



COMPARAÇÃO ENTRE OS ALGORITMOS DE ANÁLISE DE COMPONENTES
INDEPENDENTES E FILTRAGEM ADAPTATIVA PARA REDUÇÃO DE
ARTEFATOS DE PISCADA DE OLHO EM SINAIS DE
ELETROENCEFALOGRAMA

Marcelle Guedes de Medeiros Lopes

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Biomédica, COPPE, Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do grau de Mestre em Engenharia Biomédica.

Orientadores: Mauricio Cagy

Antonio Mauricio Ferreira Leite Miranda
de Sá

Rio de Janeiro
Outubro de 2020

COMPARAÇÃO ENTRE OS ALGORITMOS DE ANÁLISE DE COMPONENTES
INDEPENDENTES E FILTRAGEM ADAPTATIVA PARA REDUÇÃO DE
ARTEFATOS DE PISCADA DE OLHO EM SINAIS DE
ELETROENCEFALOGRAMA

Marcelle Guedes de Medeiros Lopes

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA DA
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM
CIÊNCIAS EM ENGENHARIA BIOMÉDICA.

Orientadores: Mauricio Cagy

Antonio Mauricio Ferreira Leite Miranda de Sá

Aprovada por: Prof. Antonio Mauricio Ferreira Leite Miranda de Sá

Prof. José Manuel de Seixas

Prof. Roberto Macoto Ichinose

RIO DE JANEIRO, RJ BRASIL

OUTUBRO DE 2020

Lopes, Marcelle Guedes de Medeiros.

Comparação entre os Algoritmos de Análise de Componentes Independentes e Filtragem Adaptativa para Redução de Artefato de Piscada de Olho em Sinais de Eletroencefalograma./ Marcelle Guedes de Medeiros Lopes. – Rio de Janeiro: UFRJ/COPPE, 2020.

XV, 61 p.: il.; 29,7 cm.

Orientadores: Mauricio Cagy

Antonio Mauricio Ferreira Leite Miranda de Sá.

Dissertação (mestrado) – UFRJ/ COPPE/ Engenharia Biomédica, 2020.

Referências Bibliográficas: p. 56 - 61.

1. EOG. 2. ICA. 3. Infomax. 4. SOBI. 5. wICA. 6. Filtragem Adaptativa. I. Cagy, Mauricio *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Biomédica. III. Título.

Dedico este trabalho aos meus
pais Leandro e Fabiana, à
minha irmã Beatriz e aos meus
orientadores.

Agradecimentos

Gostaria de agradecer, primeiramente, aos meus pais, Leandro e Fabiana, por terem colocado minha educação como prioridade, sempre me apoiando na minha vida acadêmica. Agradeço também a minha irmã, Beatriz, que foi uma ótima ouvinte durante os meus ensaios de apresentações. E, também, ao meu companheiro de quatro patas, Richard, pela presença incessante durante a realização deste trabalho.

Sou grata aos meus amigos do PEB, em especial, Gabriel Alonso, Thaís Silvestre, Andrei Lenine, Fellipe Parreira, Eric Saito e Vinícius Ecard que muito me ajudaram e divertiram ao longo do curso.

Aos meus orientadores, Mauricio Cagy e Antonio Mauricio, agradeço pelo auxílio e apoio.

Por fim, agradeço à FAPERJ, CAPES e CNPq pelo apoio financeiro a mim e ao meu programa, sem o qual este trabalho não poderia ter sido realizado.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

COMPARAÇÃO ENTRE OS ALGORITMOS DE ANÁLISE DE COMPONENTES
INDEPENDENTES E FILTRAGEM ADAPTATIVA PARA REDUÇÃO DE
ARTEFATOS DE PISCADA DE OLHO EM SINAIS DE
ELETROENCEFALOGRAMA

Marcelle Guedes de Medeiros Lopes

Outubro/2020

Orientadores: Mauricio Cagy

Antonio Mauricio Ferreira Leite Miranda de Sá

Programa: Engenharia Biomédica

Apesar de o artefato de eletro-oculograma (EOG) ser associado à ação inerente ao ser humano de piscar os olhos, o mesmo contamina e distorce as formas de onda do eletroencefalograma (EEG), prejudicando o controle das Interfaces Cérebro-Máquina (ICM) baseadas na atividade cortical. O EEGLAB é uma *toolbox* muito utilizada para atenuação de EOG em EEG, e dispõe de técnicas clássicas para tal fim como as abordagens Infomax e SOBI (do inglês, *Second-Order Blind Identification*) do método de Análise de Componentes Independentes (ICA, do inglês *Independent Component Analysis*). Apesar do vasto uso da ICA na remoção de EOG para aplicações em ICM, essa técnica apresenta dificuldade em lidar com a contaminação bidirecional dos dados. A fim de abrandar tal característica da ICA, avaliou-se sua variação *Wavelet* e a Filtragem Adaptativa como alternativas de pré-processamento para ICM. Os resultados mostraram que os métodos testados obtiveram bom desempenho na redução do EOG ao manterem o EEG recuperado o mais próximo possível ao EEG puro. Contudo, a Filtragem Adaptativa foi superior na análise do par erro médio quadrático-correlação.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

COMPARISON BETWEEN INDEPENDENT COMPONENT ANALYSIS AND
ADAPTIVE FILTERING ALGORITHMS FOR BLINK ARTIFACT REDUCTION IN
ELECTROENCEPHALOGRAM SIGNALS

Marcelle Guedes de Medeiros Lopes

October/2020

Advisors: Mauricio Cagy

Antonio Mauricio Ferreira Leite Miranda de Sá

Department: Biomedical Engineering

Although the electro-oculogram (EOG) artifact is associated with the inherent human action of blinking, it contaminates and distorts electroencephalogram (EEG) waveforms, impairing the control of Brain-Machine Interfaces (BMI) based on cortical activity. EEGLAB is a widely used toolbox for EOG attenuation in EEG, and has classical techniques for this purpose like the Infomax and SOBI (Second-Order Blind Identification) approaches of the Independent Component Analysis (ICA) method. Despite the wide use of ICA in EOG removal for MCI applications, this technique has difficulty in dealing with bidirectional contamination of the data. In order to mitigate this characteristic of ICA, its variations Wavelet and Adaptive Filtering were evaluated as pre-processing alternatives for MCI. The results showed that the tested methods performed well in reducing EOG by keeping the retrieved EEG as close as possible to the pure EEG signal. However, Adaptive Filtering has shown a slightly superior performance in the analysis of the mean squared error-correlation pair.

Sumário

Lista de Figuras.....	xii
Lista de Tabelas.....	xiv
Lista de siglas.....	xv
1 Introdução.....	1
2 Objetivos.....	3
2.1 Objetivo Geral.....	3
2.2 Objetivos Específicos	3
3 Fundamentos Teóricos.....	4
3.1 Fisiologia Neural do Sistema Visual	4
3.2 A Eletroencefalografia	5
3.2.1 Geração do Sinal de EEG.....	5
3.2.2 Ritmos de EEG.....	6
3.2.3 Montagem do EEG.....	7
3.3 Eletro-Oculograma.....	8
3.4 EEG e interface Cérebro-Máquina	11
3.4.1 Artefatos em EEG.....	12
3.5 EEGLAB.....	13
3.6 Técnicas de Processamento	14
3.6.1 Análise de Componentes Independentes	14

3.6.1.1	Infomax	16
3.1.1.2	SOBI.....	16
3.6.2	Transformada Wavelet	17
3.6.3	Wavelet-ICA	18
3.6.4	Métodos de Filtragem	19
3.6.4.1	Filtro de Wiener.....	19
3.6.4.2	Filtro Adaptativo.....	20
4	Materiais e Métodos.....	23
4.1	Remoção de Artefatos para ICM	23
4.2	Sinais de EEG.....	24
4.3	Técnicas ICA.....	30
4.4	Técnica wICA.....	30
4.5	Filtragem Adaptativa.....	31
4.6	Metodologia de Avaliação.....	32
5	Resultados.....	35
5.1	Resultado Individual.....	35
5.2	Resultados Gerais.....	41
6	Discussão.....	49
7	Conclusão.....	54
8	Trabalhos Futuros.....	55
9	Referências bibliográficas.....	56

Lista de Figuras

3.1	Mapa citoarquitetônico de Brodmann do córtex cerebral humano. Domínio Público.....	4
3.2	Campo elétrico gerado pela excitação das membranas de um neurônio piramidal. Modificado de Domínio Público. Disponível em https://commons.wikimedia.org/wiki/File:Neuron_CNS_-_no_labels.png	6
3.3	Sistema internacional 10-20 para colocação de eletrodos de EEG. Domínio público.....	8
3.4	Posições de Colocação dos Eletrodos para Eletro-Oculograma. Autoria Própria.....	9
3.5	Primeiro Quadro: EEG sem contaminação de piscada de um indivíduo normal. Segundo Quadro: vEOG do mesmo indivíduo. Terceiro quadro: EEG contaminado por piscada. Autoria Própria.....	10
3.6	Esquemático da técnica BSS. Autoria Própria.....	15
3.7	Exemplo da DWT com dois níveis de decomposição. Autoria Própria.....	18
3.8	Esquemático da Implementação do Métodos Wavelet-ICA. Autoria Própria.....	19
3.9	Diagrama de Blocos do Filtro de Wiener.....	20
3.10	Diagrama de blocos do Filtro Adaptativo.....	21
4.1	Média por canal dos sinais de EEG contaminados por EOG dos 57 indivíduos que compõem o banco de dados, seguido pelos sinais médios de vEOg e hEOG.....	25

4.2	Box plot da distribuição dos sinais médios de EEG contaminados por EOG para os canais Fp1, Fp2, F3, F4, C3 e C4.....	26
4.3	Box plot da distribuição dos sinais médios de EEG contaminados por EOG para os canais P3, P4, O1, O2, F7 e F8.....	26
4.4	Box plot da distribuição dos sinais médios de EEG contaminados por EOG para os canais T3, T4, T5, T6, Fz, Cz e Pz	27
4.5	Dados de EEG sinal de interesse sem o piscar de olhos, adquirido com os olhos fechados do Indivíduo 5. Disponível em (KLADOS; BAMIDIS, 2016).	28
4.6	Dados de EEG contaminado por EOG do indivíduo 5. Disponível em (KLADOS; BAMIDIS, 2016).	29
4.7	Esquemático da implementação do banco de filtros para Filtragem Adaptativa. A autoria Própria.	31
5.1	Dados de EEG do indivíduo 5 recuperados por Infomax	36
5.2	Dados de EEG do indivíduo 5 recuperados por Wavelet-Infomax	36
5.3	Dados de EEG do indivíduo 5 recuperados por SOBI.....	37
5.4	Dados de EEG do indivíduo 5 recuperados por Wavelet-SOBI	37
5.5	Dados de EEG do indivíduo 5 recuperados por Filtragem Adaptativa.	32
5.6	Valores de correlação, em porcentagem, entre o sinal recuperado pelas técnicas para as técnicas ICA, wICA, SOBI, wSOBI e Filtragem e o sinal original para todos os indivíduos da base de dados	42
5.7	Valores de MSE, em porcentagem, entre o sinal recuperado pelas técnicas para as técnicas ICA, wICA, SOBI, wSOBI e Filtragem e o sinal original para todos os indivíduos da base de dados.....	43

5.8	Sinais contaminados por EOG (em preto) e os sinais recuperados indivíduos que apresentaram melhor resultado de correlação (azul) e melhor resultados de MSE(vermelho) do canal Fp1 por Infomax.....	45
5.9	Sinais contaminados por EOG (em preto) e os sinais recuperados indivíduos que apresentaram melhor resultado de correlação (azul) e melhor resultados de MSE(vermelho) do canal Fp1 por SOBI.....	46
5.10	Sinais contaminados por EOG (em preto) e os sinais recuperados indivíduos que apresentaram melhor resultado de correlação (azul) e melhor resultados de MSE(vermelho) do canal Fp1 por Wavelet-Infomax.....	46
5.11	Sinais contaminados por EOG (em preto) e os sinais recuperados indivíduos que apresentaram melhor resultado de correlação (azul) e melhor resultados de MSE(vermelho) do canal Fp1 por Wavelet-SOBI..	47
5.12	Sinais contaminados por EOG (em preto) e os sinais recuperados indivíduos que apresentaram melhor resultado de correlação (azul) e melhor resultados de MSE(vermelho) do canal Fp1 por Filtragem.....	48

Lista de Tabelas

5.1	Tabela 5.1 – Resumo dos Resultados de correlação e MSE para o Indivíduo 5.....	39
5.2	Tabela 5.2 – Resumo dos Resultados de %Dif para o Indivíduo 5.....	40
5.3	Tabela 5.3 – Valor absoluto dos maiores e menores valores de correlação e MSE obtidos para cada algoritmo para o sinal do canal Fp1 dos 54 indivíduos.....	44

Lista de siglas

- BSS – *Blind Source Separation*
- CRT – *Cathode-Ray Tube*
- DWT – *Discrete Wavelet Transform*
- ECG – Eletrocardiograma
- EEG – Eletroencefalograma
- EMG – Eletromiograma
- EOG – Eletro-Oculograma
- EPSP – *Excitatory Postsynaptic Potential*
- ERD – *Event Related Desynchronization*
- ERP – *Event Related Potential*
- ERS – *Event Related Synchronization*
- HEOG – *Horizontal Electrooculogram*
- HOS – *Higher Order Statistics*
- IC – *Independent Components*
- ICA – *Independent Components Analysis*
- ICM – Interface Cérebro-Máquina
- IPSP – *Inibitory Postsynaptic Potential*
- LAPIS – Laboratório de Processamento de Imagens e Sinais
- LCD – *Liquid Crystal Display*
- LEDs – *Light-Emitting Diodes*
- LMS – *Least-Mean-Square Algorithm*
- MSE – *Mean-Square Error*
- NGL – Núcleo Geniculado Lateral

PEB – Programa de Engenharia Biomédica

RMS – *Root Mean Square*

RNA – Redes Neurais Artificiais

SOBI – *Second Order Blind Identification*

SOS – *Second Order Statistics*

SSVEP – *Steady State Visually Evoked Potential*

UFRJ – Universidade Federal do Rio de Janeiro

VEOG – *Vertical Electrooculogram*

WICA – *Wavelet-Independent Component Analysis*

1 Introdução

O controle do corpo humano é realizado pelo sistema nervoso. Didaticamente, esse sistema é subdividido em duas partes: o sistema nervoso central (SNC) e o sistema nervoso periférico (SNP). O SNP tem, basicamente, duas funções principais: a de receber informações nas extremidades do corpo e transmiti-las ao SNC, e, também, a de conduzir informações do SNC aos sistemas periféricos do corpo. Já o sistema nervoso central tem a tarefa de produzir sinais de comando em resposta aos estímulos observados na periferia do corpo. A partir da década de 1960, surgiram sistemas desenvolvidos para permitir a comunicação do SNC com o meio externo ao corpo sem utilizar as vias normais de comunicação, ou seja, o SNP (WOLPAW; WOLPAW, 2012). Tais sistemas são conhecidos como sistemas de Interface Cérebro-Máquina (ICM) (BEAR, 2002).

Os sistemas de interface cérebro-máquina (ICM) são capazes de traduzir sinais corticais em comandos para controle de dispositivos, tais como computadores e veículos, sem utilização de membros ou atividade muscular, como, por exemplo, movimentação de braços e pernas. Entre os sistemas existentes, os que fazem uso do Eletroencefalograma (EEG) para capturar os biopotenciais da atividade cortical desempenham um papel importante, permitindo, após passos de processamento de sinais, controlar estes dispositivos.

Durante o estágio de aquisição de dados, em protocolos de olhos abertos, os sinais de EEG provenientes dos eletrodos da região frontal do escalpo são severamente contaminados por artefatos oculares de piscadas de olho (CAGY; CAGY; INFANTOSI, 2011). O controle de sistemas de ICM feito por estimulação visual é comprometido quando o sinal de comando está contaminado por estes artefatos, pois os mesmos geram uma distorção de amplitude positiva ou negativa no sinal EEG, de cerca de dez vezes maior que os sinais de EEG (NIEDERMEYER; LOPES DA SILVA, 2005). Tal distorção, causada pelos artefatos de piscada, pode alterar a forma de um evento neurológico, resultando em um controle não intencional do dispositivo (ISLAM; RASTEGARNIA; YANG, 2016).

Portanto, a fim de detectar e remover os artefatos, foram criados dezenas de métodos para extração e classificação dos dados de EEG. A combinação desses métodos ou a automatização do processo de remoção foi separada em duas categorias (JIANG; BIAN; TIAN, 2019): (i) algoritmos que estimam os artefatos usando canal de referência; ou (ii) algoritmos que estimam os artefatos pela decomposição do sinal EEG em outros domínios.

As técnicas que dependem de uma referência, como a Filtragem Ótima (HAYKIN, 2014) e a Filtragem Adaptativa (HE; WILSON; RUSSELL, 2004), assim como as técnicas que utilizam a decomposição do sinal de EEG, tais como a Transformada Wavelet (UNSER; ALDROUBI, 1996) e a Análise de Componentes Independentes (ISLAM; RASTEGARNIA; YANG, 2016; SHOKER; SANEI; CHAMBERS, 2005), aparecem na literatura como formas eficientes de redução de artefatos. Entretanto, ressalta-se que não há um único método considerado ideal para remoção ou atenuação do artefato de piscada em EEG. A escolha do método depende da sua aplicação e das necessidades que cada experimento exige.

No contexto da utilização da técnica ICA para remoção de artefatos em dados de EEG, o EEGLAB é considerado o principal software de código aberto para processamento de dados eletroencefalográficos (MARTÍNEZ-CANCINO et al., 2021).

Assim, o objetivo deste trabalho é testar a capacidade da ferramenta EEGLAB (DELORME et al., 2011), plataforma amplamente utilizada para aplicação e compartilhamento de técnicas de processamento de sinais biomédicos (DELORME; MAKEIG, 2004), na atenuação de artefatos de piscada para uma mesma condição, ao utilizar dois métodos tradicionais (URIGÜEN; GARCIA-ZAPIRAIN, 2015), Infomax e SOBI, para tal objetivo. Além desses métodos, é testada a sua variação Wavelet, a fim de sanar as deficiências dos algoritmos disponibilizados pelo EEGLAB. A Filtragem Adaptativa, outro método clássico para redução de EOG em EEG, também é testada como alternativa aos métodos ICA.

2 Objetivos

2.1 Objetivo Geral

O objetivo deste trabalho é utilizar o EEGLAB, ferramenta com interface gráfica e funcionamento em ambiente MATLAB para testar e comparar os métodos clássicos de Análise de Componentes Independentes (*Infomax* e *Second-Order Blind Identification*, SOBI), as suas variações combinadas com a Transformada Wavelet (wICA, do inglês *Wavelet-Independent Component Analysis*) e a Filtragem Adaptativa no que diz respeito à sua capacidade de atenuar artefatos de piscada nos dados de EEG para aplicação em Interfaces Cérebro Máquina.

2.2 Objetivos Específicos

- Utilização dos dados de EEG na ferramenta EEGLAB para realizar a análise *Infomax*;
- Utilização dos dados de EEG na ferramenta EEGLAB para realizar a análise SOBI;
- Implementação do algoritmo *Wavelet*;
- Combinação do algoritmo *Wavelet* com as Análises de Componentes Independentes;
- Implementação do algoritmo filtragem adaptativa;
- Cálculo do valor de erro médio quadrático (MSE, do inglês, *mean squared error*) e de correlação entre os sinais recuperados para cada algoritmo e o sinal de EEG sem contaminação de EOG; e
- Comparação entre os valores de MSE.

3 Fundamentos Teóricos

Neste capítulo, é apresentada a fundamentação teórica sobre a geração dos sinais de Eletroencefalografia e de Eletrooculograma, bem como sobre a interferência dos artefatos. Além desses tópicos, aqui também é abordada a aplicação da Eletroencefalografia para controle de interfaces cérebro-computador.

3.1 Fisiologia Neural do Sistema Visual

Proposto no início do século XX pelo neuroanatomista alemão Korbinian Brodmann, o mapa citoarquitetônico do neocórtex juntou diferentes áreas deste contendo a mesma citoarquitetura em grupos (BEAR, 2002). Esses grupos específicos foram identificados por números como mostra a Figura 3.1.




Figura 3. 1—Mapa citoarquitetônico de Brodmann do córtex cerebral humano.

Domínio Público.

A partir da divisão feita por Brodmann, pôde-se demonstrar que áreas corticais distintas executavam diferentes funções. Assim, por exemplo, a “área 17” no extremo posterior do lobo occipital recebe sinalizações do núcleo do tálamo e está conectada à retina (BEAR, 2002), tendo recebido o nome de córtex visual primário (córtex estriado ou V1) por receber aferências dos olhos pela via direta retina-tálamo.

A informação extraída pela retina é encaminhada pelo núcleo geniculado lateral (NGL) do tálamo, e depois, chega ao córtex estriado (BEAR, 2002), ou seja, a informação percorre a via geniculocortical. Ao percorrer tal via, a informação é segregada em canais paralelos de processamento, por neurônios especializados na análise de diferentes atributos do estímulo (BEAR, 2002). Então, o córtex estriado retransmite a informação para as áreas de associação visual (áreas V-2, V-3 e V-4) especializadas em diferentes tipos de análises que dissecam e analisam a imagem virtual proveniente da retina (GUYTON; HALL, 2011).

3.2 A Eletroencefalografia

A eletroencefalografia (EEG) foi descrita pela primeira vez na literatura por Hans Berger em 1929, sendo um método de registro da atividade elétrica cerebral medida por eletrodos sobre o couro cabeludo. Tal atividade se caracteriza por representar o somatório do fluxo de corrente iônica extracelular somado aos potenciais excitatórios pós-sinápticos (EPSP, do inglês *Excitatory Postsynaptic Potential*) e inibitórios pós-sinápticos (IPSP, do inglês *Inibitory Postsynaptic Potential*) (GUYTON; HALL, 2011).

3.2.1 Geração do Sinal de EEG

O EEG é a medida da combinação espaço-temporal do fluxo de corrente iônica decorrente dos potenciais excitatórios e inibitórios pós-sinápticos nos dendritos dos neurônios piramidais no córtex cerebral, que se comportam como pequenos dipolos (SANEI; CHAMBERS, 2007).

Essa corrente gera um campo elétrico através do escalpo que é medido por sistemas de EEG. Por gerarem “campos elétricos abertos”, os neurônios piramidais são os que mais contribuem para geração do sinal de EEG. A Figura 3.2 mostra o campo elétrico gerado por esse tipo de neurônio.




Figura 3.2- Campo elétrico gerado pela excitação das membranas de um neurônio piramidal. Modificado de Domínio Público. Disponível em https://commons.wikimedia.org/wiki/File:Neuron_CNS_-_no_labels.png.

Segundo Gloor (BUENO, 2017; GLOOR, 1985), somente é possível medir os potenciais de ação das membranas quando os eletrodos estão localizados a distâncias muito próximas da membrana em estudo. Neste sentido, o EEG não captura potencial de ação, e sim combinações de potenciais sinápticos, pois, mesmo que apresentem menor amplitude que o potencial de ação, para a medição remota de campo elétrico por meio de eletrodos na superfície do escalpo, a geometria dos neurônios piramidais facilita o registro do potencial sináptico.

3.2.2 Rítmicos de EEG

O EEG contém um espectro de frequências amplo, com limites superiores e inferiores difusos (BEAR, 2002). Os ritmos do EEG, ou seja, suas faixas de frequência variam e correlacionam-se com determinados estados do comportamento (como os níveis de atenção, sono ou vigília) e com patologias (como crises epiléticas ou coma).

Os principais ritmos são brevemente descritos a seguir:

- Delta

O termo Delta foi introduzido por Walter em 1936 para designar as frequências de 0 a 4 Hz. Essas ondas são lentas, com grande amplitude e estão associadas com o sono profundo e podem aparecer no estado acordado.

Além disso, são facilmente confundidas com sinais de artefato gerados pelos músculos do pescoço e mandíbula. (SANEI; CHAMBERS, 2007).

- Teta

O termo Teta também foi introduzido por Walter em 1944 para definir as ondas na faixa de frequência entre 4 e 8 Hz. Esse ritmo aparece quando a consciência caminha em direção à sonolência e pode aparecer durante a vigília.

- Alfa

O termo Alfa foi introduzido por Berger em 1929 para representar frequências na banda de 8 a 12 Hz. Esse ritmo é encontrado na região occipital do cérebro durante a vigília relaxada.

- Beta

O termo Beta também foi introduzido por Berger em 1929 para identificar as frequências na faixa entre 12 e 32 Hz. Esse ritmo é encontrado nas regiões frontal e central do cérebro durante atividade que exigem demanda cognitiva.

- Gama

O termo gama foi introduzido por Jasper e Andrews em 1938 para designar frequências acima de 32 Hz. É o ritmo mais rápido de todos e que aparece quando há uma extrema demanda cognitiva, principalmente quando se usam muitos sistemas do corpo simultaneamente. É importante salientar que o ritmo gama não aparece sozinho.

Além dos aqui citados, ritmos adicionais incluem os fusos, breves ondas de 8 a 14 Hz associadas ao sono, e *ripples*, breves surtos de oscilações de 80 a 200 Hz (BEAR, 2002).

3.2.3 Montagem do EEG

O posicionamento dos eletrodos de EEG no escalpo é padronizado pelo sistema internacional 10-20 (BUENO, 2017). As letras indicam regiões do cérebro sobre as quais os eletrodos se encontram, de modo que os eletrodos são denominados de acordo com a região: frontal (F), central (C), temporal (T), parietal (P) e occipital (O) (BUENO, 2017).

Para diferenciar as áreas homólogas dos hemisférios cerebrais, utilizam-se números pares no hemisfério direito e ímpares no esquerdo. Os eletrodos auriculares são chamados A1 (a esquerda) e A2 (a direita).

A localização dos eletrodos no sistema 10-20 é mostrada na Figura 3.3.




Figura 3.3 – Sistema internacional 10-20 para colocação de eletrodos de EEG. Domínio público.

3.3 Eletro-Oculograma

Descrita pela primeira vez por Emil Du Bois-Reymond em 1848, o eletro-oculograma (EOG) mede a diferença de potencial elétrico entre a córnea e a retina do olho humano (BAREA et al., 2002) por um par de eletrodos fixados no plano horizontal próximo ao canto dos olhos (hEOG) ou no plano vertical acima e abaixo de um olho (vEOG), dependendo da alteração de posição do globo ocular que se tem interesse em medir (NIEDERMEYER; LOPES DA SILVA, 2005). O potencial entre a córnea e a retina é produzido pela hiperpolarização e despolarização das células nervosas na retina (SOUZA; BORGES; NAVES, 2010). As posições de colocação do eletrodo estão ilustradas na Figura 3.4.

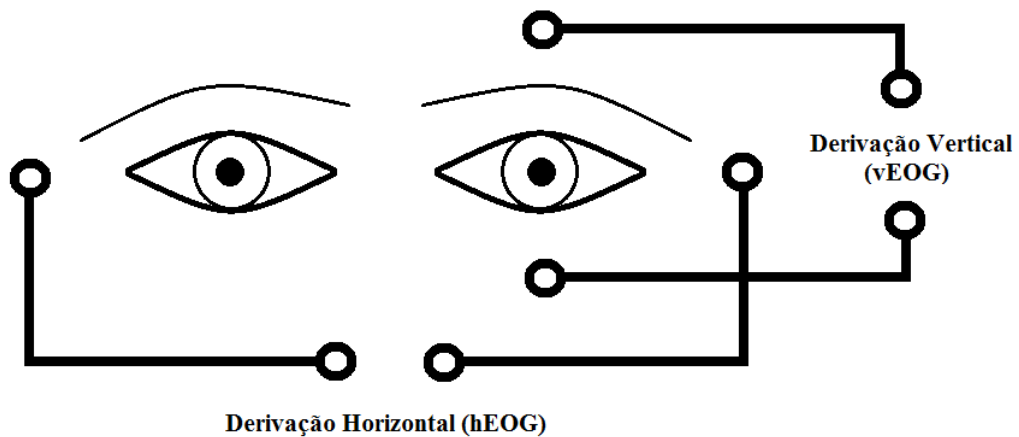
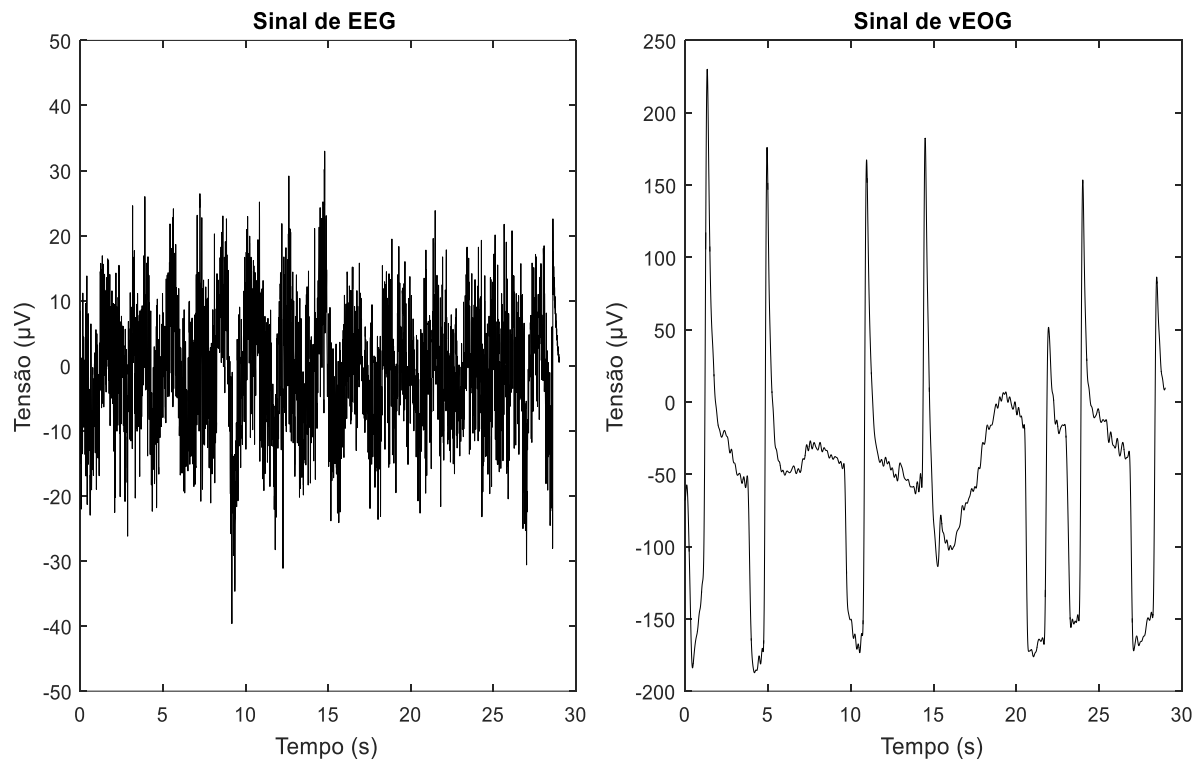


Figura 3.4 - Posições de Colocação dos Eletrodos para Eletro-Oculograma. Autoria Própria.

O olho humano pode ser considerado um dipolo elétrico (SOUZA; BORGES; NAVES, 2010). Muitos experimentos mostram que, ao se considerar o globo ocular, a córnea é o polo positivo (+ 70 μV) e a retina é o polo negativo (-30 μV) (ZHAO, 2008). Quando esse dipolo se move durante a piscada, o campo elétrico ao redor dos olhos gera uma interferência, com formato de pulsos, no sinal de EEG.

Dois pulsos são gerados pela piscada de olho, um positivo e outro negativo. O pulso positivo é produzido ao passo que os olhos rolam para cima, e o pulso negativo é gerado quando os olhos rolam para baixo. A largura desse pulso é proporcional à duração do processo de movimentação para cima ou para baixo do olho, assim como a amplitude do pulso é proporcional ao ângulo que é alcançado durante esse movimento (ZARUZ et al., 2018). A Figura 3.5 ilustra a diferença de amplitude de tensão entre sinais de EEG sem contaminação por artefatos de piscada e o sinal de EEG sem contaminação por artefato.



Artefatos de Piscada




Figura 3.5 – Primeiro Quadro: EEG sem contaminação de piscada de um indivíduo normal. Segundo Quadro: vEOG do mesmo indivíduo. Terceiro quadro: EEG contaminado por piscada. Autoria Própria.

Quando comparado ao EEG, o EOG apresenta grande amplitude, relação linear com o movimento ocular e forma de onda facilmente detectável (ZHAO, 2008).

3.4 EEG e Interface Cérebro-Máquina

Interfaces cérebro-máquina (ICM) são sistemas capazes de traduzir informações da atividade neuronal de um indivíduo em ações de controle para dispositivos, possivelmente usados na reabilitação de sujeitos com dificuldades de comunicação ou motoras (D’AFFONSÊCA NETTO; SÁ, 2014; WOLPAW et al., 2002).

As ICM podem ser divididas em ativas ou passivas, de acordo com o sinal de EEG que é utilizado para seu controle. Nas ICM passivas, os sinais empregados são espontâneos, tal como o EEG em repouso (D’AFFONSÊCA NETTO; SÁ, 2014; WOLPAW et al., 2002). Já as ICM ativas empregam EEG com estímulos sensoriais externos (D’AFFONSÊCA NETTO; SÁ, 2014; WOLPAW et al., 2002). As interfaces ativas baseadas na estimulação visual utilizam, basicamente, dois tipos de padrões cerebrais que os estímulos produzem: potenciais de Sincronização/Dessincronização relacionada a evento (ERD/ERS, da língua inglesa, *Event-Related (De)Synchronization*), sinais gerados de forma espontânea pelo usuário e potenciais relacionados a eventos (ERP, da língua inglesa, *Event-Related Potencial*), sinais em resposta de um evento ou estímulo externo.

- ICM baseadas em ERS/ERD

Chamam-se de ERD e ERS os sinais sem sincronização de fase gerados em resposta a tarefas cognitivas como, por exemplo, o movimento ou a preparação para o movimento dos membros. O ERD é a uma redução da potência dos sinais de EEG em uma faixa de frequências específica nos sensores localizados em certa região do escalpo, como resultado da dessincronização de um conjunto de neurônios (SILVA, 2017). O contrário, ou seja, aumento da potência de uma faixa de frequências que reflete uma sincronização do ritmo oscilatório de um grupo de neurônios, é chamado ERS.

Em sistemas de ICM baseados em ERS/ERD, a imaginação do movimento dos membros é normalmente utilizada como tarefa mental de gatilho (NIEDERMEYER; LOPES DA SILVA, 2005).

- ICM baseadas em ERP

Os ERP são sinais elétricos com sincronização de fase produzidos pelo cérebro em resposta a um estímulo recebido pelo usuário. Esse estímulo pode ser visual, auditivo, tátil, entre outros. Em geral, esses estímulos são apresentados ao usuário em momentos pré-determinados, e a ICM os detecta sincronamente (FATOURECHI et al., 2007; SILVA, 2017). Os potenciais evocados sensoriais (visual, auditivo, somatossensorial) (EP, do inglês, *evoked potential*), ou seja, sinais elétricos gerados pelo sistema nervoso em resposta à estimulação do sistema sensorial, são um subconjunto dos ERP (NIEDERMEYER; LOPES DA SILVA, 2005).

Dois ERP bastante utilizados em ICM são: (i) os potenciais evocados visuais em regime permanente (SSVEP, do inglês *Steady State Visually Evoked Potential*), que são desencadeados quando o usuário fixa o olhar para a fonte de estimulação, e (ii) os potenciais P300, sinais endógenos suscitados no processo de tomada de decisão quando é apresentada ao usuário uma lista de estímulos, que podem ser de diferentes naturezas. O usuário, então, deve prestar atenção ao estímulo que representa a ação desejada (FATOURECHI et al., 2007; SILVA, 2017).

Pesquisas estão sendo desenvolvidas utilizando-se a resposta SSVEP para a construção de sistemas que permitem a comunicação do Sistema Nervoso Central com o meio externo ao corpo sem utilizar o Sistema Nervoso Periférico (WOLPAW; WOLPAW, 2012). Um importante componente de uma ICM-SSVEP é a estimulação. A forma mais usual dessa etapa é pelo uso de estímulos visuais oscilantes a uma frequência constante, que pode ser efetuada por LEDs (*Light-Emitting Diodes*), monitores CRT (*Cathode-Ray Tube*) e LCD (*Liquid Crystal Display*).

3.4.1 Artefatos em EEG

EEG são contaminados por diferentes formas de artefatos de fontes internas

(ECG, EMG, EOG) e externas (interferência de equipamento, eletrodo solto, movimento de cabo, entre outras) (ISLAM; RASTEGARNIA; YANG, 2016).

Os artefatos são prejudiciais à análise automática de EEG, e devem ser eliminados, ou ao menos reduzidos ao máximo possível, se a análise de EEG por computador for usada (NIEDERMEYER; LOPES DA SILVA, 2005).

Os artefatos de piscada de olhos são muito claros nas gravações de EEG frontal e occipital, e geram uma distorção de amplitude positiva ou negativa no sinal de EEG que é da ordem de dez vezes maior que a os sinais corticais, além de chegar a 400 ms de duração (NIEDERMEYER; LOPES DA SILVA, 2005). A deformação no sinal de EEG é exemplificada na Figura 3.5.

Quando o protocolo para coleta do EEG se dá com indivíduos de olhos abertos, como é o caso deste trabalho, a piscada dos olhos é a principal fonte de artefato. A remoção deste artefato foi primeiramente estudada por Gotman em 1976 ao se estabelecer um método de subtrair o EOG do EEG. Entretanto, em 1994, Berg e Scherg constataram que a forma como o artefato de piscada era removido causava distorção dos sinais do EEG, pois a gravação do EOG também contém sinais cerebrais (SANEI; CHAMBERS, 2007).

Os artefatos de piscada interferem diretamente durante a aplicação de ICM, tendo em vista que tais artefatos podem modificar ou alterar a forma de um evento neurológico (por exemplo, ERP) que dirige o sistema ICM e que, eventualmente, resulta em um controle não intencional do dispositivo (ISLAM; RASTEGARNIA; YANG, 2016; VAUGHAN, 2003).

3.5 EEGLAB

O EEGLAB é uma *toolbox* para processamento de dados fisiológicos que dispõe de uma interface gráfica de usuário de fácil navegação ao se empregarem scripts de programação interpretados pelo Matlab (DELORME; MAKEIG, 2004).

Desde seu desenvolvimento em 2001 (BRUNNER; DELORME; MAKEIG, 2013), o EEGLAB acumula mais de 2.500 citações em seu documento de referência

(DELORME et al., 2011; BRUNNER; DELORME; MAKEIG, 2013) e pelo menos 35 ferramentas *plug-in* implementadas e liberadas por grupos de usuários. Dentre as ferramentas implementadas para o EEGLAB, existe uma gama delas para realizar a decomposição ICA (MARTÍNEZ-CANCINO et al., 2021), separação de componentes (INTERNATIONAL FEDERATION FOR MEDICAL AND BIOLOGICAL ENGINEERING, 2011) e eliminação de componentes (INTERNATIONAL FEDERATION FOR MEDICAL AND BIOLOGICAL ENGINEERING, 2011). Logo, o EEGLAB é amplamente usado como solução na detecção e mitigação de artefatos como movimentos oculares em sinais de EEG (MARTÍNEZ-CANCINO et al., 2021).

3.6 Técnicas de Processamento

3.6.1 Análise de Componentes Independentes

A Análise Componentes Independentes (ICA, do inglês *Independent Component Analysis*) é uma das técnicas contidas na área de *Blind Source Separation* (BSS) (JIANG; BIAN; TIAN, 2019, URIGÜEN; GARCIA-ZAPIRAIN, 2015). De modo geral, a ICA identifica as fontes de mistura desconhecidas usando apenas informações nas misturas observadas nos sinais de saída \mathbf{X} , com pouco ou nenhum conhecimento sobre a fonte de sinal e a de artefato (ISLAM; RASTEGARNIA; YANG, 2016), como na equação 1:

$$\mathbf{X} = \mathbf{AS} \quad (1)$$

Como o EEG é formado por misturas lineares de formas de ondas originárias de atividade cortical e de fontes de artefatos cerebrais, a equação 1 é uma típica abordagem para remoção de artefatos do mesmo. Neste caso, \mathbf{X} é uma matriz cujas colunas representam os sinais de EEG obtidos no escalpo como a soma da mistura linear das fontes independentes (colunas da matriz \mathbf{S}), ponderadas pelas linhas da matriz de mistura \mathbf{A} . Então, para duas misturas x_1 e x_2 , têm-se os coeficientes de mistura a_{ij} , e as fontes independentes s_i :

$$\begin{bmatrix} x_1[k] \\ x_2[k] \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} s_1[k] \\ s_2[k] \end{bmatrix} \quad (2)$$

Dessa forma, o objetivo da ICA é, sem conhecimento dos coeficientes de mistura e das fontes independentes, encontrar uma transformação linear, \mathbf{W} , para que as fontes estimadas, $\hat{\mathbf{S}}$, sejam as mais independentes possíveis entre si, (ISLAM; RASTEGARNIA; YANG, 2016) como mostra a equação 2 e o esquemático da Figura 3.6.

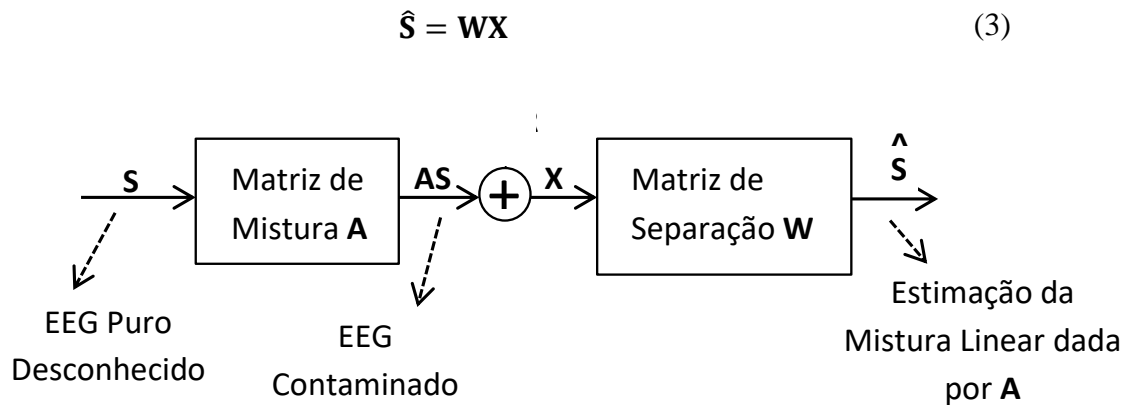


Figura 3.6 - Esquemático da técnica BSS. Autoria Própria.

Aplicada para a separação de informação de EOG no EEG por VIGARIO (JIANG; BIAN; TIAN, 2019; VIGARIO et al., 2000; VIGÁRIO, 1997), a ICA considera que o sinal de EEG contaminado por artefatos é uma mistura linear instantânea de “fontes” do sinal de EEG sem contaminação com os artefatos. Dessa forma, o sinal de EEG contaminado pode ser decomposto em Componentes Independentes (IC) (JIANG; BIAN; TIAN, 2019). As IC que contêm os artefatos são desconsideradas e o sinal é reconstruído somente com as IC que contêm o EEG.

Um grande problema do uso da ICA, disponibilizada pelo EEGLAB, para detecção e remoção de artefato é ser um método semiautomático, necessitando de intervenção manual para a rejeição das IC contaminadas de artefato (ISLAM;

RASTEGARNIA; YANG, 2016).

Dentre os métodos de ICA, serão explicadas as técnicas que, além de estarem disponíveis no EEGLAB, são as mais utilizadas na redução de artefatos de EEG, e foram as aplicadas neste trabalho. São elas: *Infomax* e SOBI.

3.6.1.1 Infomax

A técnica Infomax foi aplicada em sinais de EEG pela primeira vez em 1998 por Makeig e Jung (JUNG et al., 1998), e como uma implementação de ICA, se baseia em estatísticas de ordem superior (HOS, do inglês *Higher Order Statistics*) e funções de densidade de probabilidade das fontes (assumindo sua distribuição não gaussiana) (BELOUHRANI et al., 1997).

O algoritmo Infomax, conceito implementado por uma rede neural artificial (RNA) não supervisionada, procura encontrar uma matriz de separação para os dados de entrada minimizando-se a informação mútua entre as variáveis aleatórias resultantes da transformação linear dos sinais misturados (IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 2013). Esse processo é realizado pela maximização da entropia conjunta dos dados, ou seja, pela definição da função de mapeamento da última camada da sua RNA como uma função sigmoideal que, em geral, permite a minimização de dependências estatísticas entre as variáveis de entrada (JUNG et al., 1998).

3.6.1.2 SOBI

O SOBI (do inglês, *Second-Order Blind Identification*), algoritmo proposto por Belouchrani et al. (BELOUHRANI et al., 1997) em 1997, emprega estatísticas de segunda ordem (SOS, do inglês, *Second-Order Statistics*) para realização da ICA. Essa técnica utiliza a diagonalização conjunta de um conjunto específico de matrizes de covariância (JOYCE; GORODNITSKY; KUTAS, 2004). Shoker et al. (SHOKER; SANEI; CHAMBERS, 2005) utilizaram esse algoritmo nos sinais de EEG em 2005.

A base do mecanismo de funcionamento do SOBI é a diagonalização das matrizes de correlação defasadas (SAHONERO; CALDERON, 2017), ou seja, a decorrelação dessas matrizes ao longo de pontos no tempo.

Tal procedimento é desenvolvido em três etapas: (a) Branqueamento dos Sinais, responsável por transformar linearmente a matriz de covariância de forma que uma nova matriz tenha componentes descorrelacionadas e variâncias unitárias (HYVÄRINEN; OJA, 2000); (b) Determinação do Fator Unitário, que encontra a transformação unitária que tornará possível o próximo passo;

E (c) Diagonalização Conjunta, que minimiza, por transformação unitária, a soma dos quadrados dos módulos de todos os termos fora da diagonal principal da matriz de covariância.

Apesar do bom desempenho, as técnicas de ICA apresentam três principais problemas: dependerem de algum critério externo para a seleção das suas Componentes Independentes a serem removidas (URIGÜEN; GARCIA-ZAPIRAIN, 2015), demandarem grande tempo computacional (DELORME; SEJNOWSKI; MAKEIG, 2007) e apresentarem dificuldade em lidar com contaminação bidirecional (ISLAM; RASTEGARNIA; YANG, 2016). Essas dificuldades podem ser mitigadas ao se combinar a ICA com outras técnicas (JIANG; BIAN; TIAN, 2019, URIGÜEN; GARCIA-ZAPIRAIN, 2015).

3.6.2 Transformada Wavelet

A transformada Wavelet discreta (DWT, do inglês *Discrete Wavelet Transform*) decompõe o sinal de entrada $x[n]$ inúmeras vezes em componentes de resolução inferior, com o uso de banco de filtros digitais (ORMIGA GALVAO BARBOSA, 2010). O banco de filtros é composto por um par de filtros: um filtro passa-baixas ($H_L[n]$, responsável pelos coeficientes de aproximação), e um filtro passa-altas ($H_H[n]$, responsável pelos coeficientes de detalhe) (ORMIGA GALVAO BARBOSA, 2010). A saída dos filtros é subamostrada por um fator de 2. Para fazer a decomposição em mais níveis, basta passar a saída do filtro passa-baixas (as aproximações) por um novo banco de filtros e decimá-lo em seguida. Este processo pode ser repetido quantas vezes forem necessárias, como mostra a Figura 3.7.

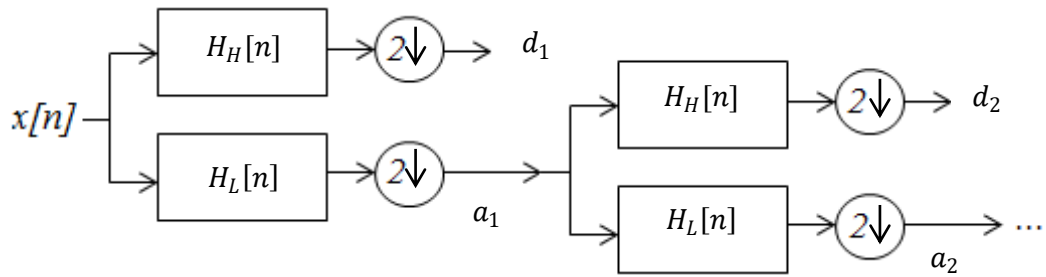


Figura 3.7 - Exemplo da DWT com dois níveis de decomposição. Autoria Própria

Após ser decomposto em aproximação e detalhe, um limiar é aplicado nesses coeficientes para suavizar os artefatos (ISLAM; RASTEGARNIA; YANG, 2016).

Apesar da versatilidade para atenuar os artefatos, a DWT não é completamente eficaz na identificação de um sinal que contém superposição espectral com artefato (JIANG; BIAN; TIAN, 2019). Por isso, a DWT é combinada com métodos de separação de fontes (BSS). Outra deficiência que se mantém, apesar de não se encontrar no escopo do presente trabalho, é a não realização *online* (JIANG; BIAN; TIAN, 2019, URIGÜEN; GARCIA-ZAPIRAIN, 2015).

A fim de resolver os problemas da necessidade de um canal de referência e pela característica de não estacionaridade do EEG, a partir dos anos 1990 (UNSER; ALDROUBI, 1996), desenvolveu-se um método, chamado de *Blind Source Separation* (BSS), capaz de fornecer resolução proporcional em cada faixa de frequência adequada para sinais de EEG (ISLAM; RASTEGARNIA; YANG, 2016).

3.6.3 Wavelet-ICA

A técnica Wavelet-ICA (wICA) foi proposta em (AZZERBONI et al., 2004) para combinar aspectos positivos dos dois algoritmos. A ideia central do algoritmo wICA é analisar a independência estatística somente dos dados provenientes da DWT. Na aplicação com dados de EEG, a wICA é capaz de minimizar a contaminação bidirecional com vEOG, ao incluir a DWT na etapa de pré-processamento da ICA.

A Figura 3.8 ilustra as principais etapas desse método, que são: (a) decomposição Wavelet em cada canal de gravação do EEG; (b) identificação e seleção do sinal corrompido por artefato em cada canal; (c) ICA nos sinais selecionados; (d) reconstrução dos sinais sem componentes de artefato provenientes da ICA; e, finalmente, (e) reconstrução Wavelet para cada canal. A forma como as etapas foram executadas serão esclarecidas no Capítulo 4.

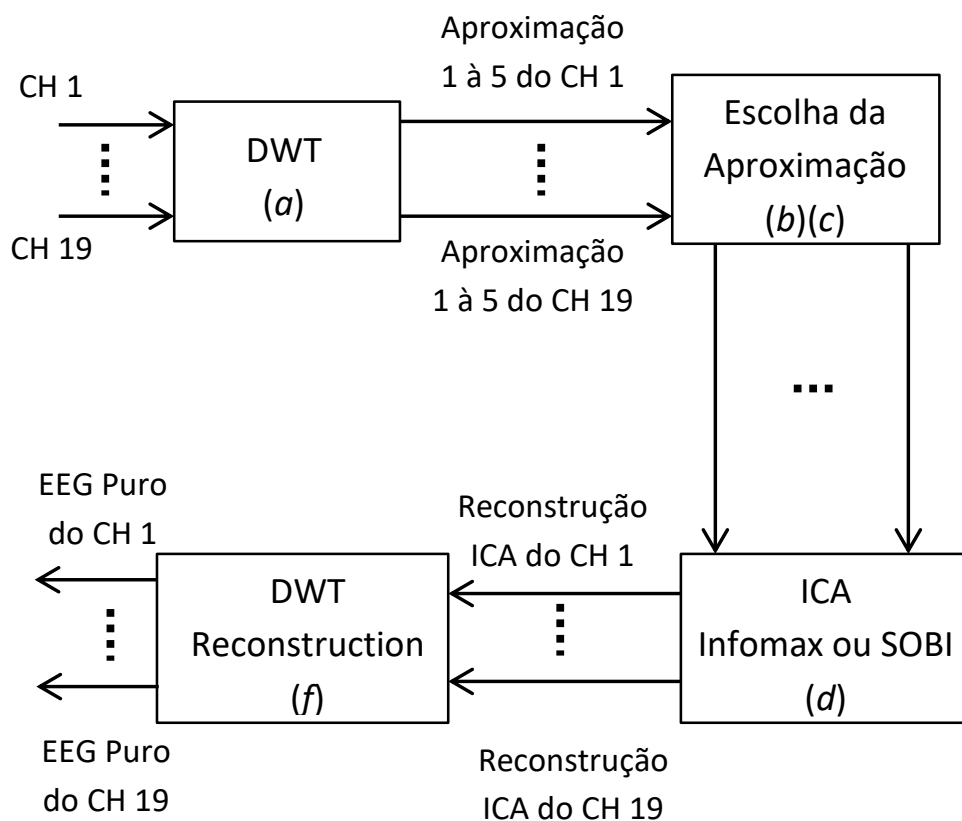


Figura 3.8 Esquemático da Implementação do Método Wavelet-ICA. Autoria Própria.

3.6.4 Métodos de Filtragem

Diversos métodos de filtragem foram empregados no cancelamento de artefatos do EEG. Esta seção se atém aos métodos que visam a minimizar o erro quadrático médio entre o sinal de saída e o sinal desejado.

3.6.4.1 Filtro de Wiener

Filtro de Wiener é um filtro linear ótimo, usado para remoção de artefato para diminuir o erro quadrático médio entre o EEG puro e o EEG com artefatos. Este método de filtragem consiste em passar uma entrada $x[n]$, o canal de vEOG, por um filtro linear invariante no tempo para obter uma saída $y[n]$, a estimativa do artefato que contamina o EEG puro. O sinal de saída $y[n]$ é, então, comparado a um sinal desejado $d[y]$, o EEG contaminado.

A diferença entre o sinal de saída e o desejado, mostrada na equação 3, é chamada erro de estimação, que, neste caso, é a estimativa do EEG puro. Quanto menor for o erro estimado, mais próximo $y[n]$ estará de $d[n]$. O filtro de Wiener está representado na Figura 3.9.




Figura 3.9- Diagrama de Blocos do Filtro de Wiener.

Como não há informações *a priori* sobre as estatísticas dos sinais utilizados, o filtro é calculado pela estimativa das densidades espectrais de potência do sinal medido e do artefato (JIANG; BIAN; TIAN, 2019; SOMERS; FRANCART; BERTRAND, 2018). Além da necessidade de um canal de referência extra, este método não pode ser aplicado de forma *online*, pois requer uma grande quantidade de dados para se estimarem as densidades espectrais (HAYKIN, 2014).

$$e[n] = y[n] - d[n] \quad (3)$$

3.6.4.2 Filtro Adaptativo

A filtragem adaptativa proposta por Haykin (HAYKIN, 2014) em 1996 foi empregada em sinais de EEG em 2004 por He, Wilson e Russel (HE; WILSON;

RUSSELL, 2004). Mesmo sendo um sistema linear, o filtro adaptativo difere do filtro de Wiener em alguns pontos.

O primeiro deles é a possibilidade da realização *online*. O segundo ponto é a capacidade de atualização de pesos da sua função de transferência necessária para otimização do filtro feita por um tipo de algoritmo específico (ALEXANDER, 2012; ISLAM; RASTEGARNIA; YANG, 2016).

Os pesos do filtro se adaptam com base na realimentação da saída do sistema, $e[n]$, pela comparação entre a saída desejada (estimativa de EEG contaminado por artefato) e a saída observada (EEG contaminado por artefato). O diagrama de blocos do Filtro Adaptativo está esquematizado na Figura 3.10.

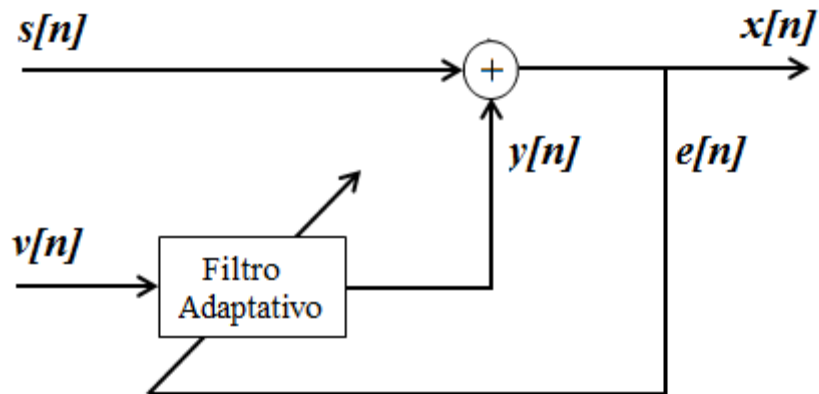


Figura 3.10 - Diagrama de blocos do Filtro Adaptativo.

A entrada $s[n]$ do sistema é representada pelo EEG puro somado ao ruído que se deseja filtrar, como mostra a equação 4. Onde $f[n]$ representa o sinal de EEG puro, e $o[n]$ o sinal de artefato.

$$s[n] = f[n] + o[n] \quad (4)$$

O canal de referência que contém o EOG é denotado por $v[n]$. O filtro adaptativo usa algoritmos baseados na diminuição do erro quadrático médio, tal como LMS (do inglês, *Least-Mean-Squares*).

Então, de forma geral, esse método atualiza um vetor de pesos de acordo com um algoritmo de adaptação, de forma que tais pesos modelam a contaminação de artefato nos canais de EEG, e assim, o subtraem do sinal $s[n]$ (JIANG; BIAN; TIAN, 2019; MARQUE et al., 2005).

Além da necessidade do canal de referência, esse método de redução de artefato, ao utilizar o EOG para tal fim, cancela uma grande porção de atividade neural (CAGY; CAGY; INFANTOSI, 2011).

4 Materiais e Métodos

O trabalho foi realizado em três etapas. A primeira foi a de aplicação dos métodos (Infomax, SOBI, Wavelet-Infomax, Wavelet-SOBI e Filtragem Adaptativa) para os sinais do banco de dados disponibilizado em KLADOS; BAMIDIS (2016). A segunda etapa foi o cálculo dos MSE e da correlação entre o sinal recuperado por cada um dos cinco métodos e o sinal de EEG livre de contaminação por artefatos de piscada de olhos. E, por fim, a terceira foi o cálculo do parâmetro %DIF para MSE e correlação.

4.1 Remoção de artefato para ICM

A necessidade da atenuação de artefato de piscada de olhos em sinais de EEG para aplicação de tais sinais no controle de ICM é amplamente discutida na literatura, como mostra o trabalho de ALLISON et al. (2013). Nesse sentido, discute-se qual dessas técnicas oferece o sinal cortical reconstruído mais similar ao sinal original livre de artefato, pois esse é um fator crucial para o controle correto de uma ICM.

O trabalho de REJER; GÓRSKI (2013) aplicou o método Infomax para remoção de artefatos de EOG em um conjunto de dados EEG de um sujeito normal (mulher, 25 anos) cuja tarefa era controlar os movimentos de uma barra de *feedback* por meio de movimentos de imagem da mão esquerda e direita. O algoritmo Infomax aumentou a precisão de classificação da IMC em 87,6%, enquanto outras variações de ICA (FastICA) obtiveram precisões menores.

O trabalho de XIAO; HU (2008) também encontrou resultados promissores no controle da ICM empregando o algoritmo SOBI para remoção dos artefatos nos sinais de EEG para dados de um grupo de indivíduos normais que tinham como tarefa imaginar movimentos da mão esquerda ou da mão direita de acordo com um aviso sinalizado em um monitor. O incremento de desempenho (classificação) da ICM variou de 70% e 92,6% entre os sujeitos. Resultados similares foram encontrados por WANG et al. (2011) ao usar SOBI para remover artefatos de EEG em dados de voluntários que tinham como tarefa imaginar o movimento da mão esquerda, mão direita ou pé direito seguindo pistas dadas em um monitor. WANG et al. (2011) obteve acurácia de classificação da ICM de, pelo menos, 66,6%.

FOLGUERAS MÉNDEZ et al. (2013) usou a Filtragem Adaptativa para redução de artefatos de EEG durante a detecção de SSVEP para uma ICM em tempo real. Os dados foram adquiridos de um grupo de 5 indivíduos saudáveis (média de idade de 31 anos e uma mulher) sem experiência prévia com a ICM. O desempenho médio na acurácia da classificação da ICM foi de 50,8% a 81,1%.

Apesar da ênfase dada na literatura para a melhora na classificação da ICM ao se removerem os artefatos de EEG, tais trabalhos não especificam a qualidade dos sinais recuperados, em termos de similaridade com os sinais livres de contaminação, e não fazem menção à perda de sinal cortical do sinal pre-processado.

Outras técnicas para atenuação de artefatos de piscada em sinais de EEG são apresentadas nos trabalhos de WANG (2011), HALDER et al. (2007) e PAPADELIS et al. (2007) que aplicam tal etapa de processamento em ICM no planejamento de movimento (WANG; JUNG, 2011), imagética motora (HALDER et al., 2007) e monitoramento do sono (PAPADELIS et al., 2007), respectivamente.

4.2 Sinais de EEG

Os dados experimentais de EEG utilizados fazem parte de um banco de dados disponibilizado na Internet por KLADOS; BAMIDIS (2016). Vinte e sete indivíduos saudáveis de ambos os sexos (14 homens) foram selecionados com média de idades de 27,7 anos.

Cada sessão de aquisição de dados foi realizada duas vezes, resultando em um banco de dados com 54 sinais EEG diferentes, todos utilizados neste trabalho. A aquisição dos sinais foi dividida em três estágios. No primeiro deles, o EEG foi registrado com olhos fechados em uma única sessão, na qual 19 eletrodos foram posicionados de acordo com o sistema internacional 10-20. Em seguida, registraram-se, com protocolo de olhos abertos, os sinais de eletro-oculograma vertical (vEOG) e do eletro-oculograma horizontal (hEOG), dispondo-se para tal um par de eletrodos acima e abaixo do olho esquerdo e outro par no canto externo de cada olho, respectivamente.

Os sinais médios (soma dos sinais dos 54 indivíduos, dividida pela quantidade de indivíduos) para cada canal foram dispostos na Figura 4.1.




Figura 4.1- Média por canal dos sinais de EEG contaminados por EOG dos 57 indivíduos que compõem o banco de dados, seguido pelos sinais médios de vEOG e hEOG.

A Figura 4.2 dispõe o *box-plot* dos sinais dos canais Fp1, Fp2, F3, F4, C3 e C4 para os dados anteriores, assim como mostra a média do sinal desses canais para um dos indivíduos presente no banco de dados. Os mesmos dados são dispostos na Figura 4.3 para os sinais médios dos canais P3, P4, O1, O2, F7 e F8. Os sinais médios dos 19 canais são constituídos por 5401 amostras.

Na Figura 4.2, foi visto que, 50% das médias dos sinais do canal Fp1 estão entre os valores -5,13 e 3,14. Para o canal Fp2, os limiares interquartis são -4,28 e 4,09. E, para os canais F3, F4, C3 e C4, esse intervalo está entre os valores, respectivamente, -1,94 e 1,65, -1,35 e 2,31, -1,39 e 1,36. Para tal conjunto de canais, a menor quantidade de *outliers* foi vista no canal Fp1, 0,002% em as amostras do sinal médio para tal canal. A maior quantidade de *outliers* foi vista no canal C4, com 0,028%.




Figura 4. 2- Box-plot da distribuição dos sinais médios de EEG contaminados por EOG para os canais Fp1, Fp2, F3, F4, C3 e C4.

Nota-se, na Figura 4.3, que, para o canal P3, metade das médias individuais está alocada no intervalo entre -1,82 e 0,83. Os intervalos, respectivamente, foram definidos entre -0,51 e 2,34, -1,78 e 9,52, -1,46 e 1,28, -3,20 e 0,93, -2,55, para os sinais médios nos canais P4, O1, O2, F7 e F8. Entre esses canais, a maior quantidade de *outliers*, 0,023% da amostra, é dada no canal F8, enquanto a menor quantidade de *outliers*, 0,002%, é vista no canal F7.




Figura 4. 3- Box plot da distribuição dos sinais médios de EEG contaminados por EOG para os canais

P3, P4, O1, O2, F7 e F8.

A Figura 4.4 mostra, novamente, a distribuição dos sinais médios em forma de *box-plot*, agora para os sinais dos canais T3, T4, T5, T6, Fz, Cz e Pz. Nesse conjunto de canais, a maior percentagem de *outliers*, 0,024%, é percebida no sinal do canal T4, enquanto a menor percentagem, 0,003%, é vista no canal T3. Em tal canal, os limites do intervalo interquartil são -0,71 e 1,26. Para os canais T4, T5, T6, Fz, Cz e Pz, os valores são, respectivamente, -0,59 e 1,64, -1,45 e 0,55, 0 e 2,02, -3,07 e 1,25, -1,34 e 1,87, -2,31 e 0,93.

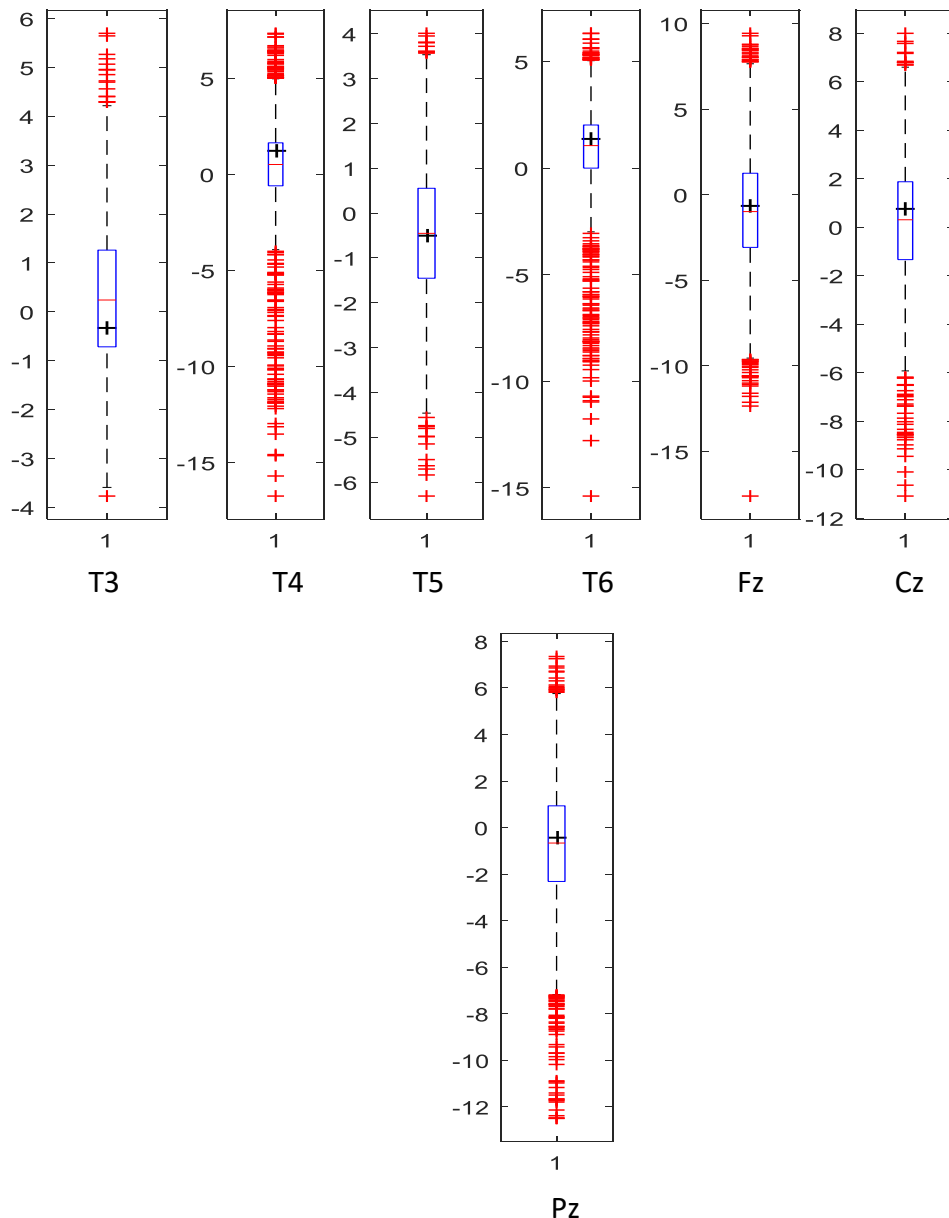


Figura 4. 4- Box-plot da distribuição dos sinais médios de EEG contaminados por EOG para os canais T3, T4, T5, T6, Fz, Cz e Pz.

A fim de exemplificar e analisar de forma mais detalhada os resultados dos algoritmos propostos para remoção de EOG dos dados de EEG, as 5 técnicas foram aplicadas para os sinais de um indivíduo escolhido aleatoriamente, do banco de dados. Entretanto, foi necessário verificar se o indivíduo escolhido representava o conjunto de dados de forma adequada. Para isso, a média dos sinais desse indivíduo não poderiam ser *outliers* na distribuição dos dados, e, cumprindo esse requisito, seus valores deveriam estar próximos à mediana da distribuição para cada canal analisado. A média do sinal de cada canal foi disposta (como uma cruz preta) na distribuição do respectivo canal na Figura 4.2, na Figura 4.3 e na Figura 4.4. Como os valores médios dos sinais do indivíduo escolhido não foram *outliers* em nenhum dos canais, e, uma vez que, esses valores não apresentaram grande dispersão em relação à mediana das distribuições para a maioria dos canais, o indivíduo foi escolhido como um representante típico do conjunto de dados.

Os sinais desse indivíduo estão ilustrados na Figura 4. 5.

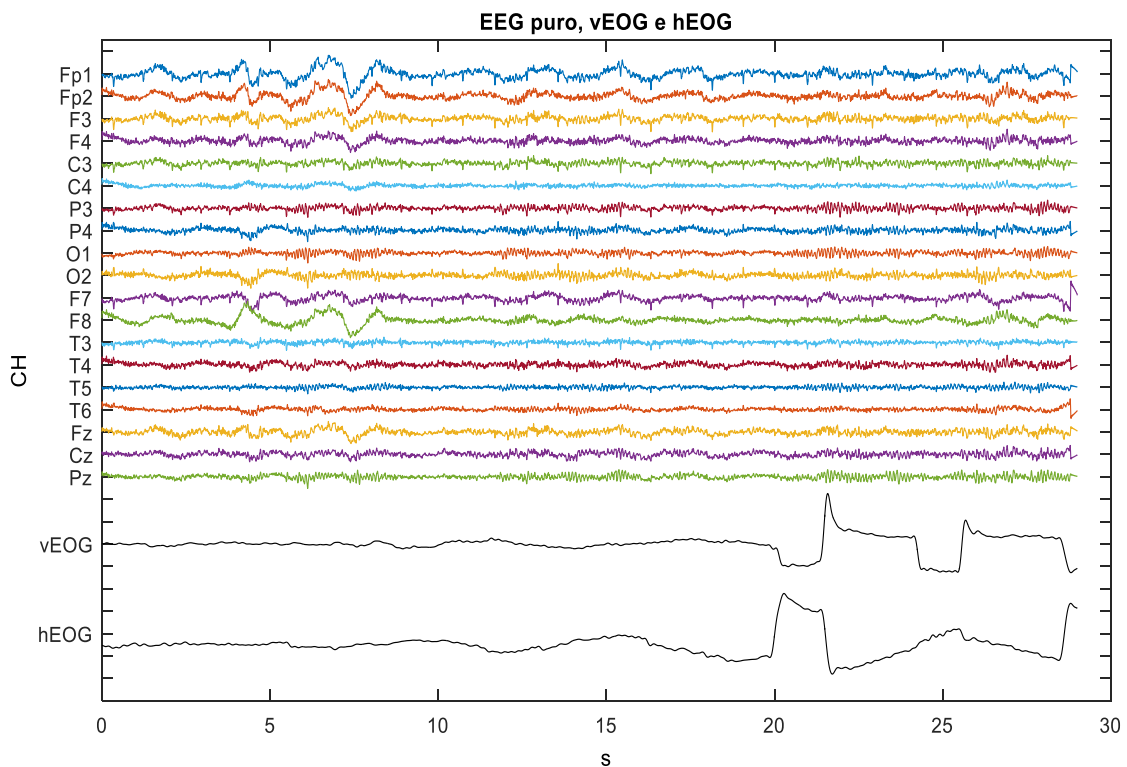


Figura 4.5- Dados de EEG sinal de interesse sem o piscar de olhos, adquirido com os olhos fechados do Indivíduo 5. Disponível em (KLADOS; BAMIDIS, 2016).

Finalmente, a contaminação dos dois conjuntos de dados das etapas anteriores foi efetuada manualmente. Todos os sinais apresentam duração de 30 segundos, tendo sido amostrados a uma taxa de 200 Hz e passados por um filtro rejeita faixa centrado em 50 Hz. Os sinais de EOG e EEG foram submetidos à filtragem analógica com banda de passagem entre 0,5 e 5 Hz, e 0,5 a 40 Hz (LINS et al., 1993), respectivamente. Os sinais resultantes da contaminação, do mesmo indivíduo, estão ilustrados na Figura 4.6.

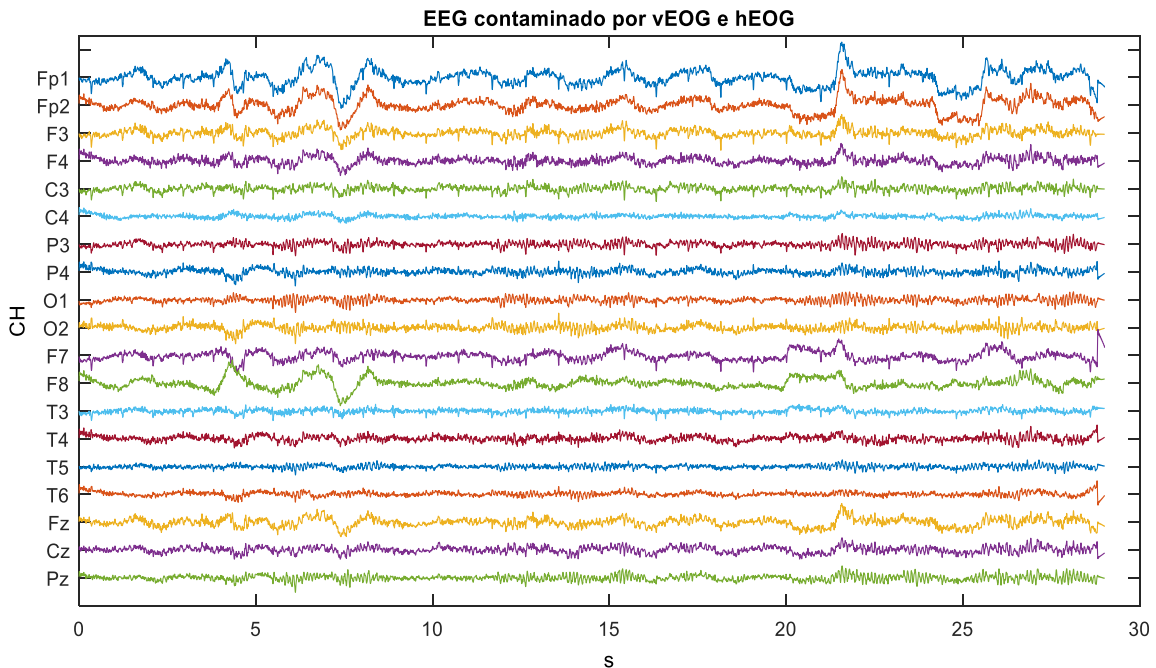


Figura 4.6- Dados de EEG contaminado por EOG do indivíduo 5. Disponível em (KLADOS; BAMIDIS, 2016).

Os sinais de EEG contaminados por EOG já haviam sido previamente disponibilizados na base de dados com a mistura linear entre os sinais de EEG livres de artefato e os sinais de EOG. A contaminação por sinais de EOG, realizada por KLADOS; BAMIDIS (2016) em sua base de dados, foi feita artificialmente por um modelo proposto em ELBERT et al. (1985). O modelo misturou linearmente cada canal com o vEOG e o hEOG, por uma matriz de mistura com pesos específicos para vEOG e para hEOG, onde cada canal recebeu um peso diferente calculado por regressão linear (DELORME; SEJNOWSKI; MAKEIG, 2007).

4.3 Técnicas ICA

As duas técnicas ICA (Infomax e SOBI) foram aplicadas aos 19 canais de EEG para todos os indivíduos. Na execução da ICA, o sinal de entrada foi composto por uma matriz $[21 \times N]$, onde a primeira coluna foi formada pelo sinal de vEOG, a segunda coluna formada pelo canal de hEOG e as colunas seguintes formadas pelos canais Fp1, Fp2, F3, F4, C3, C4, P3, P4, O1, O2, F7, F8, T5, T4, T5, T6, Fz, Cz e Pz, respectivamente. Este procedimento foi repetido para as 54 gravações de EEG. A inclusão dos sinais provenientes dos canais de EOG nas análises ICA, diferindo da ICA padrão que não utiliza os sinais de artefato, é uma configuração disponível no EEGLAB que os usa como melhores marcadores para artefatos EOG (MIYAKOSHI, 2019).

As técnicas Infomax e SOBI foram implementadas pelas funções *runica()* e *sobi()*, respectivamente, da caixa de ferramentas EEGLAB v. 5.3 (DELORME; MAKEIG, 2004).

4.4 Técnica wICA

As aplicações dos algoritmos wICA (Wavelet-Infomax e Wavelet-SOBI) foram divididas nas seguintes etapas: (a) decomposição da DWT. Os sinais foram decompostos até o nível 7, entretanto, o nível considerado como ótimo para decomposição foi nível anterior àquele que apresentou incremento no MSE entre os sinais decompostos e os sinais originais. Como os níveis 6 e 7 apresentaram aumento de MSE, o nível 5 foi o escolhido; (b) correlação entre as 5 aproximações e o sinal vEOG; (c) seleção, dentre as 5 aproximações, daquela com maior correlação com o sinal vEOG, para acentuar a independência entre o EEG e o EOG e, assim garantir o melhor desempenho da extração do EOG pelos métodos ICA; (d) atribuição da abordagem selecionada como uma das entradas da ICA (Infomax e SOBI), juntamente com o vEOG e o hEOG; (e) reconstrução da abordagem sem componentes de artefatos; e, finalmente, (f) reconstrução da DWT com seus respectivos detalhes. As 6 etapas foram realizadas para os 19 canais de gravação de EEG de cada um dos 54 indivíduos.

Nos algoritmos wICA, a oitava Symlet, devido à sua similaridade morfológica com o sinal do artefato, foi a função mãe-*wavelet* aplicada à decomposição e reconstrução da DWT. Além disso, nos métodos wICA, a escolha da abordagem com maior correlação com o sinal vEOG foi a abordagem inicial para a seleção da entrada da ICA, que pode ser alterada após o procedimento. Ao lidar com reconstruções da ICA, tanto em suas aplicações simples quanto no wICA, os artefatos de EOG foram agrupados no primeiro e no segundo componentes, de modo que apenas os componentes 3 a 21 foram mantidos.

4.5 Métodos de Filtragem

Para a aplicação da Filtragem adaptativa, em um primeiro filtro, o sinal de entrada é definido como o EEG contaminado por simulação (um único canal de um só indivíduo) e o sinal de referência como o vEOG (do mesmo indivíduo). Logo, o erro representará a estimativa de EEG livre de contaminação de vEOG para aquele canal. Em um segundo filtro, o sinal de referência é dado pelo sinal de hEOG (do mesmo indivíduo), e a entrada do filtro é dada pelo erro obtido na filtragem anterior. Desse modo, o erro representou o sinal de EEG sem contaminação de vEOG e hEOG de um canal específico. O procedimento foi realizado para os 19 canais de todos os indivíduos que compõe a base de dados.

Também foi incluído, na primeira etapa da filtragem, um banco de filtros para determinação da ordem (2, 3, 4 ou 5) de filtragem. Nesse caso, a ordem ótima para filtro foi aquela que apresentou como resultado o menor MSE entre o erro do filtro e o sinal de EEG livre de piscada de olhos.

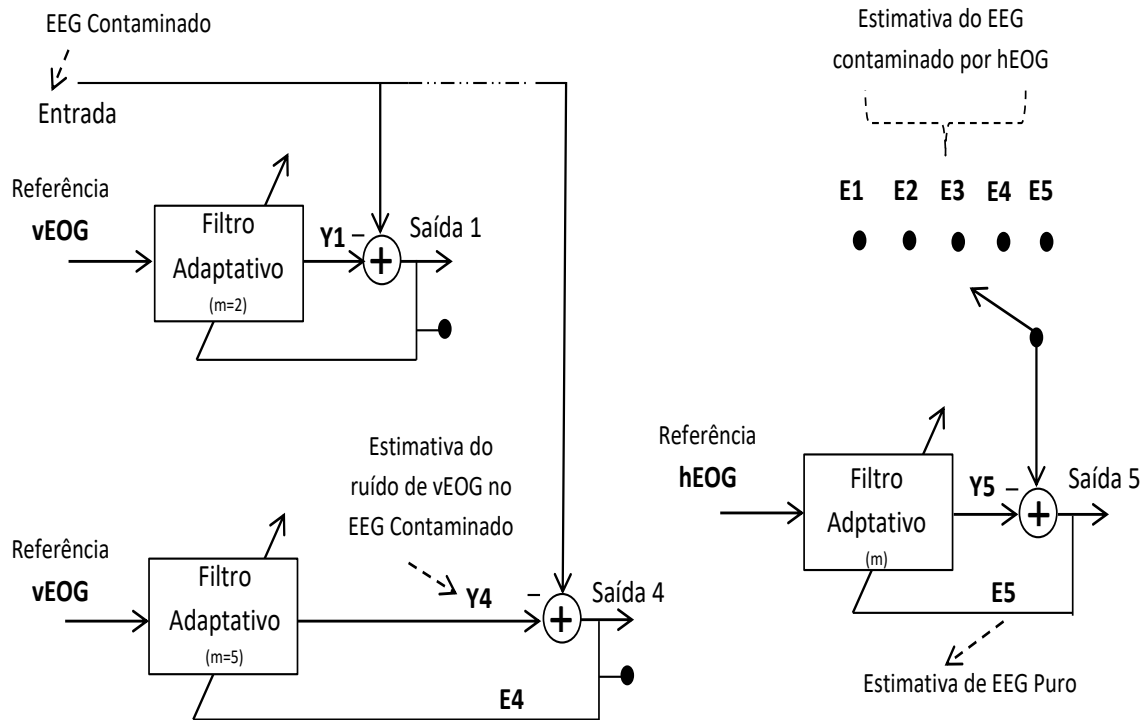


Figura 4.7 - Esquemático da implementação do banco de filtros para Filtragem Adaptativa. Autoria Própria.

4.6 Metodologia de avaliação

Para comparar os métodos e determinar qual deles apresentava o melhor desempenho, o critério analisado foi similaridade (SAHONERO; CALDERON, 2017) entre os sinais reconstruídos e o registro EEG original no protocolo de olhos fechados (EEG sem contaminação do artefato EOG). A fim de mensurar a similaridade, foram calculados dois parâmetros já conhecidos na literatura (SAHONERO; CALDERON, 2017; (MANNAN; JEONG; KAMRAN, 2016) para tal situação. Os parâmetros são: a correlação (pelo grau de coeficiente de correlação, proposto em (HAUKE; KOSSOWSKI, 2011)) e o erro quadrático médio padronizado (pela variação do sinal EEG não contaminado).

O erro quadrático médio (MSE, do inglês *Mean Squared Error*) é uma medida de qualidade que calcula o quadrado da diferença entre duas variáveis.

O MSE é sensível a *outliers*, ou seja, pune erros maiores mais que penaliza diferenças maiores entre o valor real de uma variável e sua estimação. Então, são buscados os menores valores de MSE.

A correlação, dada pelo coeficiente de Pearson, aponta o grau de relação linear entre duas variáveis (HAUKE; KOSSOWSKI, 2011) ao variar de -1 a 1, de forma que quanto mais linearmente relacionadas são as variáveis, mais próximo da unidade está o módulo do valor do coeficiente (SAHONERO; CALDERON, 2017). Ou seja, quanto mais próxima da unidade for a correlação, mais similares são os sinais por ela analisados. Como, nessa aplicação, a correlação linear e a forma dos sinais são os principais pontos de análise, tendo sido considerados os valores absolutos de correlação. O uso da correlação como parâmetro de análise é justificado pela natureza gaussiana do EEG. A gaussianidade do EEG, a contraponto da natureza não-gaussiana dos artefatos, (JIANG; BIAN; TIAN, 2019) é o que permite que os algoritmos (por exemplo ICA) removam o sinal de EOG (SAHONERO; CALDERON, 2017).

Para determinar qual algoritmo apresentou melhor desempenho na recuperação dos sinais de EEG livres de artefato, foi necessário aplicar a função desenvolvida em (SAHONERO; CALDERON, 2017) que utiliza dois parâmetros numéricos para tal definição. A função foi aplicada para a correlação e para o MSE como mostram, respectivamente, a Equação 5 e a Equação 6.

$$\%Dif = 100 \left| \frac{Correlação_x}{\max(Corr_{ICA}, Corr_{wICA}, Corr_{SOBI}, Corr_{wSOBI}, Corr_{Filtro})} - 1 \right| \quad (5)$$

$$\%Dif = 100 \left| \frac{MSE_x}{\min(MSE_{ICA}, MSE_{wICA}, MSE_{SOBI}, MSE_{wSOBI}, MSE_{Filtro})} - 1 \right| \quad (6)$$

Nesse sentido, diz-se que o algoritmo “x” obteve melhor performance, quando comparado aos outros métodos, se o par de diferenças (%Dif de MSE e %Dif de correlação) for o par ótimo (MSE mínimo e correlação máxima) entre o conjunto de diferenças computados.

Estes procedimentos foram repetidos para os sinais recuperados dos 19 canais dos 54 registros EEG e para os cinco métodos (ICA-Infomax, ICA-SOBI, w-Infomax, w-SOBI e filtragem adaptativa). Ou seja, o sinal de cada canal foi analisado separadamente.

5 Resultados

Neste capítulo, são apresentados os resultados obtidos pela metodologia proposta no capítulo anterior das cinco técnicas apresentadas para redução de artefato nos sinais de EEG. Além disso, para fins de ilustração, dentre os 54 voluntários analisados, o indivíduo de número 5 foi escolhido aleatoriamente, e seus sinais são mostrados graficamente.

5.1 Resultado Individual

Na aplicação dos algoritmos *Wavelet*-ICA, durante a decomposição *Wavelet*, os sinais de EEG nos canais Fp1, Fp2 e F3 apresentaram menor MSE na resolução de nível 3, enquanto os sinais dos canais F4, C4, P4, O2, F7, F8, T3, T4, T5, T6 e Fz obtiveram tal resultado com resolução de nível 2, e, para os sinais dos canais C3, P3, O1, Cz e Pz, a resolução foi no nível 5.

Na utilização da Filtragem Adaptativa, a ordem ótima dos filtros foi 2 para os sinais dos canais Fp2, F3, F4, C3, C4, F7, F8, T3, T4, T6 e Cz. Para os demais canais (Fp1, P3, P4, O1, O2, T5, Fz e Pz), a ordem ótima foi a 5.

A Figura 5.1 mostra os sinais dos 19 canais reconstruídos pela Infomax para o voluntário 5, enquanto a Figura 5.2 mostra os canais reconstruídos pela *Wavelet*-Infomax para o mesmo indivíduo.

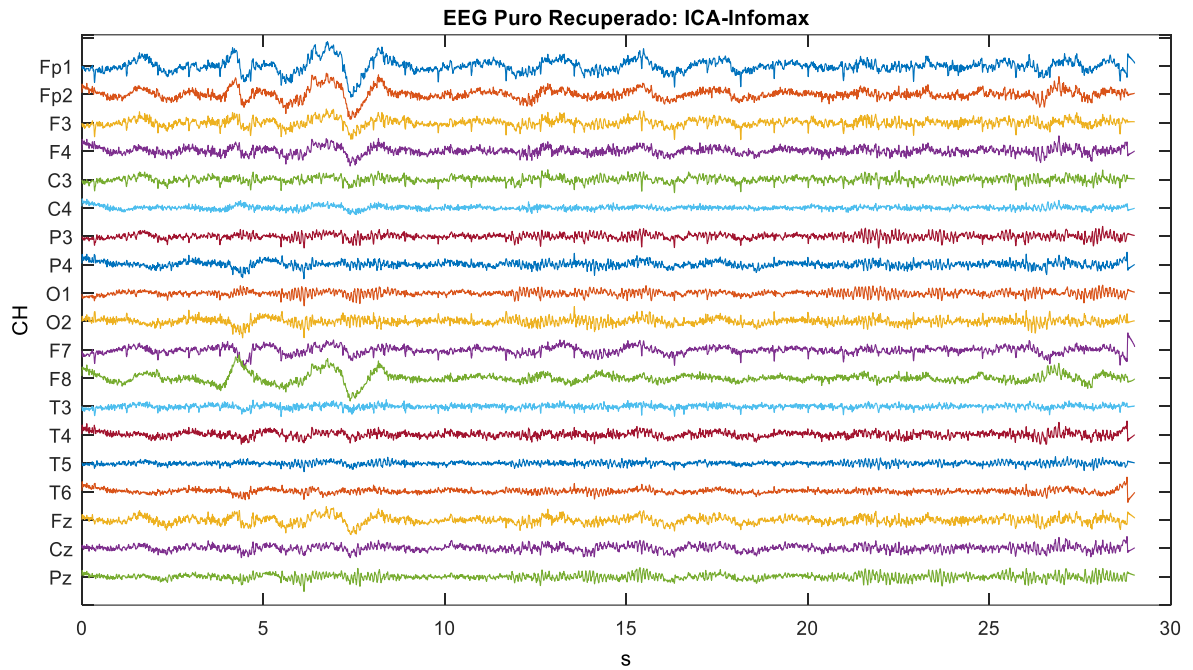


Figura 5.1 - Dados de EEG do indivíduo 5 recuperados por Infomax.




Figura 5.2- Dados de EEG do indivíduo 5 recuperados por Wavelet-Infomax.

A Figura 5.3 mostra os sinais dos 19 canais reconstruídos por SOBI para o indivíduo 5, e a Figura 5.4 mostra a reconstrução por Wavelet-SOBI.

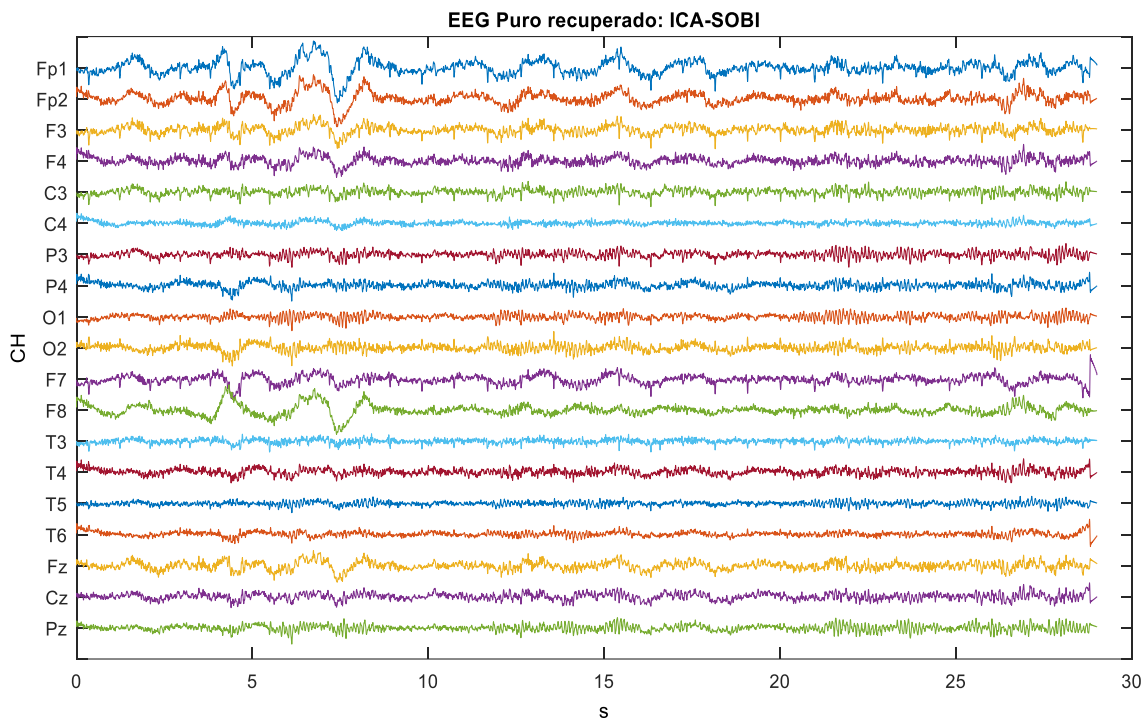


Figura 5.3 - Dados de EEG do indivíduo 5 recuperados por SOBI.

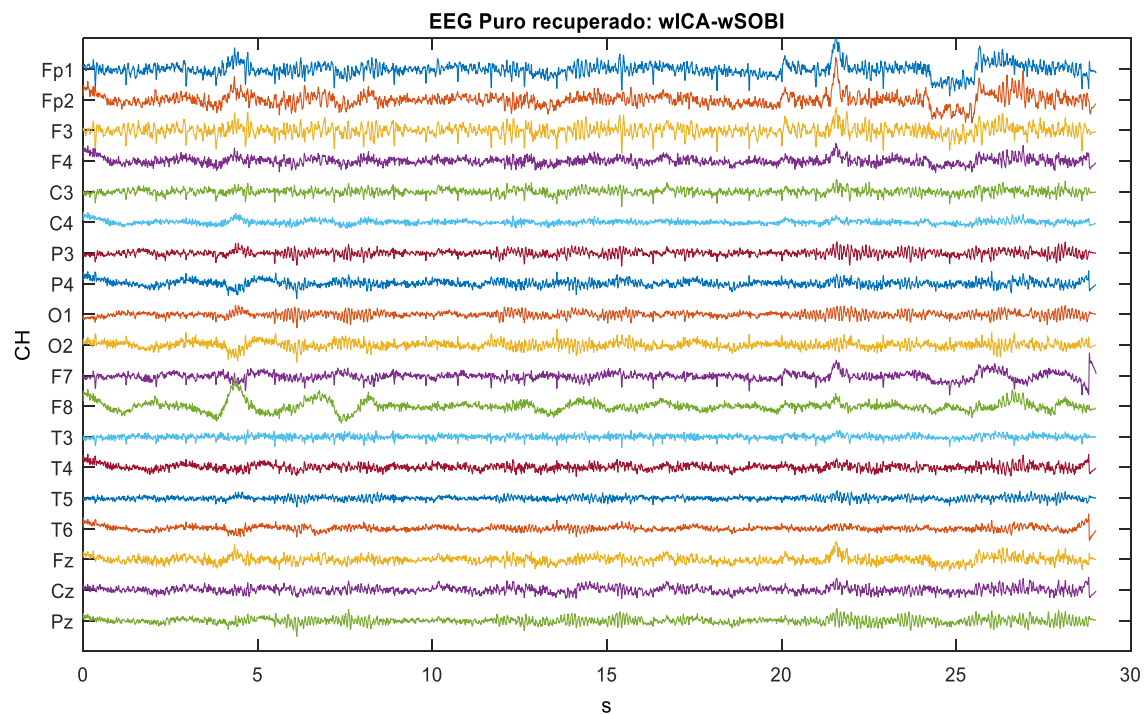


Figura 5.4- Dados de EEG do indivíduo 5 recuperados por Wavelet-SOBI.

A Figura 5.5 mostra os sinais dos 19 canais reconstruídos por Filtragem Adaptativa para o indivíduo 5.




Figura 5.5- Dados de EEG do indivíduo 5 recuperados por Filtragem Adaptativa.

A Tabela 5.1 e a Tabela 5.2 mostram, respectivamente, para o indivíduo número 5, os valores de correlação e MSE de cada um dos 19 canais, e os valores do parâmetro %Dif de correlação e MSE no mesmo cenário.

Tabela 5.1 – Resumo dos Resultados de Correlação e MSE para o Indivíduo 5.

Canais	Valores Correlação Normalizados pelo δ					Valores MSE Normalizados				
	Infomax	w-Infomax	SOBI	w-SOBI	Filtro	Infomax	w-Infomax	SOBI	w-SOBI	Filtro
Fp1	0,9709	0,9696	0,9962	0,3155	0,9839	0,0062	0,0111	0,0110	1,2441	0,0001
Fp2	0,9654	0,9542	0,9933	0,4046	0,9513	0,0072	0,0144	0,0197	1,3355	0,0002
F3	0,9722	0,9403	0,9976	0,6805	0,9746	0,0058	0,0071	0,0054	0,8775	0,0003
F4	0,9733	0,9963	0,9965	0,7535	0,9700	0,0040	0,0044	0,0057	0,3470	0,0001
C3	0,9755	0,9957	0,9987	0,8902	0,9890	0,0049	0,0030	0,0027	0,2110	0,0001
C4	0,9524	0,9950	0,9970	0,9149	0,9662	0,0066	0,0069	0,0041	0,1197	0,0008
P3	0,9747	0,9971	0,9992	0,9438	0,9942	0,0038	0,0011	0,0012	0,0844	0,0002
P4	0,9504	0,9942	0,9976	0,9646	0,9871	0,0072	0,0054	0,0035	0,0509	0,2012
O1	0,9472	0,9937	0,9988	0,9820	0,9921	0,0191	0,0003	0,0045	0,0649	0,0005
O2	0,9621	0,9950	0,9985	0,9853	0,9918	0,0076	0,0066	0,0031	0,0292	0,0002
F7	0,9743	0,9758	0,9955	0,7048	0,9363	0,0478	0,0528	0,0109	0,5446	0,0003
F8	0,907	0,9872	0,9970	0,8968	0,9236	0,0191	0,0263	0,0063	0,1981	0,0003
T3	0,9496	0,9928	0,9985	0,8804	0,9654	0,0110	0,0154	0,0030	0,2282	0,0006
T4	0,9432	0,9908	0,9974	0,9380	0,9795	0,0120	0,0158	0,0053	0,1211	0,9655
T5	0,9895	0,9984	0,9994	0,9547	0,9895	0,0021	0,0023	0,0011	0,0894	0,0002
T6	0,9608	0,9947	0,9981	0,9818	0,9907	0,0080	0,0077	0,0038	0,0366	0,0002
Fz	0,9623	0,9941	0,9964	0,6498	0,9843	0,0075	0,0120	0,0081	0,6307	0,0005
Cz	0,9127	0,9848	0,9966	0,8806	0,9891	0,0174	0,0089	0,0070	0,2294	0,0123
Pz	0,9352	0,9927	0,9979	0,9552	0,9880	0,0129	0,0031	0,0042	0,0883	0,0008

Tabela 5.2 – Resumo dos Resultados de %Dif para o Indivíduo 5.

Canais	% Dif Correlação					% Dif MSE				
	Infomax	w-Infomax	SOBI	w-SOBI	Filtro	Infomax	w-Infomax	SOBI	w-SOBI	Filtro
Fp1	0,025	2,667	0	68,333	1,236	6100	11000	10900	1244000	0
Fp2	0,028	3,929	0	59,266	4,221	3500	7100	9750	667650	0
F3	0,025	5,742	0	31,793	2,305	1833,33	2266,66	1700	292400	0
F4	0,023	0,027	0	24,388	2,663	3900	4300	5600	346900	0
C3	0,023	0,296	0	10,858	0,965	4800	2900	2600	210900	0
C4	0,044	0,197	0	8,230	3,085	725	762,50	412	14862,50	0
P3	0,024	0,208	0	5,545	0,499	1800	450	500	42100	0
P4	0,047	0,347	0	3,308	1,061	105,71	54,28	0	1354,28	5648,57
O1	0,051	0,509	0	1,682	0,672	6266,66	0	1400	21533,33	66,66
O2	0,036	0,344	0	1,315	0,665	3700	3200	1450	14500	0
F7	0,021	1,981	0	29,202	5,944	15833	17500	3533,33	181433,3	0
F8	0,090	0,982	0	10,052	7,364	6266,66	8666,66	2000	65933,33	0
T3	0,048	0,577	0	11,828	3,318	1733,33	2466,66	400	37933,33	0
T4	0,054	0,667	0	5,960	1,800	126,41	198,11	0	2184,906	18116,9
T5	0,009	0,103	0	4,472	0,996	950	1050	450	44600	0
T6	0,037	0,343	0	1,632	0,745	3900	3750	1800	18200	0
Fz	0,034	0,234	0	34,785	1,216	1400	2300	1520	126040	0
Cz	0,084	1,183	0	11,642	0,749	148,57	27,14	0	3177,143	75,71
Pz	0,062	0,522	0	4,277	0,988	1512,50	287,50	425	10937,50	0

5.2 Resultados Gerais

A fim de direcionar os resultados para a aplicação em ICM, a análise dos 54 indivíduos se concentra nos canais que contêm a maior contaminação por artefato de piscada, ou seja, os canais frontais e temporais.

A Figura 5.6 mostra o valor do MSE, em porcentagem, entre o sinal recuperado pela técnica ICA-Infomax, wICA (*Wavelet*-Infomax), SOBI, w-SOBI e Filtragem Adaptativa dos canais frontais (Fp1, Fp2, F3, F4, F7, F8 e Fz) e temporais (T3, T4, T5, T6) para os 54 indivíduos. A Figura 5.7 retrata o valor absoluto de correlação para o mesmo cenário.

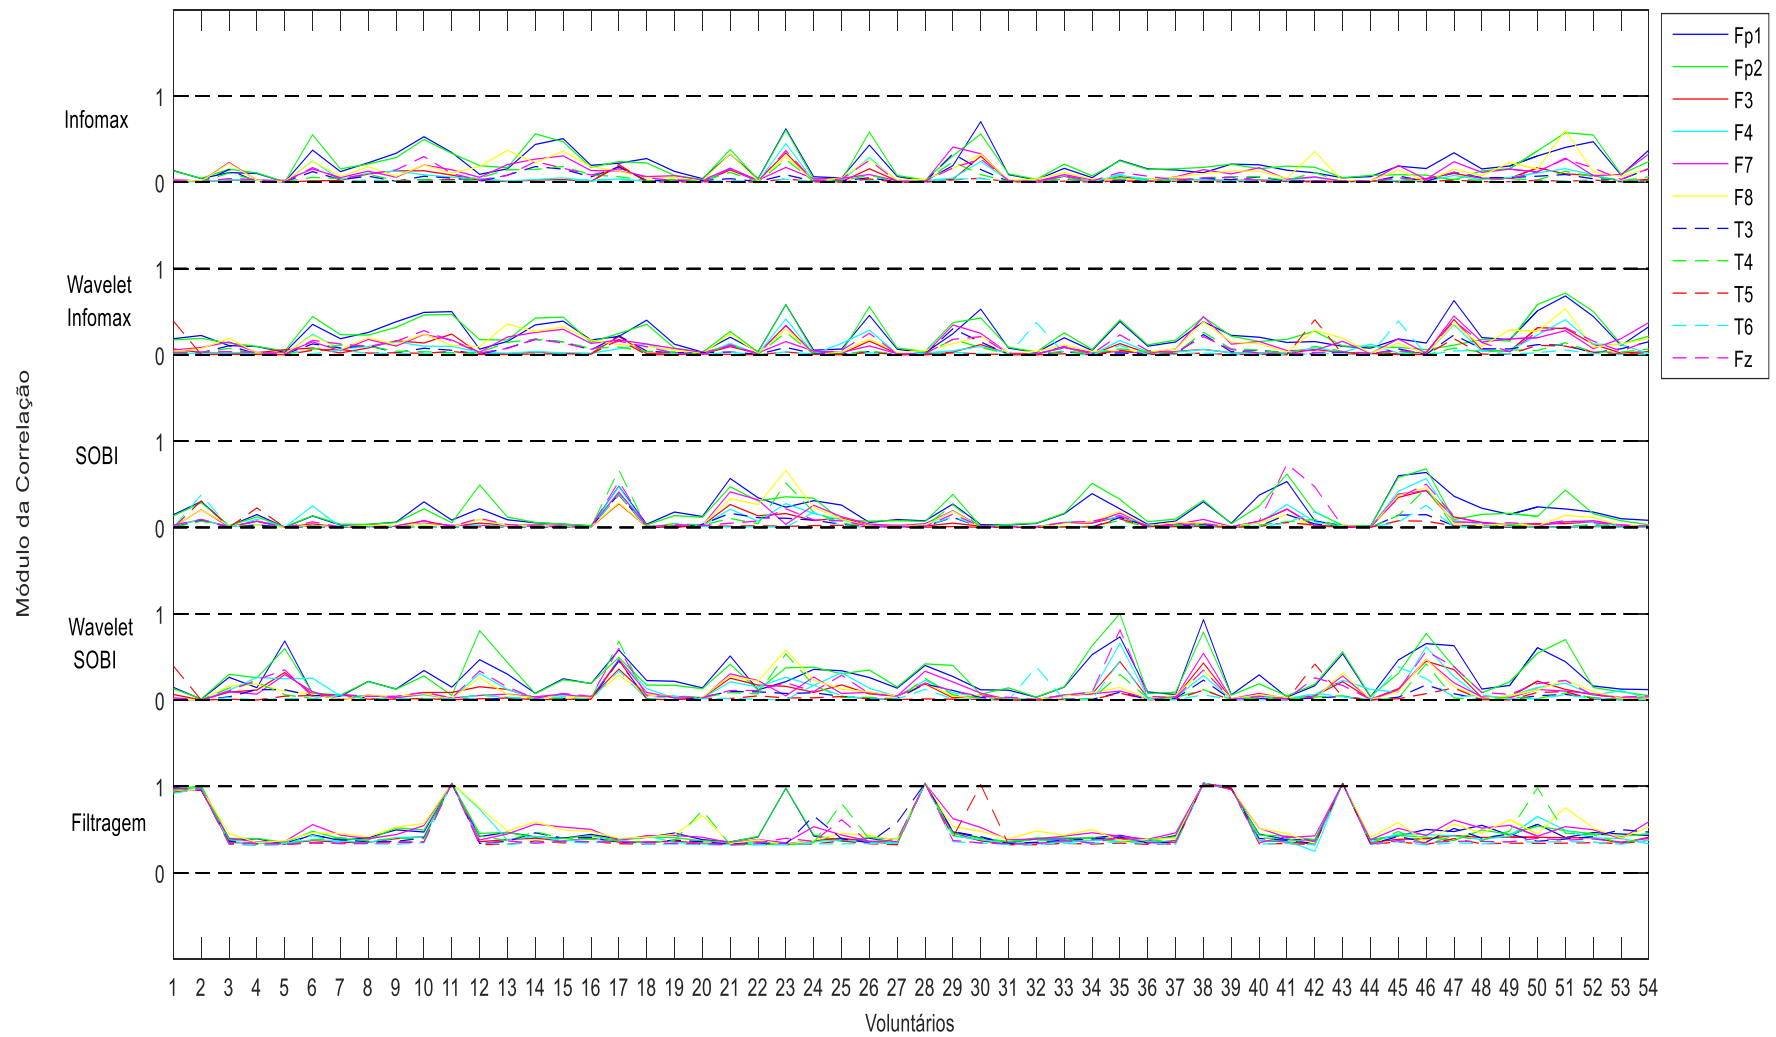


Figura 5.6 - Valores de correlação, em porcentagem, entre o sinal recuperado pelas técnicas para as técnicas ICA, wICA, SOBI, wSOBI e Filtragem e o sinal original para todos os indivíduos da base de dados




Figura 5.7 - Valores de MSE, em porcentagem, entre o sinal recuperado pelas técnicas para as técnicas ICA, wICA, SOBI, wSOBI e Filtragem e o sinal original para todos os indivíduos da base de dados

A Tabela 5.3 dispõe os valores de melhor e de pior desempenho de cada algoritmo ao realizar a remoção dos artefatos de EOG quando são considerados os sinais do canal Fp1 para os 54 indivíduos. Para o parâmetro MSE, o melhor desempenho corresponde ao menor valor, enquanto o pior desempenho reflete um maior valor. O inverso ocorre para os resultados da análise de correlação.

Tabela 5.3 – Valor absoluto dos maiores e menores valores de correlação e MSE obtidos para cada algoritmo para o sinal do canal Fp1 dos 54 indivíduos.

	Correlação		MSE	
	Maior Valor	Menor Valor	Maior Valor	Menor Valor
Infomax	0,9970	0,0062	3,9724	0,0062
SOBI	0,9961	0,3626	10,1580	0,0110
Wavelet-Infomax	0,9757	0,3170	4,1652	0,0111
Wavelet-SOBI	0,9905	0,0675	10,3300	0,0231
Filtragem	0,9838	0,0138	0,9335	0,0001

Figura 5.8 ilustra, em preto, os sinais de EEG contaminados por artefatos de piscada no canal Fp1, e os mesmos sinais com redução de EOG após serem recuperados pelo método Infomax. Os sinais em azul são referentes ao indivíduo 32 e ao indivíduo 5, que obtiveram melhores resultados nos parâmetros correlação e MSE, respectivamente. Já os sinais em vermelho, relativos ao indivíduo 5 e 30, que obtiveram os resultados menos eficazes na redução de EOG nos parâmetros correlação e MSE.

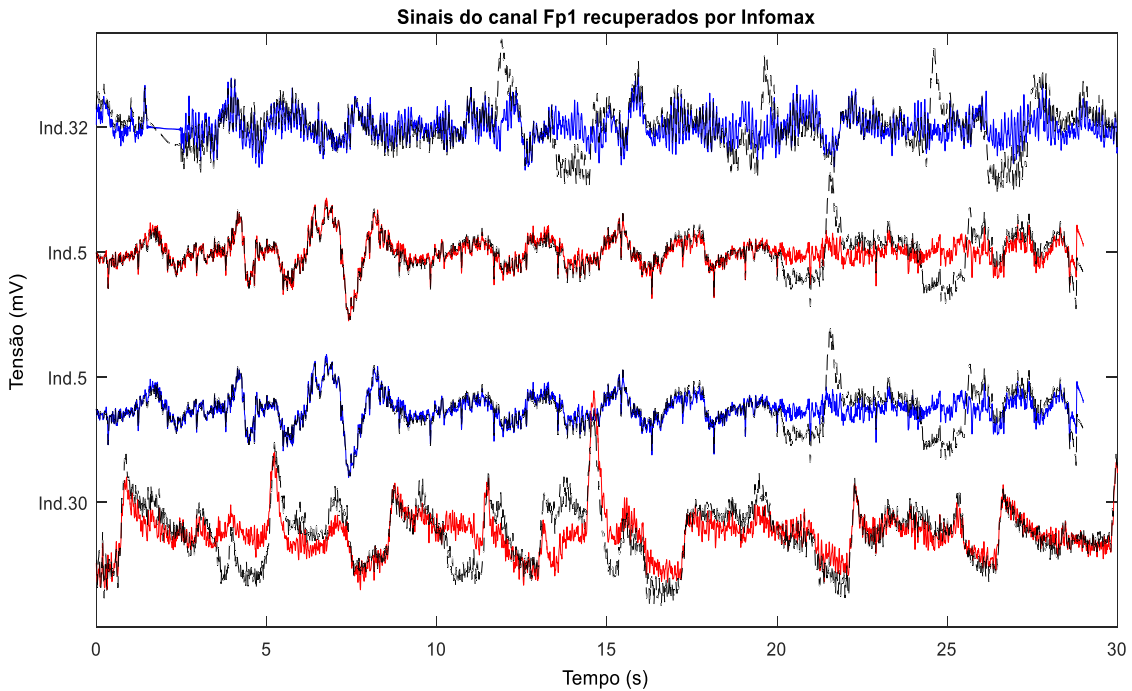


Figura 5.8 – Sinais contaminados por EOG (em preto) e os sinais recuperados dos indivíduos que apresentaram melhor resultado de correlação (azul) e melhor resultados de MSE (vermelho) do canal Fp1 por Infomax.

A Figura 5.9 e a Figura 5.10, ilustram, em preto, os sinais de EEG contaminados por artefatos de piscada no canal Fp1, e os mesmos sinais com redução de EOG após serem recuperados, respectivamente, pelos métodos SOBI e Wavelet-Infomax. Para os sinais recuperados por SOBI, são retratados os sinais contaminados originais e recuperados para o indivíduo 5, cujos desempenho de correlação e MSE foram os melhores dentre os 54 voluntários, e o indivíduo 46, que obteve os resultados menos eficientes para os dois parâmetros em análise. Enquanto que para os sinais reconstruídos por Wavelet-Infomax, o sinal recuperado do indivíduo 28 obteve a melhor performance de correlação, e o indivíduo 51, a pior. Para análise do MSE, os sinais recuperados ilustrados são os sinais do indivíduo 5 e do indivíduo 26, que apresentaram, respectivamente, a melhor e pior performance.

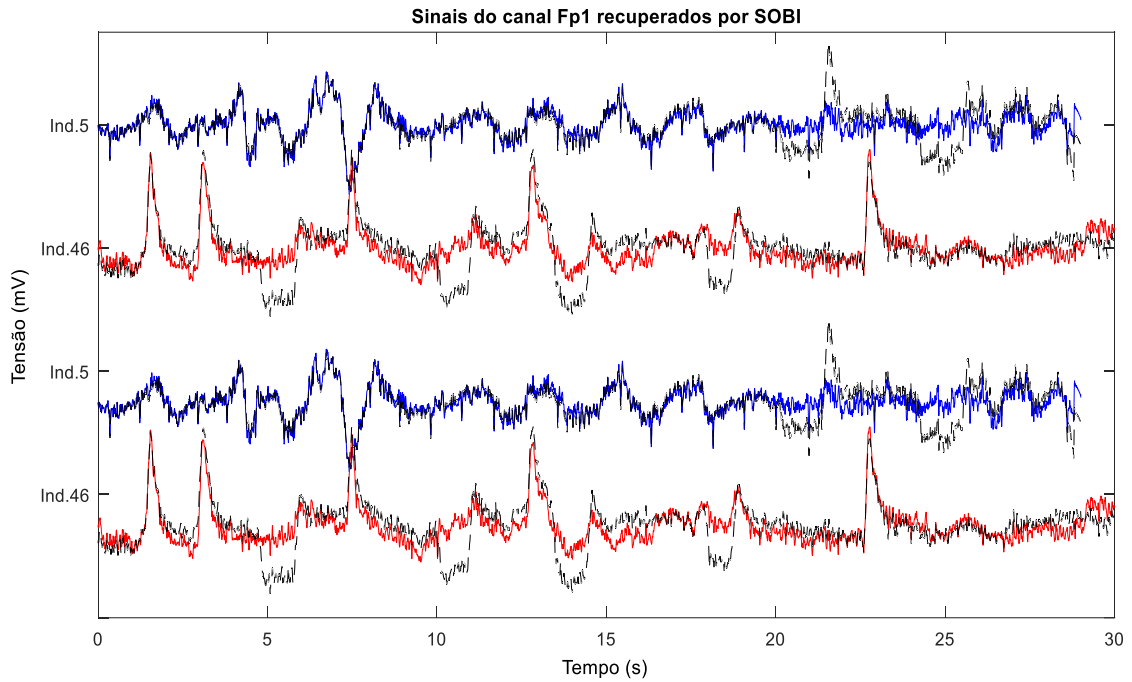


Figura 5.9 – Sinais contaminados por EOG (em preto) e os sinais recuperados dos indivíduos que apresentaram melhor resultado de correlação (azul) e melhor resultados de MSE(vermelho) do canal Fp1 por SOBI.

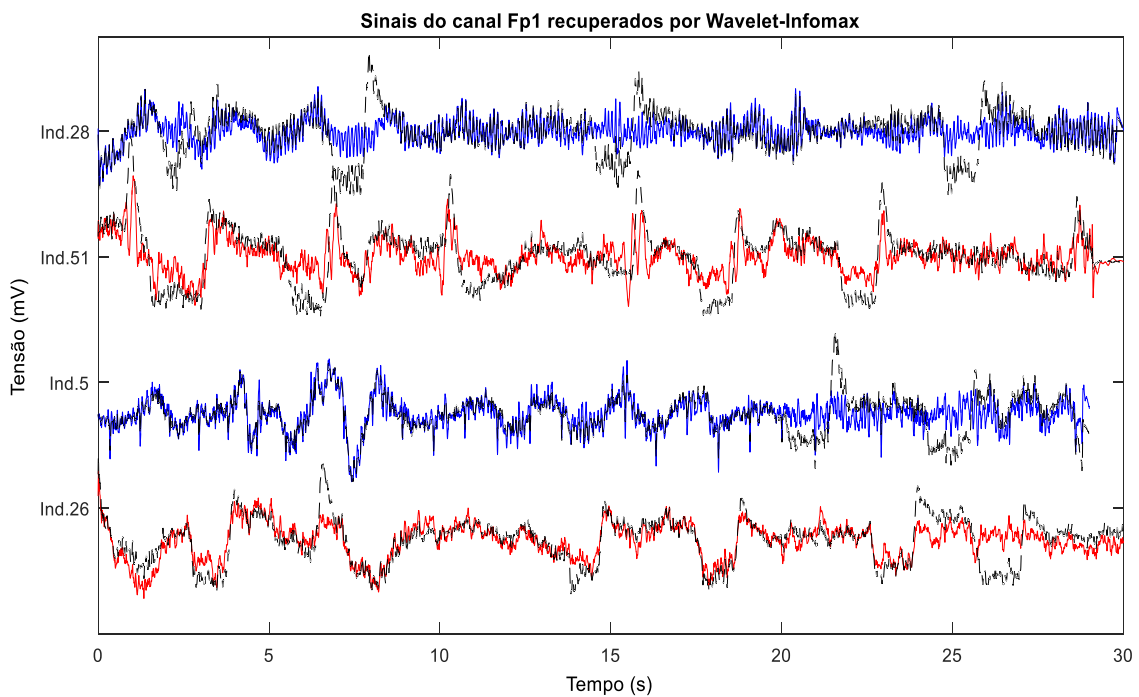


Figura 5.10 – Sinais contaminados por EOG (em preto) e os sinais recuperados dos indivíduos que apresentaram melhor resultado de correlação (azul) e melhor resultados de MSE(vermelho) do canal Fp1 por Wavelet-Infomax.

A Figura 5.10 ilustra os sinais contaminados por artefatos de piscada do canal Fp1 e os sinais de EEG sem contaminação por artefatos de EOG recuperados pelo algoritmo Wavelet-SOBI, para o indivíduo 2 (melhor correlação e MSE), para o indivíduo 38 (pior correlação) e para o indivíduo 46 (pior MSE).




Figura 5.11 – Sinais contaminados por EOG (em preto) e os sinais recuperados dos indivíduos que apresentaram melhor resultado de correlação (azul) e melhor resultados de MSE(vermelho) do canal Fp1 por Wavelet-SOBI.

Por fim, a Figura 5.11 ilustra os sinais contaminados por artefatos de piscada do canal Fp1 e os sinais de EEG adquiridos com os olhos fechados recuperados por Filtragem Adaptativa, para o indivíduo 5 (melhor correlação), para o indivíduo 23 (pior correlação), para o indivíduo 30 (pior MSE) e para o indivíduo 31 (melhor MSE).




Figura 5.12 – Sinais contaminados por EOG (em preto) e os sinais recuperados dos indivíduos que apresentaram melhor resultado de correlação (azul) e melhor resultados de MSE(vermelho) do canal Fp1 por Filtragem.

6 Discussão

Esse trabalho avaliou o desempenho dos métodos: filtragem adaptativa, Infomax e SOBI, para realização do algoritmo ICA para atenuação do artefato de piscada de olhos em gravações de EEG. Os métodos de realização da ICA foram analisados de forma isolada e ao serem combinados com a DWT.

É importante ressaltar que os três métodos (ICA, wICA e Filtragem Adaptativa) são capazes de obter uma boa estimativa do EEG sem contaminação por piscada de olhos. A filtragem adaptativa consegue tal feito com o cancelamento de ruído ao se aplicar como referência, um sinal cujo comportamento seja similar ao do artefato. O algoritmo ICA assume tal função ao reconstruir as componentes independentes desprovidas das características de artefato, assim como a DWT, que obtém resultado similar pela aglutinação dos detalhes, pois as aproximações carregam comportamento similar ao artefato.

Entretanto, o objetivo do presente trabalho é, além de remover as componentes de artefato dos dados de EEG, reduzir a perda parcial de atividade cortical pelos métodos de remoção de artefato. Por isso, nas aplicações do método wICA, os sinais de entrada fornecidos para a ICA foram os sinais de aproximação da análise DWT com o intuito de minimizar a parcela de EEG remanescente no sinal que estima o artefato.

É válido lembrar que as análises feitas foram separadamente em três diferentes cenários. O primeiro deles explorou o valor do MSE obtidos a partir de cada método aplicado para cada um dos 19 canais de EEG, tal como a análise realizada por MANNAN; JEONG; KAMRAN, (2016). O segundo cenário, tal como o primeiro, analisou o valor de correlação para os mesmos sinais, anteriormente feita em MATIĆ; HUFFEL, (2009). Neste momento, salienta-se que existem 54 gravações de EEG. Logo, existem 54 gravações de cada um dos 19 canais de EEG, mas como citado no capítulo anterior, a análise se reteve aos canais frontais e temporais. E, por último, realizou-se a comparação dos valores de diferença obtidos para o MSE e para a correlação, proposta em SAHONERO; CALDERON, (2017). Esse ponto foi ilustrado ao mostrar, detalhadamente, os resultados para o indivíduo 5.

Deste modo, com base nos dados dispostos na Tabela 5.3, verificou-se que, para os sinais dos 11 canais, o método SOBI apresentou maior valor de correlação mais vezes quando comparado aos outros quatro métodos, totalizando 48% das 594 vezes (11 canais para cada um dos 54 indivíduos) em que foi empregada. Tal resultado está de acordo com os experimentos anteriores realizados em SAHONERO; CALDERON, (2017) e MATIĆ; HUFFEL, (2009). Corroborando tal resultado, a Figura 5.6 ilustra os valores de correlação pelos 4 algoritmos nas aplicações dos canais Frontais e Temporais. Para o segundo parâmetro em análise, observou-se que a Filtragem Adaptativa foi a técnica que apresentou menores valores de MSE na maior quantidade de vezes que foi empregada (80% de 594 vezes). A Figura 5.7 corrobora esse resultado ao mostrar que Filtragem adaptativa não excedeu MSE igual a um. Já os outros quatro métodos, superaram o MSE unitário em alguns canais, como o Infomax, no canal F8, no canal T3 e no canal Fp2, que ultrapassaram o valor 10 para os voluntários 29, 29 e 14, respectivamente. Por sua vez, o método Wavelet-Infomax superou o mesmo valor nos canais F7 e F8 para o indivíduo 38. Os métodos SOBI e Wavelet-SOBI superaram o valor 10 de MSE no Fp1 para o indivíduo 46.

Destaca-se que, na aplicação dos sinais do voluntário 5 para os seus 19 canais de EEG, durante a realização da Filtragem Adaptativa, as ordens de filtros selecionadas variaram, somente, entre segunda e quinta ordens.

De forma semelhante, durante a realização dos métodos wICA, as aproximações variaram entre segunda e quinta, empregando para a reconstrução os detalhes de níveis um e dois, para o primeiro caso, e detalhes dos níveis um ao cinco, no segundo caso. Exceto para os canais Fp1 e Fp2 que utilizaram a aproximação de nível três, empregando dos detalhes um ao três durante a reconstrução.

A partir da comparação visual dos resultados dos sinais recuperados pelos cinco métodos com os sinais iniciais da Figura 5.5, verifica-se que os artefatos de vEOG, mais visíveis nos canais Fp1, Fp2, F3, F4 e Fz nos tempos 22 s e 25,5 s, foram satisfatoriamente removidos. O mesmo é visto para os artefatos de hEOG em F7, F8 e T3 no instante de 20 s.

Com base na Tabela 5.1, pode-se constatar que o algoritmo SOBI apresentou, em todos os sinais analisados, maiores valores de correlação entre os sinais de EEG originalmente livres de artefatos e os sinais de EEG recuperados. Entretanto, percebe-se

que não houve discrepância entre o maior valor de correlação, obtido pelo SOBI, e pelo “segundo” maior valor. Para os sinais dos canais F4, C3, C4, P3, P4, O1, O2, F8, T3, T4, T5, T6, Fz, Cz e Pz, a diferença não ultrapassou 1%, nos métodos que apresentaram o segundo maior valor de correlação. Já para os sinais dos canais Fp1, Fp2, F3 e F7, a diferença foi de 1,24%, 3,93%, 2,31% e 2%, respectivamente.

O mesmo não se verificou nos valores de MSE. Novamente, de acordo com a Tabela 5.1, a discrepância entre o menor valor de MSE e seu consecutivo variou de 1,6% até 78,6%. Verificou-se que, para os sinais dos canais P4, T4 e Cz, o algoritmo SOBI alcançou menores valores de MSE, enquanto que para os demais canais esse resultado foi obtido pela Filtragem Adaptativa.

A definição do melhor método para remoção dos artefatos para o indivíduo 5 é feita com auxílio dos dados presentes na Tabela 5.2. Nenhum dos sinais dos 19 canais desse indivíduo resultou no mesmo algoritmo com maior %Dif de correlação e menor %Dif de MSE. Entretanto, nota-se que, para os canais Fp1, Fp2, F4, F7 e Fz, os métodos com melhores resultados de correlação foram a Wavelet-SOBI e a Filtragem, e, com relação ao MSE, foram a Filtragem e a técnica Infomax. Então, pode-se concluir que houve uma compensação entre os métodos. Dessa forma, para esses canais, a melhor performance na remoção de artefato foi atribuída à Filtragem.

A mesma compensação pode ser percebida nos sinais dos canais C3, C4, O2, F8, T3, T5 e T6 ao lograr a maior diferença de correlação com o algoritmo Wavelet-SOBI, seguido pela Filtragem, e menor diferença para a Filtragem, seguida pelo método SOBI. Nesse caso, a Filtragem foi definida como a técnica com melhor performance. A Filtragem também foi definida como a técnica com performance superior na atenuação dos artefatos nos canais P3, O1 e Pz, que obtiveram o Wavelet-SOBI com maior diferença de correlação seguido pela Filtragem, e a Filtragem com a menor diferença de MSE, seguida pela Wavelet-Infomax. Novamente, para o sinal do canal O1, a Filtragem foi o algoritmo escolhido como o de melhor performance, pois, para esse canal, a técnica com maior diferença de correlação foi a Infomax, seguida pela Filtragem, e a menor diferença de MSE foi a Filtragem, seguida pela Wavelet-Infomax.

O sinal do canal Cz apresentou os dois melhores desempenhos de correlação com as técnicas Wavelet-SOBI e Wavelet-Infomax, respectivamente. Já os dois melhores desempenhos para o MSE foram notados nos resultados alcançados pelos

métodos SOBI e Wavelet-Infomax. Nesse canal, percebemos a compensação de performance do método Wavelet-Infomax, que, apesar de não ter logrado a melhor performance nos dois parâmetros em análise, alcançou o segundo melhor resultado tanto para correlação quanto para o MSE.

A mesma compensação pode ser percebida nos sinais dos canais F3, C3, C4, O2, F8, T3, T5 e T6 ao lograr a maior diferença de correlação com o algoritmo Infomax, seguido pela Filtragem, e menor diferença para a Filtragem, seguida pelo método SOBI. Nesse caso, a Filtragem foi definida como a técnica com melhor performance. A Filtragem também foi definida como a técnica com performance superior na atenuação dos artefatos nos canais P3 e Pz, que obtiveram o Infomax com maior diferença de correlação seguido pela Filtragem, e a Filtragem com a menor diferença de MSE, seguida pela Wavelet-Infomax.

Para o sinal do canal Cz, a compensação foi vista entre os seguintes métodos: Wavelet-SOBI e Wavelet-Infomax, na diferença de correlação, e SOBI e Wavelet-Infomax, na diferença de MSE. Atribuiu-se, dessa forma, a técnica Wavelet-SOBI como a com melhor desempenho. Já para os sinais dos canais F3 e T4 não foi vista qualquer convergência ou compensação de resultados. Então, para esses canais não houve a definição de um melhor algoritmo para a redução de artefato.

Como os canais Frontais e Temporais são os mais relevantes na aplicação na qual esse trabalho se concentra, o algoritmo que apresenta melhor resultado na atenuação dos artefatos de EOG, para o indivíduo 5, é a Filtragem, seguido Infomax. A discrepante melhor performance da Filtragem Adaptativa pode ser atribuída, nesse caso, pela forma como foi realizada a contaminação dos sinais de EEG por EOG. Entretanto, para sinais de EEG contaminados com EOG adquiridos em um experimento, ou seja, sinais nos quais a contaminação por EOG não seja puramente linear, o desempenho do SOBI sobrepuje o da Filtragem Adaptativa, como mostram os resultados obtidos em (SAHONERO; CALDERON, 2017).

Pela análise visual das Figuras 5.1, 6.1, 6.2, 6.3, 6.4 e 6.5, nota-se uma forma de onda similar entre os sinais recuperados pela Filtragem Adaptativa e o EEG livre de contaminação por EOG para os canais Fp1, Fp2, F4, C3, C4, P3, O2, F7, F8, T3, T5, T6, Fz e Pz. Esse resultado é confirmado pela análise dos parâmetros %Dif dispostos na Tabela 5.2.

Por outro lado, para os canais F3, P4 e T4, os sinais recuperados pelas técnicas ICA são mais próximos à forma de onda dos sinais de EEG adquiridos com os olhos fechados.

Os dados da Tabela 5.3 corroboram tais resultados ao apontar MSE menor para o algoritmo SOBI. É importante ressaltar que, para esse conjunto de canais, a diferença dos valores de MSE obtidos pelos algoritmos com melhor e “segunda” melhor performance é pequena. No caso dos canais P4 e T4, nota-se essa pequena diferença entre os métodos SOBI e Wavelet-Infomax, SOBI e Infomax, respectivamente.

Por fim, a maior semelhança entre a forma de onda do canal O1 e o EEG sem contaminação por EOG inspecionado visualmente consolidam o resultado posto na Tabela 5.1 ao apresentar, novamente, menor MSE menor para o algoritmo Filtragem Adaptativa, embora com pequena diferença para o Wavelet-Infomax.

A Figura 5.8, Figura 5.9, Figura 5.10, Figura 5.11 2 Figura 5.12 ilustram os resultados dispostos na Tabela 5.3. Além disso, corroboram as análises feitas até aqui, assim como os resultados encontrados na literatura ao mostrar que os artefatos de EOG foram atenuados de forma satisfatória pelas 5 técnicas Infomax, SOBI, Wavelet-Infomax, Wavelet-SOBI e Filtragem Adaptativa.

7 Conclusão

Neste estudo, foi apresentada uma comparação entre diferentes métodos para realizar o cancelamento de artefatos de piscada no sinal de EEG. As performances das várias abordagens foram medidas pelo MSE entre os sinais recuperados e os registros de EEG sem contaminação do artefato. Entre as cinco abordagens apresentadas, duas são baseadas no método ICA, duas na combinação do ICA e DWT, e uma aplica filtragem adaptativa. As aplicações do método ICA são ideais para separar sinais estatisticamente independentes, enquanto as aplicações wICA combinam as características do método ICA com a capacidade de separar sinais que têm espectros não sobrepostos presentes no método DWT. O quinto método apresentado é capaz de separar sinais sobrepostos espectralmente ao adquirir o sinal de referência com o sinal de entrada do filtro.

Após testar os algoritmos, os mesmos tiveram seus desempenhos comparados para obter um sinal o mais semelhante possível ao EEG sem contaminação dos artefatos EOG. As análises de correlação e MSE realizadas estão em acordo a literatura. Além disso, os resultados mostram um desempenho satisfatório para os 5 métodos empregados. Entretanto, notou-se uma pequena superioridade na utilização da abordagem de Filtragem Adaptativa para sinais onde a contaminação foi feita artificialmente de forma linear. Tal desempenho foi definido como superior, pois apresentou resultados convergentes no par de diferenças de correlação e MSE, que impacta diretamente na aplicação dos sinais de EEG para controle de uma ICM. Ressalta-se que, apesar do desempenho superior, a Filtragem Adaptativa pode apresentar cancelamento de uma grande porção de atividade neural. No futuro, propõe-se estender o estudo a sinais adquiridos com artefatos de piscada e outros métodos ICA.

8 Trabalhos Futuros

Alguns trabalhos futuros que podem ser sugeridos a partir dos resultados encontrados na presente dissertação:

- Adquirir sinais de EEG e EOG
- Utilizar outras funções wavelet-mãe, a fim de testar se há alteração na independência entre fontes de forma que afete a análise ICA;
- Utilizar outras técnicas ICA, pois uma nova versão do EEGLAB foi disponibilizada com novos métodos.

9 Referências bibliográficas

ALEXANDER, T. S. *Adaptive signal processing: theory and applications*. E-Book: Springer, 2012.

ALLISON, B. Z. et al. (EDS.). *Towards Practical Brain-Computer Interfaces: Bridging the Gap from Research to Real-World Applications*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013.

AZZERBONI, B. et al. *Neural-ICA and wavelet transform for artifacts removal in surface EMG*. 2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No.04CH37541). *Anais...* In: 2004

IEEE INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS. Budapest, Hungary: IEEE, 2004Disponível em: <<http://ieeexplore.ieee.org/document/1381194/>>. Acesso em: 30 abr. 2020

BAREA, R. et al. System for assisted mobility using eye movements based on electrooculography. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, v. 10, n. 4, p. 209–218, dez. 2002.

BEAR, M. F. *Neurociencias: desvendando o sistema nervoso*. Porto Alegre: Artmed, 2002.

BELOUHRANI, A. et al. A blind source separation technique using second-order statistics. *IEEE Transactions on Signal Processing*, v. 45, n. 2, p. 434–444, fev. 1997.

BELWAFI, K. et al. *An embedded implementation based on adaptive filter bank for brain-computer interface systems*. *Journal of Neuroscience Methods*, v. 305, p. 1–16, jul. 2018.

BOORD, P. et al. *Discrimination of left and right leg motor imagery for brain-computer interfaces*. *Medical & Biological Engineering & Computing*, v. 48, n. 4, p. 343–350, abr. 2010.

BRUNNER, C.; DELORME, A.; MAKEIG, S. Eeglab – an Open Source Matlab Toolbox for Electrophysiological Research. *Biomedical Engineering / Biomedizinische Technik*, 7 jan. 2013.

BUENO, L. *Interface Cérebro-Computador Baseada em EEG Utilizando Redes Neurais Auto-Organizadas*. Tese de Doutorado — Universidade Federal do Espírito Santo –

UFES, 6 jun. 2017. Disponível em <<http://repositorio.ufes.br/handle/10/9689>>. Acesso em: 23.09.2019

CAGY, M.; CAGY, M.; INFANTOSI, A. F. C. Variable-Weight Adaptive Filtering as an ERP Pre-Processing Technique. 2011.

D’AFFONSÊCA NETTO, A.; SÁ, A. M. F. L. M. DE. Coerência Multipla Aplicada a interface Cérebro Computador (ICC) com Potencial Evocado Visual. 2014. Tese de Doutorado. Disponível em <http://www.peb.ufrj.br/teses/Tese0296_2018_04_18.pdf> Acesso em: Setembro de 2019.

DELORME, A. et al. EEGLAB, SIFT, NFT, BCILAB, and ERICA: New Tools for Advanced EEG Processing. *Computational Intelligence and Neuroscience*, v. 2011, p. 1–12, 2011.

DELORME, A.; MAKEIG, S. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of Neuroscience Methods*, v. 134, n. 1, p. 9–21, mar. 2004.

DELORME, A.; SEJNOWSKI, T.; MAKEIG, S. Enhanced detection of artifacts in EEG data using higher-order statistics and independent component analysis. *NeuroImage*, v. 34, n. 4, p. 1443–1449, fev. 2007.

ELBERT, T. et al. Removal of ocular artifacts from the EEG — A biophysical approach to the EOG. *Electroencephalography and Clinical Neurophysiology*, v. 60, n. 5, p. 455–463, maio 1985.

FATOURECHI, M. et al. EMG and EOG artifacts in brain computer interface systems: A survey. *Clinical Neurophysiology*, v. 118, n. 3, p. 480–494, mar. 2007.

FOLGUERAS MÉNDEZ, J. et al. (EDS.). *V Latin American Congress on Biomedical Engineering CLAIB 2011 May 16-21, 2011, Habana, Cuba: Sustainable Technologies for the Health of All*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. v. 33

GLOOR, P. Neuronal Generators and the Problem of Localization in Electroencephalography: Application of Volume Conductor Theory to Electroencephalography. *Journal of Clinical Neurophysiology*, v. 2, n. 4, p. 327–354, out. 1985.

GOMES, M. DA M. Revista Brasileira de Neurologia. *Bases fisiológicas do eletroencefalograma*, v. 51, 2015.

GUYTON, A. C.; HALL, J. E. *Tratado de fisiología médica*. London: Elsevier Health Sciences Spain, 2011.

HALDER, S. et al. Online Artifact Removal for Brain-Computer Interfaces Using Support Vector Machines and Blind Source Separation. *Computational Intelligence and Neuroscience*, v. 2007, p. 1–10, 2007.

HAUKE, J.; KOSSOWSKI, T. Comparison of Values of Pearson's and Spearman's Correlation Coefficients on the Same Sets of Data. *Quaestiones Geographicae*, v. 30, n. 2, p. 87–93, 1 jun. 2011.

HAYKIN, S. S. *Adaptive filter theory*. Fifth edition ed. Upper Saddle River, New Jersey: Pearson, 2014.

HE, P.; WILSON, G.; RUSSELL, C. Removal of ocular artifacts from electroencephalogram by adaptive filtering. *Medical & Biological Engineering & Computing*, v. 42, n. 3, p. 407–412, maio 2004.

HYVÄRINEN, A.; OJA, E. Independent component analysis: algorithms and applications. *Neural Networks*, v. 13, n. 4–5, p. 411–430, jun. 2000.

IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (ED.). *2013 35th annual international conference of the IEEE Engineering in Medicine and Biology Society (EMBC 2013): Osaka, Japan, 3 - 7 July 2013*. Piscataway, NJ: IEEE, 2013.

INTERNATIONAL FEDERATION FOR MEDICAL AND BIOLOGICAL ENGINEERING (ED.). *2011 Pan American health care exchanges (PAHCE 2011): Rio de Janeiro, Brazil, 28 March - 1 April 2011 ; [conference, workshops, and exhibits, cooperation/linkages]*. Piscataway, NJ: IEEE, 2011

ISLAM, M. K.; RASTEGARNIA, A.; YANG, Z. Methods for artifact detection and removal from scalp EEG: A review. *Neurophysiologie Clinique/Clinical Neurophysiology*, v. 46, n. 4–5, p. 287–305, nov. 2016.

JIANG, X.; BIAN, G.-B.; TIAN, Z. Removal of Artifacts from EEG Signals: A Review. *Sensors*, v. 19, n. 5, p. 987, 26 fev. 2019.

JOYCE, C. A.; GORODNITSKY, I. F.; KUTAS, M. Automatic removal of eye movement and blink artifacts from EEG data using blind component separation. *Psychophysiology*, v. 41, n. 2, p. 313–325, mar. 2004.

JUNG, T.-P. et al. Independent Component Analysis of Electroencephalographic and

Event-Related Potential Data. In: POON, P. W. F.; BRUGGE, J. F. (Eds.). . *Central Auditory Processing and Neural Modeling*. Boston, MA: Springer US, 1998. p. 189–197.

KLADOS, M. A.; BAMIDIS, P. D. A semi-simulated EEG/EOG dataset for the comparison of EOG artifact rejection techniques. *Data in Brief*, v. 8, p. 1004–1006, set. 2016.

LINS, O. G. et al. Ocular artifacts in EEG and event-related potentials I: Scalp topography. *Brain Topography*, v. 6, n. 1, p. 51–63, set. 1993.

MANNAN, M. M. N.; JEONG, M. Y.; KAMRAN, M. A. Hybrid ICA—Regression: Automatic Identification and Removal of Ocular Artifacts from Electroencephalographic Signals. *Frontiers in Human Neuroscience*, v. 10, 3 maio 2016.

MARQUE, C. et al. Adaptive filtering for ECG rejection from surface EMG recordings. *Journal of Electromyography and Kinesiology*, v. 15, n. 3, p. 310–315, jun. 2005.

MATIĆ, V.; HUFFEL, S. Comparison of ICA algorithms for ECG artifact removal from EEG signals. Proceedings of the 4th Annual Symposium of the IEEE-EMBS Benelux Chapter, 2009.

MARTÍNEZ-CANCINO, R. et al. The open EEGLAB portal Interface: High-Performance computing with EEGLAB. *NeuroImage*, v. 224, p. 116778, jan. 2021.

MIYAKOSHI, Makoto, *SCCN Software - SCCN*, disponível em: <https://sccn.ucsd.edu/wiki/Main_Page>, acesso em: 30 jan. 2021.

NIEDERMEYER, E.; LOPES DA SILVA, F. H. (EDS.). *Electroencephalography: basic principles, clinical applications, and related fields*. 5th ed ed. Philadelphia: Lippincott Williams & Wilkins, 2005.

ORMIGA GALVAO BARBOSA, A. *Controle de um Manipulador Robótico através de uma Interface Cérebro Máquina Não-Invasiva com Aprendizagem Mútua*. Mestre em Engenharia Mecânica—Rio de Janeiro, Brazil: PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO, 31 ago. 2010.

PAPADELIS, C. et al. Monitoring sleepiness with on-board electrophysiological recordings for preventing sleep-deprived traffic accidents. *Clinical Neurophysiology*, v. 118, n. 9, p. 1906–1922, set. 2007.

PETERSON, D. A. et al. *Feature Selection and Blind Source Separation in an EEG-Based Brain-Computer Interface*. EURASIP Journal on Advances in Signal Processing,

v. 2005, n. 19, p. 218613, dez. 2005.

REJER, I.; GÓRSKI, P. *Independent Component Analysis for EEG Data Preprocessing - Algorithms Comparison*. In: SAEED, K. et al. (Eds.). . *Computer Information Systems and Industrial Management. Lecture Notes in Computer Science*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. v. 8104p. 108–119.

SAHA, S. K.; ALI, MD. S. *Data adaptive filtering approach to improve the classification accuracy of motor imagery for BCI*. 2016 9th International Conference on Electrical and Computer Engineering (ICECE). Anais... In: 2016 9TH INTERNATIONAL CONFERENCE ON ELECTRICAL AND COMPUTER ENGINEERING (ICECE). Dhaka, Bangladesh: IEEE, dez. 2016Disponível em: <<http://ieeexplore.ieee.org/document/7853902/>>. Acesso em: 23 jan. 2021

SAHONERO, G.; CALDERON, H. *A Comparison of SOBI, FastICA, JADE and Infomax Algorithms*. 2017

SANEI, S.; CHAMBERS, J. *EEG signal processing*. Chichester, England ; Hoboken, NJ: John Wiley & Sons, 2007.

SHOKER, L.; SANEI, S.; CHAMBERS, J. Artifact removal from electroencephalograms using a hybrid BSS-SVM algorithm. *IEEE Signal Processing Letters*, v. 12, n. 10, p. 721–724, out. 2005.

SILVA, C. D. *Processamento de Sinais de EEG para Classificação de Tarefas Motoras em Sistemas de Interface Cérebro-Máquina*. Disponível em <<https://repositorio.ufsc.br/handle/123456789/179946>>

SOMERS, B.; FRANCA, T.; BERTRAND, A. A generic EEG artifact removal algorithm based on the multi-channel Wiener filter. *Journal of Neural Engineering*, v. 15, n. 3, p. 036007, 1 jun. 2018.

SOUZA, R. H. C.; BORGES, F. S.; NAVES, E. L. M. *Eletro-Oculografia no Controle de Mouse, uma Ferramenta de Tecnologia Assistiva*. 2010.

TURNIP, A. *Comparison of ICA-Based JADE and SOBI Methods EOG Artifacts Removal*. *Journal of Medical and Bioengineering*, v. 4, n. 6, p. 436–440, 2015.

UNSER, M.; ALDROUBI, A. A review of wavelets in biomedical applications. *Proceedings of the IEEE*, v. 84, n. 4, p. 626–638, abr. 1996.

VAUGHAN, T. M. Guest editorial brain-computer interface technology: a review of the second international meeting. *IEEE Transactions on Neural Systems and Rehabilitation*

Engineering, v. 11, n. 2, p. 94–109, jun. 2003.

VIGARIO, R. et al. Independent component approach to the analysis of EEG and MEG recordings. *IEEE Transactions on Biomedical Engineering*, v. 47, n. 5, p. 589–593, maio 2000.

VIGÁRIO, R. N. Extraction of ocular artefacts from EEG using independent component analysis. *Electroencephalography and Clinical Neurophysiology*, v. 103, n. 3, p. 395–404, set. 1997.

WANG, J. et al. *Feature Extraction of Brain-Computer Interface based on Second Order Blind Identification and ICA*. 2011 5th International Conference on Bioinformatics and Biomedical Engineering. Anais... In: 2011 5TH INTERNATIONAL CONFERENCE ON BIOINFORMATICS AND BIOMEDICAL ENGINEERING. Wuhan: IEEE, maio 2011Disponível em: <<http://ieeexplore.ieee.org/document/5780256/>>. Acesso em: 23 jan. 2021

WANG, Y.; JUNG, T.-P. A Collaborative Brain-Computer Interface for Improving Human Performance. *PLoS ONE*, v. 6, n. 5, p. e20422, 31 maio 2011.

WOLPAW, J. R. et al. Brain–computer interfaces for communication and control. *Clinical Neurophysiology*, v. 113, n. 6, p. 767–791, jun. 2002.

WOLPAW, J. R.; WOLPAW, E. W. (EDS.). *Brain-computer interfaces: principles and practice*. Oxford ; New York: Oxford University Press, 2012.

XIAO, D.; HU, J. *Classification of Motor Imagery EEG Based on a Time-Frequency Analysis and Second-Order Blind Identification*. 2008 2nd International Conference on Bioinformatics and Biomedical Engineering. Anais... In: 2008 2ND INTERNATIONAL CONFERENCE ON BIOINFORMATICS AND BIOMEDICAL ENGINEERING. Shanghai, China: IEEE, maio 2008Disponível em: <<http://ieeexplore.ieee.org/document/4535760/>>. Acesso em: 23 jan. 2021

ZARUZ, T. F. et al. Eletro-oculografia - Ping Pong Game. 25 out. 2018. Disponível em <www.even3.com.br/Anais/xiseb/128396-ELETRO-OCULOGRAFIA---PING-PONG-GAME> . Acesso em: Outubro de 2019.

ZHAO, L. *iCBBE 2008 The 2nd International Conference on Bioinformatics and Biomedical Engineering, May 16-18, 2008, Shanghai, China*. New Jersey: IEEE, 2008.