade espectral de potência (PSD, do inglês *Power Spectral Density*) foi utilizada como método de avaliação de desempenho. O método de Welch (Welch, 1967) foi utilizado para o cálculo da PSD. Com esse método, é possível verificar se o espectro do sinal de EEG foi pouco distorcido após a filtragem, é desejável que a PSD do sinal de EEG seja pouco afetada após a eliminação de qualquer artefato (Castellanos and Makarov, 2006).

A estimativa da PSD dos sinais foi realizada considerando as faixas de frequências padronizadas para sinais de EEG: banda α (8–13 Hz), banda β (14–30 Hz) e banda γ (30–50 Hz). Kristeva et al. (2007) destaca maior interesse na banda β , devido à correlação que existe entre atividades motoras e as oscilações presentes nesta faixa. Além disso, nesta faixa de frequências os artefatos exercem menor influência. A aplicação realizada neste artigo usa dados coletados durante a realização de atividades motoras, com isso, um bom critério de eficiência do método é a comparação da PSD nas faixas de interesse, e, especialmente, na banda β .

A estimativa da PSD dos sinais foi realizada pelo método de Welch no *software* MATLAB, com janelas Hanning simétricas de 10000 amostras, sem sobreposição, considerando a faixa de frequência de 7–50 Hz. As faixas de frequência padronizadas são sinalizadas nas PSDs obtidas.

Para Urigüen and Garcia-Zapirain (2015) a avaliação do método deve ser inicialmente feita a partir de simulações. Desta forma, resultados preliminares servem como guia e, posteriormente, é necessário avaliar o verdadeiro desempenho do método com dados reais. Na Figura 9, as PSDs estimadas para o sinal EEG original (sem artefato) e para o mesmo trecho do sinal EEG, após a adição do artefato simulado, são apresentadas. O trecho considerado para estas estimativas é o trecho em que ocorre a adição do artefato simulado ($t=35$ s a $t=36$ s), apresentado na Seção 2.

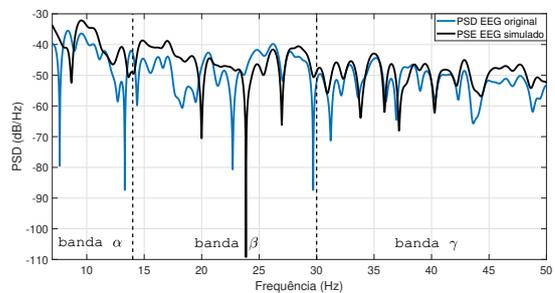


Figura 9. PSDs estimadas pelo método de Welch para sinal de EEG original e com a adição de um artefato de piscamento simulado.

Com a adição do artefato simulado o espectro do sinal é significativamente alterado. A partir da PSD obtida para

o sinal EEG original, o espectro do sinal de EEG com artefato simulado filtrado pode ser conferido na Figura 10.

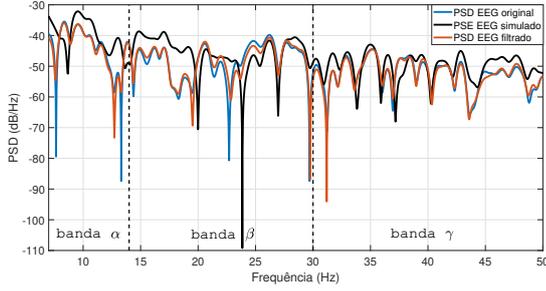


Figura 10. PSDs estimadas pelo método de Welch para sinal EEG original, simulado e filtrado pelo método proposto neste artigo.

A PSD do sinal de EEG com artefato simulado filtrado acompanha a PSD do sinal de EEG original, confirmando que a qualidade do desempenho do sinal EEG filtrado apresentado na Figura 8. O erro quadrático médio (EQM) entre elas foi calculado para as bandas α , β , γ e para faixa de frequência total, de 7 – 50 Hz. A Tabela 1 apresenta os valores obtidos e evidencia a qualidade do desempenho do método proposto neste artigo para a eliminação de artefatos de piscamento simulados.

Tabela 1. EQM entre PSDs do sinal de EEG em um trecho de artefato simulado.

Faixa de frequência	EQM
Banda α	$3,57 \times 10^{-8}$
Banda β	$6,89 \times 10^{-11}$
Banda γ	$1,99 \times 10^{-12}$
7 – 50 Hz	$5,18 \times 10^{-11}$

Considerando um artefato de piscamento real, como o primeiro artefato apresentado na Figura 7, localizado no intervalo de $t=8$ s até $t=10$ s, a estimativa das PSDs do sinal EEG original e filtrado são apresentadas na Figura 11.

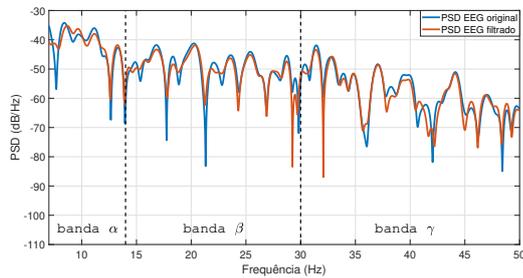


Figura 11. PSDs estimadas pelo método de Welch para sinal de EEG original e filtrado pelo método proposto neste artigo.

Nota-se que a PSD estimada para o sinal EEG filtrado é semelhante a PSD estimada para o sinal EEG real, confirmando então a qualidade do desempenho do FK para a eliminação de artefatos de piscamento reais. Nesse caso, o erro quadrático médio (EQM) calculado para cada faixa foi registrado na Tabela 2.

Tabela 2. EQM entre PSDs do sinal de EEG em um trecho de artefato real.

Faixa de frequência	EQM
Banda α	$4,73 \times 10^{-9}$
Banda β	$8,46 \times 10^{-11}$
Banda γ	$1,95 \times 10^{-11}$
7 – 50 Hz	$6,91 \times 10^{-10}$

6. CONCLUSÕES

O método proposto para a eliminação de artefatos de piscamento em sinais de EEG neste artigo foi implementado com sucesso. A abordagem definida para o problema é possível a partir do registro de um único canal de sinal de EEG e do sinal ocular registrado pelo EOG. O modelo matemático, construído a partir de modelos AR, contempla a inclusão da informação disposta pelo canal EOG, contribuindo assim para o reconhecimento e filtragem dos períodos de ocorrência dos artefatos nos sinais EEG com precisão.

A filtragem estocástica aplicada por meio do FK apresentou o sinal estimado livre de artefatos, causando pequenas distorções no sinal de EEG filtrado e mantendo a densidade espectral de potência próxima a do sinal de EEG original.

Entretanto, existem alguns aspectos do método que podem ser refinados futuramente. A definição da influência do sinal de EOG nos sinais de EEG registrados com os fatores de escala K_1 e K_2 e da calibração das matrizes de covariância do FK, a partir dos valores definidos para σ_{q_E} , σ_{q_B} , σ_{r_E} e σ_{r_B} , foi realizada empiricamente. O desempenho do filtro pode melhorar a partir da aplicação de um algoritmo de otimização para a definição destes parâmetros e também testado para diferentes sujeitos a fim de garantir a robustez do método. Além disso, considerando a baixa influência dos artefatos na banda β , a minimização do erro espectral nessa faixa é uma possibilidade para o aperfeiçoamento do método. Para efeito comparativo, coloca-se ainda uma possível aplicação futura dos métodos NLMS e HMM, aos dados selecionados para este trabalho, que também propõe abordagens com métodos estocásticos, desta forma será possível conferir, mais uma vez, a eficácia do método proposto.

AGRADECIMENTOS

A coleta dos dados utilizados no presente estudo foi realizada no âmbito de projetos previamente financiados pela FAPESP (proc. n° 11/17193-0 e n° 13/10433-1). O Prof. Dr. Leonardo Abdala Elias é bolsista de produtividade em pesquisa nível 2 do CNPq (proc. n° 312442/2017-3). O Prof. Dr. João Bosco Ribeiro do Val é bolsista de produtividade em pesquisa nível 1A do CNPq (proc. n° 303352/2018-3). A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo suporte financeiro para o desenvolvimento do artigo.

REFERÊNCIAS

- Aguirre, L.A. (2007). *Introdução à Identificação de Sistemas-Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais*. Editora UFMG.
- Anderer, P., Roberts, S., Schlögl, A., Gruber, G., Klösch, G., Herrmann, W., Rappelsberger, P., Filz, O., Barba-

- noj, M.J., Dorffner, G., et al. (1999). Artifact processing in computerized analysis of sleep EEG—a review. *Neuropsychobiology*, 40(3), 150–157.
- Bar-Shalom, Y., Li, X.R., and Kirubarajan, T. (2004). *Estimation with applications to tracking and navigation: theory algorithms and software*. John Wiley & Sons.
- Castellanos, N.P. and Makarov, V.A. (2006). Recovering EEG brain signals: artifact suppression with wavelet enhanced independent component analysis. *Journal of neuroscience methods*, 158(2), 300–312.
- Cohen, M.X. (2014). *Analyzing neural time series data: theory and practice*. MIT press.
- Elias, L., Toledo, D., Lima, F., and Kohn, A.F. (2017). The gain of visual feedback influences force variability but not corticomuscular coherence during plantar flexion isometric contractions. In *Proceedings of the 47th Annual Meeting of the Society for Neuroscience, 2017*. Neuroscience 2017, 2017, Washington.
- Hamal, A.Q. and bin Abdul Rehman, A.W. (2013). Artifact processing of epileptic EEG signals: An overview of different types of artifacts. In *2013 International Conference on Advanced Computer Science Applications and Technologies*, 358–361. IEEE.
- Jansen, B. (1985). Analysis of biomedical signals by means of linear modeling. *Critical reviews in biomedical engineering*, 12(4), 343–392.
- Jiang, X., Bian, G.B., and Tian, Z. (2019). Removal of artifacts from EEG signals: a review. *Sensors*, 19(5), 987.
- Kalman, R.E. (1960). A new approach to linear filtering and prediction problems.
- Kristeva, R., Patino, L., and Omlor, W. (2007). Beta-range cortical motor spectral power and corticomuscular coherence as a mechanism for effective corticospinal interaction during steady-state motor output. *Neuroimage*, 36(3), 785–792.
- Mohammadpour, M., Hashemi, S.M.R., and Houshmand, N. (2017). Classification of eeg-based emotion for bci applications. In *2017 Artificial Intelligence and Robotics (IRANOPEN)*, 127–131. IEEE.
- Noureddin, B., Lawrence, P.D., and Birch, G.E. (2008). Quantitative evaluation of ocular artifact removal methods based on real and estimated EOG signals. In *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 5041–5044. IEEE.
- Seeck, M., Koessler, L., Bast, T., Leijten, F., Michel, C., Baumgartner, C., He, B., and Beniczky, S. (2017). The standardized EEG electrode array of the IFCN. *Clinical Neurophysiology*, 128(10), 2070–2077.
- Shahabi, H., Moghimi, S., and Zamiri-Jafarian, H. (2012). EEG eye blink artifact removal by EOG modeling and kalman filter. In *2012 5th International Conference on BioMedical Engineering and Informatics*, 496–500. IEEE.
- Society, A.C.N. et al. (2006). Guideline 5: guidelines for standard electrode position nomenclature. *American journal of electroencephalographic technology*, 46(3), 222.
- Torse, D.A. and Desai, V.V. (2016). Design of adaptive eeg preprocessing algorithm for neurofeedback system. In *2016 International Conference on Communication and Signal Processing (ICCSP)*, 0392–0395. IEEE.
- Urigüen, J.A. and Garcia-Zapirain, B. (2015). EEG artifact removal—state-of-the-art and guidelines. *Journal of neural engineering*, 12(3), 031001.
- Wallstrom, G.L., Kass, R.E., Miller, A., Cohn, J.F., and Fox, N.A. (2004). Automatic correction of ocular artifacts in the EEG: a comparison of regression-based and component-based methods. *International journal of psychophysiology*, 53(2), 105–119.
- Welch, P. (1967). The use of fast fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms. *IEEE Transactions on audio and electroacoustics*, 15(2), 70–73.

Apêndice A. FILTRO DE KALMAN

O algoritmo do FK consiste em duas etapas: previsão e atualização. Em (A.1) a equação de previsão de estado é apresentada e a matriz de covariância do erro de previsão do estado em (A.2):

$$\hat{\mathbf{x}}(n+1|n) = \mathbf{A}(n)\hat{\mathbf{x}}(n|n), \quad (\text{A.1})$$

$$\mathbf{P}(n+1|n) = \mathbf{A}(n)\mathbf{P}(n|n)\mathbf{A}(n)^\top + \mathbf{C}(n)\mathbf{Q}(n)\mathbf{C}(n)^\top. \quad (\text{A.2})$$

Na etapa da atualização, as equações de ganho do filtro, atualização do estado e matriz de covariância do erro de estimativa do estado são dadas por:

$$\mathbf{K}(n+1) = \mathbf{P}(n+1|n)\mathbf{H}(n+1)^\top\mathbf{S}(n+1)^{-1}, \quad (\text{A.3})$$

$$\hat{\mathbf{x}}(n+1|n+1) = \hat{\mathbf{x}}(n+1|n) + \mathbf{K}(n+1)[\mathbf{z}(n+1) - \hat{\mathbf{z}}(n+1|n)], \quad (\text{A.4})$$

$$\mathbf{P}(n+1|n+1) = [\mathbf{I} - \mathbf{K}(n+1)\mathbf{H}(n+1)]\mathbf{P}(n+1|n), \quad (\text{A.5})$$

em que,

$$\mathbf{S}(n+1) = \mathbf{H}(n+1)\mathbf{P}(n+1|n)\mathbf{H}(n+1)^\top + \mathbf{R}(n+1), \quad (\text{A.6})$$

$$\hat{\mathbf{z}}(n+1|n) = \mathbf{H}(n+1)\hat{\mathbf{x}}(n+1|n). \quad (\text{A.7})$$

É importante notar a alteração introduzida nesse trabalho nas equações do filtro de Kalman, em particular na matriz de observação $\mathbf{H}(n)$, apresentada na Seção 3, vide a Eq. (17). A inclusão do próprio sinal de EOG como um elemento da matriz de observação permitiu um reconhecimento superior dos artefatos de piscamento.