

ESTIMAÇÃO DA SINCRONIZAÇÃO/DESSINCRONIZAÇÃO RELACIONADA AO EVENTO (SRE/DRE) UTILIZANDO A ESTIMAÇÃO DUAL DE ESTADOS E PARÂMETROS

Felipe A. Tavares* Fabricio J. Erazo-Costa* Wendy Y. Eras-Herrera*

* Departamento de Engenharia Elétrica, Universidade Federal de Ouro Preto, MG, (e-mail: felipe.tavares2@aluno.ufop.edu.br).

Abstract: This paper investigates the estimate of the desynchronization/synchronization (ERD/ERS) of the motor imagery of the left hand using the dual estimation of states and parameters. Our methodology includes three steps: the modeling step, the state estimation step and the parameter estimation step. The results suggest that the dual estimation of state and parameters is a promising method to estimate the ERD/ERS related to the imagination of movement, making it a useful tool for the application in brain-machine interface.

Resumo: Este trabalho investiga a estimação da sincronização e dessincronização (SRE/DRE) da imagética motora da mão esquerda utilizando a estimação dual de estados e parâmetros. A metodologia deste trabalho compreende três etapas: a etapa de modelagem, a etapa de estimação de estados e a etapa de estimação de parâmetros. Os resultados obtidos sugerem que o estimador dual de estados e parâmetros é um método promissor para a estimação da SRE/DRE relacionada à imaginação do movimento, tornando-se uma ferramenta útil para aplicações de interface cérebro-máquina.

Keywords: ERD/ERS, motor imagery, dual estimation, Kalman filter, recursive least squares.

Palavras-chaves: SRE/DRE, imagética-motora, estimação dual, filtro de Kalman, mínimos quadrados recursivos.

1. INTRODUÇÃO

Uma interface cérebro-máquina (ICM) permite o controle de dispositivos eletrônicos ou atuadores eletromecânicos como próteses ou órteses utilizando a atividade cerebral (Saha et al., 2019). A imagética motora (IM) pode ser definida como a execução de uma tarefa motora sem a ativação de vias eferentes (músculos) (Bayliss, 2001). Desta forma, ICMs baseadas em IM tem sido utilizadas como ferramentas para o auxílio de terapia de neuroreabilitação (Marchesotti et al., 2016).

O potencial relacionado ao evento (PRE) (Levine et al., 2000) e a sincronização/dessincronização relacionadas ao evento SRE/DRE (Bayliss, 2001) são respostas encontradas na eletroencefalografia (EEG) devido a realização de tarefas motoras. A SRE/DRE pode ser caracterizada pelo aumento ou redução da energia em um intervalo de frequência específico, por exemplo no ritmo alfa (8-13Hz) existe uma diminuição de energia antes e durante a IM, enquanto que na banda beta (13-30Hz) existe uma diminuição de energia durante a IM e um aumento de energia após a IM (Pfurtscheller and Da Silva, 1999a). Comumente utilizam-se os modelos auto-regressivos (AR) e modelos auto regressivos de médias móveis (ARMA) para estimação paramétrica da SRE/DRE (Florian and Pfurtscheller, 1995; Tarvainen et al., 2004), entretanto

a qualidade do modelo depende da estimativa dos seus parâmetros. O filtro de Kalman (FK) é apresentado como uma ferramenta versátil que visa melhorar a estimação da SRE/DRE, entretanto o desempenho do FK depende de sua inicialização e do ajuste dos parâmetros dos modelos (Fabri et al., 2011).

Os suavizadores baseados no filtro de Kalman (SK) tem sido utilizados na literatura para estimar a SRE/DRE (Tarvainen et al., 2004; Khan and Dutt, 2007; Oikonomou et al., 2009). Nestes estudos, duas diferentes abordagens são propostas para estimar os parâmetros variantes no tempo do modelo utilizando o SK para estimar o sinal de SRE/DRE. Em (Tarvainen et al., 2004), o algoritmo de mínimos quadrados recursivos (MQR) é utilizado para estimar os parâmetros variantes no tempo, enquanto que uma versão modificada do algoritmo SK de intervalo fixo é empregado para estimar a SRE/DRE. Nos estudos realizados por (Khan and Dutt, 2007; Oikonomou et al., 2009), para estimar os parâmetros variantes no tempo utiliza-se o algoritmo *Expectation-Maximization* (EM), enquanto que para estimar o sinal de SRE/DRE emprega-se o SK de atraso fixo. Do ponto de vista prático, a estimação de estados utilizando suavizadores pode ser empregada para melhorar a estimativa do estado por meio do uso de medições futuras, além das medições passadas e presente. O grande problema dos SKs, quando utilizados

em aplicações com ICMs, é que não podem ser empregados em aplicações em tempo real devido ao uso de informações futuras. Assim, outros métodos podem ser utilizados para obter a estimativa de estados e parâmetros do sinal de SRE/DRE considerando aplicações em tempo real.

Existem técnicas na literatura que tratam o problema de estimação de estados e parâmetros de sistemas dinâmicos como a estimação conjunta (Sitz et al., 2002; Bitencourt et al., 2004) e a estimação dual (Wan et al., 1999). A primeira abordagem realiza em uma única etapa a estimação de estados e parâmetros por meio da definição de um vetor de estados aumentado, composto pelos estados e parâmetros. Na segunda abordagem, a estimação de estados e parâmetros são tratados em etapas separadas. No estudo desenvolvido por (Nelson, 2000) relata-se que a estimação conjunta, apresenta problemas de divergência. Esse problema pode ser contornado utilizando a estimação dual cuja abordagem desacopla a estimação de estados e parâmetros.

A contribuição deste trabalho é estimar a SRE/DRE da IM da mão esquerda utilizando a estimação dual de estados e parâmetros. A metodologia proposta consiste em três etapas. Na primeira etapa, é obtido o modelo linear ARMA que representa a SRE/DRE a partir do sinal de EEG registrado durante a tarefa da IM. Na segunda etapa, esse modelo é utilizado na implementação do filtro de Kalman (FK) para estimar o sinal de SRE/DRE. Na terceira etapa, o algoritmo MQR é utilizado para estimar os parâmetros variantes no tempo do modelo usado no FK. Desta forma, a estimação dual é utilizada para estimar a SRE/DRE da IM da mão esquerda.

2. FORMULAÇÃO DO PROBLEMA

Considere o sistema linear no tempo discreto

$$x_k = f(x_{k-1}, u_{k-1}, \theta_{k-1}, w_{k-1}, k - 1), \quad (1)$$

$$y_k = h(x_k, \nu_k, k), \quad (2)$$

em que $x_k \in R^n$ é o vetor de estados, $f : R^n \times R^p \times R^{n_\theta} \times R^q \times N \rightarrow R^n$ é o modelo de processo e $h : R^n \times R^r \times N \rightarrow R^m$ é o modelo de observação. As entradas são dadas por $u_k \in R^p$ e o vetor de medições é dado por $y_k \in R^m$. Assume-se que o ruído de processo $w_k \in R^q$ e o ruído de medição $\nu_k \in R^r$ sejam variáveis aleatórias brancas, de média nula e mutuamente independentes e com matrizes de covariância Q_{k-1} e R_k , respectivamente, e $\theta_{k-1} \in R^{n_\theta}$ é o vetor de parâmetros. Assume-se que θ_k satisfaça ao modelo de regressão linear

$$\bar{z}_k = \psi_{k-1}^T \theta_k + \epsilon_k \quad (3)$$

em que $\bar{z}_k \in R$ e $\psi_{k-1} \in R^{n_\theta}$ são a saída e regressores do modelo, os quais são dados por valores presente e passados de x_k e u_k , e ϵ_k é o erro de modelagem. Neste trabalho, utiliza-se a estimação dual de estados e parâmetros para estimar a SRE/DRE da IM da mão esquerda a partir do registro do sinal de EEG.

A metodologia usada para a estimação da SRE/DRE envolve três etapas, conforme ilustrado no diagrama da Figura 1. Na primeira etapa, os registros dos sinais de EEG de um indivíduo são utilizados para obter o modelo linear ARMA que representa a SRE/DRE. Na segunda

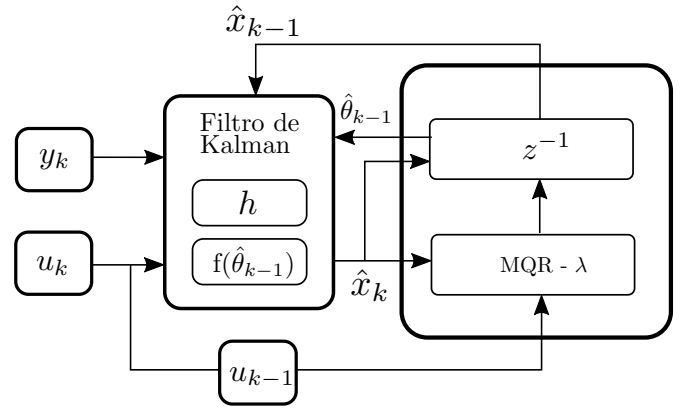


Figura 1. A abordagem de estimação dual de estados e parâmetros de um sistema dinâmico. Inicialmente, o FK é usado para estimar os estados \hat{x}_k a partir do modelo de processo com parâmetros $\hat{\theta}_{k-1}$ variantes no tempo, modelo de observação e um conjunto de medições ruidosas, y_k . Em seguida, o algoritmo de MQR é empregado para estimar os parâmetros $\hat{\theta}_k$ para atualizar o modelo de processo que será usado no próximo instante de tempo. Adaptado de (Abreu et al., 2016).

etapa, o FK clássico utiliza tal modelo ARMA para tratar o problema de estimação do sinal de SRE/DRE. A fim de tratar o problema de estimação de parâmetros variantes no tempo do modelo de processo utiliza-se o algoritmo MQR. Desta forma, a abordagem de estimação dual de estados e parâmetros emprega as estimativas do FK \hat{x}_k e as entradas u_{k-1} para a estimação dos parâmetros $\hat{\theta}_k$ do modelo de processo por meio do algoritmo MQR. Portanto, o modelo de processo é atualizado ao longo do tempo de forma independente e desacoplada da estimativa de estado fornecida pelo FK.

3. MATERIAIS E MÉTODOS

3.1 Protocolo Experimental

O conjunto de dados consiste no registro do EEG de 9 indivíduos fornecido pelo evento BCI Competition (Brunner et al., 2008).




Figura 2. Protocolo experimental. O breve aviso sonoro ($t = -3$) indica que o indivíduo deverá prestar atenção na tela do computador (cruz de fixação). Em seguida, aparece uma seta ($t = -1$) que indica ao indivíduo qual tarefa motora deverá ser executada. Posteriormente, o indivíduo executa a IM da tarefa solicitada ($t = 0$). Após um breve repouso o processo se reinicia.

Os dados foram coletados em dois dias diferentes em que os indivíduos permaneciam sentados em uma poltrona confortável em frente a uma tela de computador. A frequência de amostragem é de 250 Hz. No início de uma sessão ($t = -3s$), uma cruz de fixação aparece na tela preta, seguido de um breve tom acústico de aviso. Após dois segundos ($t = -1s$), um indicador na forma de uma seta apontando para a esquerda, direita, para baixo ou para cima orienta ao indivíduo a realização das IM: mão esquerda, mão direita, dos pés e da língua respectivamente. A tarefa motora é realizada até que a seta desaparecer em $t=3s$. Finalmente uma pausa de 1.5 a 2.5 é realizada até o início do próximo trecho. A figura 2 mostra a temporização deste protocolo.

3.2 Sincronização/Dessincronização Relacionada ao Evento.

Dado o sinal de um canal de EEG (SRE/DRE $\in R^{c \times s}$ de 68 trechos) filtrado na banda de interesse e subtraído o PRE (média coerente dos trechos), T representa a média das energias dos N trechos (ponto a ponto) e R representa a média das energias em um segmento de referência sem estimulação. Desta forma, A SRE/DRE pode ser definida a seguir (Pfurtscheller and Da Silva, 1999a)

$$SRE/DRE(\%) = \frac{T - R}{R} * 100\%, \quad (4)$$

3.3 Identificação de Sistemas

Para realizar a modelagem matemática da SRE/DRE é necessário desenvolver as cinco etapas fundamentais de identificação descritas em (Aguirre, 2004).

Modelo SRE/DRE O sinal de SRE/DRE pode ser representado por meio do modelo ARMA (Tarvainen et al., 2004). O modelo ARMA é caracterizado por uma combinação dos modelos autorregressivos (AR) com os modelos de médias móveis (MA). Esse modelo é descrito por

$$r_k = a_1 r_{k-1} + \dots + a_p r_{k-p} + b_1 e_{k-1} + \dots + b_q e_{k-q} + e_k, \quad (5)$$

em que r_k é o sinal de SRE/DRE, $\theta^T = [a_1 \dots a_p \ b_1 \dots b_q]$ é o vetor de parâmetros, p e q são a ordem dos modelos AR e MA, respectivamente. e_k é o erro de modelagem.

Para determinar a ordem dos modelos é utilizado o critério de Akaike (AIC) (Akaike, 1974). Esse critério é dado por

$$AIC = -2 \ln L(\hat{y}_i, y_i) + 2\eta_\theta \quad (6)$$

em que y_i é a i -ésima medição do sinal de SRE/DRE, \hat{y}_i é a estimativa de y_i e η_θ é o número de parâmetros no modelo.

Para estimar os parâmetros do modelo ARMA a partir dos dados medidos, é utilizado o método de mínimos quadrados (MQ). A solução desse método é dada por

$$\hat{\theta} = [\Psi^T \Psi]^{-1} \Psi^T y_k \quad (7)$$

em que θ é o vetor de parâmetros do modelo, Ψ é a matriz de regressores e y_k é o vetor de medições.

Existem diversos métodos de validação de um modelo identificado. Dentre esses métodos, a simulação livre e o índice RMSE (raiz quadrada do erro quadrático médio) são utilizados para validar o modelo da SRE/DRE.

A simulação livre também conhecida como predição de infinitos passos à frente, reutiliza valores de predições passadas para compor um vetor de regressores

$$\psi_{y u_{k-1}}^T = [y_{k-1} \ y_{k-2} \ y_{k-3} \ y_{k-4} \ y_{k-5} \ y_{k-6} \ u_{k-1} \ u_{k-2} \ u_{k-3} \ u_{k-4} \ u_{k-5} \ u_{k-6}], \quad (8)$$

O índice RMSE é dado por

$$RMSE = \frac{\sqrt{\sum_{k=1}^n (y_k - \hat{y}_k)^2}}{\sqrt{\sum_{k=1}^n (y_k - \bar{y})^2}} \quad (9)$$

em que \hat{y}_k é a simulação livre do sinal e \bar{y} é o valor médio do sinal medido y_k e n é o número de elementos da amostra de teste.

3.4 Filtro de Kalman

O filtro de Kalma é usado para estimar os estados de um sistema dinâmico de forma recursiva (Kalman, 1960). O modelo deste sinal dado pela equação (5) é reescrito no formato de espaço de estados como

$$x_k = A_{k-1} x_{k-1} + B_k u_{k-1} + w_{k-1}, \quad (10)$$

$$y_k = C_k x_k + v_k, \quad (11)$$

em que $A_{k-1} \in R^{n \times n}$ é a matriz de transição, $B_{k-1} \in R^{n \times m}$ é a matriz de entrada do sistema e a matriz de saída $C_k \in R^{m \times n}$ são conhecidas. x_{k-1} é o vetor das medições passadas do sinal de EEG e $y_k \in R^m$ é o vetor do sinal de EEG medido.

O algoritmo do FK compreende duas etapas: a *etapa de predição* e a *etapa de assimilação de dados*, conforme mostrado na Figura 3. Para a inicialização, assumamos que o vetor aleatório x_0 é Gaussiano com média $\hat{x}_{0|0}$ e covariância $P_{0|0}^{xx} = E[(x_0 - \hat{x}_{0|0})(x_0 - \hat{x}_{0|0})^T]$, ambas conhecidas.

A *etapa de predição* é responsável pela predições do sinal de SRE/DRE a partir da informação disponível *a priori* (Kalman, 1960), dada por:

$$\hat{x}_{k|k-1} = A_{k-1} \hat{x}_{k-1|k-1} + B_{k-1} u_{k-1}, \quad (12)$$

$$P_{k|k-1}^{xx} = A_{k-1} P_{k-1|k-1}^{xx} A_{k-1}^T + G_{k-1} Q_{k-1} G_{k-1}^T, \quad (13)$$

$$\hat{y}_{k|k-1} = C_k \hat{x}_{k|k-1}, \quad (14)$$

$$P_{k|k-1}^{yy} = C_k P_{k|k-1}^{xx} C_k^T + R_k, \quad (15)$$

$$P_{k|k-1}^{xy} = P_{k|k-1}^{xx} C_k^T. \quad (16)$$

em que $P_{k|k-1}^{xx} = E[(x_k - \hat{x}_{k|k-1})(x_k - \hat{x}_{k|k-1})^T]$, $P_{k|k-1}^{yy} = E[(y_k - \hat{y}_{k|k-1})(y_k - \hat{y}_{k|k-1})^T]$, $P_{k|k-1}^{xy} = E[(x_k - \hat{x}_{k|k-1})(y_k - \hat{y}_{k|k-1})^T]$ são as matrizes de covariância do erro de predição, covariância da inovação e covariância cruzada, respectivamente.

A *etapa de assimilação de dados* incorpora uma nova informação do sinal de SRE/DRE medido y_k , para obter uma melhor estimativa do sinal de SRE/DRE:

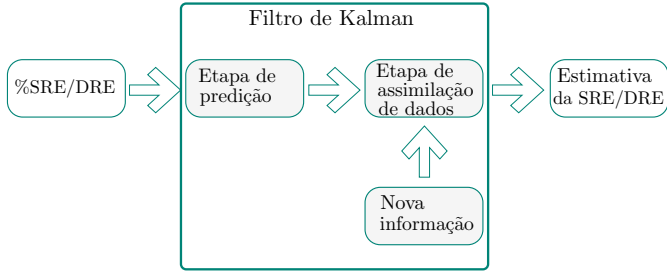


Figura 3. O filtro de Kalman compreende duas etapas fundamentais: a etapa de predição que estima as variáveis de estado a partir do modelo que representa os sinais de SRE/DRE, e a etapa de assimilação que incorpora novas informações proveniente de medições dos sinais de SRE/DRE.

$$K_k = P_{k|k-1}^{xy} (P_{k|k-1}^{yy})^{-1}, \quad (17)$$

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k (y_k - \hat{y}_{k|k-1}), \quad (18)$$

$$P_{k|k}^{xx} = P_{k|k-1}^{xx} - K_k P_{k|k-1}^{yy} K_k^T. \quad (19)$$

em que $K_k \in R^{n \times m}$ é denominado o ganho de Kalman, $\hat{x}_{k|k}$ é o vetor de estado e a correspondente matriz de covariância $P_{k|k}$.

3.5 Estimação Dual de Estados e Parâmetros

Considera-se que o sistema dinâmico de interesse para identificação é representado por um modelo em espaços de estados linear (10)-(11), para que o modelo seja atualizado é necessário estimar os estados \hat{x}_k e o vetor de parâmetros $\hat{\theta}_k$. Reescrevendo os modelos em espaços de estados f e h para uma representação polinomial temos

$$z_k = \sum_{i=1}^{n_\theta} \phi_{i,k} \hat{\theta}_i \quad (20)$$

em que $\hat{\theta}_i$ representa o i -ésimo parâmetro do modelo e $\phi_{i,k}$ indica o i -ésimo regressor do modelo para n_θ termos. Esta equação representa casos onde a representação polinomial é utilizada para estimar os parâmetros do modelo (Abreu et al., 2016).

Na Figura 1 mostra-se a abordagem de estimação dual (ED) de estados e parâmetros. A abordagem ED estima os estados e parâmetros, de maneira independente, em duas etapas. A primeira etapa consiste na estimação dos estados \hat{x}_k utilizando o FK descrito na Seção 3.4, enquanto que, na segunda etapa emprega-se o algoritmo de MQR com fator de esquecimento constante para estimar os parâmetros do modelo de processo utilizado no FK. O algoritmo de MQR é dado por

$$K_k = \frac{P_{k-1} \psi_k}{\psi_k^T P_{k-1} \psi_k + \lambda} \quad (21)$$

$$\theta_k = \theta_{k-1} + K_k [z_k - \psi_k^T \theta_{k-1}] \quad (22)$$

$$P_k = \frac{1}{\lambda} \left(P_{k-1} - \frac{P_{k-1} \psi_k \psi_k^T P_{k-1}}{\psi_k^T P_{k-1} \psi_k + \lambda} \right) \quad (23)$$

em que λ é o fator de esquecimento constante que impõe maior peso nos dados mais recentes.




Figura 4. (a) Dados de identificação do indivíduo #1 usados para obter-se o modelo ARMA (24) na banda alfa (8-13Hz) do eletrodo C_z da IM da mão esquerda (promediação dos sinais da SRE/DRE dos 34 trechos) e (b) Dados de validação do indivíduo #1 do eletrodo C_z usados para validar o modelo (24) a partir da promediação dos sinais da SRE/DRE dos 34 trechos restantes.

4. RESULTADO E DISCUSSÃO

Os dados foram processados *offline*, utilizando-se o software *Matlab* versão R2018a. Nesta etapa de processamento, o sinal de SRE/DRE é obtido a partir da filtragem no ritmo alfa (8-13Hz) dos trechos síncronos com estímulo provenientes da segmentação dos dados de acordo com as quatro tarefas realizadas por 9 indivíduos. Em seguida, esses trechos são elevados ao quadrado para encontrar a potência das amostras. Finalmente, realiza-se a promediação das amostras de potência e a promediação em janelas temporais ($N = 68$ trechos) para diminuir a variabilidade das respostas que é quantificada resultando na SRE/DRE.

Na etapa de identificação de sistemas são obtidos os modelos da SRE/DRE na banda alfa (8-13Hz) dos eletrodos C_3 , C_4 e C_z durante a IM da mão esquerda a partir da promediação dos sinais da SRE/DRE (34 trechos) do indivíduo #1. Para a validação de cada modelo emprega-se a promediação dos sinais da SRE/DRE (34 trechos restantes) do indivíduo #1 para os eletrodos C_3 , C_4 e C_z . A Figura 4 mostra os dados de identificação e validação do indivíduo #1 para o eletrodo C_z .

4.1 Modelo do SRE/DRE

São obtidos três modelos que representam a SRE/DRE dos eletrodos C_z , C_3 e C_4 durante a IM da mão esquerda. O primeiro sistema descrito pela SRE/DRE do eletrodo C_z é representado pela seguinte modelo ARMA com ordem $p = q = 6$,

$$r_k = 1.204r_{k-1} - 0.287r_{k-2} - 0.130r_{k-3} + 0.079r_{k-4} + 0.033r_{k-5} - 0.066r_{k-6} - 0.009e_{k-1} - 0.066e_{k-2} - 0.022e_{k-3} + 0.082e_{k-4} - 0.024e_{k-5} - 0.064e_{k-6} + e_k, \quad (24)$$

O segundo sistema descrito pela SRE/DRE do eletrodo C_3 é representado pela seguinte modelo ARMA com ordem $p = q = 6$,

$$r_k = 1.213r_{k-1} - 0.382r_{k-2} - 0.130r_{k-3} - 0.222r_{k-4} - 0.052r_{k-5} - 0.132r_{k-6} - 0.021e_{k-1} - 0.194e_{k-2} - 0.133e_{k-3} + 0.091e_{k-4} - 0.210e_{k-5} + 0.015e_{k-6} + e_k, \quad (25)$$

O terceiro sistema descrito pela SRE/DRE do eletrodo C₄ é representado pela seguinte modelo ARMA com ordem $p = q = 6$,

$$r_k = 1.239r_{k-1} - 0.266r_{k-2} - 0.287r_{k-3} + 0.258r_{k-4} - 0.184r_{k-5} - 0.082r_{k-6} - 0.010e_{k-1} + 0.033e_{k-2} - 0.020e_{k-3} - 0.039e_{k-4} + 0.0736e_{k-5} + 0.069e_{k-6} + e_k, \quad (26)$$

4.2 Validação dos modelos

A validação dos modelos ARMA (24), (25) e (26) será verificada utilizando duas métricas: a simulação livre e o índice RMSE. A Figura 5 mostra a validação dos modelos ARMA (24), (25) e (26) utilizando a simulação livre. Por meio de uma inspeção visual observa-se a semelhança entre o sinal de simulação livre (linha tracejada vermelha) obtido por meio dos modelos ARMA (24), (25), (26) e o sinal medido da SRE/DRE (linha contínua azul), nos três eletrodos C_z, C₃ e C₄.




Figura 5. Simulação livre dos modelos ARMA (24), (25) e (26) da SRE/DRE na banda alfa (8-13Hz) da IM da mão esquerda dos eletrodos: (a) C₃, (b) C_z e (c) C₄. Os traçados mostram a simulação livre dos modelos ARMA (linha tracejada vermelha) e o sinal medido da SRE/DRE (linha contínua azul).

Ao analisar o percentual de SRE/DRE observa-se que existe uma diminuição no ritmo alfa no instante $t = 0$, seguido de um aumento do percentual de SRE/DRE no instante de tempo $t = 1$, momento que ocorre a IM da mão esquerda do indivíduo #1, corroborando com os resultados encontrados na literatura (Pfurtscheller and Da Silva, 1999b).

A segunda métrica empregada para a validação dos modelos ARMA (24), (25) e (26) é o índice RMSE que representa a raiz do erro quadrático médio entre o valor observado e valor da predição. Na Tabela 1 mostram-se os valores de RMSE do modelo identificado (24), (25) e (26) para os eletrodos C₃, C₄ e C_z de todos os indivíduos. Observa-se que quanto mais próximo de zero for o valor do RMSE indica que os modelos obtidos representam o comportamento do sinal de SRE/DRE.

4.3 Estimação da SRE/DRE

O algoritmo do FK fornece a estimativa do sinal de SRE/DRE durante a IM da mão esquerda a partir dos valores das estimativas anteriores, das medições do sinal de SRE/DRE e dos modelos identificados (24). A Figura 6 mostra a estimativa do sinal da SRE/DRE da IM da mão esquerda do eletrodo C_z utilizando o FK. Este FK emprega o modelo de processo (24) cujos parâmetros são invariantes no tempo.




Figura 6. Estimação da SRE/DRE na banda alfa (8-13Hz) da IM da mão esquerda do eletrodo C_z utilizando o filtro de Kalman e a estimação dual. Os traçados mostram o sinal medido da SRE/DRE (linha contínua azul), a estimativa do filtro de Kalman (linha contínua vermelha) e a estimação dual (linha contínua preta).

Tabela 1: Valores RMSE dos modelos identificados ARMA (24), (25) e (26), do Filtro de Kalman(FK) e da estimação dual(ED) para os eletrodos C_z, C₃ e C₄ dos 9 indivíduos.

Indivíduo	CZ			C3			C4		
	Modelo ARMA	FK	ED	Modelo ARMA	FK	ED	Modelo ARMA	FK	ED
S1	0,56	0,22	0,02	0,54	0,19	0,02	0,53	0,23	0,00
S2	0,37	0,34	0,00	0,38	0,35	0,00	0,40	0,31	0,00
S3	0,56	0,26	0,00	0,37	0,19	0,00	0,37	0,16	0,00
S4	0,56	0,25	0,00	0,55	0,21	0,04	0,58	0,24	0,02
S5	0,73	0,24	0,19	0,62	0,24	0,01	0,66	0,22	0,01
S6	0,31	0,30	0,00	0,41	0,29	0,01	0,53	0,23	0,19
S7	0,23	0,22	0,00	0,24	0,22	0,00	0,26	0,23	0,00
S8	0,49	0,26	0,00	0,40	0,23	0,00	0,57	0,25	0,03
S9	0,46	0,26	0,00	0,36	0,35	0,32	0,29	0,19	0,00
Média	0,47	0,26	0,02	0,43	0,25	0,04	0,47	0,23	0,03

Observa-se que a estimativa do sinal da SRE/DRE da IM da mão esquerda (traçado em cor vermelha) descreve a dinâmica do sinal medido da SRE/DRE (traçado em cor azul). A abordagem de ED de estados e parâmetros fornece a estimativa do sinal de SRE/DRE durante a IM da mão esquerda utilizando o KF cujos parâmetros variantes no tempo do modelo de processo (24) são estimados utilizando o algoritmo MQR.

A Figura 6 mostra a estimativa do sinal da SRE/DRE da IM da mão esquerda do eletrodo C_z utilizando a ED. Em termos de estimativa, a abordagem de ED (traçado em cor preta) apresenta uma melhor estimativa com relação ao algoritmo do FK (traçado em cor vermelha), pois a abordagem de ED utiliza as estimativas de estado fornecida pelo KF para estimar os parâmetros, diminuindo a incerteza da estimativa.

5. CONCLUSÕES

Neste trabalho, estima-se a SRE/DRE durante a IM da mão esquerda utilizando a estimação dual de estados e parâmetros. Para isso, a metodologia proposta consiste em três etapas. Na primeira etapa é obtido o modelo ARMA que representa o sinal da SRE/DRE. Na segunda etapa, esse modelo é utilizado na implementação do FK para estimar o sinal de SRE/DRE. Na terceira etapa, o algoritmo MQR é utilizado para estimar os parâmetros variantes no tempo do modelo usado no FK.

Os resultados obtidos sugerem que a estimação dual de estados de parâmetros fornece melhores estimativas da SRE/DRE em comparação ao modelo identificado ARMA que depende da qualidade das estimativas dos parâmetros e o FK cujo desempenho depende da inicialização e do ajuste dos parâmetros do modelo (Fabri et al., 2011). Ao analisar os três cenários, diferentes valores de RMSE foram obtidos, o modelo ARMA quando analisado apresentou valor de RSME que variam entre 0.7378 e 0.2394, o FK apresentou um erro de estimativa do sinal de SRE/DRE que variam entre 0.1635 e 0.3530, em contrapartida a estimação dual apresentou um erro de estimativa do sinal de SRE/DRE que variam entre 0.0005 e 0.1961. Assim, a abordagem proposta apresenta melhor desempenho na estimativa comparada com o FK.

Como proposta para trabalhos futuros, implementar o algoritmo MQR com fator de esquecimento variante com o intuito de melhor a estimação de estados do sistema.

AGRADECIMENTOS

Os autores agradecem a instituição de ensino Universidade Federal de Ouro Preto por viabilizar suas pesquisas.

REFERÊNCIAS

Abreu, P.E., Teixeira, B.O., and Mesquita, A.R. (2016). Abordagens para atualização de parâmetros no contexto de estimação dual de estados e parâmetros.
Aguirre, L.A. (2004). *Introdução à identificação de sistemas—Técnicas lineares e não-lineares aplicadas a sistemas reais*. Editora UFMG.
Akaike, H. (1974). A new look at the statistical model identification. *IEEE transactions on automatic control*, 19(6), 716–723.

Bayliss, J.D. (2001). *A flexible brain-computer interface*.
Bitencourt, J.H., Tôrres, L.A.B., and Aguirre, L.A. (2004). Estimação conjunta de estados e parâmetros com o filtro de kalman unscented: Um estudo de caso usando o circuito de chua.
Brunner, C., Leeb, R., Müller-Putz, G., Schlögl, A., and Pfurtscheller, G. (2008). Bci competition 2008—graz data set a. *Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces), Graz University of Technology*, 16, 1–6.
Fabri, S.G., Camilleri, K.P., and Cassar, T. (2011). Parametric modelling of eeg data for the identification of mental tasks. *Biomedical Engineering, Trends in Electronics, Communications and Software*, 367–386.
Florian, G. and Pfurtscheller, G. (1995). Dynamic spectral analysis of event-related eeg data. *Electroencephalography and clinical neurophysiology*, 95(5), 393–396.
Kalman, R.E. (1960). A new approach to linear filtering and prediction problems.
Khan, M.E. and Dutt, D.N. (2007). An expectation-maximization algorithm based kalman smoother approach for event-related desynchronization (erd) estimation from eeg. *IEEE transactions on biomedical engineering*, 54(7), 1191–1198.
Levine, S.P., Huggins, J.E., BeMent, S.L., Kushwaha, R.K., Schuh, L.A., Rohde, M.M., Passaro, E.A., Ross, D.A., Elisevich, K.V., and Smith, B.J. (2000). A direct brain interface based on event-related potentials. *IEEE Transactions on Rehabilitation Engineering*, 8(2), 180–185.
Marchesotti, S., Bassolino, M., Serino, A., Bleuler, H., and Blanke, O. (2016). Quantifying the role of motor imagery in brain-machine interfaces. *Scientific reports*, 6(1), 1–12.
Nelson, A.T. (2000). *Nonlinear estimation and modeling of noisy time-series by dual Kalman filtering methods*. Ph.D. thesis, Citeseer.
Oikonomou, V.P., Tzallas, A.T., Konitsiotis, S., Tsalikakis, D.G., and Fotiadis, D.I. (2009). The use of kalman filter in biomedical signal processing. *Kalman Filter: Recent Advances and Applications*.
Pfurtscheller, G. and Da Silva, F.L. (1999a). Event-related eeg/meg synchronization and desynchronization: basic principles. *Clinical neurophysiology*, 110(11), 1842–1857.
Pfurtscheller, G. and Da Silva, F.L. (1999b). Event-related eeg/meg synchronization and desynchronization: basic principles. *Clinical neurophysiology*, 110(11), 1842–1857.
Saha, S., Mamun, K.A., Ahmed, K., Mostafa, R., Naik, G.R., Khandoker, A., Darvishi, S., and Baumert, M. (2019). Progress in brain computer interfaces: challenges and trends. *arXiv preprint arXiv:1901.03442*.
Sitz, A., Schwarz, U., Kurths, J., and Voss, H.U. (2002). Estimation of parameters and unobserved components for nonlinear systems from noisy time series. *Physical review E*, 66(1), 016210.
Tarvainen, M.P., Hiltunen, J.K., Ranta-Aho, P.O., and Karjalainen, P.A. (2004). Estimation of nonstationary eeg with kalman smoother approach: an application to event-related synchronization (ers). *IEEE Transactions on Biomedical Engineering*, 51(3), 516–524.
Wan, E.A., Van Der Merwe, R., and Nelson, A.T. (1999). Dual estimation and the unscented transformation. In *NIPS*, 666–672.