

Laboratório de Modelagem, Análise e Controle de Sistemas Não-Lineares

Departamento de Engenharia Eletrônica

Universidade Federal de Minas Gerais

Av. Antônio Carlos 6627, 31270-901 Belo Horizonte, MG Brasil

Fone: +55 3499-4866 - Fax: +55 3499-4850



Detecção do potencial relacionado à imaginação do movimento usando a filtragem de Kalman

Wendy Yadira Eras Herrera

Dissertação submetida à banca examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais, como parte dos requisitos necessários à obtenção do grau de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Bruno Otávio Soares Teixeira
Co-orientador: Prof. Dr. Carlos Julio Tierra-Criollo

Belo Horizonte, Dezembro de 2012

Dedicatória

*Aos meus pais Wilson e Gladys,
as minhas irmãs Vanessa e Saskia
e ao meu sobrinho Alejandro
pelo apoio e incentivo.
Esta não é apenas uma conquista minha,
mas sim de todos vocês, por tudo o que fizeram por mim.
Obrigada!*

Agradecimentos

A Deus, pelas oportunidades que surgem todos os dias na minha vida, por mais uma etapa vencida e principalmente pelas pessoas, verdadeiros anjos, que colocou no meu caminho e que sem elas tudo seria muito mais difícil.

A meus pais Gladys e Wilson, pelo incansável apoio, compreensão, amor e incentivo foram o suporte primordial para que eu alcançasse esta conquista.

A minhas irmãs Vanessa e Saskia pelo apoio incondicional, por me acompanhar durante estes anos de trabalho, por acreditar em mim.

Ao meu orientador, professor e amigo Bruno Otávio, pela paciência, pela clareza, pela simplicidade e pelo brilhantismo com que conduziu a orientação deste trabalho, agregando bastante valor à minha formação como engenheira e como ser humano.

Ao Prof. Carlos Julio, por dividir comigo seus conhecimentos, por me orientar nesta trajetória e a sua esposa Andrea pela presença constante na minha vida, por serem parte deste importante trabalho.

A minha família brasileira Mozar, Luciano, Arnaldo e Ludimila, pela atenção e preocupação em me ajudar no que fosse necessário e pelo apoio em todos os momentos.

Aos meus amigos Renan, Jullierme, Rogério, Rodrigo pelo suporte contínuo e pelo companheirismo dentro e fora da universidade.

Aos meus amigos do Laboratório de Modelagem, Análise e Controle de Sistemas Não-Lineares (MACSIN) pela colaboração durante a realização deste trabalho. Em especial, Victor, Dimas, Tales, Rodrigo e Anny pelo auxílio computacional e a Cristina pela apoio nos momentos difíceis.

Aos meus amigos do Laboratório de Sistemas de Computação e Robótica (CORO) pela parceria e companheirismo durante todo desenvolvimento do trabalho. Em especial, ao Jullierme e a Natália pelo auxílio computacional.

Aos amigos do Núcleo de Estudos e Pesquisas em Engenharia Biomédica (NEPEB) pela colaboração durante a realização deste trabalho. Em especial, Fabricio pelos conselhos e dicas.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), FAPEMIG e CNPq pelo apoio financeiro.

Sumário

Resumo	xi
Abstract	xiii
Lista de Figuras	xvi
Lista de Tabelas	xvii
Lista de Abreviações	xix
1 Introdução	1
1.1 Motivação e Justificativa	1
1.2 Formulação do Problema	5
1.3 Objetivos do Projeto	7
1.4 Organização do Trabalho	7
2 Uma Breve Revisão sobre o Processamento do Sinal de EEG	9
2.1 Anatomia e Fisiologia do Cérebro Humano	9
2.1.1 O cérebro	10
2.1.2 O córtex cerebral	10
2.1.3 Fisiologia do Movimento Voluntário (MV) e Imaginação do Movimento (IM)	11
2.2 Os Sinais de EEG	14
2.2.1 Protocolo de Aquisição do Sinal de EEG	15
2.2.2 Potencial Espontâneo	16

2.2.3	Potenciais Relacionados ao Evento (PRE)	16
2.3	Técnicas de Processamento de Sinais de EEG para a Detecção do PRE . .	18
2.3.1	Média Coerente de Trechos Sincronizados com o Evento	18
2.4	Número de Repetições da Tarefa Mental	19
3	Materiais e Métodos	21
3.1	Descrição do Protocolo Experimental	21
3.1.1	Pré-Processamento do Sinal de EEG	25
3.2	Decimação do sinal de EEG	25
3.3	Modelagem Matemática	27
3.3.1	Seleção de Estrutura	28
3.3.2	Estimação dos Parâmetros	31
3.3.3	Validação dos Modelos	31
3.4	Banco de Filtros de Kalman	34
3.4.1	Filtro de Kalman	35
3.4.2	Estimador de Múltiplos Modelos Interativos (MMI)	38
3.4.3	Estimador Pseudo-Bayesiano Generalizado de 1a. Ordem (GPB1)	41
4	Resultados	43
4.1	Decimação do sinal de EEG	43
4.2	Modelagem Matemática	45
4.2.1	Modelagem do Potencial Espontâneo	46
4.2.2	Modelagem do PRE Durante a Tarefa Viso-Motora	49
4.2.3	Modelagem do PRE Durante a Tarefa Imagética-Motora	52
4.2.4	Efeito do Número de Repetições da Tarefa Mental	56
4.3	Banco de Filtros de Kalman	58
4.3.1	Filtro de Kalman	58
4.3.2	Banco Interativo de Filtros de Kalman	67
4.4	Síntese Comparativa dos Resultados	71
4.4.1	Estimativa do Pico CNV	71
4.4.2	Efeito da Variação do Número de Trechos na Classificação do EEG_{IM}	74

5 Conclusões e Trabalhos Futuros	77
5.1 Considerações Finais	77
5.2 Propostas de Continuidade	79
Bibliografia	85

Resumo

A interface cérebro-máquina (ICM) é um sistema de comunicação que utiliza sinais cerebrais para controlar a ativação de dispositivos externos. A ICM é uma via de interação entre pessoas que apresentam alguma incapacidade motora e o ambiente externo. Uma das formas de aperfeiçoar os conhecimentos envolvidos no desenvolvimento de ICMs é por meio do estudo dos sinais de potenciais relacionados ao evento (PRE), os quais são obtidos pelo registro do sinal de encefalograma (EEG). A identificação do PRE em meio da atividade elétrica espontânea é uma etapa fundamental na implementação de uma ICM. O PRE motor, provocado por uma tarefa motora, pode ser caracterizado por componentes pré-evento, como contingente de variação negativa (CNV). Assim, os sinais de EEG registrados durante as tarefas mentais, como execução do movimento voluntário EEG_{TVM} ou imaginação do movimento EEG_{IM} , podem, a princípio, serem utilizados para o acionamento de dispositivos externos, como próteses, órteses ou cadeiras de rodas. Neste trabalho foram utilizados sinais de EEG de 7 indivíduos saudáveis por meio de 19 eletrodos utilizando o sistema internacional 10-20. A contribuição deste trabalho é estimar e detectar o PRE relacionado à imaginação do movimento do dedo indicador da mão esquerda utilizando um banco interativo com dois filtros de Kalman (BIFK) em paralelo. O primeiro FK fornece uma estimativa dos sinais de EEG_{TV} , ao passo que o segundo fornece uma estimativa para o sinal de EEG_{TVM} ou EEG_{IM} . Neste trabalho, a metodologia inclui duas etapas: a etapa de modelagem e a etapa de estimação. O BIFK alcançou taxas de classificação de 65, 92, 89, 94, 90, 54 e 67 % para os sete indivíduos, respectivamente, para $M = 30$ trechos. Inicialmente, o sinal de EEG durante a EEG_{IM} contém $M=30$ trechos. Além disso, é analisado o efeito do número de repetições da tarefa mental na detecção do PRE. Do ponto de vista prático, o menor número de repetições da tarefa tornaria a ICM mais rápida, pois o indivíduo executaria um menor número de repetições da mesma tarefa. Dessa forma, com a finalidade de detectar o sinal de PRE utilizando menos repetições da EEG_{IM} , propõe-se obter modelos matemáticos a partir da promediação dos trechos do sinal de EEG com $M=15$, $M=10$ e $M=5$ durante as tarefas mentais. Os resultados obtidos sugerem que o BIFK é um método promissor para a detecção de PRE relacionados à imaginação do movimento, tornando-se uma ferramenta útil para aplicações de ICMs.

Abstract

The brain-machine interface (BMI) is a communication system that uses brain signals to control the activation of external devices. The BMI is a two way interaction between people who have some motor impairment and the external environment. One way to improve the skills involved in developing BMIs is by means of the study of event-related potential (ERP) signals, which are obtained by recording the EEG signal. The identification of the ERP among the spontaneous electrical activity is a key step in implementing a BMI. The motor ERP, caused by a motor task, may be characterized by pre-event components, such as Contingent Negative Variation (CNV). Thus, the EEG signals recorded during mental tasks, such as voluntary movement execution (EEG_{TVM}) or imagination of the movement (EEG_{IM}), can, in principle, be used to drive external devices such as prostheses, orthoses or wheelchairs. In this work, EEG signals collected from 7 healthy individuals by means of 19 electrodes using the international 10-20 system were used. The contribution of this work is to estimate and detecting the ERP related to the imagination of the movement of the left hand's index finger using an interactive bank with two Kalman filters (BIFK) in parallel. The first KF estimates the EEG_{TV} signals, whereas the second one estimates the EEG_{TVM} or EEG_{IM} . This work's methodology includes two steps: the modeling step and the estimation step. The BIFK reached classification rates of 65, 92, 89, 94, 90, 54, and 67 % for all individuals, respectively, for $M=30$ epochs. Initially, the EEG signal during the EEG_{IM} contains $M=30$ epochs. Furthermore, we analyze the effect of the number of mental task's repetitions on the detection of ERP. From a practical standpoint, a smaller number of repetitions would make the BMI faster, since the individual would have to perform a smaller number of repetitions of the same task. Thus, in order to detect the signal ERP using fewer repetitions of EEG_{IM} , this work proposes obtaining mathematical models from the averaging epochs of the EEG signal with $M = 15$, $M = 10$ and $M = 5$ during mental tasks. The results suggest that the BIFK is a promising method to detect the ERP related to the imagination of movement, making it a useful tool for the application of BMIs.

Lista de Figuras

1.1	Esquema da proposta deste trabalho	6
1.2	Diagrama da abordagem proposta	6
2.1	Lobos do córtex cerebral	10
2.2	Subdivisões funcionais corticais	11
2.3	Áreas de Brodmann	12
2.4	Áreas envolvidas com o planejamento motor	13
2.5	Homúnculo em corte mostrando a área motora	14
2.6	Diagrama do SI 10-20 de posicionamento dos eletrodos para EEG	15
2.7	Potencial de EEG espontâneo	16
2.8	O componente contingente de variação negativa (CNV)	17
3.1	Etapas do pré-processamento do sinal de EEG.	22
3.2	Amplificador de sinais biológicos BrainNet BNT - 36	23
3.3	Acelerômetro	23
3.4	Promediação dos trechos dos sinais de EEG durante as tarefas	24
3.5	Registro do sinal de EEG	26
3.6	Diagrama da promediação do sinal de EEG durante as tarefas	29
3.7	Diagrama do algoritmo do filtro de Kalman	36
3.8	Diagrama da abordagem do BIFK	39
3.9	Diagrama do algoritmo do estimador MMI	40
3.10	Diagrama da abordagem do BGFK	42
4.1	Função de autocorrelação da promediação do sinal de EEG	44
4.2	Função de autocorrelação da promediação do sinal decimado de EEG	45
4.3	Promediação do sinal de EEG_{TV}	46
4.4	AIC para o sinal de EEG_{ESP}	47
4.5	Validação do modelo EEG_{ESP} usando predição 150 passos à frente	47
4.6	Índice RMSE para o sistema descrito por EEG_{ESP}	48
4.7	Análise de resíduos do sistema descrito por EEG_{ESP}	48
4.8	Promediação do sinal de EEG_{TVM}	49
4.9	AIC para o sinal de EEG_{TVM}	50

4.10	Entrada: impulso unitário nos tempos $t = -1s$ e $t = 0s$	50
4.11	Validação do modelo do PRE durante a EEG_{TVM} usando predição 150 passos à frente	51
4.12	Índice RMSE para o sistema descrito pelo PRE durante a EEG_{TVM}	52
4.13	Análise de resíduos do sistema descrito pelo PRE durante a EEG_{TVM}	52
4.14	Promediação do sinal de EEG_{IM}	53
4.15	AIC para o sinal de EEG_{IM}	54
4.16	Validação do modelo do PRE durante a EEG_{IM} usando predição 150 passos à frente	55
4.17	Índice RMSE para o sistema descrito pelo PRE durante a EEG_{IM}	55
4.18	Análise de resíduos do sistema descrito pelo PRE durante a EEG_{IM}	56
4.19	Simulação dos modelos obtidos a partir do sinal de EEG tarefa visual com M trechos.	59
4.20	Simulação dos modelos obtidos a partir do sinal de EEG tarefa visomotora com M trechos.	60
4.21	Simulação dos modelos obtidos a partir do sinal de EEG tarefa imagética-motora com M trechos.	61
4.22	Estimativa da promediação do sinal de EEG_{TV} fornecida pelo FK	64
4.23	Estimativa da promediação do sinal de PRE durante a EEG_{TVM} fornecida pelo FK	66
4.24	Estimativa da promediação do sinal de PRE durante a EEG_{IM} fornecida pelo FK	67
4.25	Estimativa da promediação do sinal de EEG_{IM} utilizando o BIFK	69
4.26	Estimativa da promediação do sinal de EEG_{IM} utilizando o BGFK	70
4.27	Comparando as estimativas da promediação do sinal de PRE durante a EEG_{IM} utilizando o FK e BFK	70
4.28	Índice RMSE das estimativas fornecidas pelas abordagens de FK, BGFK, BIFK para a promediação do sinal de EEG_{IM}	74

Lista de Tabelas

4.1	Parâmetros dos modelos AR do sistema EEG_{TV}	57
4.2	Parâmetros dos modelos ARX do sistema EEG_{TVM}	57
4.3	Parâmetros dos modelos ARX do sistema EEG_{IM}	57
4.4	Valores dos picos CNV ($t = 0s$) da promediação do sinal de EEG_{TV} e EEG_{TVM} utilizando FK	72
4.5	Valores dos picos CNV ($t = 0s$) da promediação do sinal de EEG_{TV} e EEG_{IM} utilizando FK	73
4.6	Valores dos picos CNV ($t = 0s$) durante o sinal de EEG_{TV} e EEG_{IM} utilizando BFK	73
4.7	Classificação do potencial relacionado à imaginação do movimento utilizando o BIFK	75

Lista de Acrônimos

AIC	Critério de Informação Akaike;
AMS	Área motora suplementar;
AR	Auto-regressivo;
ARX	Auto-regressivo com entradas externas;
BFK	Banco de filtros de Kalman;
BIFK	Banco interativo de filtros de Kalman;
BGFK	Banco pseudo-bayesiano generalizado de 1a. ordem de filtros de Kalman;
CNV	Contingente de variação negativa;
DRE	Dessincronização Relacionadas ao Evento;
EEG	Eletroencefalograma;
EEG _{ESP}	Potencial espontâneo;
EEG _{TVM}	Sinal de EEG durante a tarefa viso-motora;
EEG _{TV}	Sinal de EEG durante a tarefa visual;
EEG _{IM}	Sinal de EEG durante a tarefa imagética-motora;
fMRI	Imagem de ressonância magnética funcional;
FK	Filtro de Kalman;
GPB1	Estimador Pseudo-Bayesiano Generalizado de 1a. Ordem;
IM	Imaginação do Movimento;
M1	Córtex pré-motor;
MMI	Estimador Múltiplos Modelos Interativos;
MSC	Magnitude Quadrática da Coerência;
MV	Movimento Voluntário;
MQ	Mínimos Quadrados;
NEPEB	Núcleo de Estudos e Pesquisas em Engenharia Biomédica da UFMG;
PET	Tomografia por emissão de positrona;
PRE	Potencial Relacionado ao Evento;
RSR	Relação Sinal-Ruído;
SI	Sistema Internacional;
SN	Sistema Nervoso;
SNC	Sistema Nervoso Central;
SNP	Sistema Nervoso Periférico;
SRE	Sincronização Relacionadas ao Evento;

Introdução

“O caminho mais curto é sempre tentar mais uma vez”

Thomas A. Edison

1.1 Motivação e Justificativa

É promissor pensar na possibilidade de um comando mental ser capaz de mover automaticamente próteses, órteses e, conseqüentemente, melhorar a qualidade de vida de indivíduos que apresentam limitações no controle parcial ou total de membros do corpo. Um dos desafios atuais da comunidade científica é desenvolver, de forma eficiente, novas vias de interação entre pessoas que apresentam alguma incapacidade motora e o ambiente externo. Com o objetivo de alcançar esse desafio, têm sido investigados projetos de sistemas de comunicação que utilizam sinais cerebrais para controlar a ativação de dispositivos externos [Wolpaw, J. R., McFarland, D. J., Vaughan, T. M., 2000; Pfurtscheller, G., Neuper, C., 2001; Pfurtscheller, G., Flotzinger, D., Kalcher, J., 1993]. Tais sistemas são denominados de interfaces cérebro-máquina (ICM).

Uma das formas de aperfeiçoar os conhecimentos envolvidos no desenvolvimento de ICMs é por meio do estudo dos sinais de potenciais relacionados ao evento (PRE), os quais são obtidos pelo registro do sinal de eletroencefalograma (EEG) [Bayliss, 2001]. O PRE pode ser considerado como uma série de respostas transientes pós-sinápticas, principalmente de neurônios piramidais, provocadas por um estímulo específico [Pfurtscheller G, Lopes da Silva, F. H., 1999], por exemplo, considere o PRE motor, provocado por uma tarefa motora. Tal sinal pode ser caracterizado por componentes pré-evento, como contingente de variação negativa (CNV), e pós evento, como N2 e P3, entre outras [Coles, M.G.H., Rugg, M.D, 1996]. Assim, os sinais de EEG registrados durante

as tarefas cognitivas como execução do movimento voluntário (MV) ou imaginação do movimento (IM) podem, a princípio, ser utilizados para o acionamento de dispositivos externos, como próteses, órteses ou cadeiras de rodas [Jervis, B.W., Saatchi, M.R., Lacey, A., Foberts, T., Allen, E.M., Hudson, N.R., Oke, S., Grimsley, M., 1994].

Um dos grandes desafios na implementação de uma ICM é a identificação do PRE em meio da atividade elétrica espontânea (EEG_{ESP}). Assim, torna-se necessário a aplicação de técnicas de processamento de sinais para separar as duas componentes do sinal de EEG registrado durante as tarefas mentais: sinal de PRE e EEG_{ESP} . Isso é necessário porque as respostas captadas no escalpo são geralmente consideradas como a combinação de EEG_{ESP} , PRE e componentes de ruído gerados a partir de outras fontes fisiológicas, como piscar de olho e outros artefatos. Portanto, nos registros de EEG é difícil determinar a forma do PRE devido à pobre relação sinal-ruído (RSR).

Várias técnicas têm sido utilizadas para detectar o PRE no EEG, como transformada Wavelets [Hinterberger, T.; Kubler, A.; Kaiser, J.; Neumann, N.; Birbaumer, 2003; Xue, J. Z.; Zhang, H.; Zheng, C. X.; Yan, 2003; Graimann B.; Huggins, J. E.; Levine, 2004], componentes independentes e componentes principais [Makeig et al., 2000; Braga E., Braga N., 2006; Chiappa, S., Barber, D., 2006], sincronização e dessincronização relacionada ao evento [Neuper C., Wortz M., 2006; Pfurtscheller, 1999] e redes neurais [Forsslund, 2003; Piccione, F., Giorgi, F., Tonin, P., Priftis, K. Giove, S., Silvoni, S., Palmas, G., Beverina, F., 2006]. O grande problema dessas técnicas, quando utilizadas em aplicações com ICMs não invasivas, é o elevado tempo de processamento e o grande número de trechos de dados necessário que contêm os PREs. Portanto, estudos desenvolvidos por [Hinterberger, T.; Kubler, A.; Kaiser, J.; Neumann, N.; Birbaumer, 2003; Graimann B.; Huggins, J. E.; Levine, 2004] utilizam a combinação de técnicas de análise de sinais de EEG para melhorar a remoção de ruído e detecção do PRE, tornando-se uma ferramenta mais eficaz no desenvolvimento de ICMs.

Alguns estudos recentes desenvolvidos no laboratório Núcleo de Estudos e Pesquisas em Engenharia Biomédica (NEPEB) da UFMG sugerem que a combinação de diferentes técnicas de análise de sinais de EEG proporcionam uma melhora na detecção de PRE. Tal combinação de técnicas tem-se revelado como uma ferramenta promissora

para a detecção de padrões da IM, viabilizando a sua utilização em aplicações de ICMs. Uma das técnicas mais utilizadas para estimar o PRE e melhorar a RSR no domínio do tempo é a média coerente de trechos sincronizados com evento [Tierra-Criollo, 2001; Braga E., Braga N., 2006]. A magnitude quadrática da coerência (MSC) tem sido utilizada como uma técnica para melhorar a RSR e para a detecção estatística do PRE no domínio da frequência [Simpson DM., Tierra-Criollo CJ., Leite RT., Zayen EJB., Infantosi AFC., 2000; Tierra-Criollo, 2001; Dobie R. A., 1989; Miranda de Sá, A. M., Infantosi, A. F., 2005]. Por exemplo, a MSC aplicada ao EEG da IM do dedo indicador da mão esquerda, foi capaz de detectar o PRE com uma probabilidade de detecção (PD) de 58,8% utilizando 40 trechos ($M = 40$). A aplicação da MSC associada à técnica de derivação da fonte (DF) proporcionou uma PD de 99,6% para $M=40$, 34,83 % para $M=10$. Utilizando a MSC simples, foi possível detectar o PRE com uma PD de 52,2% para $M=1$, melhorando a PD [Santos Filho, 2010]. Os modelos ocultos de Markov (do inglês *Hidden Markov Model*-HMM) e as redes neurais artificiais (RNA) foram utilizadas como técnicas de classificação de IM com taxas de acerto de, respectivamente, 73,0% e 79,5% para $M=45$ e 68,5 % e 79,5 % para $M=12$ [Souza, 2010]. A prática mental (PM) foi empregada para aumentar os valores da MSC na banda delta. Posteriormente, o uso da MSC associado à máquina de vetores de suporte (SVM) apresenta uma taxa de acerto de 98% na classificação de padrões da IM para $M=45$ trechos [Erazo-Costa, 2012].

Dentre essas técnicas, a filtragem invariante ou variante no tempo têm sido utilizadas para estimar e detectar o PRE. A filtragem invariante, por exemplo, usando técnicas de filtragem de Wiener, considera o PRE como um sinal estacionário [Weerd J. P. C. , Marten W. L. J., 1978]. Porém, o sinal de PRE é considerado como uma série de respostas transientes com diferentes latências. Por outro lado, técnicas de filtragem variante no tempo geralmente não são capazes de separar o sinal de PRE e o EEG_{ESP} devido à sobreposição dos espectros [Weerd, J. P. C., Kap, J. I., 1981]. Além disso, tais técnicas geralmente não consideram a variação de amplitude e latência do sinal de PRE. Assim, outros métodos podem ser utilizados para obter a estimativa do PRE considerando o comportamento estocástico do sinal, utilizando, por exemplo, o filtro de Kalman (FK).

O FK tem sido utilizado na literatura para estimar as mudanças dinâmicas presentes

nos PREs. Nos estudos desenvolvidos por [Von Spreckelsen, 1988; Georgiadis, S. D., Ranta-aho, P. O., Tarvainen, M. P., Karjalainen, P. A, 2005], duas diferentes abordagens são propostas utilizando o FK para detectar o PRE. Em [Georgiadis, S. D., Ranta-aho, P. O., Tarvainen, M. P., Karjalainen, P. A, 2005], o método de estimativa variante no tempo, o filtro de Kalman e a filtragem de Wiener são combinados para estimar o sinal de PRE (componente P300 resposta ao estímulo auditivo) utilizando o FK. Ao passo que, no estudo realizado por [Von Spreckelsen, 1988] o FK estima o sinal de PRE (componentes sensoriais resposta ao estímulo somatossensorial) a partir de modelos auto-regressivos e auto-regressivos com entradas externas que descrevem a atividade espontânea e o potencial evocado, respectivamente. Esses modelos são usados no FK para estimar os sinais de EEG. [Hou, 2008; Mohseni, H. R., Wilding, E. L., Sanei, S., 2007] sugerem procedimentos similares para estimar o PRE utilizando o FK. Todos os estudos citados utilizam um único filtro de Kalman para estimar apenas um sinal de EEG.

A contribuição deste trabalho é estimar e detectar o PRE relacionado à imaginação do movimento do dedo indicador da mão esquerda utilizando um algoritmo recursivo com um banco interativo com dois filtros de Kalman (BIFK) em paralelo [Magill, 1965]. Neste trabalho, a etapa de modelagem dos sistemas está baseada na abordagem proposta por [Von Spreckelsen, 1988]. O BIFK é baseado em padrões identificados a partir da promediação dos sinais de EEG durante as tarefas visual (EEG_{TV}), viso-motora (EEG_{TVM}) e imagética-motora (EEG_{IM}). Na EEG_{TV} , o indivíduo não realiza a tarefa motora e nem a imaginação do movimento; na EEG_{TVM} , o indivíduo é orientado a executar o movimento e na EEG_{IM} , o indivíduo é orientado a imaginar o movimento do dedo indicador da mão esquerda. Na etapa de modelagem é analisado se o comportamento dinâmico do EEG_{IM} apresenta as mesmas características do EEG_{TVM} . O BIFK permite classificar a imaginação do movimento presente na medição do sinal de EEG por meio dos pesos obtidos a cada estimativa. Cada FK fornece a estimativa do sinal de EEG durante a EEG_{TV} e EEG_{IM} , respectivamente. Esse peso determina quando foi executada a imaginação do movimento do dedo. A vantagem do BIFK é que ele executa simultaneamente os dois sistemas (EEG_{TV} e EEG_{IM}). Desta forma, o BIFK recursivo é utilizado para detectar o PRE a partir da combinação das estimativas recursivas dos sinais de

EEG de ambas tarefas.

Além disso, é analisado o efeito do número de repetições da tarefa mental na detecção do PRE. Neste trabalho, a promediação do sinal de EEG durante a tarefa mental EEG_{TVM} e EEG_{IM} contém $M=30$ trechos. Do ponto de vista prático, o menor número de repetições da tarefa tornaria a ICM mais rápida, pois o indivíduo executaria um menor número de repetições da mesma tarefa. Dessa forma, com a finalidade de detectar o sinal de PRE utilizando menos repetições da EEG_{IM} , propõe-se obter modelos matemáticos a partir da promediação dos trechos do sinal de EEG com $M=15$, $M=10$ e $M=5$ durante as tarefas mentais. Esses modelos são usados no FK para estimar os sinais de EEG.

1.2 Formulação do Problema

Considera-se que a promediação do sinal de EEG registrado durante a tarefa imagética-motora, EEG_{IM} , é composto por duas componentes, como

$$EEG_{IM} = s_k + r_k \quad (1.1)$$

em que s_k é o PRE e r_k é o EEG_{ESP} . Neste trabalho, é usado um método de detecção e estimação do potencial relacionado à imaginação do movimento do dedo indicador da mão esquerda a partir do registro do sinal de EEG.

A Figura 1.1 mostra a metodologia usada neste trabalho. A estimativa e classificação do PRE envolve duas etapas. As coletas dos sinais de EEG e a etapa de pré-processamento foram realizados pelo aluno de mestrado Fabricio Erazo-Costa [Erazo-Costa, 2012]. Na primeira etapa, os sinais coletados são utilizados para se obter os modelos lineares auto-regressivo (AR) e auto-regressivo com entradas externas (ARX) que representam o EEG_{ESP} e o PRE, respectivamente. Na segunda etapa, o BIFK utiliza os modelos AR e ARX em cada FK para estimar a promediação dos sinais de EEG durante as tarefas mentais. Como também, o BIFK é empregado para classificar o PRE relacionado à imaginação do movimento do dedo indicador da mão esquerda.

A Figura 1.2 mostra o diagrama da abordagem do BIFK. Esse algoritmo permite

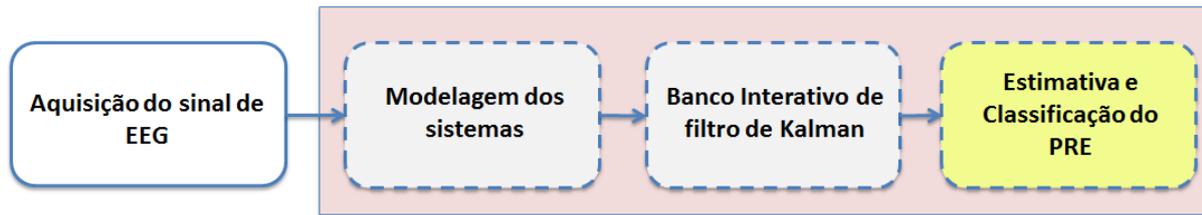


Figura 1.1: Esquema da proposta deste trabalho. O sistema possui duas etapas básicas: obtenção dos modelos matemáticos dos sinais de EEG, estimativa dos sistemas e classificação do PRE usando o banco de filtros de Kalman.

classificar a tarefa mental presente na medição do sinal de EEG por meio dos pesos obtidos a cada estimativa. A execução simultânea dos dois filtros de Kalman (FK1 e FK2) fornece a estimativa do sinal de EEG durante a EEG_{TV} e EEG_{IM} , respectivamente. O peso obtido a cada estimativa permite detectar a probabilidade de ocorrência de EEG_{TV} e EEG_{IM} . O BIFK é baseado em padrões identificados a partir da promediação do sinal de EEG durante as EEG_{TV} e EEG_{IM} . Os modelos são utilizados na implementação de cada FK. Finalmente, o BIFK combina as duas estimativas para detectar o PRE durante à imaginação do movimento.

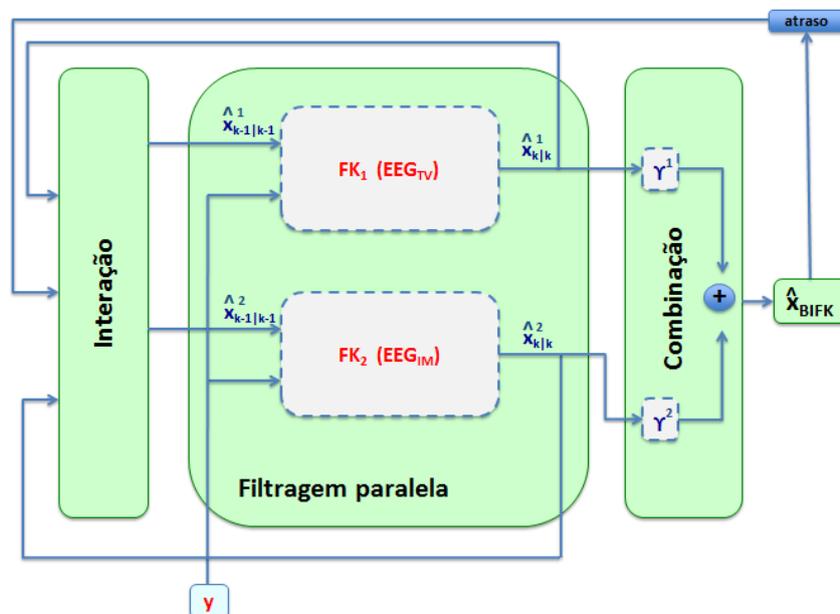


Figura 1.2: Diagrama da abordagem proposta, o BIFK detecta e estima o PRE obtidos a partir da combinação de dois FK executados em paralelo. Cada FK usa um diferente modelo de EEG_{TV} e EEG_{IM} .

1.3 Objetivos do Projeto

O objetivo deste trabalho é detectar o potencial relacionado à imaginação do movimento utilizando um banco de filtros de Kalman. Para atingir tal objetivo geral, são definidos os seguintes objetivos específicos:

1. Obter modelos matemáticos que caracterizam a dinâmica dos regimes do sinal de EEG espontâneo EEG_{ESP} e o PRE.
2. Aplicar diferentes métricas para quantificar a qualidade dos modelos matemáticos da promediação do sinal de EEG espontâneo e o PRE.
3. Incorporação desses modelos em bancos de filtros de Kalman para se detectar quais dos dois regimes dinâmicos estão presentes nos registros da promediação do sinal de EEG.
4. Analisar na etapa de modelagem e estimativa, o efeito do número de repetições da tarefa mental na detecção do PRE relacionado à imaginação do movimento.

1.4 Organização do Trabalho

A estrutura desta dissertação de mestrado compreende cinco capítulos, organizados como a seguir. O Capítulo 1 apresenta a introdução ao tema abordado, descrevendo brevemente a motivação e justificativa deste estudo e abrangendo a formulação do problema e os objetivos que levaram ao desenvolvimento deste.

No Capítulo 2, aborda-se uma breve revisão bibliográfica sobre as bases fisiológicas e as técnicas de análise de sinais de EEG utilizadas na detecção do potencial relacionado à imaginação do movimento. Além disso, é feita uma descrição do procedimento de aquisição do sinal EEG.

No Capítulo 3, descrevem-se os materiais e métodos que são utilizados. Inicialmente, é apresentada uma descrição do protocolo experimental. Em seguida, são apresentadas as técnicas de identificação utilizadas para obter modelos matemáticos

que representam a atividade espontânea e o potencial relacionado ao movimento voluntário e à imaginação do movimento. Posteriormente, são apresentados métodos de estimação de estados baseados em bancos de filtros de Kalman.

No Capítulo 4, são apresentados os resultados dos modelos obtidos durante a EEG_{TV} , EEG_{TVM} e EEG_{IM} e o BIFK utilizados para detectar o potencial relacionado à imaginação do movimento do dedo indicador da mão esquerda. Além disso, é apresentada a análise do efeito do número de repetições da tarefa mental na detecção do PRE.

Finalmente, no Capítulo 5, têm-se as conclusões finais e as propostas de trabalhos futuros.

Uma Breve Revisão sobre o Processamento do Sinal de EEG

“A imaginação é mais importante que a ciência, porque a ciência é limitada, ao passo que a imaginação abrange o mundo inteiro.”

Albert Einstein

Neste capítulo, são apresentadas as bases fisiológicas e técnicas alternativas de detecção de EEG relacionados com o movimento voluntário e imaginação do movimento. Inicialmente aborda-se conceitos relativos à anatomia e fisiologia do cérebro humano. Em seguida, é realizada uma breve descrição do processo de aquisição de sinais da atividade elétrica cerebral por meio do EEG. Posteriormente, apresentam-se diferentes técnicas de análise de EEG relacionados com o movimento voluntário e imaginação do movimento utilizadas para a identificação de padrões característicos de ativação cortical. Finalmente, é apresentada a análise do efeito do número de repetições da tarefa mental na detecção do PRE.

2.1 Anatomia e Fisiologia do Cérebro Humano

O sistema nervoso (SN) é o responsável por gerenciar as funções de integração do homem com o ambiente [Berne, 1998]. O SN apresenta duas divisões: o sistema nervoso central (SNC) e o sistema nervoso periférico (SNP). Nesta seção, discute-se brevemente sobre o funcionamento do cérebro com base na informação que chega do sistema nervoso responsável pela percepção dos estímulos, comandos e respostas [Dangelo, 2002].

2.1.1 O cérebro

O cérebro é dividido em dois hemisférios (esquerdo e direito). Segundo [Kandel, E. R., Shuwarts, J. H., Jessel, T. M., 2000] o mapeamento da estrutura cerebral mostra que um hemisfério coordena o lado oposto do corpo, ou seja, o hemisfério direito controla o lado corporal esquerdo enquanto que o hemisfério esquerdo controla o lado direito do corpo.

2.1.2 O córtex cerebral

Os hemisférios cerebrais apresentam uma camada superficial de substância cinzenta chamada *córtex cerebral* [Guyton, 2006]. O córtex cerebral pode ser dividido em quatro lobos: frontal, parietal, temporal e occipital, [Bear, M. F., Connors, B. W., Maradiso, M. A., 2002], como mostrado na Figura 2.1.

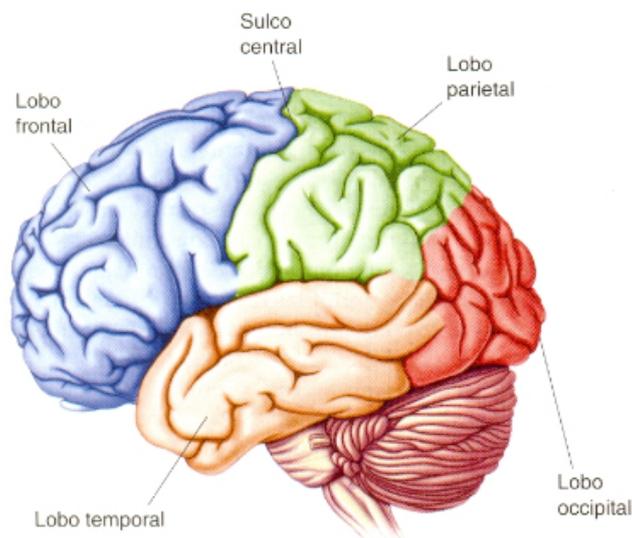


Figura 2.1: Lobos do córtex cerebral. Modificado de [Kandel, E. R., Shuwarts, J. H., Jessel, T. M., 2000].

Em termos gerais, o *lobo temporal* está relacionado com a memória, audição e fala; o *lobo frontal* é responsável pelo planejamento consciente, controle motor e controle sensorial somático; o *lobo parietal* está relacionado com os sentidos corporais e espaciais e o *lobo occipital* é responsável pela interpretação do sentido da visão [Kandel, E. R., Shuwarts, J. H., Jessel, T. M., 2000; Guyton, 2006].

2.1.3 Fisiologia do Movimento Voluntário (MV) e Imaginação do Movimento (IM)

Trabalhos desenvolvidos por Fritsch e Hitzigs, estimulando eletricamente áreas específicas do córtex de cachorros, mostraram que existe correspondência entre determinadas áreas corticais e movimentos de partes do corpo [Machado, 2007; Bear, M. F., Connors, B. W., Maradiso, M. A., 2002]. Na Figura 2.2, pode-se identificar importantes áreas corticais. Por exemplo, o movimento voluntário envolve as etapas de planejamento, execução e controle. Tal ação ativa várias áreas corticais.

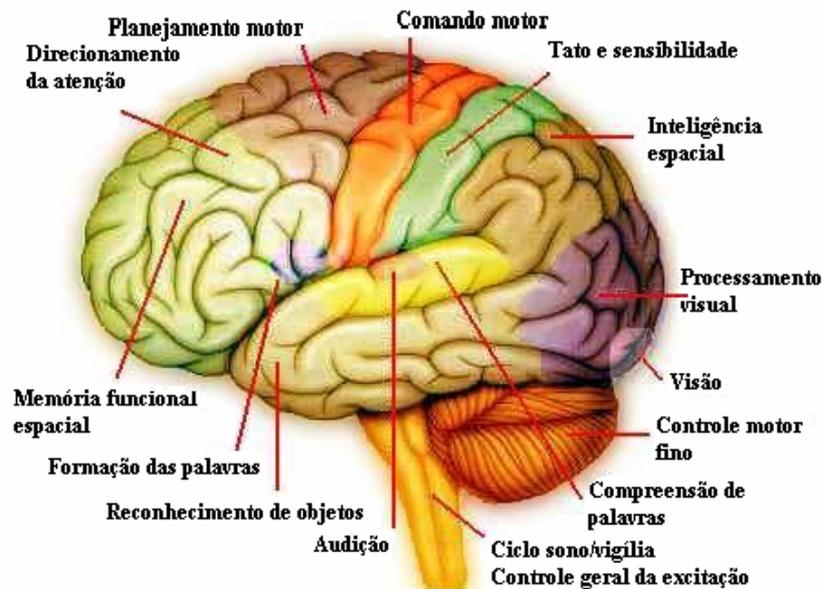


Figura 2.2: Subdivisões funcionais corticais, cerebelo e tronco encefálico. Modificado de [Vilela, A. L. M., 2005].

O córtex motor é a área cerebral destinada à execução motora, envolvendo áreas específicas dos lobos frontal e parietal [Vander, A., Sherman, J., Luciano, D., 2001]. A região de comando motor ou *área motora voluntária* está dividida em três áreas interligadas: córtex motor primário; córtex pré-motor e córtex motor suplementar. A Figura 2.3 mostra a área 4 (córtex motor primário) e a área 6 (córtex pré-motor e motor suplementar) correspondentes ao mapa citoarquitetônico de Brodmann.

O funcionamento do SNC para a execução de movimentos voluntários envolve três processos: a identificação do movimento a ser executado, o planejamento da ação e o

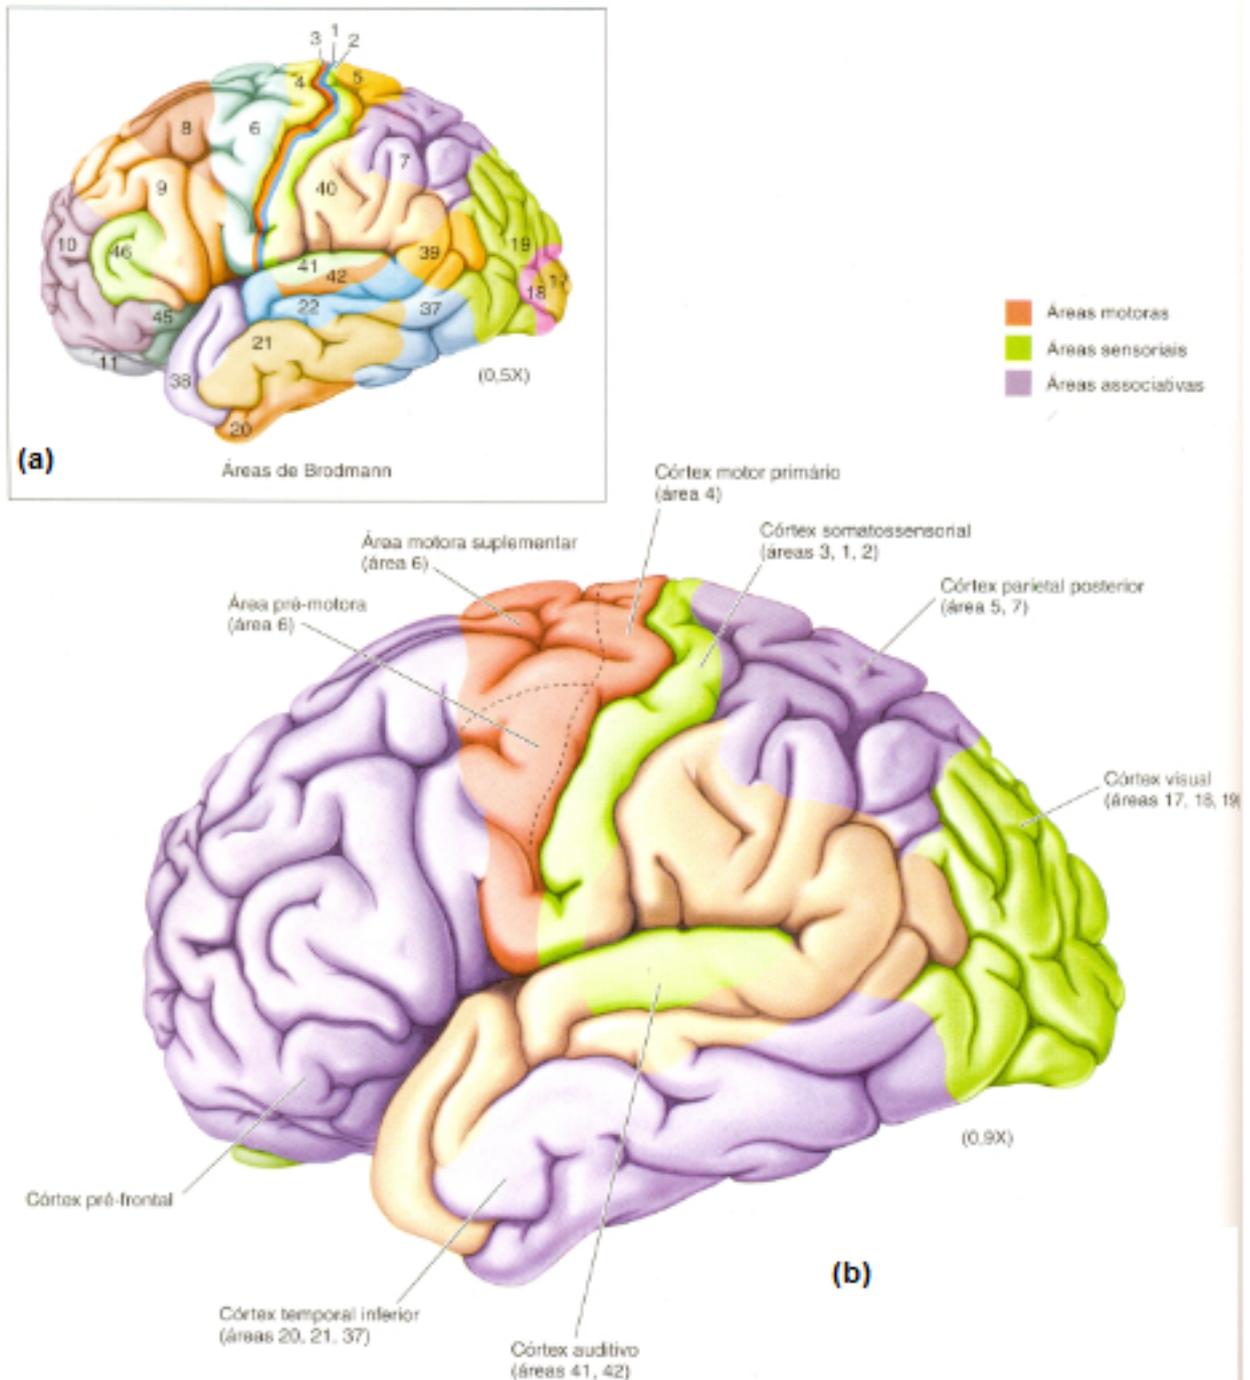


Figura 2.3: (a) Áreas de Brodmann, (b) Representação do córtex motor (áreas 6 e 4) e córtex sensorial (áreas 3, 2, 1, 5 e 7) nas divisões de Brodmann. Modificado de [Kandel, E. R., Shuwarts, J. H., Jessel, T. M., 2000]

movimento [Kandel, E. R., Shuwarts, J. H., Jessel, T. M., 2000].

A identificação do movimento inicia-se com a integração sensorial no córtex parietal posterior, mostrado na Figura 2.4, que compreende as áreas 5 e 7 do mapa de *Broadmann*. Desta forma, a área 5 recebe informação do córtex somato-sensorial, do sistema vestibular, de áreas pré-motoras e do córtex cingulado límbico. Ao passo que, a área 7 recebe informações da recepção e processamento visual. As informações sensoriais das área 5 e 7 são integradas à área 22 (auditiva) [Kandel, E. R., Shuwarts, J. H., Jessel, T. M., 2000].

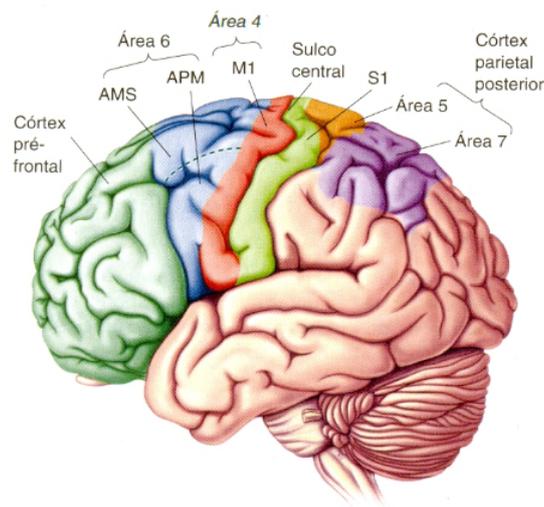


Figura 2.4: Áreas do neocórtex envolvidas com o planejamento e a instrução dos movimentos voluntários. Modificado de [Kandel, E. R., Shuwarts, J. H., Jessel, T. M., 2000].

O planejamento motor tem início na área pré-motora (APM) mostrada na Figura 2.4. A APM está relacionada com o controle motor dos músculos, por meio da informação recebida do córtex parietal posterior (áreas 5 e 7) definem os grupos musculares e músculos específicos que devem ser ativados para a realização da tarefa [Berne, 1998].

A área motora suplementar (AMS) comanda a iniciação de movimento de músculos. Essa área é responsável pela sequência dos movimentos voluntários que serão realizados pelo indivíduo por meio do tronco cerebral e cordão espinhal. A APM e AMS parecem desempenhar funções similares, mas em grupos diferentes de músculos [Bear, M. F., Connors, B. W., Maradiso, M. A., 2002]. O movimento ocorre com a trans-

missão da informação das APM e AMS que são enviadas para as áreas do córtex motor primário (M1).

A estimulação elétrica em regiões específicas do M1 geraram um mapeamento das áreas musculares sobre uma determinada seção do cérebro. A Figura 2.5 mostra o homúnculo motor, percebe-se a grande área cerebral que representa a mão comparado com o resto dos membros do corpo. Por esse motivo, vários estudos justificam o uso da mão na imaginação de movimento [Vander, A., Sherman, J., Luciano, D., 2001; Kandel, E. R., Shuwarts, J. H., Jessel, T. M., 2000; Guyton, 2006].

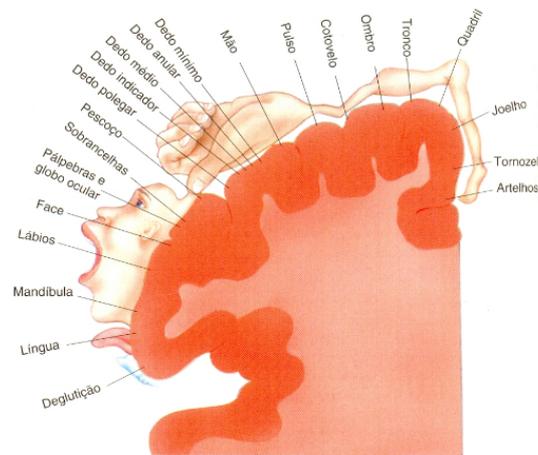


Figura 2.5: Homúnculo em corte mostrando a área motora. Adaptado de [Kandel, E. R., Shuwarts, J. H., Jessel, T. M., 2000].

2.2 Os Sinais de EEG

Os sinais cerebrais são geralmente captados por meio do eletroencefalograma (EEG). Essa técnica registra a atividade elétrica utilizando eletrodos devidamente posicionados no couro cabeludo, o que caracteriza uma captação não invasiva. O sinal de EEG é normalmente exibido na forma de um conjunto de traços irregulares simultâneos que indicam alterações nos potenciais elétricos captados no escalpo (couro cabeludo).

O EEG tem demonstrado ser uma ferramenta bastante útil no estudo do estado funcional e para o diagnóstico de danos e distúrbios do cérebro, sendo utilizado em particular por ser um exame simples e de elevada resolução temporal.

2.2.1 Protocolo de Aquisição do Sinal de EEG

A aquisição dos sinais de EEG é realizada por meio de equipamentos compactos, com maior sensibilidade e qualidade de canais de registro (derivações), conhecidos como eletroencefalógrafos. Para mensuração dessa atividade elétrica são utilizados eletrodos em forma de disco, normalmente de prata/cloreto de prata (Ag/AgCl) ou ouro de 10mm de diâmetro, devidamente posicionados no couro cabeludo, o que caracteriza uma captação não-invasiva.

Utiliza-se uma substância que serve como superfície fixadora entre o eletrodo e a pele do paciente, de modo que o eletrodo permaneça onde foi colocado. Essa substância aumenta a aderência permitindo ao eletrodo captar o sinal cerebral e evitando sinais indesejáveis associadas à movimentação do eletrodo. Com relação ao ambiente de registro do sinal de EEG deve ser um lugar confortável, calmo, silencioso, sem luzes intensas e sem interferência eletromagnética.

A Figura 2.6 mostra a disposição dos eletrodos seguindo o sistema internacional 10-20 [Jasper, 1974]. Neste sistema são utilizadas as letras para identificar as regiões do córtex, por exemplo, F para a região frontal, C para a região central, P para a região parietal, T para a região temporal e O para a região occipital. Já para o caso dos números, eles relacionam o lado da cabeça, por exemplo, números ímpares associam o lado esquerdo da cabeça e os pares o lado direito.

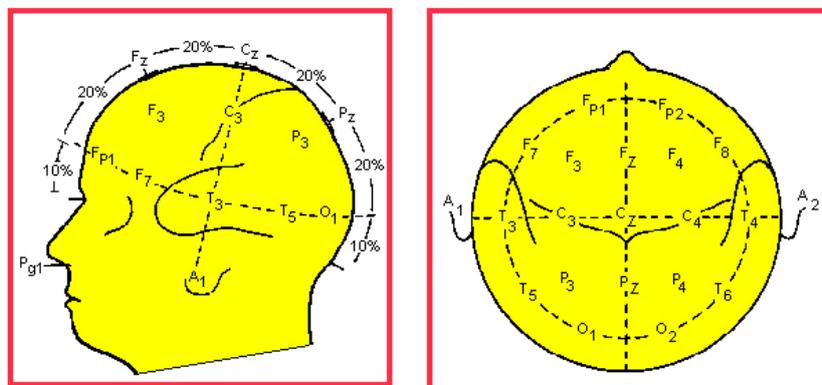


Figura 2.6: Diagrama do Sistema Internacional 10-20 de posicionamento dos eletrodos para EEG. Modificado de [Webster, J. G., 2006].

2.2.2 Potencial Espontâneo

A atividade elétrica registrada no escalpo por meio do EEG sem a existência de estímulo foi denominada como atividade espontânea. Esse sinal apresenta amplitude variável em torno de 10 a 150 μV e com conteúdo espectral entre 0,5 a 30 Hz [Kandel, E. R., Shuwarts, J. H., Jessel, T. M., 2000]. A Figura 2.7 mostra o EEG espontâneo.

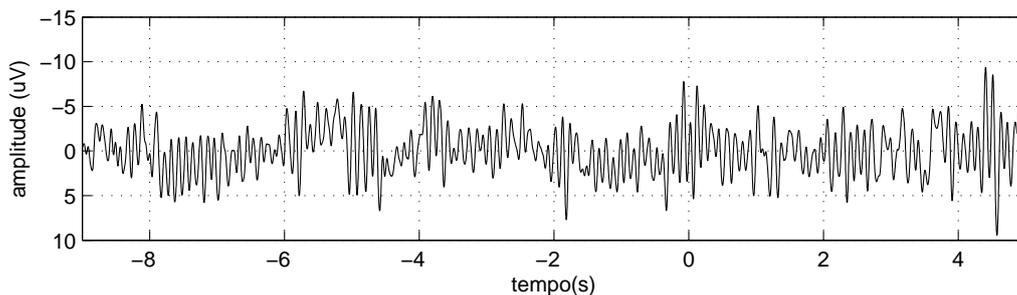


Figura 2.7: Potencial de EEG espontâneo.

2.2.3 Potenciais Relacionados ao Evento (PRE)

O potencial relacionado ao evento (PRE) pode ser considerado uma série de respostas transientes pós-sinápticas, principalmente de neurônios piramidais, provocadas por um estímulo específico [Pfustcheller G, Lopes da Silva, F. H., 1999]. Desta forma, o estímulo pode provocar dois tipos de alterações na atividade elétrica gerada no córtex; uma sincronizada em fase e no tempo com o evento, denominada de PRE, e outra denominada atividade induzida, que não está sincronizada em fase, mas pode estar sincronizada ou não no tempo.

Componentes prévias ao evento

Neste trabalho é analisada a componente do PRE motor provocado por uma tarefa motora. Especificamente, a componente prévia ao evento, denominada contingente de variação negativa (CNV) [Coles, M.G.H., Rugg, M.D, 1996], descrita a seguir.

O contingente de variação negativa (CNV)

A componente CNV ocorre durante o intervalo entre dois estímulos sensoriais, como o paradigma E1 - E2 (Estímulo 1 - Estímulo 2). O CNV tem sido considerado com uma componente que precede uma resposta motora, sendo caracterizada como uma onda negativa lenta que atinge a máxima negatividade próxima ao segundo estímulo, como mostrado na Figura 2.8.

Estudos desenvolvidos por [Jervis, B., Allen, E., Johnson, T., Nichols, M., Hudson, N., 1984] sugerem que o CNV é composto por duas componentes, a *onda O* e a *onda E* como pode ser mostrado na Figura 2.8. A *onda O* é caracterizada por uma negatividade após o estímulo sensorial E1, enquanto que a *onda E*, é caracterizada pela negatividade prévia ao segundo estímulo E2 e resposta à tarefa. O CNV apresenta uma amplitude de aproximadamente 20 μV .

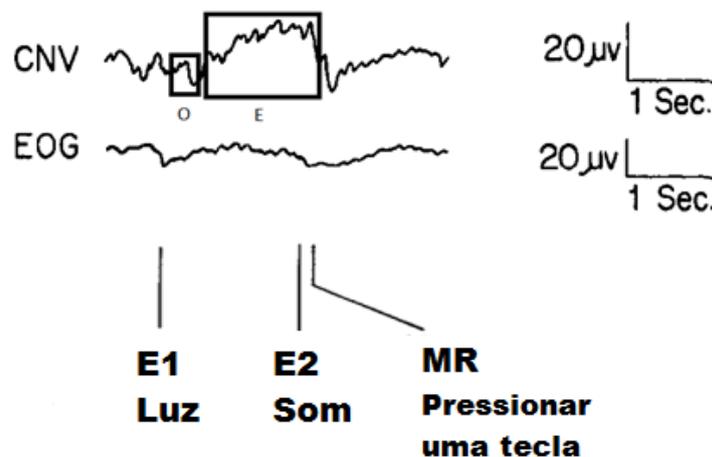


Figura 2.8: O contingente de variação negativa (CNV) composto pelas ondas O e E entre os estímulos E1(luz) e E2(som), que orientam a execução de uma tarefa motora(MR). Adaptado de [Tecce, J.J., 1974].

[Ikeda, A., Luders, H., Collura, T.F., Burgess, R.C., Morris, H.H., Hamano, T., Shibasaki, H., 1996] sugere que a componente CNV está relacionada com a preparação cognitiva de tarefas motoras, gerando uma negatividade máxima sobre o córtex pré-frontal e provocando um aumento de negatividade na AMS e M1, principalmente contralateralmente ao membro que realiza o movimento.

2.3 Técnicas de Processamento de Sinais de EEG para a Detecção do PRE

Várias técnicas de processamento de sinais têm sido utilizadas para detectar e estimar o PRE no domínio do tempo e da frequência. Entretanto, essas técnicas precisam que o PRE possua uma alta RSR com o intuito de diminuir o tempo de identificação dos PREs. Assim, é necessário aplicar uma técnica para a redução de ruído.

A média coerente de trechos sincronizados com evento tem sido utilizada na literatura para estimar o PRE [Tierra-Criollo, 2001; Braga E., Braga N., 2006]. O grande problema dessa técnica é a relação direta da RSR com o número de repetições do evento (trechos), resultando em um elevado tempo de processamento e o grande número de trechos contendo os PREs utilizados para obter uma alta RSR.

Uma breve descrição da técnica da média coerente de trechos sincronizados com o evento é apresentada a seguir.

2.3.1 Média Coerente de Trechos Sincronizados com o Evento

A média coerente tem sido utilizada como uma técnica padrão para a detecção de resposta evocada a partir de vários trechos de sinais de EEG, x_k , sincronizados com o início do estímulo [Tierra-Criollo, 2001; Braga E., Braga N., 2006].

Considere que o sinal de EEG x_k é composto por dois sinais, como

$$x_k = s_k + e_k \quad (2.1)$$

em que s_k é o sinal determinístico (PRE) e e_k é o ruído aleatório de média zero.

Calcula-se a esperança matemática do sinal x_k da equação (2.1). Assumindo que a esperança matemática do ruído é zero, a esperança do sinal é a própria resposta evocada

$$E[x_k] = E[s_k + e_k] = E[s_k] + E[e_k] \quad (2.2)$$

Assim, o PRE pode ser estimado através da média de N trechos do sinal:

$$\hat{s}_k = \frac{1}{N} \sum_{i=1}^N x_{ik} \quad (2.3)$$

$$E[\hat{s}_k] = \frac{1}{N} N s_k = s_k \quad (2.4)$$

Note que a variância da média coerente será função da variância do ruído. Assim, a RSR na promediação aumenta em um fator de N .

$$\text{var}[\hat{s}_k] = \text{var}\left[\frac{1}{N} \sum_{i=1}^N x_{ik}\right] = \frac{1}{N^2} \sum_{i=1}^N \text{var}[x_{ik}] = \frac{1}{N} \text{var}[ru_k] \quad (2.5)$$

2.4 Número de Repetições da Tarefa Mental

Nesta seção, é definido o efeito do número de repetições da tarefa mental na detecção do PRE. Neste trabalho, a análise inicial considera a promediação de 30 repetições das tarefas mentais. Estudos recentes [Santos Filho, 2010; Souza, 2010] demonstram a possibilidade de detecção do sinal de PRE por meio da promediação de 30 repetições da tarefa viso-motora e imaginação do movimento.

Do ponto de vista prático, o menor número de repetições da tarefa tornaria a ICM mais rápida na ativação do dispositivo externo, como próteses e órteses. Por exemplo, um indivíduo deve repetir 10 vezes a imaginação do movimento para acionar uma prótese.

Dessa forma, com a finalidade de detectar o sinal de PRE utilizando menos repetições da tarefa viso-motora e imaginação do movimento, o presente estudo propõe obter modelos matemáticos a partir da promediação dos trechos do sinal de EEG com $M=15$, $M=10$ e $M=5$ durante as tarefas mentais.

Materiais e Métodos

“É incrível que a matemática, tendo sido criada pela mente humana, consiga descrever a natureza com tanta precisão.”

Albert Einstein

Este capítulo descreve os materiais e métodos empregados no presente trabalho. Inicialmente, na Seção 3.1, é descrito o procedimento de aquisição dos sinais de EEG durante as diferentes tarefas mentais, bem como a etapa de pré-processamento dos sinais de EEG. Na Seção 3.2 apresenta-se um procedimento para decimar o sinal de EEG. Em seguida, na Seção 3.3, são apresentados os procedimentos para obtenção dos modelos dos sistemas a partir dos registros do sinal de EEG. Posteriormente, discute-se como esses modelos são usados em filtros de Kalman para identificar o potencial relacionado à imaginação do movimento. Finalmente, a Seção 3.4 apresenta conceitos relativos à abordagem que emprega um banco de filtros de Kalman em paralelo, para detectar o PRE a partir das estimativas recursivas dos sinais de EEG durante as tarefas mentais.

3.1 Descrição do Protocolo Experimental

No presente trabalho foram utilizados os sinais de EEG coletados nos trabalhos desenvolvidos por [Erazo-Costa, 2012; Santos Filho, 2010]. A Figura 3.1 mostra as etapas de pré-processamento do sinal de EEG. Inicialmente, os sinais cerebrais são obtidos por meio do EEG. Posteriormente, os registros dos sinais de EEG passam por uma etapa de pré-processamento. Nessa etapa, os sinais são filtrados por um filtro

digital e, em seguida, os sinais de EEG são divididos em trechos de 14s. Finalmente, são utilizados algoritmos para a remoção de artefatos do sinal de EEG. Esta etapa foi desenvolvida pelo aluno de mestrado Fabricio Erazo-Costa [Erazo-Costa, 2012].

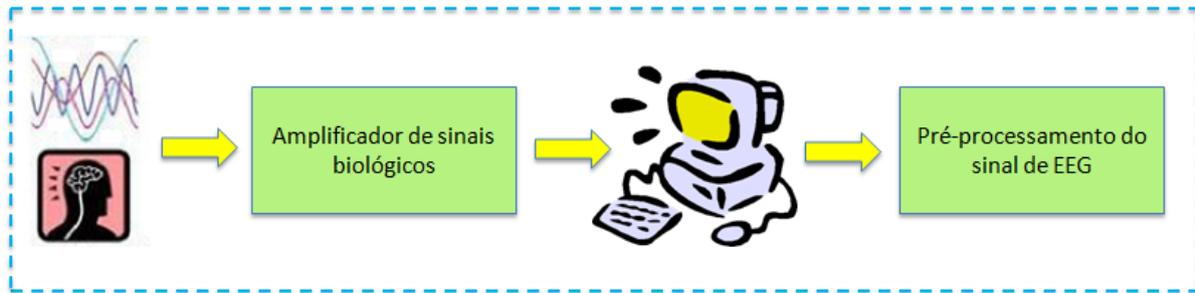


Figura 3.1: Etapas do pré-processamento do sinal de EEG: aquisição do sinal de EEG por meio do amplificador de sinais biológicos e o pré-processamento desses sinais.

Neste trabalho são utilizados os sinais de EEG de sete indivíduos saudáveis (seis homens e uma mulher) que não fazem uso de qualquer medicamento que pudesse interferir nos registros dos sinais. Durante a coleta do EEG, os indivíduos permanecem sentados confortavelmente em uma poltrona e isolados em uma cabine acústica, onde a iluminação é ajustada para não interferir nos sinais. A seguir apresenta-se uma breve descrição do protocolo experimental.

Os sinais de EEG foram coletados no laboratório "Núcleo de Estudos e Pesquisas em Engenharia Biomédica"(NEPEB) da UFMG de acordo com protocolo aprovado pelo Comitê de Ética Local. A coleta é realizada com o amplificador de sinais biológicos BrainNet BNT - 36, mostrado na Figura 3.2, com filtro passa-alta com frequência de corte de 0,1Hz, filtro passa-baixa com frequência de corte de 100Hz, filtro notch de 60Hz e frequência de amostragem de 600Hz.

O registro de sinais de EEG é obtido utilizando-se 19 eletrodos de prata (Ag/AgCl) com diâmetro de 10mm, dispostos no escalpo de acordo com o sistema internacional 10-20, com referência aos eletrodos auriculares (A1 e A2). Para registro do movimento do dedo simultaneamente ao EEG é utilizado um acelerômetro do tipo MEMS (do inglês, *micro electronics mechanical system*), marca ADXL 213, com faixa de medição típica de $\pm 1.2g$, afixado no dedo indicador da mão esquerda, conforme ilustrado na Figura 3.3.a.

Durante o registro do EEG, como mostrado na Figura 3.3.b são utilizados dois

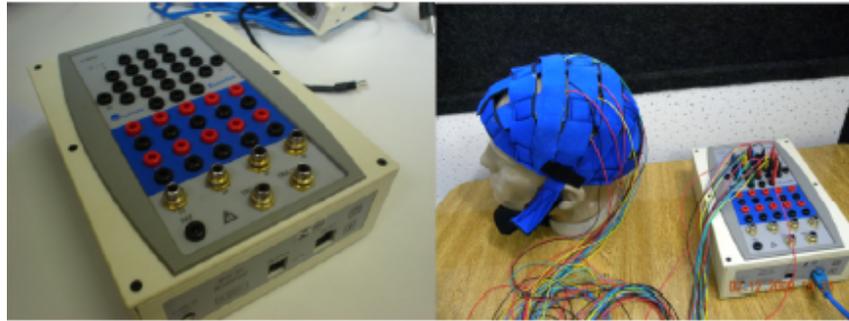
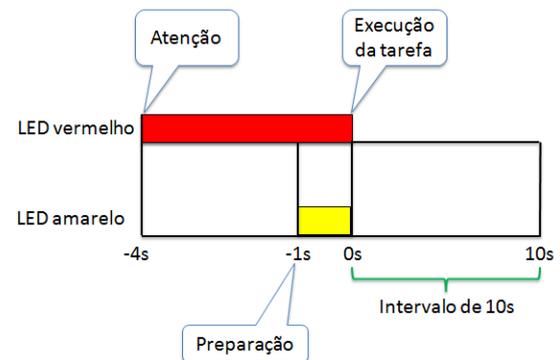


Figura 3.2: Amplificador de sinais biológicos BrainNet BNT - 36 da Lynux Tecnologia Eletronica Ltda. Adaptado de [Santos Filho, 2010].

LEDs como comandos para realizar as tarefas: visual EEG_{TV} , viso-motora EEG_{TVM} e imaginação do movimento EEG_{IM} . Na primeira tarefa, o indivíduo não realiza a tarefa motora nem a imaginação do movimento. Na segunda tarefa, o indivíduo é orientado a executar o movimento, ao passo que na terceira tarefa o indivíduo é orientado apenas a imaginar o movimento. Ambos os LEDs são fixados em um painel retangular preto (30x20 cm) situado no ângulo de visão do indivíduo, a 80 cm de seus olhos.



(a)



(b)

Figura 3.3: a) Acelerômetro utilizado para registrar o movimento do dedo indicador da mão esquerda. Adaptado de [Santos Filho, 2010]. b) Protocolo experimental. O LED vermelho indica atenção e o LED amarelo indica a preparação para o movimento ou imaginação de movimento. O indivíduo é instruído a executar uma das tarefas após o desligamento dos LEDs.

O comando para a realização da tarefa é feito da seguinte forma: quatro segundos antes da tarefa ($t = -4s$), o LED vermelho é aceso para que o indivíduo focasse sua

atenção no procedimento, três segundos depois ($t = -1s$) o LED amarelo é acionado para que o indivíduo se preparasse para a tarefa. Um segundo após o LED amarelo estar aceso, os dois LEDs são desligados orientando o indivíduo a realizar a tarefa ($t = 0$). Assim, a realização da tarefa tem duração de 14s, reiniciando-se o processo após 10s de repouso.

Cada experimento é composto por três registros do sinal de EEG durante as tarefas mentais, conforme mostrado na Figura 3.4. Assim, cada registro do sinal de EEG é realizado de forma aleatória com uma duração de: dez minutos para EEG_{TV} e vinte minutos para EEG_{TVM} e EEG_{IM} .

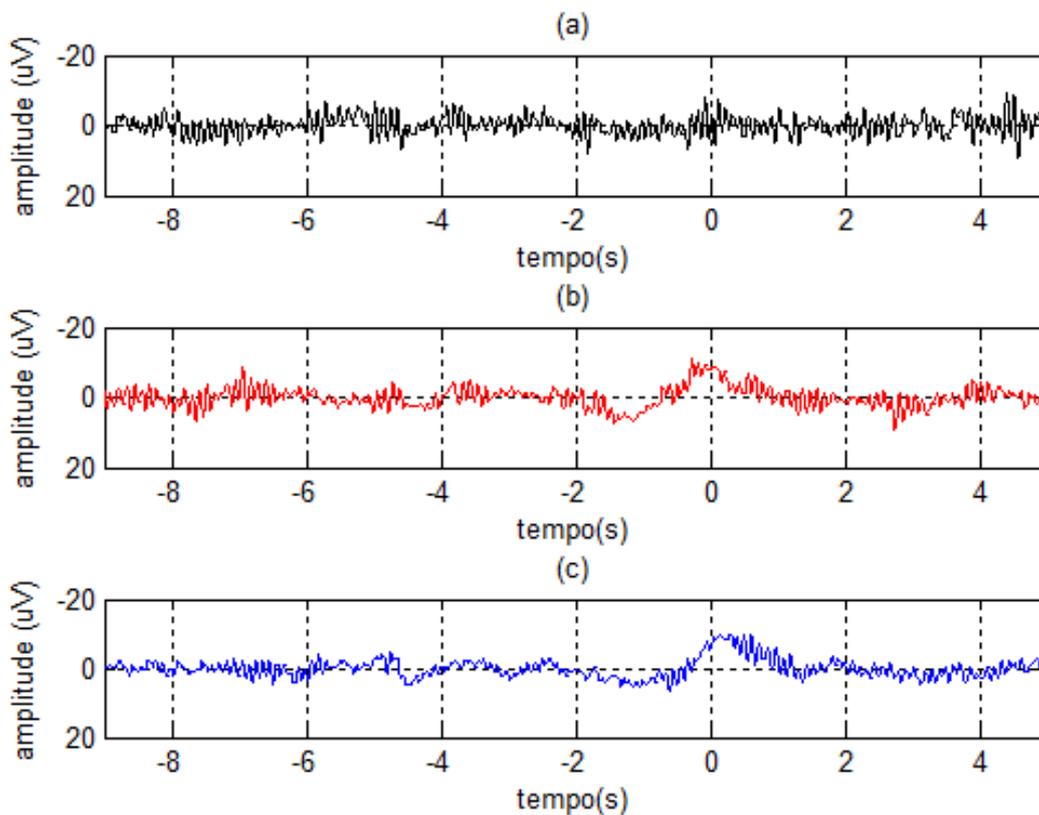


Figura 3.4: Promediação dos trechos dos sinais de EEG durante as tarefas: (a) EEG_{TV} , (b) EEG_{TVM} e (c) EEG_{IM} na derivação C_z do indivíduo #2.

3.1.1 Pré-Processamento do Sinal de EEG

A etapa de pré-processamento é realizada *offline* utilizando o software Matlab. Os sinais de EEG são filtrados de 0,1 a 15 Hz com um filtro passa-banda Butterworth de ordem 2, o que pode garantir a estacionaridade do sinal de EEG [Cohen, B. A., Sances, A. J., 1977]. A Figura 3.5a mostra o sinal de EEG após a filtragem digital.

Em seguida, o sinal de EEG é dividido em trechos de 14s, sincronizados com os eventos por meio de um sinal de sincronismo enviado quando os dois LEDs são desligados ($t=0s$). Posteriormente, são utilizados dois algoritmos para a remoção de artefatos do sinal de EEG. Um método usual para remoção de artefatos é a rejeição de segmentos do sinal a partir de inspeção visual [Anghinanh R., Basile L., Schimdt M. T., Sameshina K., 2006], ou ainda a partir da escolha de um limiar de rejeição [Li R., 2006].

O método do desvio padrão [Tierra-Criollo, 2001] utiliza um segmento referência do sinal de EEG, considerado livre de artefatos e selecionado para estimar um limiar de rejeição com base no desvio padrão (σ) de referência. O limiar é definido por três vezes o desvio padrão (3σ). Desta forma, os trechos que apresentaram 5% de amostras consecutivas ou 10% de suas amostras com valor superior ao limiar calculado são rejeitados, conforme mostrado na Figura 3.5b.

A média coerente é utilizada como uma técnica padrão para a detecção de PREs a partir da promediação (média) de vários trechos de sinais de EEG sincronizados com o início do estímulo [Tierra-Criollo, 2001], como mostrado na Figura 3.5c. Além disso, é selecionado um segmento de 3s do sinal de EEG que se inicia $t = 0,7s$ antes da tarefa e termina $t = 2,3s$ após a execução da tarefa mental devido à presença das componentes pré-evento, como contingente de variação negativa (CNV).

3.2 Decimação do sinal de EEG

Antes de obter os modelos matemáticos dos sistemas, é necessário verificar se o sinal previamente amostrado foi registrado com um período de amostragem adequado. Para verificar se o sinal encontra-se sobreamostrado, é empregado o procedimento descrito em [Aguirre, 2004]. Esse procedimento utiliza as funções de autocorrelação linear, $r_{y'y'}$

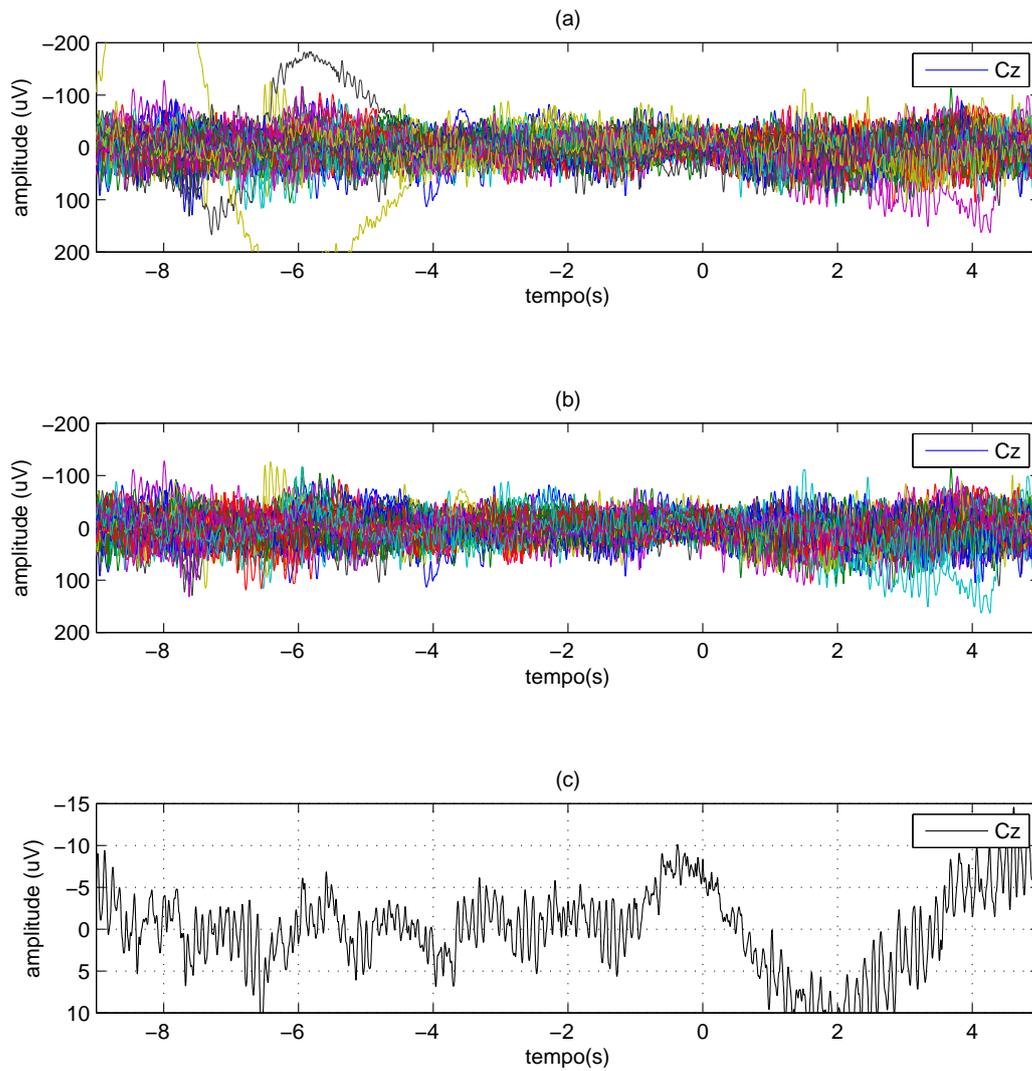


Figura 3.5: Registro de todos os trechos do sinal de EEG: (a) com artefatos, (b) sem artefatos e (c) promediação de $M=30$ trechos do sinal de EEG durante a tarefa imagética-motora na derivação C_z do indivíduo #2.

e não linear, $r_{y' y'}$ da saída do sistema:

$$r_{y' y'}(\tau) = E \left[(y_k - \bar{y}_k)(y_{k-\tau} - \bar{y}_k) \right], \quad (3.1)$$

$$r_{y^2 y^2}(\tau) = E \left[(y_k^2 - \bar{y}_k^2)(y_{k-\tau}^2 - \bar{y}_k^2) \right] \quad (3.2)$$

em que \bar{y}_k e \bar{y}_k^2 representam os valores médios, o apóstrofe (') é a média dos sinais, $E[\bullet]$ é a esperança matemática. A taxa de decimação é escolhida em função dos primeiros mínimos de (3.1) e (3.2) do sinal superamostrado, y_k^* , definida por

$$\tau_m = \min \{ \tau_{y'}, \tau_{y^2} \}, \quad (3.3)$$

em que τ_m é medido em número de atrasos com relação ao menor dos mínimos entre \bar{y}_k e \bar{y}_k^2 . Finalmente, é escolhido o fator de decimação, Δ , de forma que o sinal decimado $y_k = y_{\Delta k}^*$ deve satisfazer a seguinte relação

$$10 \leq \tau_m \leq 20 \quad (3.4)$$

Portanto, se o sinal amostrado não atinge os limites estabelecidos pela equação 3.4, é necessário decimar o sinal amostrado.

3.3 Modelagem Matemática

Modelos matemáticos podem ser obtidos pela física do processo (modelagem caixa branca) ou por meio de dados (modelagem caixa preta). Neste trabalho, consideram-se os procedimentos de modelagem caixa preta devido à intrínseca dificuldade de se modelar séries temporais biomédicas.

As principais etapas de um processo de identificação baseado na modelagem caixa preta são [Aguirre, 2004]:

1. Realização de experimento com o sistema que se deseja modelar,
2. Escolha da representação matemática do modelo e seleção da estrutura do mesmo,

3. Estimativa dos parâmetros do modelo,
4. Validação do modelo obtido.

Uma vez realizada a etapa de decimação dos sinais de EEG durante as tarefas visual, viso-motora e imaginação do movimento, a modelagem se propõe a obter modelos a partir desses dados. Nas próximas subseções, cada etapa do problema de modelagem matemática é discutida.

3.3.1 Seleção de Estrutura

A escolha da representação matemática que é utilizada no processo de modelagem do sistema é, em geral, baseada em aspectos subjetivos. Ou seja, definir uma representação a ser empregada em um determinado problema não é um procedimento claro e objetivo.

Em estudos desenvolvidos por [Von Spreckelsen, M., Bromm, B., 1988], séries temporais de EEG são modelados utilizando estruturas lineares. Tal escolha é geralmente feita por simplicidade. Assim, este trabalho também utiliza estruturas lineares.

Considere que o sinal registrado durante a EEG_{IM} apresenta duas componentes: EEG_{ESP} e o PRE, como mostrado na Figura 3.6b; enquanto que o EEG_{TV} tem apenas a parcela do sinal de EEG_{ESP} , veja Figura 3.6a.

A escolha da estrutura a ser utilizada para representar os regimes dinâmicos descritos pelos dados é de grande importância. Diversas representações de modelos lineares são utilizadas para obter modelos de sistemas a partir de séries temporais, por exemplo, modelos polinomiais AR, ARX, ARMA e ARMAX [Georgiadis, S. D., Ranta-aho, P. O., Tarvainen, M. P., Karjalainen, P. A., 2005; Mohseni, H. R., Wilding, E. L., Sanei, S., 2007; Lange, H., Pratt, H., Inbar, G. F., 1995; Britton et al., 2000; Lange, D. H., Pratt, H., Inbar, G. F., 1997], dentre outras. Dentre essas representações, o modelo AR tem sido propostos para obter modelo matemáticos a partir da informação *a priori* de sistemas fisiológicos [Timmer, J., 1998]. A seguir, é discutida a seleção da estrutura para os sistemas do EEG_{ESP} e PRE.

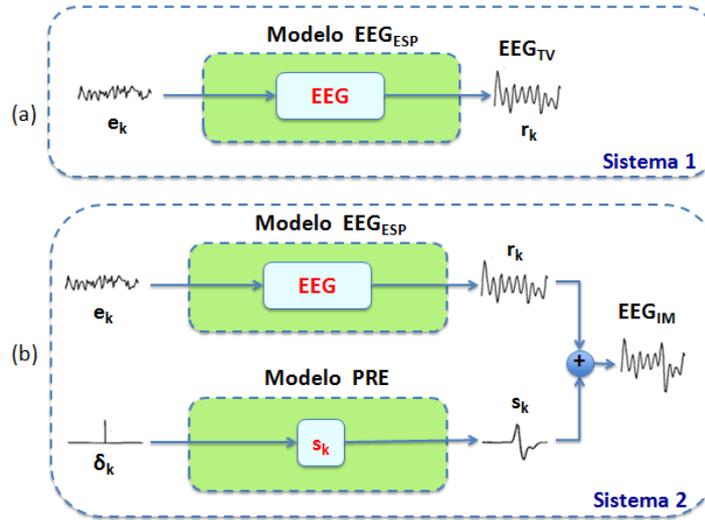


Figura 3.6: Diagrama da promediação do sinal de EEG: (a) com tarefa visual (Sistema 1) e (b) com tarefa imagética-motora (Sistema 2).

Potencial Espontâneo (EEG_{ESP})

O sinal de EEG_{ESP} é um registro das atividades elétricas do cérebro. As características do sinal são relacionadas com as condições do cérebro. Dessa forma, a detecção de mudanças no EEG é uma ferramenta útil para o monitoramento cerebral na análise neurofisiológica, sendo muito importante na avaliação clínica dos indivíduos.

Existem duas abordagens básicas que analisam os sinais de EEG: a abordagem paramétrica e a não-paramétrica. O método não-paramétrico geralmente usado é a análise espectral enquanto que, para os métodos paramétricos, são mais frequentemente usados modelos AR [Jansen, 1981; Aufrichtigl and Pedersenl, 1992; Steinberg, H., Gasser, T. H., Franke, J., 1985; Arnold et al., 1998].

Em [Kong, 1997], o sinal EEG é formado por uma combinação linear das amostras passadas de EEG, somada com um componente independente, denominado ruído branco, mostrado na Figura 3.6a. Com a finalidade de representar o sinal de EEG_{ESP} , é empregado o modelo AR descrito por

$$r_k = a_1 r_{k-1} + \dots + a_p r_{k-p} + e_k, \quad (3.5)$$

em que r_k é o EEG_{ESP} , p a ordem do modelo, $a^T = [a_1 \dots a_p]$ é o vetor de parâmetros,

$\psi_{k-1}^T = [r_{k-1} \dots r_{k-p}]$ é o vetor de regressores e e_k é o erro de modelagem.

Potencial Relacionado ao Evento (PRE)

O estímulo que provoca o PRE pode ser considerado de curta duração. Assim, esse estímulo pode ser representado por um impulso δ_k e o PRE representa a resposta ao impulso do sistema sensorial ou cognitivo, tal como proposto em [Von Spreckelsen, M., Bromm, B., 1988] e pode ser mostrado na Figura 3.6b.

O PRE representado por meio de um modelo ARX é dado por

$$s_k = c_1 s_{k-1} + \dots + c_m s_{k-m} + u_{k-1} + \dots + u_{k-n} + g_k, \quad (3.6)$$

em que s_k é o PRE, u_k é a entrada do sistema representada por um impulso unitário δ_k em que ($u_k = 1$ para $k = 0$, $u_k = 0$ para $k \neq 0$), $\theta^T = [c_1 \dots c_m \quad b_1 \dots b_n]$ é o vetor de parâmetros, m e n são os máximos atrasos da saída e entrada, respectivamente. A matriz de regressores é dada por $\psi_{k-1}^T = [s_{k-1} \dots s_{k-m} u_{k-1} \dots u_{k-n}]$ e g_k é o erro de modelagem.

Ordem do Modelo

Uma questão relevante na seleção de estrutura é determinar a ordem de um modelo linear ou não linear. Existem vários métodos para determinar o número de termos de um modelo. Destacam-se os critérios de informação, tais como os critérios de HAN (Hannan and Quinn) e RIS (Rissanen) [Steinberg, H., Gasser, T. H., Franke, J., 1985], os critérios de informação de Akaike (AIC) [Akaike, 1974] e o critério do erro de previsão final (FPE) [Aufrichtigl and Pedersenl, 1992]. Neste trabalho, utiliza-se o AIC para determinar a ordem do modelo do sistema do EEG_{ESP} e PRE, por ser o método mais frequentemente usados para o problema de selecção da ordem do modelo em geral.

De acordo com o critérios de Akaike [Akaike, 1974], o número de termos de um modelo deve minimizar a seguinte função:

$$AIC(\eta_\theta) = N \log[\sigma_{erro}^2(\eta_\theta)] + 2\eta_\theta \quad (3.7)$$

em que η_θ é o número de parâmetros no modelo, N é o comprimento da série temporal

usada na modelagem e σ_{erro}^2 é a variância dos resíduos do modelo. A interpretação da equação (3.7) é que, à medida que termos são incluídos no modelo, o número de graus de liberdade aumenta permitindo um ajuste aos dados mais exato. Dessa forma, o primeiro termo da equação (3.7) quantifica a diminuição na variância dos resíduos resultantes da inclusão de um termo. Ao passo que o segundo termo da equação (3.7) penaliza a inclusão de um termo.

O índice AIC normalmente atinge um mínimo para um determinado número de parâmetros no modelo. Vale ressaltar que tal critério é fundamentalmente estatístico e não garante que o modelo com um número indicado de termos resulte em um modelo dinamicamente válido [Aguirre, 2004].

3.3.2 Estimação dos Parâmetros

Nesta seção são estimados os parâmetros de uma determinada estrutura a fim de que o modelo reproduza o comportamento do sistema original. Uma das técnicas comumente utilizadas para estimação de parâmetros é o método dos mínimos quadrados (MQ), que se resume na minimização da soma do quadrado das diferenças entre os dados e a saída estimada pelo modelo [Aguirre, 2004; Georgiadis, S. D., Ranta-aho, P. O., Tarvainen, M. P., Karjalainen, P. A., 2005; Von Spreckelsen, M., Bromm, B., 1988].

Neste trabalho, utiliza-se o método dos mínimos quadrados para estimar os parâmetros do modelo AR e ARX dos sistemas do EEG_{ESP} e PRE, respectivamente.

3.3.3 Validação dos Modelos

Finalizando o processo de identificação de sistemas, a última etapa é a validação. A validação consiste essencialmente em verificar se os modelos incorporam ou não as características de interesse do sistema original. Os testes clássicos de validação para avaliar a qualidade de um modelo estimado são em geral baseados em considerações estatísticas, como, por exemplo, a análise da autocorrelação dos erros de predição, a análise de correlação cruzada entre entrada e resíduos, dentre outros [Aguirre, 2004].

Nesse trabalho, são utilizados três métricas: simulação k passos à frente, *índice*

RMSE e a *análise de resíduos* para quantificar a qualidade do modelos do EEG_{ESP} e PRE. Essas três métricas de validação são discutidas a seguir.

Simulação k Passos à Frente

Uma forma de simular um modelo é reutilizar as previsões passadas para compor o vetor de regressores a fim de continuar fazendo a previsão [Aguirre, 2004]. Considere que o modelo a ser simulado tem o seguinte vetor de regressores:

$$\psi_{k-1}^T = [y_{k-1} \quad y_{k-2} \quad u_{k-1} \quad u_{k-2}]. \quad (3.8)$$

Para efetuar a simulação, é necessário inicializar o modelo com valores medidos. Assim, y_1 e y_2 correspondem aos dois primeiros valores do conjunto de dados de validação, juntamente com as entradas u_1 e u_2 , resultando em

$$\hat{y}_3 = [\hat{y}_2 \quad \hat{y}_1 \quad u_2 \quad u_1] \hat{\theta}, \quad (3.9)$$

O sinal simulado conforme descrito acima é chamado de *simulação livre* ou *previsão de infinitos passos à frente*. Deve ser notado que ao simular modelos para validação, o sinal de entrada usado sempre será o sinal de entrada medido. Portanto, esse procedimento é uma boa alternativa para testar se o modelo consegue explicar o fenômeno no qual se está interessado.

Particularmente, a *simulação k passos à frente* consiste em usar o modelo como preditor livre apenas por k intervalos de amostragem, ou seja, simula-se o modelo por k iterações. Reiniciando-o logo a seguir com os dados medidos [Aguirre, 2004].

Raiz Quadrada do Erro Quadrático Médio (RMSE)

Outra métrica utilizada para validar um modelo consiste em calcular o índice RMSE, medida frequentemente usada na qualificação de previsões. O RMSE é calculado como a diferença entre os valores previstos pelo modelo e os valores efetivamente observados a partir do ambiente que está sendo modelado. Estas diferenças são também chamadas de resíduos.

O índice RMSE de uma previsão do modelo em relação à variável estimada \hat{y} é definida como a raiz quadrada do erro quadrado médio:

$$RMSE = \frac{\sqrt{\sum_{k=1}^N (y_k - \hat{y}_k)^2}}{\sqrt{\sum_{k=1}^N (y_k - \bar{y})^2}} \quad (3.10)$$

em que \hat{y}_k é a simulação livre do sinal e \bar{y} é o valor médio do sinal medido y_k , sendo que a média é calculada na janela de identificação.

A interpretação da equação (3.10) indica que o índice compara as previsões do modelo com a média temporal do sinal. Ou seja, a média é usada como *predição trivial*. Assim, os valores menores do que a unidade indicam um melhor desempenho em relação ao preditor padrão considerado (média) [Aguirre, 2004].

Análise de Resíduos

Os testes de simulação citados anteriormente não indicam se as falhas do modelo são corrigíveis. Por exemplo, ao comparar as previsões com as observações, se houver erros significativos, não é possível afirmar se os mesmos ocorreram devido a problemas na estimação de parâmetros ou na informação dinâmica contida nos dados.

Uma outra métrica para validar o modelo é utilizar a *análise de resíduo*. Esse procedimento indica se os parâmetros do modelo identificado são, ou não, estimados corretamente. Assim, o resíduo é calculado como a diferença entre o valor medido e o valor predito *k-passos à frente*,

$$\xi_k = y_k - \hat{y}_k \quad (3.11)$$

em que y_k é o valor do sinal medido e \hat{y}_k é a estimativa do sinal medido.

Com relação ao uso da *análise de resíduos* para a validação de modelos, esse procedimento é utilizado para verificar quão aleatórios são os resíduos, pois estes correspondem à parcela dos dados que o modelo não conseguiu determinar. Se, ao testar o vetor de resíduos, for verificado comportamento de uma variável aleatória branca, significa que não há informação dinâmica útil nos resíduos. Em outras palavras, o modelo explica o que era possível explicar a partir da massa de dados. Por outro

lado, se os resíduos tiverem correlacionados há indicio de que há informação nos mesmos, sugerindo que o modelo não conseguiu incorporar as características do sistema original.

Estatisticamente o vetor de valores ξ_k é *linearmente branco* se a função de autocorrelação for nula para todos os valores de atraso maiores ou iguais a um, ou seja, $r_{\xi\xi}(k) = 0$, $\forall k \neq 0$. Desta forma, para modelos AR, pode-se usar a função de autocorrelação para se avaliar a aleatoriedade dos resíduos [Billings, S A. Tao, 1991]:

$$r_{\xi\xi}(\tau) = E[\xi_{k-\tau}\xi_k] = \delta_\tau. \quad (3.12)$$

No caso do modelo ARX, uma forma de verificar se os resíduos são uma variável aleatória branca é calcular a função de correlação cruzada entre o vetor de resíduos e o sinal de entrada u_k , dada por

$$r_{u\xi}(\tau) = E[u_{k-\tau}\xi_k] = 0, \forall \tau. \quad (3.13)$$

3.4 Banco de Filtros de Kalman

Um banco interativo de dois filtros de Kalman (BIFK) em paralelo é utilizado para detectar o PRE relacionado à imaginação do movimento do dedo indicador da mão esquerda. O BIFK é baseado em modelos identificados a partir do sinal de EEG durante as tarefas visual (EEG_{TV}) e imagética-motora (EEG_{IM}).

Assim, o BIFK permite classificar a tarefa mental presente na medição do sinal de EEG por meio da execução simultânea dos dois FK, cada FK (FK1 e FK2) fornece a estimativa do sinal de EEG durante a EEG_{TV} e EEG_{IM} , respectivamente. Desta forma, o BIFK recursivo combina as estimativas recursivas dos sinais de EEG de ambas tarefas.

Nessa seção, inicialmente é analisado o funcionamento do filtro de Kalman descrito e em seguida, são descritos dois algoritmos baseados em banco de filtro de Kalman: BIFK e BGFK.

3.4.1 Filtro de Kalman

O Filtro de Kalman é usado para estimar recursivamente os sinais de EEG durante a EEG_{TV} e EEG_{IM} . Cada FK utiliza um dos modelos (3.5) e (3.6). Por exemplo, o modelo (3.5) é usado no FK, fornecendo uma estimativa dos sinais de EEG_{TV} . O mesmo princípio se aplica ao segundo caso.

Para tal, os modelos do sinal de EEG_{TV} e EEG_{IM} ilustrados na Figura 3.6 e descritos na Seção 3.3.1 são representados em forma de espaço de estados como

$$x_k = A_{k-1}x_{k-1} + B_k u_{k-1} + w_{k-1}, \quad (3.14)$$

$$y_k = C_k x_k + v_k, \quad (3.15)$$

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 $y_k \in R^m$, o vetor do sinal de EEG medido.

Assume-se o ruído de processo $w \in R^n$ e o ruído de medição $v \in R^m$ como variáveis aleatórias brancas, Gaussianas, de média nula e mutuamente independentes; Q_{k-1} e R_k representam as respectivas matrizes de covariância dos ruídos de processo e de medição, tal que:

$$p(w) \sim N(0, Q), \quad (3.16)$$

$$p(v) \sim N(0, R). \quad (3.17)$$

Considera-se o $\hat{x}_{k-1|k-1} \in R^n$ como uma estimativa de x_k no tempo k que utiliza apenas a informação até o tempo $k - 1$, denominada *estimativa do estado a priori* e $\hat{x}_{k|k} \in R^n$ como a estimativa de x_k no tempo k utilizando informação disponível até o tempo k , denominada *estimativa do estado a posteriori*.

Os erros da estimativa *a priori* e *a posteriori* são dados por

$$e_{k-1} = x_k - \hat{x}_{k|k-1}, \quad (3.18)$$

$$e_k = x_k - \hat{x}_{k|k}. \quad (3.19)$$

As matrizes de covariância do erro de predição $P_{k|k-1}^{xx}$, covariância da inovação $P_{k|k-1}^{yy}$ e covariância cruzada $P_{k|k-1}^{xy}$ são definidas como

$$P_{k|k-1}^{xx} = E[(x_k - \hat{x}_{k|k-1})(x_k - \hat{x}_{k|k-1})^T], \quad (3.20)$$

$$P_{k|k-1}^{yy} = E[(y_k - \hat{y}_{k|k-1})(y_k - \hat{y}_{k|k-1})^T], \quad (3.21)$$

$$P_{k|k-1}^{xy} = E[(x_k - \hat{x}_{k|k-1})(y_k - \hat{y}_{k|k-1})^T], \quad (3.22)$$

em que $\hat{x}_{k|k-1}$ é a estimativa do estado de predição e $\hat{y}_{k|k-1}$ é a estimativa de saída da predição.

Algoritmo do Filtro de Kalman

O algoritmo FK compreende duas etapas fundamentais: a *etapa de predição* e a *etapa de assimilação de dados*, mostrados na Figura 3.7. 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.

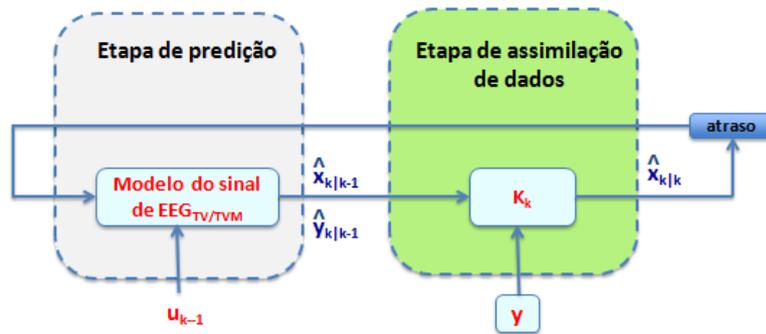


Figura 3.7: Diagrama do algoritmo do filtro de Kalman que compreende recursivamente duas etapas, etapa de predição e a etapa de assimilação de dados.

A *etapa de predição* é responsável pela predições do sinal de PRE a partir da informa-

ção disponível *a priori* $\hat{x}_{k-1|k-1}$ descrito como

$$\hat{x}_{k|k-1} = A_{k-1}\hat{x}_{k-1|k-1}, \quad (3.23)$$

$$P_{k|k-1}^{xx} = A_{k-1}P_{k-1|k-1}^{xx}A_{k-1}^T + Q_{k-1}, \quad (3.24)$$

$$\hat{y}_{k|k-1} = C_k\hat{x}_{k|k-1}, \quad (3.25)$$

$$P_{k|k-1}^{yy} = C_kP_{k|k-1}^{xx}C_k^T + R_k, \quad (3.26)$$

$$P_{k|k-1}^{xy} = P_{k|k-1}^{xx}C_k^T, \quad (3.27)$$

A etapa de assimilação de dados incorpora uma nova informação do sinal de EEG medido, y_k , para obter uma melhoria na estimativa do sinal de PRE, $\hat{x}_{k|k}$, dada por

$$K_k = P_{k|k-1}^{xy}(P_{k|k-1}^{yy})^{-1}, \quad (3.28)$$

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k(y_k - \hat{y}_{k|k-1}), \quad (3.29)$$

$$P_{k|k}^{xx} = P_{k|k-1}^{xx} - K_kP_{k|k-1}^{yy}K_k^T. \quad (3.30)$$

A parcela $(y_k - \hat{y}_{k|k-1})$ na equação (3.29) é chamada de inovação na medição, que quantifica a diferença entre a medida atual y_k , e a medida estimada $\hat{y}_{k|k-1}$ e a matriz $K_k \in R^{n \times m}$ é denominada ganho de Kalman.

Uma das principais características do FK é que pode ser implementado em sistemas com processamento em tempo real pela facilidade de cálculo, pois a estimativa do próximo estado depende apenas do estado anterior e das medições atuais, não sendo necessário manter na memória o histórico dos valores calculados previamente e nem processá-los a cada passo.

Existem várias técnicas e trabalhos na literatura que abordam o problema de estimativa do PRE. Para uma visão geral dos métodos, sugere-se a leitura de [Georgiadis, S. D., Ranta-aho, P. O., Tarvainen, M. P., Karjalainen, P. A, 2005; Mohseni, H. R., Wilding, E. L., Sanei, S., 2007; Lange, H., Pratt, H., Inbar, G. F., 1995; Britton et al., 2000; Lange, D. H., Pratt, H., Inbar, G. F., 1997].

3.4.2 Estimador de Múltiplos Modelos Interativos (MMI)

O algoritmo de banco de filtros de Kalman (BFK) é baseado na abordagem de múltiplos modelos dinâmicos (MMD) [Hide C., 2004] e é classificado como um método Bayesiano em [Mehra R.K., 1972]. Diferentes algoritmos podem ser usados para escolher o banco de filtros ou combinar suas estimativas [[Bar-Shalom Y., Li X. R., 2001], p. 441-465], [Chaer W. S., Bishop R. H., Ghosh J., 1997].

Nesta seção, são apresentadas duas abordagens baseadas em MMD. A primeira abordagem é baseada no estimador de múltiplos modelos interativos (MMI). A segunda abordagem é baseada no estimador Pseudo-Bayesiano Generalizado de primeira ordem (GPB1) utilizada para comparar os resultados com a abordagem MMI.

O banco interativo de filtros de Kalman (BIFK) baseado na abordagem MMI é utilizado para detectar o PRE relacionado à imaginação do movimento. Esse algoritmo permite classificar a tarefa mental presente na medição do sinal de EEG por meio da execução simultânea dos dois FK, cada FK (FK1 e FK2) fornece a estimativa do sinal de EEG durante a EEG_{TV} e EEG_{IM} , respectivamente. Desta forma, o BFK recursivo é utilizado para detectar o PRE a partir da combinação das estimativas recursivas dos sinais de EEG de ambas tarefas. Na Figura 3.8 mostra-se as três etapas fundamentais do BIFK: etapa de interação, etapa de filtragem paralela e etapa de combinação.

Algoritmo MMI

Na Figura 3.9 mostra-se o algoritmo do BIFK que compreende três etapas fundamentais: na *etapa de interação*, são obtidas as estimativas das entradas de cada FK a partir da mistura das estimativas prévias e os respectivos pesos iniciais, $\hat{x}_{k-1|k-1}$ e $P_{k-1|k-1}^{xx}$. Em seguida, na *etapa de filtragem paralela*, os dois FK são executados em paralelo, e cada FK fornece uma estimativa do sinal de EEG_{TV} e EEG_{IM} . Posteriormente, na *etapa de combinação*, é obtida a estimativa do sinal de PRE a partir da combinação das duas estimativas recursivas do sinal de EEG_{TV} e EEG_{IM} e os pesos γ_k^s . Os pesos γ_k^s são calculados através do termo de inovação $\eta_{k|k-1} = y_k - \hat{y}_{k|k-1}$ do sinal de EEG, y_k , fornecido por cada FK. Para a inicialização, assume-se as seguintes condições: a estimativa do vetor de estado $\hat{x}_{0|0}$ e covariância $P_{0|0}^{xx}$, ambas conhecidas.

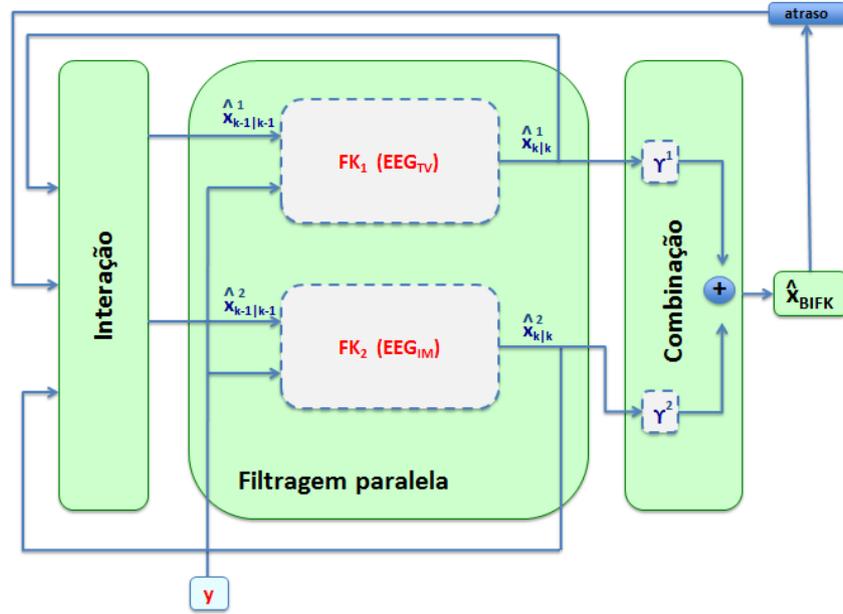


Figura 3.8: Diagrama da abordagem do banco de filtros de Kalman baseada na abordagem de múltiplos modelos interativos (MMI)

Na primeira etapa, a entrada $\hat{x}_{k-1|k-1}^{0s}, P_{k-1|k-1}^{xx,0s}$ para os s filtros, $s = 1, \dots, M$, é obtida da *interação* dos $M=2$ filtros por mistura das estimativas prévias $\hat{x}_{k-1|k-1}^s, P_{k-1|k-1}^{xx,s}$ com a mistura dos pesos $0 \leq w_k^s \leq 1, s = 1, \dots, M$. Isto é feito por

$$\hat{x}_{k-1|k-1}^{0s} = \sum_{r=1}^M w_{k-1}^{r|s} \hat{x}_{k-1|k-1}^r, \quad (3.31)$$

$$P_{k-1|k-1}^{xx,0s} = \sum_{r=1}^M w_{k-1}^{r|s} \left[P_{k-1|k-1}^{xx,r} + \left(\hat{x}_{k-1|k-1}^r - \hat{x}_{k-1|k-1}^{0s} \right) \left(\hat{x}_{k-1|k-1}^r - \hat{x}_{k-1|k-1}^{0s} \right)^T \right], \quad (3.32)$$

com os pesos dados por

$$w_{k-1}^{r|s} = \frac{(p_{r|s} \gamma_{k-1}^r)}{c_s} \quad \text{em que} \quad c_s = \sum_{r=1}^M p_{r|s} \gamma_{k-1}^r \quad (3.33)$$

Na segunda etapa, tem-se o banco de M filtros de Kalman rodando em paralelo. O algoritmo escolhido é o KF, para todo $s = 1, \dots, M$.

$$\left\{ \hat{x}_{k|k}^s, P_{k|k}^{xx,s}, \eta_{k|k-1}^s, P_{k|k}^{yy,s} \right\} = FK \left(\hat{x}_{k-1|k-1}^{0s}, P_{k-1|k-1}^{xx,0s}, y_k, A_{k-1}^s, C_k^s, Q^s, R^s \right) \quad (3.34)$$

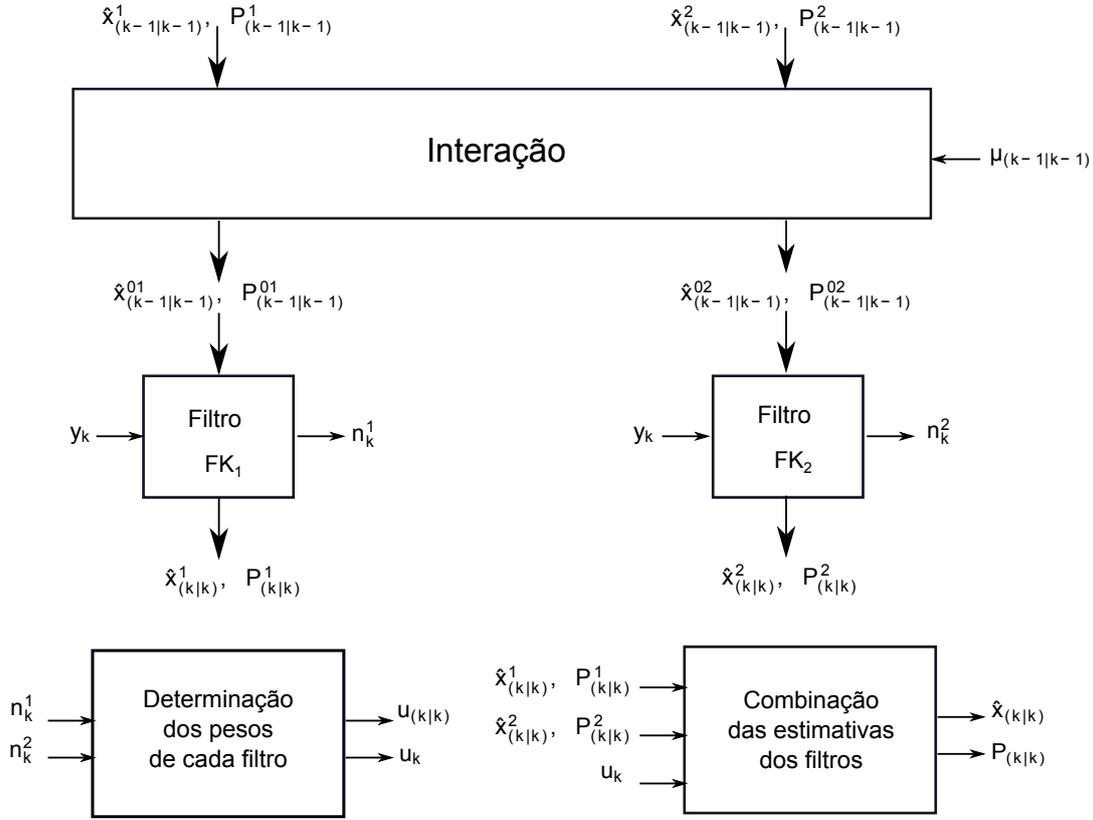


Figura 3.9: Diagrama da abordagem do estimador MMI. Adaptado de [Bar-Shalom Y., Li X. R., 2001].

em que $\hat{x}_{k-1|k-1}$ e $P_{k-1|k-1}^{xx}$ são as estimativas e matriz de covariância do KF no tempo $k-1$, respectivamente, $y_k^s, A_{k-1}^s, C_k^s, Q^s$ e R^s são os parâmetros do modelo de processo $\{r_k, s_k\}$ e modelo de observação $\{y_s\}$ usados no s -ésimo FK. Cada FK utiliza um diferente par de modelos (EEG_{TV} e EEG_{TVM}).

Na terceira etapa, as M estimativas são combinadas como

$$\hat{x}_{k|k} = \sum_{s=1}^M \gamma_k^s \hat{x}_{k|k}^s, \quad (3.35)$$

$$P_{k|k}^{xx} = \sum_{s=1}^M \gamma_k^s \left[P_{k|k}^{xx,s} + (\hat{x}_{k|k}^s - \hat{x}_{k|k}) (\hat{x}_{k|k}^s - \hat{x}_{k|k})^T \right], \quad (3.36)$$

em que $\hat{x}_{k|k}$ é a estimativa de estado e $P_{k|k}^{xx}$ é a matriz covariância de erro do BIFK.

Usando a fórmula de Bayes, γ_k^s representa a probabilidade *a posteriori* do s -ésimo mo-

delo $\{r_k, s_k\}$ ser correto, considerando os dados de medição até o tempo k e a combinação dos pesos $0 \leq \gamma_k^s \leq 1$, $s = 1, \dots, M$, e é dada por

$$\gamma_k^s = \frac{\rho_s(\eta_{k|k-1}^s) c_s}{\sum_{l=1}^M \rho_l(\eta_{k|k-1}^l) c_l}, \quad (3.37)$$

Posteriormente, as correspondentes probabilidades são obtidas a partir de regra de Bayes, onde $\eta_{k|k-1}$ é a função de densidade de probabilidade da inovação $\eta_{k|k-1}$ do s -ésimo filtro, e é dada pela expressão

$$\rho_s(\eta_{k|k-1}) = \frac{1}{\sqrt{(2\pi)^m \det(P_{k|k-1}^{yy,s})}} \times \exp \left[-\frac{1}{2} \eta_{k,k-1}^s T (P_{k|k-1}^{yy,s})^{-1} \eta_{k,k-1}^s \right] \quad (3.38)$$

em que a inovação e sua covariância $\eta_{k|k-1}$ e $P_{k|k-1}^{yy,s}$ são calculadas a partir do correspondente s -ésimo modelo estocástico. Percebe-se, que o filtro cuja inovação representa um erro de saída pequeno recebe um maior peso γ_k^s , [Teixeira, B.O. S., Barbosa, B. H. G., Gomes, L. P., Teixeira, A. F., Aguirre, L. A., 2001].

Após os filtros serem inicializados, eles são executados recursivamente em suas próprias estimativas. A probabilidade de cada modelo ser correto é obtida de acordo com a equação (3.37) com base na sua função de verossimilhança descrita na equação (3.38). Assim, suas funções de probabilidade são usadas para determinar os pesos de cada filtro. Portanto, o BIFK combina as estimativas e os pesos de cada filtro para detectar o PRE relacionado à imaginação do movimento.

3.4.3 Estimador Pseudo-Bayesiano Generalizado de 1a. Ordem (GPB1)

Várias técnicas têm sido propostas para detectar as mudanças dinâmicas de um número finito de modelos. Dentre uma delas, o banco pseudo-bayesiano de filtros de Kalman (BGFK) baseado na abordagem GPB1. Uma breve idéia do principio de funcionamento do algoritmo é que a estimativa $x_{k|k}$ é calculada em cada modelo usando o FK, onde um total de s modelos são considerados. Desta maneira, todas as estimativas passadas são combinadas. [[Bar-Shalom Y., Li X. R., 2001], p. 447-449].

A Figura 3.10 mostra o algoritmo do BGFK que compreende duas etapas: a etapa de

filtragem, onde os M filtros são executados em paralelo enquanto que na segunda etapa, combina-se as s estimativas. Percebe-se que essas duas etapas são as mesmas etapas apresentadas no BIFK, detalhadas na seção anterior. Assim, as mesmas considerações são aplicadas neste algoritmo.

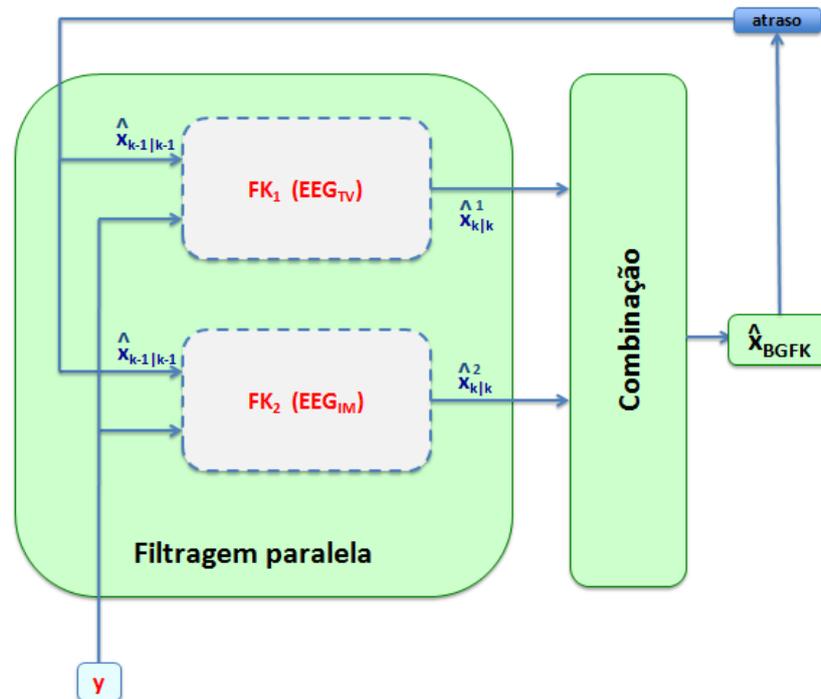


Figura 3.10: Diagrama da abordagem do banco de filtros de Kalman baseada na abordagem de múltiplos modelos interativos (GPB1)

Utiliza-se o BGFK para estimar o PRE da imaginação do movimento. Essas estimativas são comparadas com as estimativas fornecidas pelo BIFK com o intuito de avaliar o desempenho da estimativa do sinal de EEG durante a EEG_{IM} de cada banco de filtros de Kalman.

Resultados

“Os sábios mais supõem do que conhecem.”

Michel de Montaigne

Neste capítulo, são abordadas as seguintes questões: i) verificar se a promediação do sinal de EEG encontra-se sobreamostrado, ii) como modelar os sistemas EEG_{TV} , EEG_{TVM} e EEG_{IM} a partir dos modelos AR/ARX, iii) avalia-se o comportamento dinâmico do sistema EEG_{IM} que apresenta as mesmas características do sistema EEG_{TVM} , iv) avalia-se se o BIFK é capaz de detectar e estimar o PRE durante a imaginação do movimento, v) avalia-se os modelos dos sistemas EEG_{TV} , EEG_{TVM} e EEG_{IM} obtidos a partir do sinal de EEG de um determinado indivíduo representam o comportamento dinâmico de todos os indivíduos participantes do estudo, vi) avalia-se o efeito da variação do número de repetições da tarefa mental influencia na classificação do PRE durante a imaginação do movimento.

4.1 Decimação do sinal de EEG

Antes de obter os modelos matemáticos dos sistemas que representa a promediação dos sinais de EEG durante as tarefas visual, viso-motora e imaginação do movimento, é necessário verificar se o sinal de EEG amostrado (frequência de amostragem de 600Hz) se encontra dentro da faixa estabelecida pela equação (3.4). Para isso, é selecionado apenas um dos sinais de EEG durante as tarefas mentais.

A Figura 4.1a e 4.1b mostra as funções de autocorrelação linear e não linear, respectivamente, da promediação do sinal de EEG durante a tarefa viso-motora. Observa-se

que o primeiro mínimo dessas funções ($\tau_m = 35$), se encontra fora da faixa estabelecida, $10 \leq \tau_m \leq 20$. Portanto, é necessário decimar a promediação do sinal de EEG.

Agora, é calculado o fator de decimação, Δ . Note que a exceção do fator de decimação, as funções de autocorrelação da promediação do sinal de EEG original, y_k^* , e a promediação do sinal de EEG decimado, y_k , são iguais, então tem-se

$$10\Delta \leq \tau_m^* \leq 20\Delta \quad (4.1)$$

Assim, substituindo o valor do $\tau_m^* = 35$ na equação (4.1), encontra-se o intervalo de escolha do fator de decimação

$$1,75 \leq \Delta \leq 3,5 \quad (4.2)$$

Finalmente, é escolhido o fator de decimação $\Delta = 3$. Na Figura 4.2a e 4.2b mostra-se as funções de autocorrelação linear e não linear, respectivamente, da promediação do sinal de EEG decimado (frequência de amostragem de 200Hz) durante a tarefa viso-motora. Observa-se que o primeiro mínimo dessas funções ($\tau_m = 11$), satisfaz $10 \leq \tau_m \leq 20$.

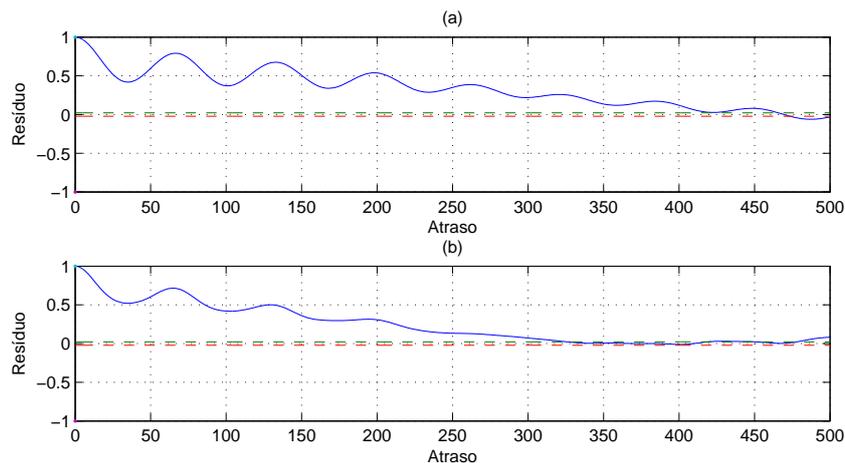


Figura 4.1: Função de autocorrelação: (a) linear e (b) não linear da promediação do sinal de EEG durante a tarefa viso-motora.

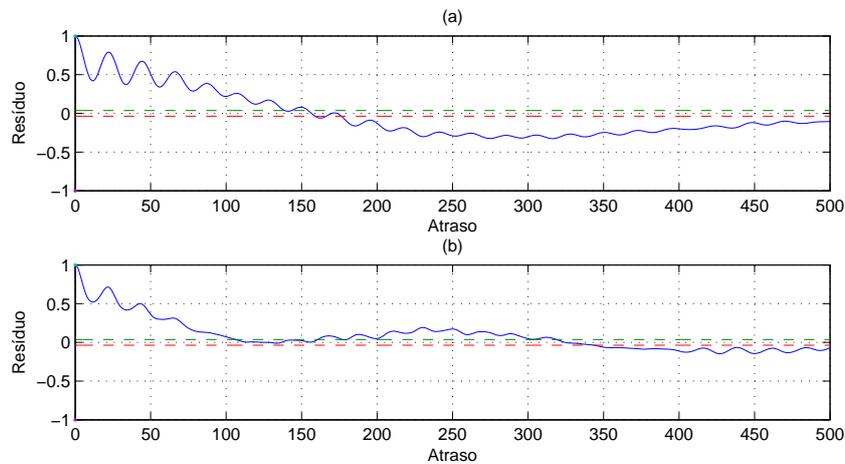


Figura 4.2: Função de autocorrelação: (a) linear e (b) não linear da promediação do sinal decimado de EEG durante a tarefa viso-motora.

4.2 Modelagem Matemática

Neste trabalho, são registrados sinais de EEG durante três tarefas mentais: (1) EEG_{TV} , o indivíduo não realiza a tarefa motora nem a imaginação do movimento; (2) EEG_{TVM} , o indivíduo é orientado a executar o movimento e (3) EEG_{IM} , o indivíduo é orientado a imaginar o movimento do dedo indicador da mão esquerda. Desta forma, é utilizada a promediação dos sinais de EEG durante as três tarefas na derivação C_z do indivíduo #2 para obter os modelos que descrevem o comportamento dinâmico das diferentes tarefas mentais. A promediação dos sinais de EEG do indivíduo #3 são empregados para validar se tais modelos incorporam as características dos sinais de EEG registrados durante a execução das tarefas mentais.

Nesta seção, é apresentada a seleção de estrutura, estimação de parâmetros e validação dos modelos obtidos a partir da promediação dos sinais de EEG. Especificamente, são analisadas as componentes do sinal de EEG durante as tarefas mentais, ou seja, a parcela do sinal de EEG_{ESP} , PRE durante as tarefas viso-motora e tarefa imagética-motora, respectivamente.

4.2.1 Modelagem do Potencial Espontâneo

Na etapa de identificação de sistemas é obtido o modelo do sistema EEG_{ESP} a partir da promediação dos sinais do EEG_{TV} na derivação Cz do indivíduo #2 com $M=20$ trechos e 660 amostras. A promediação dos sinais do EEG_{TV} do indivíduo #3 são empregados para a validação desse modelo. A Figura 4.3 mostra a promediação dos sinais de EEG_{TV} dos indivíduos #2 e #3.

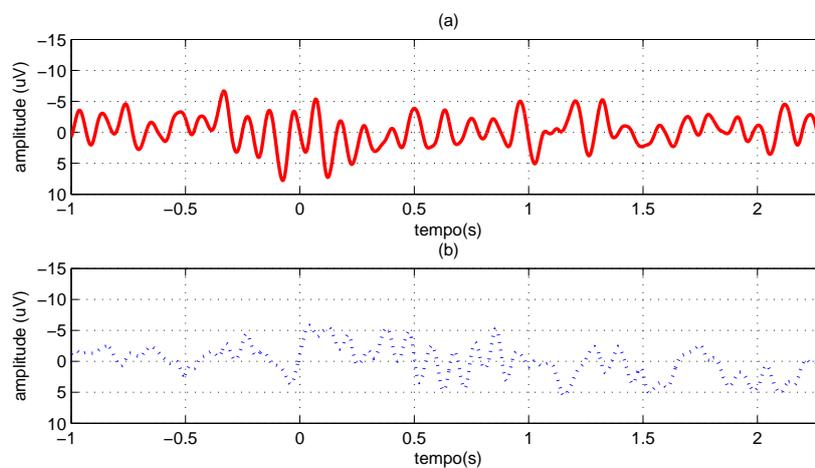


Figura 4.3: Promediação do sinal de EEG durante a tarefa visual denominada como potencial espontâneo obtido na derivação Cz: (a) indivíduo #2 (Linha contínua vermelha), (b) indivíduo #3 (Linha tracejada azul).

Seleção de Estrutura e Estimação de Parâmetros

O sistema descrito por EEG_{ESP} é modelado pelo seguinte modelo AR

$$r_k = 5,534r_{k-1} - 12,87r_{k-2} + 16,11r_{k-3} - 11,46r_{k-4} + 4,398r_{k-5} - 0,7116r_{k-6} + e_k, \quad (4.3)$$

em que r_k é o sinal de EEG_{ESP} e e_k é o erro de modelagem.

Para a estimativa dos parâmetros do modelo AR foi utilizado o método de MQ. Para determinar a ordem do modelo (4.3) foi utilizado o AIC. Observa-se que quando o índice do AIC passa por um mínimo, esse valor pode ser considerado como a ordem do modelo, resultando em $p = 6$ mostrado na Figura 4.4.

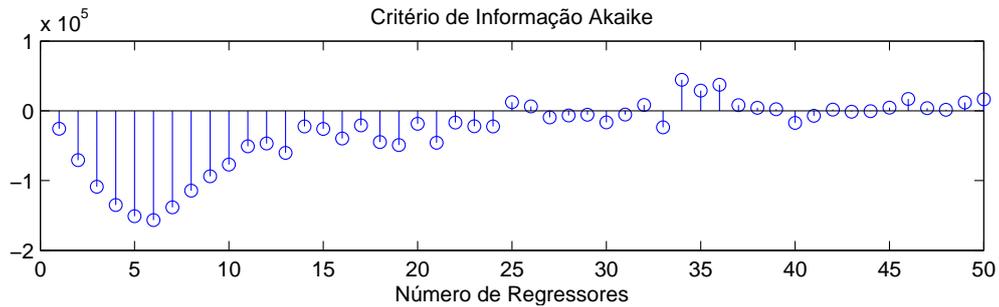


Figura 4.4: Critério de Informação Akaike para o sistema descrito por EEG_{ESP}

Validação do Modelo

Nesta seção, é validado o modelo obtido na equação (4.3). Para isso, são utilizadas três métricas: predição k passos à frente, o índice RMSE e a análise de resíduos.

A Figura 4.5a mostra a validação do modelo (4.3) utilizando a predição de 150 passos à frente. Para melhorar a visualização da Figura 4.5a é apresentado o zoom no intervalo $t = -0,2s$ e $t = 0,2s$ na Figura 4.5b.

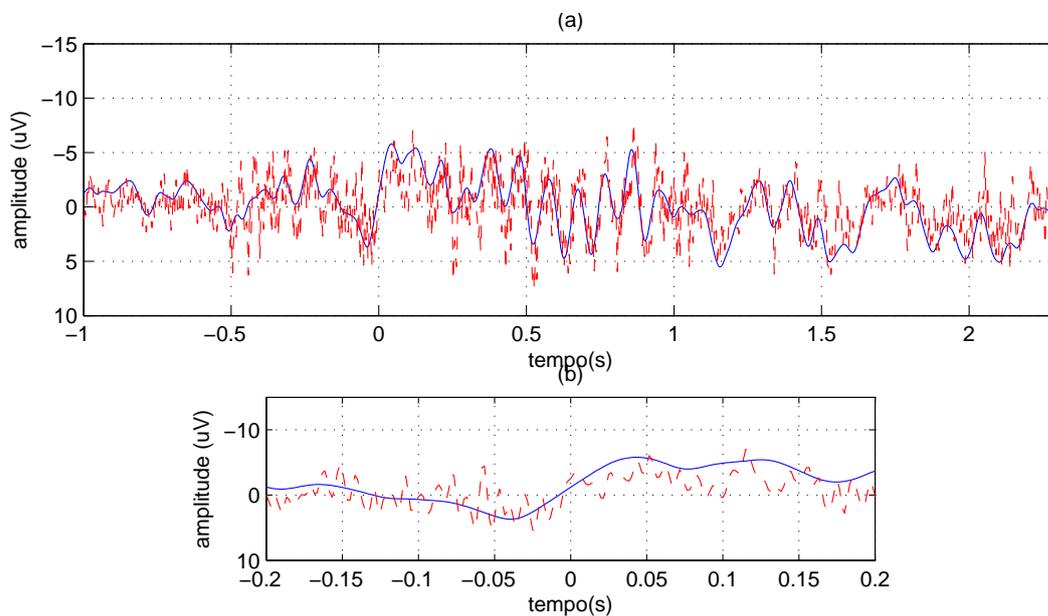


Figura 4.5: (a) Validação do modelo EEG_{ESP} usando predição 150 passos à frente, (b) Zoom da validação no intervalo $t = -0,2s$ e $t = 0,2s$. Os traçados mostram a promediação do sinal medido de EEG_{ESP} (Linha contínua azul) e a promediação do sinal simulado de (4.3) (Linha tracejada vermelha).

Observa-se que o sinal resultante da predição de 150 passos à frente, ou seja, predição

de 0,75s descreve a tendência da promediação do sinal medido de EEG_{ESP} . Deve ser notado que o modelo (4.3) foi validado utilizando-se a promediação dos sinais do indivíduo #3. Também, percebe-se que o EEG_{ESP} não apresentou componentes negativas, sendo uma das principais características do CNV entre dois estímulos E1 - E2.

Outra métrica utilizada para validar o modelo (4.3) consiste na quantificação dos erros das predições. A Figura 4.6 mostra o índice RMSE para o sinal resultante da predição de 160 passos à frente do indivíduo #2 que foi de 0,95. Também, percebe-se que a partir da predição de 150 passos à frente o índice RMSE se aproxima de 1.

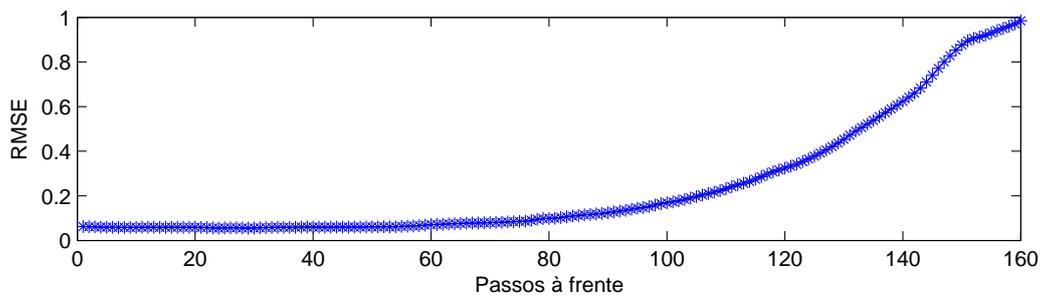


Figura 4.6: Índice RMSE para o sistema descrito por EEG_{ESP}

A análise de resíduo é outra métrica utilizada para validar o modelo (4.3). A Figura 4.7 mostra os resíduos do sinal de EEG_{ESP} . Observa-se que os resíduos não são uma variável aleatória branca, isso significa que ainda há dinâmica linear nos dados, ou seja, o modelo não incorporou todas as características do sistema original. Outra causa pode ser atribuída ao estimador ser polarizado.

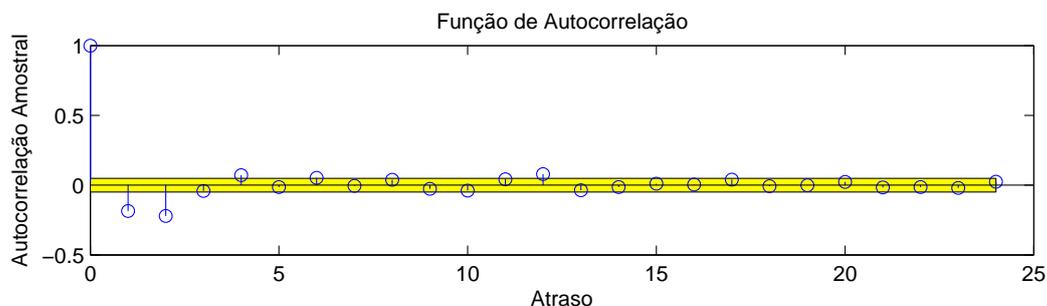


Figura 4.7: Análise de resíduos do sistema descrito por EEG_{ESP}

4.2.2 Modelagem do PRE Durante a Tarefa Viso-Motora

Nesta subseção é obtido um modelo do sistema do PRE durante o movimento voluntário a partir da promediação dos sinais do EEG_{TVM} na derivação Cz do indivíduo #2 com $M=30$ trechos e 660 amostras. O número de trechos é sugerido no estudo desenvolvido por [Santos Filho, 2010]. A promediação dos sinais do EEG_{TVM} do indivíduo #3 são empregados para a validação deste modelo. A Figura 4.8 mostra a promediação do sinal de EEG_{TVM} dos indivíduos #2 e #3.

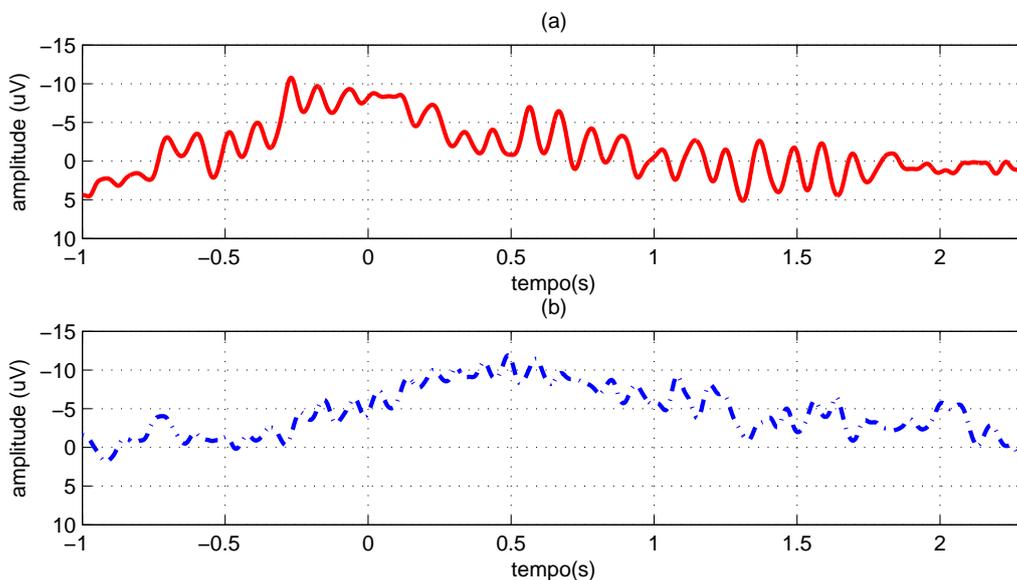


Figura 4.8: Promediação do sinal de PRE durante o movimento voluntário obtida em Cz: (a) indivíduo #2 (Linha contínua vermelha), (b) indivíduo #3 (Linha tracejada azul).

Seleção de Estrutura e Estimação de Parâmetros

O sistema descrito pelo PRE durante a tarefa viso-motora é modelado pelo seguinte modelo ARX

$$s_k = 4,88s_{k-1} - 10,51s_{k-2} + 10,26s_{k-3} - 4,87s_{k-4} + 1,42s_{k-5} - 0,95s_{k-6} + u_{k-1} + \dots + u_{k-6}, \quad (4.4)$$

em que s_k é o sinal de PRE e u_k é a entrada impulsiva. Baseado no estudo de [Von Spreckelsen, M., Bromm, B., 1988], é estabelecido o valor dos parâmetros de u_k como 1.

Para estimar os parâmetros do modelo ARX é utilizado o estimador de MQ. Para determinar a ordem do modelo (4.4) também é utilizado o AIC. Assim, quando o índice do AIC passa por um mínimo, esse valor pode ser considerado como a ordem do modelo, resultando em $p = 6$ mostrado na Figura 4.9.

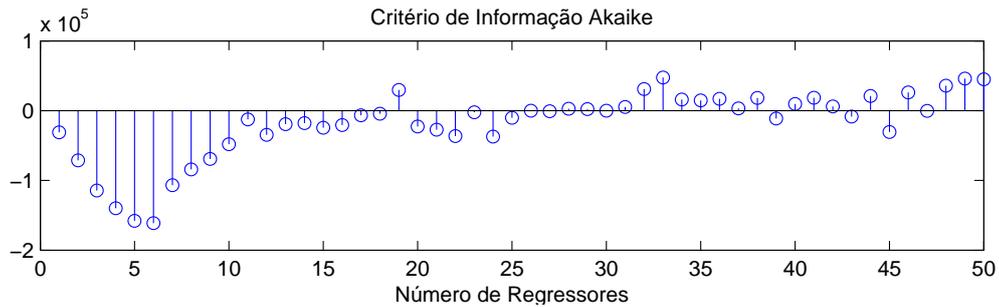


Figura 4.9: Critério de Informação Akaike para o sistema descrito pelo PRE durante a EEG_{TVM}

A fim de determinar a entrada u_k do modelo (4.4) e baseado nos estudos desenvolvidos por [Von Spreckelsen, 1988; Georgiadis, S. D., Ranta-aho, P. O., Tarvainen, M. P., Karjalainen, P. A, 2005], considera-se que o estímulo que provoca o PRE pode ser representado pelo impulso unitário δ_k e o sinal de PRE representa a resposta ao impulso do sistema sensorial ou cognitivo. Dessa forma, considera-se um impulso δ_k nos tempos $t = -1s$ e $t = 0s$, representando quando o LED amarelo é acionado e os dois LEDs são desligados, mostrados na Figura 4.10. Essa consideração é feita devido à presença das componentes prévias a execução do movimento no PRE.

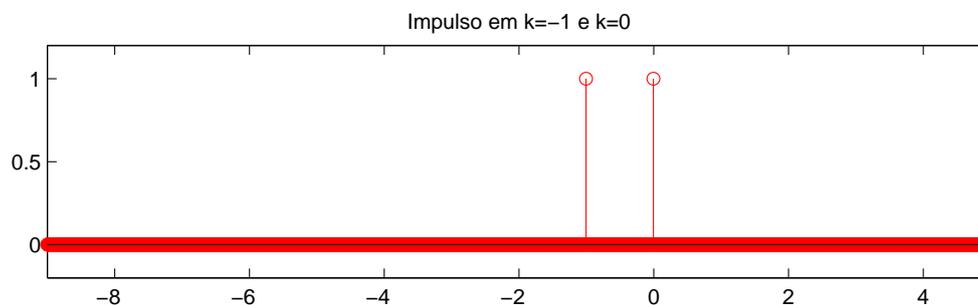


Figura 4.10: Entrada: impulso unitário nos tempos $t = -1s$ e $t = 0s$.

Validação do Modelo

A Figura 4.11a mostra a validação do modelo (4.4) utilizando a predição de 150 passos à frente. A Figura 4.11b apresenta o zoom de uma parcela contida no intervalo $t = -0,2s$ e $t = 0,2s$.

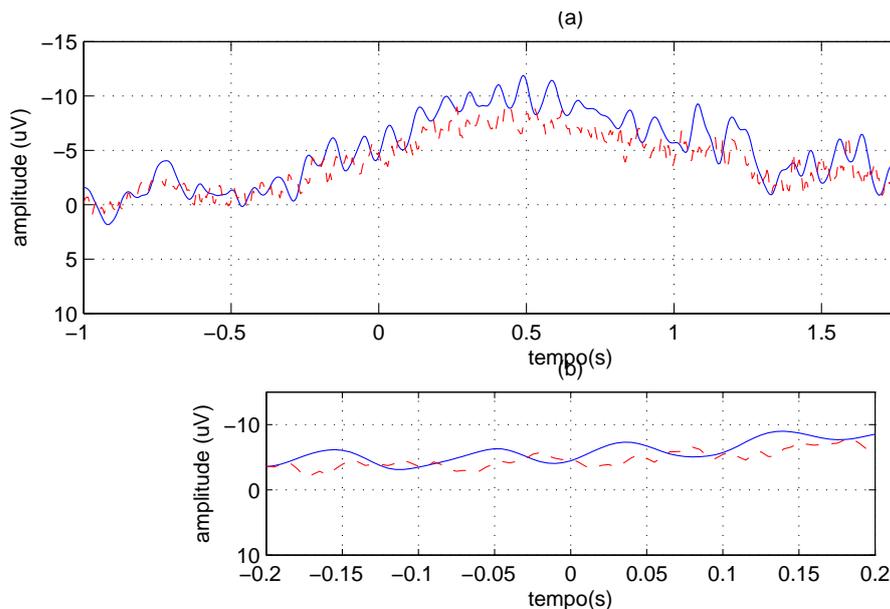


Figura 4.11: (a) Validação do modelo EEG_{TVM} usando predição 150 passos à frente, (b) Zoom da validação no intervalo $t = -0,2s$ e $t = 0,2s$. Os traçados mostram a promediação do sinal medido de EEG_{TVM} (Linha contínua azul) e a promediação do sinal simulado de (4.4) (Linha tracejada vermelha).

A observação da Figura 4.11 revela que o modelo (4.4) consegue acompanhar os dados medidos, ou seja, descreve a tendência da promediação do sinal medido de EEG_{TVM} . Percebe-se que o sinal simulado da predição de 150 passos à frente (predição de 0,75s) descreve o comportamento dominante da promediação do sinal de PRE durante o movimento voluntário. Esse sinal apresenta uma negatividade correspondente à componente CNV entre os dois estímulos E1 ($t = -1s$) - E2 ($t = 0s$). Visualiza-se que a negatividade inicia aproximadamente -0,3s antes da execução da tarefa viso-motora.

A Figura 4.12 mostra o índice RMSE para o sinal simulado do sistema do PRE durante a EEG_{TVM} com predição de 150 passos à frente do indivíduo #2 foi de 0,89. Observa-se que a partir da predição de 150 passos à frente o índice RMSE alcança valores próximos a 1.

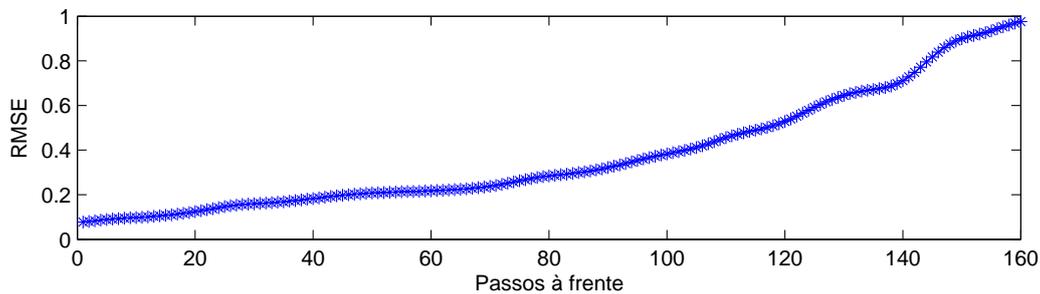


Figura 4.12: Índice RMSE para o sistema descrito pelo PRE durante a EEG_{TVM} .

A Figura 4.13 mostra que os resíduos do sinal medido de PRE durante o movimento voluntário e o sinal simulado. Esses resíduos não são uma variável aleatória branca, e como foi comentado anteriormente, ainda existe informação útil neles que não é incorporada no modelo do sistema ou o estimador pode estar polarizado.

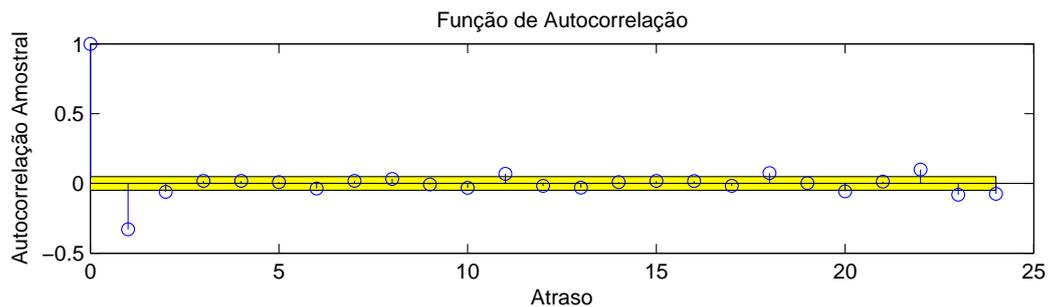


Figura 4.13: Análise de resíduos do sistema descrito pelo PRE durante a EEG_{TVM} .

4.2.3 Modelagem do PRE Durante a Tarefa Imagética-Motora

Nesta subseção é obtido um modelo do sistema do PRE durante a imaginação do movimento a partir da promediação dos sinais do EEG_{IM} na derivação Cz do indivíduo #2 com $M=30$ trechos e 660 amostras. A promediação dos sinais do EEG_{IM} do indivíduo #3 são empregados para a validação deste modelo. A Figura 4.14 mostra a promediação do sinal de EEG_{IM} dos indivíduos #2 e #3.

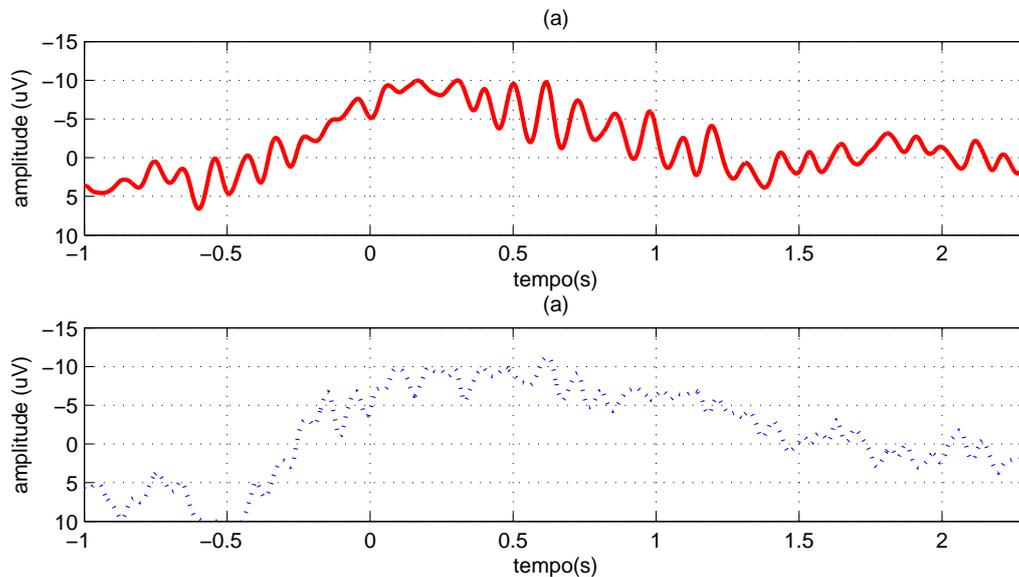


Figura 4.14: Promediação do sinal de PRE durante a imaginação do movimento obtida em Cz: (a) indivíduo #2 (Linha contínua vermelha), (b) indivíduo #3 (Linha tracejada azul).

Seleção de Estrutura e Estimação de Parâmetros

O sistema descrito pelo PRE durante a tarefa imagética-motora é modelado pelo seguinte modelo ARX

$$s_k = 4,89s_{k-1} - 10,67s_{k-2} + 10,41s_{k-3} - 4,61s_{k-4} + 1,45s_{k-5} - 0,92s_{k-6} + u_{k-1} + \dots + u_{k-6}, \quad (4.5)$$

em que s_k é o sinal de PRE e u_k é a entrada impulsiva. Na seção anterior, foi estabelecido o valor dos parâmetros de u_k como 1, baseado no estudo desenvolvido por [Von Spreckelsen, M., Bromm, B., 1988].

Percebe-se que a equação (4.5) que descreve o comportamento da promediação do sinal de PRE durante a imaginação do movimento apresenta parâmetros parecidos com o sinal de PRE durante o movimento voluntário. Esse resultado obtido corrobora os achados por [Santos Filho, 2010; Souza, 2010] mostrando que a promediação do sinal de EEG_{IM} apresenta as mesmas características que a promediação do sinal de EEG_{TVM} .

Portanto, são realizadas as mesmas considerações feitas no procedimento de análise do sinal de EEG_{TVM} . Assim, para estimar os parâmetros do modelo ARX dado pela

equação (4.5) é utilizado o estimador de MQ. Da mesma forma é utilizado o AIC para determinar a ordem do modelo ARX dado pela equação (4.5), resultando em $p = 6$ mostrado na Figura 4.15.

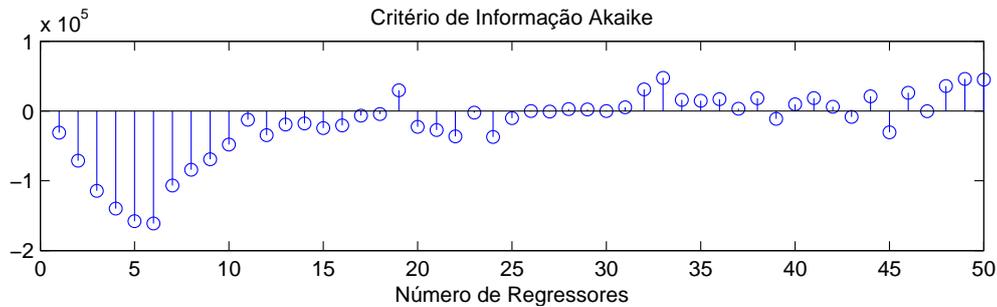


Figura 4.15: Critério de Informação Akaike para o sistema descrito pelo PRE durante a EEG_{IM} .

Validação do Modelo

A Figura 4.16a mostra a validação do modelo (4.5) utilizando a predição de 150 passos à frente. A Figura 4.16b apresenta o zoom de uma parcela contida no intervalo $t = -0,2s$ e $t = 0,2s$.

É importante notar que o sinal simulado da predição de 100 passos à frente descreve a tendência da promediação do sinal de EEG_{IM} , ou seja, o modelo obtido na equação (4.5) representa o comportamento da promediação do sinal de EEG durante a tarefa imagética-motora.

Com relação ao sinal de PRE durante a imaginação do movimento obtido da predição de 150 passos à frente (predição de 0,75s) mostra-se que descreve o mesmo comportamento dinâmico da promediação do sinal de PRE durante o movimento voluntário. Como era esperado, o EEG_{IM} mostra a presença de uma negatividade entre os dois estímulos E1 ($t = -1s$) - E2 ($t = 0s$) que caracteriza a componente CNV, resultado semelhante ao encontrado no EEG_{TVM} . Observa-se que a negatividade inicia aproximadamente -0,3s antes da execução da tarefa imagética-motora.

A Figura 4.17 mostra o índice RMSE para o sinal resultante do sistema de PRE durante a EEG_{IM} com predição de 150 passos à frente do indivíduo #2 foi de 0,85. Da

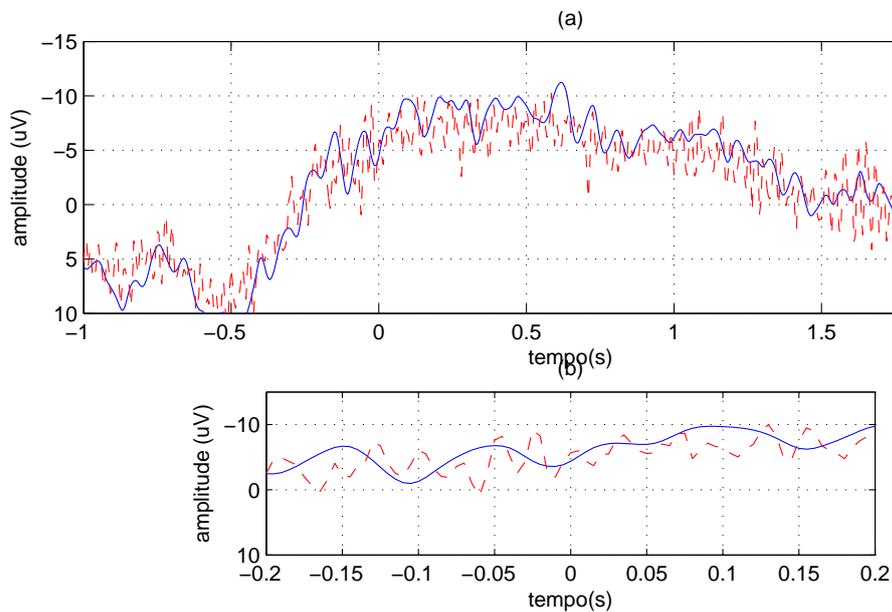


Figura 4.16: (a) Validação do modelo EEG_{IM} usando predição 150 passos à frente, (b) Zoom da validação no intervalo $t = -0,2s$ e $t = 0,2s$. Os traçados mostram a promediação do sinal medido de EEG_{IM} (Linha contínua azul) e a promediação do sinal simulado de (4.5) (Linha tracejada vermelha)

mesma forma que na seção anterior, percebe-se que a partir da predição de 150 passos à frente o índice RMSE alcança valores próximos a 1.

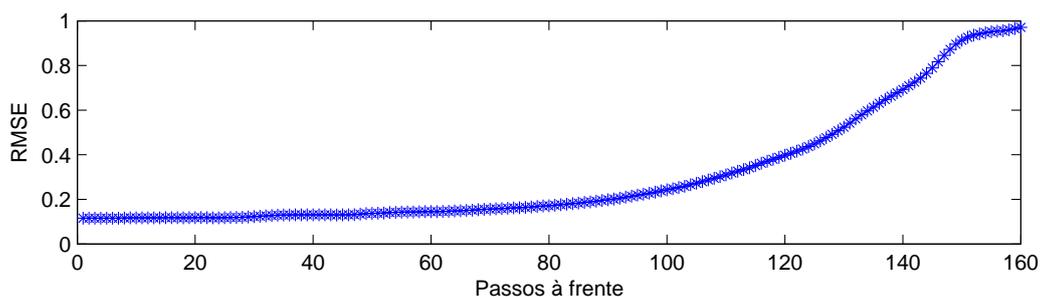


Figura 4.17: Índice RMSE para o sistema descrito pelo PRE durante a EEG_{IM} .

A Figura 4.18 mostra que os resíduos do sinal de PRE durante a imaginação do movimento não são uma variável aleatória branca. Observe-se que esse resultado apresenta o mesmo comportamento que o sinal de PRE durante EEG_{TVM} , analisado na seção anterior.

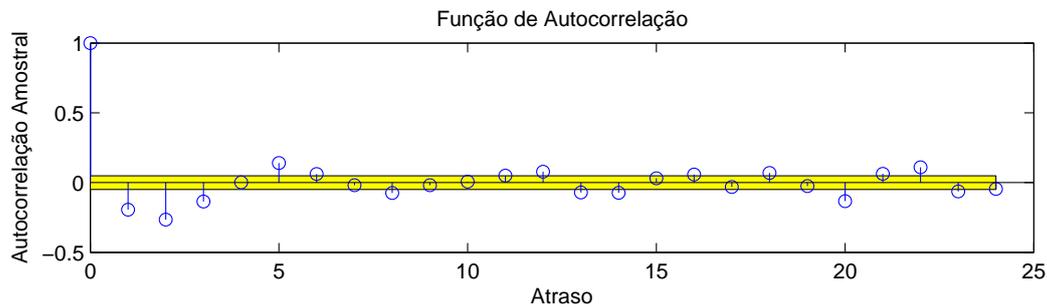


Figura 4.18: Análise de resíduos do sistema descrito pelo PRE durante a EEG_{IM} .

4.2.4 Efeito do Número de Repetições da Tarefa Mental

Visando a detecção do PRE com o menor número de repetições da tarefa mental, avalia-se o efeito, na etapa de modelagem, de se usar dados a partir da promediação dos trechos do sinal de EEG com $M=15$, $M=10$ e $M=5$ durante as tarefa visual, viso-motora e imagética motora.

Os resultados preliminares obtidos a partir da promediação dos $M=15$ trechos do sinal de EEG durante as EEG_{TV} , EEG_{TVM} e EEG_{IM} apresentam uma semelhança com os parâmetros dos modelos dos sistemas obtidos a partir do sinal de EEG com $M=30$ trechos (Tabela 4.1, 4.2 e 4.3.).

Observe-se que os parâmetros do modelo AR obtidos a partir da promediação dos $M=10$ trechos do sinal de EEG são semelhantes aos parâmetros do sistema de EEG_{TV} com $M=30$ trechos. Ao passo que, os parâmetros do modelo ARX obtidos a partir da promediação do sinal de EEG durante a EEG_{TVM} e EEG_{IM} com o mesmo número de trechos ($M=10$), apresentam aumento na ordem dos modelos.

No caso dos parâmetros do modelo AR comparados com os parâmetros ARX obtidos a partir da promediação dos $M=5$ trechos do sinal de EEG (Tabela 4.1, 4.2 e 4.3.), também apresentam aumento na ordem dos modelos. Assim, deve ser notado que a modelagem do sistema a partir do sinal de EEG resultante da promediação de M trechos ($M < 10$), resulta em um aumento na ordem dos modelos devido ao fato que o modelo precisa de um número maior de parâmetros para descrever a dinâmica dominante do sistema.

A Figura 4.19 mostra a simulação dos modelos obtidos a partir da promediação do sinal de EEG durante a tarefa visual com $M=30$, $M=15$, $M=10$ e $M=5$, respectiva-

Tabela 4.1: Parâmetros do modelo AR do sistema de EEG durante a EEG_{TV} com $M=30$, 15, 10, 5 trechos.

Parâmetros AR	EEG_{TV}			
	$M = 30$	$M = 15$	$M = 10$	$M = 5$
a_1	5,53	5,52	5,51	5,50
a_2	-12,87	-12,82	-12,73	-12,73
a_3	16,11	16,01	15,84	15,84
a_4	-11,46	-11,36	-11,20	-11,20
a_5	4,39	4,35	4,27	4,27
a_6	-0,71	-0,70	-0,69	-0,68

Tabela 4.2: Parâmetros dos modelos ARX do sistema de EEG durante a EEG_{TVM} com $M=30$, 15, 10, 5 trechos.

Parâmetros ARX	EEG_{TVM}			
	$M = 30$	$M = 15$	$M = 10$	$M = 5$
c_1	4,88	4,87	4,85	4,74
c_2	-10,51	-10,48	-10,37	-10,68
c_3	10,26	10,20	12,83	12,75
c_4	-4,87	-4,86	-10,34	-10,58
c_5	1,42	1,38	6,42	6,56
c_6	-0,95	-0,93	-4,56	-4,47
c_7	-	-	1,11	1,07
c_8	-	-	-0,71	-0,72

Tabela 4.3: Parâmetros dos modelos ARX do sistema de EEG durante a EEG_{IM} com $M=30$, 15, 10, 5 trechos.

Parâmetros ARX	EEG_{IM}			
	$M = 30$	$M = 15$	$M = 10$	$M = 5$
c_1	4,89	4,91	4,79	4,71
c_2	-10,57	-10,55	-10,15	-10,18
c_3	10,21	10,29	12,45	12,53
c_4	-4,81	-4,80	-9,73	-9,92
c_5	1,45	1,42	4,98	4,46
c_6	-0,92	-0,94	-1,59	-1,23
c_7	-	-	-0,25	-0,27

mente. Observa-se que o sistema EEG_{TV} com $M=30$, $M=15$, $M=10$ e $M=5$ trechos, não apresentam componentes negativas, sendo elas uma das principais características do CNV.

A Figura 4.20 mostra a simulação dos modelos obtidos a partir da promediação do sinal de EEG durante a tarefa viso-motora com $M=30$, $M=15$, $M=10$ e $M=5$ trechos, respectivamente. A observação mais importante a ser feita aqui é que por meio da inspeção visual, o modelo que descreve o sistema EEG_{TVM} com $M=30$ trechos (Figura 4.20a), apresenta uma negatividade que caracteriza a componente CNV. Visualiza-se que o pico de máxima amplitude de $15,2 \mu V$ ocorre com o início do movimento. Tal característica não é observada no sistema EEG_{TVM} com $M=15$, $M=10$ e $M=5$ trechos, pois o pico de máxima amplitude é de $5 \mu V$ no início do movimento, mostrado na Figura 4.20b, c, d.

A Figura 4.21 mostra a simulação dos modelos obtidos a partir da promediação do sinal de EEG durante a tarefa imagética-motora com $M=30$, $M=15$, $M=10$ e $M=5$ trechos, respectivamente. Observa-se que o sistema EEG_{IM} com $M=30$ trechos (Figura 4.21a) apresenta uma componente CNV, característica similar ao que ocorre com o sistema EEG_{TVM} com um pico de máxima amplitude de $13,4 \mu V$. Utilizando a inspeção visual não é possível observar a componente CNV no sistema EEG_{IM} com $M=15$, $M=10$ e $M=5$ trechos, mostrado na Figura 4.21b, c, d.

4.3 Banco de Filtros de Kalman

É empregado um banco de dois FK em paralelo para detectar o PRE relacionado à imaginação do movimento do dedo indicador da mão esquerda utilizando as abordagens MMI e GPB1. Os modelos dos sistemas EEG_{TV} , EEG_{TVM} e EEG_{IM} obtidos na seção anterior são usados no FK para estimar os sinais de EEG durante as três tarefas mentais. Inicialmente, é analisado a estimativa do PRE durante a tarefa mental utilizando um único FK. Em seguida, é apresentado a estimativa do PRE fornecidas pelas abordagens baseadas em um banco de dois filtro de Kalman.

4.3.1 Filtro de Kalman

O filtro de Kalman é utilizado para estimar recursivamente o valor do sinal do EEG durante uma determinada tarefa mental. Neste trabalho, o sinal de EEG é estudado

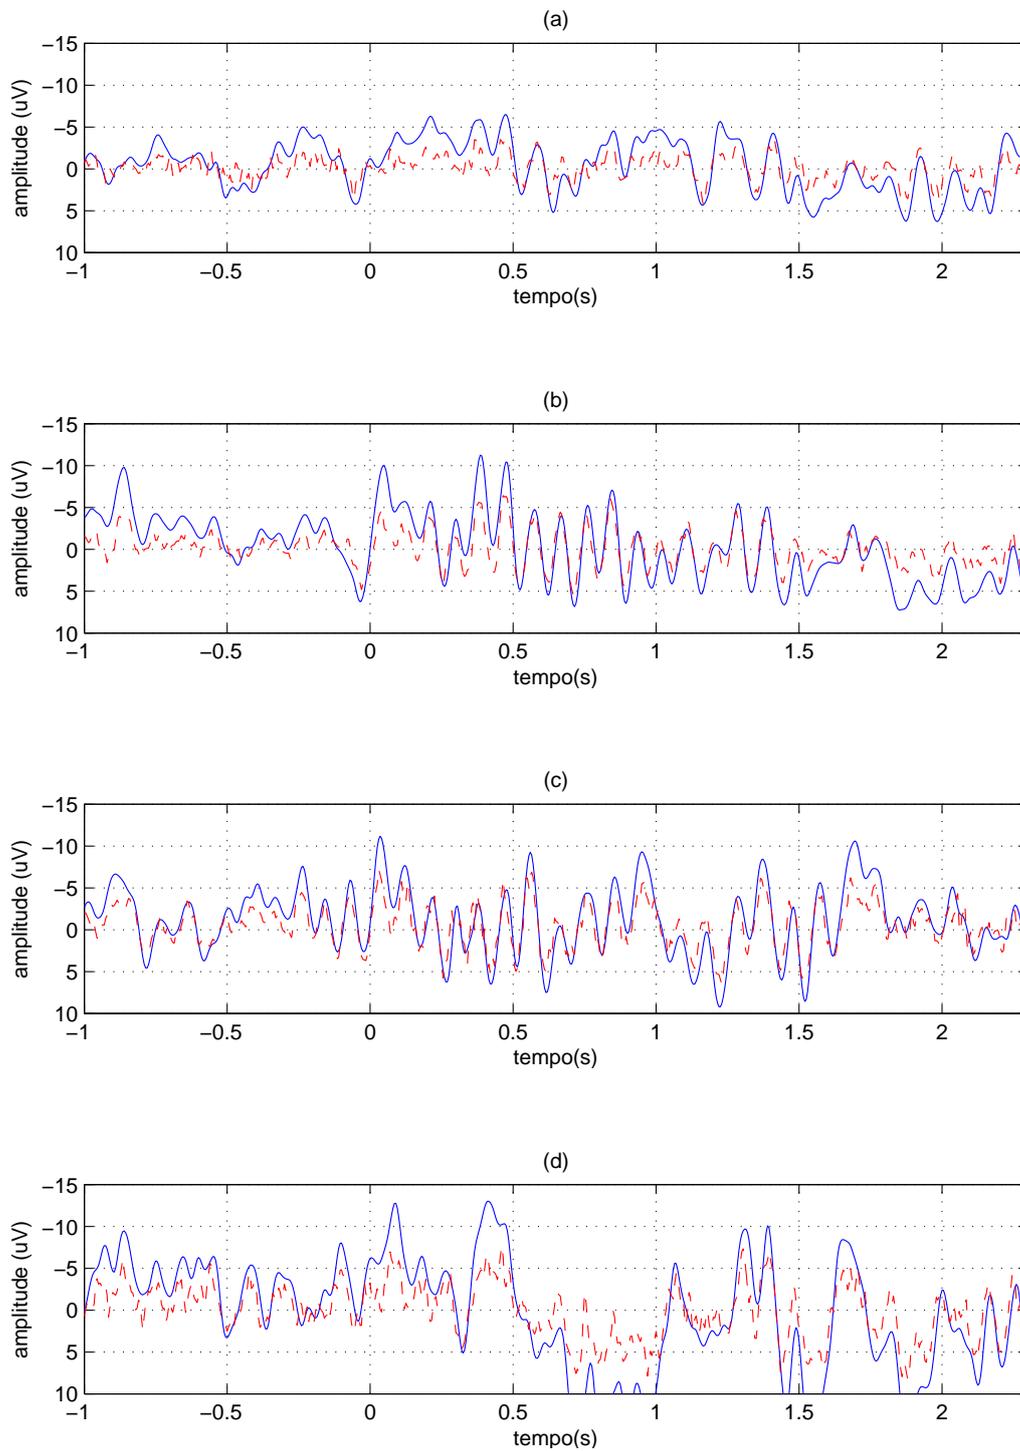


Figura 4.19: Simulação dos modelos obtidos a partir da promediação do sinal de EEG durante a tarefa EEG_{TV} com: (a) $M=30$, (b) $M=15$, (c) $M=10$ e (d) $M=5$ trechos. Os traçados mostram a promediação do sinal EEG_{TV} medido (Linha contínua azul) e a estimativa desse sinal (Linha tracejada vermelha).

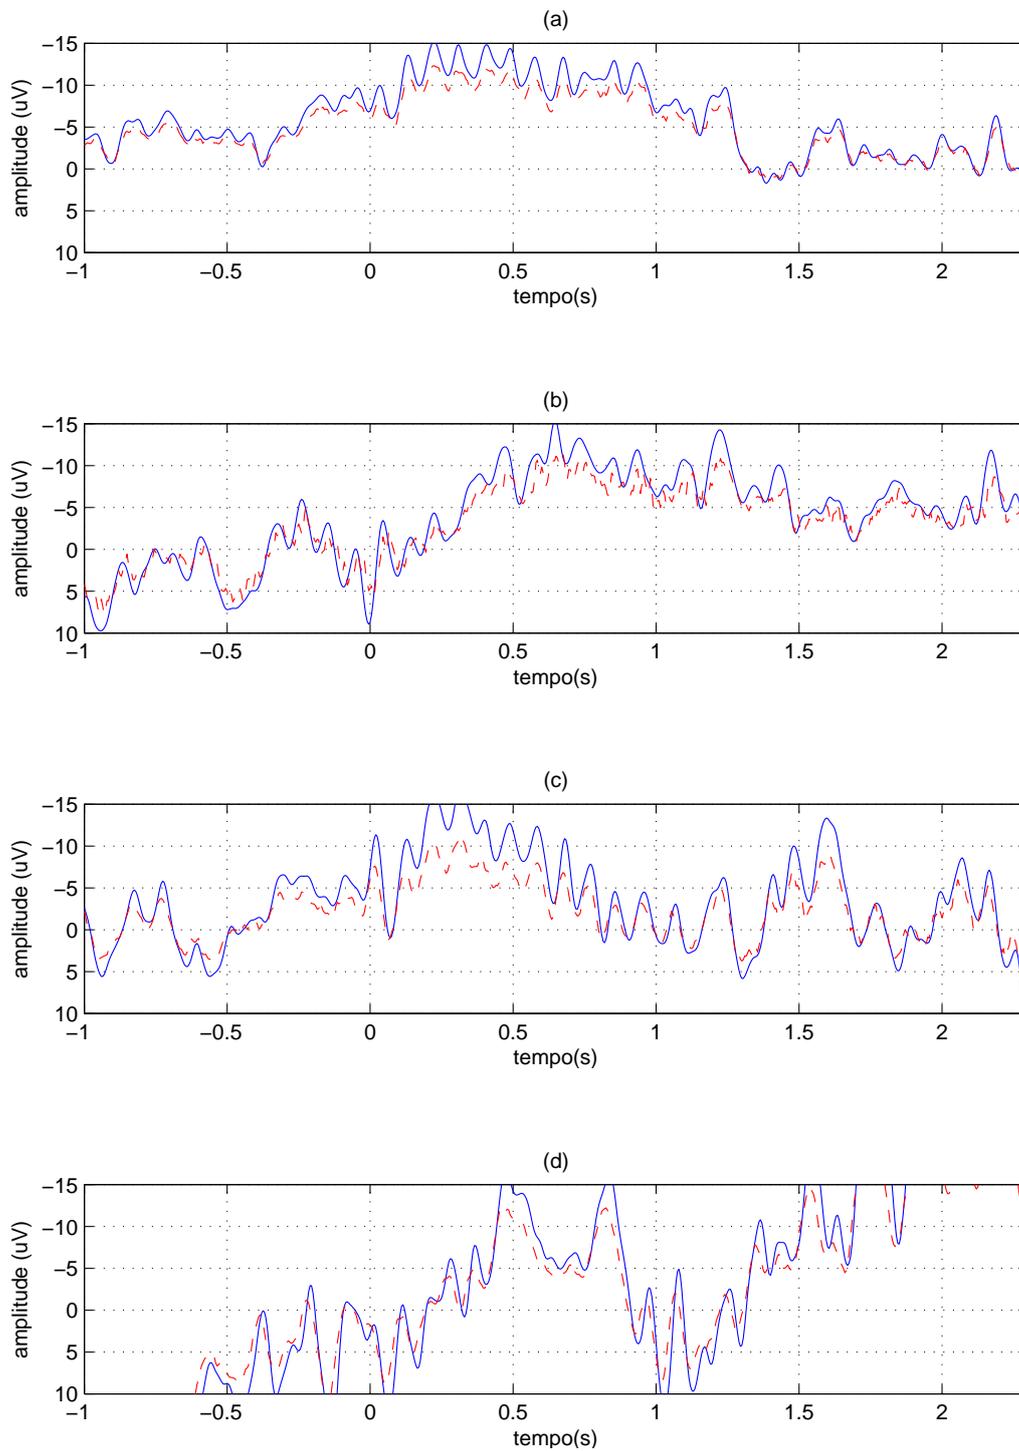


Figura 4.20: Simulação dos modelos obtidos a partir da promediação do sinal de EEG durante a tarefa EEG_{TVM} com: (a) $M=30$, (b) $M=15$, (c) $M=10$ e (d) $M=5$ trechos. Os traçados mostram a promediação do sinal EEG_{TVM} medido (Linha contínua azul) e a estimativa desse sinal (Linha tracejada vermelha).

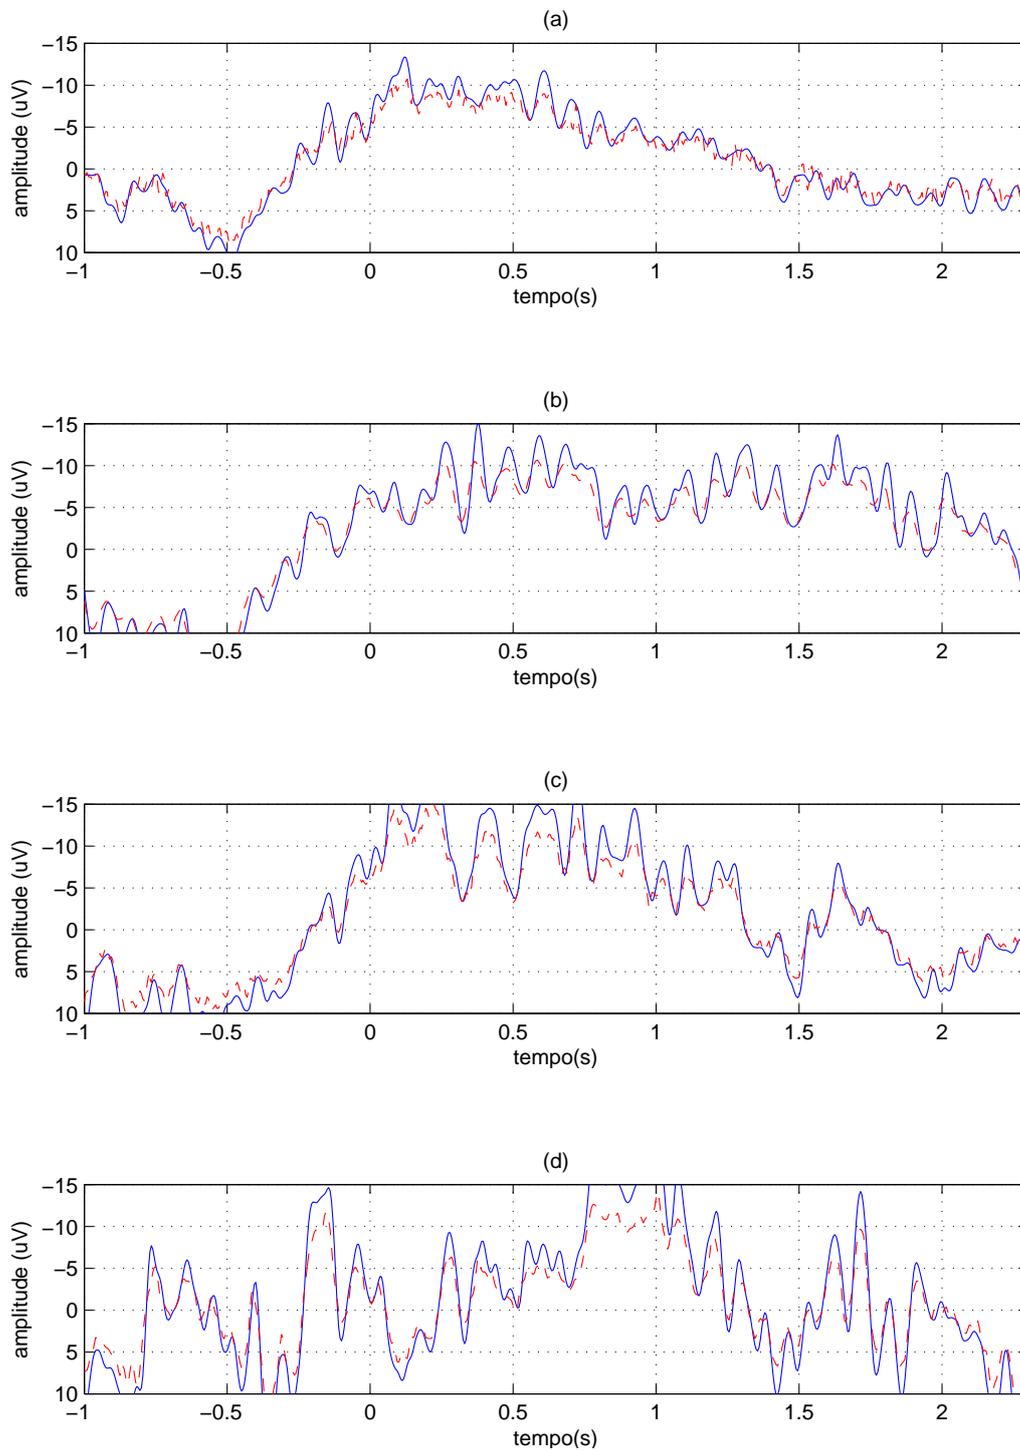


Figura 4.21: Simulação dos modelos obtidos a partir da promediação do sinal de EEG durante a tarefa EEG_{IM} com: (a) $M=30$, (b) $M=15$, (c) $M=10$ e (d) $M=5$ trechos. Os traçados mostram a promediação do sinal EEG_{IM} medido (Linha contínua azul) e a estimativa desse sinal (Linha tracejada vermelha).

durante as tarefas: EEG_{TV} , EEG_{TVM} e EEG_{IM} . O algoritmo de FK fornece uma estimativa do sinal de EEG durante uma determinada tarefa mental a partir dos valores das estimativas anteriores, as medições do sinal de EEG e os modelos identificados nas seções 4.2.1, 4.2.2 e 4.2.3.

Representação em Espaço de Estados dos Sistemas

Considera-se que a promediação do sinal registrado durante o EEG_{TVM} e EEG_{IM} apresenta duas componentes: sinal de EEG_{ESP} e o PRE; enquanto que o EEG_{TV} tem apenas o sinal de EEG_{ESP} . A fim de obter uma estimativa do sinal de EEG durante as diferentes tarefas mentais utilizando o FK, os modelos do sinal de EEG_{ESP} e PRE durante a EEG_{TVM} e EEG_{IM} devem ser representados em forma de espaço de estado.

Utilizando os modelos definidos nas seções 4.2.1, 4.2.2 e 4.2.3 pelas equações (4.3), (4.4), (4.5) são representados em espaços de estados como

$$\begin{aligned}
 x_{k+1} &= \begin{bmatrix} -5.53 & 12.87 & -16.11 & 11.46 & -4.39 & 0.712 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix} x_k + w_k \\
 y_k &= \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} + v_k
 \end{aligned} \tag{4.6}$$

e

$$\begin{aligned}
 x_{k+1} &= \begin{bmatrix} -4,88 & 10,51 & -10,26 & 4,87 & -1,42 & 0,95 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix} x_k + w_k \\
 y_k &= \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} + v_k
 \end{aligned} \tag{4.7}$$

em que a promediação dos sinais de EEG_{ESP} são representados pelo sistema (4.6) enquanto que o PRE relacionados ao movimento voluntário e imaginação do movimento são representados pelo sistema (4.7). Como já foi mencionado anteriormente, os parâmetros do modelo do sistema do sinal de EEG obtido a partir da promediação do sinal de EEG_{TVM} e EEG_{IM} são semelhantes. Como era esperado, o sistema de EEG durante a imaginação do movimento apresenta características dinâmicas similares ao que ocorre durante o movimento. A seguir, é discutido o algoritmo baseado em um único FK para estimar os sistemas EEG_{ESP} , EEG_{TVM} e EEG_{IM} .

O algoritmo do FK é utilizado para estimar os sinais de EEG_{TV} , EEG_{TVM} e EEG_{IM} na derivação Cz do indivíduo #2. Para efetuar a estimativa de cada sinal, segue-se o procedimento descrito na Seção 3.3. Inicialmente, são escolhidas arbitrariamente as condições iniciais, $\hat{x}_{0|0}$ como um valor relativo ao intervalo que o sinal pode variar enquanto que a matriz de covariância $P_{0|0}^{xx}$, por simplicidade, é definida como uma matriz identidade devido à baixa amplitude do sinal de EEG.

O ruído de processo Q_k é sintonizado de forma empírica e o ruído de medição R_k é sintonizado a partir de informações fornecidas pelas especificações de instrumentação. Particularmente, para o sinal de EEG_{TV} , o ruído de processo é $Q_k = 0,001I$, percebe-se que o valor da matriz é relativamente baixo devido à pouca incerteza que possui-se sobre o modelo. O ruído de medição é sintonizado como $R_k = 0,001$, determinado como o ruído inserido pelo equipamento que registra o sinal de EEG.

Estimativa do Sinal de EEG Durante a Tarefa Visual

A observação da Figura 4.22a revela que a estimativa do sistema EEG_{TV} utilizando o modelo 4.3 no FK descreve a dinâmica do sistema medido. Porém, existe um erro entre o sinal de EEG_{TV} medido e a estimativa obtida usando o FK, mostrado na Figura 4.22b.

Na Figura 4.22a, percebe-se que o sinal de EEG_{TV} não apresentou componentes negativas, sendo essa uma das principais características do CNV entre dois estímulos E1 - E2, pois, não houve variação na amplitude durante a EEG_{TV} . Esses resultados são mostrados na Tabela 4.4.

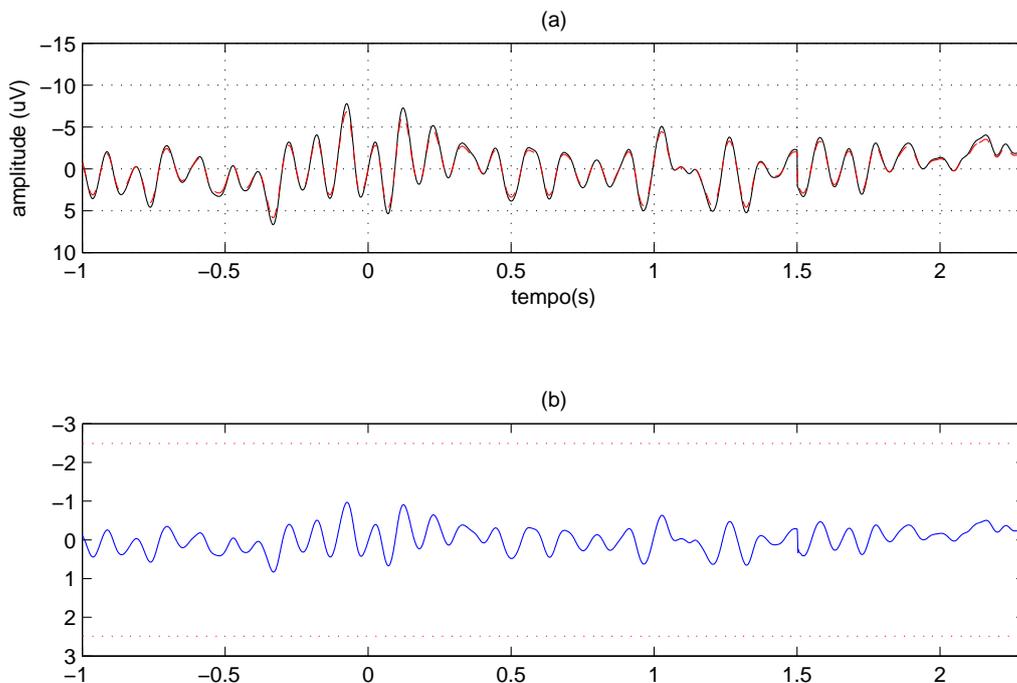


Figura 4.22: (a) Estimativa da promediação do sinal de EEG_{TV} fornecida pelo FK. Os traçados mostram a promediação do sinal de EEG_{TV} medido (Linha contínua preta) e a estimativa desse sinal (Linha tracejada vermelha). (b) Erro de estimativa da promediação do sinal de EEG_{TV} . O traçado em azul mostram o erro da estimativa e as linhas pontilhadas mostram mais e menos três desvios padrão em torno da estimativa.

Estimativa do Sinal de EEG Durante a Tarefa Viso-Motora

A Figura 4.23a mostra a estimativa da promediação do sinal de PRE relacionado ao movimento voluntário utilizando o modelo 4.4 no FK. Ao comparar a estimativa da promediação do sinal EEG_{TVM} com o sinal medido, percebe-se a presença de um erro mostrado na Figura 4.23b. Com relação ao Figura 4.23a, observa-se que a estimativa consegue acompanhar as oscilações da promediação do sinal de EEG_{TVM} . Tal sinal apresenta uma negatividade entre E1 ($t = -1s$) e E2 ($t = 0s$) que caracteriza a componente CNV. Esse potencial se inicia aproximadamente 1 segundo antes da execução do movimento. Após o início do movimento, é observado um declínio do sinal de PRE até atingir valores próximos a zero.

Outra característica da componente CNV é analisada na Figura 4.23a, o pico de máxima amplitude CNV que ocorre com o início do movimento voluntário. Percebe-se que o sinal EEG_{TVM} alcança um pico de máxima amplitude de $9,92\mu V$ em aproximadamente $-100ms$ e o pico de $9,33\mu V$ de amplitude em ($t=0$). Esses resultados são mostrados na Tabela 4.4.

Estimativa do Sinal de EEG Durante a Tarefa Imagética-Motora

A Figura 4.24a mostra a estimativa da promediação do PRE relacionado à imaginação do movimento utilizando o modelo 4.5 no FK, ao passo que a Figura 4.24b mostra o erro entre a promediação do sinal de PRE durante EEG_{IM} medido e a estimativa obtida usando o FK. Observa-se que a estimativa da promediação do sinal de PRE relacionado à imaginação do movimento apresenta uma forma de onda similar ao que ocorre durante o movimento voluntário como, uma componente negativa que inicia aproximadamente 1 segundo antes da imaginação do movimento. Após o início da imaginação, é observado um declínio do sinal de PRE até atingir valores próximos a zero.

Neste caso, o pico de máxima amplitude CNV ocorre com o início da imaginação do movimento. A Figura 4.24a mostra que a promediação do sinal de EEG_{IM} alcança um pico de máxima amplitude de $14\mu V$ em aproximadamente $300ms$ e o pico de $4\mu V$ de amplitude em ($t=0$). Esses resultados são mostrados na Tabela 4.5.

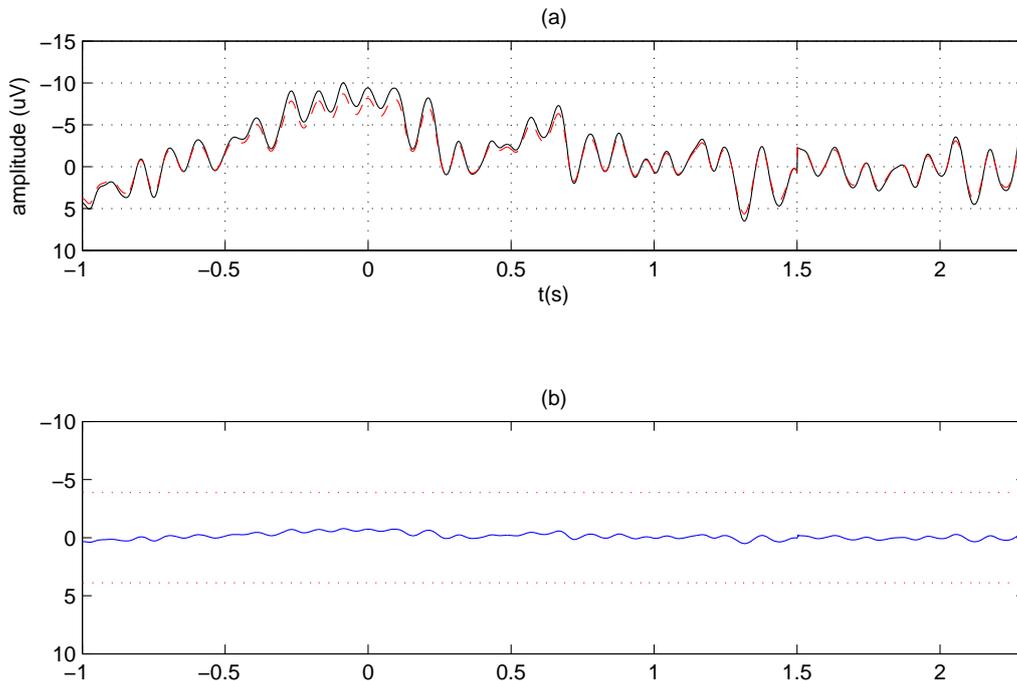


Figura 4.23: (a) Estimativa da promediação do sinal de EEG_{TVM} fornecida pelo FK. Os traçados mostram a promediação do sinal de EEG_{TVM} medido (Linha contínua preta) e a estimativa desse sinal (Linha tracejada vermelha). (b) Erro de estimativa da promediação do sinal de EEG_{TVM} . O traçado em azul mostram o erro da estimativa e as linhas pontilhadas mostram mais e menos três desvios padrão em torno da estimativa.

Com a aplicação do FK é estimado o PRE provocado por uma tarefa motora, caracterizado por uma componente negativa que precede uma determinada tarefa mental, tanto para a promediação do sinal de EEG_{TVM} quanto para o EEG_{IM} corroborando os resultados do sinal de PRE relatados por [Von Spreckelsen, 1988; Georgiadis, S. D., Ranta-aho, P. O., Tarvainen, M. P., Karjalainen, P. A, 2005].

Portanto, a partir da análise dos resultados obtidos pelas estimativas da promediação do PRE durante as tarefas EEG_{TVM} e EEG_{IM} , observa-se que a promediação do sinal de PRE relacionado à imaginação do movimento possui uma forma de onda parecida à promediação do sinal de PRE relacionado ao movimento voluntário. Dessa forma, na próxima etapa deste trabalho, apenas é considerada a análise da resposta obtida pelo potencial relacionado à imaginação do movimento.

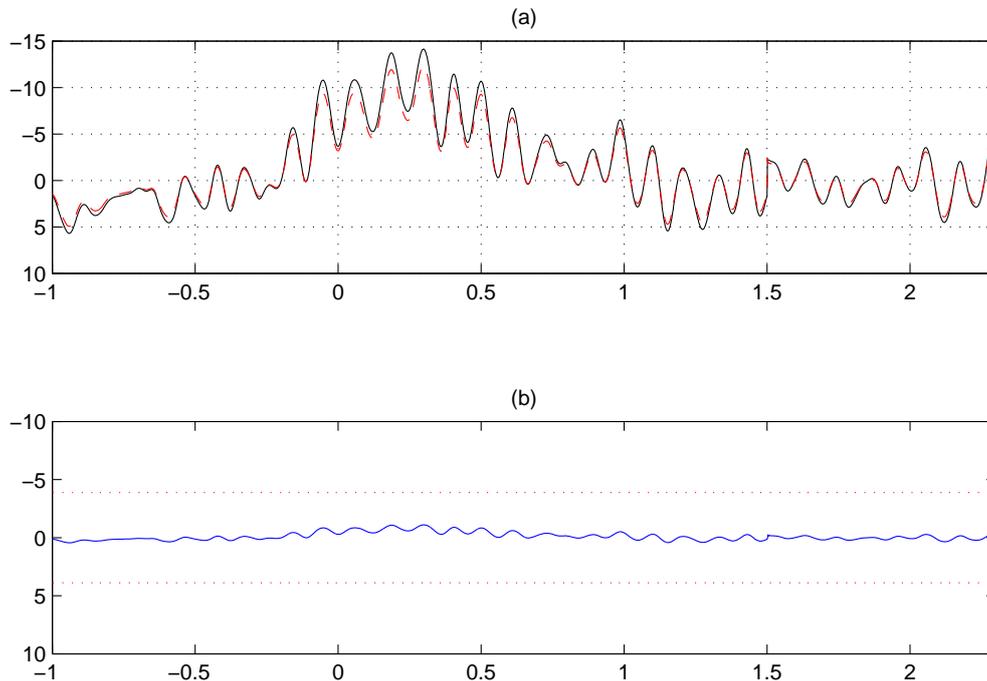


Figura 4.24: (a) Estimativa da promediação do sinal de EEG_{IM} fornecida pelo FK. Os traçados mostram a promediação do sinal de EEG_{IM} medido (Linha contínua preta) e a estimativa desse sinal (Linha tracejada vermelha). (b) Erro de estimativa da promediação do sinal de EEG_{IM} . O traçado em azul mostram o erro da estimativa e as linhas pontilhadas mostram mais e menos três desvios padrão em torno da estimativa.

4.3.2 Banco Interativo de Filtros de Kalman

O BIFK é utilizado para classificar o sinal de PRE relacionado à imaginação do movimento na derivação Cz. O BIFK é baseado em modelos identificados (4.3), (4.5) a partir da promediação do sinal de EEG durante as tarefas mentais. Esses modelos são utilizados na implementação de cada FK. No primeiro FK é utilizado o modelo (4.3) para fornecer a estimativa da promediação do sinal de EEG_{TV} , ao passo que, no segundo FK é implementado o modelo (4.5) para fornecer a estimativa da promediação do sinal de EEG_{IM} . Assim, cada FK foi sintonizado como mostrado na seção passada. Finalmente, o BIFK combina as duas estimativas para obter a estimativa do PRE durante a imaginação do movimento.

A Figura 4.25a mostra os pesos de cada FK γ_k^s . Os pesos são utilizados para classificar a tarefa mental realizada pelo indivíduo. O traçado em preto mostra que é detectado o

signal de EEG_{IM} com um 80% de certeza comparado ao 20% do signal de EEG_{TV} traçado em azul durante 3,5 segundos. Após, esse intervalo de tempo, os sinais de EEG durante as duas tarefas são alternados. Percebe-se que depois de 3,5 segundos é detectado o signal de EEG_{TV} com um 80% de certeza comparado ao 20% do signal de EEG_{IM} .

A Figura 4.25b,c mostram a estimativa da promediação do PRE relacionado à imaginação do movimento obtida utilizando o BIFK. Observa-se que a estimativa da promediação do signal de PRE durante a EEG_{IM} apresenta as mesmas características na forma de onda discutidas na seção anterior. Já na Figura 4.25d mostra-se o erro entre a promediação do signal de PRE relacionado à imaginação do movimento e a estimativa do PRE usando o BIFK.

A Tabela 4.6 mostra a estimativa do pico de máxima amplitude CNV obtido utilizando o BIFK. Observa-se que a promediação do signal de PRE relacionado à imaginação do movimento alcança um pico de máxima amplitude de $11,65\mu V$ em aproximadamente $-100ms$ e o pico de $6,47\mu V$ de amplitude em ($t = 0$). A estimativa do pico de máxima amplitude utilizando o BIFK é de $8,84\mu V$.

Também é testado o banco de filtro de Kalman baseado no algoritmo GPB1 (BGFK). Esse algoritmo é utilizado para comparar a estimativa obtida utilizando o BIFK. O ruído de processo e medição dos FK são sintonizados com os mesmos valores definidos no BIFK.

A Figura 4.26 mostra a estimativa da promediação do PRE relacionado à imaginação do movimento utilizando o BGFK. Observa-se que a estimativa fornecida pelo BGFK consegue acompanhar a promediação do signal de PRE durante a tarefa imagética-motora. Essa estimativa apresenta as mesmas características achadas usando o BIFK. Observa-se que a estimativa do pico de máxima amplitude utilizando o BGFK é de $7,19\mu V$ (Tabela 4.6).

A Figura 4.27 mostra a comparação das estimativas da promediação do signal de PRE relacionado com a imaginação do movimento fornecidas pelos algoritmos: FK, BGFK e BIFK na derivação Cz do indivíduo #2. Observa-se que a promediação do signal de PRE estimado por meio das diferentes abordagens acompanha a promediação do signal de PRE medido. Como já foi descrito anteriormente, as estimativas possuem uma forma

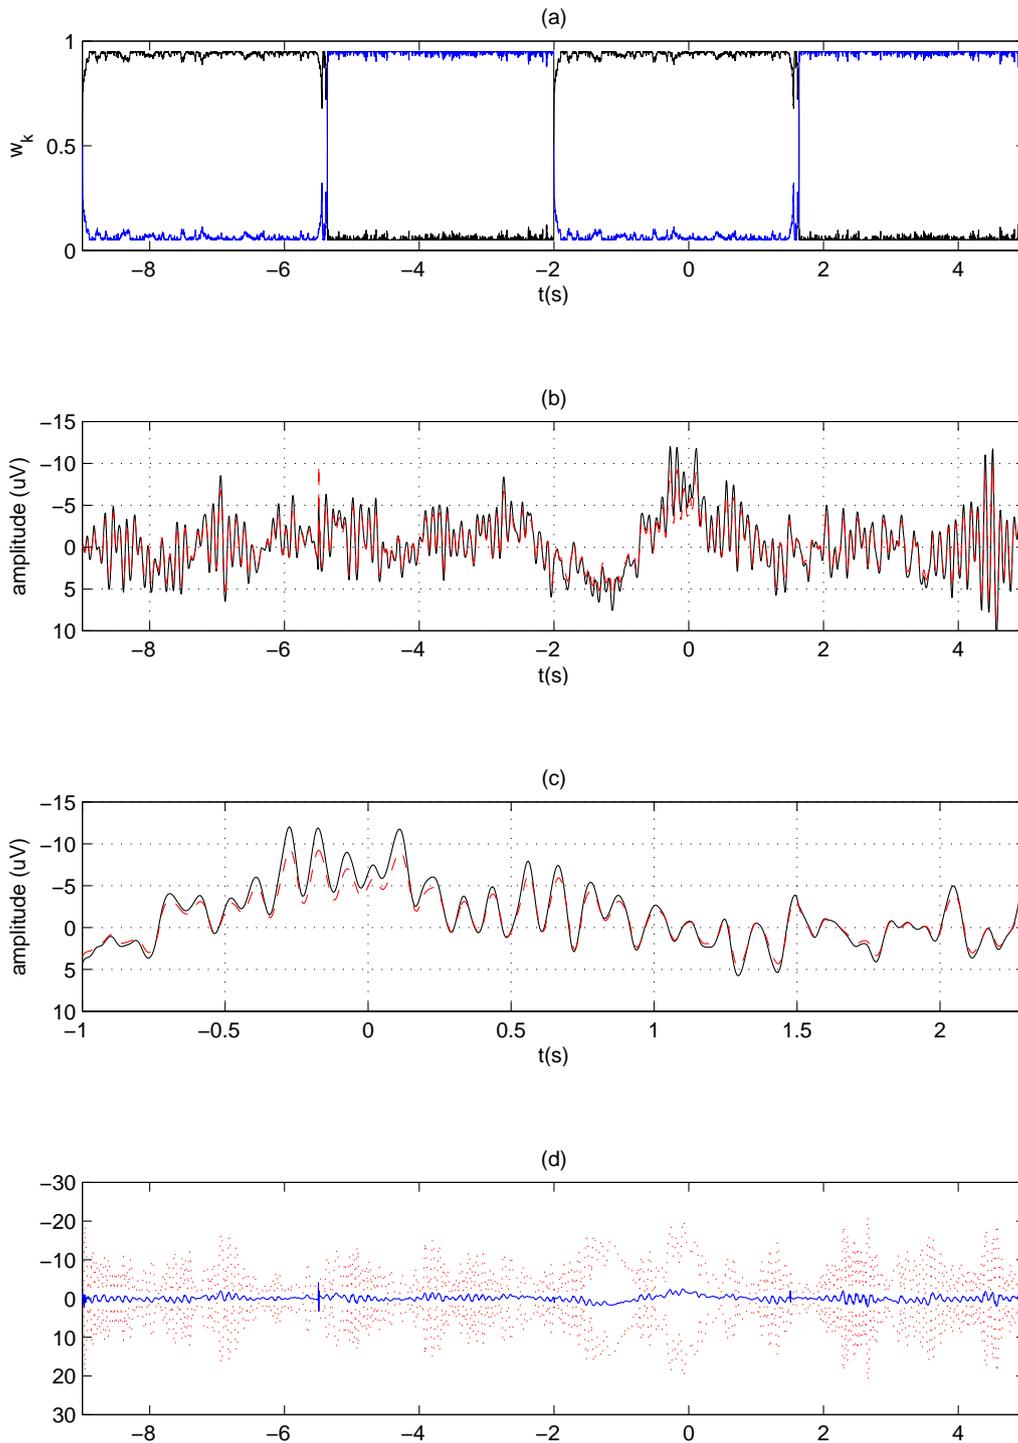


Figura 4.25: (a) Pesos de cada FK utilizando a abordagem BIFK. Os traçados em preto indicam o peso da promediação do sinal de EEG_{IM} enquanto que os traçados em azul mostram o peso do sinal de EEG_{TV} , (b) Estimativa da promediação do sinal de PRE relacionada à imaginação do movimento utilizando o BIFK. A linha contínua preta é a promediação do sinal de PRE medido e a estimativa da promediação do sinal em linha tracejada vermelha, (c) Zoom da estimativa no intervalo $t = -1s$ e $t = 2,3s$, (d) Erro de estimativa do BIFK. O traçado em azul mostra o erro de estimativa e as linhas pontilhadas em vermelho indicam mais e menos três desvios padrão da estimativa.

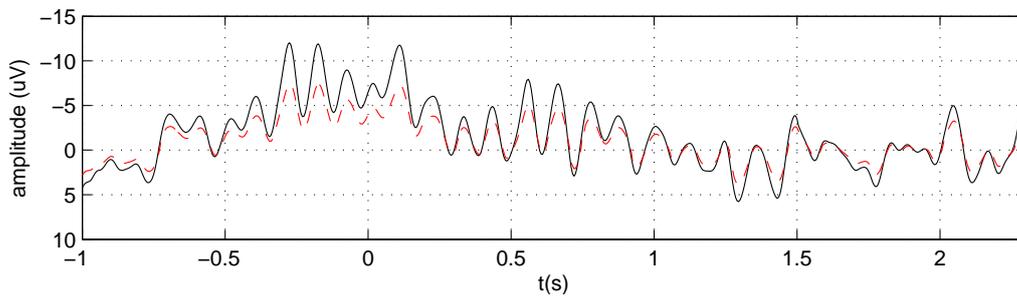


Figura 4.26: Estimativa da promediação do sinal de PRE relacionada à imaginação do movimento utilizando o BGFK. A linha contínua preta é a promediação do sinal de PRE medido e a estimativa do sinal em linha tracejada vermelha.

de onda parecida com o PRE relacionado com a imaginação do movimento. Em termos de estimativa, o FK apresenta uma melhor estimativa com relação aos dois banco de filtros de Kalman, pois, o FK é implementado com apenas o modelo do sistema EEG_{IM} , diminuindo a incerteza da estimativa. Ao passo que, o BIFK e BGFK estão compostos por dois FK em paralelo, cada um dos FK é implementado com um modelo do sistema EEG_{TV} e EEG_{IM} . Conseqüentemente, a incerteza da estimativa aumenta pela interação de dos possíveis modelos do sistema EEG_{TV} ou EEG_{IM} .

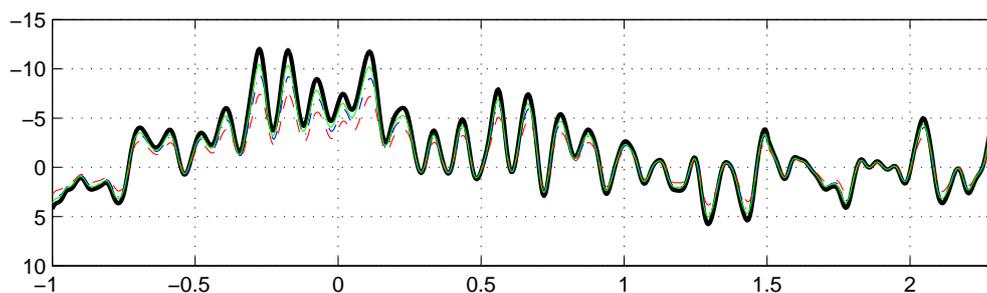


Figura 4.27: Comparando as estimativas: da promediação do sinal de PRE relacionado com a imaginação do movimento medida (linha preta), FK (linha contínua verde), BIFK (linha pontilhada azul), BGFK (linha tracejada vermelha).

4.4 Síntese Comparativa dos Resultados

Nesta seção, é analisado o comportamento da promediação dos sinais de EEG durante as tarefas mentais de todos os indivíduos participantes do estudo (seis homens e uma mulher) utilizando os modelos obtidos a partir do sinal de EEG_{TV} , EEG_{TVM} e EEG_{IM} na derivação Cz do indivíduo #2. É importante fazer a seguinte observação, os algoritmos do FK, BIFK e BGFK continuam usando os modelos (4.3), (4.4) e (4.5) associados ao indivíduo #2.

Neste trabalho, utiliza-se várias investigações com o intuito de comparar alguns resultados, dois casos são avaliados: i) qualidade da estimativa do pico CNV durante as três tarefas mentais utilizando o FK, BIFK e BGFK, ii) efeito da variação do número de trechos na classificação do potencial relacionado à imaginação do movimento.

4.4.1 Estimativa do Pico CNV

A Tabela 4.4 mostra os valores dos picos de amplitude máxima CNV que ocorrem com o início do movimento ($t = 0s$) para os sete indivíduos. Observa-se um incremento da amplitude (módulo) do sinal de EEG_{TVM} comparado com o sinal de EEG_{TV} indicando uma resposta motora. Essa mesma característica (incremento de amplitude) apresenta-se no sinal de EEG_{IM} , de maneira similar ao que ocorre durante o movimento, mostrado na Tabela 4.5. Assim, o pico CNV obtido com a promediação dos sinais medidos de EEG_{TVM} e EEG_{IM} são utilizados como referência para comparar a estimativa do pico CNV obtida utilizando o FK durante a tarefa EEG_{TVM} e EEG_{IM} .

Na Tabela 4.4, percebe-se que a componente de CNV obtida durante a tarefa de EEG_{TVM} apresenta maiores amplitudes na maioria dos indivíduos analisados (quatro dos sete indivíduos - S2, S3, S4, S5). Os três indivíduos (S1, S6, S7) que não apresentam o pico negativo de CNV está relacionado a diversos fatores, que podem alterar a RSR. Os fatores podem ser de diferente natureza como fisiológicos, de instrumentação, nível de concentração e estresse durante a coleta.

Observa-se nas Tabelas 4.4 e 4.5, que os resultados obtidos da estimativa do pico CNV durante a EEG_{TVM} e EEG_{IM} para os sete indivíduos fornecida pelo FK apresentam

um erro médio de estimativa de 13,2% e 13,1%, respectivamente, com relação ao pico CNV medido. Percebe-se que o erro das duas estimativas é pequeno devido à pouca incerteza na estimativa.

Posteriormente, os resultados obtidos da componente de CNV durante o sinal de EEG_{IM} são comparados com o sinal de EEG_{TVM} (Tabela 4.5). Observa-se que a componente de CNV durante o sinal de EEG_{IM} também mostram um incremento de amplitude na maioria dos indivíduos analisados (quatro dos sete indivíduos). Os três indivíduos que não apresentaram o pico negativo de CNV podem estar relacionado a uma menor capacidade de imaginação. Como já foi mencionado anteriormente, os resultados obtidos com o sinal de EEG_{IM} apresentam as mesmas características que o sinal de EEG_{TVM} .

Da mesma forma, os resultados obtidos utilizando o FK para estimar o pico CNV durante a tarefa EEG_{IM} são comparados com o pico CNV medido durante a tarefa EEG_{IM} para os sete indivíduos. Esses resultados apresentam um erro médio da estimativa dos sete indivíduos de 13% com relação ao pico CNV medido (Tabela 4.5). Assim, para diminuir o erro de 13% pode-se tentar sintonizar a matriz de covariância do ruído de processo e ruído de medição.

Tabela 4.4: Valores dos picos CNV (em $t = 0s$) da promediação do sinal de EEG_{TV} e EEG_{TVM} comparados com a estimativa fornecida por um único FK.

Indivíduo	EEG_{TV}	EEG_{TVM}	FK	$Erro_{FK}(\%)$
S1	-3,91	4,26	3,69	13,26
S2	-7,78	-10,02	-8,69	13,24
S3	-6,83	-10,38	-9,01	13,23
S4	-4,30	-7,08	-6,14	13,22
S5	-2,27	-8,41	-7,29	13,25
S6	-4,82	0,77	0,66	13,37
S7	2,69	5,95	5,17	13,01

A Tabela 4.6 mostra as estimativas dos picos de amplitude máxima CNV para os sete indivíduos obtidos durante a tarefa EEG_{IM} utilizando o BGFK e BIFK. Os registros da promediação dos sinais de EEG_{TV} e EEG_{IM} são utilizados como referência para comparar as estimativas do pico CNV fornecidas pelo BGFK e BIFK. Esses resultados apresentam um incremento da amplitude do sinal de EEG_{IM} comparado com o sinal de

Tabela 4.5: Valores dos picos CNV (em $t = 0s$) da promediação do sinal de EEG_{TV} e EEG_{IM} comparados com a estimativa fornecida por um único FK.

Indivíduo	EEG_{TV}	EEG_{IM}	FK	$Erro_{FK}(\%)$
S1	-3,91	-5,32	-4,64	12,71
S2	-7,78	-10,83	-9,39	13,21
S3	-6,83	-10,49	-9,10	13,25
S4	-4,30	-6,63	-5,74	13,24
S5	-2,27	-17,99	-15,61	13,24
S6	-4,82	-0,74	-0,64	13,08
S7	2,69	2,69	2,34	13,31

Tabela 4.6: Valores dos picos CNV (em $t = 0s$) durante o sinal de EEG_{TV} e EEG_{IM} comparados com a estimativa fornecida pelo BGFK e BIFK.

Indivíduo	EEG_{TV}	EEG_{IM}	BGFK	$Erro_{BGFK}(\%)$	BIFK	$Erro_{BIFK}(\%)$
S1	-5,47	1,33	0,89	32,64	1,09	17,37
S2	-8,92	-11,65	-7,19	39,19	-8,84	23,42
S3	-4,69	-6,96	-4,33	37,86	-5,43	21,93
S4	-1,37	-7,09	-4,40	37,91	-5,53	21,98
S5	-0,91	-6,19	-3,90	37,03	-4,91	20,78
S6	-4,82	-3,35	-2,18	34,73	-2,72	18,77
S7	2,67	9,39	5,69	39,43	7,15	23,96

EEG_{TV} indicando a presença de uma resposta motora.

Os resultados das estimativas do pico CNV obtidas utilizando o BGFK e BIFK (Tabela 4.6), apresentam um incremento da amplitude da promediação do sinal de EEG_{IM} comparado com a promediação do sinal de EEG_{TV} na maioria dos indivíduos analisados (cinco de sete indivíduos - S2, S3, S4, S5, S7). Os dois indivíduos (S1, S6) que não apresentam o pico CNV podem ser relacionados aos fatores descritos anteriormente.

A Tabela 4.6 mostra a estimativa do pico CNV da promediação do sinal de EEG_{IM} para os sete indivíduos apresentam um erro médio da estimativa de 38% e 22% utilizando BGFK e BIFK, respectivamente. Percebe-se que os resultados apresentam um menor erro de estimativa utilizando o BIFK comparado com o BGFK, este fato pode ser explicado devido à etapa de interação dos dois FK que geram as estimativas prévias a partir da estimativa obtida pelo BIFK. Assim, o BIFK apresenta melhor precisão na

estimativa do PRE durante a imaginação do movimento.

A Figura 4.28 mostra o índice RMSE das estimativas fornecidas pelas abordagens do BGFK e BIFK para o sinal de EEG_{IM} na derivação Cz dos sete indivíduos. Observa-se que utilizando o índice RMSE para os sete indivíduos apresentam um erro de estimativa de 38% e 20% fornecida pelo BGFK e BIFK, respectivamente. Esses resultados são obtidos utilizando o modelo obtido a partir da promediação dos sinais de EEG do indivíduo #2.

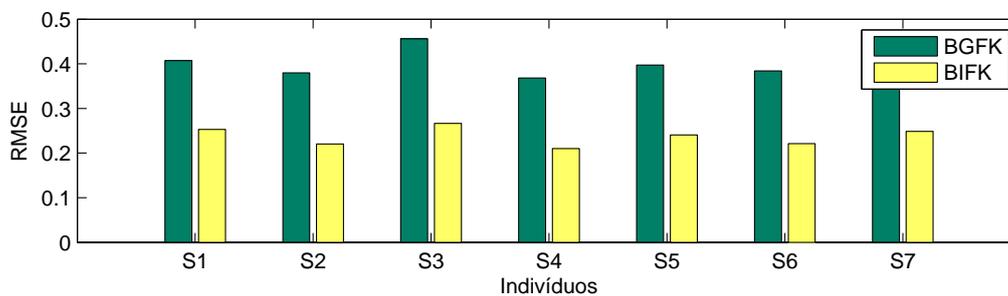


Figura 4.28: Índice RMSE das estimativas fornecidas pelas abordagens de BGFK e BIFK para a promediação do sinal de EEG_{IM} na derivação Cz dos sete indivíduos com $M=30$ trechos.

4.4.2 Efeito da Variação do Número de Trechos na Classificação do EEG_{IM}

A Tabela 4.7 mostra a taxa de acerto do classificador BIFK variando o número de trechos para os sete indivíduos. Para calcular a taxa de acerto são executadas 20 repetições do algoritmo BIFK. A variação do número de trechos é $M=30$, $M=15$, $M=10$, $M=5$ e $M=1$. Observa-se que com $M=30$ trechos, os indivíduos (S2, S3, S4, S5) apresentam uma taxa de acerto de 92%, 89%, 94%, 90%, respectivamente. Ao passo que, os indivíduos (S1, S6, S7) mostram uma baixa taxa de acerto 65%, 54%, 67%, respectivamente. Esse resultado está relacionado com a capacidade de imaginação do indivíduo.

Na Tabela 4.7, observa-se que a medida que diminui o número de trechos, também diminui a taxa de acerto do classificador. Pode-se perceber que os modelos (4.3) e (4.5)

dos sistemas EEG_{TV} e EEG_{IM} com $M=30$ trechos não descrevem a dinâmica presente nos sistemas com um número menor de trechos. Nesse caso, é necessário ajustar os modelos dos sistemas EEG_{TV} e EEG_{IM} com $M=30$ trechos com o intuito de incorporar as características dinâmicas presentes nos sistemas com $M=10$, $M=5$ e $M=1$ trechos.

Tabela 4.7: Classificação do potencial relacionado à imaginação do movimento utilizando o BIFK para os sete indivíduos utilizando o mesmo modelo AR/ARX (vertical) e variando o número de trechos (horizontal).

Indivíduo	Taxa de acerto (%)				
	$M = 30$	$M = 15$	$M = 10$	$M = 5$	$M = 1$
S1	65	45	39	31	25
S2	92	74	62	49	38
S3	89	72	67	31	34
S4	94	67	59	44	28
S5	90	71	60	47	35
S6	54	32	41	21	35
S7	67	38	23	12	17

Conclusões e Trabalhos Futuros

“Descobrir consiste em olhar para o que todo mundo está vendo e pensar em uma coisa diferente.”

Roger Von Oech

5.1 Considerações Finais

Esta dissertação se propôs a detecção e estimativa do potencial relacionado à imaginação do movimento do dedo indicador da mão esquerda utilizando registros do sinal de EEG durante a tarefa imagética-motora (derivação Cz). Para isso, empregou-se o banco interativo de filtros de Kalman (BIKF). A metodologia do BIFK compreende duas etapas, uma de modelagem e outra de estimação recursiva. Assim, os sinais de EEG são utilizados para obter modelos a partir da promediação do sinal de EEG durante as tarefas: visual, viso-motora e imagética-motora. Esses modelos são utilizados no FK para estimar a promediação dos sinais de EEG durante as três tarefas. A partir da análise das componentes pré-evento, como contingente de variação negativa (CNV), é possível identificar o PRE motor provocado por uma determinada tarefa (EEG_{TVM} e EEG_{IM}) por meio de uma inspeção visual. Entretanto, o BIFK é utilizado como um método de classificação automática dos sinais de EEG durante a tarefa visual e imagética-motora.

Modelos lineares auto-regressivo (AR) e auto-regressivo com entradas externas (ARX) foram obtidos a fim de caracterizar a dinâmica dos sistemas EEG_{TV} , EEG_{TVM} e EEG_{IM} . Os modelos descrevem a tendência da promediação dos sinais de EEG_{TV} , EEG_{TVM} e EEG_{IM} . O sistema EEG_{TV} não apresenta componentes negativas CNV, ao passo que, os sistemas EEG_{TVM} e EEG_{IM} apresentam uma negatividade CNV (aumento

de amplitude) entre os dois estímulos E1 e E2 (E1, LED amarelo acionado e E2, dois LEDs são desligados). As métricas k -passos à frente, índice RMSE e análise de resíduos sugerem que esses modelos incorporam a dinâmica dominante dos sinais medidos. Nessa etapa, observaram-se indícios de que o comportamento dinâmico do sistema EEG_{IM} apresenta as mesmas características do sistema EEG_{TVM} . Além disso, sugere-se que os modelos dos sistemas EEG_{TV} , EEG_{TVM} e EEG_{IM} obtidos a partir da promediação do sinal de EEG ($M=30$ trechos) de um determinado indivíduo representam o comportamento dinâmico de todos os indivíduos participantes do estudo. Com relação aos modelos obtidos a partir da promediação do sinal de EEG ($M=15$, $M=10$ e $M=5$ trechos) de um determinado indivíduo, observa-se que não é possível representar as características dinâmicas dos sistemas EEG_{TV} , EEG_{TVM} e EEG_{IM} . Consequentemente, esses modelos não representam o comportamento de todos os indivíduos participantes do estudo.

O BIFK produz uma estimativa do sinal de EEG ao longo do tempo e detecta o padrão do PRE relacionado com a imaginação do movimento por meio dos pesos obtidos a cada estimativa. O peso é uma medida de probabilidade de ocorrência da tarefa EEG_{TV} ou EEG_{IM} . Essa medida determina quando foi executada a imaginação do movimento do dedo indicador da mão esquerda. Desta forma, a classificação desse padrão está relacionada com o número de repetições da tarefa imagética-motora EEG_{IM} . Os modelos AR e ARX obtidos a partir da promediação dos trechos do sinal de EEG com $M=15$, $M=10$ e $M=5$ durante essa tarefa apresentam uma menor taxa de acerto, 74%, 62% e 49%, respectivamente, em comparação com o 92% obtido com a promediação do sinal de EEG com $M=30$ trechos. Apesar do baixo desempenho mostrado na classificação de PRE com menor número de repetições, a ICM se tornaria mais rápida, pois o indivíduo executaria com menor número de repetições a mesma tarefa. Com relação à taxa de acerto, o BIFK apresenta uma taxa de acerto de 92% com $M=30$ trechos, esse resultado é comparado com estudos desenvolvidos no laboratório NEPEB mostrando similares resultados, por exemplo, a aplicação da MSC associada à técnica de derivação da fonte proporcionou uma probabilidade de detecção de 99,6% para $M=40$ trechos [Santos Filho, 2010], modelo ocultos de Markov e redes neurais artificiais

apresentam taxas de acerto de 73,0% e 79,5%, respectivamente, para M=45 trechos [Souza, 2010], a prática mental associada à máquina de vetores de suporte apresenta uma taxa de acerto de 98% para M=45 trechos [Erazo-Costa, 2012]. Entretanto, o BIFK utiliza um menor número de trechos na classificação de padrões da imaginação do movimento. Com relação a estimativa, o BIFK estima simultaneamente a promediação dos sinais de EEG durante as tarefas visual e imaginação do movimento. Estudos desenvolvidos na literatura [Von Spreckelsen, 1988; Georgiadis, S. D., Ranta-aho, P. O., Tarvainen, M. P., Karjalainen, P. A, 2005] utilizam um único filtro de Kalman para estimar apenas um sinal de EEG. Assim, o BIFK mostra-se como um método promissor para a detecção e estimativa de potenciais relacionados à imaginação do movimento.

5.2 Propostas de Continuidade

Os resultados obtidos neste trabalho mostram que o BIFK tem-se revelado como uma ferramenta promissora para a detecção de padrões da imaginação do movimento, viabilizando a sua utilização em aplicações de ICMS. Ao longo do trabalho realizado, algumas propostas de continuidade deste estudo foram levantadas. Entre elas, pode-se destacar:

- Emprego de modelos não-lineares para melhorar a estimativa do filtro de Kalman utilizando os registros dos sinais de EEG.
- Obter modelos matemáticos a partir do *grand average* dos PRE's relacionados à imaginação do movimento utilizando as derivações centrais e frontais.
- Detectar as componentes após a execução da tarefa, como N2 e P300.
- Estudo mais apurado a respeito do mesmo modelo matemático ser usado para outros indivíduos. É possível obter um modelo para certos grupos de indivíduos?
- Aplicar um método de otimização para sintonizar as matrizes de covariância de ruído de processo e medição do FK.

Referências Bibliográficas

- Aguirre, L. A. (2004). *Introdução à identificação de sistemas. Técnicas lineares e não lineares aplicadas a sistemas reais.*
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transaction on Automatic Control*, 19(6):716–723.
- Anghinanh R., Basile L., Schimdt M. T., Sameshina K., G. W. (2006). Artefatos biológicos no EEG quantitativo. *Arquivos de Neuro-psiquiatria*, 64(2A):264–268.
- Arnold, M., Miltner, W. H. R., Witte, H., Bauer, R., and Braun, C. (1998). Adaptive AR Modeling of Nonstationary Time Series by Means of Kalman Filtering. *IEEE Transaction on Biomedical Engineering*, 45(5):553–562.
- Aufrichtigl, R. and Pedersenl, S. B. (1992). Order estimation and model verification in Autoregressive modeling of EEG sleep recordings. *Engineering in Medicine and Biology Society*, 6:2653–2654.
- Bar-Shalom Y., Li X. R., K. T. (2001). *Estimation with Applications to Tracking and Navigation.* New York, wiley-inte edition.
- Bayliss, J. D. (2001). *A flexible Brain-Computer Interface.* PhD thesis, University of Rochester, New York, EUA.
- Bear, M. F., Connors, B. W., Maradiso, M. A. (2002). *Neurociências Desvendando o sistema nervoso.* Nova York: John Wiley Sons, 2th edition.
- Berne, R. M., L. M. N. (1998). *Fisiologia.* Rio de Janeiro, 4th edition.
- Billings, S A. Tao, Q. H. (1991). Model validation test for nonlinear signal processing applications. *International Journal of Control*, 54:157–194.
- Braga E., Braga N., G. G. S. (2006). Potencial evocado a Estímulo Elétrico Senoidal de 2 kHz usando Wavelet. *Anais do XVII Congresso Brasileiro de Engenharia Biomédica - São Pedro (SP).*

- Britton, J., Jervis, B. W., and Grunewald, R. A. (2000). Extracting single trial event related potentials. *Medical Signal Processing*, 147(6):382–388.
- Chaer W. S., Bishop R. H., Ghosh J. (1997). A mixture-of-experts framework for adaptive Kalman filtering. *IEEE Transactions on Systems, Man, and Cybernetics - Part B*, 27(3):452–464.
- Chiappa, S., Barber, D. (2006). EEG classification using generative independent component analysis. *Neurocomputing*, 69(1):769–777.
- Cohen, B. A., Sances, A. J. (1977). Stationarity of the human electroencephalogram. *Medical Biomedical Engineering Computer*, 15(1):513–518.
- Coles, M.G.H., Rugg, M.D (1996). *Electrophysiology of Mind â Event-Related Brain Potentials and Cognition*. New York: Oxford University Press Inc., 5th edition.
- Dangelo, J. G., F. C. A. (2002). *Anatomia Humana Básica*. 2th edition.
- Dobie R. A., W. M. J. (1989). Analysis of auditory evoked potentials by magnitude-squared coherence. *Ear Hearing*, 10(1):2–13.
- Erazo-Costa, F. J. (2012). *Efeito da prática mental no eletroencefalograma durante tarefas visuo- motoras*. PhD thesis, UFMG.
- Forslund, P. (2003). *A neural network based brain-computer interface for classification of movement related EEG*.
- Georgiadis, S. D., Ranta-aho, P. O., Tarvainen, M. P., Karjalainen, P. A (2005). Single-trial dynamical estimation of event-related potentials: a Kalman filter-based approach. *IEEE Transactions on Biomedical Engineering*, 52(8):1397–406.
- Graimann B.; Huggins, J. E.; Levine, S. P. (2004). Toward a direct brain interface based on human subdural recordings and wavelet-packet analysis. *IEEE Transaction Biomedical Engineering*, 51(6):954–962.
- Guyton, A. C., H. J. E. (2006). *Textbook of Medical Physiology*. Pensilvânia, 11th edition.
- Hide C., Moore T., S. M. (2004). Adaptive Kalman filtering algorithms for integrating GPS and low cost INS. *IEEE Position Location and Navigation Symposium*, pages 227–233.
- Hinterberger, T.; Kubler, A.; Kaiser, J.; Neumann, N.; Birbaumer, N. (2003). A brain-computer interface (BCI) for the locked in:comparasion of different EEG classification for the though translation device. *Clinical Neurophysiology*, 114(3):416–425.
- Hou, S. (2008). Application of Kalman Filtering in the Detection of Evoked Potentials. *Electronics Industry*, 3(8):873–875.

- Ikedda, A., Luders, H., Collura, T.F., Burgess, R.C., Morris, H.H., Hamano, T., Shibasaki, H. (1996). Subdural potentials at orbitofrontal and mesial prefrontal areas accompanying anticipation and decision making in humans: a comparison with Bereitschaftspotential. *Electroencephalogram Clinical Neurophysiology*, 98:206–12.
- Jansen, B. E. Ward, N. H. J. W. (1981). Autoregressive Estimation of Short Segment Spectra for Computerized EEG Analysis. *Brain*, 11(9):630–638.
- Jasper, H. H. (1974). The 10-20 Electrode System of the International Federation. *Handbook of Electroencephalography and Clinical Neurophysiology*, 3(C).
- Jervis, B., Allen, E., Johnson, T., Nichols, M., Hudson, N. (1984). The Application of Pattern Recognition Techniques to the Contingent Negative Variation for the Differentiation of Subject Categories. *IEEE Transactions On Biomedical Engineering*, 31(4):342–349.
- Jervis, B.W., Saatchi, M.R., Lacey, A., Foberts, T., Allen, E.M., Hudson, N.R., Oke, S., Grimsley, M. (1994). Artificial neural network and spectrum analysis methods for detecting brain diseases from the CNV response in the electroencephalogram. *IEEE Proceedings - Science Measurement and Technology*, 141(6):432–440.
- Kandel, E. R., Shuwarts, J. H., Jessel, T. M. (2000). *Princípios da Neurociência*. Nova York, EUA, 4 edition.
- Kong, X. (1997). Forward and Backward Autoregressive Modeling of EEG.
- Lange, D. H., Pratt, H., Inbar, G. F. (1997). Modeling and Estimation of Single Evoked Brain Potential Components. *IEEE Transactions on Biomedical Engineering*, 44(9):791–799.
- Lange, H., Pratt, H., Inbar, G. F. (1995). Segmented Matched Filtering of Single Event Related Evoked Potentials. *IEEE Transactions on Biomedical Engineering*, 42(3):317–321.
- Li R., Principe, J. C. (2006). Blinking Artifact Removal in Cognitive EEG Data Using ICA. *Conference of the IEEE Engineering in Medicine and Biology Society*, pages 5273–5276.
- Machado, A. (2007). *Neuroanatomia Funcional*. São Paulo, 2th edition.
- Magill, D. (1965). Optimal Adaptive Estimation of Sampled Stochastic Processes. *IEEE Transactions on Automatic Control*, 10(4):434–439.
- Makeig, S., Enghoff, S., Jung, T. P., and Sejnowski, T. J. (2000). A Natural Basis for Efficient Brain-Actuated Control. *IEEE Transaction Rehabilitation Engineering*, 8(2):208–211.
- Mehra R.K. (1972). Approaches to Adaptive Filtering. *IEEE Transactions on Automatic Control*, 17:693–698.

- Miranda de Sá, A. M., Infantosi, A. F. (2005). Evaluating the entrainment of the alpha rhythm during stroboscopic flash stimulation by means of coherence analysis. *Medical Engineering & Physics*, 27(2):167–173.
- Mohseni, H. R., Wilding, E. L., Sanei, S. (2007). Preprocessing of event-related potential signal via Kalman. *Digital Signal Processing*, pages 179–182.
- Neuper C., Wortz M., P. G. (2006). ERD/ERS patterns reflecting sensorimotor activation and deactivation. *Progress in Brain Research*, 159:211–222.
- Pfurtscheller, G. (1999). Quantification of ERD and ERS in the time domain. *Handbook Electroencephalogram Clinical Neurophysiology*, 5:89–105.
- Pfurtscheller, G., Flotzinger, D., Kalcher, J. (1993). Brain-computer Interface - a new communication device for handicapped persons. *Journal of Microcomputer Applications*, 16(3):293–299.
- Pfurtscheller, G., Neuper, C. (2001). Motor imagery and direct brain-computer communication. *IEEE Neural Engineering: Merging Engineering and Neuroscience*, 89(7):1123–1134.
- Pfustcheller G., Lopes da Silva, F. H. (1999). Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clinical Neurophysiology*, 110(2):1842–57.
- Piccione, F., Giorgi, F., Tonin, P., Priftis, K. Giove, S., Silvoni, S., Palmas, G., Beverina, F. (2006). P300-based brain computer interface: Reliability and performance in healthy and paralysed participants. *Clinical Neurophysiology*, 117:531–537.
- Santos Filho, S. A. (2010). *Magnitude quadrática da coerência na detecção da imaginação do movimento para aplicação em interface cérebro-máquina*. PhD thesis, UFMG.
- Simpson DM., Tierra-Criollo CJ., Leite RT., Zayen EJB., Infantosi AFC. (2000). Objective response detection in an electroencephalogram during somatosensory stimulation. *Annals of Biomedical Engineering*, 42(3):239–240.
- Souza, A. P. (2010). *Coerência, modelo oculto de markov e perceptron de multi-camadas em imagética motora*. PhD thesis, UFMG.
- Steinberg, H., Gasser, T. H., Franke, J. (1985). Fitting Autoregressive Models to EEG Time Series : An Empirical Comparison of Estimates. *IEEE Transactions on Acoustics, Speech and Signal Processing*, 33(1):143–150.
- Tecce, J.J. (1974). Contingent Negative Variation (Cnv) and psychological processes in man. *Psychological Bulletin*, 77(2):73–108.
- Teixeira, B.O. S., Barbosa, B. H. G., Gomes, L. P., Teixeira, A. F., Aguirre, L. A. (2001). UKF-Based Data-Driven Soft Sensing : A Case Study of a Gas-Lifted Oil Well. (1).

- Tierra-Criollo, C. J. (2001). *Monitorização objetiva da Resposta à Estimulação Somato-Sensitiva utilizando parâmetros espectrais*. PhD thesis, COPPE/UFRJ.
- Timmer, J. (1998). Modelling noisy time series: Physiological tremor. *Bifurcation and Chaos.*, 7(8):1505–1516.
- Vander, A., Sherman, J., Luciano, D. (2001). *Human Physiology: The Mechanism of Body*. 8th edition.
- Vilela, A. L. M. (2005). *Sistema Nervoso*. In: *Anatomia Fisiologia Humanas*. 2th edition.
- Von Spreckelsen, M., B. B. (1988). Estimation of single-evoked cerebral potentials by means of parametric modeling and Kalman filtering. *IEEE transactions on bio-medical engineering*, 35(9):691–700.
- Von Spreckelsen, M., Bromm, B. (1988). Estimation of single-evoked cerebral potentials by means of parametric modeling and Kalman filtering. *IEEE Transactions on Biomedical Engineering.*, 35(9):691–700.
- Webster, J. G. (2006). *Medical Devices and Instrumentation*. Nova York: John Wiley Sons, 2th edition.
- Weerd J. P. C. , Marten W. L. J. (1978). Theory and practice of a posteriori Wiener filtering of average evoked potentials. *Biological Cybernetics*, 30(2):81–94.
- Weerd, J. P. C., Kap, J. I. (1981). A posteriori time-varying filtering of averaged evoked potentials. *Biological Cybernetics*, 30(41):211–234.
- Wolpaw, J. R., McFarland, D. J., Vaughan, T. M. (2000). Brain computer-interface research at the Wadsworth Center. *IEEE Transaction Rehabilitation Engineering*, 8(2):222–226.
- Xue, J. Z.; Zhang, H.; Zheng, C. X.; Yan, X. G. (2003). Wavelet packet transform for feature extraction of EEG during mental tasks. *Proceedings of the Second International Conference on Machine Learning and Cybernetics*, 1:360 – 363.