

UNIVERSIDADE FEDERAL DE UBERLÂNDIA  
FACULDADE DE ENGENHARIA ELÉTRICA  
PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA ELÉTRICA

GUSTAVO MOREIRA DA SILVA

CARACTERIZAÇÃO E FILTRAGEM DE ELETROENCEFALOGRAAMA  
CONTAMINADO POR ELETROMIOGRAFIA DOS MÚSCULOS FACIAIS

Uberlândia

2020

GUSTAVO MOREIRA DA SILVA

CARACTERIZAÇÃO E FILTRAGEM DE  
ELETROENCEFALOGRAMA CONTAMINADO POR  
ELETROMIOGRAFIA DOS MÚSCULOS FACIAIS

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Uberlândia, como requisito parcial para obtenção do título de Doutor em Ciências.

Área de Concentração: Processamento Digital de Sinais Biomédicos

Orientador: Prof. Dr. Adriano O. Andrade, PhD

Uberlândia

2020

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU  
com dados informados pelo(a) próprio(a) autor(a).

S586 Silva, Gustavo Moreira da, 1987-  
2020 CARACTERIZAÇÃO E FILTRAGEM DE ELETROENCEFALOGRAMA  
CONTAMINADO POR ELETROMIOGRAFIA DOS MÚSCULOS FACIAIS  
[recurso eletrônico] / Gustavo Moreira da Silva. - 2020.

Orientador: Adriano de Oliveira Andrade.  
Tese (Doutorado) - Universidade Federal de Uberlândia,  
Pós-graduação em Engenharia Elétrica.  
Modo de acesso: Internet.  
Disponível em: <http://doi.org/10.14393/ufu.te.2020.624>  
Inclui bibliografia.  
Inclui ilustrações.

1. Engenharia elétrica. I. Andrade, Adriano de  
Oliveira,1975-, (Orient.). II. Universidade Federal de  
Uberlândia. Pós-graduação em Engenharia Elétrica. III.  
Título.

CDU: 621.3

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091



## UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Coordenação do Programa de Pós-Graduação em Engenharia Elétrica  
Av. João Naves de Ávila, 2121, Bloco 3N - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902  
Telefone: (34) 3239-4707 - www.posgrad.feelt.ufu.br - copel@ufu.br



### ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Elétrica			
Defesa de:	Tese de Doutorado, 273, PPGEELT			
Data:	Vinte e cinco de agosto de dois mil e vinte	Hora de início:	08:00	Hora de encerramento:
Matrícula do Discente:	11423EEL012			
Nome do Discente:	Gustavo Moreira da Silva			
Título do Trabalho:	Caracterização e filtragem do eletroencefalograma contaminado por eletromiografia dos músculos faciais			
Área de concentração:	Processamento da informação			
Linha de pesquisa:	Engenharia biomédica			
Projeto de Pesquisa de vinculação:				

Reuniu-se por meio de videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Elétrica, assim composta: Professores Doutores: Alcimar Barbosa Soares - FEELT/UFU; Adriano Alves Pereira - FEELT/UFU; Edgard Morya - IIN-ELS; Adson Ferreira da Rocha - UNB; Marcus Fraga Vieira - UFG; Adriano de Oliveira Andrade - FEELT/UFU, orientador(a) do(a) candidato(a).

Iniciando os trabalhos o(a) presidente da mesa, Dr(a). Adriano de Oliveira Andrade, apresentou a Comissão Examinadora e o candidato(a), agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(as) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Doutor.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Marcus Fraga Vieira, Usuário Externo**, em 25/08/2020, às 12:36, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015.](#)



Documento assinado eletronicamente por **Adriano de Oliveira Andrade, Professor(a) do Magistério Superior**, em 25/08/2020, às 12:36, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015.](#)



Documento assinado eletronicamente por **Adriano Alves Pereira, Professor(a) do Magistério Superior**, em 25/08/2020, às 12:36, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015.](#)



Documento assinado eletronicamente por **Edgard Morya, Usuário Externo**, em 25/08/2020, às 12:37, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015.](#)



Documento assinado eletronicamente por **Alcimar Barbosa Soares, Professor(a) do Magistério Superior**, em 25/08/2020, às 12:38, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015.](#)



Documento assinado eletronicamente por **Adson Ferreira da Rocha, Usuário Externo**, em 25/08/2020, às 17:22, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015.](#)



A autenticidade deste documento pode ser conferida no site  
[https://www.sei.ufu.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **2216535** e o código CRC **B4729388**.

**GUSTAVO MOREIRA DA SILVA**

**CARACTERIZAÇÃO E FILTRAGEM DE  
ELETROENCEFALOGRAMA CONTAMINADO POR  
ELETROMIOGRAFIA DOS MÚSCULOS FACIAIS**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Uberlândia, como parte dos requisitos para obtenção do título de Doutor em Ciências.

Área de Concentração: Processamento de Sinais

Uberlândia, 25 de agosto de 2020.

**BANCA EXAMINADORA**

---

Prof. Adriano de Oliveira Andrade, PhD – FEELT/UFU

Orientador

---

Prof. Alcimar Barbosa Soares, PhD – FEELT/UFU

---

Prof. Dr. Adriano Alves Pereira – FEELT/UFU

---

Prof. Dr. Marcus Fraga Vieira – FEFID/UFG

---

Prof. Edgard Morya, PhD – IIN-ELS

---

Prof. Dr. Adson Ferreira da Rocha – FGA/UNB

Dedico esse trabalho à minha mãe  
Deusirene.

## AGRADECIMENTOS

Primeiramente a Deus por sempre me cercar das pessoas mais especiais, pela proteção e por toda a inspiração.

Ao meu orientador, Professor Adriano Andrade, um profissional brilhante e um ser humano extremamente generoso. Obrigado por tudo que aprendi com você, pela confiança, pela parceria e pelo seu tempo dedicado na orientação deste trabalho e na minha orientação e apoio. Sou eternamente grato pela oportunidade que me foi dada aprender com você, um exemplo de competência e dedicação.

Ao Professor Alcimar Soares, pelos valiosos ensinamentos e conselhos, pela inspiração que desperta nós desde a graduação e durante a convivência no Biolab.

Ao professor Adriano Alves, desde a graduação sempre empenhado na docência e um ser humano incrível e pelo apoio nos momentos mais difíceis.

À minha mãe Deusirene, sempre presente, obrigado por existir! Obrigado por sonhar todos os meus sonhos comigo e não medir esforços para me ajudar e acompanhar nessa jornada.

À minha irmã e parceira de muitas jornadas Dênia, serei eternamente agradecido por estar sempre comigo.

Aos meus irmãos, Letícia, Tarcísio, Elias e Ana Clara, por serem os melhores irmãos que poderia ter, amo imensamente cada uma de vocês.

À Mariana Cardoso Melo, grande amiga e companheira que caminhou ao meu lado nessa jornada sempre me apoiando e incentivando.

Aos meus amigos do NIATS e Biolab, Amanda Rabelo, Fábio Henrique, Luiza Maire, Carlos Magno, Samila e Dhainner. Obrigado a vocês pela amizade, auxílio nos desafios do dia a dia, pela parceria nos trabalhos e momentos de descontração.

Aos meus amigos de vida, a família que escolhi: Lídia, Thyago, Maria, Issa, Vinícius, Douglas, Gabriela, Daniela, Edvânia, Karen, Damares, Fabiano, Fernando e Pablo.

Ao programa de pós-graduação em Engenharia Elétrica da UFU.

À CAPES pelo apoio financeiro.

“Deus nos concedeu o dom de viver;  
compete a nós viver bem”. (Voltaire)

## RESUMO

O Eletroencefalograma (EEG), é uma medida da atividade cerebral que ostenta as vantagens de portabilidade, baixo custo, alta resolução temporal e não invasivo. Os desafios desse exame são os artefatos de diferentes fontes que tornam a análise de dados do EEG mais difícil, e que potencialmente resulta em erros de interpretação. Portanto, é essencial para muitas aplicações médicas e práticas remover esses artefatos no pré-processamento antes de analisar os dados do EEG. Nos últimos trinta anos, vários métodos foram desenvolvidos para remover diferentes tipos de artefatos de dados de EEG contaminados; ainda assim, não há nenhum método padrão que pode ser usado de forma otimizada e, portanto, a pesquisa permanece atraente e desafiadora. Algumas aplicações, como as Interfaces Homem Computador (HCI), podem ocasionalmente estar associadas a frequentes contrações dos músculos da cabeça, corrompendo o sinal de controle baseado no EEG, requerendo a aplicação de alguma técnica de filtragem. No entanto, as técnicas padrão de ouro para filtragem de sinal ainda contêm limitações, como a incapacidade de eliminar o ruído em todos os canais EEG com relações sinal-ruído (SNR) muito baixas e quando a faixa espectral do ruído sobrepuja a do EEG, que caracteriza diversas contaminações no EEG, mas principalmente a contaminação oriunda do sinal eletromiográfico. Por esta razão, além de estudar e aplicar técnicas de filtragem, é necessário entender a contaminação do eletromiograma (EMG) ao longo do couro cabeludo. Alguns estudos concluíram que o artefato EMG contamina o EEG em frequências a partir de 15 Hz em uma distribuição topográfica que engloba praticamente todo o couro cabeludo. Assim, o presente trabalho tem como objetivo estimar quantitativamente o ruído EMG em 16 canais bipolares de EEG distribuídos ao longo do couro cabeludo de acordo com o sistema 10-20. Essa estimativa foi baseada em um protocolo experimental considerando a aquisição simultânea de EEG e EMG de cinco músculos faciais amostrados a 5 kHz. O protocolo consistiu em ativar os músculos faciais enquanto o voluntário ouvisse 15 sons de bip. Os músculos avaliados foram o frontal, masseter, temporal, zígomático, orbicular do olho e orbicular da boca. A potência média do EEG contaminado pela EMG das contrações da musculatura facial foi comparado entre os períodos de contração muscular e não contração. Os resultados mostram que a contaminação muscular do frontal e do masseter provoca um aumento de energia sobre o couro cabeludo de  $63,5 \mu\text{V}^2$  para  $816 \mu\text{V}^2$  e de  $118,3 \mu\text{V}^2$  para  $5,617,9 \mu\text{V}^2$ , respectivamente. Além disso, este trabalho propõe uma técnica de remoção do artefato de EMG menos sensível a baixas SNRs que as atuais técnicas padrão ouro. O método proposto, chamado EMDRLS, emprega Decomposição

do Modo Empírico (EMD) para gerar uma referência de ruído EMG a um filtro RLS (Recursive Least Squares) adaptativo. Para testar o EMDRLS, foram coletados sinais de EEG de 10 indivíduos saudáveis durante a execução controlada de sucessivas contrações musculares faciais. O protocolo experimental considerou a ativação isolada dos músculos masseter e frontal. Os sinais corrompidos por EEG foram filtrados por EMDRLS considerando SNRs distintos. Os resultados foram comparados às abordagens tradicionais: Wiener, Wavelet, EMD e um método de filtragem híbrido wavelet-RLS. As seguintes métricas de desempenho foram consideradas na avaliação comparativa: (i) SNR do sinal contaminado; (ii) o erro quadrático médio da raiz (RMSE) entre o espectro de potência das épocas de EEG filtradas e sem artefatos; (iii) a preservação espectral de ritmos cerebrais (isto é, delta, teta, alfa, beta e gama) dos sinais filtrados. Para sinais EEG com SNR abaixo de -10dB, o método EMDRLS produziu sinais EEG filtrados com SNR variando de 0 a 10 dB. A técnica reduziu o RMSE dos canais frontais de 1,202 para 0,043, que são a fonte dos sinais de EEG mais corrompidos. O teste de Kruskal-Wallis e o teste post-hoc de Tukey-Kramer ( $p < 0,05$ ) confirmaram a preservação de todos os ritmos cerebrais dados pelos sinais de EEG filtrados pelo método EMDRLS. Os resultados mostraram que o método EMDRLS pode ser aplicado a sinais EEG altamente contaminados por sinal facial EMG com desempenho superior ao dos métodos estabelecidos.

**Palavras-chave:** *Eletroencefalograma (EEG), Eletromiograma (EMG), remoção de artefatos, filtragem digital, Caracterização do EEG, Interface Homem-Computador, decomposição em modos empíricos, filtragem adaptativa RLS, filtragem wavelet, filtragem de Wiener.*

## ABSTRACT

The Electroencephalogram (EEG) has been the most preferred way of recording the brain activity due to its noninvasiveness and affordability benefits. Information estimated from EEG has been employed broadly, e.g., for diagnosis or as input signal to Brain Computer Interfaces (BCI). Nevertheless, the EEG is prone to artifacts including non-brain physiological activities, such as eye blinking and the contraction of the muscles of the scalp. Some applications such as BCI systems may occasionally be associated with frequent contractions of muscles of the head corrupting the EEG-based control signal. This requires the application of a number of filtering techniques. However, standard gold techniques for signal filtering still contain limitations, such as the incapacity of eliminating noise in all EEG channels. For this reason, besides studying and applying filtering techniques, it is necessary to understand the contamination from electromyogram (EMG) along the scalp. Several studies concluded that EMG artifact contaminates the EEG at frequencies beginning at 15 Hz on the topographic distribution of the energy that encompasses practically the entire scalp. Thus, the present work aims to quantitatively estimate EMG noise in 16 bipolar channels of EEG distributed along the scalp according to the 10-20 system. This estimation was based on an experimental protocol considering the simultaneous acquisition of EEG and EMG of five facial muscles sampled at 5 kHz. The protocol consisted in activating facial muscles while listening to 15 beep sounds. The evaluated muscles were occipitofrontalis (venter frontalis), masseter, temporalis, zygomaticus major, orbicularis oculi and orbicularis oris. The mean power of the EEG contaminated by EMG of facial muscles contractions was compared between the periods of muscle contraction and non-contraction. The results show that occipitofrontalis and masseter muscular contamination is present over the scalp with increase from  $63.5 \mu\text{V}^2$  to  $816 \mu\text{V}^2$  and from  $118.3 \mu\text{V}^2$  to  $5,617.9 \mu\text{V}^2$ , respectively. In addition, this paper proposes a technique for EMG artifact removal that is less sensitive to low SNR as the current gold standard techniques. The proposed method, so-called EMDRLS, employs Empirical Mode Decomposition (EMD) to generate an EMG noise reference to an adaptive Recursive Least Squares (RLS) filter. To test EMDRLS, EEG signals were collected from 10 healthy subjects during the controlled execution of successive facial muscular contractions. The experimental protocol considered the isolated activation of masseter and frontalis muscles. EEG corrupted signals were filtered by EMDRLS considering distinct SNRs. The results were compared to traditional approaches: Wiener, Wavelet, EMD and a hybrid wavelet-RLS filtering method. The following performance metrics were considered in the comparative

evaluation: (i) SNR of the contaminated signal; (ii) the root mean square error (RMSE) between the power spectrum of artifact free and filtered EEG epochs; (iii) the spectral preservation of brain rhythms (i.e., delta, theta, alpha, beta, and gamma) of filtered signals. For EEG signals with SNR below -10dB, the EMDRLS method yielded filtered EEG signals with SNR varying from 0 to 10 dB. The technique reduced the RMSE of frontal channels from 1.202 to 0.043, which are the source of the most corrupted EEG signals. The Kruskal-Wallis test and the Tukey-Kramer post-hoc test ( $p < 0.05$ ) confirmed the preservation of all brain rhythms given by EEG signals filtered with the EMDRLS method. The results have shown that the single-channel EMDRLS method can be applied to highly contaminated EEG signals by facial EMG signal with performance superior to that of established methods.

**Keywords:** *Electroencephalogram (EEG), Electromyogram (EMG), artifact removal, digital filtering, EEG characterization, Human Computer Interface, empirical mode decomposition, adaptive filtering, wavelet filtering, Wiener filtering.*

# LISTA DE FIGURAS

FIGURA 1: DIAGRAMA DE BLOCOS COM OS PRINCIPAIS COMPONENTES DE UM SISTEMA DE CAPTURA DE SINAL EEG .....	29
FIGURA 2: DERIVAÇÕES DAS LIGAÇÕES DOS ELETRODOS DE EEG: A. UNIPOLAR OU REFERÊNCIA COMUM; B. BIPOLAR.....	31
FIGURA 3: DIAGRAMA ESQUEMÁTICO DO BLOCO DE AQUISIÇÃO DE DADOS DE UM SISTEMA DE EEG .....	33
FIGURA 4: ESQUEMA DAS DIFERENTES FONTES DE ARTEFATOS PRESENTES NO REGISTRO DE EEG.....	35
FIGURA 5: USO TÍPICO DE FILTRAGEM ADAPTATIVA NO CANCELAMENTO DE ARTEFATOS FISIOLÓGICOS COM O CANAL DE ORIGEM DE ARTEFATO DISPONÍVEL COMO REFERÊNCIA .....	39
FIGURA 6: ILUSTRAÇÃO DE UM FILTRO WIENER. ....	41
FIGURA 7: MODELO DE ESPAÇO DE ESTADOS PARA FORMULAÇÃO DO FILTRO DE KALMAN.....	43
FIGURA 8: IDEIA GERAL DA SEPARAÇÃO CEGA DE FONTES. ....	44
FIGURA 9: ESCALAS TEMPO-FREQUÊNCIA DA STFT E DWT. ....	51
FIGURA 10: PROCESSO DO ALGORITMO EMD NA GERAÇÃO DAS IMFs. ....	54
FIGURA 11: ESQUEMA GERAL DE FILTRAGEM COM MÉTODOS HÍBRIDOS DE BSS-EMD OU BSS-WT .....	57
FIGURA 12: QUANTIDADE DE ARTIGOS PUBLICADOS EM REMOÇÃO DE ARTEFATOS DE EEG (2008-2019) ..	63
FIGURA 13: QUANTIDADE TRABALHOS VOLTADOS PARA A REMOÇÃO DE ARTEFATOS SEPARADOS POR TÉCNICA APLICADA. ....	64
FIGURA 14: DIAGRAMA COM A DISTRIBUIÇÃO DOS ARTEFATOS DE ORIGEM FISIOLÓGICA TIPO DE ARTEFATO DIRECIONADO PELOS TRABALHOS DA TABELA 5.....	65
FIGURA 15: PROCEDIMENTO DE COLETA SIMULTÂNEA DE EEG E EMG.....	69
FIGURA 16: A) TOUCA E SISTEMA DE AQUISIÇÃO DE EEG. B) CONEXÃO ELÉTRICA DOS ELETRODOS, REFERÊNCIA BIPOLAR. ....	69
FIGURA 17: RESPOSTA EM FREQUÊNCIA DO PRÉ-PROCESSAMENTO .....	70
FIGURA 18: TRECHO DE UM SINAL DE EEG (P4-P4) CONTAMINADO POR CONTRAÇÕES DO MÚSCULO MASSETER QUE ILUSTRA O JANELAMENTO EM ÉPOCAS CONTAMINADAS E NÃO CONTAMINADAS POR EMG. ....	70
FIGURA 19: (A) POTÊNCIA DO EEG COMPARANDO OS PERÍODOS DE CONTRAÇÃO E NÃO-CONTRAÇÃO DO MÚSCULO FRONTAL E (B) POTÊNCIA DOS SINAIS EEG PARA CADA DERIVAÇÃO BIPOLAR NOS PERÍODOS DE CONTRAÇÃO MUSCULAR FRONTAL. ....	72
FIGURA 20: POTÊNCIA DO EEG COMPARANDO OS PERÍODOS DE CONTRAÇÃO E NÃO-CONTRAÇÃO DO MASSETER (B) PODER DOS SINAIS DE EEG PARA CADA DERIVAÇÃO BIPOLAR NOS PERÍODOS DE CONTRAÇÃO MASSETER.....	72
FIGURA 21: (A) POTÊNCIA DO EEG COMPARANDO OS PERÍODOS DE CONTRAÇÃO MUSCULAR ORBICULAR DO OLHO ATIVA E INATIVA (B) POTÊNCIA DOS SINAIS EEG PARA CADA DERIVAÇÃO BIPOLAR NOS PERÍODOS DE CONTRAÇÃO DO MÚSCULO ORBICULAR ATIVO E NÃO ATIVO. ....	73
FIGURA 22: (A) POTÊNCIA DO EEG COMPARANDO OS PERÍODOS DE CONTRAÇÃO MUSCULAR DO ZIGOMÁTICO (B) POTÊNCIA DOS SINAIS EEG PARA CADA DERIVAÇÃO BIPOLAR NOS PERÍODOS DE CONTRAÇÃO MUSCULAR ATIVA E NÃO ATIVA. ....	74

FIGURA 23: POTÊNCIA DO EEG COMPARANDO OS PERÍODOS DE CONTRAÇÃO DO MÚSCULO ORBICULAR DA BOCA ATIVO E NÃO ATIVO (B) PODER DOS SINAIS DE EEG PARA CADA DERIVAÇÃO BIPOLAR NOS PERÍODOS DE CONTRAÇÃO ORBICULAR DA BOCA ATIVA E NÃO ATIVA.....	74
FIGURA 24: GANHO DA POTÊNCIA MÉDIA EM DECIBÉIS PARA OS SINAIS EMG E EEG.....	75
FIGURA 25: DIAGRAMA DE BLOCOS DA TÉCNICA EMDRLS PARA ATENUAÇÃO DE RUÍDO NOS SINAIS DE EEG. PRIMEIRA ETAPA: REGIÕES DE SINAL SEM EMG SÃO DETECTADAS. SEGUNDA ETAPA: O SINAL DE ENTRADA $S[n]$ É DECOMPOSTO EM IMFs PARA EM SEGUIDA, O SINAL É LIMIARIZADO BASEADO NAS REGIÕES LIVRES DE EMG PARA A GERAÇÃO DE UM SINAL DE REFERÊNCIA DE RUÍDO EMG ( $R[n]$ ). TERCEIRA ETAPA: O SINAL DE ENTRADA, $S[n]$ , É FILTRADO POR UM FILTRO RLS COM UM SINAL DE REFERÊNCIA ( $R[n]$ ), RESULTANDO EM UM SINAL EEG FILTRADO ( $Y[n]$ ).....	78
FIGURA 26: SINAIS DE EEG E EMG DURANTE O PROTOCOLO DE CONTRAÇÃO DO MÚSCULO MASSETER.....	82
FIGURA 27: SINAL DO CANAL Pz-P4 AO LONGO DE CONTRAÇÕES DO MASSETER. ....	83
FIGURA 28: PROCESSO DE GERAÇÃO DE UM SINAL DE EEG CONTAMINADO POR EMG.....	84
FIGURA 29. A) SINAIS DE EEG CONTAMINADOS POR EMG E SINAIS DE EEG PUROS. B) SINAIS CONTAMINADOS POR EEG E SINAIS FILTRADOS COM O FILTRO ADAPTATIVO RLS. ....	85
FIGURA 30: A) TRECHO AMPLIADO DA FIGURA 32 DOS SINAIS DE EEG CONTAMINADOS POR EMG E DOS SINAIS DE EEG PUROS. B) TRECHO DOS SINAIS CONTAMINADOS POR EEG E DOS SINAIS FILTRADOS COM RLS.....	86
FIGURA 31: ESPECTROS DOS SINAIS DE EEG PURO, CONTAMINADO E FILTRADO PARA COMPARAR A CAPACIDADE DE FILTRAGEM PARA OS 3 DIFERENTES GRAUS DE CONTAMINAÇÃO. ....	86
FIGURA 32: SINAIS DE EEG CONTAMINADOS POR EMG E SINAIS DE EEG PUROS. B) SINAIS CONTAMINADOS POR EEG E SINAIS FILTRADOS COM FILTRO DE WIENER. ....	87
FIGURA 33: A) TRECHO AMPLIADO DA FIGURA 35 DOS SINAIS DE EEG CONTAMINADOS POR EMG E DOS SINAIS DE EEG PUROS. B) TRECHO DOS SINAIS CONTAMINADOS POR EEG E DOS SINAIS FILTRADOS COM O FILTRO DE WIENER. ....	88
FIGURA 34: ESPECTROS DOS SINAIS DE EEG PURO, CONTAMINADO E FILTRADO PARA COMPARAR NO DOMÍNIO DA FREQUÊNCIA A CAPACIDADE DE FILTRAGEM DO FILTRO WIENER PARA OS 3 DIFERENTES GRAUS DE CONTAMINAÇÃO. ....	88
FIGURA 35: A) SINAIS DE EEG CONTAMINADOS POR EMG E SINAIS DE EEG PUROS. B) SINAIS CONTAMINADOS POR EEG E SINAIS FILTRADOS COM O FILTRO WAVELET. ....	89
FIGURA 36: A) TRECHO AMPLIADO DA FIGURA 35 DOS SINAIS DE EEG CONTAMINADOS POR EMG E DOS SINAIS DE EEG PUROS. B) TRECHO DOS SINAIS CONTAMINADOS POR EEG E DOS SINAIS FILTRADOS COM O FILTRO DE WAVELET.....	90
FIGURA 37: ESPECTROS DOS SINAIS DE EEG PURO, CONTAMINADO E FILTRADO PARA COMPARAR NO DOMÍNIO DA FREQUÊNCIA A CAPACIDADE DE FILTRAGEM WAVELET PARA OS 3 DIFERENTES GRAUS DE CONTAMINAÇÃO. ....	90
FIGURA 38: SINAIS DE EEG CONTAMINADOS POR EMG E SINAIS DE EEG PUROS. B) SINAIS CONTAMINADOS POR EEG E SINAIS FILTRADOS COM O FILTRO EMD. ....	91

FIGURA 39: A) TRECHO AMPLIADO DA FIGURA 35 DOS SINAIS DE EEG CONTAMINADOS POR EMG E DOS SINAIS DE EEG PUROS. B) TRECHO DOS SINAIS CONTAMINADOS POR EEG E DOS SINAIS FILTRADOS COM O FILTRO DE EMD.....	92
FIGURA 40: ESPECTROS DOS SINAIS DE EEG PURO, CONTAMINADO E FILTRADO PARA COMPARAR NO DOMÍNIO DA FREQUÊNCIA A CAPACIDADE DE FILTRAGEM DO FILTRO EMD PARA OS 3 DIFERENTES GRAUS DE CONTAMINAÇÃO.....	92
FIGURA 41: COMPARAÇÃO DA SNR DAS TÉCNICAS DE FILTRAGEM EM FUNÇÃO DA SNR CAUSADA POR SINAL EMG.....	93
FIGURA 42: COMPARAÇÃO DO RMSE DAS TÉCNICAS DE FILTRAGEM EM FUNÇÃO DA SNR CAUSADA POR SINAL EMG.....	94
FIGURA 43: DEFINIÇÃO DAS ÉPOCAS DO SINAL EEG (A, B, C E D) PARA A ESTIMATIVA DAS MÉTRICAS DE DESEMPENHO. S[N] É O SINAL EEG CONTAMINADA COM ARTEFATO MUSCULAR E Y[N] É SUA VERSÃO FILTRADA CORRESPONDENTE. A É A ÉPOCA DO SINAL CORROMPIDA PELO EMG, ENQUANTO C É A MESMA ÉPOCA NO SINAL FILTRADO CORRESPONDENTE. B É A ÉPOCA LIVRE DE EMG E D É A MESMA ÉPOCA NO SINAL FILTRADO CORRESPONDENTE.....	96
FIGURA 44: FORMAS DE ONDA TÍPICAS DE SINAIS EEG CONTAMINADOS (A) E FILTRADOS COM CADA MÉTODO DE FILTRAGEM (B - F). NESTE EXEMPLO, O EEG DETECTADO EM F3-F7 FOI CORROMPIDO POR UM SINAL EMG ORIGINADO DE UMA CONTRAÇÃO DO MÚSCULO MASSETER.....	99
FIGURA 45: RELAÇÃO ENTRE O NÍVEL DE CONTAMINAÇÃO E A SNR DO SINAL FILTRADO EM RELAÇÃO AO SINAL CONTAMINADO POR EMG DO MÚSCULO FRONTAL.....	100
FIGURA 46: RELAÇÃO ENTRE O NÍVEL DE CONTAMINAÇÃO E A SNR DO SINAL FILTRADO EM RELAÇÃO AO SINAL CONTAMINADO POR EMG DO MÚSCULO MASSETER.....	101
FIGURA 47: SNR MÉDIA GLOBAL DOS SINAIS DE EEG FILTRADOS APÓS A CONTAMINAÇÃO PELO EMG DOS MÚSCULOS FRONTAIS EM RELAÇÃO A CADA CANAL DE EEG. O SNR MÉDIO GERAL DO SINAL EEG CONTAMINADO, S[N], TAMBÉM É MOSTRADO.....	101
FIGURA 48: SNR MÉDIA GLOBAL DOS SINAIS DE EEG FILTRADOS APÓS A CONTAMINAÇÃO PELO EMG DOS MÚSCULOS FRONTAIS EM RELAÇÃO A CADA CANAL DE EEG. O SNR MÉDIO GERAL DO SINAL EEG CONTAMINADO, S[N], TAMBÉM É MOSTRADO.....	102

# LISTA DE TABELAS

TABELA 1: BANDAS DE FREQUÊNCIAS BÁSICAS DO SINAL EEG. ÉPOCA RETIRADA DE COLETA REALIZADA NESTE ESTUDO E DECOMPOSTA DENTRO DE TAIS FAIXAS DE FREQUÊNCIAS POR MEIO DE FILTROS PASSA BANDA DIGITAIS DO TIPO BUTTERWORTH SINTONIZADOS NAS 5 FAIXAS DAS BANDAS DO EEG.....	27
TABELA 2: RESUMO DAS PRINCIPAIS PROPRIEDADES DOS RITMOS DO EEG ABAIXO DE 70 Hz [1], [27]–[34].	28
.....	28
TABELA 3: DIFERENTES TIPOS DE ARTEFATOS E SUAS ORIGENS. ....	36
TABELA 4: COMPARAÇÃO ENTRE AS PRINCIPAIS TÉCNICAS DE REMOÇÃO DE ARTEFATO DO EEG.....	58
TABELA 5: RELAÇÃO DOS TRABALHOS FOCADOS EM APLICAÇÃO DE TÉCNICAS DE REMOÇÃO DE ARTEFATOS FISIOLÓGICOS DO EEG. ....	59
TABELA 6: DESCRIÇÃO DAS SESSÕES DE COLETA DE DADOS DE EEG-EMG.....	68
TABELA 7: CONTRAÇÕES MUSCULARES BASEADAS NA HCI.....	68
TABELA 8: DE-PARA DO ÍNDICE DE CONTAMINAÇÃO RESPECTIVO A CADA FAIXA DE CONTAMINAÇÃO DAS ÉPOCAS A E B DO SINAL.....	100
TABELA 9: MÉDIA E DESVIO PADRÃO DO RMSE ENTRE O ESPECTRO DE POTÊNCIA DO EEG SEM EMG E AS ÉPOCAS DO EEG FILTRADO CONTAMINADAS PELO EMG PELO MÚSCULO FRONTAL. OS RÓTULOS NUMÉRICOS EM SOBRESCRITO DENOTAM DIFERENÇA SIGNIFICATIVA ENTRE CENÁRIOS NÃO FILTRADOS E FILTRADOS.....	103
TABELA 10: MÉDIA E DESVIO PADRÃO DO RMSE ENTRE O ESPECTRO DE POTÊNCIA DO EEG SEM EMG E AS ÉPOCAS DO EEG FILTRADO CONTAMINADAS POR EMG DO MÚSCULO MASSETER. OS RÓTULOS NUMÉRICOS EM SOBRESCRITO DENOTAM DIFERENÇA SIGNIFICATIVA ENTRE CENÁRIOS NÃO FILTRADOS E FILTRADOS.....	103
TABELA 11: MÉDIA E DESVIO PADRÃO DA MPSP (EM $\mu$ V) ENTRE O ESPECTRO DE POTÊNCIA DAS ÉPOCAS DO EEG SEM CONTAMINAÇÃO DE EMG E AS ÉPOCAS DO EEG FILTRADO CONTAMINADAS PELO EMG DO MÚSCULO FRONTAL PARA OS RITMOS CEREBRAIS DISTINTOS. A EFICÁCIA DA FILTRAGEM É MEDIDA PELA SIMILARIDADE ESPECTRAL ENTRE OS SINAIS DE EEG FILTRADOS E O SINAL DE EEG LIVRE DE ARTEFATO DE EMG. OS RÓTULOS NUMÉRICOS SOBRESCRITOS DENOTAM DIFERENÇA SIGNIFICATIVA ENTRE O ESPECTRO DE POTÊNCIA DO EEG LIVRE DE CONTAMINAÇÃO POR EMG E AS ÉPOCAS DO EEG FILTRADO EM UM NÍVEL DE SIGNIFICÂNCIA DE 0,05.....	104
TABELA 12: MÉDIA E DESVIO PADRÃO DA MPSP (EM $\mu$ V) ENTRE O ESPECTRO DE POTÊNCIA DAS ÉPOCAS DO EEG SEM CONTAMINAÇÃO DE EMG E AS ÉPOCAS DO EEG FILTRADO CONTAMINADAS PELO EMG DO MÚSCULO MASSETER PARA OS RITMOS CEREBRAIS DISTINTOS. A EFICÁCIA DA FILTRAGEM É MEDIDA PELA SIMILARIDADE ESPECTRAL ENTRE OS SINAIS DE EEG FILTRADOS E O SINAL DE EEG LIVRE DE ARTEFATO DE EMG. OS RÓTULOS NUMÉRICOS SOBRESCRITOS DENOTAM DIFERENÇA SIGNIFICATIVA ENTRE O ESPECTRO DE POTÊNCIA DO EEG LIVRE DE CONTAMINAÇÃO POR EMG E AS ÉPOCAS DO EEG FILTRADO EM UM NÍVEL DE SIGNIFICÂNCIA DE 0,05.....	104

# SUMÁRIO

<b>CAPÍTULO 1 A ELETROENCEFALOGRAFIA COMO MEDIDA DA ATIVIDADE CEREBRAL: APLICAÇÕES E DESAFIOS.....</b>	<b>16</b>
1.1    Motivação e justificativa .....	18
1.2    Objetivos do trabalho .....	19
1.2.1    Objetivos específicos .....	19
1.3    Publicações deste trabalho .....	20
1.4    Estrutura do trabalho .....	23
<b>CAPÍTULO 2 GERAÇÃO, AQUISIÇÃO E CARACTERÍSTICAS DO SINAL EEG .....</b>	<b>24</b>
2.1    A gênese do sinal EEG: das células piramidais ao galvanômetro .....	24
2.2    Os ritmos cerebrais.....	26
2.3    O sistema de aquisição de EEG.....	29
2.3.1    Eletrodos.....	29
2.3.2    Sistema de condicionamento de sinais.....	32
2.3.3    Demais elementos de um sistema de aquisição de sinal EEG .....	33
2.4    Os principais artefatos presentes no sinal EEG .....	34
2.5    Considerações Finais.....	36
<b>CAPÍTULO 3 FILTRAGEM DE SINAIS AMOSTRADOS NO TEMPO E AS PRINCIPAIS ESTRATÉGIAS DE FILTRAGEM DO EEG.....</b>	<b>37</b>
3.1    Principais técnicas de remoção de artefatos do EEG .....	38
3.1.1    Filtragem Adaptativa .....	38
3.1.2    Filtragem de Wiener .....	40
3.1.3    Filtro de Kalman.....	42
3.1.4    Métodos de Separação Cega de Fontes.....	43
3.1.5    Transformada Wavelet.....	50
3.1.6    Decomposição em Modos Empíricos (EMD).....	52
3.1.7    Métodos Híbridos .....	55
3.2    Comparação entre os métodos.....	58
3.3    Cenário da aplicação dos principais métodos para remoção dos artefatos de EEG.....	59
3.4    Considerações Finais.....	65
<b>CAPÍTULO 4 COLETA DE DADOS E CARACTERIZAÇÃO DA CONTAMINAÇÃO DO SINAL EEG CAUSADA POR CONTRAÇÃO DE MÚSCULOS FACIAIS.....</b>	<b>66</b>
4.1    Caracterização do estudo.....	67

4.2	A metodologia de coleta e caracterização da contaminação de EMG no EEG .....	68
4.3	Caracterização da contaminação do EEG.....	71
4.4	Considerações Finais.....	76
<b>CAPÍTULO 5 MÉTODO EMDRLS PARA REMOÇÃO DE ARTEFATOS MUSCULARES DO EEG FORTEMENTE CONTAMINADOS .....</b>		<b>77</b>
5.1	O Filtro Híbrido EMDRLS .....	77
5.2	Métodos de canal único confrontados com técnica EMDRLS .....	80
<b>CAPÍTULO 6 AVALIAÇÃO DE DESEMPENHO DO MÉTODO EMDRLS COM SINAL SEMI-SINTÉTICO .....</b>		<b>81</b>
6.1	Geração de sinais EEG corrompidos por EMG de diferentes SNR.....	82
6.2	Remoção de artefato muscular do EMG por meio de filtragem adaptativa RLS .....	84
6.3	Remoção de artefato muscular do EMG com filtro de Wiener .....	87
6.4	Remoção de artefato muscular do EMG por meio de filtragem Wavelet.....	89
6.5	Remoção de artefato muscular do EMG por meio de filtragem EMD .....	91
6.6	Comparação entre os filtros utilizados .....	93
<b>CAPÍTULO 7 AVALIAÇÃO DO MÉTODO DE REMOÇÃO EMDRLS COM SINAIS REAIS.....</b>		<b>95</b>
7.1	Medidas de desempenho dos filtros de eeg nos sinais reais coletados .....	95
7.1.1	Relação sinal-ruído (SNR).....	97
7.1.2	Raiz do erro médio quadrático (RMSE) dos espectros .....	97
7.1.3	Densidade espectral de potência média (MPSD).....	98
7.2	Inspeção visual dos sinais filtrados .....	99
7.3	Análise da snr do sinais filtrados.....	99
7.4	Comparação da RMSE do espectro de potência entre as épocas com sinal de EEG puro e as épocas com sinal de EEG filtrado .....	102
7.5	Preservação espectral (MPSD) dos ritmos de frequência no EEG .....	103
<b>CAPÍTULO 8 DISCUSSÕES E CONCLUSÕES .....</b>		<b>105</b>
<b>REFERÊNCIAS.....</b>		<b>108</b>

# **Capítulo 1**

## **A ELETROENCEFALOGRAFIA COMO MEDIDA DA ATIVIDADE CEREBRAL: APLICAÇÕES E DESAFIOS**

A eletroencefalografia (EEG) é uma técnica para registro da atividade de populações neuronais do córtex cerebral medida no escalpo. É oriunda de um processo macroscópico, não invasivo, com alta resolução temporal e de baixo custo, se comparada aos exames de neuroimagem funcionais [1]. Essa informação funcional do cérebro é extensivamente empregada em diversas aplicações clínicas e comerciais, dentre elas, estudos em neurociência cognitiva, quantificação de habilidades cerebrais, diagnósticos de patologias corticais, biometria e Interfaces Cérebro-Computador (BCI) [2–5].

O sistema para medida deste sinal eletrofisiológico amplifica as minúsculas perturbações dos potenciais elétricos dos eletrodos posicionados no couro cabeludo. Esse sinal é medido no escalpo, o qual está anatomicamente separado das fontes geradoras do sinal pelas meninges, pelos ossos do crânio e o pelo couro cabeludo. Assim, os potenciais sinápticos que já apresentam baixas amplitudes, são fortemente atenuados por essas estruturas anatômicas reduzindo a amplitude do sinal lido no escalpo pelos eletrodos [6]. Devido à essa baixa amplitude, normalmente não ultrapassando 50 µV, o sinal EEG é extremamente suscetível a artefatos [7].

Esses artefatos são normalmente causados por campos eletromagnéticos gerados por dispositivos eletrônicos próximos ou pela rede elétrica, além destes, artefatos podem ser produzidos por outras fontes de sinais eletrofisiológicos (por exemplo, a atividade muscular e cardíaca ou o movimento ocular) [8,9]. Essa contaminação diminui a precisão de aplicações, como interfaces cérebro-computador (BCI) ou diagnóstico de patologias, uma vez que a amplitude do artefato normalmente terá uma amplitude várias ordens de grandeza maior que a amplitude do eletroencefalograma (EEG) [10,11].

Nesse contexto, a caracterização e eliminação de artefatos é um ponto crucial para garantir a validade das aplicações, tendo posto que essas requerem a correta interpretação dos sinais elétricos oriundos dos potenciais sinápticos medidos no escalpo. Dentre todo o conjunto de artefatos que podem comprometer esta interpretação do EEG, os sinais eletromiográficos (EMG) faciais são uma fonte importante de contaminação do EEG. O principal desafio em relação a eliminação do ruído gerado pelo sinal EMG reside no fato do sinal muscular emergir de músculos anatomicamente posicionados ao longo do crânio ou bem próximos deste, os quais, mesmo uma fraca contração muscular pode ser detectável em todo o couro cabeludo devido ao fenômeno do volume condutor. Além disso, o sinal EMG contém uma sobreposição espectral com o sinal EEG em praticamente todas as bandas de frequência [12].

Para resolver esse problema são descritos na literatura diversos métodos de filtragem de EEG, os quais apresentam algumas limitações. Estas envolvem, a incapacidade de completa remoção do ruído no sinal corrompido sem introduzir distorções indesejadas, a necessidade de informações do ruído a priori ou possuem alto custo computacional inviabilizando sua execução online. Essas limitações associadas às numerosas características que podem ser estimadas a partir do sinal EEG para atender as mais diversas aplicações resulta em múltiplos padrões de ouro para a remoção de artefatos de EEG [9,13–17].

Além disso, a aplicação de métodos para remoção de contaminação EMG requer um bom entendimento das propriedades espetrais e topográficas dos artefatos. Como por exemplo, a característica do artefato no EEG em relação à localização anatômica ocupada pelo músculo que foi ativado. Para o estudo dos artefatos musculares no EEG, existem estudos que analisaram a distribuição da densidade espectral de potência ao longo do escalpo e a análise de coerência dos sinais em [12,18]. Esses estudos apontam principalmente a sobreposição espectral dos sinais EEG e EMG acima de 15 Hz, isso para protocolos experimentais que envolveram contrações musculares dos músculos frontal e masseter.

No contexto da complexidade do artefato de EMG nos sinais EEG, esse trabalho visa caracterizar a contaminação eletromiográfica no sinal EEG e propor um novo método de filtragem para remoção de artefatos musculares no sinal EEG. Este método tem objetivo de remover em especial dos artefatos de alta potência que normalmente são evitados durante a coleta ou tem suas épocas removidas.

## 1.1 MOTIVAÇÃO E JUSTIFICATIVA

A contaminação do EEG decorrente da proximidade entre os sítios de coleta dos sinais EEG com relação aos músculos faciais (como o frontal e o masseter) ocasiona em uma dificuldade de eliminação do artefato comprometendo as mais diversas aplicações do EEG. Dentre essas aplicações, este trabalho é especificamente inspirado na necessidade de remoção da contaminação do EEG gravado durante uma sequência de contrações musculares cujo o sinal EMG é utilizado para o manuseio de um cursor de uma interface homem-computador (HCI) [19]. A motivação para a remoção do ruído gerado pela contração dos músculos faciais demandou da necessidade de avaliação do EEG em um estudo do processo de aprendizagem durante o controle desta HCI [20].

Entretanto, os maiores esforços para remoção de artefatos fisiológicos do EEG documentados na literatura estão direcionados para a contaminação causada pelo eletro-oculograma (EOG). Isso devido ao fato de que esse tipo de contaminação origina de um evento fisiológico de maior ocorrência durante a gravação de EEG e além de ser mais difícil de ser evitado. Quanto às contrações musculares, estas são evidentemente mais fáceis de serem evitadas em uma coleta de EEG, entretanto, se não for evitada, o artefato gerado pode alcançar os eletrodos do escâlpo com amplitudes na ordem de milhares de vezes maiores que o EEG, em uma ampla faixa de frequências.

Por esta razão, o procedimento mais recorrente quando o EEG é contaminado por EMG, é a remoção das épocas contaminadas. Contudo, essa estratégia não é adequada quando se precisa analisar a atividade eletroencefalográfica de uma pessoa enquanto essa faz alguma contração muscular facial. Como o próprio exemplo que motivou esse trabalho que surgiu de uma demanda do próprio grupo de pesquisa, ao utilizar o EEG para compor um índice de aprendizado durante a utilização de uma HCI controlada por músculos faciais. Além dessa aplicação, a remoção de épocas contaminadas também pode não ser uma alternativa para as aplicações de BCI, EEG vestível, estudo da atividade cerebral durante crises epiléticas ou durante a fala. Isso leva a concluir que existe uma demanda por trabalhos que aprimorem as técnicas de remoção de artefato muscular.

Atualmente, as técnicas de canal único, têm se mostrado as mais eficazes para a remoção do artefato muscular, principalmente se é conhecido um sinal de referência [21]. Contudo, a maior limitação dessa classe de técnicas de remoção é a queda de desempenho em relações sinal-ruído (SNR) abaixo de -10 dB, o que é algo bem comum nas contaminações causadas por músculos faciais [21–23]. Além disso, faltam estudos sobre a remoção de artefatos musculares faciais do

EEG. Isso é importante quando há necessidade de monitorar a atividade cerebral durante a interação humano-computador [49].

Em direção dessas necessidades, este estudo propõe o método EMDRLS na filtragem de EEG contaminado por EMG facial, o qual é independente de um ruído de referência externo e é adequado para sinais com baixo SNR (por exemplo, menor que -10 dB). Assim, a hipótese testada neste trabalho foi a de que um sinal de referência EMG de canal único, estimado a partir de decomposição em modos empíricos (EMD), em combinação com um filtro de mínimos quadrados recursivos (RLS) [24–26] melhorará a filtragem de EEG fortemente contaminado com EMG facial. Os resultados do método proposto, chamado EMDRLS, são comparados com os obtidos a partir de métodos tradicionais, como a filtragem wavelet, a filtragem Wiener, a filtragem EMD e a filtragem híbrida wavelet-RLS (wRLS). O protocolo experimental adotado neste estudo é baseado na necessidade prática de avaliar a atividade cerebral para quantificação da aprendizagem motora durante a interação com uma interface mioelétrica [27]. Além disso, este trabalho apresenta a caracterização da contaminação que foi útil para estabelecimento de valores alvo de SNR que o processo de filtragem precisa atender.

## 1.2 OBJETIVOS DO TRABALHO

O presente trabalho tem o objetivo central de apresentar e testar a proposta de um novo método para remoção de artefatos musculares de alta potência, denominado EMDRLS e confrontá-lo com os principais métodos para filtragem do artefato de EMG no sinal EEG.

### 1.2.1 Objetivos específicos

- Elaboração de protocolos experimentais que ocasionam em uma contaminação controlada do sinal EEG aplicado ao uso de uma Interface Homem-Computador (HCI);
- Coletar atividade muscular facial e cerebral de usuários durante a execução dos protocolos experimentais de coleta de dados;
- Caracterizar e quantificar a contaminação do EEG causada pela contração muscular;

- Aplicar filtros nos sinais de EEG contaminados com EMG, e avaliar os sinais filtrados para medir o desempenho dos filtros.
- Comparação de resultados da com os principais filtros de EEG utilizados.

### 1.3 PUBLICAÇÕES DESTE TRABALHO

Este trabalho gerou até o momento as seguintes publicações/submissões:

LEITE, J. A. A.; SANTOS, M. A. C.; SILVA, R. M. C.; Adriano O. Andrade; SILVA, G. M.; BAZAN, R.; SANDE, L. A. P.; LUVIZUTTO, G. J. **Alpha and beta cortical activity during guitar playing: task complexity and audiovisual stimulus analysis**. Somatosensory and Motor Research, 2020.

SILVA, G. M.; QUEIROZ, C. M. M.; WALTER, S.; PERES, L. B.; LUIZ, L. M. D.; COSTA, S. C.; PEREIRA, A.A.; VIEIRA, M. F.; Adriano O. Andrade. **EMDRLS – Single channel approach for filtering EEG signals strongly contaminated with facial EMG**. PLOS ONE (**Submetido**). 2020.

DA SILVA, K.; LUVIZUTTO, G.; BRUNO, A.; DE OLIVEIRA, S.; COSTA, S.; SILVA, G.; PEREIRA, J.; Adriano O. Andrade.; SOUZA, L. **Electroencephalographic gamma-band activity and motor development in music trained children**. Perceptual and Motor Skills (**Major Review**). 2020.

SILVA, G. M.; PERES, L. B.; QUEIROZ, C. M. M.; LUIZ, L. M. D.; VIEIRA, M. F.; Adriano O. Andrade. **Spatial Quantification of Facial Electromyography Artifacts in the Electroencephalogram**. IFMBE Proceedings: XXVI Brazilian Congress on Biomedical Engineering. 1ed.: Springer Nature: Singapore, 2018.

SILVA, G. M.; OLIVEIRA, F. H. M.; PERES, L. B.; QUEIROZ, C. M. M.; LUIZ, L. M. D.; COSTA, S.; VIEIRA, M. F.; Adriano O. Andrade. **Methodology for Quantification of Frontal Muscle Electromyography Contamination in the Electroencephalogram** ([https://doi.org/10.1007/978-981-10-9038-7\\_98](https://doi.org/10.1007/978-981-10-9038-7_98)). IFMBE Proceedings: World Congress on

Medical Physics and Biomedical Engineering 2018. 1ed.: Springer Nature: Singapore, 2018, v. 68, p. 535-538.

LUIZ, L. M. D.; COSTA, S.; G. M. da Silva; PERICLES, A.; QUEIROZ, C. M. M.; ANDRADE, A. O. **Análise de aprendizagem na realização de tarefas de controle em uma interface homem-computador com protocolos experimentais com dificuldades crescentes.** In: V Congresso Brasileiro de Eletromiografia e Cinesiologia e X Simpósio de Engenharia Biomédica., 2017, Uberlândia. Anais do V Congresso Brasileiro de Eletromiografia e Cinesiologia e X Simpósio de Engenharia Biomédica., 2017.

SILVA, G. M.; QUEIROZ, C. M. M.; RABELO, A. G.; ANDRADE, A. O. **Proposta de filtragem do eletroencefalograma da região occipital contaminado por atividade muscular facial utilizando decomposição de modos empíricos.** In: XXV Congresso Brasileiro de Engenharia Biomédica, 2016, Foz do Iguaçu. Anais do XXV Congresso Brasileiro de Engenharia Biomédica, 2016.

SILVA, G. M.; PERES, L. B.; QUEIROZ, C. M. M.; LUIZ, L. M. D.; OLIVEIRA, I. M.; ANDRADE, A. O. **Estudo do índice de correlação cruzada entre a atividade eletromiográfica do músculo frontal e o eletroencefalograma.** In: XXV Congresso Brasileiro de Engenharia Biomédica. CBEB 2016, 2016, Uberlândia. Anais do XXV Congresso Brasileiro de Engenharia Biomédica. CBEB 2016, 2016.

QUEIROZ, C. M. M.; PERES, L. B.; SILVA, G. M.; NASUTO, S. J.; ANDRADE, A. O. **Remoção de tendências não lineares da eletromiografia em tempo real utilizando filtro de média móvel.** In: XXV Congresso Brasileiro de Engenharia Biomédica. CBEB 2016, 2016, Foz do Iguaçu. Anais do XXV Congresso Brasileiro de Engenharia Biomédica, 2016.

MELO, M. C.; SILVA, G. M.; MIZIARA, I. M.; ANDRADE, A. O. **Avaliação da atividade eletroencefalográfica e eletromiográfica durante a operação de interfaces homem-máquina.** In: Conferência de Estudos em Engenharia Elétrica (CEEL), 2014, Uberlândia. Artigos da XIII Conferência de Estudos em Engenharia Elétrica, 2014.

Além dessas, outras publicações com assuntos relacionados realizadas no período do doutorado:

PACETTI, G. A.; SOUZA, D. Q.; SILVA, G. M.; ANDRADE, A. O; BARJA, P. R.; LIMA, M. O.; LIMA, F. P. S. **The electromyographic analysis (root mean square and wavelet**

**transform) of lumbar disorders before and after kinesiotherapy and vibrating therapy.**  
Research on Biomedical Engineering (**Submetido**), 2020.

SEGATTO, L. G.; MELO, M. C.; DA SILVA, G. M. **Proposal of an educational game for improvement of cognitive performance of intellectually disabled people.** (<https://doi.org/10.1109/IHTC.2017.8058168>). In: 2017 IEEE Canada International Humanitarian Technology Conference (IHTC), 2017, Toronto. 2017 IEEE Canada International Humanitarian Technology Conference (IHTC), 2017. p. 109.

ZARUZ, THAÍLA F.; SILVA, RAFAEL; MOREIRA, GUSTAVO; ANDRADE, ADRIANO. **Desenvolvimento de aparelho para aquisição de sinais biológicos.** (<https://doi.org/10.17648/seb-2016-53317>). Em: IX Simpósio de Engenharia Biomédica, 2016, 2016.

SOARES, V. J.; SILVA, G. M. **Protótipo de sistema de biofeedback a partir de sinais de GSR.** Em: VIII Simpósio em Engenharia Biomédica, 2015, Uberlândia. Anais do VIII Simpósio em Engenharia Biomédica. Bauru: Canal 6, 2015. v. 1. p. 219-224.

RABELO, A. G.; SILVA, G. M.; L. P. Neves; PERINI, A. P.; ANDRADE, A. O. **Análise de um novo método para mensuração do tremor fisiológico por meio do magnetômetro LSM303D imerso em um campo magnético.** Em: 7º Simpósio de Instrumentação e Imagens Médicas (SIIM) / 6º Simpósio de Processamento de Sinais da UNICAMP (SPS-UNICAMP'2015), 2015, Campinas. Anais do VII Simpósio de Instrumentação e Imagens Médicas (SIIM) VI Simpósio de Processamento de Sinais da UNICAMP (SPS-UNICAMP'2015), 2015. p. 58-61.

WALTER, S.; GRUSS, S.; TRAUE, H. C.; HAZER, D.; MA, X. Y.; JERG-BRETZKE, L.; WERNER, P.; AL-HAMADI, A.; SILVA, G. M.; Adriano O. Andrade. **Data fusion for automated pain recognition.** International Conference on Pervasive Computing Technologies for Healthcare (PervasiveHealth). 2015

WALTER, S.; GRUSS, S.; TRAUE, H. C.; HAZER, D.; MA, X. Y.; JERG-BRETZKE, L.; WERNER, P.; AL-HAMADI, A.; SILVA, G. M.; Adriano O. Andrade. **Multimodal Automatic Pain Recognition via Video Signals and Biopotentials.** In: Adriano de Oliveira Andrade; Alcimar Barbosa Soares; Alexandre Cardoso; Edgard Afonso Lamounier. (Org.). *Tecnologias, Técnicas e Tendências em Engenharia Biomédica.* 1ed. Bauru: Canal 6, 2014, v. 1, p. 201-210

## **1.4 ESTRUTURA DO TRABALHO**

O presente trabalho está dividido em oito capítulos. Este capítulo apresentou uma breve introdução ao tema da pesquisa com a motivação para seu desenvolvimento e os objetivos.

O Capítulo 2 aborda os processos fisiológicos envolvidos na geração do sinal EEG detectável no escalpo, bem como o condicionamento e processamento necessário no sinal medido para caracterizar o sinal EEG. Além disso, são discutidos a natureza e características dos principais artefatos que podem contaminar o sinal de interesse.

Perspectivas históricas e o Estado da arte com as principais técnicas de filtragem do EEG serão apresentadas no Capítulo 3.

Na sequência, o Capítulo 4 mostra a caracterização do ruído presente no sinal EEG gerado por contração musculares faciais em um estudo com 10 voluntários.

O Capítulo 5 apresenta a estratégia de filtragem de sinais EEG contaminados por sinais musculares o filtro EMDRLS.

O Capítulo 6 apresenta uma visão com enfoque na inspeção visual das formas de onda e dos espectros do filtro EMDRLS em comparação com demais técnicas de canal único em um sinal semi-sintético.

O desempenho do filtro EMDRLS aplicado à sinais reais para contaminações causadas por contrações dos músculos frontal e masseter são apresentadas no Capítulo 7.

As discussões e conclusões deste trabalho são apresentadas no Capítulo 8.

# **Capítulo 2**

## **GERAÇÃO, AQUISIÇÃO E CARACTERÍSTICAS DO SINAL EEG**

Este capítulo aborda como o EEG reflete a atividade elétrica do cérebro medida no escalpo por meio de eletrodos posicionados sobre o couro cabeludo, bem como as características desse registro. Além disso, são explanados os requisitos de um sistema de EEG e os principais artefatos que corrompem a forma de onda do sinal neuronal.

### **2.1 A GÊNESE DO SINAL EEG: DAS CÉLULAS PIRAMIDAIS AO GALVANÔMETRO**

A história do EEG em seres humanos parte da curiosidade do pesquisador Hans Berger nos fenômenos psíquicos da “energia mental” que culminou no seu relato de registro da atividade elétrica rítmica no couro cabeludo, em 1924. Entretanto, mesmo o pesquisador tendo demonstrado a deflexão angular do ponteiro de seu galvanômetro conectado à eletrodos posicionados sobre o

escalpo [28], apenas em 1934 quando Adrian e Mathews demonstraram que o ritmo alfa, ou “ritmo de Berger”, era de origem cortical que o EEG começou a ser aceito como um método de mensurar a atividade cerebral [29]. No entanto, as fontes neuronais do ritmo alfa permaneceram desconhecidas até os anos 1970, quando foi demonstrado que a geração do ritmo é oriunda de camadas do córtex visual [30].

Esse registro da atividade elétrica espontânea é gerado pelos neurônios cerebrais. Como todas as demais células do corpo, os neurônios têm altas concentrações de íons potássio ( $K^+$ ) e cloreto ( $Cl^-$ ) no interior, enquanto altas concentrações de íons sódio ( $Na^+$ ) e cálcio ( $Ca^{2+}$ ) são mantidas no exterior da célula. Isso leva a uma diferença de tensão em torno de -60 a -70 mV em relação à parte externa da membrana celular. Essa diferença de voltagem pode ser modificada por um fluxo de íons, os quais estes dependem de canais de abertura e fechamento de íons que são induzidos por estímulos elétricos ou químicos.

Uma redução dessa diferença de tensão através da membrana, devido a um influxo de íons positivos carregados na célula, resulta em um potencial menos negativo da membrana e é denominado despolarização. E um aumento que leve a um potencial mais negativo da membrana é chamado hiperpolarização. Quando uma quantidade crítica de  $Na^+$  entra na célula e o potencial da membrana atinge um nível limite, a abertura de canais adicionais de  $Na^+$  é facilitada, levando a um aumento acentuado da despolarização. Esse rápido evento despolarizante corresponde à fase ascendente do potencial de ação, enquanto a fase descendente está relacionada a um fluxo de íons  $K^+$  que, combinado com uma diminuição do influxo de  $Na^+$ , induz uma repolarização da célula. Após um potencial de ação, há uma inativação transitória dos canais de  $Na^+$  que causa um período refratário durante o qual outro potencial de ação não pode ser gerado [31,32].

O potencial de ação pode percorrer longas distâncias axonais o qual alcança o terminal nervoso sem perda de amplitude. Assim, ele dispara a liberação de neurotransmissores na fenda sináptica, propagando o sinal para o próximo neurônio no circuito. Um potencial de ação no neurônio pré-sináptico de natureza excitatória ou inibitória induz o que chamamos de potencial excitatório pós-sináptico (PEPS) e de potencial inibitório pós-sináptico (PIPS), no neurônio pós-sináptico. Um PEPS produz um influxo de cargas positivas na célula, enquanto um PIPS age de maneira oposta, induzindo um fluxo de cargas positivas fora da célula. Ambos, PEPS e PIPS, representam a fonte mais importante na leitura dos sinais de EEG no escopo [33].

Ao contrário dos potenciais de ação (normalmente com maior amplitude), os potenciais sinápticos têm uma duração mais longa (dezenas de milissegundos), o que aumenta a probabilidade desses eventos ocorrerem com uma sobreposição temporal. Além disso, envolvem uma superfície de membrana maior. Essas características contribuem com soma temporal e espacial de potenciais sincronizados que podem ser lidos no escopo refletindo atividade cerebral [34].

Buzsaki e colaboradores em 2003 destacaram uma possível contribuição de eventos intercelulares não sinápticos, como oscilações subliminares, após potenciais e picos de  $\text{Ca}^{2+}$ , que também produzem eventos transmembranares duradouros, para o sinal de EEG [32]. Além disso, Speckmann e colaboradores também complementaram em 2006, que não apenas os neurônios, mas também as células da glia podem contribuir para o campo médio medido pelo EEG, provavelmente com um efeito amplificador [34].

Contudo a principal contribuição para o sinal elétrico detectado pelo eletroencefalógrafo é de majoritariamente representada pela soma de PIPS E PEPS nos dendritos e corpos celulares neuronais do córtex, em particular os dos neurônios piramidais de orientação vertical, com dendritos apicais estendendo-se para lâminas e axônios mais superficiais, projetando-se para lâminas mais profundas. A polaridade dos potenciais de superfície está relacionada à localização da atividade sináptica no córtex, uma vez que os eletrodos do EEG no couro cabeludo detectam os campos elétricos extracelulares gerados mais próximos da superfície cortical [35].

Tais processos permitem o sistema nervoso executar sua principal função que é a de controlar as atividades do corpo, processando as informações aferentes. Contudo, cerca de 99% da informação sensorial é descartada pelo cérebro, sendo que apenas as informações sensoriais importantes são canalizadas para regiões integrativas e motoras apropriadas objetivando provocar respostas desejadas. Em análise temporal o comportamento do sinal EEG não tem padrão específico, porém há momentos que características específicas podem aparecer, ocorrendo principalmente quando há presença de patologias neurológicas [31].

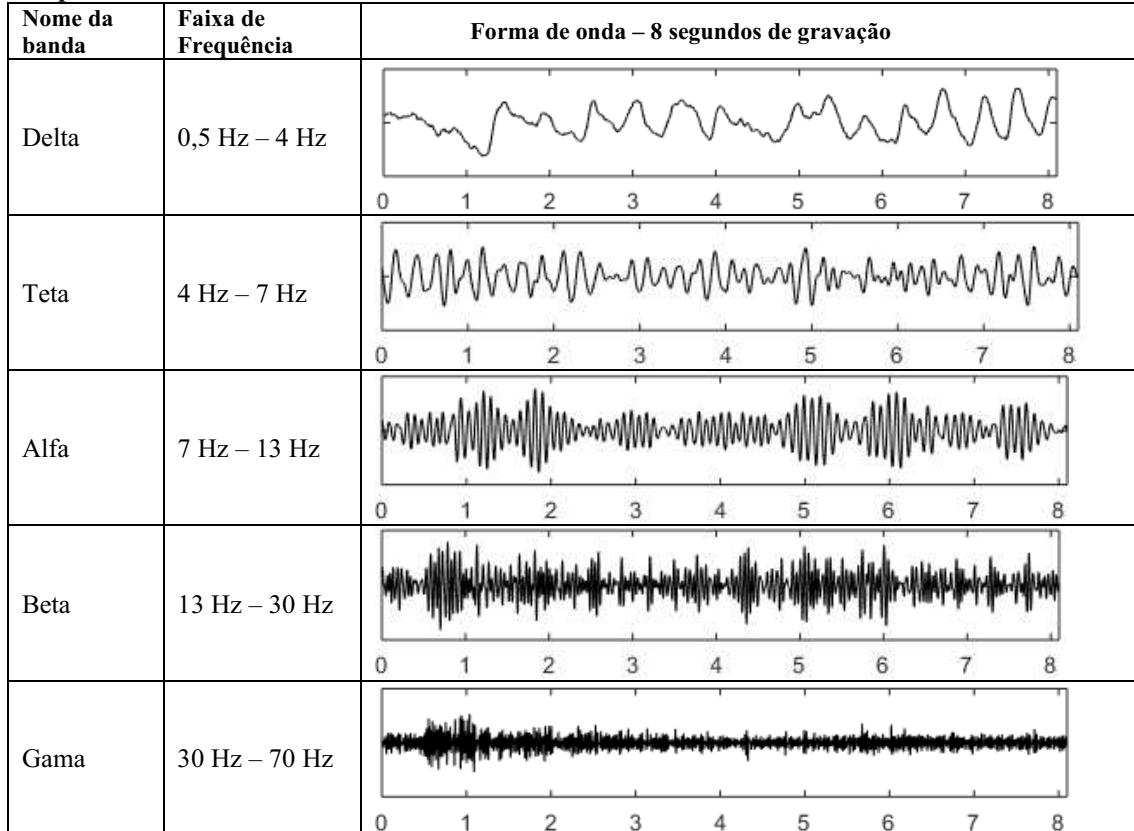
## 2.2 OS RITMOS CEREBRAIS

Pode não ser surpreendente que os mecanismos de geração e o significado funcional do EEG permaneceram controversos por um tempo relativamente longo, considerando a complexidade dos sistemas neuronais subjacentes e a propagação dessa energia para a superfície ao couro cabeludo graças às propriedades do volume condutor. Tal complexidade de origem demandou por classificações do sinal EEG que se relacionassem com determinados processos eletrofisiológicos corticais. Assim, a metodologia mais clássica de identificação dos diferentes padrões do sinal EEG é através dos ritmos da forma de onda, os quais configuram um agrupamento da frequência dominante em bandas de frequência específicas [1,36].

Desde as descobertas de Hans Berger, oscilações de potenciais elétricos medidos no escálepo de inúmeras espécies de mamíferos foram estudadas, hoje se sabe que essas oscilações

partem de oscilações lentas com períodos de minutos até oscilações muito rápidas com frequências atingindo 600 hertz. Em seres humanos, tais faixas de frequências descobertas foram posteriormente rotuladas com letras gregas e as fronteiras entre as bandas determinadas de maneira arbitrária [32]. Essa forma de classificação para as bandas de frequência do EEG (delta, teta, alfa, beta e gama), como mostrado na Tabela 1, é uma das classificações mais aceitas, estabelece pelo 5 bandas entre 0,5 Hz até 70 Hz.

**Tabela 1: Bandas de frequências básicas do sinal EEG. Época retirada de coleta realizada neste estudo e decomposta dentro de tais faixas de frequências por meio de filtros passa banda digitais do tipo Butterworth sintonizados nas 5 faixas das bandas do EEG.**



Essas bandas de frequências apresentadas na Tabela 1 inferem processos cerebrais diferentes e merecem a devida atenção sendo relevantes também no processo de caracterização de artefatos e nas medidas de desempenho de um filtro de EEG. A Tabela 2 explicita mais detalhes das principais bandas relacionadas com os processos corticais básicos e a sua distribuição topográfica. Apesar do intervalo de frequência típico empregado para o diagnóstico de várias condições cerebrais concentrar-se nas bandas de baixa frequência (delta, teta e alfa), nas atuais aplicações devem ser incluídos componentes de alta frequência ( $> 30$  Hz). Estes componentes, são incluídos nas análises de sinais de EEG aplicados a avaliações clínicas em doenças como esquizofrenia, déficits no processamento visual e disfunções do córtex motor. Isso foi possível a partir do início do uso de técnicas computacionais de processamento digital de sinais (PDS) na faixa de frequência acima 30 Hz [37,38].

Apesar de frequentemente descrita com a faixa de 30 a 70 Hz, hoje é conhecido que a atividade da banda gama ultrapassa essa faixa de frequência de EEG e pode alcançar 200 Hz, e é amplamente distribuída pelas estruturas cerebrais. Sabe-se que as altas frequências do EEG estão envolvidas em funções cerebrais, como percepção, atenção, memória, consciência, plasticidade sináptica e controle motor [39]. Assim, dentro da faixa de frequência da banda gama, é possível diferenciar a clássica faixa de frequências da banda gama (30–70 Hz) e as altas frequências da banda gama (*high gamma-band*) (70–200 Hz). Alguns estudos eletrofisiológicos mostraram que a atividade da banda gama na faixa de frequências de 30 a 90 Hz pode ser registrada em uma ampla gama de regiões do cérebro durante o repouso ou na execução de tarefas motoras [40,41].

A atividade da banda gama é normalmente registrada com um alto número de eletrodos, para avaliação da dor muscular tônica ou do processamento multissensorial em pacientes com esquizofrenia. Esse processo requer métodos complexos de processamento de sinal para reduzir o ruído e amplificar os componentes (filtros passa-banda, rejeição de artefato, ICA, wavelets). As análises são baseadas na densidade espectral de potência na banda de interesse usando análises de tempo-frequência.

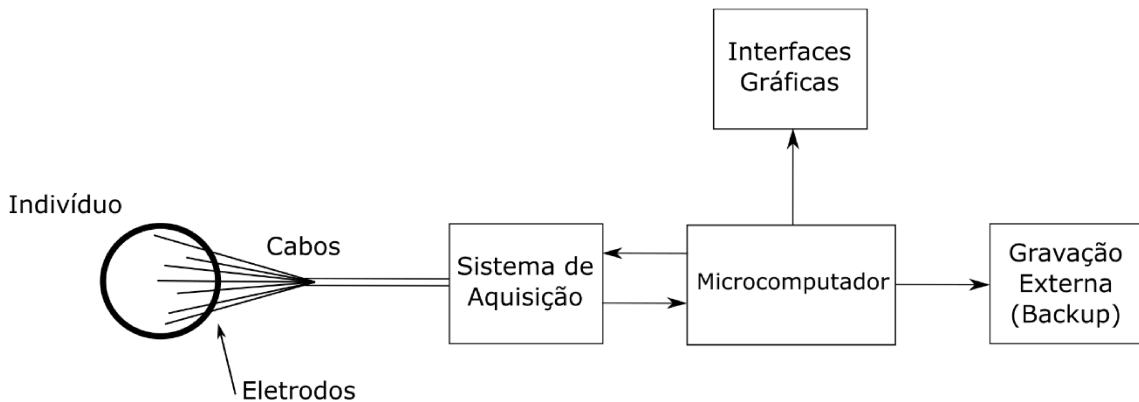
**Tabela 2: Resumo das principais propriedades dos ritmos do EEG abaixo de 70 Hz [1,31,36,38,42–46].**

	Distribuição	Estados de sentimento subjetivo	Tarefas e comportamentos associados	Correlatos fisiológicos
Delta	Geralmente ampla ou difusa, pode ser bilateral.	Sono profundo, sem sonhos, sono não-REM, transe, inconsciência.	Letárgico, sem movimento, não atento.	Não se movendo, baixo nível de excitação.
Teta	Geralmente regional, pode envolver muitos lobos, pode ser lateralizada ou difusa.	Intuitivo, criativo, recordação, fantasia, imagens, sonolento.	Criatividade, mas também pode ser distraído, desfocado.	Relaxado
Alfa	Regional, geralmente envolve lobo inteiro; forte no occipital com olhos fechados	Relaxado, não agitado, mas não sonolento; tranquilo, consciente.	Meditação, sem ação.	Relaxado
Beta	Localizada lateralmente e por lobo (frontal, occipital, etc.). Pode ser focado em um eletrodo.	Focado, pensamento integrado, consciente de si e do entorno, estado de alerta, agitação.	Atividade mental, por exemplo, matemática, planejamento.	Alerta, ativo
Gama	muito localizada	Pensamento; pensamento integrado	Processamento de informações de alto nível	Associados ao processamento de tarefas ricas em informações

O entendimento, e a correta interpretação das origens e causas das diferentes formas de onda contidas em um sinal EEG tem importância obvia para a efetividade das diversas aplicações. Entretanto, tem uma importância particular nos processos de filtragem de artefatos. Isso porque é importante que os processos de filtragem ofereçam garantias da qualidade do sinal recuperado pelo filtro, além do fato de manter os investigadores atentos aos protocolos de coletas de dados.

## 2.3 O SISTEMA DE AQUISIÇÃO DE EEG

Os sistemas de aquisição e processamento de EEG possuem capacidade de realizar aquisição de dados, algum tipo de filtragem, gravação/leitura de dados e análise quantitativa dos dados para melhor descrever a atividade neurológica relevante. Como é mostrado na Figura 1, um sistema típico é composto de múltiplos dispositivos, os quais tem as funções de condicionar, processar e exibir o sinal EEG [47].



**Figura 1:** Diagrama de blocos com os principais componentes de um sistema de captura de sinal EEG. Os eletrodos captam sinais que são condicionados pelo sistema de aquisição para em seguida serem processados nas suas respectivas aplicações.

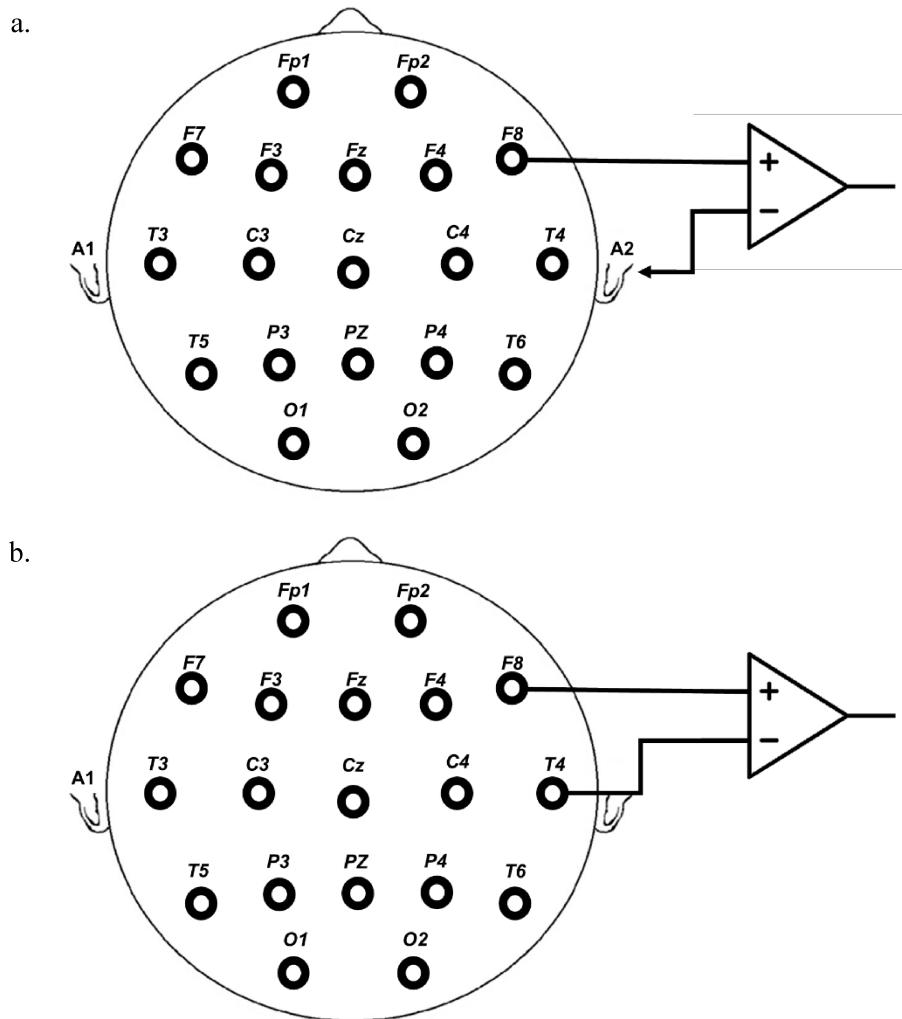
### 2.3.1 Eletrodos

Os eletrodos são os elementos que provêm a ligação elétrica entre o sinal do cérebro e o monitor de EEG, os quais devem ser apropriadamente colocados no couro cabeludo para a gravação dos potenciais elétricos. Normalmente são pequenos discos de prata cobertos com sais de cloro e requerem limpeza e abrasão do couro cabeludo, além disso, o contato elétrico é garantido por meio de gel condutor. Os eletrodos não devem causar distorção ao potencial elétrico registrado no couro cabeludo, devem ser construídos com materiais que não interagem quimicamente com os eletrólitos no couro cabeludo e devem ter impedância inferior à  $5\text{ k}\Omega$  [48,49].

Além desses requisitos físicos dos eletrodos de EEG, os padrões para o posicionamento dos mesmos no couro cabeludo devem ser adequados a fim de uma cobertura uniforme no couro cabeludo. A Federação Internacional das Sociedades de EEG e Neurofisiologia Clínica

recomendam a configuração de posicionamento conhecida como 10-20 [50]. Esta configuração usa as distâncias entre os marcos ósseos da cabeça para gerar um sistema de linhas, que passam pela cabeça e se cruzam em intervalos de 10 ou 20% do seu comprimento total, atribuindo números ímpares para os eletrodos do lado esquerdo da cabeça e números pares para os eletrodos do lado esquerdo. O uso do sistema 10-20 garante uma cobertura simétrica e uma reproduzibilidade na colocação dos eletrodos e que assegura uma comparação mais precisa entre registros diferentes de EEG [51,52].

Em conjunto com as propriedades físicas e os arranjos de posicionamento, a ligação elétrica dos eletrodos também é outro fator importante do sistema de aquisição. A maneira como cada eletrodo é conectado nos pinos de entrada do amplificador de instrumentação é denominado montagem. Estas podem ser requisitadas principalmente de duas derivações: (1) referência comum ou montagem unipolar, o eletrodo é medido em relação à uma referência em comum com todos os outros eletrodos – eletrodos no lóbulo da orelha (A1 ou A2), o eletrodo Cz ou o Fpz, como mostrado na Figura 2a; (2) montagem bipolar, o eletrodo é medido em relação à algum eletrodo vizinho como mostrado na Figura 2b. Além dessas referências a nível de hardware, a referência comum média, que é uma média da medida de grupos de eletrodos pode ser usada como referência na medida de cada eletrodo, como exemplo das referências laplacianas, CAR (*common average reference*) ou combinação dos eletrodos A1 e A2, os quais podem ser considerados referências médias comuns [42,48,53,54]. Essa última técnica que utiliza a média comum também é conhecida como gravação sem referência. Normalmente todas essas montagens podem ser requisitadas para todo EEG, permitindo um eletroencefalografista no momento da revisão analisar o traçado em diversas montagens [55]. Contudo, apesar dessas montagens apresentarem vantagens e desvantagens a cada aplicação, na área de instrumentação biomédica moderna, a escolha de uma dessas três montagens de eletrodos não ocasionará em prejuízo nas medições [56–58]. Afinal, devido à alta capacidade de processamento computacional atual, as referências podem ser facilmente recalculadas.



**Figura 2: Derivações das ligações dos eletrodos de EEG: a. Unipolar ou referência comum; b. Bipolar**

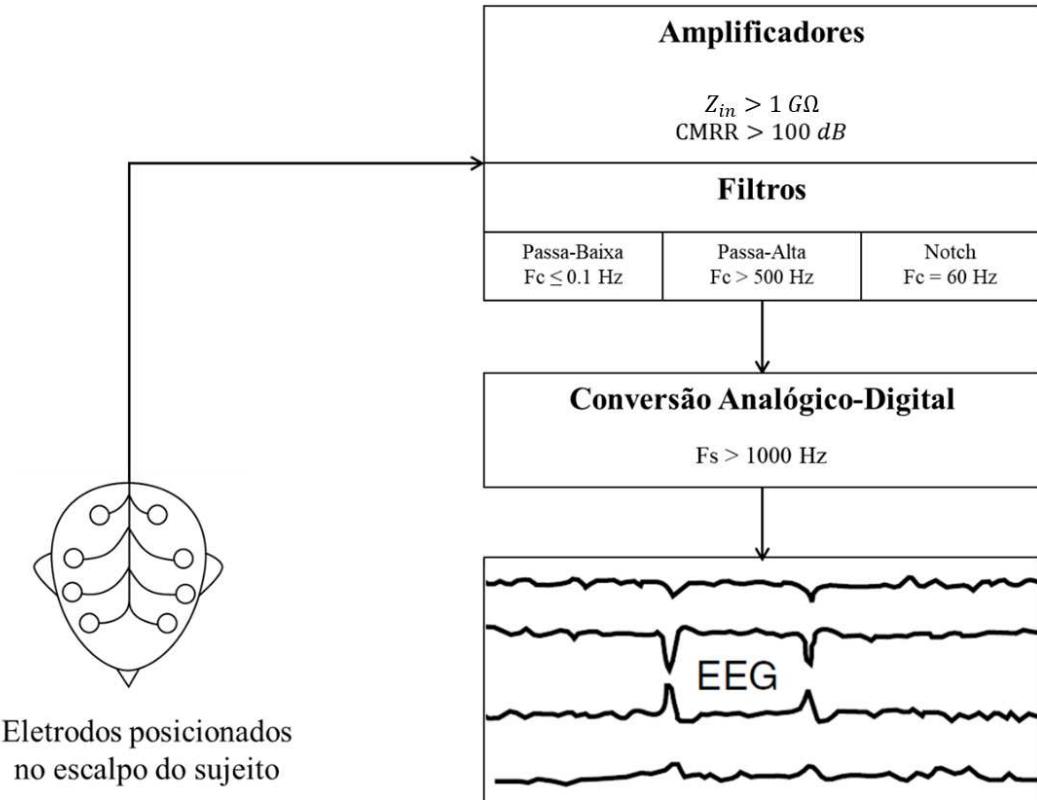
Também é importante mencionar as principais especificações para o cabo que irá conectar os terminais do eletrodo à entrada dos amplificadores de instrumentação dos instrumentos de monitoramento. É preferível que o cabo seja, blindado, de curto comprimento, que garanta uma baixa impedância para o adequado casamento das impedâncias e que não cause distorção do potencial elétrico que representa a atividade neurológica.

### 2.3.2 Sistema de condicionamento de sinais

Conforme vem sendo construído ao longo deste capítulo, o monitoramento da atividade elétrica cerebral nos auxilia a entender o funcionamento dos substratos neurais fisiológicos e patológicos. Entretanto, como já foi apresentado, a baixa amplitude dos sinais de EEG e a sua susceptibilidade a ruídos dificultam a sua detecção. Assim o ponto de partida de um instrumento para aquisição e condicionamento de dados de EEG se baseia principalmente: (1) na amplitude do EEG medido pelos eletrodos do crânio, que compreendem valores entre 1 e 50 microvolts; (2) na faixa frequência ocupada, abrangendo um espectro com largura de até 200Hz, apesar da maioria das aplicações e coletas limitarem a banda em 70 Hz [40] e (3) nos deslocamentos do offset do sinal devido à interface eletrodo-tecido e ocasionais movimentos dos cabos e do próprio sujeito. Por conseguinte, os modernos condicionadores de sinal EEG usados em seres humanos contam com alto ganho, alta impedância de entrada e filtragem passa-banda [59].

A Figura 3 apresenta um diagrama de blocos referente a instrumentação do sistema de aquisição, o qual compõe o sistema de EEG mostrado na Figura 1 com seus elementos analógicos e digitais. Conforme mostrado na Figura, o mesmo é composto basicamente por (1) amplificadores, (2) filtros e (3) conversores analógico-digitais (ADC): (1) Os estágios de amplificação apresentam alto ganho, na ordem de 20.000 vezes, uma vez que potenciais do cérebro medidos no couro cabeludo são da ordem de microvolts. Além disso, os amplificadores de instrumentação contribuem com o condicionamento do sinal medido através do casamento de impedâncias feito com a interface eletrodo-pele por meio de uma alta impedância de entrada, na ordem de Gigaohms, resultando em uma maior transferência de potência. O estágio de amplificação para EEG também normalmente demandará de uma rejeição em modo comum nos pinos de entrada do amplificador de instrumentação superior ao que se exige na aquisição de outros biopotenciais (exemplo: ECG e EMG), acima de 100 dB [48,60]. (2) A filtragem analógica é uma etapa de pré-processamento na qual atenua frequências externas à faixa de frequências do EEG, reduzindo a contaminação do EEG bem como limitando a frequência máxima do sinal amostrado, evitando o *aliasing* [61]. (3) O conversor analógico-digital (ADC) digitaliza os dados do EEG por amostragem (converte o sinal EEG de tempo contínuo em um sinal de tempo discreto) e atribui um nível quantizado para cada amostra. Nesse estágio deve ser observado a frequência de amostragem, na qual provoca alterações no espectro do sinal amostrado e a deve atender fundamentalmente o teorema da amostragem [48,59–61]. Também deve ser observado a sensibilidade do quantizador, no qual os níveis de quantização devem privilegiar a forma de onda do EEG ao mesmo tempo que auxilia suprimir ruídos intrínsecos dos condutores, como o ruído

térmico. É importante também se atentar em um projeto de aquisição e processamento, a adição de ruído no sinal EEG causada pelo processo da quantização uniforme [62,63].



**Figura 3: Diagrama esquemático do bloco de aquisição de dados de um sistema de EEG. O mesmo apresenta as condições mínimas para leitura e amostragem de um sinal EEG tanto em relação aos parâmetros do amplificador de instrumentação como em relação aos filtros e o amostrador.**

### 2.3.3 Demais elementos de um sistema de aquisição de sinal EEG

Um dos grandes saltos na consolidação das diversas aplicações do EEG se deu devido ao emprego de microprocessadores nas máquinas de EEG, por isso, um computador poderá interligar demais elementos periféricos ao registro do EEG. Tais elementos, como mostrado na Figura 1, incluirão interfaces gráficas e os bancos de dados das aplicações diagnósticas. Além disso, como é sabido, o computador também é recurso que permitiu a interligação das leituras de EEG com HCIs e BCIs das mais variadas aplicações, abrangendo de comunicações a jogos virtuais.

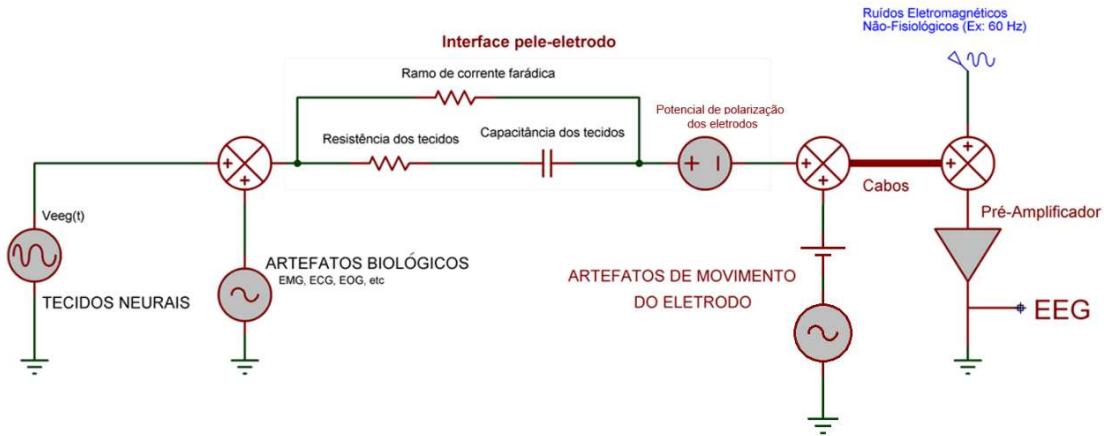
## 2.4 OS PRINCIPAIS ARTEFATOS PRESENTES NO SINAL EEG

O uso do computador para processamento de um sinal de origem analógica, a exemplo de um sinal biomédico, implica que este sinal analógico deve ser representado no formato digital [64]. Consequentemente, dois fatos sobre a mensagem analógica são apontados: (i) a mensagem analógica que contém a forma de onda original da informação desejada e que (ii) o próprio processo de digitalização desta, adicionará um ruído de digitalização intrínseco. No entanto, os sistemas digitais são mais robustos que os sistemas analógicos, pois toleram melhor o ruído e a distorção ao longo do canal [63,65].

Desta forma, a tratativa dos sinais biomédicos no domínio digital possibilitou, não somente o avanço no processamento e armazenamento das informações, como também foi um importante fator no aumento da relação sinal-ruído. Contudo, a propagação dos biopotenciais humanos pelo menos entre o ponto de geração até o ponto de detecção nos eletrodos é feita por um canal analógico, que são os próprios tecidos do corpo. Durante essa propagação reside um dos principais desafios da aquisição de biopotenciais, que é a contaminação por outros potenciais elétricos que não contém a informação desejada.

Nesse sentido, os artefatos comuns no EEG podem ser divididos em duas categorias: fisiológicos e os não-fisiológicos. Sinais elétricos originados em fontes não são cerebrais do corpo humano são os ruídos fisiológicos do EEG. Já os artefatos originados de fontes externas ao corpo são os sinais não fisiológicos. A Figura 4 esquematiza o processo de registro de EEG, partindo da geração do potencial elétrico pelas células nervosas até a entrada dos estágios de amplificação dos leitores de EEG. Os potenciais pré e pós-sinápticos que formam o EEG ( $V_{eeg}(t)$ ) são somados aos potenciais gerados pelos diversos artefatos fisiológicos (EMG, ECG, EOG e etc).

A Figura também permite verificar que a informação oriunda dos tecidos neurais, além de somadas com artefatos fisiológicos, também estão sujeitas à imposição de uma forte atenuação na interface pele-eletrodo, devido à magnitude da sua impedância. Além disso, após percorrer a interface eletrodo-pele, o sinal EEG ainda estará sujeito à importantes artefatos não-fisiológicos, como por exemplo o potencial de meia-célula dos eletrodos, potenciais oriundos de interferências eletromagnéticas ao longo dos cabos, além de eventuais artefatos causados pelo movimento dos cabos ou dos eletrodos [6,48,62,66].



**Figura 4:** Esquema das diferentes fontes de artefatos presentes no registro de EEG. Os principais produtores de artefatos são oriundos dos artefatos biológicos (mais próximos da fonte), a interface eletrodo-pele e eventuais movimentos dos cabos ou eletrodos.

Para descrever esse conjunto de artefatos, a Tabela 3 apresenta as características dos principais ruídos presentes em um registro de EEG. Nela são tabelados os artefatos fisiológicos [67]:

- Os artefatos oculares, decorrentes do globo ocular agindo como um dipolo elétrico o qual propaga artefatos de grande amplitude no EEG, estes incluem piscadas, movimentos verticais e horizontais dos olhos, movimento durante o sono REM etc;
- Os artefatos musculares, se enquadram como um dos mais proeminentes, com frequências espectrais mínimas a partir de 15 Hz, geradas principalmente por mordidas, fala, movimento das sobrancelhas, movimento da boca e do nariz e etc;
- Artefatos cardíacos, advindos do campo eletromagnético gerado pelo coração, podendo adicionar ruído de ECG e um ruído originado na pulsação, este último de baixa frequência que pode ser bem semelhante ao próprio EEG;
- Artefatos respiratórios, originados nos movimentos de inspiração e expiração os quais podem se parecer com as ondas lentas do EEG, delta por exemplo;
- Artefatos na interface pele-eletrodo, estes têm origem no suor, ou endotérmicas o quais podem causar alterações na concentração eletrolítica na interface, ocasionando em um artefato de baixa frequência até 0,5 Hz.

Além disso, a Tabela também mostra os artefatos de origem não fisiológica [68]:

- Os instrumentais, como 50/60 Hz da rede e seus harmônicos; eletrodos soltos ou mal colocados os quais podem levar a mudança de impedância na interface eletrodo-tecido, vale lembrar que estes são diferentes dos artefatos gerados por suor na pele;

- As interferências vindas dos dispositivos elétricos, eletrônicos, máquinas e qualquer interferência sonora ou óptica que possam ser captadas pelos eletrodos de EEG como artefatos;
- Artefatos de movimento do sujeito, os quais tem uma amplitude extremamente alta, normalmente saturando o fundo de escala das gravações, gerados principalmente por movimento da cabeça, movimentos nos membros, tremores, caminhada, corridas, e muitos outros.

**Tabela 3: Diferentes tipos de artefatos e suas origens.**

<b>Fisiológico/Interno</b>				<b>Não-Fisiológico/Externo</b>		
Ocular	Cardíaco	Muscular	Outros	Instrumental	Interferências	Movimento
Piscada, movimento ocular, espasmos na pálpebra, Movimento rápido dos olhos (sono REM) e etc.	ECG e pulsação	Mastigação, deglutição, fala, contração do couro cabeludo e etc.	Respiração, pele e etc.	Eletrodos mal posicionados, movimento de cabo, problemas no aterrramento	Elétrica, magnética, sonora e etc.	Movimento da cabeça, do corpo, dos membros, tremores e etc.

## 2.5 CONSIDERAÇÕES FINAIS

Este capítulo apresentou a geração do sinal EEG lido pelos sistemas de aquisição, as interpretações básicas das formas de onda, as características e os requisitos mínimos a serem atendidos em um sistema de aquisição. O capítulo encerrou abordando sobre os artefatos nos quais o EEG está suscetível o que ajuda a direcionar o capítulo a seguir para a discussão de conceitos clássicos de processamento e filtragem de sinais digitais bem como a análise da abordagem dos recentes esforços na literatura em torno da filtragem do EEG.

# **Capítulo 3**

## **FILTRAGEM DE SINAIS AMOSTRADOS NO TEMPO E AS PRINCIPAIS ESTRATÉGIAS DE FILTRAGEM DO EEG**

Conforme abordado no Capítulo 2, o EEG pode ser contaminado por artefatos de diversas naturezas, os quais sobrepõem a forma de onda de interesse. Isso demanda de sistemas que removam o artefato sinal contaminado. Assim, esse capítulo apresenta as principais técnicas descritas na literatura usadas para a remoção de artefatos do EEG. E por fim, é apresentado uma análise dos trabalhos desde 2008 os quais foram direcionados para a remoção de artefatos do sinal EEG.

## 3.1 PRINCIPAIS TÉCNICAS DE REMOÇÃO DE ARTEFATOS DO EEG

Ao se estudar a filtragem digital de forma abrangente, normalmente são apresentados conceitos relacionados com o projeto de filtros lineares digitais, como os filtros de resposta ao impulso finita e infinita (FIR e IIR). Para o EEG, no entanto, um projeto de filtros FIR ou IIR não é sempre tão eficiente na remoção de alguns artefatos, especialmente os artefatos de origem fisiológica. Isso ocorre devido à sobreposição com as faixas de frequência dos artefatos e da natureza não linear da geração tanto do EEG como dos artefatos. Deste modo, o condicionamento do sinal EEG, que inclui a remoção de artefatos, requer tanto técnicas de filtragem linear e determinística, como o caso dos filtros IIR e FIR, quanto técnicas de filtragem não linear, filtragem adaptativa e baseada em decomposição [6,8,9,13,15,69].

Essa seção apresenta as principais técnicas descritas na literatura para a remoção de artefatos fisiológicos do EEG. Destas técnicas, os filtros seletores de frequência, passa-baixa, passa-faixa ou passa-alta representam classicamente uma das primeiras tentativas de remoção de artefatos do EEG. Contudo, isso só é eficaz quando as faixas de frequência do sinal e da interferência não são sobrepostas [8].

Nesse contexto, a literatura apresenta as seguintes técnicas para remoção de artefatos no EEG: filtragem adaptativa [70]; filtragem de wiener [71,72], filtragem bayesiana [73], *Blind Source Separation* (BSS) [74,75], transformada wavelet (WT) [76,77], *empirical mode decomposition* (EMD) [78,79] e métodos híbridos [14,80–83].

### 3.1.1 Filtragem Adaptativa

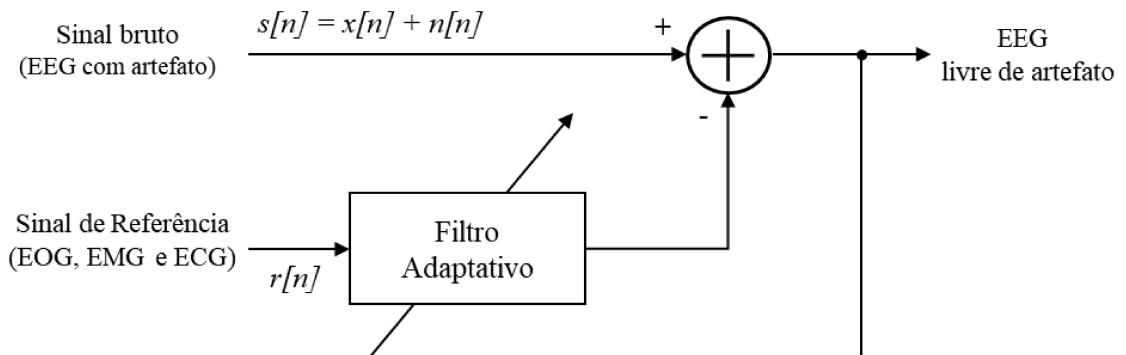
Um filtro adaptativo é necessário quando as especificações fixas são desconhecidas quando não podem ser satisfeitas por filtros invariantes no tempo. Estritamente falando, um filtro adaptativo é um filtro não linear já que suas características dependem do sinal de entrada e consequentemente a homogeneidade e aditividade não serão atendidas. No entanto, se os parâmetros do filtro fossem congelados em um determinado instante de tempo, a maioria dos filtros adaptativos seriam lineares. Portanto, os filtros adaptativos variam no tempo, pois seus parâmetros estão mudando continuamente para atender a um requisito de desempenho [84].

Nesse sentido, podemos interpretar um filtro adaptativo como um filtro que executa a etapa de aproximação em tempo real. Normalmente, a definição do critério de desempenho requer a existência de um sinal de referência que geralmente é desconhecido na etapa de aproximação do projeto de filtro. Esta discussão traz a sensação de que, no projeto de filtros não-adaptativos, é necessária uma completa caracterização dos sinais de entrada e de referência para conceber um filtro que atenda a um desempenho prescrito [26].

O procedimento de projeto é modelar os sinais e, subsequentemente, projetar o filtro. Este procedimento pode ser caro e difícil de implementar online. A solução para este problema é empregar um filtro adaptativo que realize a atualização online de seus parâmetros através de um algoritmo bastante simples, usando apenas informações disponíveis no ambiente, realizando a etapa de aproximação [26].

Sem especificações disponíveis, o algoritmo adaptativo que determina a atualização dos coeficientes do filtro, requer informações extras que geralmente são extraídas de um sinal. Este sinal é chamado de sinal desejado ou de referência. Na filtragem de EEG, a escolha da referência é a chave para a filtragem adequada. A mesma é obtida por meio do EOG para a remoção de movimentos oculares [70,85,86], ou do EMG para a remoção de artefatos musculares [87]. Uma ilustração do uso do filtro adaptativo para a remoção de artefatos no EEG é mostrada na Figura 5.

Na figura, o sinal  $s[n]$ , composto de duas componentes: o EEG original,  $x[n]$  e o artefato  $n[n]$ . Se a fonte do artefato  $r[n]$  está disponível a partir de um canal dedicado (por exemplo, EOG ou EMG), então é possível estimar o EEG livre de artefato por meio de um algoritmo adaptativo (por exemplo, *Least Mean Squares* – LMS e *Recursive Least Squares* - RLS). Essa suposição é possível se assumindo que o EEG desejado e o artefato sinal são independentes (ou pelo menos não correlacionados [8,88,89]).



**Figura 5:** Uso típico de filtragem adaptativa no cancelamento de artefatos fisiológicos com o canal de origem de artefato disponível como referência.

A literatura descreve que a família de algoritmos mais prevalente para a rejeição de artefatos de EEG é baseada no método de mínimos quadrados, a qual é linear em complexidade e convergência [70,90].

### 3.1.2 Filtragem de Wiener

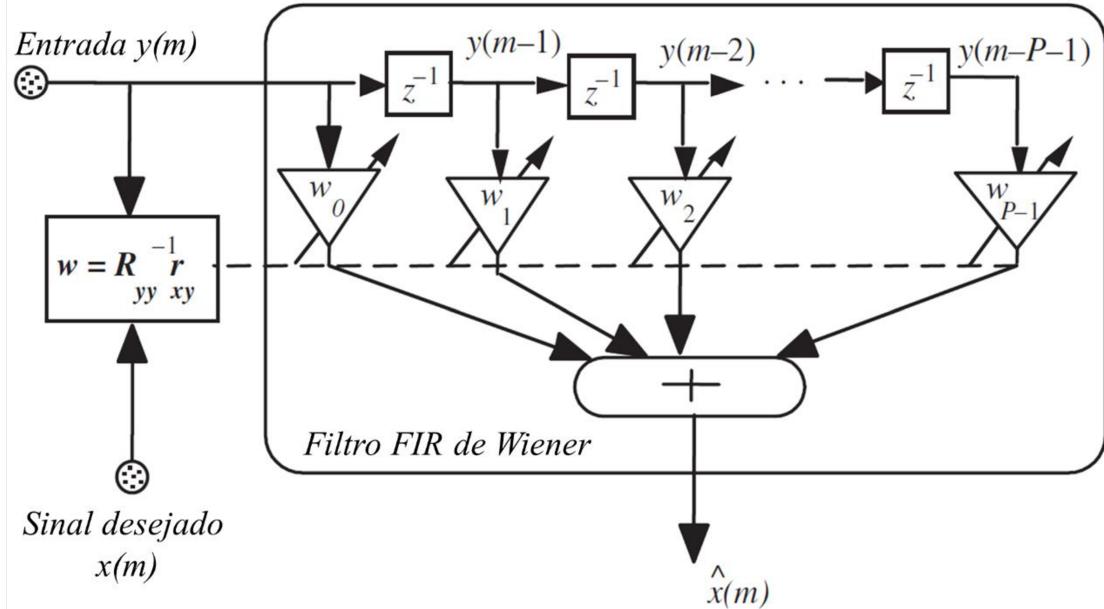
A filtragem de Wiener está fundamentada na teoria de inferência estatística na qual busca a definição de critérios para a escolha de estimadores de parâmetros populacionais a partir de características de uma amostra aleatória [91].

Assim, considerando um sinal  $x[n]$ , por exemplo o EEG, contaminado por um processo ruidoso  $v[n]$ , os quais combinados formam o sinal discreto no tempo  $y[n]$ .

$$y[n] = x[n] + v[n] \quad (1)$$

O objetivo do filtro de Wiener é estimar valores de  $\hat{x}[n]$ , a partir dos valores de  $y[n]$ , sendo  $\hat{x}[n]$  uma estimativa do sinal desejado  $x[n]$ . Essa estimativa, é dada pela soma de convolução entre  $y[n]$  e o vetor de coeficientes de Wiener  $w_k$ , conforme mostra a Equação 2 e o diagrama da Figura 6.

$$\hat{x}[n] = \sum_{k=0}^{P-1} w_k y(m-k) = w^T y \quad (2)$$



**Figura 6: Ilustração de um Filtro Wiener.**

Esses coeficientes  $w$  que compõem o filtro de Wiener devem minimizar o erro médio quadrático ( $e^2$ ) esperado na Equação 3.

$$E\{e^2[n]\} = E\{(x[n] - \hat{x}[n])^2\} \quad (3)$$

Substituindo  $\hat{x}[n]$ , da Equação 2 e reescrevendo-o na Equação 3 em notação vetorial [89].

$$e = x - Yw \quad (4)$$

Definida expressão matricial na Equação 4, a Equação 5 é composta pela matriz de coeficientes  $w$  que minimizará o erro médio quadrático ( $e$ ) será obtida com a matriz de autocorrelação ( $R_{yy}$ ) da entrada  $y[n]$  e a matriz de correlação cruzada ( $r_{yx}$ ) entre  $y[n]$  e o valor desejado  $x[n]$ .

$$R_{yy}w = r_{yx} \quad (5)$$

Que equivale ao mostrado na Equação 6.

$$w = R_{yy}^{-1}r_{yx} \quad (6)$$

Portanto, por não se tratar de um filtro determinístico a abordagem de Wiener se mostra adequada em situações em que o sinal e o espectro se encontram sobrepostos, apesar de requerer de uma referência estimada, medida ou confiável, para operar. Isso pode ser comprovado através

de relatos recentes literatura que testaram essa abordagem na remoção de ruídos do sinal EEG. Borowicz em 2017, comparou a *multichannel Wiener filter* (MWF) com BSS na remoção de artefatos do EEG, tendo MWF o melhor desempenho [92]. Ademais, Ferdous e Ali em 2015 compararam filtros de Wiener e de Kalman [71], tendo novamente o filtro de Wiener sido mais efetivo na remoção do artefato do EEG.

### 3.1.3 Filtro de Kalman

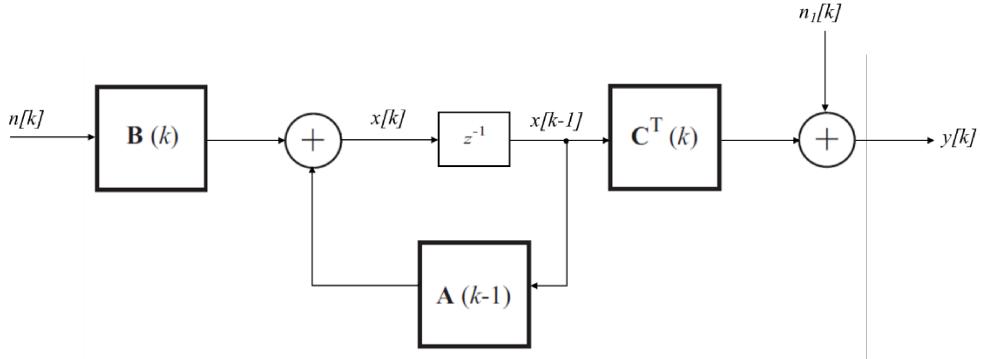
O filtro de Kalman, assim como o filtro de Wiener, é uma classe de filtro adaptativo, porém se fundamenta em um conjunto de equações matemáticas as quais constituem um processo recursivo eficiente de estimativa. Além disso, assim como a filtragem de Wiener, o mesmo também é direcionado à minimização do erro quadrático entre uma informação medida e estimada, contudo, trata-se de um procedimento aplicável quando os modelos do sistema estão escritos sob a forma espaço-estado, sendo uma essa uma importante particularidade do filtro de Kalman [93].

Formulado por Thorvald Nicolai Thiele em 1880 e Peter Swerling em 1958, o mesmo foi aplicado para estimativa de trajetória no programa espacial Apollo. O mesmo possui diversas aplicações sendo amplamente utilizado no controle de processos, em rádios, rastreamento de posição GPS, em HCIs baseadas em EEG [73,89,94], localização de fontes no EEG [95] e detecção e remoção de artefatos de EEG [96,97]. Trata-se de um filtro emprega as distribuições de probabilidade anteriores do sinal e os processos de ruído com o objetivo na minimização da estimativa do erro quadrático de um sinal não-estacionário com ruído. O sinal estimado é modelado utilizando a formulação do espaço de estados descrevendo seu comportamento dinâmico gerando sinais que podem ser medidos e processados utilizando fórmulas recursivas de estimativa de tempo [26].

Antes da descrição do funcionamento do filtro é importante explicar o que é a representação em espaço de estados, que pode ser definida como uma forma conveniente de representar alguns sistemas dinâmicos. Em tal descrição, as saídas dos elementos de memória são consideradas como estados do sistema. Os sinais de estado são coletados em um vetor denotado como  $x[k]$ , que por sua vez são gerados do seu estado anterior  $x[k - 1]$  e de um vetor de sinal externo denotado como  $u[k]$ . Os sinais medidos são coletados em outro vetor denotado como  $y[k]$  cujos elementos são originários de combinações lineares das variáveis de estado atual e dos sinais externos representados em  $u_1[k]$  [26].

A Figura 7 mostra que conhecidos os valores dos sinais externos  $u[k]$  e  $u_1[k]$ , conforme a Equação 14, pode-se determinar os valores atuais do estado do sistema, que serão as entradas de atraso, e o vetor de observação do sistema. As principais aplicações implicam que os sinais externos  $u[k]$  e  $u_1[k]$ , sejam ruídos e erros no modelo e na medição, respectivamente [98].

$$\begin{cases} x[k] = A[k-1]x[k-1] + B[k]n[k] \\ y[k] = C^T[k]x[k] + D[k]n_1[k] \end{cases} \quad (7)$$



**Figura 7: Modelo de espaço de estados para formulação do filtro de Kalman.**

Portanto, conforme a Figura 7, observa-se que o presente método realiza uma estimativa probabilística do sistema a partir de observações ruidosas  $u$  e do modelo do sistema  $x$ , o que caracteriza o filtro adaptativo de Kalman como um filtro Bayesiano [8]. Estes filtros superam algumas das limitações do filtro de Wiener e dos filtros determinísticos porque são capazes de trabalhar sem um sinal de referência e operar em tempo real. Filtros bayesianos não são diretamente implementáveis devido à sua complexidade; sendo o filtro de Kalman uma aproximação do mesmo.

### 3.1.4 Métodos de Separação Cega de Fontes

As técnicas cegas nasceram na década de 1980, quando os primeiros equalizadores adaptativos foram concebidos para comunicações digitais. A comunidade científica usou a palavra “cego” para denotar métodos de decomposição baseados apenas em observações de saída [99]. Esse conceito é aplicado para separação de fontes, que é uma técnica de processamento da informação a qual recupera um conjunto de fontes a partir de um conjunto de observações, estando elas compostas por uma mistura das fontes [100]. Em vista disso, a separação cega de fontes ou *Blind Source Separation* (BSS), hoje compõe uma ampla classe de algoritmos que estimam as fontes

e os parâmetros de um sistema de mistura [101]. A Equação matricial 8 mostra o princípio matemático dessa técnica, os quais  $s_i$  e  $x_i \in \mathbb{R}^{1 \times L}$  representam  $M$  e  $P$  vetores de  $L$  amostras os quais contém respectivamente os sinais fonte e medido.

$$\begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_P \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1M} \\ a_{21} & a_{22} & \cdots & a_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ a_{P1} & a_{P2} & \cdots & a_{PM} \end{bmatrix} \begin{bmatrix} s_1 \\ s_2 \\ \vdots \\ s_M \end{bmatrix} + N \quad (8)$$

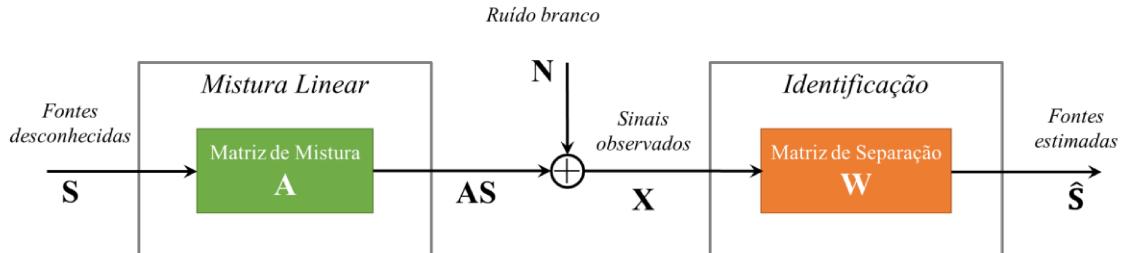
A matriz  $A$  é chamada de matriz de mistura e  $N$  representa a matriz com sinal de ruído. Isso posto, a maioria dos modelos de BSS pode ser expresso na forma matricial.

$$X = A \cdot S \quad (9)$$

A partir Equação 9, utilizando apenas observações  $X$  conhecidas, a técnica BSS é usada para gerar uma matriz não combinada para determinar as fontes originais  $\hat{S}$  [99], como mostrado na Equação 10

$$\hat{S} = W \cdot X \quad (10)$$

Em que  $W$  é a matriz de separação. A Figura 8 ilustra esse conceito geral da separação de fontes cegas.



**Figura 8: Ideia geral da separação cega de fontes.**

Apresentado o objetivo central dessa técnica, um importante ponto a se discutir é sobre a eficácia do conjunto de metodologias BSS existentes as quais estão sujeitas a confirmação de algumas suposições. Essas suposições, dependendo a técnica, podem exigir que as medidas sejam, descorrelacionadas, independentes, lineares, distribuídas de forma não-gaussiana ou propagadas instantaneamente e etc [101]. Quanto mais as hipóteses levantadas por um determinado algoritmo são satisfeitas, mais eficiente a separação dos componentes. Portanto, os algoritmos BSS vão se diferenciar em algumas dessas suposições particulares sobre os sinais, resulta em diversas estratégias diferentes disponíveis para executar a separação das fontes. Estas incluem análise de

componentes principais (PCA), análise de componentes independentes (ICA), análise de correlação canônica (CCA) descritas a seguir:

### 3.1.4.1 Análise de Componentes Principais (PCA)

Análise de componentes principais usa uma transformação ortogonal para converter um conjunto de observações de variáveis possivelmente correlacionadas em variáveis lineares descorrelacionadas, chamadas componentes principais. Estas existirão em menor ou igual número em relação às variáveis originais. Uma forma de exemplificar é que esse tipo de transformação irá resultar em um novo sistema de coordenadas em que os eixos desse sistema correspondem as componentes principais. As restrições impostas nessa técnica é a de que as componentes principais, possuam seus eixos na direção de maior variância dos dados possível e que sejam ortogonais entre si. No contexto da separação de fontes, esta técnica é baseada na suposição de que o conjunto de dados é normalmente distribuído e que as fontes são não-correlacionadas [102].

A PCA foi introduzida na análise de EEG por Berg em 1991 [103] que utilizou para determinar a distribuição da atividade ocular no EEG e então foi usada também na remoção de artefatos de EOG [104]. Entretanto, pode ser argumentado que a PCA não seja um algoritmo BSS válido, uma vez que a restrição de ortogonalidade das fontes é irreal [105]. De fato, também foi demonstrado que a PCA é incapaz de separar alguns componentes ruidosos dos sinais cerebrais, especialmente se tiverem amplitudes similares [104].

Apesar disso, a recuperação cega via estatística de segunda ordem, mesmo que gere sinais não-análogos às fontes verdadeiras provou ser útil em alguns domínios para a separação de sinais [105]. Especialmente na construção de filtros espaciais para separação de artefatos de sinais cerebrais [106]. Em conjunto disso, algumas extensões para este método foram propostas com o objetivo de tornar a PCA mais efetiva contra certos tipos de ruído. Alguns desses algoritmos incluem PCA robusta [107], bem como o Kernel PCA (KPCA) que é uma versão não-linear da PCA [108].

Portanto, mesmo a PCA sendo útil na remoção de certos tipos de artefatos em alguns cenários de contaminação de EEG [109], a maioria dos estudos atuais na literatura emprega outros métodos na remoção de artefato do EEG. Fato é de que a PCA é frequentemente usada apenas como uma primeira descorrelação ou na etapa de branqueamento de um algoritmo ICA. A literatura aponta que a suposição de independência entre artefatos e sinais cerebrais é mais razoável que a suposição de ortogonalidade [74,101,110].

### 3.1.4.2 Análise de Componentes Independentes (ICA)

A Análise de Componentes Independentes é uma técnica de BSS na qual sinais multicanais são separados em fontes ou componentes independentes (ICs), por meio da geração de uma estimativa  $\hat{s}$  das fontes  $s$  [111]. O conceito de independência pode ser explicado do seguinte modo: dado duas variáveis aleatórias  $x$  e  $y$ , estas serão independentes se a função densidade de probabilidade conjunta,  $p(x, y)$  for igual as probabilidades marginais de  $x$  e  $y$ ,  $p(x)$  e  $p(y)$  respectivamente [99]. A Equação 11 mostra essa condição.

$$p(x, y) = p(x)p(y) \quad (11)$$

Essa condição de independência advém da descorrelação não-linear, que é a condição da ICA, e que a separa da PCA. Isso pois, enquanto a primeira irá maximizar a independência entre as variáveis e a segunda irá maximizar a descorrelação linear (12).

$$E[XY] = E[X]E[Y] \quad (12)$$

No entanto, a descorrelação linear não implica na ocorrência de uma descorrelação não-linear (como exemplificado nas Equações 13 e 14, em que  $E$  é a esperança das variáveis).

$$E[X^3Y^4] = E[X^3]E[Y^4] \quad (13)$$

$$E[X^2\ln(Y)] = E[X^2]E[\ln(Y)] \quad (14)$$

Avançando essa ideia, a Equação 12 é adequada apenas para as variáveis aleatórias gaussianas, as quais, havendo descorrelação desse tipo, haverá também descorrelação em todos os possíveis contextos não-lineares. No entanto, isso é algo peculiar à gaussiana, que é totalmente definida por média e covariância, ou seja, pode ser perfeitamente descrita com estatísticas que não excedem a ordem da correlação linear. Por esse motivo, da garantia da plena descorrelação não-linear, que é garantida pelo conceito de independência, definido pela Equação 11, implica que:

$$\begin{aligned} E[f(X)g(Y)] &= \iint_{-\infty}^{\infty} f(x)g(y)p(x,y)dxdy \\ &= \iint_{-\infty}^{\infty} f(x)g(y)p(x)p(y)dxdy \end{aligned} \tag{15}$$

$$E[f(X)g(Y)] = \int_{-\infty}^{\infty} f(x)p(x)dx \cdot \int_{-\infty}^{\infty} g(y)p(y)dy \tag{16}$$

$$E[f(X)g(Y)] = E[f(X)]E[g(Y)] \tag{17}$$

Portanto, independência estatística (Equação 11) resulta em descorrelação não-linear em qualquer situação, como mostrado na Equação 17 o que mostra a superioridade estatística dessa medida em relação a descorrelação para a recuperação cega das fontes [99]. A contrapartida da quantificação de independência é que conforme mencionado deve-se trabalhar diretamente com as funções densidades de probabilidade envolvidas, e não apenas com as estatísticas de primeira e segunda ordem.

Posto a principal restrição do método ICA, que é a independência estatística, existem diversos caminhos matemáticos para a construção desse critério, sendo os dois principais: (i) Informação mútua e (ii) Não-gaussianidade [112,113].

- (i) A informação mútua é uma grandeza que quantifica o grau de dependência estatística entre variáveis aleatórias. Essa grandeza é sempre não-negativa e vale zero em alguma condição de independência, indicando de modo direto que a informação mútua pode fazer o papel de função custo para ajuste da matriz  $\mathbf{W}$  na Equação 10. Nesse sentido, a ideia é encontrar uma matriz que produz a menor informação mútua possível entre as projeções. Caso seja possível atingir uma situação em que os componentes gerados sejam estritamente independentes, tem-se  $I(\mathbf{x}) = 0$  ( $I$  é informação mútua). Caso essa situação não seja atingível, tem-se, ao menos, uma situação tão próxima do ideal quanto possível. Portanto, minimizar a informação mútua equivale a minimizar a seguinte função custo, das  $i$ -ésimas componentes independentes. [114,115].
- (ii) Embora a informação mútua seja uma forma sólida ne construção de um critério para ICA, existem outras alternativas como a maximização da não-gaussianidade para a geração das componentes independentes  $s$ . Esse critério tem como exigência, além da independência estatística, a restrição à que no máximo 1 sinal da fonte  $\mathbf{s}$ , seja gaussiano. Assim, base da não-gaussianidade é o *teorema central do limite*. Fundamentalmente, esse teorema diz que, sob certas condições, a soma de variáveis aleatórias independentes e identicamente distribuídas tendem a possuir uma densidade de probabilidade gaussiana. Assim, as misturas ponderadas de componentes independentes  $\mathbf{X}$ , da Equação 9, tendem a ser mais gaussianas que os

elementos de  $\mathbf{S}$ . Essa consequência permite a construção de matrizes buscando projeções de máxima não-gaussianidade, tem em mãos os valores medidos  $\mathbf{X}$ . Dentre inúmeras maneiras de medida da não-gaussianidade, tem-se minimização da função custo de negentropia e a utilização da curtose [101,114–116].

Existem diversos algoritmos diferentes propostos para determinar a matriz de separação  $\mathbf{W}$ . Dos mais comumente empregados incluem fastICA [117], o algoritmo de Bell-Sejnowski [118], ICA estendido [119] e JADE [120,121]. O fastICA separa as fontes maximizando a magnitude da curtose ou maximizando a negentropia. O algoritmo de Bell-Sejnowski usa negentropia. O algoritmo ICA estendido é semelhante ao proposto por Bell e Sejnowski, aceitando fontes que têm uma curtose negativa. Finalmente, o JADE algoritmo maximiza a curtose da função densidade de probabilidade.

### 3.1.4.3 Análise de Correlação Canônica (CCA)

A Análise de Correlação Canônica (CCA) é outro método BSS para separação de sinais medidos de uma mistura de fontes. O método multivariado usa estatísticas de segunda ordem impondo a restrição das fontes serem maximamente autocorrelacionadas e mutuamente não-correlacionadas [122]. Para exemplificar será tomado a variável medida  $\mathbf{x}$  da Equação 18 como bidimensional.

$$\mathbf{X} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad (18)$$

A qual define as esperanças:

$$E[x_1] = \mu_1 ; E[x_2] = \mu_2 \quad (19)$$

E definindo também as covariâncias:

$$Cov[x_1] = \sum_1 ; Cov[x_2] = \sum_2 \text{ e } Cov[x_1, x_1] = \sum_{12} = \sum'_{21} \quad (20)$$

E a matriz de covariâncias:

$$\Sigma = \begin{bmatrix} \sum_{11} & \sum_{12} \\ \sum_{21} & \sum_{22} \end{bmatrix} \quad (21)$$

Em que  $\Sigma$  representa a matriz de covariâncias de  $X$ .

A partir dessas definições toma-se combinações lineares de  $X$  como mostradas em (30).

$$\begin{cases} U = a^1 x_1 \\ V = a^2 x_2 \end{cases} \quad (22)$$

Em que  $U$  e  $V$  são variáveis canônicas, que representam combinações lineares das variáveis  $x_1$  e  $x_2$ , e  $a^1$  e  $a^2$  são vetores não nulos dos coeficientes dessas combinações lineares.

O objetivo da CCA é encontrar coeficientes  $a^1$  e  $a^2$ , com variâncias unitárias e que maximize a equação 23.

$$Corr(U, V) = \frac{a' \Sigma_{12} b}{\sqrt{a' \Sigma_{11} a} \sqrt{b' \Sigma_{22} b}} \quad (23)$$

Assim, por meio de autovetores e autovalores, pode se encontrar o primeiro par  $U$  e  $V$  de variáveis canônicas, ou primeiro par de combinações lineares que satisfazem as duas restrições. O segundo par de variável canônica, terá as mesmas restrições do primeiro par combinada com a restrição de ser descorrelacionado com o primeiro par de combinações lineares. Para  $k$  combinações, devem ser estabelecidas as restrições: (i) variância unitária, (ii) maximização da Equação 23 e (iii) que sejam descorrelacionados das  $k-1$  variáveis canônicas anteriores [123].

Nessa procura de componentes não correlacionados, a abordagem se vale de uma condição mais fraca do que a independência estatística do algoritmo ICA, uma vez que esse não leva em conta correlações temporais; as amostras podem ser arranjadas arbitrariamente no tempo e o método ICA retornará o mesmo resultado de separação. Portanto, a CCA explora exatamente esse ponto, sendo capaz de encontrar componentes não-correlacionados, mas que possuem ou correlação temporal dentro de cada componente [124]. A remoção de artefatos pode ser realizada levando as colunas da matriz de separação que representam os artefatos para zero quando executar a reconstrução. Também se nota que o método CCA sempre retorna o mesmo resultado quando aplicado nos mesmos dados, isso, no entanto, não é verdadeiro ao usar o algoritmo ICA.

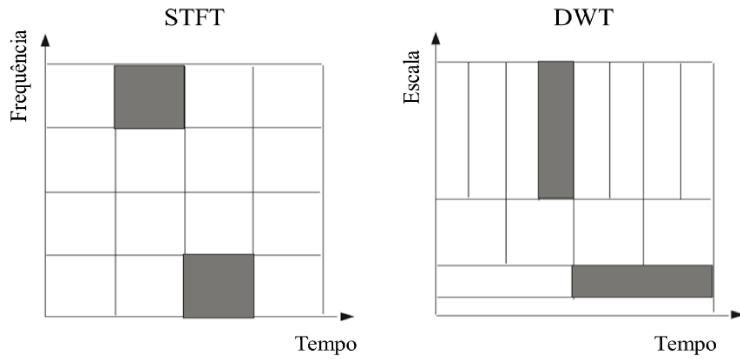
Borga e Knutsson em 2001 [123] compararam tanto CCA quanto o FastICA para o problema de separar cinco canais EEG diferentes. Ambos os métodos tiveram qualitativamente os mesmos resultados, mas como o CCA emprega estatística de segunda ordem, enquanto ICA emprega estatísticas de alta ordem (como a curtose), o método CCA é mais eficiente computacionalmente.

Em 2006, Clercq e colaboradores [125] usaram CCA para remover artefatos musculares do EEG. Neste estudo o método foi testado em dados sintéticos, o qual filtrou melhor que um filtro passa-baixa com diferentes frequências de corte e que técnica ICA-JADE na remoção de artefatos musculares. Em comparação com este último, o erro médio quadrático (MSE) foi 2,48 vezes menor para a CCA do que com ICA. Tal desempenho foi também comprovado por Gao e colaboradores em 2010 [126]. Um possível motivo para o melhor desempenho do CCA em relação ao ICA deve-se ao fato desse último empregar a restrição de independência estatística para separar as fontes, isso isolaria os artefatos com topografias bem definidas no couro cabeludo em um único componente independente. No entanto, os artefatos musculares, não tem uma topografia estereotipada e, portanto, justifique a deficiência plena na filtragem via ICA.

### 3.1.5 Transformada Wavelet

Uma maneira para introdução do conceito de Transformada Wavelet (WT) é traçando um paralelo com a Transformada de Fourier. Ambas as transformações, representam um dado sinal temporal por meio da combinação linear de funções de base, o que as diferencia são justamente essas funções de base [127]. A transformação de Fourier utiliza escalonamentos de funções de cosseno e de seno (cada um abrangendo todo o intervalo de tempo) [128]. Já a transformada wavelet utiliza translações e escalonamentos de uma função escala, com propriedades particulares que as tornam adequadas para servirem de base para a decomposição de outras funções [129].

Esses escalonamentos das funções de base de ambas as transformadas possibilitam a obtenção de informações sobre frequência do sinal sendo analisado, o que as tornaram ferramentas clássicas na análise de sinais no domínio da frequência. Ao mesmo tempo, as características temporais das funções de base podem prover recursos adicionais à ferramenta, como por exemplo a localização temporal. Essa localização é um recurso que pode ser bem explorado com as funções base da wavelet pois as mesmas são compactas ou finitas no tempo, enquanto os Fourier não são [127,129]. Embora a Transformada de Fourier de Curto-Prazo (STFT) seja semelhante à transformada wavelet, como mostra a representação tempo-frequência da Figura 9, a wavelet fornece uma melhor representação do sinal usando análise multi-resolução de tempo e de frequência.



**Figura 9: Escalas Tempo-Frequência da STFT e DWT.**

Para a definição matemática, sejam  $a$  e  $b$  dois parâmetros contínuos em todo domínio  $\mathbb{R}$  que correspondam a características de deslocamento no tempo e escalonamento no tempo da função base  $\Psi_{a,b}$ , denominadas *wavelets*.

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (24)$$

E transformada wavelet para sinais contínuos é dada por:

$$F(a, b) = \int f(t) \Psi_{a,b}(t) dt \quad (25)$$

Em que  $f(t)$  é função que se deseja transformar e  $\Psi_{a,b}(t)$  a função base com deslocamento no tempo  $b$  e escalonamento no tempo  $a$ .

A WT contínua depara-se com redundâncias, pois os parâmetros  $a$  e  $b$  variam continuamente. Esse problema é contornado por meio da discretização de  $a$  e  $b$ , processo esse que origina a transformada wavelet discreta (DWT). A DWT é a técnica mais comumente usada baseada na teoria de wavelets. Dentre as diversas aplicações, a DWT pode ser utilizada na filtragem de sinais digitais. Diferentemente do grupo de estratégias de remoção de artefato de EEG citadas até aqui, as quais baseiam em métodos que se agrupam em projetos determinísticos, adaptativos ou separadores de fontes cegas, a filtragem DWT aborda de uma maneira diferente, que consiste na decomposição de cada canal individualmente em formas de ondas básicas que representam tanto o sinal de interesse, como o artefato, permitindo então a remoção das componentes deste último [130]. Dentre os algoritmos desenvolvidos a luz dessa ideia de decomposição de um único canal da fonte (sinal e/ou artefato), estão as funções de modo intrínseco (IMF) para a decomposição em modos empíricos (EMD) e algumas funções bases wavelet para DWT [9].

Seguindo essa estratégia, a filtragem é feita seguindo 3 etapas: decomposição, limiarização e seleção por características de interesse, reconstrução do sinal filtrado. A remoção

de artefatos baseada nessa estratégia depende se fontes de interesse são decomponíveis por uma wavelet, ao passo que as formas de onda dos artefatos não. Assim, uma boa separação do sinal e ruído depende da wavelet mãe e sua semelhança com os sinais de origem a serem preservados, de modo que os pontos cruciais no projeto de remoção de artefato via DWT envolvem a escolha da wavelet mãe, a regra de escalonamento e o nível de ruído [131].

No processamento de EEG a DWT foi usada por Gao em 2009 [132] para testar um algoritmo adaptativo na redução do ECG durante registros de apneia do sono; por Iyer em 2007 [133] que comparou com um filtro ICA interativo para posterior detecção de potencial evocado de única tentativa (*single-trial*) e também por Krishnaveni em 2006 [130] na remoção de artefatos oculares em comparação com o algoritmo JADE. Nesses três estudos apenas o último houve uma melhor filtragem quando utilizado a DWT.

Também é considerado que a DWT como técnica isolada para remoção completa de artefatos do EEG é incapaz caso esses artefatos sobreponham o domínio espectral, como é o caso do ECG e o EMG [8]. Assim, ela é mais comumente encontrada aplicada em conjunto de outras técnicas de filtragem como o ICA. Akhtar em 2012 [134], combinou essas técnicas para gerar componentes independentes e aplicar a decomposição pela transformada de wavelet para remover artefatos de EOG. A principal vantagem foi a redução do tempo computacional em comparação com as abordagens existentes.

### 3.1.6 Decomposição em Modos Empíricos (EMD)

A Decomposição em Modos Empíricos (EMD) é um método empírico aplicado em processos estocásticos, não-estacionários, não-lineares [79]. Estas características um tornam um método adequado para análise e processamento de sinal EEG. No entanto, a técnica apresenta uma complexidade computacional que pode limitar as aplicações [13].

A técnica decompõe o sinal em funções base, denominadas funções de modos intrínsecos (IMFs), as quais são componentes moduladas em frequência e em amplitude. Essas funções, por terem uma frequência instantânea bem definida, são calculadas utilizando a transformada de Hilbert [135].

O algoritmo EMD decompõe um sinal,  $s(n)$  em uma soma de  $M$  componentes de banda limitada  $d_m(n)$  chamadas funções do modo intrínseco (IMF) com frequências instantâneas bem definidas [136,137]. Existem duas condições básicas condições para ser um IMF:

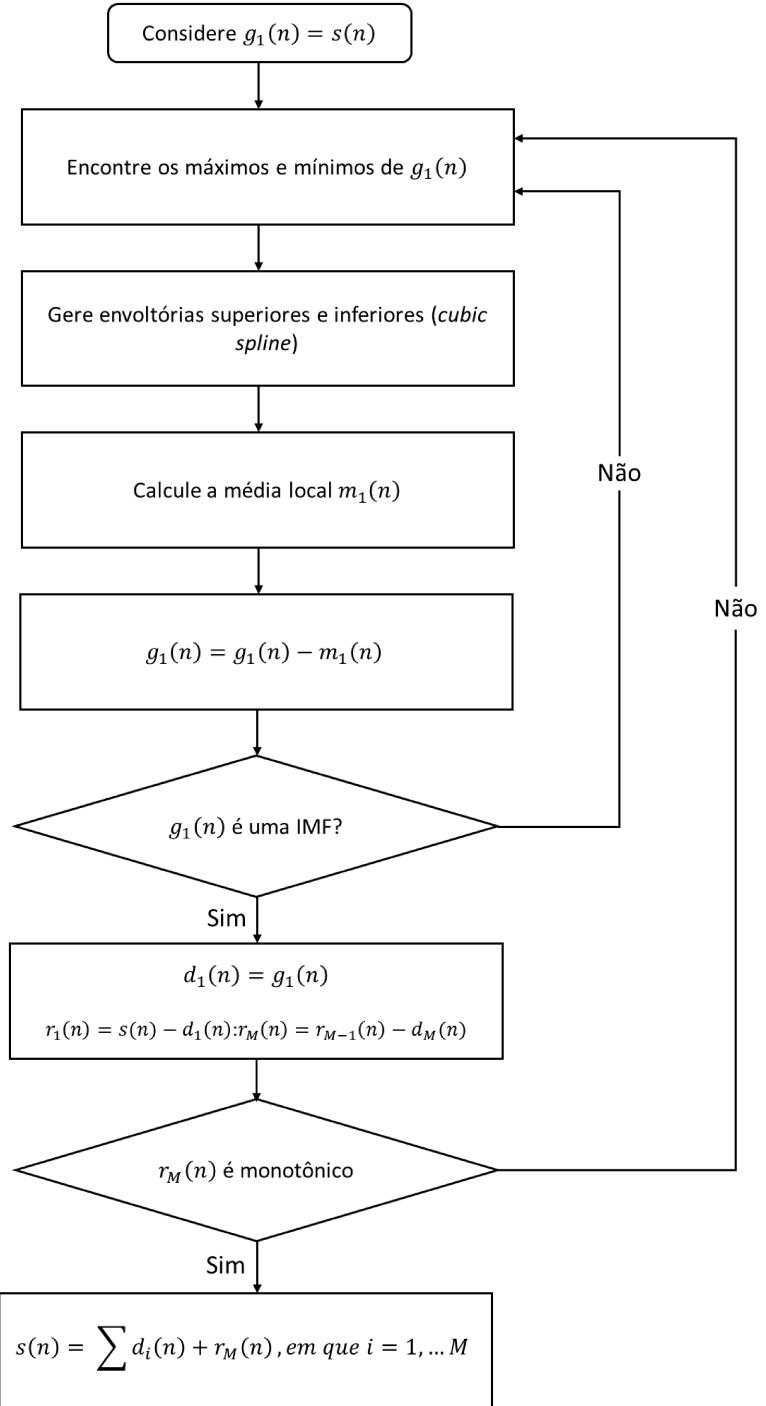
- (i) Em todo o conjunto de dados, o número de extremos (máximos e mínimos) deve ser igual ao número de cruzamentos de zero (*zero-crossings*) ou diferir em no máximo um;
- (ii) Em qualquer, o valor médio dos envelopes definidos pelos máximos locais e os mínimos locais deve ser zero.

Ao final da decomposição, o sinal  $s(n)$  pode ser representado por:

$$s(n) = \sum_{m=1}^M d_m(n) + r_M(n) \quad (26)$$

Em que  $r_M(n)$  é o resíduo final o qual pode ser uma constante ou uma tendência média. A Figura 10 ilustra o processo geral de um algoritmo EMD.

Apesar de adequada aos sinais EEG, um sinal não linear e não estacionário, a técnica EMD é criticada por sua baixa robustez contra ruídos em geral, tendo seu desempenho bem prejudicado pelo ruído branco por exemplo [138]. Na contramão dessa limitação, o algoritmo original tem sido melhorado com o Ensemble-Empirical Mode decomposition (EEMD) [139].



**Figura 10: Processo do algoritmo EMD na geração das IMFs.**

Proposto por Wu e Huang, o algoritmo EMD assistido por ruído, denominado EEMD, permite uma melhoria na escala de separação do que o método EMD padrão. O EEMD consiste em adicionar diferentes séries de ruído branco ao sinal em várias tentativas. Como o ruído adicional é diferente para cada teste, as IMFs resultantes não exibem qualquer correlação com as IMFs correspondentes de um teste para outro. Se o número de tentativas for adequado, o ruído

adicionado pode ser eliminado pela média dos conjuntos das IMFs obtidas dos diferentes ensaios [139].

O EMD foi usado com sucesso para a remoção de artefatos de EEG por [13,140] e também em conjunto com métodos BSS [137,141]. E a principal limitação apontada nesses métodos são muitas vezes a complexidade computacional, inviabilizando a utilização no sinal EEG.

### 3.1.7 Métodos Híbridos

Uma abordagem na qual são direcionados os recentes esforços, é a combinação desses algoritmos descritos para a remoção de artefatos do EEG. Os métodos híbridos são, portanto, considerados o estado da arte na filtragem de EEG pois utilizam as vantagens dos diferentes métodos em dois mais estágios e tem apresentados os melhores resultados nas suas aplicações [8,9,14,67,80,131,142].

As principais combinações podem formar os pares a seguir:

- Filtragem adaptativa com BSS-ICA
- EMD com BSS
- Wavelet com BSS
- Filtragem Adaptativa com EMD

#### 3.1.7.1 Filtragem Adaptativa e ICA

Nessa mistura, a ICA decompõe o EEG em ICs, as quais ainda contêm sinais neuronais fracos, logo se essas componentes forem removidas, como prevê a filtragem BSS, pode ocasionar em distorção no sinal de EEG após a reconstrução [131]. Isso requer uma estratégia de filtragem que retenha essa informação neuronal presente das ICs com artefatos. Assim, Klados em 2011 [143] propôs um método híbrido que combina Filtragem Adaptativa e ICA para remoção eficiente dos artefatos de dados EEG. Um método similar foi desenvolvido por Guerrero-Mosquera em 2012 [144], que combinou filtro adaptativo e BSS para remoção de artefatos oculares.

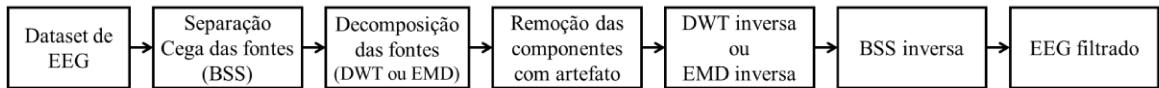
O problema desses métodos é que por não selecionarem automaticamente as componentes ruidosas, o filtro adaptativo acaba sendo aplicado em todas as ICs podendo resultar em perda de informações neuronais importantes, além do custo computacional. Na direção da solução dessa limitação, Mannan em 2016 [142] propôs um método híbrido de Filtragem Adaptativa com BSS que identifica automaticamente os artefatos oculares nas ICs para a posterior filtragem e remoção das componentes independentes. O autor comparou esta estratégia, nomeada regressão-ICA (REGICA) com mais outros três métodos da literatura: ICA; análise de regressão e o híbrido wavelet-ICA (wICA). Nessa comparação, os resultados mostraram que o REGICA apresentou um menor erro quadrático médio e absoluto e uma maior informação mútua entre EEG reconstruído e original.

### 3.1.7.2 EMD e BSS

O EMD e BSS ao serem combinados para remover artefatos do EEG empregam a seguinte estratégia: Geração das IMFs de cada canal seguida da separação cega provida pelo BSS. Linsden em 2010 [145] aplicou ICA seguido de EMD para correção de artefatos de EOG automaticamente em dados simulados e reais. O método removeu os artefatos de EEG, contudo os autores relatam que o método combinado também pode eliminar a atividade do EEG de baixas frequências, como a banda delta. Já Chen em 2014 [81], utilizou CCA como técnica do BSS em conjunto com EEMD. Neste trabalho, o foco foi a remoção de artefatos musculares do EEG usando dados sintéticos e reais, os quais apresentaram a melhor relação sinal-ruído em todos os cenários de contaminação quando comparados com uma filtragem passa-baixa com cortes de 10 Hz, 20 Hz e 50 Hz. É importante ressaltar que o método híbrido EEMD-MCCA apresentou melhor desempenho em um conjunto de dados com menos canais.

### 3.1.7.3 Wavelet e BSS

Por se tratar de uma técnica multicanal seguida de uma técnica de canal único, a aplicação dessa estratégia, será semelhante com a abordagem híbrida EMD-BSS. A Figura 11 ilustra como essas combinações são aplicadas na remoção dos artefatos do EEG.



**Figura 11: Esquema geral de filtragem com métodos híbridos de BSS-EMD ou BSS-WT.**

Raghavendra em 2011 [146] relatou a aplicação do CCA para decomposição de EEG multicanal em componentes, os componentes identificados com artefato muscular foram descartados, e os componentes com artefato ocular foram submetidos à filtragem de wavelet. Os autores relataram que o método foi avaliado com registros reais de EEG por meio do espectro de energia como uma medida quantitativa o qual obteve um bom desempenho na retificação de artefatos oculares e musculares, afetando minimamente a atividade cerebral no EEG.

Em um relato mais recente, Mahajan em 2015 [147] apresentou um algoritmo, baseado em ICA e EMD, não supervisionado, para a identificação e atenuação automáticas das ICs contaminadas com piscadas. O método apresentou sensibilidade de 90%, e demonstrou que o método oferece a vantagem de não exigir intervenção manual para identificação de uma IC nem necessita de canais de EOG adicionais como referência.

### 3.1.7.4 Filtragem Adaptativa e EMD

Este método híbrido baseia-se na combinação da Filtragem Adaptativa e EMD. Para essa estratégia Navarro em 2015 [148] propõe essa combinação para remoção do ruído cardíaco (ECG) no eletroencefalograma de bebês prematuros. Os autores sugerem os parâmetros que levam aos melhores desempenhos e como estes são afetados pela corrupção das funções intrínsecas IMFs, uma limitação bem conhecida do EMD. Além disso, essa técnica foi comparada com o método híbrido composto por filtragem adaptativa e wavelet, no qual também foi apontado como uma possibilidade de remoção de artefato alternativa, porém com uma dificuldade aumentada no ajuste dos parâmetros.

## 3.2 COMPARAÇÃO ENTRE OS MÉTODOS

Essa seção discute os algoritmos apresentados na seção anterior anteriormente os quais são os mais comumente empregados em processamento de sinais biomédicos. A escolha do algoritmo depende de diferentes fatores, como a remoção automática ou a disponibilidade e necessidade de sinais de referência. Se disponíveis, estes podem ser usados em filtros adaptativos, em técnicas BSS, como o ICA para melhorar a precisão e robustez e para determinação as épocas de dados, intervalos onde as técnicas de remoção de artefatos deverão ser aplicadas [74].

O número e a qualidade dos sensores de também têm impacto na escolha da técnica de remoção de artefatos. Um exemplo pode ser levantado traçando um paralelo entre gravações de EEG em ambientes de pesquisa em comparação com ambientes clínicos-hospitalares, nos quais estes últimos, devido a limitações do tempo de configuração utilizarão um número reduzido de eletrodos, ao passo que em um ambiente de pesquisa a quantidade de eletrodos normalmente não é um fator limitante [149]. Portanto, os algoritmos devem ser capazes de separar fontes sem sensores redundantes, podendo exigir técnicas de remoção de artefatos mais complexas computacionalmente, como por exemplo o filtro de Kalman. Contudo, essas técnicas, exigem ao menos os modelos dos sinais, os quais nem sempre estão disponíveis [8].

Embora uma variedade de algoritmos tenha sido desenvolvida para a remoção de artefatos do EEG, a remoção de artefatos continua a ser um problema de pesquisa aberta. A Tabela 4, ilustra que atualmente não existe nenhum método de ponta que seja eficiente e robusto uma ampla gama de condições. Portanto, sugere a tendência de que sejam desenvolvidos algoritmos personalizados que atendam determinadas circunstâncias. De fato, muito dos algoritmos atuais, como o EEMD-ICA, EEMD-CCA e DWT-BSS, incorporam atributos desejados, mas não conseguem satisfazê-los completamente [150].

**Tabela 4: Comparação entre as principais técnicas de remoção de artefato do EEG.**

	Exigência de sensores adicionais	Exigência de modelos <i>a priori</i> .	Remoção automática	Pode operar em modo canal único	Pode operar em domínios não-lineares
<b>Filtro Adaptativo</b>	Sim	Sim	Sim	Sim	Sim
<b>Filtro de Wiener</b>	Não	Sim	Sim	Sim	Sim
<b>Filtro de Kalman</b>	Não	Sim	Sim	Sim	Sim
<b>ICA</b>	Não	Não	Não	Não	Sim
<b>CCA</b>	Não	Não	Não	Não	Sim
<b>DWT</b>	Não	Não	Não	Sim	Sim
<b>EMD</b>	Não	Não	Não	Sim	Sim
<b>DWT-ICA</b>	Não	Não	Não	Sim	Sim
<b>EMD-ICA</b>	Não	Não	Não	Sim	Sim

### 3.3 CENÁRIO DA APLICAÇÃO DOS PRINCIPAIS MÉTODOS PARA REMOÇÃO DOS ARTEFATOS DE EEG

Essa seção encerra o presente capítulo com uma discussão sobre o cenário na literatura desses métodos de remoção de artefatos apresentados através do estudo comparativo, apresentado na Tabela 5, a partir de 2008. As bases de buscas foram IEEE Xplore e portal de periódicos CAPES. Não foram incluídos estudos que, apesar de aplicarem alguma estratégia de remoção de artefato, não compunha o objetivo principal do trabalho.

**Tabela 5: Relação dos trabalhos focados em aplicação de técnicas de remoção de artefatos fisiológicos do EEG.**

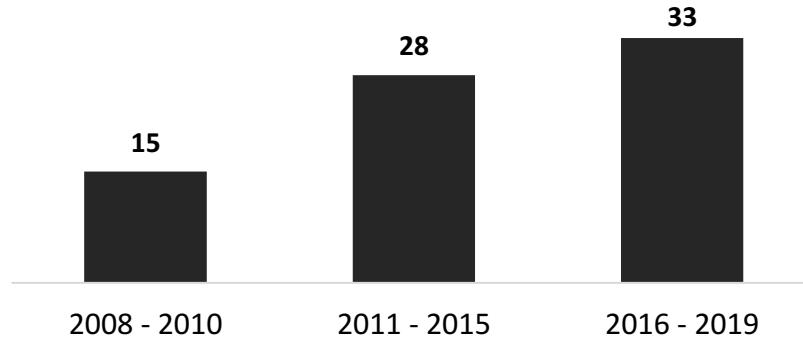
Estudo	Ano	Método	Tipo(s) de Artefato	Automático	Aplicações	Ref
Devuyst et al, [151]	2008	ICA	Cardíaco	Sim	Gerais	Não
Crespo-Garcia et al, [152]	2008	ICA	Muscular	Não	Gerais	Não
Mammone e Morabito, [153]	2008	ICA	Ocular + Muscular	Sim	Gerais	Não
Viola et al, [154]	2009	ICA	Ocular + Cardíaco	Sim	Gerais	Não
Zhou e Gotman, [155]	2009	ICA	Ocular	Sim	Gerais	Não
Gao et al, [126]	2010	CCA	Muscular	Sim	Gerais	Não
De Vos et al, [156]	2010	CCA	Muscular	Sim	Potencial Evocado	Não
Gao et al, [157]	2010	ICA	Ocular	Sim	Online	Não
Gao et al, [158]	2010	CCA + ICA	Ocular + Muscular	Sim	Online	Não
Gao et al, [159]	2010	ICA	Ocular	Sim	Online	Não
Lindsen e Bhattacharya [145]	2010	EMD + ICA	Ocular	Sim	Gerais	Não
Chan et al, [160]	2010	Filtro Adaptativo + ICA	Ocular	Sim	Gerais	Não
Mognon et al, [161]	2011	ICA	Ocular	Sim	Potencial Evocado	Não

<b>Estudo</b>	<b>Ano</b>	<b>Método</b>	<b>Tipo(s) de Artefato</b>	<b>Automático</b>	<b>Aplicações</b>	<b>Ref</b>
Winkler et al, [162]	2011	ICA	Todos	Sim	BCI	Não
Raghavendra e Dutt [146]	2011	ICA + Wavelet	Ocular + Muscular	Sim	Gerais	Não
Plöchl et al, [163]	2012	ICA	Ocular	Sim	Potencial Evocado	Não
Zhang el al, [164]	2012	CCA	Ocular	Sim	Online	Não
Yong et al, [165]	2012	Wavelet	Ocular + Muscular	Não	BCI	Não
Molla et al, [166]	2012	EMD	Ocular	Não	Gerais	Não
Vázquez et al, [167]	2012	ICA + Wavelet	Todos	Sim	Epilepsia	Não
Guerrero-Mosquera e Navia-Vázquez [144]	2012	Filtro Adaptativo + ICA	Ocular	Sim	Gerais	Não
Mammone et al, [168]	2012	ICA + Wavelet	Todos	Sim	Gerais	Não
Li et al, [169]	2012	ICA + Wavelet	Ocular	Sim	Online	Não
Kong et al, [170]	2013	ICA	Ocular	Sim	Online	Não
Peng et al, [171]	2013	Filtro Adaptativo + Wavelet	Ocular	Sim	EEG Portátil	Não
Chen et al, [172]	2013	CCA + EMD	Muscular	Sim	Gerais	Não
Winkler et al, [173]	2014	ICA	Todos	Sim	BCI	Não
Keshava e Khan [174]	2014	EMD	Ocular	Não	Gerais	Não
Wang et al, [175]	2014	Filtro Adaptativo + ICA	Ocular	Sim	Gerais	Não
Zhao at al, [176]	2014	Filtro Adaptativo + Wavelet	Ocular	Sim	EEG Portátil	Não
Hamaneh et al, [177]	2014	ICA + Wavelet	Cardíaco	Sim	Epilepsia	Não
Chen et al, [81]	2014	ICA + Wavelet	Muscular	Sim	Ambulatorial	Não
Mammone e Morabio, [178]	2014	ICA + Wavelet	Todos	Sim	Gerais	Não
Cassani et al, [179]	2014	ICA + Wavelet	Todos	Sim	Alzheimer	Não
Frölich et al, [180]	2015	ICA	Todos	Sim	Online	Não

<b>Estudo</b>	<b>Ano</b>	<b>Método</b>	<b>Tipo(s) de Artefato</b>	<b>Automático</b>	<b>Aplicações</b>	<b>Ref</b>
Chaumon et al, [181]	2015	ICA	Ocular + Muscular	Sim	Gerais	Não
Mahajan e Morshed, [147]	2015	ICA + Wavelet	Ocular	Sim	Gerais	Não
Mingai et al, [182]	2015	ICA + Wavelet	Ocular	Sim	BCI	Não
Gao et al, [183]	2015	EMD + ICA	Ocular	Sim	Potencial Evocado	Não
Yang et al, [184]	2015	EMD + ICA + Filtro Adaptativo	Ocular	Sim	BCI	Não
Mowla et al, [185]	2015	ICA + Wavelet	Ocular + Muscular	Sim	Potencial Evocado	Não
Daly et al, [83]	2015	ICA + Wavelet	Todos	Sim	BCI	Não
Labate et al, [186]	2015	ICA + Wavelet	Todos	Sim	Alzheimer	Não
Zou et al, [187]	2016	ICA	Todos	Sim	BCI	Não
Fitzgibbon et al, [188]	2016	ICA	Muscular	Sim	Ambulatorial	Não
Somers e Bertrand [189]	2016	CCA	Ocular	Sim	EEG Wirelees	Não
Hou et al,[190]	2016	ICA	Ocular	Sim	High-Density EEG	Não
Daud e Sudirman, [191]	2016	Wavelet	Ocular + Muscular	Não	Gerais	Não
Patel et al, [192]	2016	EMD	Ocular	Não	Gerais	Não
Khatun et al, [193]	2016	Wavelet	Ocular	Não	Gerais	Não
Bono et al, [14]	2016	EMD + Wavelet	Ocular + Muscular	Sim	Gerais	Não
Bono et al, [14]	2016	ICA + Wavelet	Ocular + Muscular	Sim	Gerais	Não
Chen et al, [21]	2016	CCA + EMD	Muscular	Sim	Ambulatorial	Não
Zeng et al, [80]	2016	EMD + ICA	Ocular + Muscular	Sim	Epilepsia	Não
Bai et al, [194]	2016	CCA + EMD	Ocular + Muscular	Sim	TMS-EEG	Não
Çınar et al, [195]	2017	ICA	Ocular	Sim	Potencial Evocado	Não
Drisdelle et al, [196]	2017	ICA	Ocular	Sim	Potencial Evocado	Não

<b>Estudo</b>	<b>Ano</b>	<b>Método</b>	<b>Tipo(s) de Artefato</b>	<b>Automático</b>	<b>Aplicações</b>	<b>Ref</b>
Pontifex[197] et al,	2017	ICA	Ocular	Sim	Gerais	Não
Szentkirályi et al, [198]	2017	ICA	Ocular + Muscular	Sim	Simulação de Direção	Não
Barthélemy et al, [199]	2017	ICA	Ocular	Sim	Online	Não
Guarascio e Puthusserypady, [200]	2017	EMD	Ocular	Não	Gerais	Não
Jafarifarmand et al, [201]	2017	Filtro Adaptativo + ICA	Ocular	Sim	BCI	Não
Yang et al, [202]	2017	CCA + EMD	Ocular	Sim	BCI	Não
Anastasiadou et al, [203]	2017	CCA + Wavelet	Muscular	Sim	Gerais	Não
Somers et al, [204]	2018	Filtro de Wiener	Todos	Não	Gerais	Não
Chavez et al, [205]	2018	Wavelet	Ocular + Muscular	Não	Gerais	Não
Mammone, [206]	2018	ICA + Wavelet	Todos	Sim	Alzheimer	Não
Tamburro et al, [207]	2018	ICA + SVM	Todos	Sim	Gerais	Não
Gabard-Durnam et al, [208]	2018	ICA + Wavelet	Todos	Sim	Gerais	Não
Correa et al, [209]	2019	Adaptativo	Todos	Sim	Epilepsia	Não
Val-Calvo et al, [210]	2019	ICA + Wavelet	Todos	Sim	Estimativa de emoção	Não
Kilicarslan et al, [211]	2019	Adaptativo	Movimento	Sim	Gerais	Não
Gajbhiye et al, [212]	2019	Bayesiano	Movimento	Sim	Gerais	Não
Dai et al, [213]	2019	Adaptativo	Cardíaco	Sim	Gerais	Sim
Bajaj et al, [214]	2019	Wavelet	Todos	Sim	Tarefas auditivas	Não

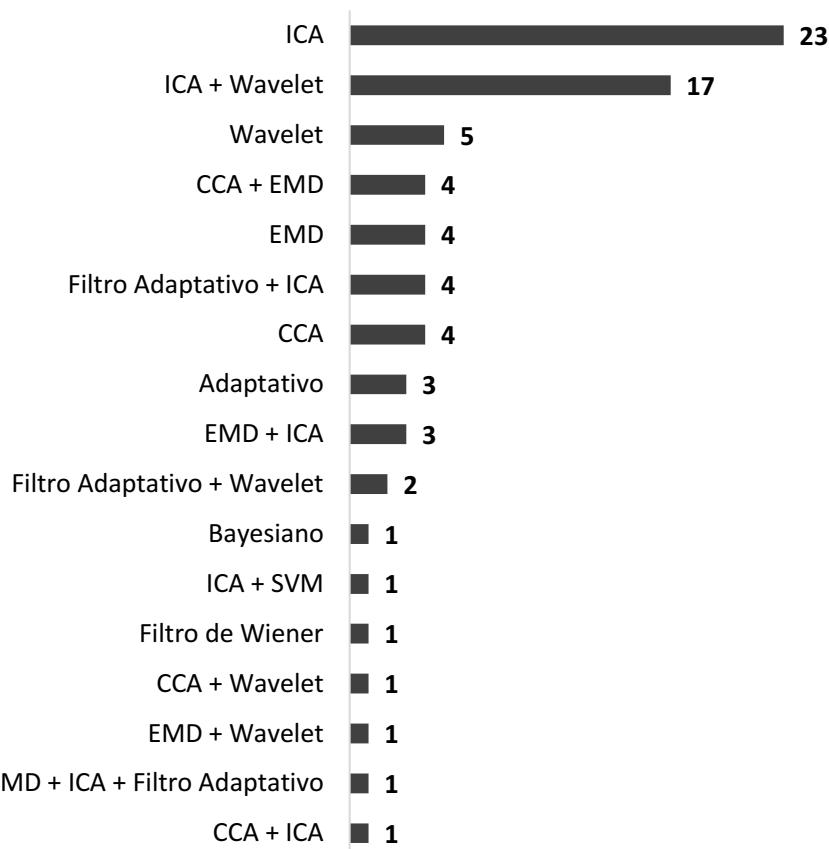
A Figura 12 apresenta uma contagem do número de artigos dos últimos 10 anos agrupados conforme suas respectivas datas de publicação em 2008-2010, 2011-2014 e 2015-2019.



**Figura 12: Quantidade de artigos publicados em remoção de artefatos de EEG (2008-2019)**

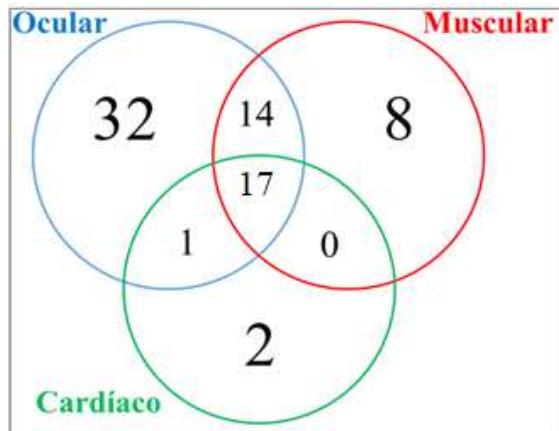
Desses trabalhos, que objetivam o estudo de técnicas de filtragem na remoção de artefatos de EEG, pode ser observado que houve um aumento na quantidade dessa categoria de trabalho nos últimos 4 anos. Isso pode indicar que a remoção de artefatos fisiológicos ainda é um importante problema científico a ser explorado. Na sequência da análise a Figura 13 separa os artigos por técnica aplicada mostrando que a ICA em um quadro geral é o método de remoção de artefatos mais utilizado, para superar uma das limitações desse algoritmo de separação cega de fontes, que é ao ser aplicado carrega também sinal de EEG nas componentes independentes classificadas por componentes ruidosas, uma solução a isso pode ser a decomposição em canal único como as oferecidas pelas técnicas EMD e decomposição wavelet das componentes independentes, refinando ainda mais filtragem da técnica ICA. Isso pode ser corroborado pelo fato da segunda principal técnica empregada pelos trabalhos recentes seja a combinação híbrida de ICA com wavelet. Além disso, o terceiro método mais utilizado foi novamente ICA híbrido com filtragens adaptativas, o que mostra a predominância de técnicas de separação cega de fontes se também for considerado a CCA.

Outra razão da predominância dos algoritmos BSS, especialmente ICA, baseia-se no fato de que são métodos aplicáveis sem a necessidade de qualquer sinal de referência, apesar da performance de remoção de artefatos de EOG ser consideravelmente melhorada com a gravação da referência do artefato [8]. Além do mais, as técnicas BSS ainda esbarram na desvantagem de não conseguirem por si só, identificar automaticamente as ICs ruidosas a serem removidas, consequentemente requer perícia visual para remoção com precisão dos artefatos [142].



**Figura 13: Quantidade trabalhos voltados para a remoção de artefatos separados por técnica aplicada.**

Partindo para uma análise dos estudos sob o ponto de vista do tipo do artefato fisiológico a Figura 14 mostra um diagrama que quantifica para qual artefatos os esforços dos trabalhos recentes foram direcionados. Os artefatos oculares, representam mais da metade dos trabalhos (53,2%) se considerados os trabalhos que focam em separar mais de um tipo de artefato e incluem os artefatos gerados pela eletro-oculografia. Das razões desse maior número, podem ser o fato da gravação de EEG exigir predominantemente parado e nessa condição o artefato de EMG não seria um problema. No entanto algumas aplicações, como a interpretação do EEG durante o uso de interfaces mioelétricas ou a monitorização em sujeitos que alguma patologia que os impede de um relaxamento muscular facial mínimo requer também trabalhos que foquem na remoção de artefatos dessa categoria.



**Figura 14:** Diagrama com a distribuição dos artefatos de origem fisiológica tipo de artefato direcionado pelos trabalhos da Tabela 5.

### 3.4 CONSIDERAÇÕES FINAIS

Este capítulo abordou o sinal EEG do ponto de vista de um sinal amostrado no tempo que possibilita aplicação de diversas estratégias de filtragem de artefatos. Deste modo, foi apresentado ao longo do capítulo uma sucessão de filtros aplicáveis para a remoção das diversas classes de artefatos do sinal EEG. Além disso, também foi descrito o estado da arte das estratégias de remoção de artefato, que apontou esta como uma área desafiadora tanto pelo crescente número de trabalhos recentes quanto pela multiplicidade de técnicas possíveis de serem combinadas, ajustadas e aplicadas para superarem limitações individuais das mesmas.

# **Capítulo 4**

## **COLETA DE DADOS E CARACTERIZAÇÃO DA CONTAMINAÇÃO DO SINAL EEG CAUSADA POR CONTRAÇÃO DE MÚSCULOS FACIAIS**

O capítulo anterior apresentou um panorama sobre remoção de artefatos em sequências amostradas e a direção dos trabalhos correlatos mais recentes nessa área. A partir disso, entende-se que os métodos para remoção de contaminação EMG exigem um bom entendimento das propriedades espetrais e topográficas dos artefatos. Portanto, além do conhecimento das técnicas de filtragem apropriadas nas mais variadas aplicações também é necessário apontar como ocorre a contaminação por eletromiografia no EEG, quais suas características, e como se dá a propagação no escalpo.

Na direção de fornecer uma análise espectral e topográfica apropriada da contaminação EMG causada pelos músculos frontais e temporais, Goncharova em 2003 [12] demonstrou que os artefatos musculares contaminam a atividade do EEG em frequências menores que 15 Hz. Além disso, também mostrou existir uma considerável variação topográfica inter-indivíduo na

contaminação do EEG, demandando um cuidado na caracterização geral da contaminação do eletroencefalograma pelo EMG. Somando a esse estudo, é importante destacar que outros esforços na caracterização medidas da contaminação do EMG utilizadas que incluíram densidade espectral de potência e a análise de coerência [18].

Este capítulo tem o objetivo contribuir para a caracterização da contaminação eletromiográfica no sinal EEG medido pela potência média do sinal. Essa caracterização foi feita a partir de uma sequência de contrações musculares destinadas no treinamento do cursor uma interface homem-computador (HCI) [19]. A caracterização de ganho de potência foi observada no próprio canal, permitindo verificar a comparação da potência média entre as épocas de relaxamento muscular fácil e as épocas de contração muscular.

Os seguintes músculos faciais foram avaliados: frontal, masseter, zígomático, orbicular do olho e orbicular da boca. Essa estratégia de caracterização, utilizando a potência média normalizada para a construção de mapas topográficos da cabeça irá também auxiliar a configurações e avaliações dos filtros.

## 4.1 CARACTERIZAÇÃO DO ESTUDO

Este estudo segue a Resolução 466/2012 do Comitê Nacional de Ética em Pesquisa e a coleta de dados foi realizada no Núcleo de Avaliação de Inovação e Tecnologia em Saúde da Universidade Federal de Uberlândia (UFU) autorizado pelo Comitê de Ética em Pesquisa em Seres Humanos (CEP -UFU), Número CAAE: 43670815.4.0000.5152.

Para caracterizar a contaminação da atividade muscular facial no sinal EEG, foram coletados conjuntos de dados de EEG durante sucessivas contrações musculares faciais com 10 indivíduos saudáveis. O protocolo consistiu em 10 sessões por voluntário, estas sessões classificadas de acordo com o tipo de contração realizada e a abertura dos olhos, a Tabela 6 apresenta informações sobre as 10 sessões de coletas de dados. Como mostra a Tabela 6, o voluntário foi orientado a realizar 15 contrações musculares com a maior intensidade que conseguisse. A duração dessas contrações tinha o objetivo de simular as contrações musculares necessárias para controle de uma IHM mioelétrica [19], assim, eram classificadas em 3 durações conforme mostra a Tabela 7. Para guiar o voluntário na duração intervalo entre as contrações, ele deveria realizar a contração muscular sempre que ouvisse um bip, e deveria manter a contração até o bip encerrar. Esses bips tinham duração de 0,5 segundos, 1 segundo ou 3 segundos, distribuídos aleatoriamente com intervalo de 2 segundos entre cada um.

**Tabela 6: Descrição das sessões de coleta de dados de EEG-EMG.**

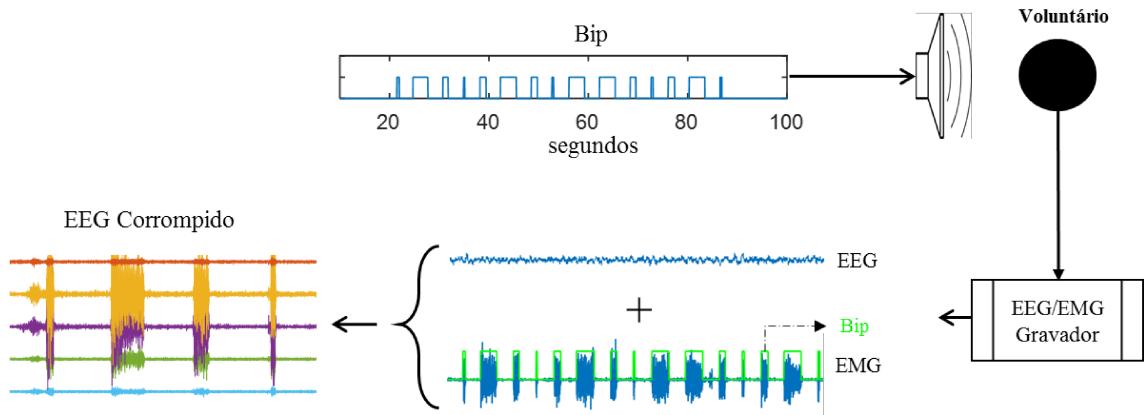
Sessão	Quantidade de Contrações	Músculo contraído	Movimento	Olhos
1	15	1 – Frontal	Levanta sobrancelhas	Abertos
2	15	2 - Masseter/Temporal	Mordida	Abertos
3	15	3 – Orbicular do olho	Serra os olhos	Abertos
4	15	4 – Zigomático	Muda ângulo da boca (sorriso)	Abertos
5	15	5 – Orbicular da boca	Enruga os lábios (beijo)	Abertos
6	15	1 – Frontal	Levanta sobrancelhas	Fechados
7	15	2 - Masseter/Temporal	Mordida	Fechados
8	15	3 – Orbicular do olho	Serra os olhos	Fechados
9	15	4 – Zigomático	Muda ângulo da boca (sorriso)	Fechados
10	15	5 - Orbicular da boca	Enruga os lábios (beijo)	Fechados

**Tabela 7: Contrações musculares baseadas na HCI.**

Contração	Quantidade	Intervalo entre contrações	Duração da Contração	Comando equivalente no cursor da HCI [20]
Curta	5 contrações	2 segundos	0,5 segundos	Gira o mouse
Média	5 contrações	2 segundos	1 segundo	Move o mouse
Longa	5 contrações	2 segundos	3 segundos	Clique

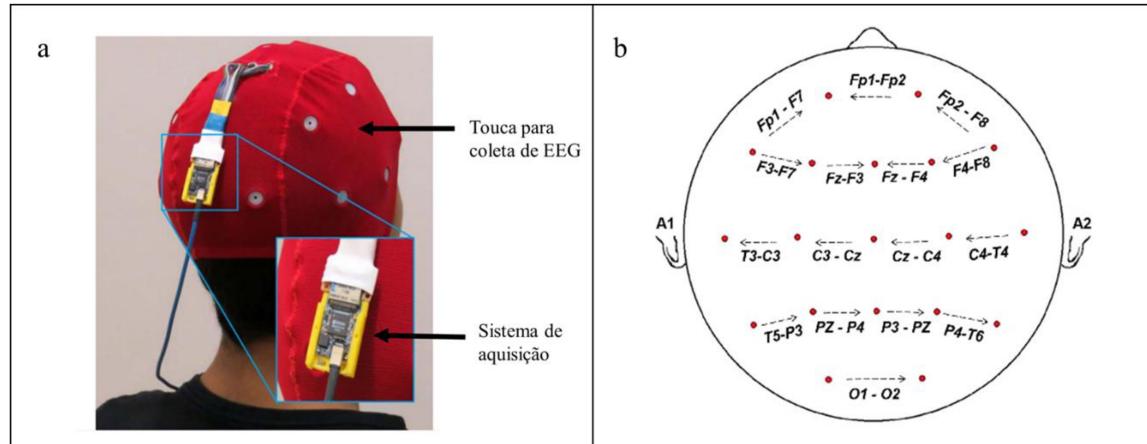
## 4.2 A METODOLOGIA DE COLETA E CARACTERIZAÇÃO DA CONTAMINAÇÃO DE EMG NO EEG

A Figura 15 ilustra o procedimento para coleta de dados por *trial*. O processo começa com um estímulo acústico. Conforme descrito na Tabela 7, os bipes têm intervalos de 2 segundos entre eles. Os sinais de EEG e EMG foram registrados simultaneamente, o objetivo dessa etapa foi corromper o EEG durante os períodos de contrações musculares, permitindo assim a caracterização dos padrões de contaminação na região cada eletrodo.



**Figura 15: Procedimento de coleta simultânea de EEG e EMG.**

A Figura 16a mostra sistema para coleta e touca para coleta de dados EEG. Os eletrodos de EEG são posicionados conforme o padrão 10-20 e conectados com referência bipolar totalizando 16 canais diferenciais como mostrado na Figura 16b. O sistema utiliza o amplificador RHD200 (Intan, US) [215], amostrado a 5 kHz e filtrado por filtro passa banda com frequências de corte de 0,1 Hz e 1 kHz.

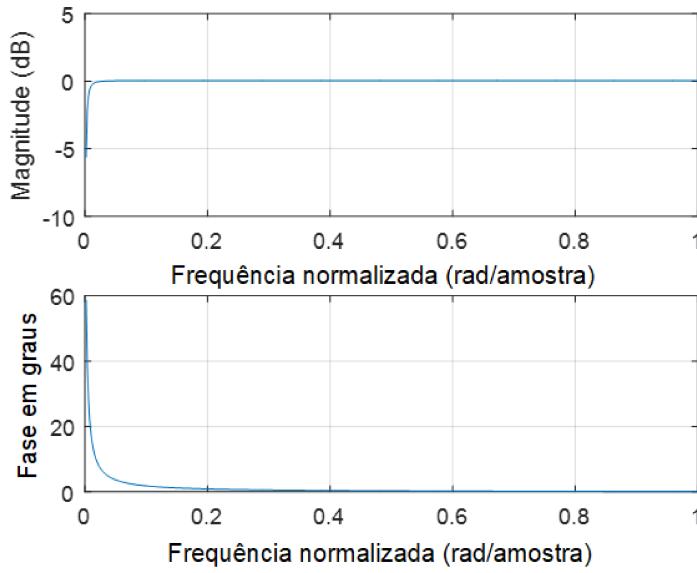


**Figura 16: a) Touca e sistema de aquisição de EEG. b) conexão elétrica dos eletrodos, referência bipolar.**

Após a coleta dos dados, o sinal foi submetido as seguintes etapas processamento:

- Pré-processamento – O offset dos sinais coletados foi removido por meio do filtro passa alta digital com função de transferência conforme a Equação 27, e a resposta em frequência do filtro como mostra a Figura 17.

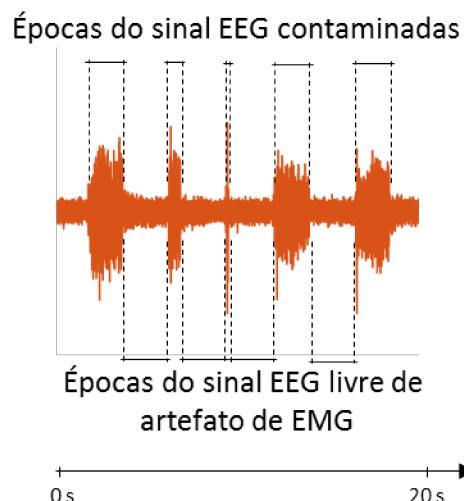
$$F(z) = \frac{z - 1}{z - 0.99} \quad (27)$$



**Figura 17: Resposta em frequência do pré-processamento**

- b) Janela de sinalização - O envelope do sinal EMG foi estimado para a detecção do início e do final da contração muscular. Esses pontos de referência foram usados para janelar as épocas de EEG em períodos livres de contaminação de EMG e períodos contaminados, como mostra a Figura 18.
- c) Estimativa da potência média do sinal dentro da janela – A Equação 28 define a potência média ( $P$ ) do sinal, em que  $V$  é a série temporal discreta de entrada e  $N$  é o número de amostras do sinal. Esta é calculada para gerar o índice de potência média da contaminação e do EEG livre de artefato para cada eletrodo.

$$P = \sum_{n=1}^N \frac{V[n]^2}{N} \quad (28)$$



**Figura 18: Trecho de um sinal de EEG (P4-P4) contaminado por contrações do músculo masseter que ilustra o janelamento em épocas contaminadas e não contaminadas por EMG.**

- d) Normalização da potência média - Para a visualização comparativa da potência do sinal em todos os períodos de contração muscular ativa e não ativa, a potência média foi normalizada pela Equação 29. A potência média estimada para cada k-ésima janela de sinal pela Equação 28 é  $P_k$ ; a potência total mínima e máxima de  $P_k$  é  $P_{min}$  e  $P_{max}$ , respectivamente.

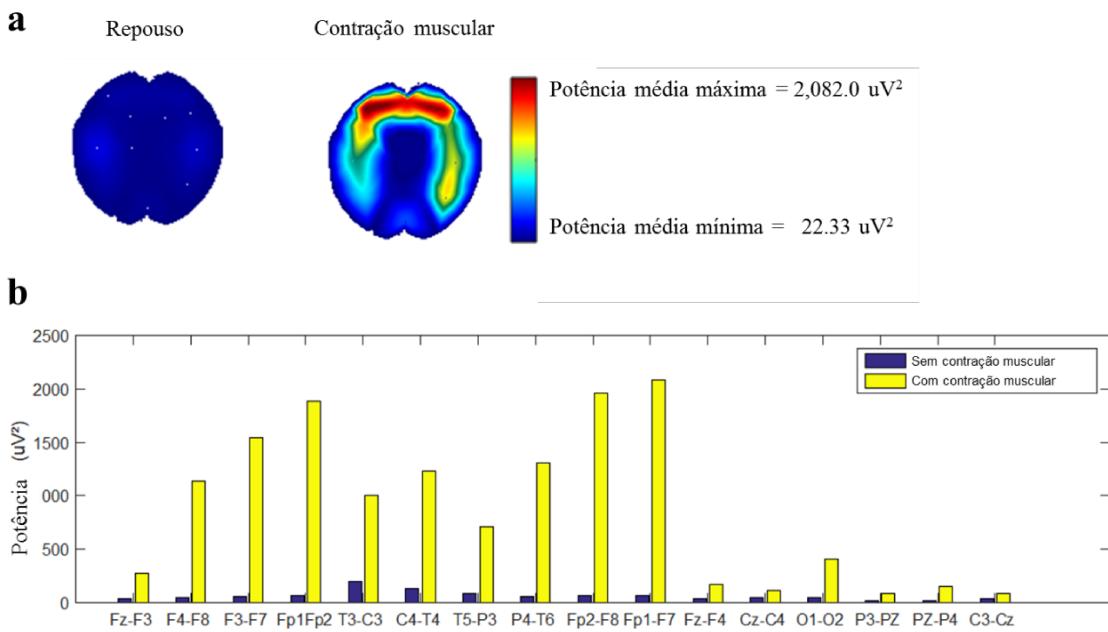
$$P_{norm} = \frac{P_k - P_{min}}{P_{max}} \quad (29)$$

- e) Geração de mapas topográficos da distribuição de energia - A distribuição global de energia considerando todos os indivíduos foi estimada para cada músculo (com e sem contração muscular).
- f) Geração de mapa topográfico correspondente ao ganho médio de potência - O ganho de potência médio das janelas de contração em relação à potência média dos períodos de não contração para todos os músculos, conforme a Equação 30.

$$P_{(dB)} = 10 * \log\left(\frac{P_{contração}}{P_{sem contração}}\right) \quad (30)$$

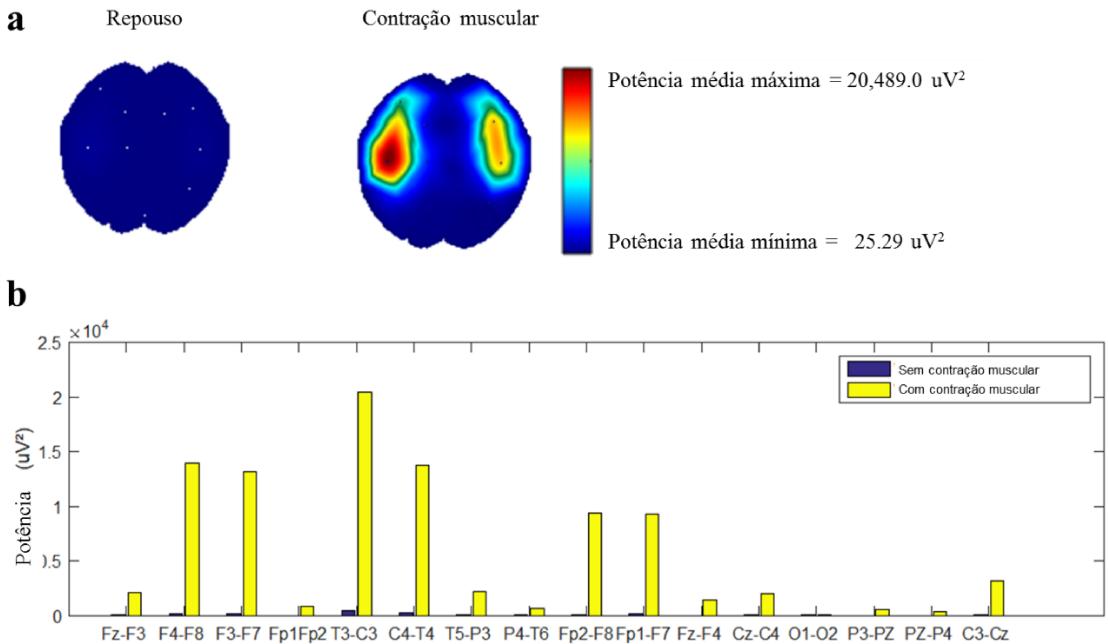
### **4.3 CARACTERIZAÇÃO DA CONTAMINAÇÃO DO EEG**

A Figura 19a mostra o mapa topográfico da potência média do sinal medido no escalpo comparando os períodos de contração muscular frontal ativa e períodos com essa musculatura relaxada. A Figura 19b apresenta a potência média de cada derivação nos períodos com e sem contração muscular.



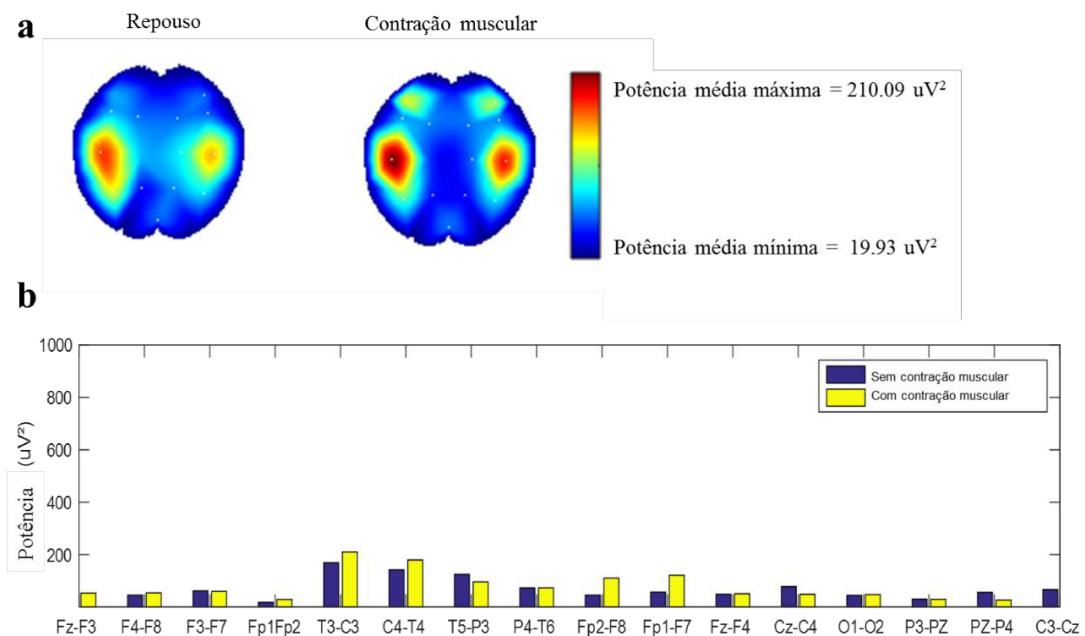
**Figura 19:** (a) Potência do EEG comparando os períodos de contração e não-contração do músculo frontal e (b) Potência dos sinais EEG para cada derivação bipolar nos períodos de contração muscular frontal.

A Figura 20a mostra o mapa topográfico da potência média comparando os períodos durante a contração do masseter com períodos em repouso dessa musculatura. A Figura 20b apresenta a potência média de cada derivação nos períodos com e sem contração muscular.



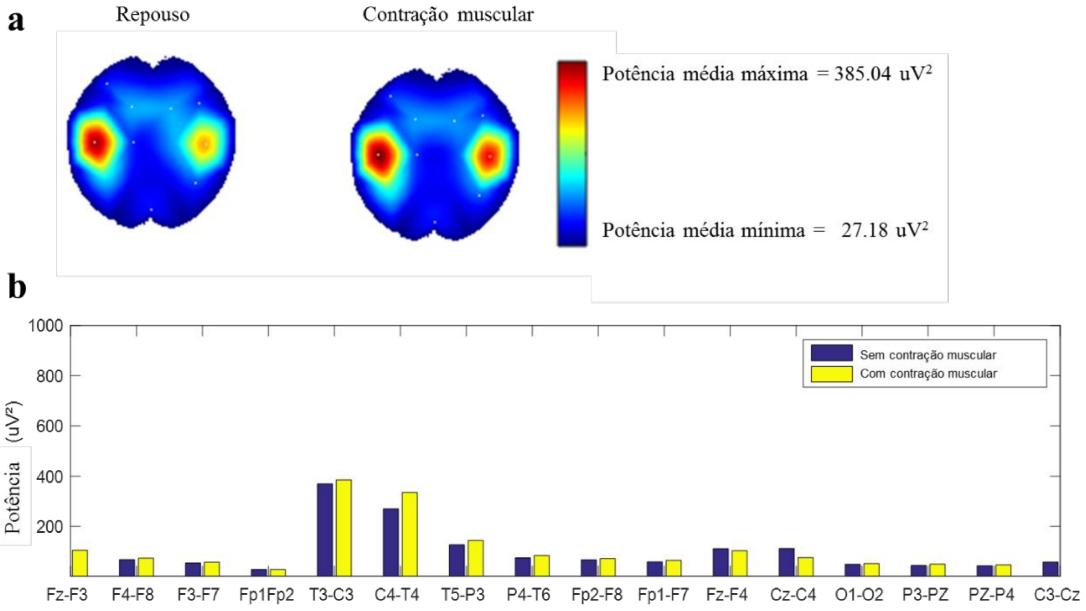
**Figura 20:** Potência do EEG comparando os períodos de contração e não-contração do masseter (b) Potência dos sinais de EEG para cada derivação bipolar nos períodos de contração masseter.

O mapa topográfico comparativo da contaminação no EEG, originado pela sequência de contrações musculares realizadas neste protocolo, geradas para o músculo frontal (Figura 19) e músculo masseter (Figura. 20), mostrou contaminação de praticamente todo o couro cabeludo. A potência média nos eletrodos variou de  $63,5 \text{ uV}^2$  para  $816 \text{ uV}^2$  no músculo frontal e de  $118,3 \text{ uV}^2$  a  $5617,9 \text{ uV}^2$  no músculo masseter. As épocas com contração dos músculos frontal e do masseter aumentaram a energia média registrada pelos eletrodos no escâlpo em 11,1 dB e 16,7 dB, respectivamente. Esse aumento na contaminação, após a normalização, resultou na impossibilidade de discriminá-la topograficamente a potência do EEG durante a condição de repouso, motivo pelo qual o mapa topográfico é todo azul. Por outro lado, a contaminação gerada pela contração muscular orbicular do olho, como mostrado na Figura 21a, é menor e, portanto, mesmo após o processo de normalização com períodos de contração, os períodos de repouso têm alguma distribuição de energia no couro cabeludo possível visualizado. A Figura 21b apresenta a potência média global de cada derivação nos períodos com e sem contração muscular.



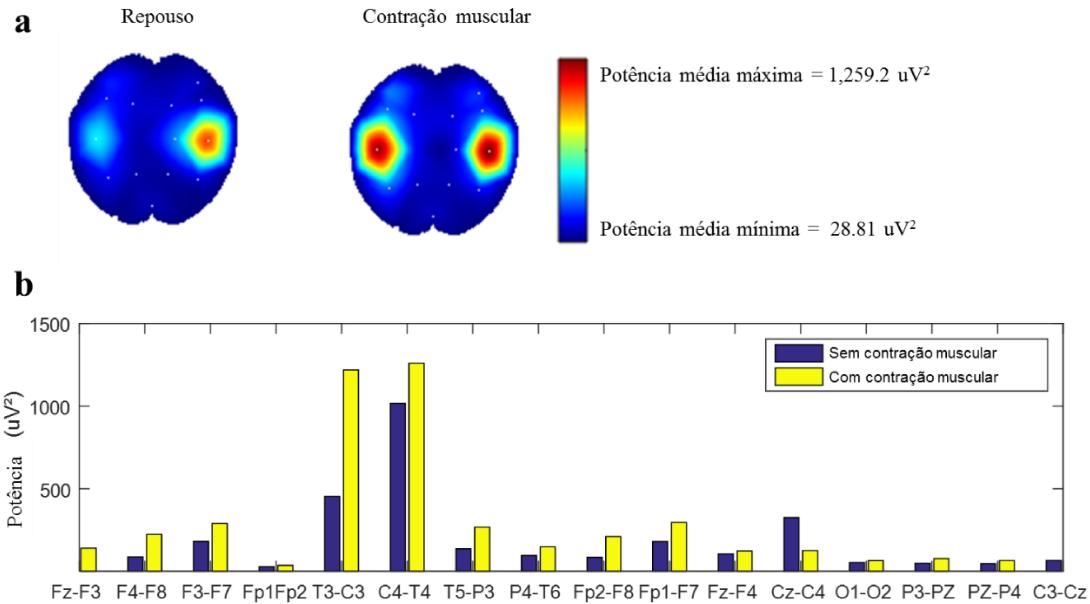
**Figura 21:** (a) Potência do EEG comparando os períodos de contração muscular orbicular do olho ativa e inativa (b) Potência dos sinais EEG para cada derivação bipolar nos períodos de contração do músculo orbicular ativo e não ativo.

A Figura 22a mostra o mapa topográfico da potência média comparando os períodos de contração muscular ativa zigomática ativa e não ativa. Na Figura, é possível visualizar uma situação semelhante àquela mostrada na figura 21a, na qual a potência dos períodos de contaminação EMG é semelhante aos períodos de não contaminação. A Figura 22b apresenta a potência média global de cada derivação nos períodos com e sem contração muscular.



**Figura 22:** (a) Potência do EEG comparando os períodos de contração muscular do zigomático (b) Potência dos sinais EEG para cada derivação bipolar nos períodos de contração muscular ativa e não ativa.

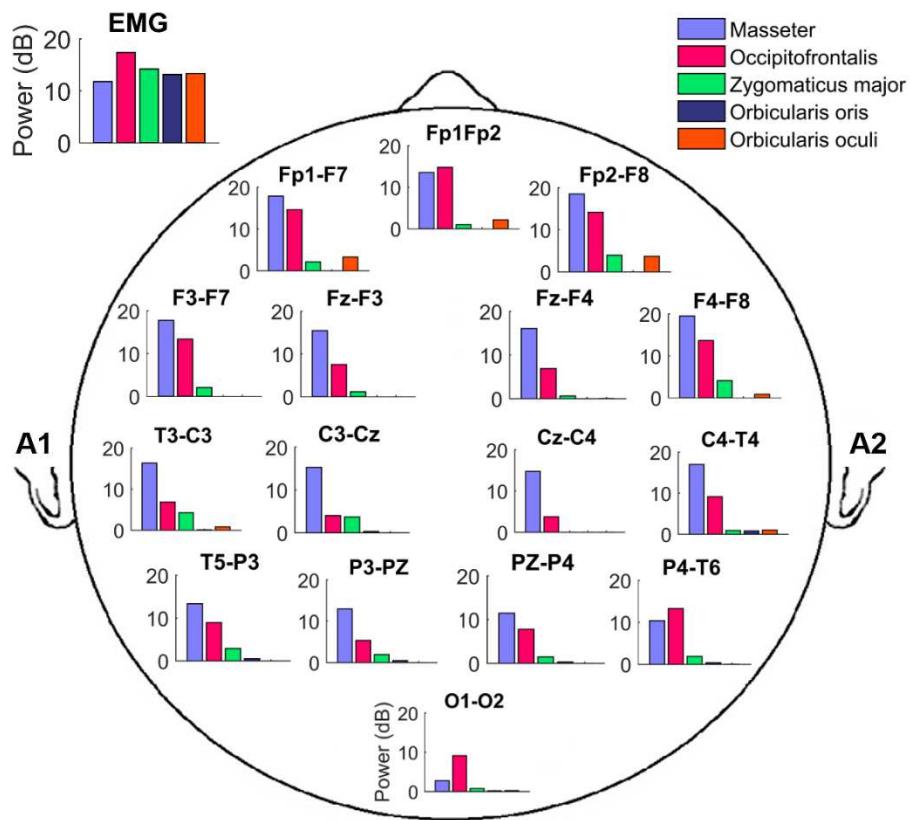
A Figura 23a mostra o mapa topográfico da potência média comparando os períodos de contração muscular orbicular da boca ativa e não ativa. A Figura 23b apresenta a potência média global de cada derivação nos períodos com e sem contração muscular.



**Figura 23:** Potência do EEG comparando os períodos de contração do músculo orbicular da boca ativo e não ativo (b) Potência dos sinais de EEG para cada derivação bipolar nos períodos de contração orbicular da boca ativa e não ativa.

A Figura 24 mostra o mapa topográfico do ganho médio de potência dos sinais EMG e EEG em decibéis, de acordo com a Equação 30. Com a qual, foi estimado o ganho de potência das janelas de contração em relação à potência média das janelas de não contração para todos os

sujeitos e para todas as contrações musculares. A figura mostra o ganho de potência do sinal EMG em relação ao ganho de potência do sinal EEG sobre a sequência de contrações musculares especificadas no protocolo experimental. A potência média pela contração muscular do frontal, temporal, zigmático maior, orbicular do olho e orbicular da boca foi medida por eletrodos EMG e comparada com o artefato do sinal EEG, no qual o valor do poder médio aumentou sobre os músculos. durante as contrações musculares foi em torno de 13 dB, para todos os músculos. Nesse caso, o músculo masseter apresentou o maior aumento da potência média entre os períodos de contração e não contração, no qual aumentou 16,7 dB.



**Figura 24: Ganho da potência média em decibéis para os sinais EMG e EEG.**

## 4.4 CONSIDERAÇÕES FINAIS

Este capítulo descreveu a contaminação do EEG pela atividade EMG facial (causada pelos músculos frontal, masseter, orbicular da boca, orbicular do olho e zigomático). Para isso, utilizou-se a potência média do sinal EEG estimada durante uma sequência de contrações musculares, tipicamente utilizada para o controle de um cursor na tela do computador [10]. Tal aplicação atende uma demanda real do nosso grupo de pesquisa, que é a avaliação do uso da informação estimada a partir dos sinais do EEG para a avaliação do processo de aprendizagem durante o controle de uma IHM.

Para isso, um bipe periódico com três durações diferentes foi empregado como estímulo para o início da contração muscular, para coordenar uma ativação voluntária do músculo. A série temporal utilizada para controle do estímulo acústico foi comparada ao envelope do sinal EMG facial, que apresentou um atraso de cerca de 100 ms, indicando concordância entre o início e o final da contração muscular com o estímulo acústico.

Usando as informações da distribuição da contaminação de energia gerada pela contração EMG, pode ser possível projetar filtros específicos para a remoção de artefatos EMG do EEG, customizando-os para bandas de frequência específicas e cada região do couro cabeludo. Foram apresentados mapas topográficos apresentaram a medida de potência média de ganho, assim como a medida de ganho de ganho médio pelos sensores EMG. Os mapas comparativos confirmaram a forte contaminação causada pelos músculos frontal e masseter e a fraca contaminação dos músculos orbiculares (do olho e da boca). Esta observação é consistente com relatos prévios [12] que confirmam uma maior contaminação de potência dos músculos frontais e temporais, que frequentemente indicam co-contração, unilateral ou bilateral, de outros músculos e uma sobreposição anatômica com os pontos de captação de EEG no escalpo.

A próxima etapa deste trabalho é a descrição do desenvolvimento da técnica EMDRLS para filtragem desse EEG fortemente contaminado por EMG.

# **Capítulo 5**

## **MÉTODO EMDRLS PARA REMOÇÃO DE ARTEFATOS MUSCULARES DO EEG FORTEMENTE CONTAMINADOS**

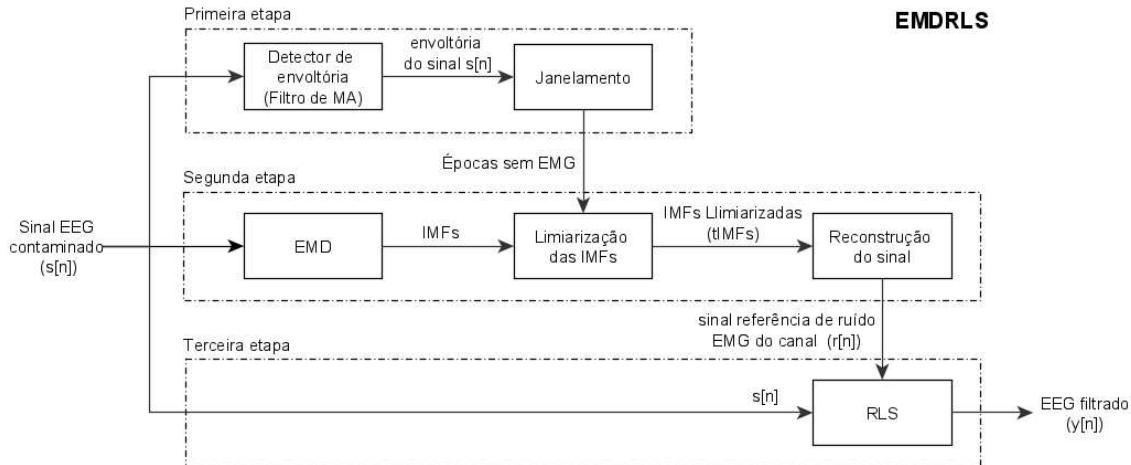
Este capítulo descreve o método de filtragem EMDRLS bem como os demais métodos de canal único utilizados na comparação de desempenho.

### **5.1 O FILTRO HÍBRIDO EMDRLS**

Esta seção descreve a técnica EMDRLS proposta neste trabalho. Esse método híbrido é baseado na aplicação de duas estratégias centrais:

- Utilização de um filtro baseado em EMD para isolar o sinal de EMG lido em cada canal de EEG, o qual será usado posteriormente como sinal de referência para o filtro RLS;
- Filtragem adaptativa RLS para filtrar sinais de EEG corrompidos por ruído utilizando como sinal de referência o sinal EMG que foi isolado na etapa anterior pelo filtro EMD.

Estas estratégias compõem uma segunda e terceira etapa de todo o processo de filtragem EMDRLS, como mostra a Figura 25.



**Figura 25: Diagrama de blocos da técnica EMDRLS para atenuação de ruído nos sinais de EEG.** Primeira etapa: regiões de sinal sem EMG são detectadas. Segunda etapa: o sinal de entrada  $s[n]$  é decomposto em IMFs para em seguida, o sinal é limiarizado baseado nas regiões livres de EMG para a geração de um sinal de referência de ruído EMG ( $r[n]$ ). Terceira etapa: O sinal de entrada,  $s[n]$ , é filtrado por um filtro RLS com um sinal de referência ( $r[n]$ ), resultando em um sinal EEG filtrado ( $y[n]$ ).

A primeira etapa do processo de filtragem consiste na detecção de épocas de EEG de sinal sem contaminação de EMG. Tal etapa, realiza a detecção da contração muscular facial. A detecção do sinal EMG é baseada na aplicação de um filtro de média móvel ou *moving average* (MA) no qual o tamanho da janela  $L$  é igual à metade do período de amostragem (isto é, 5 kHz neste estudo).

A função de transferência no domínio complexo,  $H(z)$ , do filtro MA é mostrada na Equação 31. A média global da saída do filtro MA foi limiarizada para detectar regiões livres de EMG. Tal verificação de contaminação precisa ser feita apenas em um canal, o canal mais contaminado, normalmente os frontais.

$$H(z) = \frac{1}{L} \sum_{k=0}^{L-1} s[k] z^{-k} \quad (31)$$

Na segunda etapa é gerado o sinal de referência de ruído EMG. O filtro EMD foi usado para decompor o sinal contaminado  $s[n]$  em componentes de banda limitada  $d_m[n]$ , as chamadas IMFs, as quais foram definidas de acordo com as seguintes condições:

- i. Em toda a série temporal, o número de extremos e o número de cruzamentos zero devem ser iguais ou, no máximo, diferir em 1.
- ii. Em qualquer ponto da série temporal, o valor médio dos envelopes, um definido pelos máximos locais (envelope superior) e o outro pelos mínimos locais (envelope inferior), é 0. Essa média é calculada para todas as amostras disponíveis no séries temporais.

O sinal  $s[n]$  pode ser representado pela Equação 32.

$$s[n] = \sum_{m=1}^M d_m[n] + r_M[n] \quad (32)$$

Em que  $d_m[n]$  é a m-ésima IMF e  $r_M[n]$  é o resíduo final que poderá ser uma tendência constante.

Como o EMD fornece a decomposição de um sinal na mesma escala de tempo, é possível filtrar cada um dos componentes do sinal (IMFs) individualmente, em vez do sinal original. Assim, o procedimento a seguir é aplicado para filtrar sinais EEG:

1. Decomposição do sinal em IMFs
2. Limiarização das IMFs estimadas, assumindo que as épocas livres de EMG sejam o ruído
3. Reconstrução do sinal para obter um sinal referência de ruído EMG por meio de um somatório linear das IMFs limiarizadas.

A estratégia usada para a limiarização das IMF é a técnica chamada de *soft-thresholding* que é aplicada a cada componente decomposta, conforme mostrado na Equação 33 [216].

$$tIMF_m sign(IMF_m) = (|IMF_m| - t_m)_+ \quad (33)$$

Em que  $tIMF_m$  é a versão filtrada (ou limiarizada) da m-ésima IMF. O limite  $t_m$  é estimado usando a seguinte estratégia: uma janela de ruído é selecionada no sinal original e, em seguida, os limites desta janela são usados para extrair uma região de ruído das IMFs. O desvio padrão de cada região é então estimado e aplicado como os limiares requeridos  $t_m$  ( $t_1, \dots, t_M$ ).

A terceira etapa consiste na aplicação filtragem adaptativa RLS [25,26,84] nos canais de EEG conforme mostra a Figura 25. O sinal de entrada  $s[n]$  é composto por dois componentes, isto é, o EEG o artefato de EMG. O sinal de referência,  $r[n]$ , obtido como descrito na segunda etapa. A aplicação do filtro RLS pressupõe que o EEG desejado e o ruído sejam independentes (ou pelo menos não correlacionados) [47]. A saída deste sistema é o sinal  $y[n]$ , o sinal EEG filtrado.

## **5.2 MÉTODOS DE CANAL ÚNICO CONFRONTADOS COM TÉCNICA EMDRLS**

O método EMDRLS será comparado aos seguintes métodos de remoção de artefato de canal único: (i) Wavelet, (ii) Wiener (iii) EMD e (iv)wavelet-RLS (wRLS).

O filtro wavelet foi usado como sugerido em [217], Daubechies 8 (db8) foi identificado como o mais adequado para eliminar o ruído dos sinais de EEG. Além disso, foram aplicados 5 níveis de decomposição e um limiar suave. O filtro Wiener usado foi baseado na técnica de redução de ruído em duas etapas para a filtragem de EEG proposta em [218]. O filtro EMD foi usado para filtrar o EEG, conforme sugerido em [219] por meio de uma limiarização das IMFs. O método híbrido wRLS foi usado de acordo com [220,221] que ilustra sua aplicação para remover artefatos oculares do EEG.

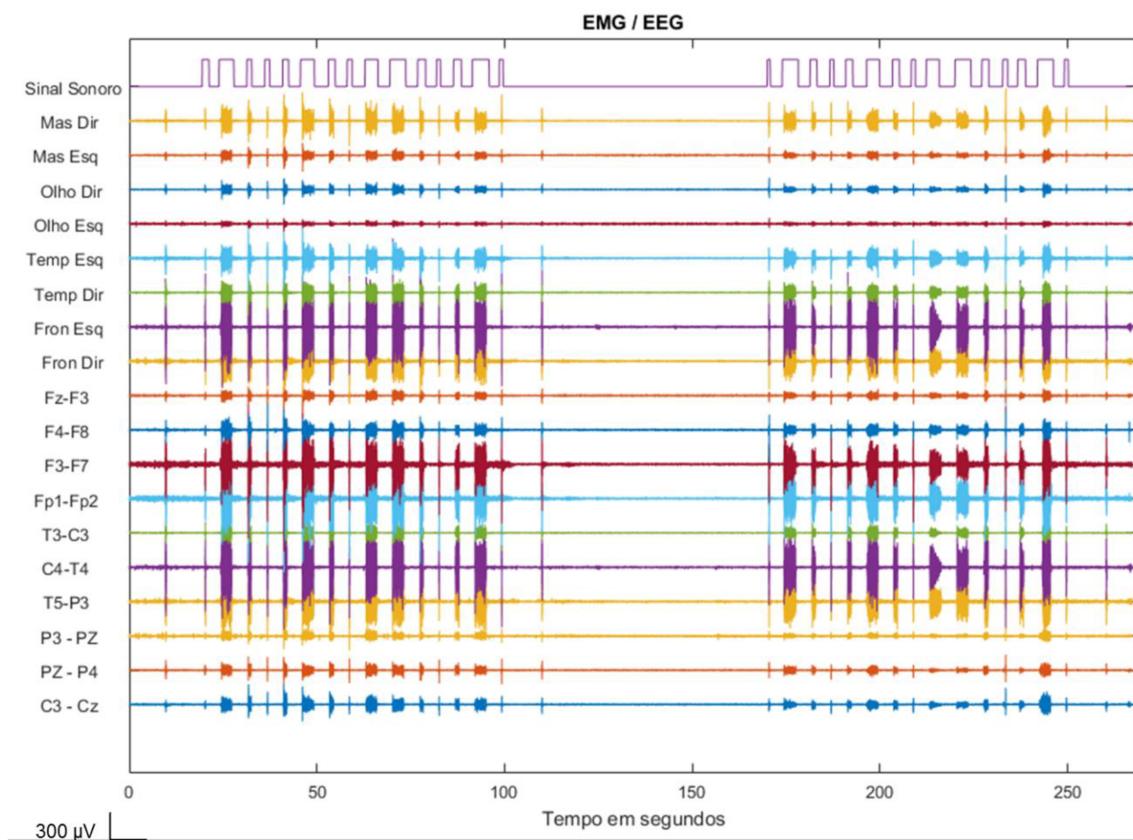
# **Capítulo 6**

## **AVALIAÇÃO DE DESEMPENHO DO MÉTODO EMDRLS COM SINAL SEMI- SINTÉTICO**

Este trabalho apontou para os esforços da remoção de artefato muscular do EEG, como mostrado no Capítulo 3 e na forma como esse tipo de ruído se propaga pelo escalpo no Capítulo 4. Baseado nesse tipo de contaminação do EEG, este capítulo apresenta uma comparação de diferentes estratégias de remoção de artefato muscular do sinal eletroencefalográfico. Serão submetidos a testes um sinal contaminado obtido a partir de dois sinais de referência, um para EMG e outro para EEG, ambos devidamente pré processados. Para avaliação de desempenho das técnicas de remoção de artefato o EMG é escalonado em amplitude em crescentes graus para em seguida ser somado ao EEG afim de resultar um sinal de EEG contaminado por eletromiografia, com o intuito de avaliar os filtros em relações sinal-ruído progressivas. Neste capítulo serão comparadas as técnicas de canal único: RLS, Wavelet e Wiener híbridas com EMD.

## 6.1 GERAÇÃO DE SINAIS EEG CORROMPIDOS POR EMG DE DIFERENTES SNR

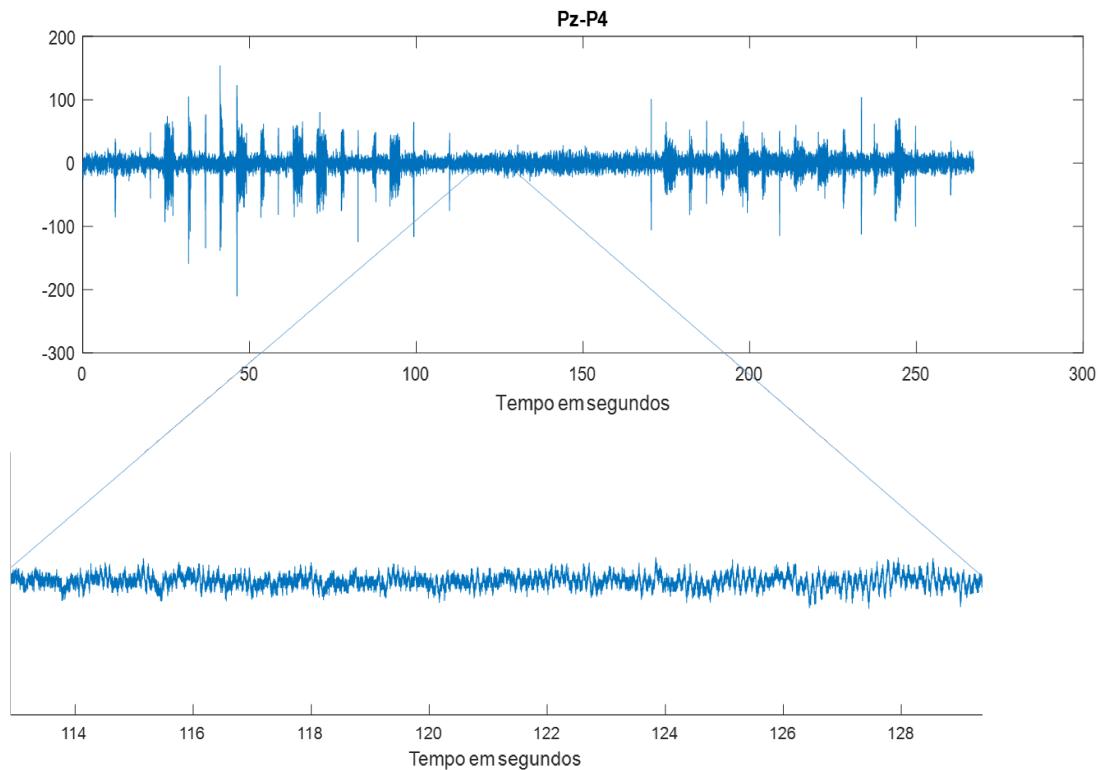
Essa seção apresenta a metodologia de obtenção dos sinais de EEG corrompidos por EMG que serão submetidos à filtragem para avaliação dos métodos de remoção de artefatos. Para essa análise foi utilizada a coleta de dados de EEG e EMG durante a execução do protocolo no qual o voluntário contraiu o músculo masseter enquanto ouvisse beeps periódicos com as durações mostradas na Tabela 7. A Figura 26 exibe os sinais de uma coleta completa para a execução do protocolo com o músculo masseter utilizando o sistema de aquisição RDH200 Intan.



**Figura 26:** Sinais de EEG e EMG durante o protocolo de contração do músculo masseter.

Nesse estágio de filtragem, como as técnicas utilizadas foram técnicas de canal único, como sugere o estudo de Chen em 2016 [21], foi selecionado o canal Pz-P4 para constituir a base para geração de sinais contaminados para a avaliação dos filtros. Este canal foi selecionado pelo

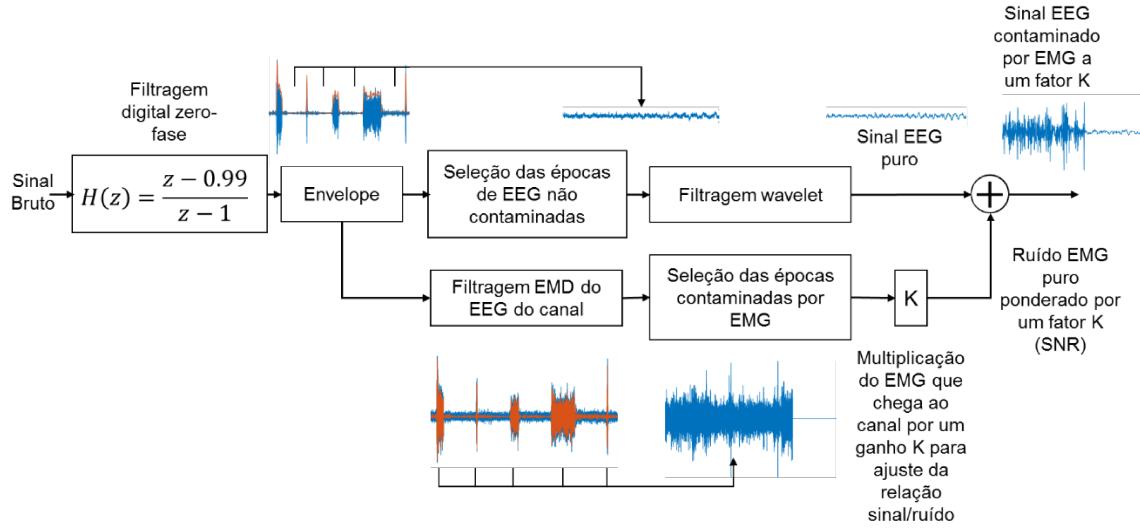
motivo de ser um canal que a verificação da atividade alfa e beta é fácil de ser verificada no domínio temporal, como mostrado na Figura 27. Além disso é um sinal que sofreu uma contaminação significativa que levou o sinal para uma relação sinal ruído na ordem -10 dB nas épocas de contaminação.



**Figura 27: Sinal EEG do canal Pz-P4 contaminado por contrações sequenciais do músculo masseter.**

Uma vez selecionado o canal, este terá suas épocas que estão livres da contaminação de EMG separadas das épocas contaminadas. O diagrama da Figura 28 ilustra o processo de geração de sinal de EEG puro e de um sinal contaminado por EMG. O processo se inicial com uma filtragem FIR zero-fase para remoção de offset. Na sequência, foi gerado uma envoltória em que são selecionadas as épocas livres de contaminação de EMG, estão são então janeladas em um novo sinal o qual são filtradas pela técnica wavelet. Este sinal filtrado será então denominado sinal EEG puro. Para a geração do sinal denominado por EMG puro, o sinal EEG é filtrado pela técnica EMD a qual foi utilizada para remover a maior parte do sinal EEG do canal. As épocas contaminadas por EMG são então selecionadas para gerar o denominado EMG puro. A técnica EMD permite a geração de sinal de referência para ruído a partir do sinal EMG que realmente alcança os eletrodos Pz-P4 e não de um sinal EMG coletado sobre o ventre muscular. Os comprimentos dos sinais EEG puro e de referência são então ajustados para em seguida o sinal de referência com EMG puro ter sua amplitude escalonada o quanto se queria. O processo de

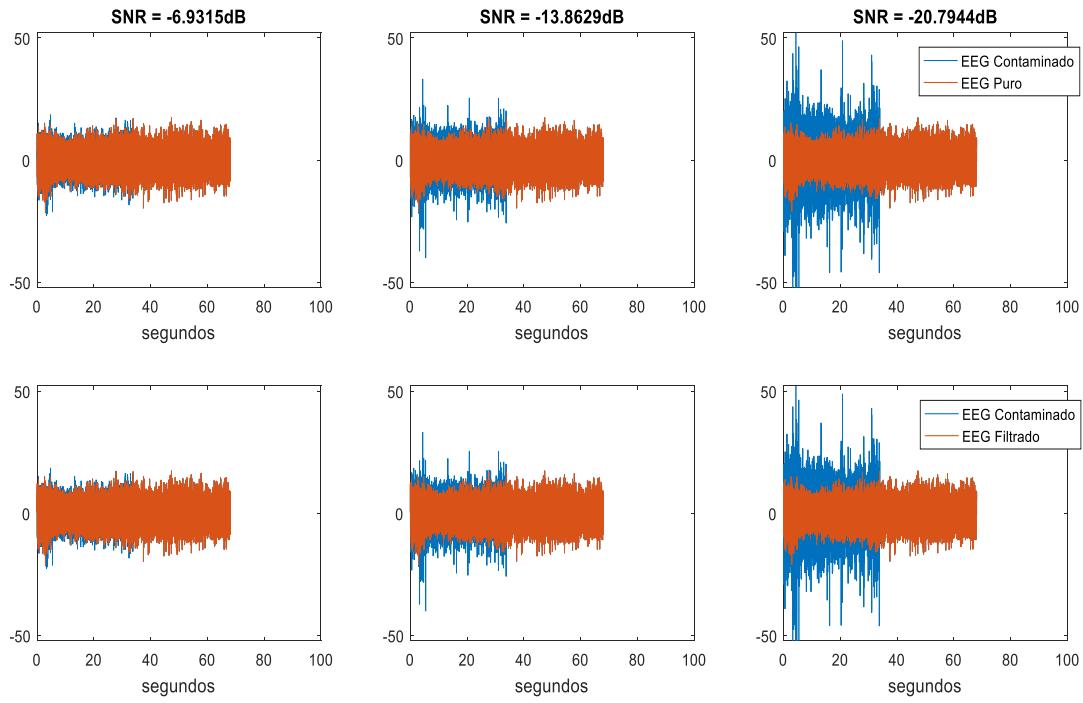
geração do sinal contaminado se finaliza ao somar o sinal EEG com o sinal de referência EMG puro, resultando em um sinal de EEG contaminado com uma ampla faixa possível para a SNR.



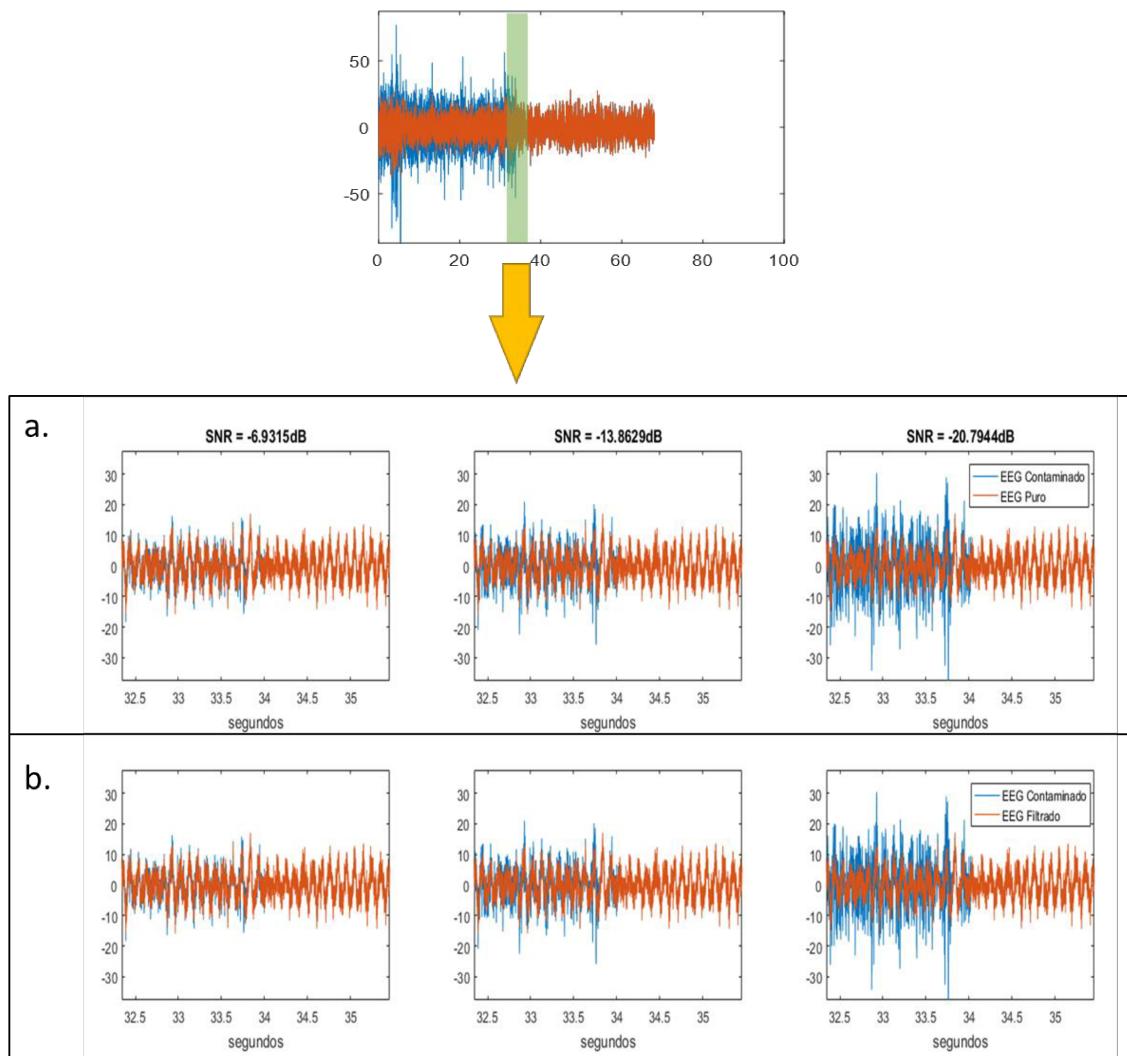
**Figura 28:Processo de geração de um sinal de EEG contaminado por EMG.**

## 6.2 REMOÇÃO DE ARTEFATO MUSCULAR DO EMG POR MEIO DE FILTRAGEM ADAPTATIVA RLS

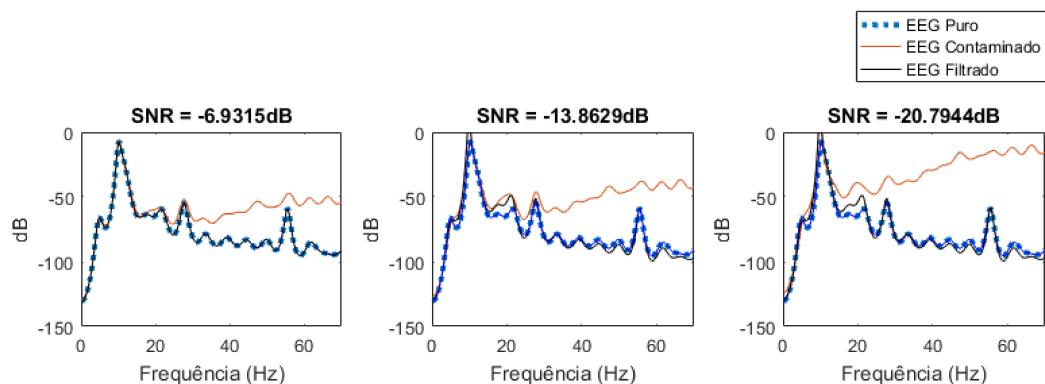
Nesta etapa, a filtragem RLS foi aplicada para remover o artefato de EMG do sinal contaminado em diferentes relações sinal-ruído. A Figura 29a ilustra o sinal de EEG puro e o sinal de EEG contaminado por EMG com 3 níveis de SNRs: -6,93 dB; -13,86 dB e -20,79 dB e a Figura 29b mostra o sinal de EEG contaminado e os sinais após a filtragem RLS. Já a Figura 30a ilustra em um intervalo de tempo de 3 segundos os sinais da Figura 29a, o mesmo vale para a Figura 30b. A inspeção visual das Figuras 29 e 30 mostram que técnica não é sensível a SNRs mais baixas, como -20,79 dB. Visualmente, a técnica demonstrou reduzir a energia do ruído tão bem quanto na contaminação de -6,93 dB. A Figura 31 apresenta o espectro em dB dos sinais de EEG contaminados nos 3 níveis de SNR, este também mostra o acerto dessa estratégia de filtragem na remoção da energia de contaminação por EMG sem prejudicar a potência espectral do EEG.



**Figura 29.** a) Sinais de EEG contaminados por EMG e sinais de EEG puros. b) Sinais contaminados por EEG e sinais filtrados com o Filtro Adaptativo RLS.



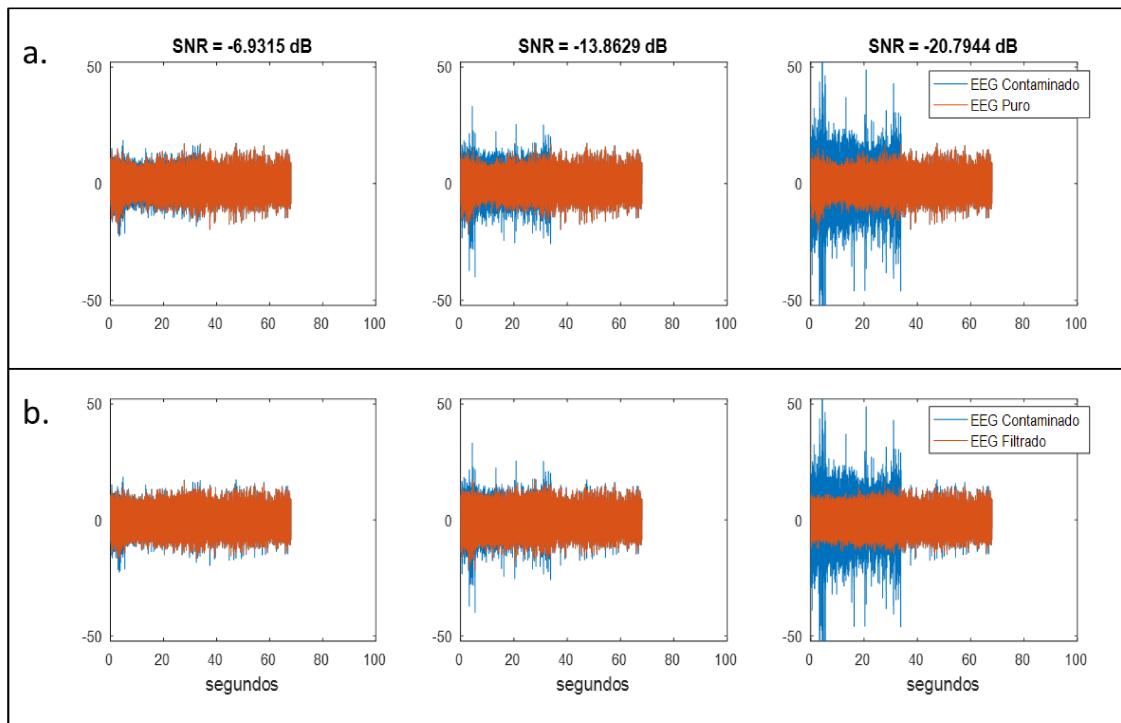
**Figura 30:** a) Trecho ampliado da Figura 29 dos sinais de EEG contaminados por EMG e dos sinais de EEG puros. b) Trecho dos sinais contaminados por EEG e dos sinais filtrados com RLS.



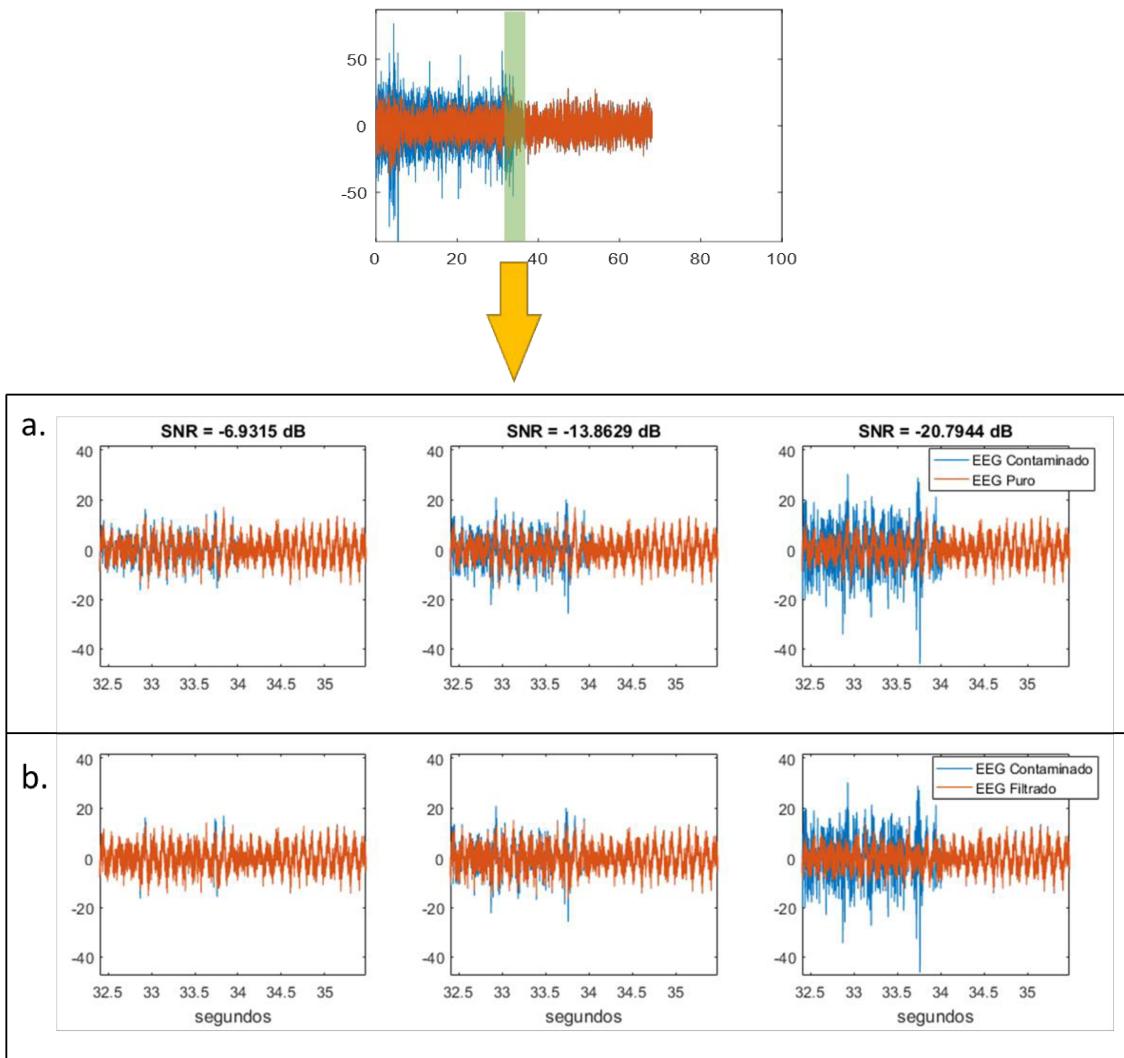
**Figura 31:** Espectros dos sinais de EEG puro, contaminado e filtrado para comparar a capacidade de filtragem para os 3 diferentes graus de contaminação.

## 6.3 REMOÇÃO DE ARTEFATO MUSCULAR DO EMG COM FILTRO DE WIENER

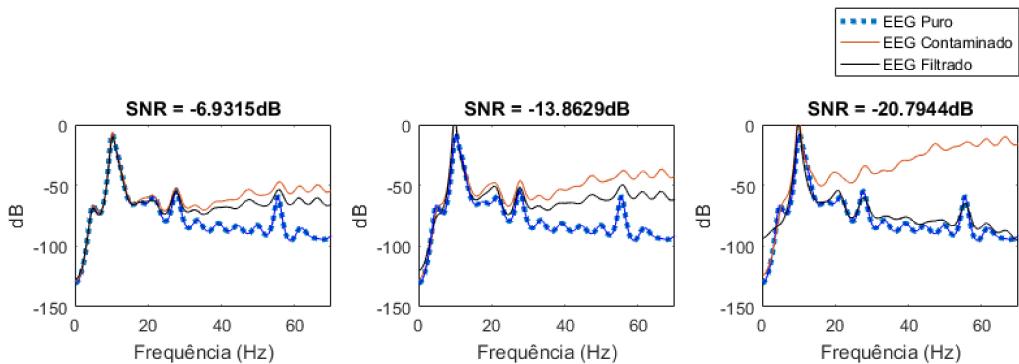
Dando continuidade, a filtragem Wiener foi aplicada para remover o artefato de EMG do sinal contaminado em diferentes relações sinal-ruído, similar ao processo com a filtragem RLS. A Figura 32a ilustra o sinal de EEG puro e o sinal de EEG contaminado por EMG com 3 níveis de SNRs: -6,93 dB; -13,86 dB e -20,79 dB e Figura 32b mostra o sinal de EEG contaminado e os sinais após a filtragem. Já a Figura 33a ilustra em um intervalo de tempo de 3 segundos os sinais da Figura 32a, o mesmo vale para a Figura 33b. A inspeção visual das Figuras 32 e 33 mostrou um desempenho inferior dessa técnica de remoção para SNRs mais baixas em comparação com o filtro RLS. A Figura 34 reforça a análise apresentando o espectro em dB dos sinais de EEG contaminados nos 3 níveis de SNR.



**Figura 32:** Sinais de EEG contaminados por EMG e sinais de EEG puros. b) Sinais contaminados por EEG e sinais filtrados com Filtro de Wiener.



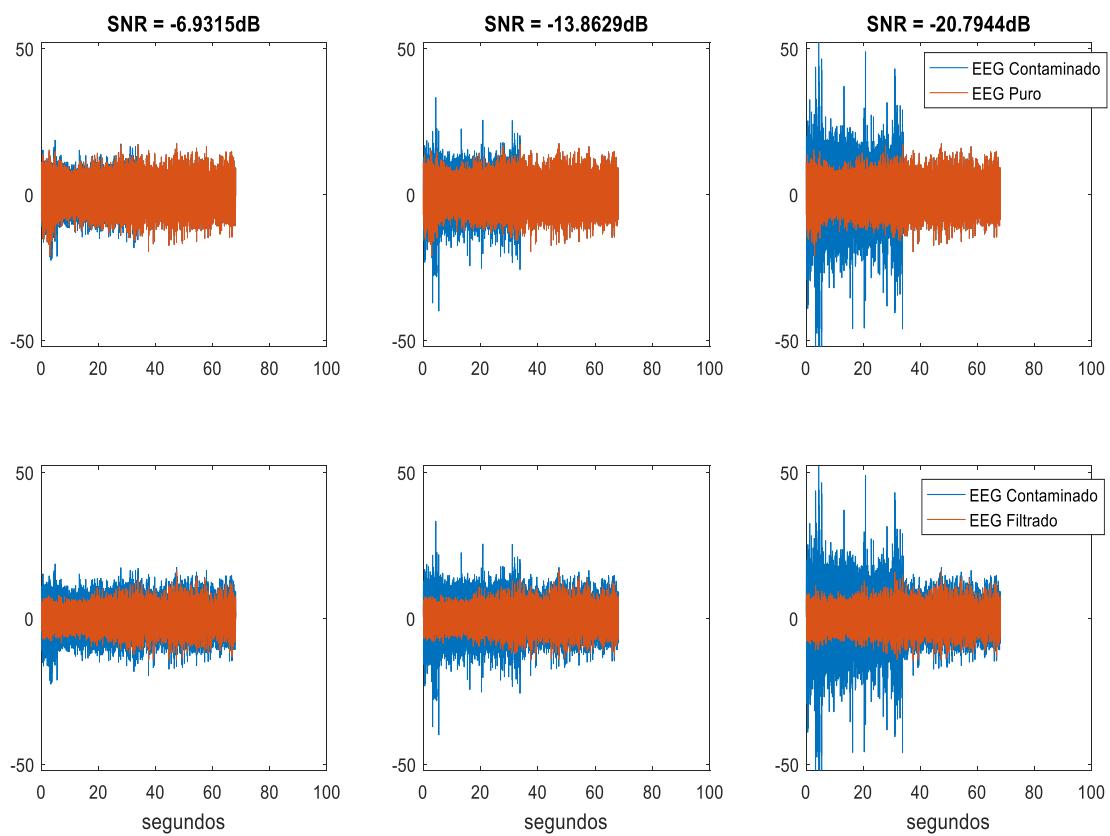
**Figura 33:** a) Trecho ampliado da Figura 32 dos sinais de EEG contaminados por EMG e dos sinais de EEG puros. b) Trecho dos sinais contaminados por EEG e dos sinais filtrados com o filtro de Wiener.



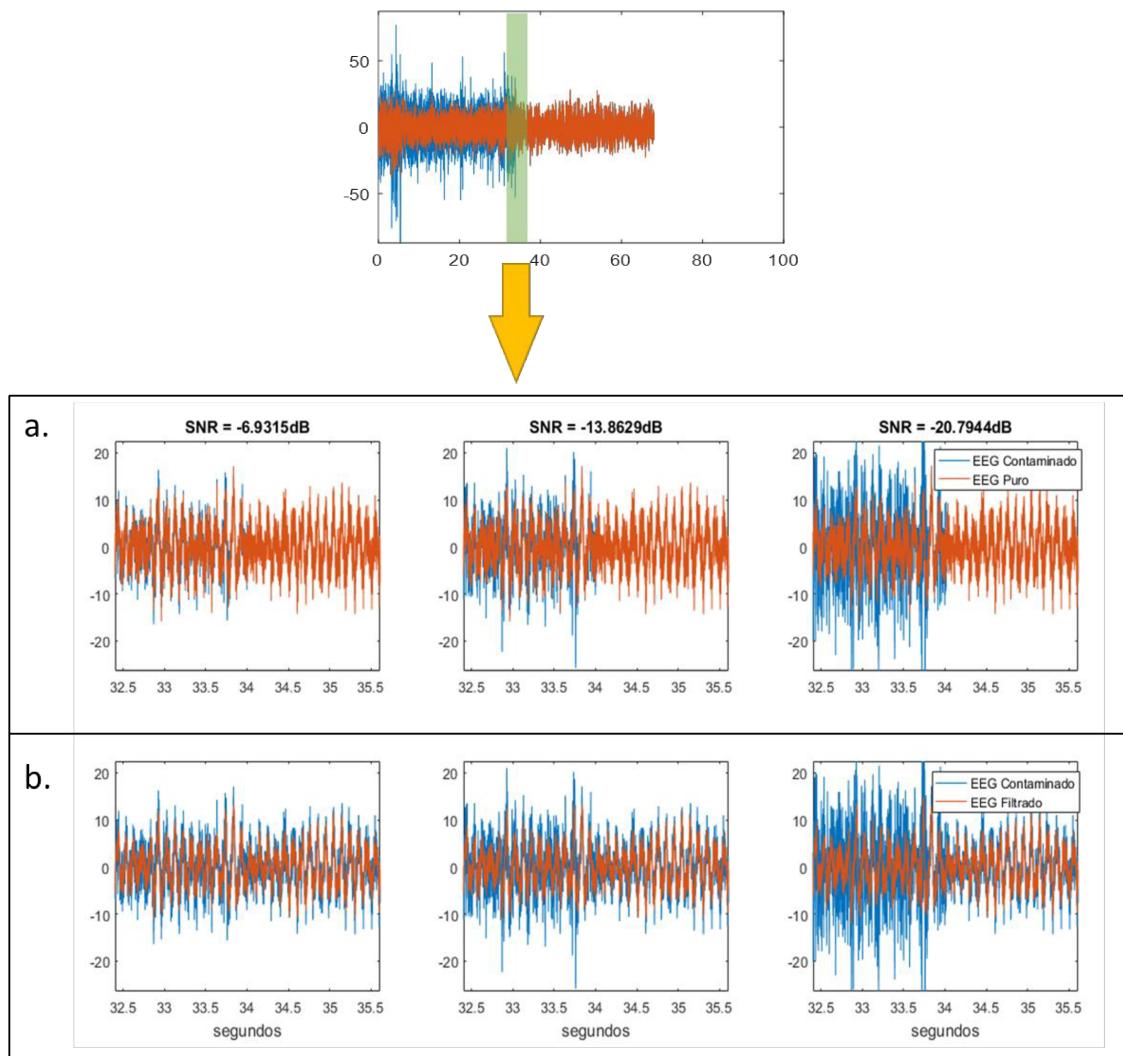
**Figura 34:** Espectros dos sinais de EEG puro, contaminado e filtrado para comparar no domínio da frequência a capacidade de filtragem do Filtro Wiener para os 3 diferentes graus de contaminação.

## 6.4 REMOÇÃO DE ARTEFATO MUSCULAR DO EMG POR MEIO DE FILTRAGEM WAVELET

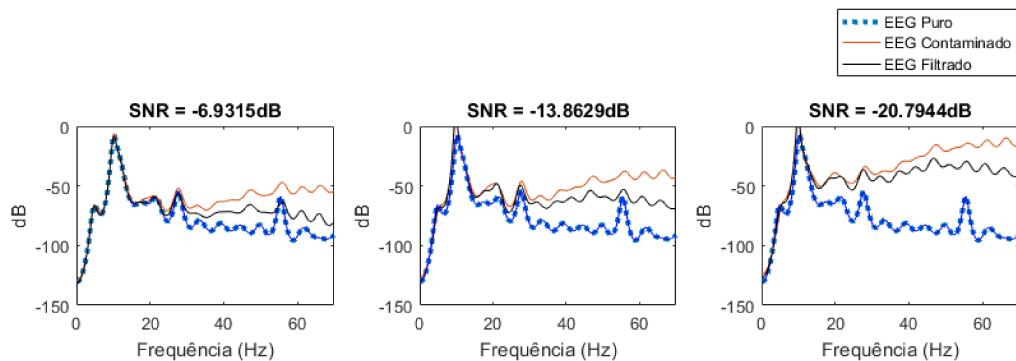
Nesta etapa, a filtragem Wavelet também foi testada para remoção do artefato de EMG do sinal contaminado nas diferentes relações sinal-ruído, similar aos processos anteriores. A Figura 35a ilustra o sinal de EEG puro e o sinal de EEG contaminado por EMG com 3 níveis de SNRs: -6,93 dB; -13,86 dB e -20,79 dB e Figura 35b mostra o sinal de EEG contaminado e os sinais após a filtragem. Já a Figura 36a ilustra em um intervalo de tempo de 3 segundos os sinais da Figura 35a, o mesmo vale para a Figura 36b. Com inspeção visual das Figuras 35 e 36 é possível analisar um bom desempenho na remoção de artefatos nas para as baixas oscilações de EEG. A Figura 37 apresenta o espectro em dB dos sinais de EEG contaminados nos 3 níveis de SNR.



**Figura 35:** a) Sinais de EEG contaminados por EMG e sinais de EEG puros. b) Sinais contaminados por EEG e sinais filtrados com o Filtro Wavelet.



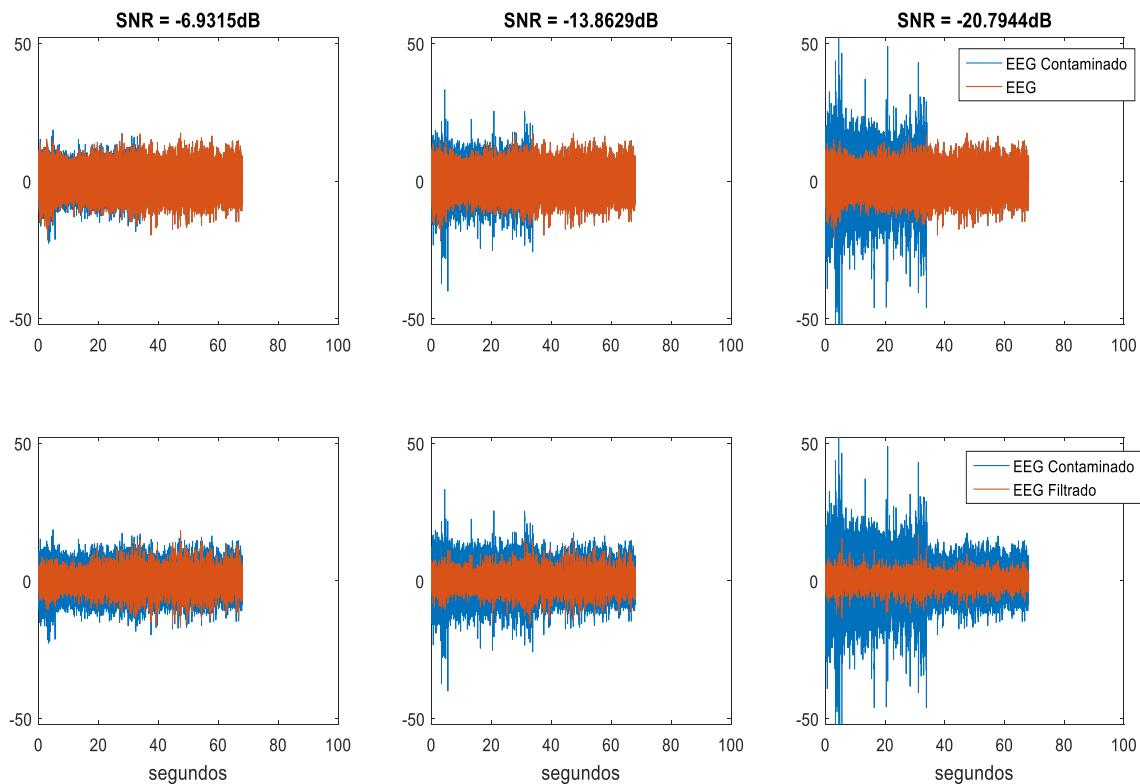
**Figura 36:** a) Trecho ampliado da Figura 35 dos sinais de EEG contaminados por EMG e dos sinais de EEG puros. b) Trecho dos sinais contaminados por EEG e dos sinais filtrados com o filtro de Wavelet.



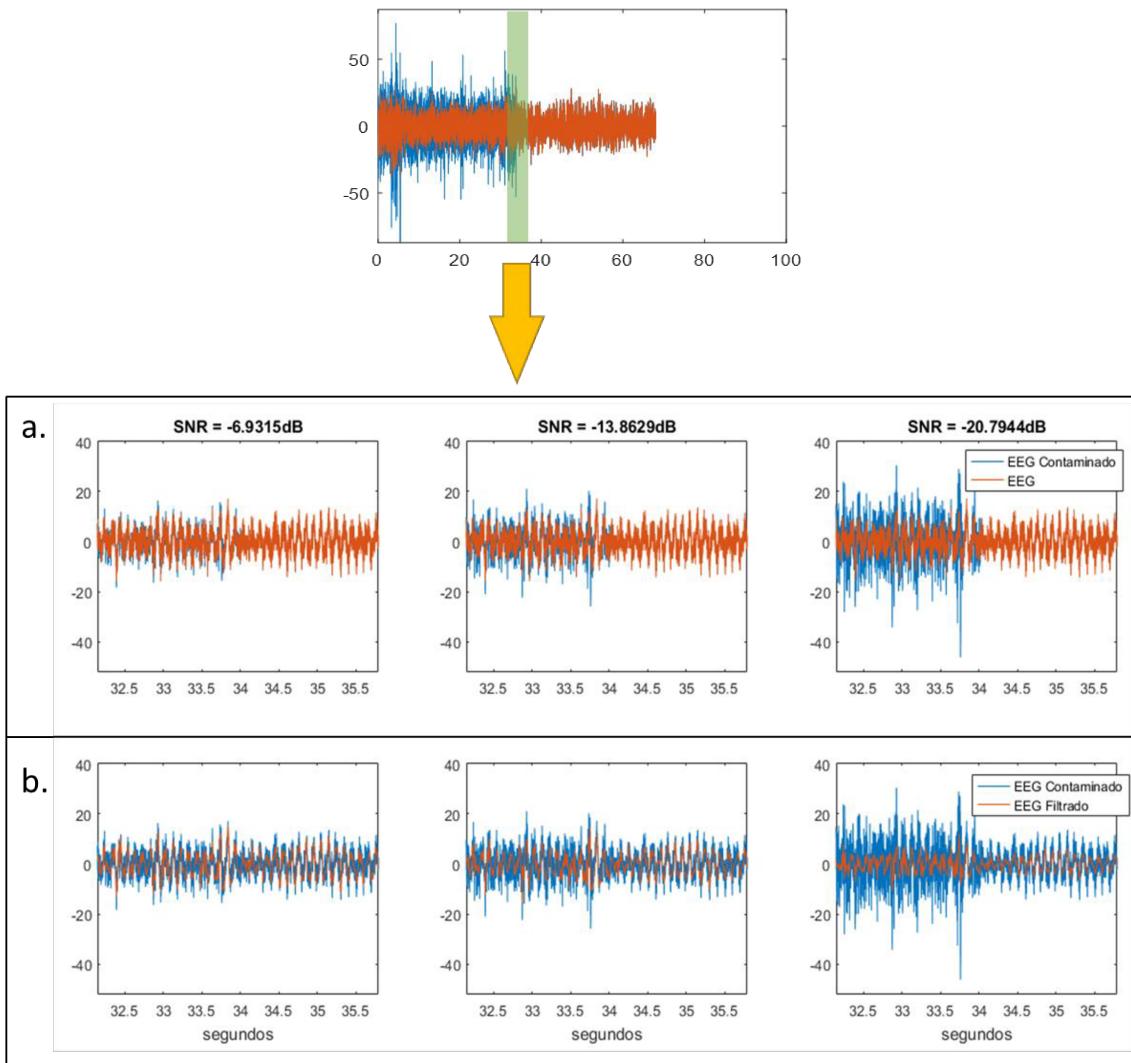
**Figura 37:** Espectros dos sinais de EEG puro, contaminado e filtrado para comparar no domínio da frequência a capacidade de filtragem Wavelet para os 3 diferentes graus de contaminação.

## 6.5 REMOÇÃO DE ARTEFATO MUSCULAR DO EMG POR MEIO DE FILTRAGEM EMD

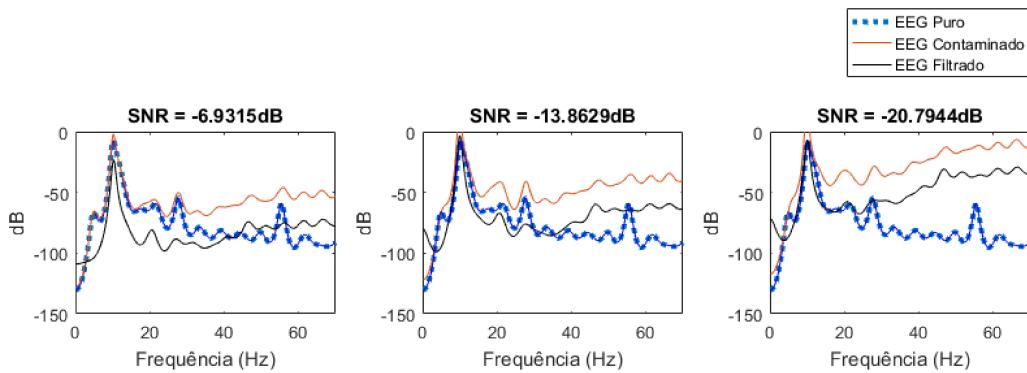
Um outro teste realizado foi a aplicação de filtragem EMD também para remover o artefato de EMG do sinal contaminado nas diferentes relações sinal-ruído, similar aos processos anteriores. Neste processo então, foi utilizado o EMD duas vezes, uma para gerar o sinal e outra para tentar remover componentes de ruído. A Figura 38a ilustra o sinal de EEG puro e o sinal de EEG contaminado por EMG com 3 níveis de SNRs: -6,93 dB; -13,86 dB e -20,79 dB e Figura 38b mostra o sinal de EEG contaminado e os sinais após a filtragem. Já a Figura 39a ilustra em um intervalo de tempo de tempo de 3 segundos os sinais da Figura 38a, o mesmo vale para a Figura 39b. Com inspeção visual das Figuras 38 e 39 é possível analisar um bom desempenho na remoção de artefatos nas baixas oscilações de EEG, as custas, entretanto, de uma diminuição da energia do sinal nas energias do EEG original acima de 50 Hz. A Figura 40 apresenta o espectro em dB dos sinais de EEG contaminados nos 3 níveis de SNR.



**Figura 38:** Sinais de EEG contaminados por EMG e sinais de EEG puros. b) Sinais contaminados por EEG e sinais filtrados com o Filtro EMD.



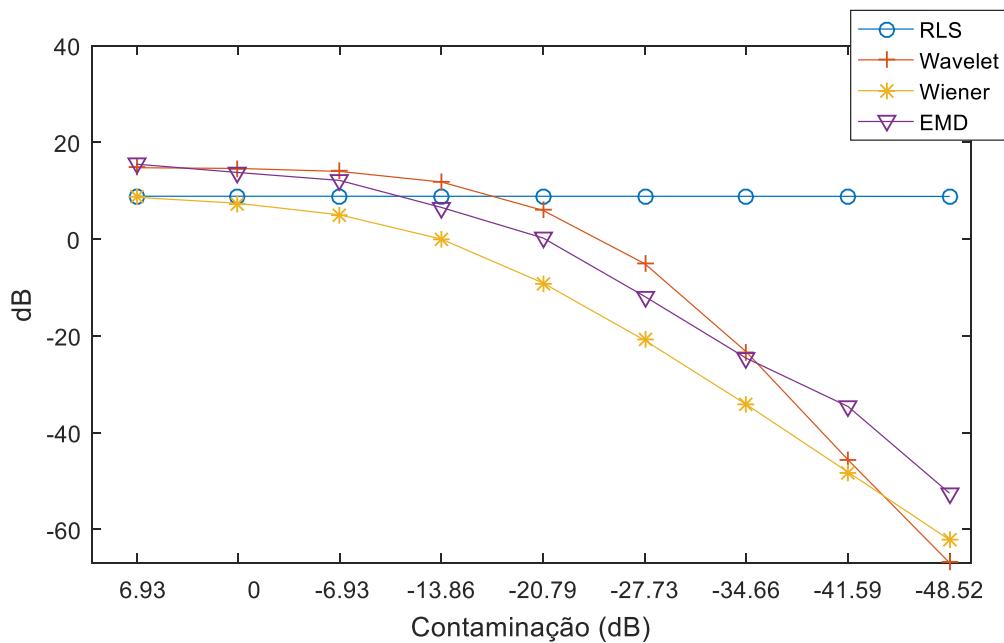
**Figura 39:** a) Trecho ampliado da Figura 38 dos sinais de EEG contaminados por EMG e dos sinais de EEG puros. b) Trecho dos sinais contaminados por EEG e dos sinais filtrados com o filtro de EMD.



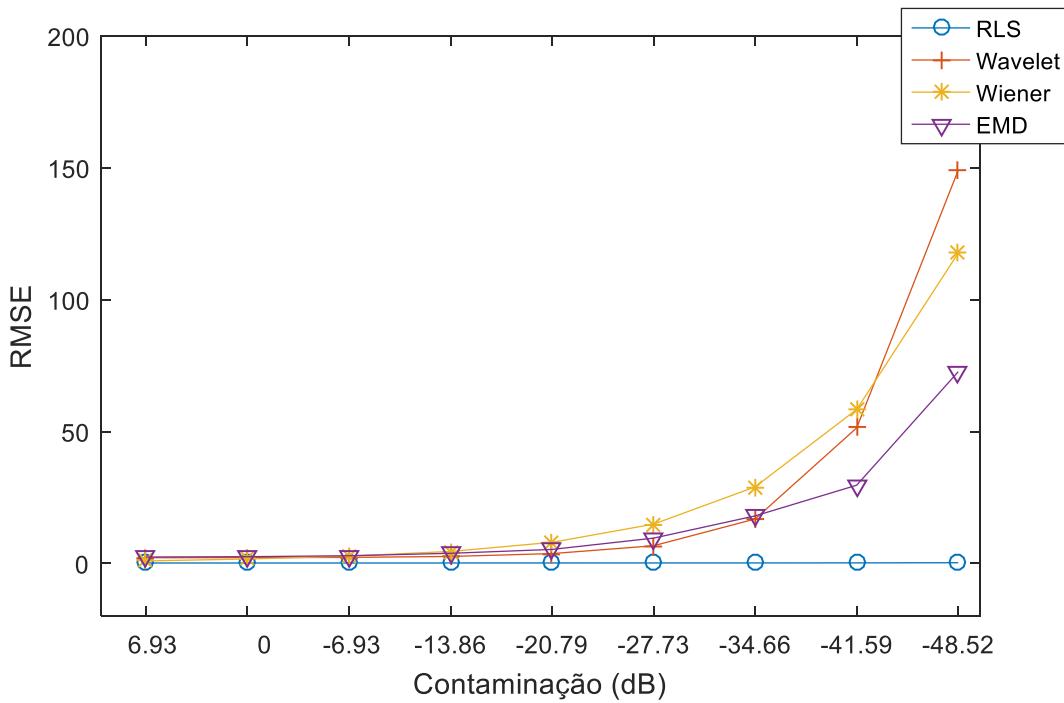
**Figura 40:** Espectros dos sinais de EEG puro, contaminado e filtrado para comparar no domínio da frequência a capacidade de filtragem do Filtro EMD para os 3 diferentes graus de contaminação.

## 6.6 COMPARAÇÃO ENTRE OS FILTROS UTILIZADOS

Além das inspeções visuais dos sinais filtrados, as técnicas de remoção de artefatos musculares do EEG apresentadas também foram comparadas em relação à dois parâmetros quantitativos (1) aumento da relação sinal/ruído (SNR) apresentado na Figura 41 e a raiz do erro quadrático médio (RMSE) na Figura 42.



**Figura 41:** Comparação da SNR das técnicas de filtragem em função da SNR causada por sinal EMG.



**Figura 42: Comparação do RMSE das técnicas de filtragem em função da SNR causada por sinal EMG.**

Os gráficos podem considerados como parâmetros que determinam a eficiência da filtragem a medida que se reduziu a SNR. Ambos os gráficos levam a concluir que neste ensaio, a filtragem adaptativa RLS híbrida com EMD é uma técnica menos sensível à piora da SNR quando contaminada por ruído de EMG, apresentando um erro quadrático médio entre a série temporal filtrada e o sinal EEG de referência na faixa de 0,13 uV e 0,28 uV.

A Filtragem de Wiener, apesar reduzir sua qualidade de filtragem em termos de SNR e RMSE, quando a relação sinal ruído é inferior à -13,86 dB mostrou na inspeção visual um desempenho que justifica sua utilização em aplicações com canais que apresentem contaminação de EMG superiores à -10 dB, com a vantagem de ser uma técnica que não precisa de canais adicionais de referência como a filtragem RLS e sim apenas índices de trecho sem contaminação dentro do sinal a ser filtrado.

As técnicas Wavelet e EMD, apesar de apresentarem resultados semelhantes ao Filtro de Wiener, apresentaram uma considerável alteração no espectro de frequências e uma considerável perda de energia de EEG. Por essa razão, a essas técnicas quando híbridas com o EMD não apresentaram resultados satisfatórios se comparadas com as filtragens híbridas EMD-RLS e EMD-Wiener.

# **Capítulo 7**

## **AVALIAÇÃO DO MÉTODO DE REMOÇÃO EMDRLS COM SINAIS REAIS**

Este capítulo apresenta a avaliação do método EMDRLS ao ser confrontado com outras técnicas de canal único utilizadas na remoção de artefatos do EEG. Será introduzida uma descrição das métricas de comparação seguido da exibição dos resultados das análises das filtragens dos sinais reais.

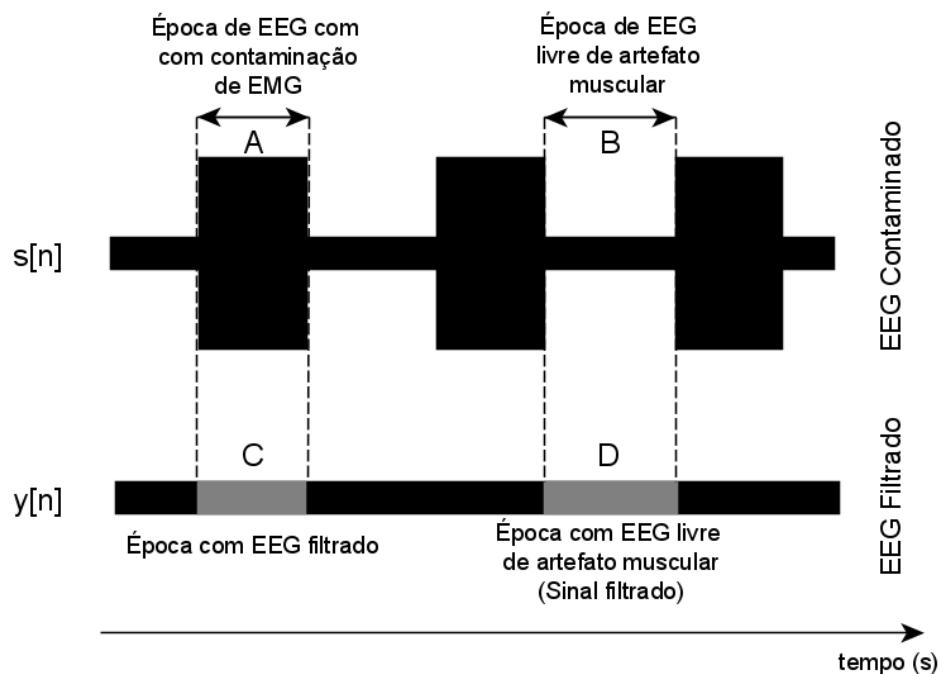
### **7.1 MEDIDAS DE DESEMPENHO DOS FILTROS DE EEG NOS SINAIS REAIS COLETADOS**

O objetivo das métricas de desempenho de filtragem é permitir a avaliação objetiva da capacidade de remoção de ruído de cada método investigado. Para avaliação do desempenho da filtragem de EEG do filtro EMDRLS, serão utilizadas as seguintes métricas:

- (i) a relação sinal-ruído (SNR) do sinal contaminado,

- (ii) o erro quadrático médio da raiz (RMSE) entre o espectro de potência das épocas livres de artefatos com as épocas de EEG filtradas,
- (iii) a preservação espectral dos ritmos cerebrais (ie, delta, teta, alfa, beta e gama) dos sinais filtrados em relação às épocas sem contaminação de EEG.

Para auxiliar na descrição dos métodos a Figura 43 será utilizada para apresentação das épocas do sinal EEG que devem ser comparados nas métricas de avaliação. Na figura são definidas as regiões no sinal **A**, **B**, **C** e **D**, além disso, define também  $s[n]$  como o sinal contaminado por EEG e  $y[n]$  como a versão filtrada correspondente. **A** é a época do sinal corrompida pelo EMG, enquanto **C** é a época correspondente no sinal filtrado. **B** é a época livre de EMG e **D** é a época correspondente no sinal filtrado.



**Figura 43: Definição das épocas do sinal EEG (A, B, C e D) para a estimativa das métricas de desempenho.  $s[n]$  é o sinal EEG contaminada com artefato muscular e  $y[n]$  é sua versão filtrada correspondente. A é a época do sinal corrompida pelo EMG, enquanto C é a mesma época no sinal filtrado correspondente. B é a época livre de EMG e D é a mesma época no sinal filtrado correspondente.**

### 7.1.1 Relação sinal-ruído (SNR)

Para as avaliações da SNR são calculadas as potências das épocas que se deseja analisar. A Equação 34 define a potência média ( $P_{epoca}$ ) de cada época, na qual  $V$  é a série temporal discreta de entrada e  $N$  é o número de amostras do sinal.  $SNR_{in}$  (Equação 35) mede a SNR em relação às regiões A e B do sinal contaminado  $s[n]$ , enquanto  $SNR_{out}$  (Equação 36) mede o SNR em relação às regiões D e C do sinal filtrado  $y[n]$ .

$$P_{epoca} = \sum_{n=1}^N V[n]^2 \quad (34)$$

$$SNR_{in} = 10 \log_{10} \left( \frac{P_B}{P_A} \right) \quad (35)$$

$$SNR_{out} = 10 \log_{10} \left( \frac{P_D}{P_C} \right) \quad (36)$$

### 7.1.2 Raiz do erro médio quadrático (RMSE) dos espectros

A RMSE fornece uma medida de distância entre o espectro de potência da época livre de artefato em relação às épocas de EEG filtradas. A densidade espectral de potência de cada sinal foi obtida pelo método Burg [222]. O método de Burg, também conhecido como Método da entropia máxima (MEM), consiste em minimizar a soma ao quadrado dos erros de previsão ao longo de toda a série temporal. A Equação 37 mostra a equação do espectro  $S(f)$  resultante da derivada da função Lagrange, em que os coeficientes de transformação de Fourier são substituídos pelo multiplicador Lagrange  $\lambda_n$ , após maximizar a função de entropia [60].

$$S(f) = \frac{1}{\sum_{k=-n}^n \lambda_k \exp(ifk)} \quad (37)$$

Em que  $\lambda_k$  é o k-ésimo multiplicador de Lagrange,  $n$  é o número de amostras do sinal de entrada e  $f$  é a frequência de  $S(f)$ .

A Equação 38 define o  $RMSE_{in}$ , que é a medida de erro entre a densidade espectral de potência da época de EEG sem contaminação de EEG,  $X(f)$  e a potência da época de EEG contaminada,  $R(f)$ . Já a Equação 39 define o  $RMSE_{out}$  como uma medida de erro entre a densidade

espectral de potência da época de EEG sem EMG,  $X(f)$  e a potência da época de EEG filtrada,  $Y(f)$ .

$$RMSE_{in} = \sqrt{\frac{1}{N} \sum_{f=1}^F (X(f) - R(f))^2} \quad (38)$$

Em que  $N = F$ , que corresponde o comprimento dos vetores  $X(f)$  e  $R(f)$ .

$$RMSE_{out} = \sqrt{\frac{1}{N} \sum_{f=1}^F (X(f) - Y(f))^2} \quad (39)$$

Em que  $N = F$ , que corresponde o comprimento dos vetores  $X(f)$  e  $Y(f)$ .

O teste de Kolmogorov-Smirnov foi empregado para testar a normalidade do conjunto de dados de RMSE (com  $p < 0,05$ ), o qual rejeitou a hipótese de que a distribuição do conjunto de dados RMSE seja normal. Assim, o teste não paramétrico de Kruskal-Wallis foi utilizado para verificar a diferença estatística ( $p < 0,05$ ) entre  $RMSE_{in}$  e  $RMSE_{out}$ . Além disso, o teste post hoc de Tukey-Kramer foi usado para comparar os grupos quando estes produziram um resultado significativo no teste de Kruskal-Wallis.

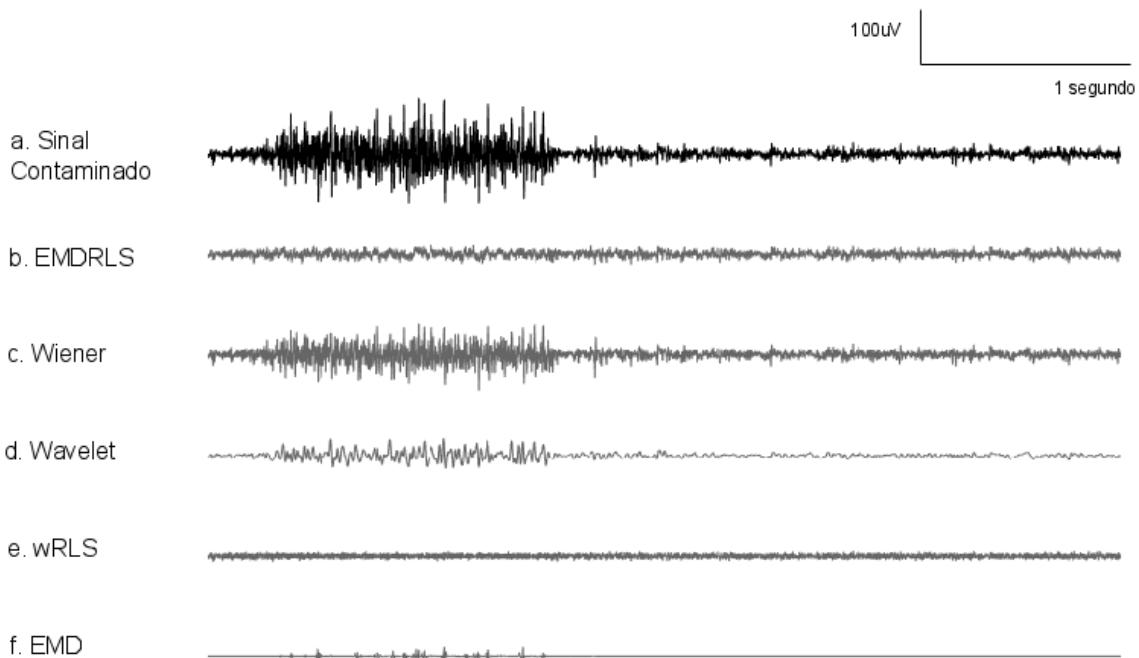
### 7.1.3 Densidade espectral de potência média (MPSD)

A densidade espectral de potência média ou *mean power spectral density* (MPSD) foi mais uma característica empregada para a avaliação da preservação espectral de ritmos cerebrais (isto é, delta, teta, alfa, beta e gama) dos sinais filtrados. Uma média global da MPSD foi calculada para cada sinal contaminado  $s[n]$ , para o sinal filtrado  $y[n]$  e para as épocas livres de EMG.

Além disso, o teste de Kolmogorov-Smirnov também foi empregado para testar a normalidade da característica MPSP ( $p < 0,05$ ) o qual rejeitou a hipótese nula de que a distribuição dos dados fosse normal. Dessa forma, na sequência foi aplicado o teste não-paramétrico de Kruskal-Wallis para verificar a diferença estatística ( $p < 0,05$ ) entre o MPSD estimado a partir das regiões B e C e regiões B e D ilustradas na Figura 43. Além disso, o teste post-hoc de Tukey-Kramer foi utilizado para comparar os grupos quando obtiveram resultado significativo no teste de Kruskal-Wallis.

## 7.2 INSPEÇÃO VISUAL DOS SINAIS FILTRADOS

A Figura 44 apresenta uma época de EEG do canal F7-F3 contaminado por EMG devido a contração muscular do masseter. Logo abaixo é mesma época após a aplicação das técnicas testadas, as técnicas híbridas EMDRLS e wRLS, removem com sucesso a contaminação por EMG. No entanto, a partir da inspeção visual pode-se observar que o método wRLS não preserva completamente a forma de onda da região livre de ruído.



**Figura 44:** Formas de onda típicas de sinais EEG contaminados (a) e filtrados com cada método de filtragem (b - f). Neste exemplo, o EEG detectado em F3-F7 foi corrompido por um sinal EMG originado a partir de uma contração do músculo masseter.

## 7.3 ANÁLISE DA SNR DO SINAIS FILTRADOS

As Figura 45 e 46 mostram a média global da SNR para todos sinais filtrados para o nível de contaminação definido conforme a Tabela 8. Os resultados são mostrados para a contaminação EMG frontal (Figura 45) e masseter (Figura 46). Essas figuras mostram a relação estimada entre o nível de contaminação e o SNR do sinal filtrado. As curvas correspondentes para cada filtro

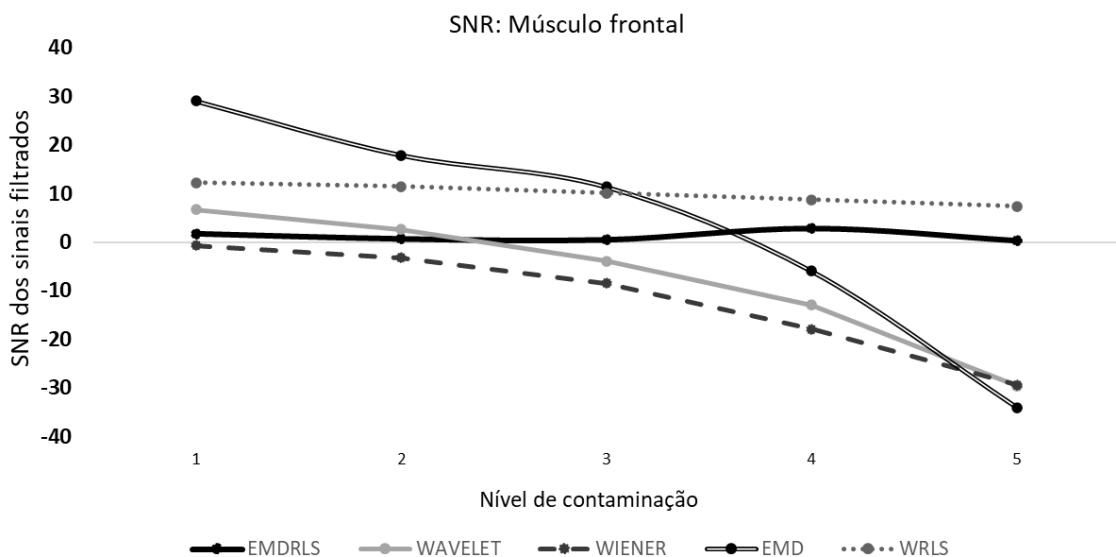
avaliado foram obtidas por um modelo de regressão (*spline*) com base nos dados disponíveis nos pontos discretos (isto é, de 1 a 5), mostrado na Tabela 8.

**Tabela 8: DE-PARA do índice de contaminação respectivo a cada faixa de contaminação das épocas A e B do sinal.**

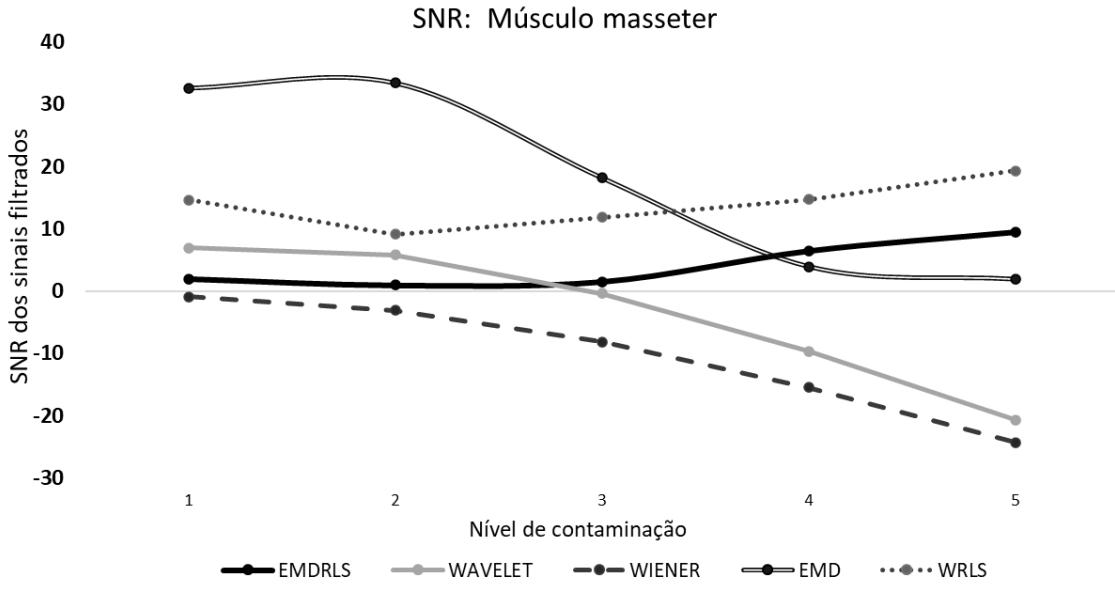
Índice adotado para o nível de contaminação	Faixa de SNR geral entre as épocas A e B
1	$\text{SNR} \geq -5 \text{ dB}$
2	$-10 \text{ dB} \leq \text{SNR} < -5 \text{ dB}$
3	$-20 \text{ dB} \leq \text{SNR} < -10 \text{ dB}$
4	$-30 \text{ dB} \leq \text{SNR} < -20 \text{ dB}$
5	$\text{SNR} < -30 \text{ dB}$

A Figura 45 mostra que as técnicas EMDRLS e wRLS são as menos sensíveis a uma redução no nível de contaminação. A inclinação de um modelo linear ajustado para cada curva da Figura 46 em relação ao eixo horizontal formariam uma reta inclinada com  $-0,41^\circ$ ,  $-9,42^\circ$ ,  $-44,41^\circ$ ,  $-50,60^\circ$ ,  $-64,24^\circ$ , respectivamente para os métodos EMDRLS, wRLS, EMD, wavelet e Wiener.

As inclinações estimadas para as curvas da Figura 46 são  $13,59^\circ$ ,  $16,71^\circ$ ,  $-39,08^\circ$ ,  $-44,46^\circ$ ,  $-50,45^\circ$ , respectivamente para os métodos wRLS, EMDRLS, Wiener, wavelet e EMD.



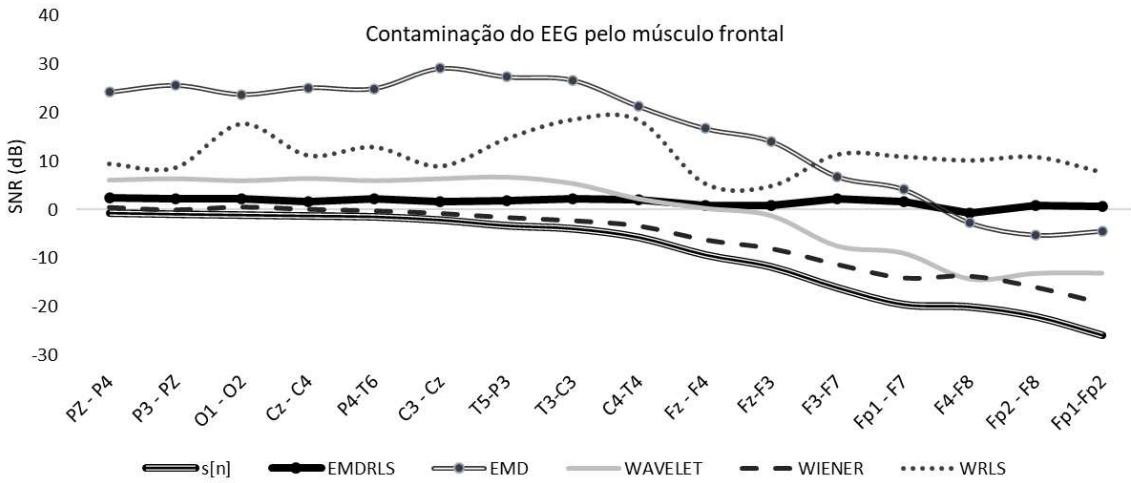
**Figura 45: Relação entre o nível de contaminação e a SNR do sinal filtrado em relação ao sinal contaminado por EMG do músculo frontal.**



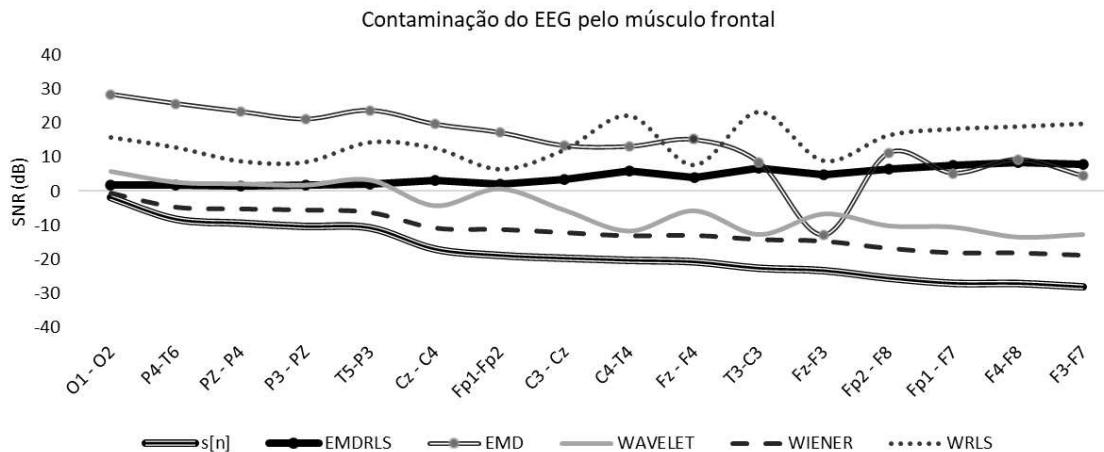
**Figura 46:** Relação entre o nível de contaminação e a SNR do sinal filtrado em relação ao sinal contaminado por EMG do músculo masseter.

A Figura 47 mostra a média geral da SNR do sinal contaminado por EMG após a filtragem pelo EMG dos músculos frontais e a Figura 48 mostra a mesma informação para as contrações do músculo masseter (B) em relação ao canal de EEG. O SNR médio global do sinal EEG corrompido,  $s[n]$ , também é mostrado.

Nestes cenários, idealmente, o filtro deve ser capaz de remover o ruído mantendo as informações do sinal, independentemente do nível de contaminação. Isso pode ser alcançado por um filtro cuja relação entre o nível de contaminação e o SNR do sinal filtrado segue um modelo linear com um coeficiente linear e angular próximo a zero, a fim de evitar a degradação do sinal filtrado em altos níveis de contaminação. Esse cenário pode ser obtido quando  $P_D$  é igual a  $P_C$  na Equação 36.



**Figura 47:** SNR média global dos sinais de EEG filtrados após a contaminação pelo EMG do músculo frontal em relação a cada canal de EEG. O SNR médio geral do sinal EEG contaminado,  $s[n]$ , também é mostrado.



**Figura 48:** SNR média global dos sinais de EEG filtrados apóas a contaminação pelo EMG do músculo masseter em relação a cada canal de EEG. O SNR médio geral do sinal EEG contaminado,  $s[n]$ , também é mostrado.

## 7.4 COMPARAÇÃO DA RMSE DO ESPECTRO DE POTÊNCIA ENTRE AS ÉPOCAS COM SINAL DE EEG PURO E AS ÉPOCAS COM SINAL DE EEG FILTRADO

As Tabelas 9 e 10 mostram os valores médios globais do RMSE para os músculos frontal e masseter, respectivamente. Nas tabelas foram incluídos resultados para os canais frontal e central, pois são os mais contaminados.

Quanto mais baixo o RMSE, mais eficiente é o filtro em termos de preservação espectral em relação ao sinal livre de EMG. Os melhores resultados foram obtidos no filtro EMDRLS, que mostrou menor variabilidade e diferenças significativas para todos os canais frontais e contaminação EMG de ambos os músculos (ou seja, frontal e masseter).

**Tabela 9: Média e desvio padrão do RMSE entre o espectro de potência do EEG livre de EMG e as épocas do EEG filtrado contaminadas pelo EMG pelo músculo frontal. Os rótulos numéricos sobreescrito denotam diferença significativa entre cenários não filtrados e filtrados**

Canal	Músculo frontal (Sem filtro)	EMDRLS	EMD	Wiener	Wavelet	WRLS
Fp2 - F8	$1,670 \pm 0,029^{1,2}$	$0,039 \pm 0,011^1$	$1,225 \pm 1,666$	$0,650 \pm 0,656$	$1,325 \pm 1,752$	$0,109 \pm 0,652^2$
F4-F8	$1,311 \pm 0,060^{3,4}$	$0,076 \pm 0,093^3$	$0,995 \pm 1,546$	$0,446 \pm 0,436$	$1,166 \pm 1,611$	$0,091 \pm 0,109^4$
Fp1 - F7	$1,251 \pm 0,019^{5,6}$	$0,025 \pm 0,024^5$	$0,737 \pm 1,491$	$0,636 \pm 1,001$	$0,658 \pm 0,976$	$0,074 \pm 0,039^6$
Fp1-Fp2	$1,107 \pm 0,223^{7,8}$	$0,013 \pm 0,008^7$	$0,619 \pm 1,228$	$0,553 \pm 0,792$	$0,493 \pm 0,625$	$0,058 \pm 0,053^8$
C4-T4	$0,708 \pm 1,355$	$0,140 \pm 0,080$	$0,618 \pm 0,629$	$0,387 \pm 0,670$	$0,643 \pm 1,126$	$0,422 \pm 0,314$
F3-F7	$0,580 \pm 0,066^9$	$0,032 \pm 0,021^9$	$0,219 \pm 0,314$	$0,284 \pm 0,249$	$0,388 \pm 0,275$	$0,081 \pm 0,049$

**Tabela 10: Média e desvio padrão do RMSE entre o espectro de potência do EEG livre de EMG e as épocas do EEG filtrado contaminadas por EMG do músculo masseter. Os rótulos numéricos sobreescrito denotam diferença significativa entre cenários não filtrados e filtrados**

Canal	Músculo masseter (sem filtro)	EMDRLS	EMD	Wiener	Wavelet	WRLS
C4-T4	$8,047 \pm 3,596^{1,2}$	$0,271 \pm 0,221^1$	$0,338 \pm 0,353^2$	$1,270 \pm 5,221$	$1,279 \pm 7,724$	$0,290 \pm 0,430$
T3-C3	$7,842 \pm 0,912^{3,4}$	$0,362 \pm 0,383^3$	$0,380 \pm 0,227$	$0,429 \pm 3,363$	$0,373 \pm 5,434$	$0,396 \pm 0,443^4$
F4-F8	$5,388 \pm 0,189^{5,6,7,8,9}$	$0,151 \pm 0,159^5$	$0,159 \pm 0,155^6$	$0,170 \pm 2,905^7$	$0,181 \pm 3,555^8$	$0,155 \pm 0,181^9$
F3-F7	$4,571 \pm 1,107^{10,11,12}$	$0,158 \pm 0,119^{10}$	$0,260 \pm 0,053^{11}$	$0,482 \pm 1,522$	$0,510 \pm 1,641$	$0,258 \pm 0,119^{12}$
Fp2 - F8	$3,373 \pm 0,013^{13,14,15}$	$0,109 \pm 0,105^{13}$	$0,143 \pm 0,072^{14}$	$0,175 \pm 1,519$	$0,179 \pm 1,600$	$0,151 \pm 0,099^{15}$
Fp1 - F7	$3,345 \pm 0,150^{16,17,18}$	$0,134 \pm 0,125^{16}$	$0,186 \pm 0,055^{17}$	$0,141 \pm 0,816$	$1,172 \pm 0,587$	$0,229 \pm 0,123^{18}$

## 7.5 PRESERVAÇÃO ESPECTRAL (MPSD) DOS RITMOS DE FREQUÊNCIA NO EEG

As Tabelas 11 e 12 mostram a média geral e o desvio padrão da MPSD para os músculos frontal e masseter, respectivamente. As tabelas comparam o MPSD para cada ritmo cerebral entre as épocas do sinal EEG sem contaminação EMG e o sinal filtrado. Somente o método EMDRLS proposto não produziu diferenças entre os sinais sem ruído e os sinais filtrados para todos os ritmos cerebrais em ambas as contaminações (frontal e masseter).

**Tabela 11:** Média e desvio padrão da MPSP (em  $\mu$ V) entre o espectro de potência das épocas do EEG sem contaminação de EMG e as épocas do EEG filtrado contaminadas pelo EMG do músculo frontal para os ritmos cerebrais distintos. A eficácia da filtragem é medida pela similaridade espectral entre os sinais de EEG filtrados e o sinal de EEG livre de artefato de EMG. Os rótulos numéricos sobreescritos denotam diferença significativa entre o espectro de potência do EEG livre de contaminação por EMG e as épocas do EEG filtrado em um nível de significância de 0,05

Ritmo	Época de EEG não contaminada	EMDRLS	WIENER	WAVELET	EMD	WRLS
Delta	0,041 $\pm$ 0,035 <sup>1,2</sup>	0,071 $\pm$ 0,179	0,094 $\pm$ 0,501 <sup>1</sup>	0,113 $\pm$ 0,3245	0,073 $\pm$ 0,108	0,004 $\pm$ 0,007 <sup>2</sup>
Theta	0,071 $\pm$ 0,0691 <sup>3,4</sup>	0,087 $\pm$ 0,106	0,135 $\pm$ 0,724 <sup>3</sup>	0,167 $\pm$ 0,497	0,107 $\pm$ 0,147	0,005 $\pm$ 0,004 <sup>4</sup>
Alpha	0,406 $\pm$ 0,6321 <sup>5,6</sup>	0,309 $\pm$ 0,422	0,476 $\pm$ 2,491 <sup>5</sup>	0,908 $\pm$ 2,678	0,483 $\pm$ 0,748	0,015 $\pm$ 0,021 <sup>6</sup>
Beta	0,340 $\pm$ 0,491 <sup>7,8</sup>	0,304 $\pm$ 0,419	0,374 $\pm$ 1,532 <sup>7</sup>	0,937 $\pm$ 1,768	0,574 $\pm$ 0,718	0,022 $\pm$ 0,012 <sup>8</sup>
Gamma	0,095 $\pm$ 0,166 <sup>9,10,11</sup>	0,092 $\pm$ 0,147	0,257 $\pm$ 0,721 <sup>9</sup>	0,586 $\pm$ 1,085 <sup>10</sup>	0,356 $\pm$ 0,594	0,014 $\pm$ 0,006 <sup>11</sup>

**Tabela 12:** Média e desvio padrão da MPSP (em  $\mu$ V) entre o espectro de potência das épocas do EEG sem contaminação de EMG e as épocas do EEG filtrado contaminadas pelo EMG do músculo masseter para os ritmos cerebrais distintos. A eficácia da filtragem é medida pela similaridade espectral entre os sinais de EEG filtrados e o sinal de EEG livre de artefato de EMG. Os rótulos numéricos sobreescritos denotam diferença significativa entre o espectro de potência do EEG livre de contaminação por EMG e as épocas do EEG filtrado em um nível de significância de 0,05

Ritmo	Época de EEG não contaminada	EMDRLS	WIENER	WAVELET	EMD	WRLS
Delta	0,056 $\pm$ 0,058 <sup>1,2</sup>	0,063 $\pm$ 0,057	0,025 $\pm$ 0,062 <sup>1</sup>	0,136 $\pm$ 0,269	0,089 $\pm$ 0,125	0,002 $\pm$ 0,001 <sup>2</sup>
Theta	0,088 $\pm$ 0,089 <sup>3,4</sup>	0,096 $\pm$ 0,084	0,035 $\pm$ 0,085 <sup>3</sup>	0,190 $\pm$ 0,358	0,127 $\pm$ 0,164	0,003 $\pm$ 0,003 <sup>4</sup>
Alpha	0,456 $\pm$ 0,653 <sup>5,6</sup>	0,360 $\pm$ 0,467	0,117 $\pm$ 0,302 <sup>5</sup>	0,764 $\pm$ 1,169	0,475 $\pm$ 0,622	0,009 $\pm$ 0,015 <sup>6</sup>
Beta	0,388 $\pm$ 0,579 <sup>7,8,9</sup>	0,285 $\pm$ 0,374	0,162 $\pm$ 0,465 <sup>7</sup>	1,943 $\pm$ 3,979 <sup>8</sup>	0,925 $\pm$ 1,735	0,025 $\pm$ 0,015 <sup>9</sup>
Gamma	0,201 $\pm$ 0,327 <sup>10,11,12,13</sup>	0,122 $\pm$ 0,203	0,124 $\pm$ 0,290 <sup>10</sup>	2,321 $\pm$ 5,343 <sup>11</sup>	1,090 $\pm$ 2,400 <sup>12</sup>	0,015 $\pm$ 0,006 <sup>13</sup>

# Capítulo 8

## DISCUSSÕES E CONCLUSÕES

O método EMDRLS foi desenvolvido para a remoção de artefatos musculares faciais dos sinais de EEG, que é um requisito importante para aplicações distintas. É uma abordagem de canal único para filtrar EEG com baixos valores SNR onde as ferramentas tradicionais perdem desempenho. Neste trabalho, o EMD foi usado para gerar uma referência de ruído EMG para um filtro RLS adaptativo. O desempenho do filtro EMDRLS (Figura 25) foi comparado com outras abordagens tradicionais de canal único (wRLS, EMD, wavelet e Wiener) usando como métricas quantitativas SNR, RMSE e MPSD. Estas mediram a capacidade de remoção em relação ao nível de contaminação, o erro médio no espectro e a preservação de energia nos ritmos clássicos de EEG.

O filtro desenvolvido foi avaliado em dados reais de EEG coletados de 10 indivíduos saudáveis. Apresentando uma comparação de eficácia dos métodos de filtragem para diferentes músculos atendendo uma necessidade percebida na literatura [9,142]. Assim, esse trabalho investigou o desempenho dos filtros considerando a contaminação por EEG por dois músculos faciais distintos (ou seja, frontal e masseter).

A inspeção visual de um sinal filtrado EEG típico (Figura 44) mostra como o método EMDRLS garante a preservação de formas de onda na região livre de EMG em comparação com outras abordagens e como a contaminação EMG é removida do sinal EEG.

A partir dos resultados apresentados nas Figuras 45 e 46, pode-se observar que o método EMDRLS é o menos sensível ao SNR do sinal EEG corrompido. Tais resultados são consistentes, independentemente do ruído produzido pelos músculos frontal e masseter, medidos pela

inclinação relativamente baixa do modelo linear ajustado à curva de resposta do método EMDRLS.

Ao avaliar o erro de espectro (RMSE) entre o sinal livre de EMG e os sinais corrompidos (Tabelas 9 e 10), o RMSE mais alto (ou seja, 7.842 e 8.047) foi obtido para as regiões centrais do couro cabeludo durante a contração do masseter. Esses valores foram reduzidos para 0,362 (para T3-C3) e 0,271 (C4-T4) nos sinais filtrados pelo método EMDRLS. A técnica manteve os valores mais baixos de RMSE para todos os outros canais (central e frontal) em comparação com outras técnicas de filtragem. Embora não haja consenso entre os pesquisadores sobre a seleção das técnicas de remoção de artefatos de EEG, alguns pesquisadores propuseram o uso do RMSE no domínio do tempo [9,142,223]. Nesta pesquisa, essa métrica foi introduzida para contrastar o espectro de potência entre o EEG sem contaminação de EMG e as épocas filtradas por EEG.

As Tabelas 9 e 10 compararam o RMSE entre o EEG sem contaminação de EMG e as épocas de EEG filtradas contaminadas por EMG dos músculos frontal e masseter. Os canais selecionados foram os que apresentaram o maior nível de contaminação por EMG. O RMSE para o masseter é maior que o RMSE para o músculo frontal. Isso pode ser justificado pelo fato de o masseter ser um dos músculos mais fortes (com base no seu peso) no corpo humano.

Quando comparado aos outros métodos de filtragem, o método EMDRLS foi o que produziu o menor RMSE médio com a menor variabilidade para todos os canais, sugerindo preservação espectral. Além disso, foi o único método que produziu diferença estatística entre o RMSE dos sinais não filtrados em relação aos sinais filtrados para todos os canais de EEG contaminados por EMG do músculo masseter (Tabela 10). Para os canais de EEG contaminados por EMG do músculo frontal (Tabela 9), os resultados são semelhantes, exceto para o RMSE do canal C4-T4 que foi estatisticamente equivalente ao RMSE do sinal não filtrado. No entanto, o valor de RMSE foi reduzido significativamente de 0,708 para 0,140.

As tabelas 11 e 12 apresentam os resultados para o MPSP métrico. O comportamento desejável do filtro é garantir uma similaridade de valores entre o MPSP de EEG livre de EMG e épocas de EEG filtrado. Os resultados nas tabelas são fornecidos para ritmos cerebrais específicos. O método EMDRLS foi o único que produziu sinais de EEG filtrados cuja MPSP foi estatisticamente semelhante à MPSP do EEG livre de EMG, para todos os ritmos cerebrais.

As técnicas híbridas analisadas neste estudo combinaram o filtro adaptativo RLS com as técnicas de decomposição EMD e wavelet, que removeram a contaminação EMG, como mostrado na Figura 44. No entanto, o método wRLS não preserva a forma de onda do sinal EEG sem EMG. O desempenho superior de uma técnica híbrida com o método EMD é consistente com [224], que também comparou os métodos EMD e wavelet em uma combinação híbrida com ICA e concluiu que a técnica híbrida wavelet teve desempenho pior que o híbrido com EMD. A possível razão é que a análise de wavelets decompõe um sinal em cada estágio de maneira predeterminada, excluindo a possibilidade de adaptar a decomposição às variações locais da oscilação. Sem o

conhecimento prévio do sinal de EEG livre de EMG, é inconveniente selecionar efetivamente as ondas-mãe ideais e os níveis de decomposição da wavelet. Por outro lado, os filtros híbridos com EMD são totalmente orientado aos dados, o que significa que decompõe um sinal de maneira natural sem exigir conhecimento prévio sobre o sinal de interesse. Portanto, as variações híbridas de EMD são geralmente preferidas e têm sido amplamente utilizadas para filtragem de EEG, como sugere [22,23,81,137].

A decomposição do modo empíricos (EEMD) combinada com o CCA em uma abordagem de canal único, conforme descrito por [137], foi usada para remover o artefato EMG no EEG. Este método também foi comparado aos métodos de filtragem wavelet, EMD e EEMD-ICA. Os resultados mostraram que a técnica híbrida EEMD-CCA é um filtro confiável e computacionalmente eficiente. No entanto, eles mostraram uma melhora relativa no SNR abaixo de 4 dB, o que contrasta com o nosso trabalho, que mostrou melhorias no SNR na ordem de 20 dB com os canais frontais do EEG. O mesmo acontece com o filtro de canal único híbrido descrito por [23] que avaliou a técnica EEMD-ICA, mas para valores ainda mais baixos de SNR, abaixo de 2 dB. Assim, embora tenha sido feito um esforço significativo para desenvolver métodos para detectar e remover artefatos em aplicações de EEG, essa ainda é uma área ativa de pesquisa.

Considerações adicionais devem ser feitas com relação aos métodos ICA e CCA usados nos filtros híbridos EMD, uma vez que elas podem não ser eficazes quando o número de canais não for igual ao número de fontes, conforme descrito por [9]. De acordo com [225], há divergências na literatura sobre a eficácia da ICA, especialmente em alta frequência, na remoção da atividade EMG dos dados, fato também relatado em [226,227]. Esse foi um dos fatores que motivou o uso do filtro adaptativo RLS neste trabalho para a remoção do artefato EMG da referência criada a partir da decomposição com o EMD.

A avaliação pelas métricas de desempenho utilizadas, juntamente com a inspeção visual dos sinais filtrados, confirmou a robustez do método EMDRLS. Estudos futuros devem considerar a adaptação do filtro EMDRLS para aplicações em tempo real e a atenuação de outros tipos de ruído, por exemplo, movimento. Também é necessário estender o banco de dados de sinais coletados para que o filtro possa ser avaliado sob várias outras condições experimentais.

# REFERÊNCIAS

1. Niedermeyer E, da Silva FHL. *Electroencephalography: basic principles, clinical applications, and related fields*. Baltimore: Williams & Williams; 2005.
2. Foxe JJ, Snyder AC. The role of alpha-band brain oscillations as a sensory suppression mechanism during selective attention. *Front Psychol*. 2011;2. doi:10.3389/fpsyg.2011.00154
3. Ramadan RA, Vasilakos A V. Brain computer interface: control signals review. *Neurocomputing*. 2017;223: 26–44. doi:10.1016/j.neucom.2016.10.024
4. Mihajlovic V, Grundlehner B, Vullers R, Penders J. Wearable, wireless EEG solutions in daily life applications: What are we missing? *IEEE J Biomed Heal Informatics*. 2015;19: 6–21. doi:10.1109/JBHI.2014.2328317
5. Abo-Zahhad M, Ahmed SM, Abbas SN. A New EEG Acquisition Protocol for Biometric Identification Using Eye Blinking Signals. *Int J Intell Syst Appl*. 2015;7: 48–54. doi:10.5815/ijisa.2015.06.05
6. Sanei S, Chambers JA. *EEG Signal Processing*. *Signal Processing*. 2007. doi:10.1109/MSP.2006.1657808
7. Silva GEG, Valen  a MOS. *Neurologia Cl  nica*. Recife: Editora Universit  ria da Universidade Federal De Pernambuco (UFPE); 2003.
8. Sweeney KT, Ward TE, McLoone SF. Artifact Removal in Physiological Signals - Practices and Possibilities. *IEEE Trans Inf Technol Biomed*. 2012;16: 488–500. doi:10.1109/TITB.2012.2188536
9. Urig  n JA, Garcia-Zapirain B. EEG artifact removal—state-of-the-art and guidelines. *J Neural Eng*. 2015;12: 031001. doi:10.1088/1741-2560/12/3/031001
10. Tatum WO, Dworetzky BA, Schomer DL. Artifact and recording concepts in EEG. *J Clin Neurophysiol*. 2011;28: 252–263. doi:10.1097/WNP.0b013e31821c3c93
11. Nunez PL, Srinivasan R. *Electric Fields of the Brain*. Nova York: Oxford University Press; 2006. doi:10.1093/acprof:oso/9780195050387.001.0001
12. Goncharova II, McFarland DJ, Vaughan TM, Wolpaw JR. EMG contamination of EEG: Spectral and topographical characteristics. *Clin Neurophysiol*. 2003;114: 1580–1593.

doi:10.1016/S1388-2457(03)00093-2

13. Safieddine D, Kachenoura A, Albera L, Birot G, Karfoul A, Pasnicu A, et al. Removal of muscle artifact from EEG data: Comparison between stochastic (ICA and CCA) and deterministic (EMD and wavelet-based) approaches. EURASIP J Adv Signal Process. 2012;2012. doi:10.1186/1687-6180-2012-127
14. Bono V, Das S, Jamal W, Maharatna K. Hybrid wavelet and EMD/ICA approach for artifact suppression in pervasive EEG. J Neurosci Methods. 2016;267: 89–107. doi:10.1016/j.jneumeth.2016.04.006
15. Frølich L, Dowding I. Removal of muscular artifacts in EEG signals: a comparison of linear decomposition methods. Brain Informatics. 2018. doi:10.1007/s40708-017-0074-6
16. Gabsteiger F, Leutheuser H, Reis P, Lochmann M, Eskofier BM. ICA-based reduction of electromyogenic artifacts in EEG data: Comparison with and without EMG data. 2014 36th Annu Int Conf IEEE Eng Med Biol Soc EMBC 2014. 2014; 3861–3864. doi:10.1109/EMBC.2014.6944466
17. Upadhyay R, Padhy PK, Kankar PK. EEG artifact removal and noise suppression by Discrete Orthonormal S-Transform denoising. Comput Electr Eng. 2016;53: 125–142. doi:10.1016/j.compeleceng.2016.05.015
18. Yong X, Ward RK, Birch GE. Facial EMG contamination of EEG signals: Characteristics and effects of spatial filtering. 2008 3rd Int Symp Commun Control Signal Process ISCCSP 2008. 2008; 729–734. doi:10.1109/ISCCSP.2008.4537319
19. Queiroz CMQ, Luiz LMD, Miranda M, Lima GFM, Andrade AO. Proposta de uma Interface Gráfica para Aprendizagem. Annals of 8th Biomedical Engineering Symposium. Uberlândia; 2015. pp. 310–315.
20. Queiroz CMM, Nasuto SJ, Andrade AO. Development and Evaluation of Human-Computer Interface Based on Facial Motor Unit Activity. 7th Int Jt Conf Biomed Eng Syst Technol. 2014; 47–53.
21. Chen X, Liu A, Chiang J, Wang ZJ, McKeown MJ, Ward RK. Removing Muscle Artifacts from EEG Data: Multichannel or Single-Channel Techniques? IEEE Sens J. 2016;16: 1986–1997. doi:10.1109/JSEN.2015.2506982
22. Mucarquer JA, Prado P, Escobar M-J, El-Deredy W, Zanartu M. Improving EEG Muscle Artifact Removal With an EMG Array. IEEE Trans Instrum Meas. 2020;69: 815–824. doi:10.1109/TIM.2019.2906967
23. Zeng K, Chen D, Ouyang G, Wang L, Liu X, Li X. An EEMD-ICA Approach to Enhancing Artifact Rejection for Noisy Multivariate Neural Data. IEEE Trans Neural Syst Rehabil Eng. 2016;24: 630–638. doi:10.1109/TNSRE.2015.2496334
24. Gerardo J, C. J, Velazquez J. Applications of Adaptive Filtering. Adaptive Filtering Applications. InTech; 2011. pp. 1–20. doi:10.5772/16873
25. Bellanger MG. Fast Least Squares Transversal Adaptive Filters. Adaptive Digital Filters. New York: Marcel Dekker; 2001.
26. Diniz PSR. Adaptive Filtering. Boston, MA: Springer US; 2008. doi:10.1007/978-0-387-68606-6

27. Andrade AOAO, Pereira AAA, Jr CGPCGP, Kyberd PJPJ. Mouse emulation based on facial electromyogram. *Biomed Signal Process Control.* 2013;8: 142–152. doi:10.1016/j.bspc.2012.09.001
28. Berger H. Über das Elektrenkephalogramm des Menschen. *Dtsch Medizinische Wochenschrift.* 1934;60: 1947–1949. doi:10.1055/s-0028-1130334
29. Adrian ED, Matthews BHC. The interpretation of potential waves in the cortex. *J Physiol.* 1934;81: 440–471. doi:10.1113/jphysiol.1934.sp003147
30. da Silva FL. EEG: Origin and Measurement. *EEG - fMRI.* Berlin, Heidelberg: Springer Berlin Heidelberg; 2009. pp. 19–38. doi:10.1007/978-3-540-87919-0\_2
31. Hall JE, Guyton AC. *Tratado de Fisiologia Médica.* Rio de Janeiro: Elsevier; 2011. doi:10.1017/CBO9781107415324.004
32. Buzsaki G, Traub R., Pedley T. The cellular basis of EEG activity. 3rd ed. In: Speckmann E., Casper H, editors. *Current Practice of Clinical Electroencephalography.* 3rd ed. Philadelphia: Thieme Medical Publishers, Inc.; 2003. pp. 1–11.
33. Eccles JC. *The Physiology of Synapses.* Berlim: Springer; 1964.
34. Speckmann E-J, Elger CE, Gorji A. *Neurophysiologic Basis of EEG and DC Potentials.* 5th ed. In: Niedermeyer E, Lopez Da Silva F, editors. *Electroencephalography Basic Principles, Clinical Applications, and Related Fields.* 5th ed. Philadelphia: Lippincott Williams and Wilkins; 206AD.
35. Lent R. *Cem Bilhões de Neurônios.* 2<sup>a</sup>. Atheneu; 2010.
36. Bucci P, Mucci A, Galderisi S. Normal EEG Patterns and Waveforms. *Standard Electroencephalography in Clinical Psychiatry: A Practical Handbook.* 2011. pp. 33–57. doi:10.1002/9780470974612.ch4
37. Amo Usanos C, Boquete L, de Santiago L, Barea Navarro R, Cavaliere C. Induced Gamma-Band Activity during Actual and Imaginary Movements: EEG Analysis. *Sensors.* 2020;20: 1545. doi:10.3390/s20061545
38. Tallon-Baudry C. BO. Oscillatory gamma activity in humans and its role in object representation. *Trends Cogn Sci.* 1999;3: 151–162.
39. Crone NE, Sinai A, Korzeniewska A. High-frequency gamma oscillations and human brain mapping with electrocorticography. 2006. pp. 275–295. doi:10.1016/S0079-6123(06)59019-3
40. Uhlhaas PJ, Pipa G, Neuenschwander S, Wibral M, Singer W. A new look at gamma? High- (>60 Hz)  $\gamma$ -band activity in cortical networks: Function, mechanisms and impairment. *Prog Biophys Mol Biol.* 2011;105: 14–28. doi:10.1016/j.pbiomolbio.2010.10.004
41. Jia X, Kohn A. Gamma Rhythms in the Brain. *PLoS Biol.* 2011;9: e1001045. doi:10.1371/journal.pbio.1001045
42. Ebersole JS, Pedley TA. *Current Practice of Clinical Electroencephalography.* New York: Lippincott Williams & Wilkins; 2003.
43. Bazanova O., Vernon D. Interpreting EEG alpha activity. *Neurosci Biobehav Rev.*

2014;44: 94–110. doi:10.1016/j.neubiorev.2013.05.007

44. Barry RJ, Clarke AR, Johnstone SJ, Magee CA, Rushby JA. EEG Differences Between Eyes-Closed and Eyes-Closed Resting Conditions. *Int J Psychophysiol.* 2007;118: 2765–2773. doi:<https://doi.org/10.1016/j.clinph.2007.07.028>
45. Toscani M, Marzi T, Righi S, Viggiano MP, Baldassi S. Alpha waves: A neural signature of visual suppression. *Exp Brain Res.* 2010;207: 213–219. doi:10.1007/s00221-010-2444-7
46. Gola M, Magnuski M, Szumska I, Wróbel A. EEG beta band activity is related to attention and attentional deficits in the visual performance of elderly subjects. *Int J Psychophysiol.* 2013;89: 334–341. doi:10.1016/j.ijpsycho.2013.05.007
47. Pivik RT, Broughton RJ, Coppola R, Davidson RJ, Fox N, Nuwer MR. Guidelines for the recording and quantitative analysis of electroencephalographic activity in research contexts. *Psychophysiology.* 1993;30: 547–558. doi:10.1111/j.1469-8986.1993.tb02081.x
48. Webster JG. Encyclopedia of Medical Devices and Instrumentation. New Jersey: John Wiley & Sons; 2006. doi:10.1002/0471732877
49. Ferree TC, Luu P, Russell GS, Tucker DM. Scalp electrode impedance, infection risk, and EEG data quality. *Clin Neurophysiol.* 2001;112: 536–544. doi:10.1016/S1388-2457(00)00533-2
50. Report of the committee on methods of clinical examination in electroencephalography. *Electroencephalogr Clin Neurophysiol.* 1958. doi:10.1016/0013-4694(58)90053-1
51. Jasper HH. The 10-20 electrode system of the International Federation. *Electroencephalogr Clin Neurophysiol.* 1958;10: 371–375.
52. Jurcak V, Tsuzuki D, Dan I. 10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems. *Neuroimage.* 2007;34: 1600–1611. doi:10.1016/j.neuroimage.2006.09.024
53. Smith EJ. Introduction to EEG. In: EBME & Clinical Engineering Articles [Internet]. [cited 2 May 2018]. Available: <https://www.ebme.co.uk/articles/clinical-engineering/56-introduction-to-eeg>
54. Chaves MLF, Finkelsztein A, Stefani MA. Eletroencefalografia. Rotinas em neurologia e neurocirurgia. Artmed Editora; 2008.
55. ACNS. Guideline One; Minimum Technical Requirements for performing clinical EEG. *J Clin Neurophysiol.* 1994;11: 2–5.
56. Effects of electrode placement. [cited 4 Apr 2018]. Available: <http://www.focused-technology.com/electrod.htm>
57. Collura TF. A guide to Electrode Selection, Location, and Application for EEG Biofeedback. 1998.
58. Teplan M. Fundamentals of EEG measurement. *Meas Sci Rev.* 2002;2: 1–11. doi:10.1021/pr0703501
59. Northrop RB. Non-invasive Instrumentation and Measurement in Medical Diagnosis. Neuman MR, editor. Boca Raton: CRC Press; 2001.

60. Malvino AP. Eletrônica. 4ª. São Paulo: Makron Books; 1995.
61. Northrop RB. Analysis and Application of Analog Electronic Circuits to Biomedical Instrumentation. Boca Raton: CRC Press; 2004.
62. Khandpur RS. Handbook of Biomedical Instrumentation. 2ª. Nova Delhi: McGraw-Hill; 2003.
63. II Couch LW. Digital and Analog Communication Systems. Upper Saddle River: Prentice Hall; 2000.
64. Lessard CS. Signal Processing of Random Physiological Signals. College Station: Morgan & Claypool; 2006.
65. Lathi BP. Sistemas de comunicações analógicos e digitais modernos. 4ª. Rio de Janeiro: LTC; 2012.
66. Savelainen A, Ehtamo H, Särkelä M. Movement Artifact Detection from Electroencephalogram Utilizing Accelerometer. Aalto University. 2011.
67. Sweeney K. Motion Artifact Processing Techniques for Physiological Signals. 2013.
68. Schachter SC, Schomer DL. Atlas of Ambulatory EEG. 2005.
69. Akay M. Biomedical signal processing. London: Academic Press; 1994.
70. Correa AG, Laciari E., Patiño HD., Valentinuzzi ME. Artifact removal from EEG signals using adaptive filters in cascade. *J Phys Conf Ser.* 2007; 10. doi:10.1088/1742-6596/90/1/012081
71. Ferdous MJ, Ali S. A Comparison of Wiener and Kalman Filters for the Artifact Suppression from EEG Signal. *Int J Sci Res.* 2017;6: 2029–2035. doi:10.21275/ART20172896
72. Maki H, Toda T, Sakti S, Neubig G, Nakamura S. EEG signal enhancement using multi-channel wiener filter with a spatial correlation prior. *2015 IEEE Int Conf Acoust Speech Signal Process.* 2015; 2639–2643. doi:10.1109/ICASSP.2015.7178449
73. Morbidi F, Garulli A, Prattichizzo D, Rizzo C, Rossi S. Application of Kalman filter to remove TMS-induced artifacts from EEG recordings. *IEEE Trans Control Syst Technol.* 2008;16: 1360–1366. doi:10.1109/TCST.2008.921814
74. James C, Hesse C. Independent component analysis for biomedical signals. *Physiol Meas.* 2005;26: R15. doi:doi: 10.1088/0967-3334/26/1/r02
75. Albera L, Kachenoura A, Comon P, Karfoul A, Wendling F, Senhadji L, et al. ICA-based EEG denoising: A comparative analysis of fifteen methods. *Bull Polish Acad Sci Tech Sci.* 2012;60: 407–418. doi:10.2478/v10175-012-0052-3
76. Turnip A, Pardede J. Artefacts Removal of EEG Signals with Wavelet Denoising. *2017;00058:* 1–10. doi:10.1051/matecconf/201713500058
77. Ngoc PP, Hai VD, Bach NC, Binh P Van. EEG Signal Analysis and Artifact Removal by Wavelet Transform. 2015; 179–183. Available: [http://link.springer.com/chapter/10.1007/978-3-319-11776-8\\_44](http://link.springer.com/chapter/10.1007/978-3-319-11776-8_44)

78. Alam ME, Samanta B. Performance Evaluation of Empirical Mode Decomposition for EEG Artifact Removal. Volume 4B: Dynamics, Vibration, and Control. ASME; 2017. p. V04BT05A024. doi:10.1115/IMECE2017-71647
79. Huang NE, Shen Z, Long SR, Wu MC, Shih HH, Zheng W, et al. The empirical mode decomposition method and the Hilbert spectrum for non-stationary time series analysis. 1998.
80. Zeng K, Chen D, Ouyang G, Wang L, Liu X, Li X. An EEMD-ICA Approach to Enhancing Artifact Rejection for Noisy Multivariate Neural Data. *IEEE Trans Neural Syst Rehabil Eng.* 2016;24: 630–638. doi:10.1109/TNSRE.2015.2496334
81. Chen X, He C, Peng H. Removal of muscle artifacts from single-channel EEG based on ensemble empirical mode decomposition and multiset canonical correlation analysis. *J Appl Math.* 2014;2014. doi:10.1155/2014/261347
82. Salsabili S, Sardoui SH, Shamsollahi MB. Interictal EEG Denoising using Independent Component Analysis and Empirical Mode Decomposition. 2015; 0–5.
83. Daly I, Scherer R, Billinger M, Muller-Putz G. FORCe: Fully Online and Automated Artifact Removal for Brain-Computer Interfacing. *IEEE Trans Neural Syst Rehabil Eng.* 2015;23: 725–736. doi:10.1109/TNSRE.2014.2346621
84. J. Gerardo Avalos JCS and JV. Applications of Adaptive Filtering. *Adaptive Filtering Applications.* 2011. pp. 1–20. Available: <http://www.intechopen.com/books/adaptive-filtering-applications/applications-of-adaptive-filtering%5Cnwww.intechopen.com>
85. Croft RJ, Barry RJ. Removal of ocular artifact from the EEG: a review. *Neurophysiol Clin Neurophysiol.* 2000;30: 5–19. doi:10.1016/S0987-7053(00)00055-1
86. Kher R, Gandhi R. Adaptive filtering based artifact removal from electroencephalogram (EEG) signals. 2016 International Conference on Communication and Signal Processing (ICCP). IEEE; 2016. pp. 0561–0564. doi:10.1109/ICCP.2016.7754202
87. Mehrkanoon S, Moghavvemi M, Fariborzi H. Real time ocular and facial muscle artifacts removal from EEG signals using LMS adaptive algorithm. 2007 International Conference on Intelligent and Advanced Systems. IEEE; 2007. pp. 1245–1250. doi:10.1109/ICIAS.2007.4658583
88. Romero S, Mañanas MA, Barbanoj MJ. Ocular Reduction in EEG Signals Based on Adaptive Filtering, Regression and Blind Source Separation. *Ann Biomed Eng.* 2009;37: 176–191. doi:10.1007/s10439-008-9589-6
89. Vaseghi S V. Advanced Digital Signal Processing and Noise Reduction. Chichester, UK: John Wiley & Sons, Ltd; 2001. doi:10.1002/0470841621
90. Kim M, Kim S-P. A comparsion of artifact rejection methods for a BCI using event related potentials. 2018 6th International Conference on Brain-Computer Interface (BCI). IEEE; 2018. pp. 1–4. doi:10.1109/TWW-BCI.2018.8311530
91. Blair RC, Taylor RA. Bioestatística para ciências da saúde. São Paulo: Person; 2013.
92. Borowicz A. Correction of eye-blink artifacts in EEG recordings using Wiener filtering. *Signal Process - Algorithms, Archit Arrange Appl Conf Proceedings, SPA.* 2017;2017-Septe. doi:10.23919/SPA.2017.8166859

93. Kay SM. Fundamentals of statistical signal processing: estimation theory. Upper Saddle River: Prentice Hall; 1993.
94. Aznan NKN, Yang Y-M. Applying Kalman filter in EEG-Based Brain Computer Interface for Motor Imagery classification. 2013 International Conference on ICT Convergence (ICTC). IEEE; 2013. pp. 688–690. doi:10.1109/ICTC.2013.6675451
95. Barton M, Robinson P, Kumar S, Galka A, Durrant-Whyte H, Guivant J, et al. Evaluating the Performance of Kalman-Filter-Based {EEG} Source Localization. *IEEE Trans Biomed Eng.* 2009;56: 122–136.
96. Roháľová M, Sykacek P, Koska M, Dorffner G. Detection of the EEG Artifacts by the Means of the (Extended) Kalman Filter. *Meas Sci Rev.* 2001;1: 59–62.
97. Shahabi H, Moghimi S, Zamiri-Jafarian H. EEG eye blink artifact removal by EOG modeling and Kalman filter. 2012 5th International Conference on BioMedical Engineering and Informatics. IEEE; 2012. pp. 496–500. doi:10.1109/BMEI.2012.6513162
98. Nise NS. Engenharia de Sistemas de Controle. 5<sup>a</sup>. LTC; 2009.
99. Comon P, Jutten C. Handbook of Blind Source Separation: Independent Component Analysis and Applications. Elsevier; 2010.
100. Deville Y, Deville A. Quantum-Source Independent Component Analysis and Related Statistical Blind Qubit Uncoupling Methods. In: Naik GR, Wang W, editors. *Blind Source Separation*. Berlin, Heidelberg: Springer Berlin Heidelberg; 2014. doi:10.1007/978-3-642-55016-4
101. Choi S, Cichocki A, Park HM, Lee SY. Blind source separation and independent component analysis: A review. *Neural Inf Process Rev.* 2005;6: 1–57. doi:10.1016/j.neucom.2005.12.018
102. Jolliffe IT. Principal Component Analysis. Springer; 2002.
103. Berg P, Scherg M. Dipole models of eye movements and blinks. *Electroencephalogr Clin Neurophysiol.* 1991;79: 36–44. doi:10.1016/0013-4694(91)90154-V
104. Ille N, Berg P, Scherg M. Artifact Correction of the Ongoing EEG Using Spatial Filters Based on Artifact and Brain Signal Topographies. *J Clin Neurophysiol.* 2002;19: 113–124. doi:10.1097/00004691-200203000-00002
105. Fitzgibbon SP, Powers DMW, Pope KJ, Clark CR. Removal of EEG Noise and Artifact Using Blind Source Separation. *J Clin Neurophysiol.* 2007;24: 232–243. doi:10.1097/WNP.0b013e3180556926
106. Lagerlund TD, Sharbrough FW, Busacker NE. Spatial Filtering of Multichannel Electroencephalographic Recordings Through Principal Component Analysis by Singular Value Decomposition. *J Clin Neurophysiol.* 1997;14: 73–82. doi:10.1097/00004691-199701000-00007
107. Shi LC, Duan RN, Lu BL. A robust principal component analysis algorithm for EEG-based vigilance estimation. *Proc Annu Int Conf IEEE Eng Med Biol Soc EMBS.* 2013; 6623–6626. doi:10.1109/EMBC.2013.6611074
108. Teixeira AR, Tomé AM, Lang EW. Greedy {KPCA} in Biomedical Signal Processing.

109. Wallstrom GL, Kass RE, Miller A, Cohn JF, Fox NA. Automatic correction of ocular artifacts in the EEG: A comparison of regression-based and component-based methods. *Int J Psychophysiol*. 2004;53: 105–119. doi:10.1016/j.ijpsycho.2004.03.007
110. Jung TP, Makeig S, Humphries C, Lee TW, McKeown MJ, Iragui V, et al. Removing electroencephalographic artifacts by blind source separation. *Psychophysiology*. 2000;37: 163–178. doi:10.1017/S0048577200980259
111. Comon P. Independent component analysis, A new concept? *Signal Processing*. 1994;36: 287–314. doi:10.1016/0165-1684(94)90029-9
112. Flexer A, Bauer H, Pripfl J, Dorffner G. Using ICA for removal of ocular artifacts in EEG recorded from blind subjects. *Neural Networks*. 2005;18: 998–1005. doi:10.1016/j.neunet.2005.03.012
113. Sánchez A VD. Frontiers of research in BSS/ICA. *Neurocomputing*. 2002;49: 7–23. doi:10.1016/S0925-2312(02)00533-7
114. Lee T-W. *Independent Component Analysis*. Boston, MA: Springer US; 1998. doi:10.1007/978-1-4757-2851-4
115. Hyvritinen A, Karhunen J, Oja E. *Independent Component Analysis*. John Wiley & Sons; 2001.
116. Caiafa CF, Salerno E, Proto AN, Fiumi L. Blind spectral unmixing by local maximization of non-Gaussianity. *Signal Processing*. 2008;88: 50–68. doi:10.1016/j.sigpro.2007.07.011
117. Bingham E, Yväriinen A. A Fast Fixed-Point Algorithm for Independent Component Analysis of Complex Valued Signals. *Int J Neural Syst*. 2000;10: 1–8. doi:10.1142/S0129065700000028
118. Bell AJ, Sejnowski TJ. An Information-Maximization Approach to Blind Separation and Blind Deconvolution. *Neural Comput*. 1995;7: 1129–1159. doi:10.1162/neco.1995.7.6.1129
119. Lee T-W, Girolami M, Sejnowski TJ. Independent Component Analysis Using an Extended Infomax Algorithm for Mixed Subgaussian and Supergaussian Sources. *Neural Comput*. 1999;11: 417–441. doi:10.1162/089976699300016719
120. Draper BA, Baek K, Bartlett MS, Beveridge JR. Recognizing faces with PCA and ICA. *Comput Vis Image Underst*. 2003;91: 115–137. doi:10.1016/S1077-3142(03)00077-8
121. Rutledge DN, Jouan-Rimbaud Bouveresse D. Independent Components Analysis with the JADE algorithm. *TrAC Trends Anal Chem*. 2013;50: 22–32. doi:10.1016/j.trac.2013.03.013
122. Theil H, Chung C-F. Relations between two sets of variates: The bits of information provided by each variate in each set. *Stat Probab Lett*. 1988;6: 137–139. doi:10.1016/0167-7152(88)90107-1
123. Borga M, Knutsson H. A Canonical Correlation Approach to Blind Source Separation. 2001.
124. Liu W, Mandic DP, Cichocki A. Analysis and online realization of the CCA approach for

- blind source separation. *IEEE Trans Neural Networks.* 2007;18: 1505–1510. doi:10.1109/tnn.2007.894017
125. Wim De Clercq, Vergult A, Vanrumste B, Van Paesschen W, Van Huffel S. Canonical Correlation Analysis Applied to Remove Muscle Artifacts From the Electroencephalogram. *IEEE Trans Biomed Eng.* 2006;53: 2583–2587. doi:10.1109/TBME.2006.879459
  126. Gao J, Zheng C, Wang P. Online Removal of Muscle Artifact from Electroencephalogram Signals Based on Canonical Correlation Analysis. *Clin EEG Neurosci.* 2010;41: 53–59. doi:10.1177/155005941004100111
  127. Strang G. Wavelet transforms versus fourier transforms. *Bull Am Math Soc.* 1993;28: 288–305. doi:10.1090/S0273-0979-1993-00390-2
  128. Lathi BP. Linear Systems and Signals. Oxford University Press; 2004.
  129. Lima PC de. Wavelets: uma introdução. Matemática Univ. 2002.
  130. Krishnaveni V, Jayaraman S, Anitha L, Ramadoss K. Removal of ocular artifacts from EEG using adaptive thresholding of wavelet coefficients. *J Neural Eng.* 2006;3: 338–346. doi:10.1088/1741-2560/3/4/011
  131. Castellanos NP, Makarov VA. Recovering EEG brain signals: Artifact suppression with wavelet enhanced independent component analysis. *J Neurosci Methods.* 2006;158: 300–312. doi:10.1016/j.jneumeth.2006.05.033
  132. Gao J, Sultan H, Jing Hu, Wen-Wen Tung. Denoising Nonlinear Time Series by Adaptive Filtering and Wavelet Shrinkage: A Comparison. *IEEE Signal Process Lett.* 2010;17: 237–240. doi:10.1109/LSP.2009.2037773
  133. Iyer D, Zouridakis G. Single-trial evoked potential estimation: Comparison between independent component analysis and wavelet denoising. *Clin Neurophysiol.* 2007;118: 495–504. doi:10.1016/j.clinph.2006.10.024
  134. Akhtar MT, Mitsuhashi W, James CJ. Employing spatially constrained ICA and wavelet denoising, for automatic removal of artifacts from multichannel EEG data. *Signal Processing.* 2012;92: 401–416. doi:10.1016/j.sigpro.2011.08.005
  135. Motamedi-Fakhr S, Moshrefi-Torbat M, Hill M, Hill CM, White PR. Signal processing techniques applied to human sleep EEG signals—A review. *Biomed Signal Process Control.* 2014;10: 21–33. doi:10.1016/j.bspc.2013.12.003
  136. Rashed-Al-Mahfuz M, Islam MR, Hirose K, Molla MKI. Artifact suppression and analysis of brain activities with electroencephalography signals. *Neural Regen Res.* 2013;8: 1500–13. doi:10.3969/j.issn.1673-5374.2013.16.007
  137. Sweeney KT, McLoone SF, Ward TE. The Use of Ensemble Empirical Mode Decomposition With Canonical Correlation Analysis as a Novel Artifact Removal Technique. *IEEE Trans Biomed Eng.* 2013;60: 97–105. doi:10.1109/TBME.2012.2225427
  138. Iatsenko D, McClintock PVE, Stefanovska A. Nonlinear mode decomposition: A noise-robust, adaptive decomposition method. *Phys Rev E.* 2015;92: 032916. doi:10.1103/PhysRevE.92.032916

139. Wu Z, Huang NE. Ensemble Empirical Mode Decomposition: a Noise-Assisted Data Analysis Method. *Adv Adapt Data Anal.* 2009;01: 1–41. doi:10.1142/S1793536909000047
140. Molla MKI, Tanaka T, Rutkowski TM, Cichocki A. Separation of EOG artifacts from EEG signals using bivariate EMD. 2010 IEEE International Conference on Acoustics, Speech and Signal Processing. IEEE; 2010. pp. 562–565. doi:10.1109/ICASSP.2010.5495594
141. Zhang C, Yang J, Lei Y, Ye F. Single channel blind source separation by combining slope ensemble empirical mode decomposition and independent component analysis. *Journal of Computational Information Systems.* 2012.
142. Mannan MMN, Jeong MY, Kamran MA. Hybrid ICA—Regression: Automatic Identification and Removal of Ocular Artifacts from Electroencephalographic Signals. *Front Hum Neurosci.* 2016;10. doi:10.3389/fnhum.2016.00193
143. Klados MA, Papadelis C, Braun C, Bamidis PD. REG-ICA: A hybrid methodology combining Blind Source Separation and regression techniques for the rejection of ocular artifacts. *Biomed Signal Process Control.* 2011;6: 291–300. doi:10.1016/j.bspc.2011.02.001
144. Guerrero-Mosquera C, Navia-Vázquez A. Automatic removal of ocular artefacts using adaptive filtering and independent component analysis for electroencephalogram data. *IET Signal Process.* 2012;6: 99. doi:10.1049/iet-spr.2010.0135
145. Linsen JP, Bhattacharya J. Correction of blink artifacts using independent component analysis and empirical mode decomposition. *Psychophysiology.* 2010. doi:10.1111/j.1469-8986.2010.00995.x
146. Raghavendra BS, Dutt D. Wavelet enhanced CCA for minimization of ocular and muscle artifacts in EEG. World Academy of Science, Engineering and Technology. 2011.
147. Mahajan R, Morshed BI. Unsupervised Eye Blink Artifact Denoising of EEG Data with Modified Multiscale Sample Entropy, Kurtosis, and Wavelet-ICA. *IEEE J Biomed Heal Informatics.* 2015;19: 158–165. doi:10.1109/JBHI.2014.2333010
148. Navarro X, Porée F, Beuchée A, Carrault G. Denoising preterm EEG by signal decomposition and adaptive filtering: A comparative study. *Med Eng Phys.* 2015;37: 315–320. doi:10.1016/j.medengphy.2015.01.006
149. Sweeney KT, Leamy DJ, Ward TE, McLoone S. Intelligent artifact classification for ambulatory physiological signals. 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology. IEEE; 2010. pp. 6349–6352. doi:10.1109/IEMBS.2010.5627285
150. Waterhouse E. New horizons in ambulatory electroencephalography. *IEEE Eng Med Biol Mag.* 2003;22: 74–80. doi:10.1109/MEMB.2003.1213629
151. Devuyst S, Dutoit T, Stenuit P, Kerkhofs M, Stanus E. Removal of ECG artifacts from EEG using a modified independent component analysis approach. 2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE; 2008. pp. 5204–5207. doi:10.1109/IEMBS.2008.4650387
152. Crespo-García M, Atienza M, Cantero JL. Muscle Artifact Removal from Human Sleep EEG by Using Independent Component Analysis. *Ann Biomed Eng.* 2008;36: 467–475.

doi:10.1007/s10439-008-9442-y

153. Mammone N, Morabito FC. Enhanced automatic artifact detection based on independent component analysis and Renyi's entropy. *Neural Networks*. 2008;21: 1029–1040. doi:10.1016/j.neunet.2007.09.020
154. Viola FC, Thorne J, Edmonds B, Schneider T, Eichele T, Debener S. Semi-automatic identification of independent components representing EEG artifact. *Clin Neurophysiol*. 2009;120: 868–877. doi:10.1016/j.clinph.2009.01.015
155. Zhou W, Gotman J. Automatic removal of eye movement artifacts from the EEG using ICA and the dipole model. *Prog Nat Sci*. 2009;19: 1165–1170. doi:10.1016/j.pnsc.2008.11.013
156. Vos DM, Riès S, Vanderperren K, Vanrumste B, Alario F-X, Huffel VS, et al. Removal of Muscle Artifacts from EEG Recordings of Spoken Language Production. *Neuroinformatics*. 2010;8: 135–150. doi:10.1007/s12021-010-9071-0
157. Gao J, Lin P, Yang Y, Wang P, Zheng C. Real-time removal of ocular artifacts from EEG based on independent component analysis and manifold learning. *Neural Comput Appl*. 2010;19: 1217–1226. doi:10.1007/s00521-010-0370-z
158. Gao J, Yang Y, Sun J, Yu G. Automatic Removal of Various Artifacts From EEG Signals Using Combined Methods. *J Clin Neurophysiol*. 2010;27: 312–320. doi:10.1097/WNP.0b013e3181f534f4
159. Gao JF, Yang Y, Lin P, Wang P, Zheng CX. Automatic Removal of Eye-Movement and Blink Artifacts from EEG Signals. *Brain Topogr*. 2010;23: 105–114. doi:10.1007/s10548-009-0131-4
160. Chan H-L, Tsai Y-T, Meng L-F, Wu T. The Removal of Ocular Artifacts from EEG Signals Using Adaptive Filters Based on Ocular Source Components. *Ann Biomed Eng*. 2010;38: 3489–3499. doi:10.1007/s10439-010-0087-2
161. Mognon A, Jovicich J, Bruzzone L, Buiatti M. ADJUST: An automatic EEG artifact detector based on the joint use of spatial and temporal features. *Psychophysiology*. 2011;48: 229–240. doi:10.1111/j.1469-8986.2010.01061.x
162. Winkler I, Haufe S, Tangermann M. Automatic Classification of Artifactual ICA-Components for Artifact Removal in EEG Signals. *Behav Brain Funct*. 2011;7: 30. doi:10.1186/1744-9081-7-30
163. Plöchl M, Ossandón JP, König P. Combining EEG and eye tracking: identification, characterization, and correction of eye movement artifacts in electroencephalographic data. *Front Hum Neurosci*. 2012;6. doi:10.3389/fnhum.2012.00278
164. Zhang L, Wang Y, He C. Online removal of eye blink artifact from scalp EEG using canonical correlation analysis based method. *J Mech Med Biol*. 2012;12: 1250091. doi:10.1142/S0219519412500911
165. Yong X, Fatourechi M, Ward RK, Birch GE. Automatic artefact removal in a self-paced hybrid brain- computer interface system. *J Neuroeng Rehabil*. 2012;9: 50. doi:10.1186/1743-0003-9-50
166. Molla MKI, Rabiul Islam M, Tanaka T, Rutkowski TM. Artifact suppression from EEG signals using data adaptive time domain filtering. *Neurocomputing*. 2012;97: 297–308.

doi:10.1016/j.neucom.2012.05.009

167. Romo Vázquez R, Vélez-Pérez H, Ranta R, Louis Dorr V, Maquin D, Maillard L. Blind source separation, wavelet denoising and discriminant analysis for EEG artefacts and noise cancelling. *Biomed Signal Process Control.* 2012;7: 389–400. doi:10.1016/j.bspc.2011.06.005
168. Mammone N, La Foresta F, Morabito FC. Automatic Artifact Rejection From Multichannel Scalp EEG by Wavelet ICA. *IEEE Sens J.* 2012;12: 533–542. doi:10.1109/JSEN.2011.2115236
169. Li M, Cui Y, Yang J. Automatic Removal of Ocular Artifact from EEG with DWT and ICA Method. *Appl Math Inf Sci.* 2013;7: 809–816. doi:10.12785/amis/070252
170. Kong W, Zhou Z, Hu S, Zhang J, Babiloni F, Dai G. Automatic and Direct Identification of Blink Components from Scalp EEG. *Sensors.* 2013;13: 10783–10801. doi:10.3390/s130810783
171. Peng H, Hu B, Shi Q, Ratcliffe M, Zhao Q, Qi Y, et al. Removal of Ocular Artifacts in EEG—An Improved Approach Combining DWT and ANC for Portable Applications. *IEEE J Biomed Heal Informatics.* 2013;17: 600–607. doi:10.1109/JBHI.2013.2253614
172. Chen X, Liu A, Peng H, Ward R. A Preliminary Study of Muscular Artifact Cancellation in Single-Channel EEG. *Sensors.* 2014;14: 18370–18389. doi:10.3390/s141018370
173. Winkler I, Brandl S, Horn F, Waldburger E, Allefeld C, Tangermann M. Robust artifactual independent component classification for BCI practitioners. *J Neural Eng.* 2014;11: 035013. doi:10.1088/1741-2560/11/3/035013
174. Murthy Keshava GN, Khan ZA. Correction of ocular artifacts in EEG signal using empirical mode decomposition and cross-correlation. *Res J Biotechnol.* 2014;9.
175. Wang Z, Xu P, Liu T, Tian Y, Lei X, Yao D. Robust removal of ocular artifacts by combining Independent Component Analysis and system identification. *Biomed Signal Process Control.* 2014;10: 250–259. doi:10.1016/j.bspc.2013.10.006
176. Zhao Q, Bin Hu, Yujun Shi, Yang Li, Moore P, Minghou Sun, et al. Automatic Identification and Removal of Ocular Artifacts in EEG—Improved Adaptive Predictor Filtering for Portable Applications. *IEEE Trans Nanobioscience.* 2014;13: 109–117. doi:10.1109/TNB.2014.2316811
177. Hamaneh MB, Chitravas N, Kaiboriboon K, Lhatoo SD, Loparo KA. Automated Removal of EKG Artifact From EEG Data Using Independent Component Analysis and Continuous Wavelet Transformation. *IEEE Trans Biomed Eng.* 2014;61: 1634–1641. doi:10.1109/TBME.2013.2295173
178. Mammone N, Morabito F. Enhanced Automatic Wavelet Independent Component Analysis for Electroencephalographic Artifact Removal. *Entropy.* 2014;16: 6553–6572. doi:10.3390/e16126553
179. Cassani R, Falk TH, Fraga FJ, Kanda PAM, Anghinah R. The effects of automated artifact removal algorithms on electroencephalography-based Alzheimer’s disease diagnosis. *Front Aging Neurosci.* 2014;6. doi:10.3389/fnagi.2014.00055
180. Frølich L, Andersen TS, Mørup M. Classification of independent components of EEG into multiple artifact classes. *Psychophysiology.* 2015;52: 32–45. doi:10.1111/psyp.12290

181. Chaumon M, Bishop DVM, Busch NA. A practical guide to the selection of independent components of the electroencephalogram for artifact correction. *J Neurosci Methods*. 2015;250: 47–63. doi:10.1016/j.jneumeth.2015.02.025
182. Mingai L, Shuoda G, Guoyu Z, Yanjun S, Jinfu Y. Removing ocular artifacts from mixed EEG signals with FastKICA and DWT. *J Intell Fuzzy Syst.* 2015;28: 2851–2861. doi:10.3233/JIFS-151564
183. Gao C, Ma L, Li H. An ICA/HHT Hybrid Approach for Automatic Ocular Artifact Correction. *Int J Pattern Recognit Artif Intell.* 2015;29: 1558001. doi:10.1142/S021800141558001X
184. Yang B, He LL, Wang L. Fast removal of ocular artifacts from electroencephalogram signals using spatial constraint independent component analysis based recursive least squares in brain-computer interface. *Front Inf Technol Electron Eng.* 2015;16: 486–496. doi:10.1631/FITEE.1400299
185. Mowla MR, Ng S-C, Zilany MSA, Paramesran R. Artifacts-matched blind source separation and wavelet transform for multichannel EEG denoising. *Biomed Signal Process Control.* 2015;22: 111–118. doi:10.1016/j.bspc.2015.06.009
186. Labate D, La Foresta F, Mammone N, Morabito FC. Effects of artifacts rejection on EEG complexity in Alzheimer's disease. *Smart Innov Syst Technol.* 2015;37: 129–136. doi:10.1007/978-3-319-18164-6\_13
187. Zou Y, Nathan V, Jafari R. Automatic Identification of Artifact-Related Independent Components for Artifact Removal in EEG Recordings. *IEEE J Biomed Heal Informatics.* 2016;20: 73–81. doi:10.1109/JBHI.2014.2370646
188. Fitzgibbon SP, DeLosAngeles D, Lewis TW, Powers DMW, Grummets TS, Whitham EM, et al. Automatic determination of EMG-contaminated components and validation of independent component analysis using EEG during pharmacologic paralysis. *Clin Neurophysiol.* 2016;127: 1781–1793. doi:10.1016/j.clinph.2015.12.009
189. Somers B, Bertrand A. Removal of eye blink artifacts in wireless EEG sensor networks using reduced-bandwidth canonical correlation analysis. *J Neural Eng.* 2016;13: 066008. doi:10.1088/1741-2560/13/6/066008
190. Hou J, Morgan K, Tucker DM, Konyn A, Poulsen C, Tanaka Y, et al. An improved artifacts removal method for high dimensional EEG. *J Neurosci Methods*. 2016;268: 31–42. doi:10.1016/j.jneumeth.2016.05.003
191. Sayed Daud SNS, Sudirman R. Artifact removal and brain rhythm decomposition for eeg signal using wavelet approach. *J Teknol.* 2016;78. doi:10.11113/jt.v78.9460
192. Patel R, Janawadkar MP, Sengottuvvel S, Gireesan K, Radhakrishnan TS. Suppression of Eye-Blink Associated Artifact Using Single Channel EEG Data by Combining Cross-Correlation With Empirical Mode Decomposition. *IEEE Sens J.* 2016;16: 6947–6954. doi:10.1109/JSEN.2016.2591580
193. Khatun S, Mahajan R, Morshed BI. Comparative Study of Wavelet-Based Unsupervised Ocular Artifact Removal Techniques for Single-Channel EEG Data. *IEEE J Transl Eng Heal Med.* 2016;4: 1–8. doi:10.1109/JTEHM.2016.2544298
194. Bai Y, Wan X, Zeng K, Ni Y, Qiu L, Li X. Reduction hybrid artifacts of EMG–EOG in electroencephalography evoked by prefrontal transcranial magnetic stimulation. *J Neural*

195. Çınar S, Acır N. A novel system for automatic removal of ocular artefacts in EEG by using outlier detection methods and independent component analysis. *Expert Syst Appl.* 2017;68: 36–44. doi:10.1016/j.eswa.2016.10.009
196. Drisdelle BL, Aubin S, Jolicoeur P. Dealing with ocular artifacts on lateralized ERPs in studies of visual-spatial attention and memory: ICA correction versus epoch rejection. *Psychophysiology.* 2017;54: 83–99. doi:10.1111/psyp.12675
197. Pontifex MB, Miskovic V, Laszlo S. Evaluating the efficacy of fully automated approaches for the selection of eyeblink ICA components. *Psychophysiology.* 2017;54: 780–791. doi:10.1111/psyp.12827
198. Szentkirályi A, Wong KKH, Grunstein RR, D’Rozario AL, Kim JW. Performance of an automated algorithm to process artefacts for quantitative EEG analysis during a simultaneous driving simulator performance task. *Int J Psychophysiol.* 2017;121: 12–17. doi:10.1016/j.ijpsycho.2017.08.004
199. Barthélémy Q, Mayaud L, Renard Y, Kim D, Kang S-W, Gunkelman J, et al. Online denoising of eye-blanks in electroencephalography. *Neurophysiol Clin.* 2017;47: 371–391. doi:10.1016/j.neucli.2017.10.059
200. Guarascio M, Puthusserypady S. Automatic minimization of ocular artifacts from electroencephalogram: A novel approach by combining Complete EEMD with Adaptive Noise and Renyi’s Entropy. *Biomed Signal Process Control.* 2017;36: 63–75. doi:10.1016/j.bspc.2017.03.017
201. Jafarifarmand A, Badamchizadeh M-A, Khanmohammadi S, Nazari MA, Tazehkand BM. Real-time ocular artifacts removal of EEG data using a hybrid ICA-ANC approach. *Biomed Signal Process Control.* 2017;31: 199–210. doi:10.1016/j.bspc.2016.08.006
202. Yang B, Zhang T, Zhang Y, Liu W, Wang J, Duan K. Removal of Electrooculogram Artifacts from Electroencephalogram Using Canonical Correlation Analysis with Ensemble Empirical Mode Decomposition. *Cognit Comput.* 2017;9: 626–633. doi:10.1007/s12559-017-9478-0
203. Anastasiadou MN, Christodoulakis M, Papathanasiou ES, Papacostas SS, Mitsis GD. Unsupervised detection and removal of muscle artifacts from scalp EEG recordings using canonical correlation analysis, wavelets and random forests. *Clin Neurophysiol.* 2017;128: 1755–1769. doi:10.1016/j.clinph.2017.06.247
204. Somers B, Francart T, Bertrand A. A generic EEG artifact removal algorithm based on the multi-channel Wiener filter. *J Neural Eng.* 2018;15: 036007. doi:10.1088/1741-2552/aaac92
205. Chavez M, Grosselin F, Bussalb A, De Vico Fallani F, Navarro-Sune X. Surrogate-Based Artifact Removal From Single-Channel EEG. *IEEE Trans Neural Syst Rehabil Eng.* 2018;26: 540–550. doi:10.1109/TNSRE.2018.2794184
206. Mammone N. Preprocessing the EEG of Alzheimer’s Patients to Automatically Remove Artifacts. Part of the Smart Innovation, Systems and Technologies book series. 2018. pp. 279–287. doi:10.1007/978-3-319-56904-8\_27
207. Tamburro G, Fiedler P, Stone D, Haueisen J, Comani S. A new ICA-based fingerprint method for the automatic removal of physiological artifacts from EEG recordings. *PeerJ.*

2018;6: e4380. doi:10.7717/peerj.4380

208. Gabard-Durnam LJ, Mendez Leal AS, Wilkinson CL, Levin AR. The Harvard Automated Processing Pipeline for Electroencephalography (HAPPE): Standardized Processing Software for Developmental and High-Artifact Data. *Front Neurosci.* 2018;12. doi:10.3389/fnins.2018.00097
209. Garcés Correa A, Orosco LL, Diez P, Laciár Leber E. Adaptive Filtering for Epileptic Event Detection in the EEG. *J Med Biol Eng.* 2019;39: 912–918. doi:10.1007/s40846-019-00467-w
210. Val-Calvo M, Álvarez-Sánchez JR, Ferrández-Vicente JM, Fernández E. Optimization of Real-Time EEG Artifact Removal and Emotion Estimation for Human-Robot Interaction Applications. *Front Comput Neurosci.* 2019;13. doi:10.3389/fncom.2019.00080
211. Kilicarslan A, Contreras Vidal JL. Characterization and real-time removal of motion artifacts from EEG signals. *J Neural Eng.* 2019;16: 056027. doi:10.1088/1741-2552/ab2b61
212. Gajbhiye P, Tripathy RK, Bhattacharyya A, Pachori RB. Novel Approaches for the Removal of Motion Artifact From EEG Recordings. *IEEE Sens J.* 2019;19: 10600–10608. doi:10.1109/JSEN.2019.2931727
213. Dai C, Wang J, Xie J, Li W, Gong Y, Li Y. Removal of ECG Artifacts From EEG Using an Effective Recursive Least Square Notch Filter. *IEEE Access.* 2019;7: 158872–158880. doi:10.1109/ACCESS.2019.2949842
214. Bajaj N, Requena Carrión J, Bellotti F, Berta R, De Gloria A. Automatic and tunable algorithm for EEG artifact removal using wavelet decomposition with applications in predictive modeling during auditory tasks. *Biomed Signal Process Control.* 2020;55: 101624. doi:10.1016/j.bspc.2019.101624
215. Intan Technologies. RHD2000 series digital electrophysiology interface chips. [cited 21 Sep 2018]. Available: [http://intantech.com/RHD2000\\_system\\_intro.html](http://intantech.com/RHD2000_system_intro.html)
216. Huang NE, Shen Z, Long SR, Wu MC, Snin HH, Zheng Q, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proc R Soc A Math Phys Eng Sci.* 1998;454: 903–995. doi:10.1098/rspa.1998.0193
217. Mamun M, Al-Kadi M, Marufuzzaman M. Effectiveness of Wavelet Denoising on Electroencephalogram Signals. *J Appl Res Technol.* 2013;11: 156–160. doi:10.1016/S1665-6423(13)71524-4
218. Plapous C, Marro C, Scalart P. Improved Signal-to-Noise Ratio Estimation for Speech Enhancement. *IEEE Trans Audio, Speech Lang Process.* 2006;14: 2098–2108. doi:10.1109/TASL.2006.872621
219. Safieddine D, Kachenoura A, Albera L, Birot G, Karfoul A, Pasnicu A, et al. Removal of muscle artifact from EEG data: comparison between stochastic (ICA and CCA) and deterministic (EMD and wavelet-based) approaches. *EURASIP J Adv Signal Process.* 2012;2012: 127. doi:10.1186/1687-6180-2012-127
220. Kumar PS, Arumuganathan R, Sivakumar K, Vimal C. Removal of artifacts from EEG signals using adaptive filter through wavelet transform. 2008 9th International Conference on Signal Processing. IEEE; 2008. pp. 2138–2141. doi:10.1109/ICOSP.2008.4697569

221. Babu PA, Prasad KVSVR. Removal of Ocular Artifacts from EEG Signals by Fast RLS Algorithm using Wavelet Transform. *Int J Comput Appl.* 2011;21: 1–5. doi:10.5120/2503-3384
222. Orfanidis SJ. Optimum Signal Processing. 2nd ed. Piscataway, NJ, United States: McGraw-Hill Publishing Company; 2007.
223. Saini M, Satija U, Upadhyay MD. Effective automated method for detection and suppression of muscle artefacts from single-channel EEG signal. *Healthc Technol Lett.* 2020;7: 35–40. doi:10.1049/htl.2019.0053
224. Mijović B, De Vos M, Gligorijević I, Taelman J, Van Huffel S. Source Separation From Single-Channel Recordings by Combining Empirical-Mode Decomposition and Independent Component Analysis. *IEEE Trans Biomed Eng.* 2010;57: 2188–2196. doi:10.1109/TBME.2010.2051440
225. Muthukumaraswamy SD. High-frequency brain activity and muscle artifacts in MEG/EEG: a review and recommendations. *Front Hum Neurosci.* 2013;7. doi:10.3389/fnhum.2013.00138
226. McMenamin BW, Shackman AJ, Greischar LL, Davidson RJ. Electromyogenic artifacts and electroencephalographic inferences revisited. *Neuroimage.* 2011;54: 4–9. doi:10.1016/j.neuroimage.2010.07.057
227. Olbrich S, Jödicke J, Sander C, Himmerich H, Hegerl U. ICA-based muscle artefact correction of EEG data: What is muscle and what is brain? *Neuroimage.* 2011;54: 1–3. doi:10.1016/j.neuroimage.2010.04.256