

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ELETRÔNICA E SISTEMAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

DIOGO DOS SANTOS JARDIM

REMOÇÃO DE ARTEFATOS EM EEG PARA NEUROFEEDBACK

Recife

2017

DIOGO DOS SANTOS JARDIM

REMOÇÃO DE ARTEFATOS EM EEG PARA NEUROFEEDBACK

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Pernambuco como parte dos requisitos para a obtenção do grau de Mestre em Engenharia Elétrica.

Área de Concentração: Eletrônica – Sensores e Instrumentação Eletrônica

Orientador: Prof. Dr. Marco Aurélio Benedetti Rodrigues

Recife

2017

Catálogo na fonte
Bibliotecária Maria Luiza de Moura Ferreira, CRB-4 / 1469

J37r Jardim, Diogo dos Santos.
Remoção de artefatos em EEG para NEUROFEEDBACK / Diogo dos Santos Jardim.
- 2017.
92 folhas, il., tabs., abr. e sigl.

Orientador: Prof. Dr. Marco Aurélio Benedetti Rodrigues.
Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de
Pós-Graduação em Engenharia Elétrica, 2017.
Inclui Referências.

1. Engenharia Elétrica. 2.EEG. 3. Artefatos. 4. Tempo real. 5. Remoção de artefatos.
I. Rodrigues, Marco Aurélio Benedetti (Orientador). II.Título.

UFPE

621.3 CDD (22. ed.)

BCTG/2018-335



Universidade Federal de Pernambuco

Pós-Graduação em Engenharia Elétrica

PARECER DA COMISSÃO EXAMINADORA DE DEFESA DE
DISSERTAÇÃO DO MESTRADO ACADÊMICO DE

DIOGO DOS SANTOS JARDIM

TÍTULO

**“REMOÇÃO DE ARTEFATOS EM EEG
PARA NEUROFEEDBACK”**

A comissão examinadora composta pelos professores: MARCO AURÉLIO BENEDETTI RODRIGUES, DES/UFPE; RENATO EVANGELISTA DE ARAUJO, DES/UFPE e GILSON JERÔNIMO DA SILVA JÚNIOR, DES/UFPE, sob a presidência do primeiro, consideram o candidato **DIOGO DOS SANTOS JARDIM APROVADO.**

Recife, 31 de agosto de 2017.

MARCELO CABRAL CAVALCANTI
Coordenador do PPGEE

MARCO AURÉLIO BENEDETTI RODRIGUES
Orientador e Membro Titular Interno

GILSON JERÔNIMO DA SILVA JÚNIOR
Membro Titular Externo

RENATO EVANGELISTA DE ARAUJO
Membro Titular Interno

Dedico este trabalho aos meus pais, Raimundo Jardim e Nadja Maria dos Santos, por me inspirarem e me apoiarem a ser o que sou.

AGRADECIMENTOS

Agradeço primeiramente à Deus, a quem tudo devo e de quem tudo recebo.

Agradeço aos meus pais e meu irmão pelo amor e carinho. Agradeço a minha namorada, Milena Pininga por todo apoio, incentivo e amor dedicado a mim. À minha cunhada, Rubiane Pininga, pela ajuda e apoio. Sem vocês nada disso seria possível.

Agradeço ao Professor Marco Aurélio pela orientação e atenção no desenvolvimento deste trabalho.

Agradeço à Ubirakitan Maciel, meu sócio e amigo por toda ajuda, assim como toda a equipe da NeuroUP: é uma honra trabalhar com vocês.

RESUMO

A eletroencefalografia é a medida do somatório das atividades elétricas de diversos neurônios, sendo tradicionalmente utilizada para análises médicas. Nos últimos anos, tem crescido o interesse neste sinal devido ao aumento da incidência de transtornos cerebrais que, muitas vezes, podem ser auxiliados com o uso de *Neurofeedback*. Apesar disso, o uso do EEG encontra inúmeras dificuldades para ser utilizado na vida diária. Entre as dificuldades apresentadas estão os artefatos, sinais indesejados que introduzem mudanças nas medições. Assim, esse trabalho tem por objetivo desenvolver um método de remoção de artefatos de EEG com tempo de processamento viável para aplicações em *Neurofeedback* (tempo real) e que permita ser posteriormente embarcado em um *hardware* de baixo processamento. O método deste trabalho propõe a geração de filtros espaciais a partir da matriz de misturas estimada com o método de Análise de Componentes Independentes (ICA), executado com o algoritmo *Infomax*. Desse modo, foi possível atenuar artefatos fisiológicos (artefatos de origem muscular e ocular) e eletromagnéticos, com a vantagem de evitar a eliminação do sinal de interesse e obter resultados semelhantes quando comparado ao método tradicional utilizando o *toolbox* EEGLAB. Além de apresentar um tempo de execução viável para a aplicação de interesse deste trabalho e um algoritmo possível de ser implementado em sistemas embarcados.

Palavras-chave: EEG. Artefatos. Tempo real. Remoção de artefatos.

ABSTRACT

Electroencephalography (EEG) is a sum measure of electrical activities from several neurons and it is generally used for medical analysis. Interest in this signal has been increased in recent years due to the increased incidence of brains disorders. It can often be aided by the use of neurofeedback. Nevertheless, the use of EEG has many difficulties in daily life such as artifacts, which are unwanted signals that can introduce changes in measurements. Thus, this work aims to develop an EEG artifacts removal method that should have a viable processing time to applications for Neurofeedback (real time) and that can be embedded in low processing hardware. The methods purposed the generation of spatial filters based on Independent Component Analysis (ICA), which are executed with Infomax algorithm. This way, it was possible to attenuate physiological (muscle and ocular artifacts) and electromagnetic artifacts, with the advantage of avoiding the loss of the interest signal and obtaining results when compared to the traditional method which uses the EEGLAB toolbox. Still presenting a feasible execution time for an application of interest of this work and a possible algorithm to be implemented in embedded systems.

Keywords: EEG. Artifacts. Real-time. Artifact removal.

LISTA DE FIGURAS

Figura 1-	Estrutura da membrana celular.....	20
Figura 2-	Fases do potencial de ação.....	20
Figura 3-	Propagação do Potencial de Ação na célula nervosa.....	21
Figura 4-	(a) Tipos de onda de EEG; (b) Sinais eletrofisiológicos comuns.....	24
Figura 5-	Exemplo de touca de EEG.....	25
Figura 6-	Distribuição de eletrodos no sistema 10-20.....	28
Figura 7-	Distribuição de eletrodos no sistema 10-10.....	28
Figura 8-	Amplificador operacional.....	29
Figura 9-	Amplificador de Instrumentação.....	30
Figura 10-	Sistemas de EEG. (a) e (b): Sistemas da cognionics. (c) Emotiv Epoc (d) g.Nautilus da g.tec (e) Enobio da Neuroelectrics (f) Neurosky.....	32
Figura 11-	Sinal de EEG com artefatos de EOG.....	35
Figura 12-	Sinal de EEG com artefatos de EMG.....	36
Figura 13-	Sinal de EEG com artefato de ECG.....	37
Figura 14-	Resumo da combinação de métodos de remoção de artefatos.....	43
Figura 15-	Análise estatística da frequência de aparição de métodos de remoção de artefatos de EEG na literatura.....	45
Figura 16-	Problema Cocktail Party.....	48
Figura 17-	Esquematização da utilização de ICA para encontrar as fontes de sinais elétricos cerebrais.....	49
Figura 18-	Touca de Eletroencefalografia da neuroUP.....	52
Figura 19-	Equipamento Nexus-32 da MindMedia.....	53
Figura 20-	Componentes de EEG gerados com o ICA.....	54
Figura 21-	Exemplos de componentes artefatuosos.....	55
Figura 22-	Esquema da fase 1 (off-line) do método de remoção proposto.....	56
Figura 23-	Fluxograma do algoritmo do método proposto (tempo real).....	58
Figura 24-	Subgrupos criados para a estimação e realização de testes utilizando k-fold (Validação Cruzada). Em laranja, são os subgrupos de estimação e em azul são os subgrupos de teste.....	62
Figura 25-	Exemplo do ciclo de estimação e teste realizado para o indivíduo 1.....	63

Figura 26-	Exemplo de um sinal de EEG adquirido e que ainda não passou por nenhum método de remoção de artefatos.....	64
Figura 27-	Mesmo sinal de EEG da Figura 26 após aplicado o método de remoção de artefatos de referência off-line da Seção 4.2.....	65
Figura 28-	Mesmo sinal de EEG da Figura 26 após aplicado o método de remoção de artefatos de tempo real da Seção 4.3.....	66
Figura 29-	Destaque dos artefatos de piscada presentes em um dos sinais de EEG adquiridos, anteriormente a utilização dos métodos de remoção de artefatos.....	66
Figura 30-	Mesmo sinal de EEG da Figura 29 destacando os pontos onde haviam artefatos de piscada, após a utilização do método de referência off-line da Seção 4.2.....	67
Figura 31-	Mesmo sinal de EEG da Figura 29 destacando os pontos onde haviam artefatos de piscada, após a utilização do método de remoção de tempo real Seção 4.3.....	67
Figura 32-	Destaque de um artefato de EMG presente em um dos sinais de EEG adquiridos, anteriormente a utilização dos métodos de remoção de artefatos.....	68
Figura 33-	Mesmo sinal de EEG da Figura 32 destacando o canal onde havia artefato de EMG, após a utilização do método de referência off-line da Seção 4.2.....	69
Figura 34-	Mesmo sinal de EEG da Figura 32 destacando o canal onde havia artefato de EMG, após a utilização do método de tempo real da Seção 4.3.....	70
Figura 35-	Artefato de piscada de olhos criado artificialmente.....	71
Figura 36-	Sinal de EEG sem artefato ocular ao qual foi adicionado o artefato ocular criado artificialmente.....	71
Figura 37-	Trecho do sinal de EEG após somado o artefato de piscada dos olhos.....	72
Figura 38-	Trecho do sinal de EEG resultante após a remoção do artefato de piscada com a utilização do método.....	73
Figura 39-	Espectro do sinal de EEG após adicionado o artefato de piscada (vermelho), do sinal resultante após a aplicação do método (verde) e o sinal	

	original sem artefato (azul).....	74
Figura 40-	Gráfico demonstrando as médias dos erros percentuais obtidos para cada teste da Validação Cruzada para o Método Proposto.....	78
Figura 41-	Gráfico demonstrando as médias dos NRMSE obtidos para cada teste da Validação Cruzada para o Método Proposto.....	78

LISTA DE TABELAS

Tabela 1 -	Características de sinais bioelétricos.....	22
Tabela 2 -	Resultados dos erros relativos percentual e NRMSE para cada grupo de teste da Validação Cruzada, da comparação entre o método de referência e o Método proposto.	77

LISTA DE ABREVIATURAS E SIGLAS

AAR	<i>Adaptive Autoregressive</i>
BCI	<i>Brain Computer Interface</i>
BSS	<i>Blind Source Separation</i>
ECG	Eletrocardiografia
EEG	Eletroencefalografia
EMG	Eletromiografia
EOG	Eletro-oculografia
FIR	<i>Finite Impulse Response</i>
fMRI	Ressonância Magnética Funcional
ICA	<i>Independent Component Analysis</i>
IIR	<i>Infinite Impulse Response</i>
LMS	<i>Least Mean-Squares</i>
MDE	Modo de decomposição empírico
NRMSE	<i>Normalized root-mean-square-Error</i>
OMS	Organização Mundial de Saúde
PCA	<i>Principal Component Analysis</i>
PET	<i>Positron Emission Tomography</i>
RLS	<i>Recursive Least-Square</i>
SOBI	<i>Second-Order Blind Identification</i>
FPGA	<i>Field-Programmable Gate Array</i>

SUMÁRIO

1	INTRODUÇÃO.....	15
1.1	Objetivos.....	17
1.2	Organização da Dissertação.....	17
2	FUNDAMENTAÇÃO TEÓRICA.....	19
2.1	Sinais Bioelétricos.....	19
2.2	O sinal de Eletroencefalografia.....	22
2.3	Aquisição do sinal de Eletroencefalografia.....	25
2.3.1	<i>Eletrodos.....</i>	<i>26</i>
2.3.2	<i>Amplificação do sinal.....</i>	<i>29</i>
2.3.3	<i>Equipamentos de Eletroencefalografia.....</i>	<i>30</i>
2.4	Remoções de artefatos.....	33
2.4.1	<i>Artefatos.....</i>	<i>33</i>
2.4.1.1	<i>Artefatos de EOG.....</i>	<i>34</i>
2.4.1.2	<i>Artefatos de EMG.....</i>	<i>35</i>
2.4.1.3	<i>Artefatos de ECG.....</i>	<i>36</i>
2.4.1.4	<i>Outros artefatos fisiológicos.....</i>	<i>37</i>
2.4.2	<i>Métodos de Remoção de Artefatos.....</i>	<i>38</i>
2.4.2.1	<i>Filtragem do sinal.....</i>	<i>39</i>
2.4.2.2	<i>Regressão Linear.....</i>	<i>41</i>
2.4.2.3	<i>Decomposição de fontes.....</i>	<i>41</i>
2.4.2.4	<i>Blind Source Separation (BSS)</i>	<i>42</i>
2.4.2.5	<i>Combinação de métodos.....</i>	<i>42</i>
2.4.2.6	<i>Conclusão da análise dos métodos de remoção.....</i>	<i>44</i>
3	DETALHAMENTO DE BSS E ICA.....	46
3.1	BSS.....	46
3.2	ICA.....	47
4	DESENVOLVIMENTO DO MÉTODO.....	51
4.1	Aquisição de Dados.....	51
4.2	Método de referência para comparação.....	53
4.3	Método proposto para remoção em tempo real.....	55
4.4	Metodologia de análise de resultados e comparação dos métodos propostos.	58
5	RESULTADOS.....	64

5.1	Resultados da análise comparativa visual.....	64
5.2	Resultados da remoção do artefato artificial e análise espectral.....	70
5.3	Resultado do tempo de execução do método proposto e análise para embarcar o método proposto.....	74
5.4	Resultados quantitativos de comparação entre os métodos propostos e o método de referência.....	76
6	CONCLUSÃO.....	80
	REFERÊNCIAS.....	82

1 INTRODUÇÃO

Os primeiros tipos de registros de sinais bioelétricos sob a forma impressa foram realizados por Jean Marie Duhamel em 1842 e, mais tarde por Max Wertheim em 1844 (HOFF; GEDDES, 1959). Foram realizados registros gráficos da pressão sanguínea de acordo com uma variação dos batimentos cardíacos em animais sobre uma superfície enfumaçada para minimizar o atrito de uma pena.

Em 1883, James Mackenzie desenvolveu um polígrafo, capaz de fazer longos registros em rolos de papel (MACKENZIE, 1910). Com este equipamento foi possível realizar registros do funcionamento do coração e o significado de várias arritmias. Apenas em 1924, foram realizados os primeiros registros de sinais elétricos cerebrais por Hans Berger (HAAS, 2003).

Desde então, a importância da aquisição de sinais bioelétricos só vem aumentando e, hoje, é amplamente utilizada no cotidiano de ambientes hospitalares no auxílio de diagnósticos, permitindo que inúmeras patologias possam ser detectadas com o estudo destes tipos de sinais. Desta forma, novas tecnologias para o estudo e processamento destes sinais são necessárias. Os tipos mais comuns de sinais bioelétricos são o ECG (eletrocardiograma), EEG (eletroencefalograma), EMG (eletromiograma) e o EOG (eletro-oculograma).

O EEG é o sinal base de estudo neste trabalho. A técnica para a sua obtenção consiste em dispor-se eletrodos sobre o escalpo e em uma referência para, em seguida, registrarem-se as atividades elétricas captadas pelos mesmos e representá-las de maneira conveniente (BUTTON, 2003). O cérebro é formado por bilhões de células nervosas, cada qual recebe sinais elétricos de outros neurônios e os retransmite a outras células nervosas. Todas as funções do cérebro, incluindo sensibilidade, raciocínio, emoções e reflexos dependem desta transmissão de sinais elétricos (AIRES, 1997).

Atualmente, o EEG é usado extensivamente em neurociências, ciências cognitivas, psicologia cognitiva, neurolinguística e em diferentes pesquisas (URIGÜEN; GARCIA-ZAPIRAIN, 2015). Além disso, é frequentemente utilizado para o diagnóstico de várias condições cerebrais, como a determinação do tipo e localização da atividade epiléptica ou para análise de distúrbios do sono (NUNEZ; SRINIVASAN, 2005), bem como outras disfunções neurológicas como encefalopatias, infecções neurológicas, demência, entre outras (SMITH, 2005).

Tradicionalmente, o EEG tem sido usado para análises médicas e aplicações médicas de interface cérebro computador (em inglês, *Brain Computer Interface* - BCI), mas, nos

últimos anos, tem aumentado o interesse de aplicações não médicas de BCI como controle de dispositivos, treinamento e educação, jogos e entretenimento (HAMMOND, 2007; VAN ERP; LOTTE; TANGERMANN, 2012; MATIKO; BEEBY; TUDOR, 2013).

O *neurofeedback* é um tipo de aplicação do EEG tanto para tratamento de distúrbios como o déficit de atenção quanto para o treinamento e melhoria do desempenho cerebral. O *neurofeedback* é um tipo de *biofeedback*, em que no caso, as ondas cerebrais são utilizadas como *feedback* em tempo real para a pessoa que está realizando o treinamento. Esta aplicação do EEG é utilizada no tratamento de ansiedade e para relaxamento (LANTYER; VIANA; PADOVANI, 2013), bem como para a melhora de desempenho (humor, atenção, entre outros fatores) em pessoas saudáveis (VERNON et al., 2009). É intuito neste trabalho, o desenvolvimento de algoritmos de processamento de EEG capazes de serem utilizados em aplicações de *neurofeedback*.

O EEG fornece informações clinicamente valiosas bem como permite a realização de tratamentos, confirmando a importância de desenvolver métodos que possibilitem uma melhor interpretação e utilização deste sinal, logo, as diferentes aplicações do EEG são, por si só, uma motivação para o estudo deste sinal.

Os sistemas de aquisição de sinais bioelétricos enfrentam um grande desafio que, devido as características destes sinais, eles são facilmente susceptíveis a ruídos. Os artefatos são sinais indesejáveis que podem introduzir mudanças no sinal de interesse (URIGÜEN; GARCIA-ZAPIRAIN, 2015) e, entre os sinais bioelétricos, o EEG é um dos mais vulneráveis a esse tipo de influências. Como por exemplo, a presença de sinais no ambiente da aquisição que interferem no sinal analisado, tais como a rede elétrica (60 Hz), radiações eletromagnéticas emitidas por aparelhos eletroeletrônicos e torres de transmissão de sinais de TV, rádio e celulares (DUTRA, 2012).

Além de artefatos de origem ambiental, comumente chamados de ruídos, existem os artefatos biológicos causados por interferências dos sinais fisiológicos da pessoa que está sendo submetida à aquisição, como por exemplo, artefatos musculares, artefatos eletrocardiográficos, movimentos dos olhos, a movimentação durante a respiração, potenciais da pele, entre outros. Desta forma, todos esses fatores devem ser levados em consideração para o desenvolvimento de um sistema de aquisição de EEG.

A remoção de artefatos é uma questão importante no processamento do sinal EEG e, normalmente, um pré-requisito para que a análise de sinal seja mais confiável no caso de aplicações clínicas, assim como para as aplicações mais recentes. A literatura sobre a remoção de artefatos de EEG é muito ampla e, até o momento, não há uma definição de um método

melhor que todos os outros (URIGÜEN; GARCIA-ZAPIRAIN, 2015). Um ponto importante é que, devido às fontes de ruídos serem muito diversas e com características diferentes, a maioria dos autores escolhe e se concentra na remoção de apenas um tipo de artefato (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

Durante a última década, apenas alguns métodos inovadores foram propostos na área de remoção de artefatos, além de abordagens clássicas existentes, como regressão linear, filtragem ou separação cega de fontes (mais amplamente utilizada). Em vez disso, a área evoluiu com a melhora dos algoritmos existentes, combinando diferentes métodos ou tentando tornar o processo de remoção automático e criando simulações mais realistas e métricas de desempenho mais objetivas (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

Desta forma, pode-se concluir que há a necessidade do desenvolvimento de novos algoritmos para remoção de artefatos do sinal de EEG, tendo em vista as diversas aplicações do EEG.

1.1 Objetivos

Este trabalho tem o objetivo de desenvolver técnicas de processamento digital de sinais capazes de remover artefatos dos sinais de eletroencefalografia, para aplicações em *Neurofeedback*.

Os objetivos específicos desse trabalho são:

- Aquisição de sinais de eletroencefalografias de voluntários, para a realização de métodos de remoção de artefatos.
- Desenvolvimento de algoritmos de remoção de artefatos de EEG possíveis de serem utilizados em tempo real em aplicações de *Neurofeedback* e de baixo consumo computacional.
- Desenvolvimento de métodos para testar os desempenhos dos algoritmos desenvolvidos para a remoção de artefatos.

1.2 Organização da Dissertação

No segundo capítulo (Fundamentação Teórica) é feita a fundamentação teórica, onde é explicitada a origem dos sinais bioelétricos e suas características, aprofundando-se nos principais tipos que podem ser captados, sobretudo, o estudo a respeito do sinal de eletroencefalografia, observando aspectos da sua aquisição, bem como dos artefatos presentes neste sinal.

Além disso, é feito um panorama dos dispositivos mais presentes no mercado mundial. Em seguida, neste mesmo capítulo, é feita uma revisão dos principais e mais utilizados métodos de remoção de artefatos.

No terceiro capítulo é realizada a descrição detalhada dos métodos desenvolvidos, explicando-se desde a aquisição dos dados utilizados como base deste trabalho, bem como o desenvolvimento dos filtros espaciais propostos a partir do algoritmo de Análise de Componentes Independentes e as técnicas criadas para a remoção dos artefatos. Além disso, são explicados como foram desenvolvidos os métodos para medição de desempenho, apresentando os sinais utilizados para comparação com os resultantes dos métodos de remoção desenvolvidos neste trabalho.

O quarto capítulo apresenta os resultados referentes à aquisição e a todos os passos das técnicas de processamento desenvolvidas. Além de serem feitas análises e discussões com relação ao desempenho dos métodos propostos.

Por fim, o quinto capítulo expõe as conclusões deste trabalho além de discutir propostas de trabalhos futuros para esta pesquisa.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são abordados os fundamentos teóricos dos sinais bioelétricos, observando-se desde suas origens até o aprofundamento no sinal biológico base deste trabalho, a eletroencefalografia (EEG). Além disso, serão analisados métodos e detalhes da aquisição destes sinais.


Em seguida, será feito um panorama dos mercados nacional e internacional de Neurotecnologia com foco nos sistemas de aquisição existentes para aquisição de EEG. Por fim, abordam-se os métodos existentes na literatura para a remoção dos principais tipos de artefatos existentes nos sinais de EEG.

2.1 Sinais Bioelétricos

Os diferentes órgãos do corpo humano, tais como coração, cérebro, músculos e olhos, exercem suas funções por meio de geração de atividade elétrica nos mesmos. Entre os sinais mais conhecidos, estão o Eletroencefalograma (EEG - atividade elétrica do cérebro), Eletromiograma (EMG - atividade elétrica relacionada a contração e relaxação dos músculos) e o Eletro-oculograma (EOG - resposta ao movimento dos olhos). O registro destes sinais é utilizado em diversas aplicações nas áreas de medicina, odontologia, fonoaudiologia e fisioterapia, já que podem fornecer informações importantes no estudo de funções normais ou patológicas dos órgãos humanos (SILVA, 2014).

A origem dos biopotenciais pode ser considerada a partir da atividade elétrica a nível celular. O potencial elétrico através da membrana de uma célula é resultado de diferentes concentrações iônicas que existem no meio intra e extracelulares. A estrutura da membrana que reveste cada célula do corpo humano consiste quase inteiramente de uma camada bilipídica, contendo também grande número de moléculas de proteínas, incrustadas nos lipídios, algumas delas atravessando toda espessura da membrana, como na Figura 1. Essas proteínas intrínsecas podem atuar como canais iônicos e transportadores, permitindo a comunicação do citoplasma com o meio extracelular (GUYTON; HALL, 2011).


Figura 1 - Estrutura da membrana celular



Fonte: Guyton e Hall (2011).

A alteração do potencial de membrana e a propagação deste ao longo da membrana da fibra nervosa recebe o nome de potencial de ação. Este é o responsável pela transmissão dos sinais nervosos nos tecidos. O potencial de ação tem a duração de poucos milissegundos e, nele, pode-se identificar três estágios. O primeiro é o de repouso, quando a célula se encontra polarizada. O estágio de despolarização é o subsequente, quando o potencial de membrana detém valor positivo. Por fim, tem-se o estágio de repolarização, quando há a restituição do potencial de repouso da membrana. Durante o potencial de ação ocorre, portanto, a inversão rápida da polaridade nos meios intra e extracelulares, seguida da repolarização (GUYTON; HALL, 2011). Na Figura 2, pode-se ver o resumo das fases do potencial de ação seguindo o que foi descrito.

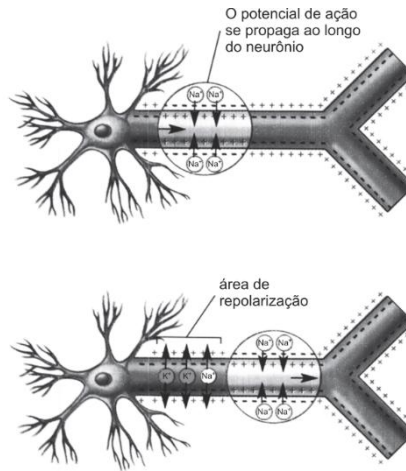
Figura 2 - Fases do potencial de ação



Fonte: Guyton e Hall (2011).

Enquanto acontece o potencial de ação em qualquer local da membrana celular, ocorre a abertura de canais de sódio dependentes de voltagem nas porções adjacentes da membrana. A partir deste ponto, ocorre a propagação do potencial de ação por toda a fibra nervosa e, conseqüentemente, a transmissão de sinais. É possível ver na Figura 3 o exemplo da propagação do potencial de ação em uma célula nervosa.

Figura 3 - Propagação do Potencial de Ação na célula nervosa



Fonte: Aires (1997).

Estes sinais elétricos em nível celular geram os sinais que são utilizados para estudos e análises. O sinal de eletromiografia (EMG), por exemplo, é relacionado a contração muscular e surge da excitação de neurônios, transmitida de um nervo a uma junção neuromuscular produzindo estímulos nas fibras nervosas. Elementos constitutivos de fibras musculares são as unidades motoras simples e sua atividade elétrica é chamada de potencial motor unitário (BRONZINO, 1995). A atividade elétrica de um grande número de unidades motoras simples manifesta-se na superfície do corpo como o sinal de EMG (SILVA, 2014).

O Eletro-oculograma (EOG) é relacionado ao movimento ocular. Este se origina da diferença de potencial entre a córnea e a retina que forma um dipolo elétrico entre esses dois extremos do eixo córnea. O movimento do globo ocular relativo ao dipolo altera esse potencial elétrico e, com a colocação de eletrodos na vizinhança dos olhos, é possível medir o potencial associado com este movimento dos olhos (SILVA, 2014).

Já o sinal de Eletroencefalograma (EEG) é relacionado a atividade elétrica cerebral. A excitação elétrica de um neurônio produz um potencial de ação que se desloca entre seus dendritos e axônio. No córtex cerebral estão localizados os corpos dos neurônios e seus axônios na parte mais interna do cérebro. A atividade de um grande número de neurônios e

suas interações com o córtex resulta no sinal de EEG (KANDEL; SCHWARTZ; JESSELL, 2000).

Na Tabela 1, é possível ver um resumo de algumas características dos principais sinais bioelétricos, onde nota-se que o EEG, é um dos sinais com menor amplitude.

Tabela 1 - Características de sinais bioelétricos.

Tipos de sinais	Faixa de Frequência (Hz)	Faixa de Amplitude (V)
Eletromiograma	1-500	50 μ -5m
Eletro-oculograma	0-100	10 μ -5m
Eletroencefalograma	0,5-100	2 μ -100 μ
Eletrocardiograma	0,05-100	1m-10m

Fonte: Modificado de Cohen (1995)

2.2 O sinal de Eletroencefalografia

O cérebro é formado por bilhões de células nervosas, cada qual recebendo sinais elétricos de outros neurônios e os retransmitindo a outras células nervosas. Todas as funções do cérebro, incluindo sensibilidade, raciocínio, emoções e reflexos dependem desta transmissão de sinais elétricos (AIRES, 1997).

Cada tecido do organismo humano possui um grupo de células diferenciadas com propriedades semelhantes que o caracterizam. As células nervosas (neurônios) são as responsáveis por formar o tecido neural e possuem como característica a capacidade de iniciar e conduzir sinais elétricos (WIDMAIER; RAFF; STRANG, 2006). Esses sinais elétricos são responsáveis por controlar e por enviar informações às outras células do organismo.

O conjunto de potenciais elétricos gerados pela soma dos potenciais pós-sinápticos disparados pelos neurônios piramidais e capturados em um determinado tempo e região, forma o sinal de Eletroencefalografia (EEG) (SPECKMANN; WALDEN, 1991).

A atividade elétrica do EEG é uma medida atenuada do fluxo de corrente extracelular do somatório de atividades de diversos neurônios. No entanto, nem todas as células nervosas contribuem igualmente. O EEG reflete predominantemente a atividade dos neurônios corticais próximos ao eletrodo fixado. A forma de onda detectada pelo eletrodo de superfície depende da orientação e da distância da fonte elétrica em relação ao eletrodo (KANDEL; SCHWARTZ; JESSELL, 2000).

O sinal de EEG é atenuado devido a intervenção das camadas de tecido e osso. Assim, a amplitude do potencial de EEG (microvolts) é o resultado do somatório de tensão de um agrupamento de neurônios muito menor do que as variações de tensão em um único neurônio (milivolts) (SILVA, 2014). A amplitude do sinal EEG está relacionada com a sincronização ou não da excitação dos neurônios geradores (NUNEZ; SRINIVASAN, 2005; DELORME et al., 2012).

Atualmente, o EEG está sendo amplamente utilizado em neurociência, ciências cognitivas, psicologia cognitiva, neurolinguística e entre outras aplicações. Desta forma, aplicações que vão além do seu uso mais tradicional (URIGÜEN; GARCIA-ZAPIRAIN, 2015). De maneira mais específica, o EEG é frequentemente empregado para o diagnóstico de várias condições cerebrais, tal como determinar o tipo e a localização da atividade epiléptica ou para analisar distúrbios do sono (SANEI; CHAMBERS, 2007), além disso, é utilizado na análise de outras disfunções neurológicas como encefalopatias, infecções neurológicas, demência, entre outras (SMITH, 2005).

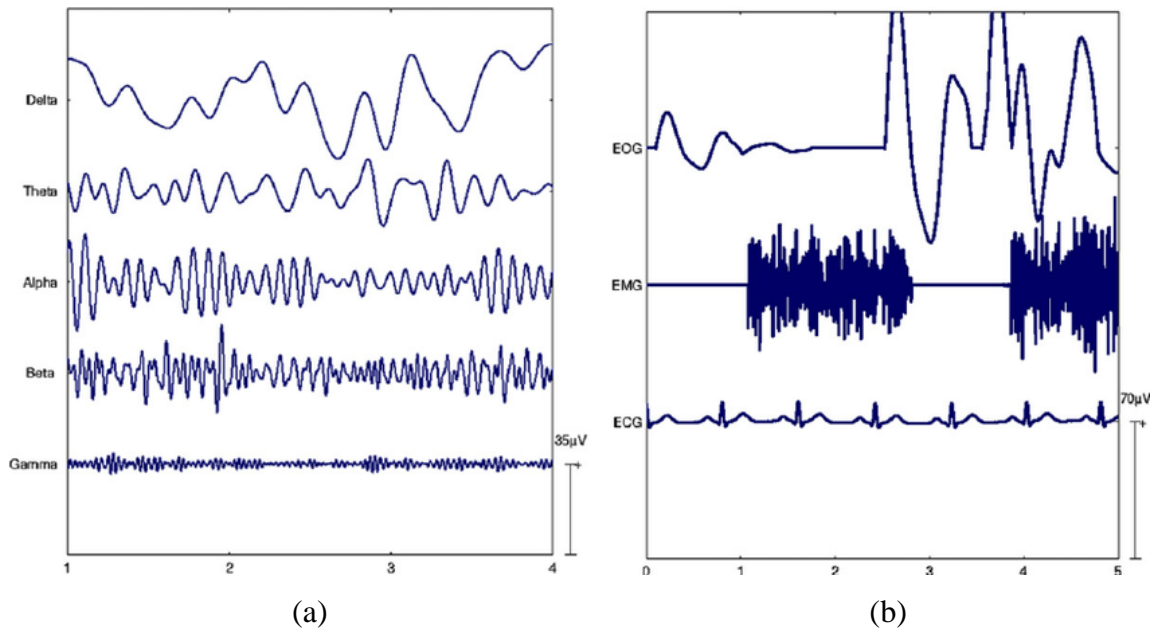
Os diferentes tipos de formas de onda do EEG transmitem informações clinicamente valiosas, por isso é importante desenvolver métodos para a aquisição e quantificação objetiva das características do sinal de forma que facilite a sua interpretação (URIGÜEN; GARCIA-ZAPIRAIN, 2015). Muitos fenômenos neurológicos podem ser registrados tais como: mudanças nos ritmos cerebrais, potenciais relacionados ao movimento, potenciais corticais lentos, potenciais evocados, entre outros (FATOURECHI, 2007).

Os ritmos do EEG são comumente classificados em cinco diferentes tipos por suas bandas de frequência (URIGÜEN; GARCIA-ZAPIRAIN, 2015):

- Ritmo ou ondas Delta: 0,5 - 4Hz
- Ritmo ou ondas Teta: 4 - 7Hz
- Ritmo ou ondas Alfa: 8 - 13Hz
- Ritmo ou ondas Beta: 13 - 30Hz
- Ritmo ou ondas Gama: >30Hz (tipicamente <100Hz)

Na Figura 4 (a), podem-se ver os tipos de ondas de EEG descritas. Algumas informações podem ser extraídas a partir da análise destes tipos de ondas, no entanto é preciso observar que as características destas ondas variam dependendo da idade e do estado mental do indivíduo (SANEI; CHAMBERS, 2007). Em algumas ocasiões, estes ritmos do EEG e suas variações são utilizados para o controle de interfaces cérebro máquina (SILVA, 2014).

Figura 4 - (a) Tipos de onda de EEG; (b) Sinais eletrofisiológicos comuns.



Fonte: Urigüen e Garcia-Zapirain (2015).

Em geral, não é possível prever as características exatas do sinal EEG em termos de amplitude, duração ou forma, desta maneira, não é possível realizar o registro de um sinal de EEG "puro". Por isso, é razoável considerar o EEG como um processo estocástico mesmo que algumas características do sinal sejam conhecidas (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

Um ponto importante com relação a aquisição do sinal de EEG é que, por ter uma pequena amplitude como descrito na Tabela 1, este sinal é facilmente contaminado com artefatos, ou seja, sinais indesejáveis que podem introduzir mudanças nas medições e afetar o sinal de interesse. A forma ideal de realizar a aquisição do sinal de EEG é evitar a ocorrência de artefatos no momento da gravação dos dados, no entanto, o sinal é muitas vezes contaminado por vários fatores fisiológicos diferentes da atividade cerebral, que não são tipicamente de interesse, como pode ser visto na Figura 4(b) (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

Ressalta-se que, além do EEG, outras tecnologias são utilizadas para o monitoramento da atividade cerebral. Entre elas estão a tomografia por emissão de pósitrons (PET) e ressonância magnética funcional (fRMI) (PHAN et al., 2002) que possuem uma melhor resolução espacial que o EEG, mas uma resolução temporal inferior.

2.3 Aquisição do sinal de Eletroencefalografia

Nesta seção, são abordados pontos em relação a aquisição e condicionamento do sinal de EEG, pois este é o sinal de interesse de estudo deste trabalho.

Tradicionalmente, a técnica para a obtenção do EEG consiste em disporem-se eletrodos sobre o escalpo para, em seguida, registrar-se as atividades elétricas captadas por estes e representá-la de maneira conveniente (BUTTON, 2003). Os eletrodos são colocados sobre o escalpo com a utilização de pastas especiais para a aderência sobre o couro cabeludo e condução do sinal (CAPARELLI, 2007) ou com a utilização de uma touca como é possível ver na Figura 5, onde é utilizado, em geral, um gel que auxilia na condução do sinal.

Estes sistemas de aquisição de EEG tradicionais são conectados por cabos a um amplificador que fica, normalmente, sobre uma mesa. Desta maneira, estes sistemas não facilitam a execução de tarefas de movimento (mais reais e do cotidiano) devido aos cabos, tamanho, peso e portabilidade dos dispositivos (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017).

Figura 5 - Exemplo de touca de EEG



Fonte: Bio-medical (2017).

Nos últimos anos, tecnologias mais sofisticadas têm sido abordadas na comunidade de pesquisa que sejam capazes de monitorar e acompanhar a saúde humana, tais como o eletrocardiograma (ECG) e a eletroencefalografia (EEG). Apesar do EEG ser muito utilizado no domínio clínico, raramente é levado para fora dos hospitais e assim encontra inúmeras dificuldades para ser usado em aplicações da vida diária (MIHAJLOVIĆ et al., 2015).

A utilização padrão dos aparelhos de aquisição de EEG (em hospitais) requer um procedimento de preparação complexo e demorado que, por vezes, pode levar a experiências desagradáveis, envolvendo a preparação da pele e também a utilização de pastas ou géis

condutores. Isto está longe de ser fácil de usar, confortável e conveniente (MIHAJLOVIĆ et al., 2015).

Por consequência, o EEG comumente utilizado apenas em aplicações clínicas, tal como a previsão de epilepsia (NOACHTAR; RÉMI, 2009). Outra aplicação é na avaliação de pessoas após um evento traumático e monitoramento da recuperação cerebral após uma lesão (ZIAI et al., 2012).

Uma das poucas áreas de aplicação que começam a explorar o uso de soluções de EEG no cotidiano das pessoas (MIHAJLOVIĆ et al., 2015) tem sido na utilização por indivíduos saudáveis na busca de melhores desempenhos (atenção, humor, entre outros fatores) (VERNON et al., 2009) e pessoas com problemas cognitivos como o transtorno por déficit de atenção (ARNS et al., 2009) ambos através do uso de *Neurofeedback*.

Nos últimos anos, observa-se uma tendência crescente de indivíduos e instituições governamentais preocupados com a saúde mental devido ao aumento da prevalência de transtornos cerebrais, como a depressão que já é considerada pela OMS (Organização Mundial de Saúde) a doença mais incapacitante do mundo (WORLD HEALTH ORGANIZATION, 2017).

Estas questões indicam que é necessário o progresso substancial no desenvolvimento de tecnologias para o monitoramento conveniente, sem fio e portátil do EEG. Desta forma, vários centros de pesquisas estão empenhados no desenvolvimento de soluções de sistemas de aquisição de EEG que possam ser utilizados no cotidiano das pessoas (LIN et al., 2008; CHEN; WANG, 2011; MORIKAWA et al, 2013).

2.3.1 Eletrodos

Os eletrodos são uma parte importante dos sistemas de aquisição de sinais elétricos cerebrais. Muitos ruídos introduzidos ao sinal são devidos à má colocação ou má qualidade dos mesmos. Além disso, o tipo de eletrodo pode variar com a aplicação. Os eletrodos são classificados nos seguintes grupos (DUTRA, 2012):

- Não invasivos: Aplicados sobre o escalpo.
- Invasivos: Utilizados para aquisição do sinal direto no córtex. Neste caso, o sinal adquirido se chama eletrocorticografia.

A diferença entre o potencial adquirido por dois eletrodos distintos é referenciada como derivação (ou canal) e pode ser classificado como monopolar ou bipolar (GEDDES; BAKER, 1989). Nas derivações monopolares o registro é resultante da diferença de potencial

de um eletrodo e um potencial de referência que pode ser de outra parte do corpo sem ser o crânio. Já as derivações bipolares são resultantes da diferença de potencial de dois eletrodos no crânio.

Esses eletrodos são, em geral, fabricados com a utilização de metais ou ligas metálicas. O material mais comum é o Ag/AgCl (SILVA, 2014) no entanto é também comum encontrar eletrodos de ouro, de latão e de prata. E, a depender do formato, podem ser presos diretamente no escalpo ou através de toucas (Figura 5).

Os eletrodos também são classificados de outra maneira, quanto a utilização ou não de pasta ou gel condutivo. Sendo assim, são classificados em eletrodos molhados ou secos, em que os mais tradicionais são os molhados e sendo considerados o padrão-ouro (LOPEZ-GORDO; SANCHEZ-MORILLO; PELAYO-VALLE, 2014). Os primeiros requerem a preparação da pele e o uso de gel ou pasta condutora para melhorar a impedância da interface eletrodo-couro cabeludo. Essa preparação é demorada, o que contribui para a fadiga do usuário e requer o apoio de pessoas treinadas para a realização do posicionamento (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017).

Os eletrodos de EEG secos são uma boa alternativa para aplicação deste sinal no cotidiano das pessoas. É possível encontrar na literatura, algumas diferentes propostas deste tipo de eletrodo (SULLIVAN et al., 2008; ESTEPP et al., 2009). Idealmente, eles são capazes de realizar a aquisição de potenciais do couro cabeludo sem a necessidade de preparação. No entanto, esse tipo de eletrodo ainda não é uma unanimidade entre os pesquisadores, pois muitos consideram que os tradicionais eletrodos de EEG molhados fornecem uma qualidade melhor dos sinais em comparação aos eletrodos de EEG seco (LOPEZ-GORDO; SANCHEZ-MORILLO; PELAYO-VALLE, 2014).

Apesar disso, o eletrodo seco demonstra fortes vantagens com relação ao eletrodo molhado, como a colocação mais ágil do sistema e o uso mais confortável. É importante ressaltar que alguns trabalhos declaram que ambos os tipos de eletrodos (seco e molhado) fornecem um sinal com nível de qualidade semelhante (CHI; JUNG; CAUWENBERGHS, 2010; LIAO et al., 2011).


Os eletrodos, geralmente, são distribuídos utilizando o Sistema Internacional 10-20 que foi publicado em 1958 (JASPER, 1958), sendo o método mais utilizado para descrever a colocação de eletrodos em intervalos específicos ao longo da cabeça. Ele utiliza 21 pontos que são marcados dividindo-se o crânio em proporções de 10% ou 20% do comprimento das distâncias entre os pontos de referência, násio e ínio no plano medial e os pontos pré-auriculares no plano perpendicular ao crânio. Tradicionalmente, o número de canais não

excede 64, no entanto novos padrões, como 10-10 (CHATRIAN; LETTICH; NELSON, 1985) e 10-5 (cinco por cento) (OOSTENVELD; PRAAMSTRA, 2001) permitiram estudos de EEG de alta densidade com 128-256 canais (PISARENCO et al., 2014).

Apesar do aumento de eletrodos possibilitar uma maior densidade de captação e resolução espacial, este tipo de sistema apresenta desvantagens devido ao maior tempo de preparação e dificultando a usabilidade, o que torna esse tipo de sistema quase que restrito ao uso em pesquisas (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017).


Na Figura 6, pode-se ver a distribuição dos eletrodos no sistema 10-20 e na Figura 7 a distribuição dos eletrodos no sistema 10-10.

Figura 6 - Distribuição de eletrodos no sistema 10-20



Fonte: NR SIGN (2017).

Figura 7 - Distribuição de eletrodos no sistema 10-10




Fonte: Fieldtrip (2017).

2.3.2 Amplificação do sinal

O desenvolvimento de sistemas de aquisição de sinais bioelétricos tem um grande desafio que são os valores de amplitude muito baixos (TEXAS INSTRUMENTS, 2017) como pode ser visto alguns exemplos na Tabela 1. Portanto, é necessário um sistema de condicionamento do sinal, para que seja efetuada a medição e processamento de forma eficaz, onde sua primeira etapa é a amplificação.

Para isso, utilizam-se amplificadores operacionais para a realização desta tarefa. Amplificador Operacional é um circuito integrado linear, com elevado ganho de tensão e que usa externamente uma rede de realimentação negativa para controlar suas características de operação. Na Figura 8, é representado um amplificador operacional.


Figura 8 - Amplificador operacional



Fonte: Nova Eletrônica (2017).

Entre todos os tipos de amplificadores, o amplificador de instrumentação é o mais utilizado para realizar a aquisição de sinais bioelétricos. O amplificador de instrumentação é um circuito integrado cuja configuração é no modo diferencial, possuindo três amplificadores operacionais. Este tipo de dispositivo fornece uma saída baseada na diferença entre duas entradas. Assim, pode ser dividido em dois estágios: no primeiro estágio, há um amplificador não-inversor em cada uma das entradas e na segunda etapa existe um amplificador configurado como diferencial em que as entradas são as saídas dos amplificadores não-inversores. Na Figura 9, é possível ver a estrutura do amplificador de instrumentação.

Figura 9 - Amplificador de Instrumentação



Fonte: ALL ABOUT CIRCUITS (2017).

Uma característica deste tipo de amplificador é a capacidade de fornecer uma rejeição de modo-comum descrita por um parâmetro chamado de razão de rejeição de modo-comum (*Common-Mode Rejection Ratio* - CMRR). A CMRR deve ser alta, em torno de 80dB a 120dB, para que o amplificador de instrumentação apresente boa atenuação dos artefatos.

Outra característica é que pode ter o ganho programado por meio de um único resistor (R_{gain} da Figura 9). Além dessas vantagens o amplificador de instrumentação possui as seguintes características:

- Alta Impedância de entrada: Da ordem de 1.000K Ω .
- Baixa Impedância de saída: valor próximo de 0,1 Ω .
- Baixo ruído.
- Baixos desvios.
- Baixa não linearidade.
- Ganho estável.

2.3.3 Equipamentos de Eletroencefalografia

A evolução dos primeiros equipamentos desenvolvidos capazes de registrar a atividade elétrica do cérebro ocorreu, principalmente, pelos avanços tecnológicos da eletrônica, em que os equipamentos se tornaram mais compactos, precisos e sensíveis (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017). Além da maior participação da computação para a realização desses registros (DUTRA, 2012). Os eletroencefalógrafos podem ser divididos quanto a sua estrutura em dois tipos (DUTRA, 2012):

- Analógico: Em equipamentos desse tipo o sinal é registrado diretamente em uma folha de papel. Foram os primeiros equipamentos e são pouco utilizados hoje em dia.
- Digital: Em equipamentos desse tipo o sinal sofre uma conversão analógico-digital de forma que seja possível a exibição deste sinal em um monitor de vídeo ou computador. Além disso, este tipo de equipamento facilita a realização de técnicas de processamento.

Quanto aos tipos de monitoramento, podem ser classificados como (BERTEMES FILHO, 1998):

- Estacionário: Neste modo é realizado o EEG de forma tradicional onde o paciente encontra-se em repouso em um leito.
- Móvel: Neste modo o paciente pode se mover no ambiente dedicado a este tipo de exame.
- Ambulatorial: O paciente fica completamente livre para se movimentar em uma unidade ambulatorial longe do hospital.

Alguns fatores e parâmetros destacam-se na estrutura de um Eletroencefalógrafo. Alguns deles são (DUTRA, 2012):

- Número de canais: Relativo ao número de canais medidos simultaneamente. Há equipamentos de 1 canal à equipamentos de 268 canais.
- Amplificadores: Os amplificadores utilizados e suas características (ganho, rejeição de modo comum, impedâncias de entrada e saída) são de grande relevância.
- Taxa de amostragem: Nos equipamentos digitais, este é um importante parâmetro, logo que deve ser observado o Teorema da Amostragem de maneira que garanta uma boa representação do sinal.
- Seleção de Montagem: Relacionado ao tipo de eletrodo a ser utilizado e o sistema de distribuição deste.

Nos últimos anos, há um número crescente de novos produtos no mercado que visam a aquisição do sinal de EEG de uma maneira mais simples do que os sistemas tradicionais, principalmente, usando eletrodos secos (MIHAJLOVIĆ et al., 2015). Algumas empresas e grupos de pesquisa criaram sistemas que utilizam comunicação sem fio, como o *Bluetooth* e que, além disso, são pequenos e com baixo consumo de energia, proporcionando assim portabilidade e os tornando em sistemas vestíveis (*wearables*) (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017). Na Figura 10, pode-se ver alguns equipamentos do mercado.

Figura 10 - Sistemas de EEG. (a) e (b): Sistemas da cognionics. (c) Emotiv Epoc (d) g.Nautilus da g.tec (e) Enobio da Neuroelectric (f) Neurosky



Fonte: Modificado de Minguillon, Lopez-Gordo e Pelayo (2017).

Existe uma quantidade significativa de equipamentos disponíveis no mercado. Pode-se citar entre eles (MIHAJLOVIĆ et al., 2015):

- Quick 20 (Figura 10 (a)) e o HD 72 (Figura 10(b)) (COGNIONICS, 2017): Ambos os equipamentos são da empresa *Cognionics*. São equipamentos que tem 20 e 64 canais de aquisição, respectivamente, utilizam eletrodos secos e transmitem seus sinais por tecnologia sem fio. São equipamentos propostos para o uso no cotidiano, no entanto possuem um alto custo.
- EPOC (Figura 10(c)) (EMOTIV, 2017): Está entre os dispositivos mais disponíveis e utilizados no mundo. Possui 14 canais espalhados pela cabeça e de baixo custo. Os dados são transmitidos sem fio através de um protocolo de rádio proprietário. No entanto, possui uma licença de alto custo que é necessária para obter acesso aos dados “brutos” do sinal de EEG (ou seja, sem o *software* da empresa). Além disso, possui uma taxa de amostragem limitada e é necessário o uso de uma solução salina para a condução do sinal, o que prejudica a sua usabilidade.
- g.Nautilus (Figura 10(d)) (G.TEC, 2017): Este sistema pode ser utilizado com eletrodos ativos secos (fabricados com ouro) ou molhados que são distribuídos de acordo com o Sistema Internacional 10-20. Os dados são transmitidos sem fio através

de um protocolo de rádio proprietário. É um sistema de alto custo, o que o torna restrito a grandes centros de pesquisa.

- Enobio (Figura 10(e)) (NEUROELECTRICS, 2017): Este equipamento possui configurações de 8 à 32 canais. Os dados são transmitidos sem fio por protocolo proprietário e é proposto como um equipamento para análises fora do laboratório. Para o mercado Europeu, é considerado um equipamento de custo médio para alto, o que o torna de alto custo para o mercado Brasileiro.
- Neurosky (Figura 10(f)) (NEUROSKY, 2017): Este equipamento possui apenas um canal com eletrodo seco. Tipicamente, este canal de medição é posicionado na testa, o que permite gravações frontais. Os dados são transmitidos sem fio para um computador ou *smartphone* usando *Bluetooth*. Possui o menor preço de todos os produtos, no entanto dirige-se a mercados não científicos e sem apelo para o uso em aplicações médicas.

Uma possível conclusão a se retirar a partir da análise do mercado, é que os equipamentos são desenvolvidos para servir ao mercado de baixo preço e, por isso, comprometem a qualidade do sinal e/ou robustez. Já por outro lado, há equipamentos que fornecem um sinal de alta qualidade e boa usabilidade, mas com preços muito maiores (MIHAJLOVIĆ et al., 2015).

2.4 Remoções de artefatos

Nesta seção, são abordados aspectos referentes aos artefatos presentes no sinal de EEG e quais os principais métodos existentes para removê-los do sinal, sobretudo os métodos que são propostos para a remoção dos artefatos em tempo real, tendo em vista o objetivo deste trabalho.

2.4.1 Artefatos

Os artefatos são sinais indesejáveis que podem introduzir mudanças nas medições e afetar o sinal de interesse e, devido às características do sinal de EEG, ele é bastante suscetível a ruídos e interferências, em geral, maiores que o próprio sinal (RODRIGUES, 1997).

Os artefatos nas aquisições de EEG são causados por fontes endógenas (ou fisiológicas) e exógenas (por exemplo, da linha de alimentação elétrica) (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017). Ainda que a forma ideal de se trabalhar com o sinal de

EEG seja evitar a ocorrência de artefatos ao realizar a gravação dos dados, o sinal de EEG é, infelizmente, muitas vezes, contaminado por vários outros sinais/ruídos que são diferentes da atividade cerebral. Os fatores mais comuns de interferência do sinal são (URIGÜEN; GARCIA-ZAPIRAIN, 2015):

- Rede elétrica: Rede de distribuição de energia pode gerar uma interferência eletromagnética ao sinal de EEG, em geral, na frequência de 60 Hz. É um tipo de ruído muito comum ao sinal.
- Eletrodos: Muitas vezes os eletrodos não fazem contato corretamente com a superfície analisada gerando artefatos e flutuações do sinal. Em alguns casos, a interferência é gerada pela má higienização dos eletrodos formando uma superfície com maior impedância.
- Movimentação: Durante a realização do exame o sujeito pode se mover, o que causa alterações na linha de base do sinal.
- Outros sinais fisiológicos tais como a piscada dos olhos, contração muscular e o sinal cardíaco.

Um fator ainda mais prejudicial causado pelas interferências no sinal de EEG é que estes artefatos têm uma tendência a se assemelhar a atividade cognitiva e psicológica e, portanto, pode resultar em análises erradas (JOHAL; JAIN, 2016).

Para poder minimizar a influência dos artefatos no sinal de EEG, é importante compreender melhor os artefatos existentes e a forma como estes interferem no sinal de interesse. A maior parte dos autores categorizam os artefatos em dois grupos: fisiológicos e não fisiológicos (URIGÜEN; GARCIA-ZAPIRAIN, 2015). Os artefatos não fisiológicos podem ser reduzidos por uma colocação adequada dos eletrodos, através da gravação em um ambiente controlado, entre outras formas.

Já os artefatos fisiológicos, por outro lado, raramente podem ser evitados, desta forma a maioria dos métodos desenvolvidos para a remoção de artefatos do sinal de EEG se destinam à redução de artefatos fisiológicos (URIGÜEN; GARCIA-ZAPIRAIN, 2015). A seguir, são abordados os principais artefatos fisiológicos.

2.4.1.1 Artefatos de EOG

O EOG é o sinal elétrico ligado a movimentação dos olhos e pode ser utilizado, por exemplo, no acionamento e controle de equipamentos (SANTOS FILHO, 2008), em que deve-se reconhecer os trechos do sinal que foram realizados movimentos oculares. Porém, em

um sinal de EEG o movimento ocular, bem como a piscada palpebral, pode interferir no sinal de interesse.

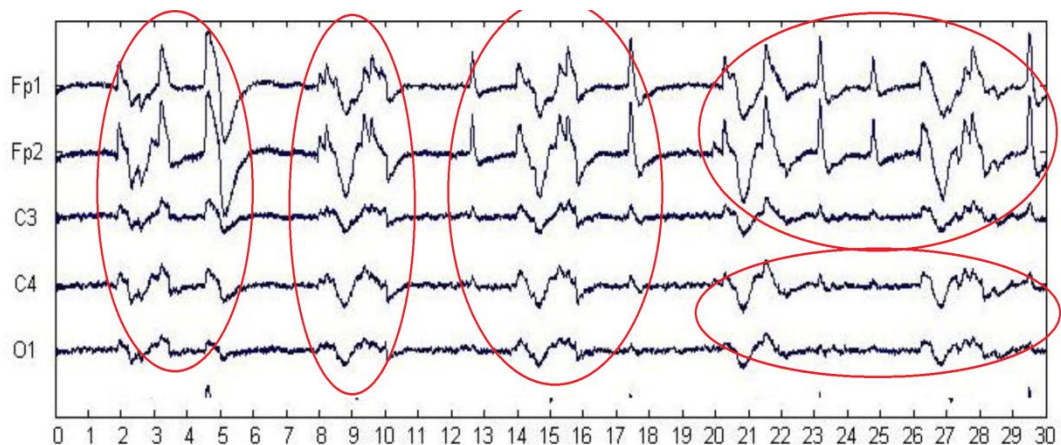
Entre todas as possíveis interferências geradas no sinal de EEG, o artefato de EOG é um dos mais importantes. Pode-se concluir isso logo que, uma piscada dos olhos produz amplitudes 10 vezes superiores ao sinal de EEG, chegando entre 800 e 1000 μV e ocorrendo em um período muito curto de 200-400ms (HSU et al., 2016; YANG; DUAN; ZHANG, 2016).

Durante a aquisição do sinal de EEG, é inevitável a piscada e os movimentos dos olhos e, mesmo quando os indivíduos são solicitados a manter os olhos fechados e imóveis, os artefatos de EOG ainda são provocados no sinal de EEG (HSU et al., 2016).

Os artefatos de EOG são, principalmente, captados pelos eletrodos frontais, embora também se estendam para outros canais (ROMERO; MAÑANAS; BARBANOJ, 2008). As piscadas causam mudanças abruptas no sinal de EEG em frequências mais baixas (<4 Hz), já a movimentação dos olhos causa maior interferência na faixa de frequência mais alta (>13 Hz) (URIGÜEN; GARCIA-ZAPIRAIN, 2015). Alguns trabalhos sugerem que, o sinal de EOG seja captado simultaneamente ao sinal de EEG (CROFT et al., 2005).

Alguns autores relatam que, os artefatos gerados pelo EOG afetam os ritmos theta e alfa do EEG e são difíceis de serem detectados automaticamente devido à grande variabilidade entre indivíduos (CHANG; LIM; IM, 2016). Na Figura 11, pode-se ver um sinal de EEG com os artefatos de EOG circulado em vermelho.

Figura 11 - Sinal de EEG com artefatos de EOG



Fonte: Modificado de Zeng et al. (2013).

2.4.1.2 Artefatos de EMG

O sinal de EMG é o resultante da atividade elétrica gerada pela contração muscular. Este sinal pode ser utilizado para a análise dos músculos, bem como para o acionamento e

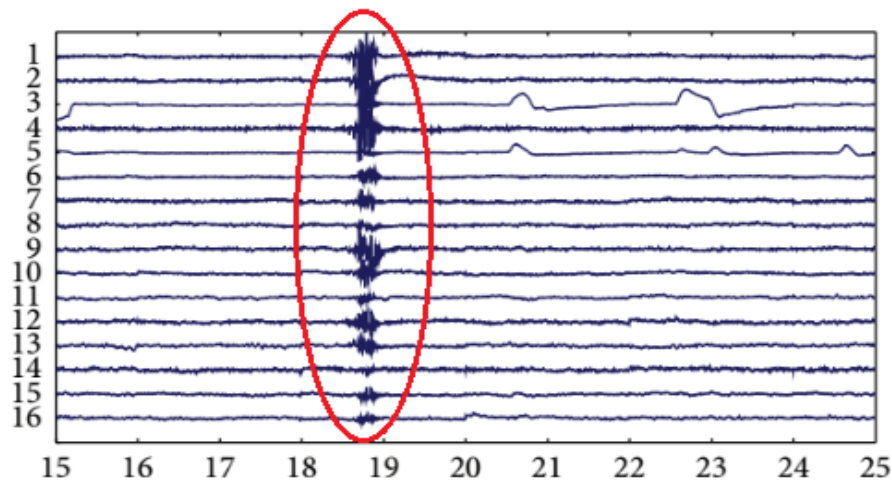
controle de dispositivos (ROSA, 2005). Este artefato é causado por pacientes acordados, ocorrendo quando ele realiza a deglutição, quando fala, anda, entre outros momentos.

As formas e a amplitude das interferências geradas pelo sinal de EMG dependem do nível de contração muscular e do tipo de músculo que é ativado, o que torna este sinal um tipo de artefato difícil de padronizar. As diferentes características do sinal de EMG são responsáveis por seus efeitos adversos sobre a atividade de EEG (MCMENAMIN, 2010), dificultando ainda mais a remoção deste artefato (SAFIEDDINE et al., 2012).

O sinal de EMG apresenta altas amplitudes e uma ampla distribuição espectral o que causa interferência em todas as bandas do sinal de EEG, em particular, se sobrepõe consideravelmente com o ritmo beta na faixa de 15 Hz-30 Hz (SÖRNMO; LAGUNA, 2005) mas pode também atingir baixa frequências de até 2 Hz (GONCHAROVA, 2003), fazendo com que o ritmo alfa também sofra interferência.

Além disso, o sinal de EMG também apresenta menos repetições do que outros artefatos fisiológicos e, portanto, é mais difícil de caracterizar, uma vez que surge da atividade de grupos musculares independentes e espacialmente distribuídos, com amplitudes e distribuições espectrais diferentes (URIGÜEN; GARCIA-ZAPIRAIN, 2015). Na Figura 12, é possível ver um exemplo de um sinal de EEG apresentando um artefato de EMG.

Figura 12 - Sinal de EEG com artefatos de EMG



Fonte: Modificado de Zhang C. (2015).

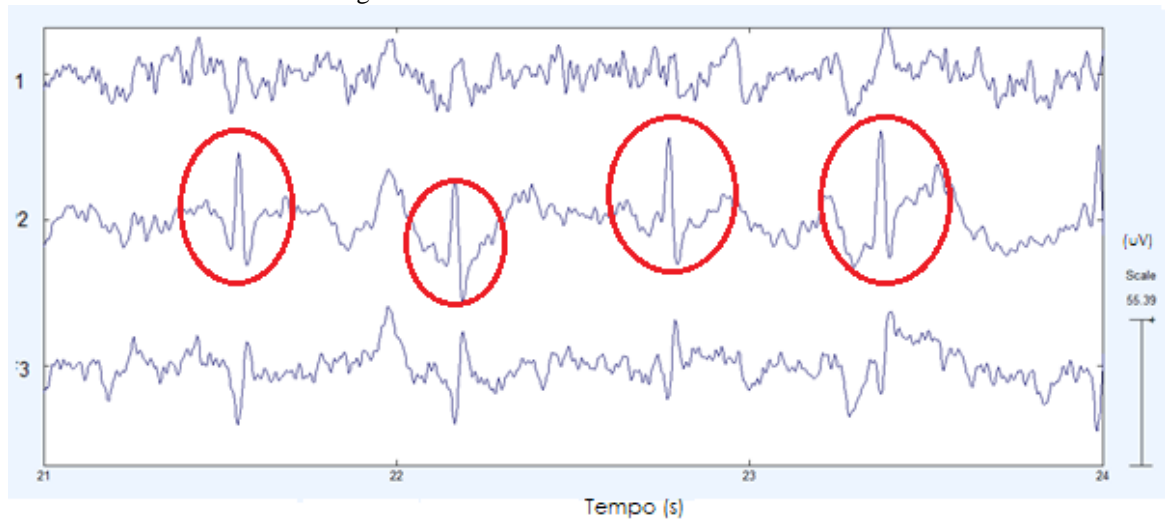
2.4.1.3 Artefatos de ECG

O eletrocardiograma (ECG) é a representação da atividade elétrica do coração. A amplitude da atividade cardíaca no couro cabeludo é geralmente de baixa amplitude, porém isso depende consideravelmente das posições dos eletrodos e difere em cada pessoa.

O ECG tem um padrão repetitivo e regular bem determinado, o que facilita a remoção deste artefato do sinal de EEG. Além disso, o sinal de ECG é muitas vezes adquirido em

paralelo ao EEG, auxiliando na sua identificação no sinal de EEG. Apesar disso, algumas vezes este artefato é confundido com atividade epiléptica no sinal de EEG (URIGÜEN; GARCIA-ZAPIRAIN, 2015). Na Figura 13, é possível ver um exemplo de sinal de EEG com artefato de ECG.

Figura 13 - Sinal de EEG com artefato de ECG



Fonte: Arquivo do próprio autor (2017).

2.4.1.4 Outros artefatos fisiológicos

Além dos artefatos descritos anteriormente, podem surgir duas outras interferências (em uma frequência muito menor do que as outras) de potenciais elétricos gerados na pele. O primeiro é o artefato de transpiração, que se apresenta como ondas lentas que alteram a linha de base do sinal de EEG e, em alguns casos, a resposta simpática da pele, que também consiste em ondas lentas, e altera a linha de base do sinal de EEG (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

Devido às fontes de artefatos serem muito diversas e com características bem diferentes, a maioria dos autores se concentram na remoção de um único tipo de artefato (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

A remoção de artefatos é um ponto de grande importância no processamento do sinal de EEG e, normalmente, um pré-requisito para posteriores análises e aplicações deste sinal. Desta forma, serão abordados na próxima seção alguns métodos de remoção de artefatos do sinal de EEG.

2.4.2 Métodos de Remoção de Artefatos

Desde a descoberta dos sinais de EEG, os métodos para redução e remoção de artefatos têm sido essenciais no pré-processamento deste sinal. Na literatura, é possível encontrar diversas abordagens baseadas no processamento de sinais, mineração de dados, modelos estatísticos e outros métodos que buscam realizar a remoção de artefatos sejam no domínio do tempo, da frequência ou do espaço.

Por quase um século, as aquisições de EEG exigiram condições experimentais rigorosas que necessitavam de uma sala isolada, sistemas de aquisição clínicos e protocolos experimentais rígidos. No entanto, na última década, avanços tecnológicos nas interfaces entre cérebro-computador (*BCI*) permitiram a aquisição do sinal de EEG por meio de equipamentos com tecnologia sem fio, móveis e de baixo custo, com intuito de serem aplicados em ações do cotidiano das pessoas. Desta forma, novos aspectos não considerados antes, tais como interferência eletromagnética intensiva, número reduzido de eletrodos, além da necessidade de aplicações em tempo real, passam a ter grande importância (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017).

Com os avanços da utilização do EEG, pode-se dizer que há a necessidade da evolução nos algoritmos de processamento do sinal, em particular, a remoção de artefatos. No entanto, as técnicas de remoção de artefatos não evoluíram em conformidade, comprovando-se pelo fato de que a maioria dos estudos encontrados na literatura foca apenas na remoção de artefatos em condições de alto controle (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017).

Outra necessidade das recentes aplicações é que os métodos sejam capazes de remover os artefatos em tempo real, no entanto a maioria dos trabalhos propõe métodos *offline* ou com nível de atraso inviável para a grande parte das aplicações. A principal vantagem dos métodos *offline* é que não precisa de alto desempenho em termos de tempo de processamento. No entanto, a operação automática em tempo real é fundamental para aplicações como jogos (LIAO et al., 2012) ou controle de dispositivos (WANG, 2011).

As técnicas de processamento de artefatos vão desde a rejeição de segmentos do EEG (CROFT et al., 2005; KIRKOVE; FRANOIS; VERLY, 2014) na qual um marcador é criado para identificar o artefato e o objetivo é excluir os segmentos com os artefatos, até os de remoção do artefato do sinal de EEG, no qual os trechos do sinal são mantidos e apenas os artefatos são removidos. Embora a rejeição seja ainda uma alternativa para segmentos que contêm interferência excessiva, é muitas vezes desejável reter o máximo possível de dados (SÖRNMO; LAGUNA, 2005).

Urigüen e Garcia-Zapirain (2015) classifica os métodos de tratamento de artefatos de EEG com relação ao nível de intervenção humana no processo como semi-automatizado ou automatizado. No primeiro é necessário realizar a inspeção visual do sinal medido ou dos componentes obtidos pelo método de remoção de artefatos e, portanto, eles só podem ser usados para aplicações *offline*. Já para aplicações *online* (tempo real), são necessários algoritmos automatizados, o que também propicia a diminuição da subjetividade no processo.

Vários procedimentos para identificação e correção automática de artefatos foram desenvolvidos, porém nenhum deles se destaca entre os outros (URIGÜEN; GARCIA-ZAPIRAIN, 2015). A automatização de algoritmos existentes não é fácil uma vez que, como visto na seção 2.4.1, existem múltiplos tipos de interferências que são introduzidas de maneira indeterminada no sinal de EEG, limitando assim a aplicabilidade de métodos padrões, excetuando-se os casos onde é possível adaptar cenários específicos.

A literatura sobre remoção de artefatos EEG é muito ampla, no entanto até esta data não há um consenso entre os pesquisadores do melhor método a ser aplicado na remoção dos artefatos do EEG.

Esta falta de acordo se deve a três razões que são normalmente ignoradas, segundo Urigüen e Garcia-Zapirain (2015): Existem vários tipos de sinais de EEG com características diferentes aos quais são aplicadas técnicas de remoção semelhantes; Existem poucos conjuntos de dados públicos disponíveis, portanto, as comparações entre os métodos tendem a ser feitas em quantidades reduzidas de sinais; E não há medidas objetivas de desempenho consistentes usadas entre as publicações, o que torna as comparações muito difíceis de serem realizadas.

A seguir, são estudados os principais métodos de remoção de artefatos observados na literatura.

2.4.2.1 Filtragem do sinal

A filtragem é um método frequentemente utilizado no pré-processamento do EEG. Para isso, os coeficientes dos filtros são estimados de acordo com a ordem que é estabelecida, a faixa de frequência de atuação (passa-baixa, passa-alta, rejeita-faixa ou passa-faixa) e também com relação ao tipo de resposta ao impulso (FIR – *Finite Impulse Response* e IIR – *Infinite Impulse Response*) (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017).

Uma simples filtragem tipo passa-baixa, passa-banda, rejeita-faixa ou passa-alta é, em geral, a primeira tentativa clássica de remover os artefatos do EEG medido, no entanto, isso só é eficaz quando as bandas de frequência de sinal e dos artefatos não se sobrepõem

(SWEENEY; WARD; MCLOONE, 2012). Esta sobreposição espectral é comum para artefatos típicos gravados juntamente com o EEG, logo são necessárias técnicas alternativas de filtragem ou outros métodos, como serão vistos adiante.

Além da filtragem tradicional, há a filtragem adaptativa, método no qual se pressupõe que o sinal e os artefatos não estão correlacionados (URIGÜEN; GARCIA-ZAPIRAIN, 2015). O filtro gera um sinal correlacionado com o artefato usando um sinal de referência e então a estimativa gerada do artefato é subtraída do EEG adquirido (SWEENEY; WARD; MCLOONE, 2012). A escolha da referência do artefato é fundamental para o bom funcionamento do algoritmo e pode ser obtida, por exemplo, da gravação dos sinais que geram os artefatos no sinal de EEG, tal como a partir da aquisição do sinal de EOG para a remoção de movimentos oculares e/ou piscadas EEG (CROFT et al., 2005), ou de aquisições de EMG para a remoção de artefatos musculares (DALY et al., 2013).

Os filtros adaptativos ajustam iterativamente os seus coeficientes de acordo com um algoritmo de otimização. Estes coeficientes buscam modelar a interferência do artefato no sinal de EEG (ROMERO; MAÑANAS; BARBANOJ, 2009). A família de algoritmos mais prevalente é o LMS (*Least Mean-Squares*), que é linear em complexidade e convergência. Outra família bem conhecida é o RLS (*Recursive Least-Square*), que é quadrática em complexidade e convergência. Os filtros adaptativos são mais apropriados para sinais de variação linear no tempo (por exemplo, o EEG) do que filtros não adaptativos, além disso, são eficientes na remoção de artefatos em tempo real, mas exigem o conhecimento prévio dos artefatos (GUERRERO-MOSQUERA; VAZQUEZ, 2009).

Além destes tipos de filtros citados, há a filtragem de Bayes, sendo este um método de estimação probabilística (SWEENEY; WARD; MCLOONE, 2012). Estes filtros superam algumas das limitações das técnicas acima mencionadas na medida em que são capazes de trabalhar sem um sinal de referência e operam em tempo real, no entanto apresentam grande complexidade na sua implementação, o que impede sua aplicação direta e torna necessária a aproximação através de filtros de Kalman (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

Na prática, entre os tipos de filtragens citadas (excetuando-se os filtros de frequência), a filtragem adaptativa é a mais utilizada (URIGÜEN; GARCIA-ZAPIRAIN, 2015). Um ponto que vale a pena ser ressaltado é que, em geral, esses métodos de filtragem são utilizados em conjunto com outros métodos (ZHAO, 2014; YANG; DUAN; ZHANG, 2016), logo que, a filtragem por si só não é capaz de remover todos os artefatos.

2.4.2.2 Regressão Linear

A Regressão Linear se baseia no princípio da superposição, em que se considera que o sinal de EEG é a soma do sinal “puro” de EEG mais os sinais de artefatos, ou seja, as fontes de artefatos. Neste caso, os sinais de artefatos, geralmente, são obtidos por canais de referência que fazem a aquisição destes artefatos, seja EOG, EMG ou ECG, ou por modelos de artefatos (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017).

Nos anos 90, os algoritmos de regressão foram, sem dúvida, uma das técnicas de remoção de artefatos de EEG mais utilizadas, especialmente para artefatos de EOG. Isto se deve a simplicidade deste método e a baixa necessidade de processamento computacional (URIGÜEN; GARCIA-ZAPIRAIN, 2015). Logo, quando há canais de referência disponíveis e considerando que estes representam adequadamente todas as formas de onda dos sinais de interferência, então os artefatos podem ser removidos com a regressão linear, subtraindo-os do sinal de EEG (GRATTON; COLES; DONCHIN, 1983).

Com o decorrer dos anos, os métodos de regressão linear foram substituídos por algoritmos mais sofisticados, principalmente, porque necessitam de um ou mais canais de referência, o que dificulta e limita sua aplicabilidade (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

2.4.2.3 Decomposição de fontes

Os métodos deste tipo buscam decompor cada canal de aquisição de EEG nas componentes que os formam. Nos métodos de BSS (*Blind Source Separation*, ver seção 2.4.2.4) a decomposição é feita considerando todos os canais e componentes podem representar a atividade cerebral ou artefatos, o que permite que os sinais sejam recompostos sem componentes de artefatos. Já na decomposição de fontes, isto pode ser realizado independentemente para cada canal (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017).

A transformada de *Wavelets* é ideal para aplicações biomédicas devido à sua versatilidade, logo que permite a concepção de métodos robustos e funcionais na maioria das circunstâncias, além de possibilitar a análise em tempo-frequência, de modo que pode avaliar os sinais biomédicos que possuem características específicas no domínio do tempo ou da frequência (URIGÜEN; GARCIA-ZAPIRAIN, 2015). A transformada de *Wavelets* tem sido amplamente utilizada no contexto da decomposição do sinal de EEG, desde o início dos anos 90 (UNSER; ALDROUBI, 1996).

A transformada discreta de *Wavelet* é normalmente calculada pela filtragem do sinal de entrada através de uma série de filtros passa-baixa e passa-alta que fornecem os

coeficientes de aproximação e de detalhe. A separação entre o sinal de interesse e o ruído depende da *Wavelet* base (*Wavelet* mãe) utilizada e sua semelhança com os sinais de análise (SAFIEDDINE et al., 2012).

Em Silva (2014), o sinal de EEG foi decomposto em suas bandas pela transformada discreta de *Wavelet* com o objetivo de selecionar o melhor detalhe ou aproximação que represente de forma mais adequada para a detecção de artefatos de EOG e EMG. Com a detecção dos pontos referentes aos artefatos presentes no sinal de EEG, sua eliminação foi realizada de maneira que não houvessem muitas perdas de trechos e, por isso, os pontos detectados como artefato foram eliminados do sinal original, sendo substituídos pelo valor do ponto anterior.

Teng, Yanyan e Gang (2014) propôs um método empírico de decomposição para a remoção de artefatos de EMG de sinais de EEG. No entanto, o sinal de EMG foi simulado e o método é utilizado apenas para a remoção *off-line* do artefato.

2.4.2.4 *Blind Source Separation (BSS)*

Os métodos de *Blind Source Separation*, em português Separação Cega de Fontes, fornecem uma matriz de estimações de fontes geradoras de sinais a partir de uma matriz de observação formada, neste caso, por cada canal de aquisição do sinal de EEG, mas sem usar qualquer referência de artefatos (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017). As fontes estimadas são tanto de sinal de EEG “puro” quanto dos artefatos presentes na aquisição.

Uma vez que as fontes foram estimadas, aquelas correspondentes aos artefatos podem ser identificadas e extraídas, recompondo assim o EEG com as fontes sem artefatos. Entre os métodos mais utilizados de *BSS*, está a Análise Independente de Componentes (em inglês, *Independent Component Analysis – ICA*) (URIGÜEN; GARCIA-ZAPIRAIN, 2015). No capítulo 3, este método é aprofundando, logo que é a base deste trabalho.

2.4.2.5 *Combinação de métodos*

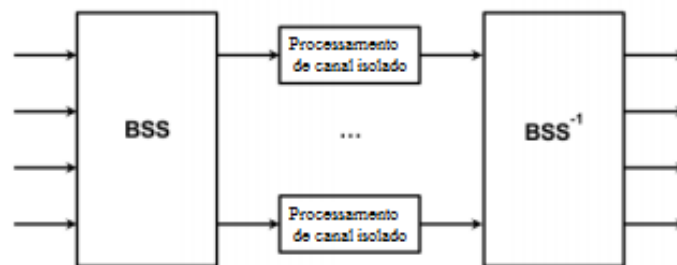
Ao analisar os trabalhos existentes a literatura, é possível concluir que a maioria é uma combinação de métodos, além disso, há uma quantidade relevante de trabalhos que fazem a combinação de métodos (SAFIEDDINE et al., 2012; JOHAL; JAIN, 2016). Esse fato pode ser um indicativo de que não existe um método universal para remoção de artefatos.

Usar uma combinação de algoritmos para remover artefatos do sinal de EEG é uma opção que ganhou atenção recentemente para o processamento de múltiplos canais


(AKHTAR; MITSUASHI; JAMES, 2012) e de canais isolados (MIJOVIC et al., 2010). Em geral, a primeira classe (Figura 14 - a) de métodos é caracterizada pelo uso de um algoritmo BSS, cujos componentes podem ser refinados por métodos focados em canais isolados. Já a segunda classe (Figura 14 - b), segue uma abordagem contrária à primeira, onde há a decomposição de cada canal isoladamente em componentes mais simples e, em seguida, aplica-se algum algoritmo de BSS (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

Uma terceira opção (Figura 14 - c) que é menos explorada é a combinação de métodos em cascata (CORREA et al., 2007; YANG; DUAN; ZHANG, 2016). Nesta classe, a ideia é usar qualquer combinação de diferentes métodos que removam os artefatos do sinal de EEG um após o outro, de modo que cada algoritmo que seja voltado para um determinado tipo de artefato possa atuar em conjunto (URIGÜEN; GARCIA-ZAPIRAIN, 2015).


Figura 14 - Resumo da combinação de métodos de remoção de artefatos.



(a) Multicanais para canais isolados



(b) Canais isolados para multicanais



(c) Métodos em cascata

Fonte: Modificado de Urigüen e Garcia-Zapirain (2015).

Em Zhao (2014), foi realizada a combinação entre Transformada de *Wavelet* e filtros adaptativos para detecção e remoção automática de artefatos de EOG. Neste trabalho, inicialmente é calculada a transformada discreta de *Wavelet* para dividir os sinais de EEG em diferentes sinais de frequência, em seguida, é estabelecido um modelo adaptativo para prever os componentes com artefatos de EOG de baixa frequência. Esse modelo utilizou um filtro adaptativo com base na técnica de adaptação auto-regressiva (*Adaptive Autoregressive-AAR*). Apesar de se propor ser um método de tempo real, não foi demonstrado o tempo de atraso ao fim da implementação.

Em Zhang, C. (2015) é realizada a combinação entre transformada discreta de *Wavelet* e ICA para a remoção de artefatos de EMG e EOG, utilizando informações prévias dos artefatos para a identificação automática dos componentes com artefatos. Após a identificação dos artefatos, foi feita a reconstrução do sinal sem os componentes com artefatos. Este método foi proposto para aplicações em tempo real, no entanto apresentou um tempo de processamento de quase 5s, o que impossibilitaria para aplicações em neurofeedback, por exemplo. Majmudar e Morshed (2016), também utiliza a transformada de *Wavelet*, mas nesse caso faz a composição com um algoritmo algébrico, para a remoção de EOG. Neste trabalho, o método desenvolvido foi embarcado em um *hardware* para ser aplicado em tempo real, mesmo com atraso de 3s.

Já em Çinar e Acir (2017) utiliza-se um método combinado de detecção de *Outlier* e ICA para a remoção automática de artefatos de EOG. A detecção de *Outlier* é utilizada para identificar automaticamente os componentes resultantes do ICA com artefatos. Em seguida, o sinal é recomposto sem os componentes identificados. No entanto, não é possível utilizá-lo para aplicações em tempo real.

2.4.2.6 Conclusão da análise dos métodos de remoção


É possível concluir pela análise da literatura, que não existe um algoritmo ideal para todos os cenários possíveis. Em vez disso, a escolha do método de remoção a ser utilizado depende profundamente do tipo de aquisição do sinal de EEG, dos artefatos presentes nas aquisições e da aplicação no qual este será utilizado (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017; URIGÜEN; GARCIA-ZAPIRAIN, 2015).

Apesar dos inúmeros métodos existentes, as técnicas que são baseadas em ICA são as mais comuns e mais aceitas para obter um sinal de EEG livre de artefatos (MCMENAMIN, 2010) mesmo que nem sempre separem completamente os artefatos dos sinais de EEG. Nos últimos 15 anos, diferentes pesquisadores vêm utilizando métodos com ICA e trazendo

melhorias, como exemplo tem-se Vigário (1997), Vigário e Oja (2008), Hyvarinen e Oja (2000), Hyvarinen e Karhunen (2001), Makeig et al. (1996 e 2000), Delorme e Makeig (2004) Jung et al. (2000), entre outros.

Na Figura 15, é possível ver um resumo da frequência observada dos diferentes métodos utilizados para a remoção de artefatos apresentando por Urigüen e Garcia-Zapirain (2015), embasando-se na análise de trabalhos de remoção de artefatos de EEG de 90 jornais e de congressos com maior foco à partir dos anos 2000, onde é possível notar que, quase 50% dos trabalhos encontrados na literatura, utilizam a Análise de Componentes Independentes para a remoção de artefatos e as outras técnicas são distribuídas em parcelas menores.

Figura 15 - Análise estatística da frequência de aparição de métodos de remoção de artefatos de EEG na literatura.



Fonte: Urigüen e Garcia-Zapirain (2015)

3 DETALHAMENTO DE BSS E ICA

Neste capítulo, serão aprofundados os conceitos com relação aos métodos de *Blind Source Separation*, detalhando particularmente no método de Análise de Componentes Independentes (ICA). Por fim, explicando-se o algoritmo *Infomax*, utilizado neste trabalho para a execução do ICA.

3.1 BSS

Uma abordagem típica da remoção de artefatos no sinal de EEG é supor que a atividade elétrica cerebral medida $X(n)$ é a soma da atividade cerebral propriamente dita $S(n)$ e dos artefatos ou ruídos $V(n)$, desta forma (URIGÜEN; GARCIA-ZAPIRAIN, 2015):

$$X(n) = S(n) + V(n) \quad (1)$$

Ampliando-se esta ideia, o modelo mais aceito considera que, pode-se pressupor que os sinais EEG medidos são misturas lineares dos sinais elétricos provenientes de múltiplas fontes cerebrais e dos artefatos presentes. Esta generalização do modelo, vem da formulação do problema inverso do EEG que permite calcular a atividade elétrica resultante no couro cabeludo resultante da atividade de fontes neuronais e outras fontes fisiológicas (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

Sendo assim, considerando X uma matriz ($m \times n$), cuja a mesma é dada pela mistura de elementos independentes de uma matriz aleatória S , e A é uma matriz de mistura $m \times m$, formando assim a Equação (2) (LANGLOIS; CHARTIER; GOSSELIN, 2010).

$$X = AS \quad (2)$$

O objetivo dos métodos de BSS é estimar as fontes S do sinal de EEG, a partir das observações de X na equação (2), sem a necessidade de sinais de referência para o sinal desejado ou os artefatos indesejados, explorando conjuntamente a informação fornecida por todos os eletrodos sem nenhuma informação prévia.

Uma vez que as fontes estimadas S são identificadas, uma matriz X^* isenta de artefatos é obtida removendo-se as fontes artefatuosas de S e projetando-se de volta ao subespaço das observações (URIGÜEN; GARCIA-ZAPIRAIN, 2015). Esta exclusão dos componentes artefatuosos pode ser feita, por exemplo, zerando-se os valores dos coeficientes da matriz A que multiplicam as fontes a serem excluídas, projetando as fontes de sinais ao subespaço das observações, ou seja, a matriz X^* , utilizando a equação (2).

Para a realização das estimações das fontes, é necessário partir de alguns pressupostos. Entre eles, observa-se que as fontes devem ser não correlacionadas, independentes, não-

Gaussianas, entre outras. Quanto mais próximas as hipóteses da realidade, melhor será o desempenho do método na separação dos componentes (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

Uma diferença interessante do BSS com relação a maioria dos outros métodos de remoção de artefatos de EEG é que, enquanto os métodos baseados em BSS avaliam todos os canais para estimar as fontes de artefatos, os outros métodos buscam remover os artefatos de cada canal independentemente (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

Além disso, segundo Zhang C. (2015), a técnica de BSS é a abordagem mais promissora para separar os sinais de EEG em componentes que os geram e consideram os artefatos de EOG, EMG e outros artefatos como sinais produzidos por fontes independentes. Isso pode ser também demonstrado pelo fato deste tipo de método ser o mais encontrado na literatura para a remoção de artefato (MINGUILLON; LOPEZ-GORDO; PELAYO, 2017).

Entre os principais métodos de BSS está a Análise de Componentes Principais (em inglês *Principal Component Analysis* – PCA). Este método usa uma transformação ortogonal para converter as observações de variáveis possivelmente correlacionadas em variáveis linearmente não correlacionadas chamadas de componentes principais, que devem ser de número menor ou igual aos de variáveis originais. A transformação é definida com o objetivo de que as componentes principais tenham as maiores variâncias possíveis ao serem ortogonais entre si (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

No caso do uso de PCA para a remoção de artefatos de EEG, um problema é observado no pressuposto da ortogonalidade entre a atividade elétrica cerebral e os artefatos existentes, sobretudo os artefatos de origem fisiológica que, neste caso, não é possível fazer tal afirmação (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

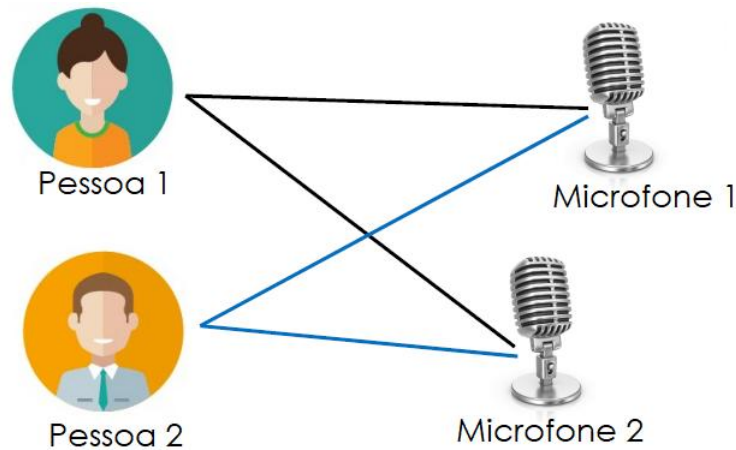
3.2 ICA

Outro método de BSS é a Análise de Componentes Independentes, o mais utilizado e base deste trabalho (ZHANG, C. et al., 2015). A primeira vez que o ICA foi aplicado para a análise de EEG foi por Makeig et al. (1996). Desde então, este método já demonstrou ser capaz de separar do EEG os artefatos de EOG (JOYCE; GORODNITSKY; KUTAS, 2004) e os artefatos de EMG (CRESPO-GARCIA; ATIENZA; CANTERO, 2008).

O conhecido problema do *Cocktail Party* é bastante utilizado para explicar a utilização do ICA. Neste problema, considera-se duas pessoas em uma sala e falando simultaneamente. Se dois microfones são colocados em dois locais diferentes da sala, então cada um deles vai gravar uma combinação linear específica de cada uma das vozes. Usando apenas as gravações

de cada microfone, é possível identificar a voz de cada uma das pessoas (LANGLOIS; CHARTIER; GOSSELIN, 2010). A Figura 16 resume o problema do *Cocktail Party*.

Figura 16 - Problema *Cocktail Party*.



Fonte: Arquivo do próprio autor (2017).


O ICA se baseia no pressuposto de que os sinais observados no couro cabeludo durante um certo tempo são misturas de fontes de sinais cerebrais e de artefatos temporariamente independentes, onde os potenciais decorrentes das diferentes partes do cérebro e de outras partes são somados linearmente nos eletrodos e os atrasos de propagação são insignificantes (JUNG et al., 2000).

Originalmente, o ICA foi proposto para resolver problemas de BSS para encontrar as fontes (S da Equação (2)) de sinais como músicas e ruídos de áudio, depois que estes são linearmente misturado por uma matriz desconhecida (A da equação (2)) (JUNG et al., 2000).

Logo, o objetivo é recuperar uma versão aproximada de S ($S = \{s_1, \dots, s_n\}$), das fontes originais, Y ($Y = \{y_1, \dots, y_n\}$), ao estimar uma matriz quadrada, W , especificando filtros espaciais que desfaçam o processo da mistura linear a partir da matriz de observação X ($X = \{x_1, \dots, x_n\}$). Ou seja, o intuito é encontrar a matriz inversa de A (no caso W), com a qual se obtenha Y , a melhor aproximação de S (JUNG et al., 2000), como pode ser visto na equação (3). A Figura 17 resume a utilização do ICA para encontrar as fontes dos sinais de EEG.

$$Y = WX \cong S \quad (3)$$

Figura 17 - Esquemática da utilização de ICA para encontrar as fontes de sinais elétricos cerebrais.



Fonte: modificado de Urigüen e Garcia-Zapirain (2015).

Em muitos casos, as fontes encontradas pelo ICA são temporalmente independentes e são também funcionalmente independentes. Isto permite que o ICA seja geralmente aplicável e efetivo para remover uma grande variedade de artefatos de registros de EEG (JUNG et al., 2000).

Para a análise do EEG, as linhas da matriz X (Equação (3)) são os sinais de EEG adquiridos de cada canal, enquanto as linhas da matriz S (Equação (3)) são os sinais de ativação durante o tempo das fontes localizadas pelo ICA. Já as colunas da matriz inversa de W , ou seja, W^{-1} , é a representação da projeção dos componentes nos canais de aquisição presentes no couro cabeludo. Logo, as projeções dos componentes encontrados com o ICA no couro cabeludo fornecem informações sobre a localização espacial das fontes. Por exemplo, os componentes da atividade ocular são, normalmente, projetados na parte frontal da cabeça.

Entre os algoritmos que fazem o ICA, o *Infomax* é o mais utilizado (URIGÜEN; GARCIA-ZAPIRAIN, 2015). Em 1995, Bell e Sejnowski propuseram um algoritmo que utiliza uma rede neural de aprendizagem não supervisionada que faz a separação cega de fontes independentes, usando a maximização da informação (por isso o nome deste algoritmo), sendo este o algoritmo utilizado neste trabalho. Eles mostraram que maximizar a entropia conjunta da saída de um processador neural, minimiza a informação mútua entre os componentes de saída.

Diferentemente das fontes $S(s_1, s_2...s_n)$, no qual se assume que são temporariamente independentes, os sinais de observação $X(x_1, x_2...x_n)$ são estaticamente dependentes uns dos outros, logo a informação mútua dos sinais de observação, $I(x_i, x_j)$, é em geral positiva. Desta

forma, é o intuito deste método encontrar a matriz W , de modo que se aproxime da condição: $I(x_i, x_j) = 0$, para todo i e j (JUNG et al., 2000).

Considerando a entropia conjunta de dois componentes não linearmente transformados de y : $H(y_1, y_2) = H(y_1) + H(y_2) - I(y_1, y_2)$, na qual $y_i = g(u_i)$ e g é uma função sigmoide. Para maximizar esta entropia conjunta, envolve a maximização das entropias individuais, $H(y_1)$ e $H(y_2)$, ao mesmo tempo que minimiza a informação mútua, $I(y_1, y_2)$, compartilhada entre as duas. Assim, maximizar $H(y)$, em geral, minimiza $I(y)$. Quando a informação mútua chega a zero, as duas variáveis são estatisticamente independentes (BELL; SEJNOWSKI, 1995).

O algoritmo tenta maximizar a entropia $H(y)$ ajustando iterativamente os elementos da matriz quadrada, W , seguindo a seguinte equação, na qual $\varphi_i = \frac{\partial}{\partial u_i} \ln \frac{\partial y_i}{\partial u_i}$ (BELL; SEJNOWSKI, 1995):

$$\Delta W \sim \frac{\partial H(y)}{\partial W} W^T W = [I + \varphi \mu^T] W$$

4 DESENVOLVIMENTO DO MÉTODO

Neste capítulo será abordada a metodologia desenvolvida neste trabalho. Inicialmente, será explicada a aquisição dos sinais de EEG utilizados para estudos e o pré-processamento executado nos mesmos. Após, será explicitado o desenvolvimento dos filtros espaciais desenvolvidos a partir do algoritmo de ICA e a técnica criada para a remoção dos artefatos, detalhando-se também o método “padrão” executado para intuito de comparação com o método proposto neste trabalho.

Além disso, são explicados como foram desenvolvidos os métodos para medição de desempenho, esclarecendo-se os sinais utilizados para comparação com os resultantes do método de remoção desenvolvido neste trabalho.

4.1 Aquisição de Dados

Para o desenvolvimento e teste dos métodos propostos, foram utilizados sinais de EEG de aquisições de dados reais (Código do comitê de ética: CAAE 62327816.2.0000.5208).

Participaram 12 pessoas, dos quais 6 eram homens e 6 eram mulheres, todos sem disfunções neurológicas e fora dos critérios de exclusão. Cada um dos participantes fez 3 diferentes aquisições de aproximadamente 28 segundos, com intervalo de 5 minutos entre cada uma. Durante cada uma das aquisições os participantes visualizaram imagens diferentes em cada uma delas. Ao fim, foram obtidos 36 sinais de EEG diferentes.

Para a realização das aquisições, foi utilizada uma touca de Eletroencefalografia da empresa neuroUP, primeira touca de projeto e fabricação nacional. Esta touca possui 64 eletrodos, dos quais 1 é o de terra (GND) e 2 são utilizados como referência (localizado nos mastoides, na região atrás das orelhas), no entanto foram utilizados apenas 22 do total de eletrodos. O eletrodo presente na touca era de Ag/AgCl e folhado a Ouro. Além disso, foi utilizado gel condutivo para permitir a condução entre o couro cabeludo e o eletrodo. Na Figura 18 é possível ver um exemplar da touca utilizada no projeto.

Figura 18 - Touca de Eletroencefalografia da neuroUP.



Fonte: Arquivo do próprio autor (2017)

O equipamento utilizado para amplificação dos sinais é o Nexus-32 da empresa MindMedia, visto na Figura 19. Este equipamento pode realizar a aquisição de sinais de EEG, EMG, ECG e EOG, além de medir a resposta galvânica da pele, temperatura e frequência respiratória. Este equipamento tem uma frequência de amostragem de 512 Hz por canal e o conversor analógico-digital de 24bits (MINDMEDIA, 2017). Além disso, este equipamento realiza a amplificação utilizando uma técnica chamada *Common Average Reference*, processo que vem sendo cada vez mais utilizado em equipamentos modernos, onde a amplificação não é realizada a um eletrodo específico, mas sim em relação a média de todos os outros eletrodos (LUDWIG et al., 2009). Apesar disso, foi realizado digitalmente uma nova referência, utilizando os eletrodos localizados nos mastoides, para haver uma compatibilização dos trabalhos existentes.

Desta forma, dos 22 eletrodos utilizados para a aquisição, 19 foram de fato utilizados como canais de aquisição, 1 foi utilizado como terra e os outros dois como referência. Foram dispostos na touca de acordo com o sistema internacional 10-20.

Figura 19 - Equipamento Nexus-32 da MindMedia.



Fonte: MINDMEDIA (2017)

4.2 Método de referência para comparação

Inicialmente, foi implementado e aplicado aos sinais um método de remoção de artefatos, utilizando algoritmos de ICA *offline* para posterior comparação com o método de remoção de artefatos de tempo real. Este método aplicado é considerado neste trabalho como um padrão para remoção de artefatos, tendo em vista o grande número de pesquisas e artigos existentes que utilizam o ICA *offline*.

O método inicia pela realização da referência digitalmente dos eletrodos dos mastoides, para aproximar-se dos trabalhos existentes na literatura. Em seguida, foi aplicado um filtro digital de resposta infinita ao impulso do tipo *Butterworth*, de ordem 10 e com banda de passagem de 1 à 40 Hz utilizando as funções *butter* e *filter* do Matlab.


O passo seguinte foi a utilização do ICA com o algoritmo *Infomax* para a separação em componentes de sinais de EEG e de artefatos. Esta etapa foi feita utilizando o *toolbox* EEGLAB. O EEGLAB é um *toolbox* de código aberto que foi feito para o Matlab, mas que pode ser também utilizado isoladamente, possuindo mais de 250 rotinas para análises de EEG e com a facilidade de poder ser utilizado através de uma interface gráfica ou por códigos (DELORME; MAKEIG, 2004). Apesar de ter outros algoritmos de ICA, o *Infomax* foi escolhido por ser o mais comum (URIGÜEN; GARCIA-ZAPIRAIN, 2015).

Com a utilização do ICA, uma matriz para desfazer a mistura das fontes de sinal é proposta, W (Equação (3)). Essa matriz é então invertida e utilizada para a localização e identificação das fontes, logo que esta é a projeção no escalpo das ativações das fontes. Desta forma, após a aplicação do ICA em cada um dos sinais de estudo, uma imagem é gerada com os componentes de cada sinal, tal como a Figura 20. Para a geração desta imagem, é utilizado a informação de localização topográfica de cada eletrodo, ou seja, a posição espacial de cada

eletrodo. Com a localização dos eletrodos e os valores dos coeficientes da matriz W^{-1} as imagens são geradas.

A quantidade de componentes gerados pelo ICA é igual ao número de canais de aquisição e, no caso deste trabalho, são 19, o mesmo número de linhas e colunas da matriz W .

Figura 20 - Componentes de EEG gerados com o ICA.




Fonte: Arquivo do próprio autor (2017)

Com os componentes plotados, foi feita uma inspeção visual neste para definir quais são artefatos e quais são fontes de sinal de EEG. Um dos fatores considerados nesta análise foi a localização do componente, pois, em geral, os componentes que se localizam com área de maior ativação mais externamente ao escalpo são artefatos, principalmente artefatos de origem fisiológica. Na Figura 21, é possível ver alguns exemplos de componentes artefatuosos, os quais apresentam maior atividade na parte da frente do escalpo é de origem ocular (piscada ou movimento dos olhos) e este de maior ativação lateralmente ao escalpo é um artefato de origem muscular (ativados em deglutição ou na mordida).

Após a etapa de escolha dos componentes artefatuosos, o sinal é recomposto sem estes componentes, onde, na matriz inversa de W , a coluna correspondente do componente é zerada e o sinal é recomposto sem o mesmo. Para esse processo é utilizada a Equação (3) para encontrar as fontes de sinal e, após zeradas a colunas dos componentes artefatuosos de W^{-1} , o sinal X^* é recomposto, onde a matriz W^{-1} após modificada, se torna um filtro espacial para remoção dos artefatos.

Figura 21 - Exemplos de componentes artefatuosos.



Fonte: Arquivo do próprio autor (2017)

É importante ressaltar que este método é inviável de ser executado em tempo real, logo que o tempo para realização do ICA é de aproximadamente 1 minuto para um sinal de EEG de cerca de 30 segundos. Além disso, é necessária uma etapa de inspeção visual que pode levar aproximadamente 8 minutos para cada sinal.

4.3 Método proposto para remoção em tempo real

Nesta seção será explicado o método proposto e desenvolvido para a remoção de artefatos de EEG em tempo real.

A primeira parte do método é igual ao método padrão, para que sejam medidas apenas as diferenças nos métodos de remoção. Logo, os métodos iniciam pela realização da referência digitalmente dos eletrodos dos mastoides, para aproximar-se dos trabalhos existentes na literatura. Em seguida, foi aplicado um filtro digital de resposta infinita ao impulso do tipo *Butterworth*, de ordem 10 e com banda de passagem de 1 à 40 Hz utilizando as funções *butter* e *filter* do Matlab.

O método utiliza o algoritmo ICA-*Infomax*. Ele inicia por uma fase de decomposição de fontes que é realizada de maneira *off-line*, que serve como uma calibração para a realização da fase em tempo real e só é necessária ser feita uma única vez para cada voluntário, que deve ser feita como uma fase prévia à remoção de artefatos de fato.

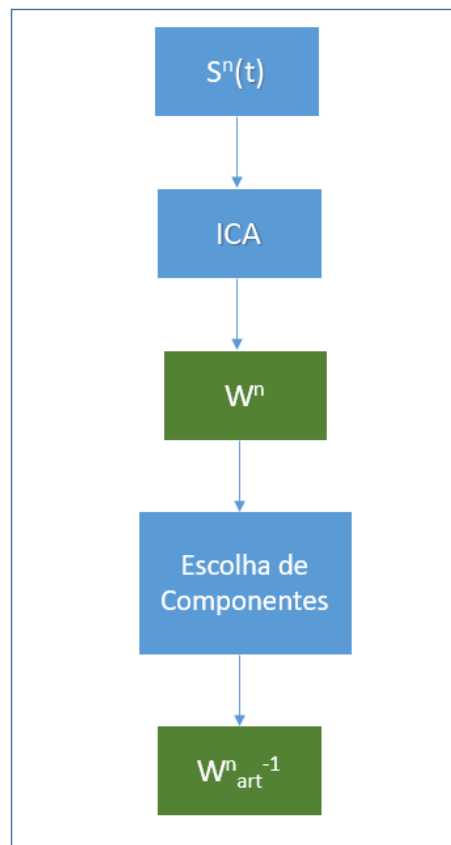
Nesta primeira fase realizada após a aplicação do filtro, utiliza-se o ICA para encontrar os componentes de cada um dos sinais, ou seja, a matriz W é definida. A partir disto, são definidos quais componentes são artefatos. Após esta definição, uma matriz W_{art}^{-1} é salva

apenas com os componentes artefatuosos do sinal, que será em seguida utilizada como filtro espacial para a remoção de artefatos.

Sendo assim, cada sinal utilizado para estudo gerou uma matriz W e W_{art}^{-1} , em que “art” representa que é a matriz apenas com os componentes artefatuosos. Na Figura 22, é possível ver o esquema desta primeira fase, na qual as caixas em verde são as matrizes que são salvas de cada sinal para serem utilizadas posteriormente.

Em conclusão, esta fase apesar de ser *off-line* é necessária apenas para encontrar as matrizes que serão utilizadas para as fases em tempo real e deve ser executada uma única vez, logo todas as outras aquisições usarão as mesmas matrizes definidas no início.

Figura 22- Esquema da fase 1 (*off-line*) do método de remoção proposto.



Fonte: Arquivo do próprio autor (2017)

Após a primeira fase, inicia-se a remoção dos artefatos em tempo real. Esta segunda fase é para a detecção dos pontos de sinal onde há artefato. É importante ressaltar que, as matrizes da fase anterior são utilizadas para detectar e remover os artefatos do mesmo indivíduo. Por exemplo, um sinal de uma certa pessoa passa pela fase 1, as matrizes resultantes são utilizadas para remover artefatos de outros sinais desta mesma pessoa. Isto foi

aplicado por considerar que as diferenças dos sinais de cada pessoa podem influenciar nos métodos.

Como a fase 2 já é implementada para tempo real, uma janela de tempo de 0,1 s é considerada para as aplicações do método, ou seja, dentro desta janela de tempo são aplicados os cálculos para detecção e remoção dos artefatos. Esta janela foi definida com base nas aplicações de *Neurofeedback*, pois um tempo maior que esse poderia causar atrasos perceptivos no momento do treinamento de *neurofeedback* e um tempo menor que esse poderia não ter dados o suficiente para permitir o processamento correto.

Para detectar os artefatos, primeiramente é feita a decomposição de fontes utilizando a matriz W , conforme a Equação (4), em que S é o sinal de entrada (do qual será removido o artefato) e Y é a ativação dos componentes.

$$Y = WS \quad (4)$$

Após encontrado Y , a Equação (5) é utilizada para encontrar a magnitude no tempo da projeção dos componentes artefatuosos no escalpo, em que W_{art}^{-1} é a matriz de componentes e utilizada com filtro espacial e S_{art} é a representação no tempo dos sinais de resultantes das fontes artefatuosas captadas pelos eletrodos de EEG, ou seja, são os sinais artefatuosos captados juntos com o EEG.

$$S_{art} = W_{art}^{-1} Y \quad (5)$$

Em seguida, para considerar tanto a parte positiva quanto negativa do sinal, é calculada a potência média do sinal na janela de tempo citada utilizando a Equação (6), em que N é o tamanho da janela (no caso 0,1s, como já dito). Essa potência é então comparada a uma potência de referência e, caso a potência do sinal S_{art} seja maior que o limite, então considera-se que a janela possui artefato e o método de remoção do artefato é aplicado. A potência média de referência foi definida a partir do valor médio do sinal de EEG que, em geral, não passa de 100 μ V de pico. Desta forma, foi considerado que seria artefato, se o valor fosse 1,5 vezes maior que o valor de potência média padrão.

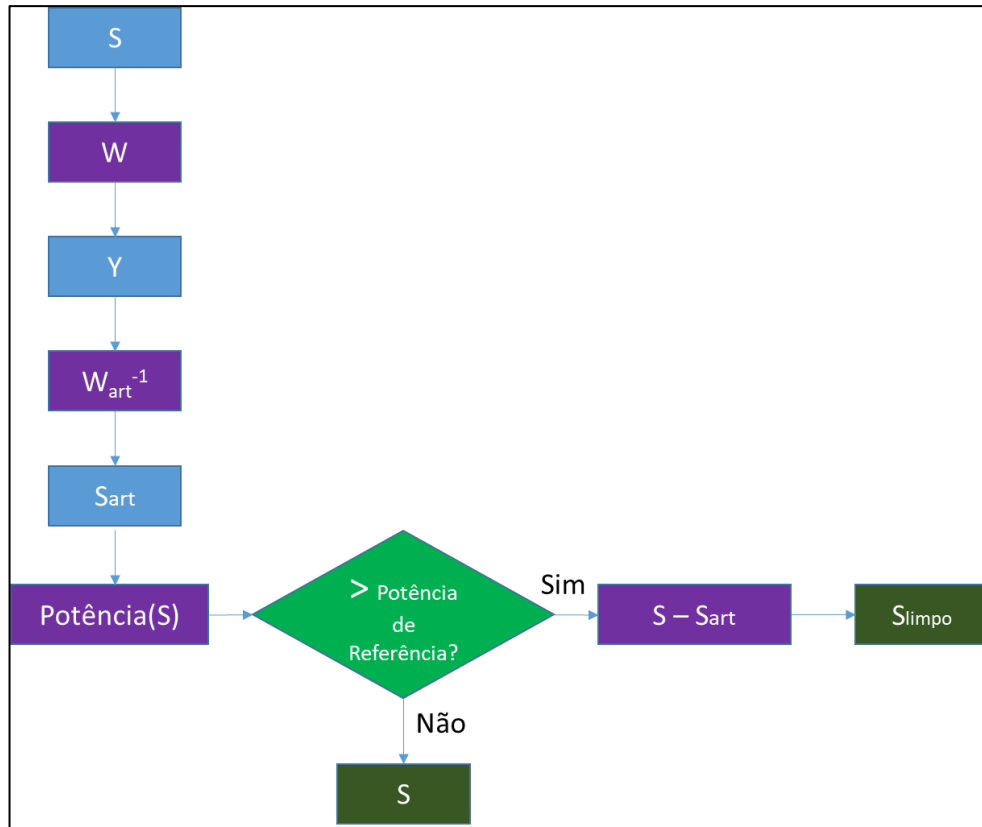
$$P \triangleq \frac{1}{N} \sum_{n=1}^N S_{art}[n]^2 \quad (6)$$

Logo que detectado o artefato, então é aplicado a remoção de artefato conforme a equação (7). Em que S é o sinal de entrada e captado pelos eletrodos, S_{art} é o sinal de artefatos da equação (5) e S_{limpo} é o sinal “limpo” após a remoção do artefato.

$$S_{limpo} = S - S_{art} \quad (7)$$

A Figura 23 demonstra o fluxograma do algoritmo proposto, onde ao fim é obtido o sinal “limpo” dos artefatos ou o sinal permanece o mesmo, caso não seja detectado nenhum artefato, executado em tempo real.

Figura 23 - Fluxograma do algoritmo do método proposto (tempo real).



Fonte: Arquivo do próprio autor (2017)

4.4 Metodologia de análise de resultados e comparação dos métodos propostos

Nesta seção, descreve-se a metodologia aplicada para analisar os resultados obtidos e para realizar a comparação entre os resultados obtido do método de referência (Seção 4.2) e os resultados do método proposto neste trabalho (Seção 4.3).

A primeira análise realizada foi a inspeção visual dos sinais, para verificar se todos removiam os artefatos independentemente do método aplicado. Em seguida, foi realizada a comparação visual entre o método de referência que utiliza o EEGLAB (*toolbox* do Matlab) e os métodos propostos. Estas inspeções visuais, apesar de serem pouco objetivas e qualitativas, ainda são utilizadas e levadas em consideração (URIGÜEN; GARCIA-ZAPIRAIN, 2015). É importante ressaltar que esta etapa foi realizada com o auxílio de um especialista em neurociências.

Na etapa seguinte, foi criado e adicionado artificialmente, um artefato de piscada dos olhos a um trecho de sinal de EEG no canal FP1, onde não havia este tipo de artefato. Este artefato foi criado a partir de um dos sinais adquiridos que apresentava o artefato de piscada.

Um sinal com o artefato foi escolhido, em seguida, foi isolado um trecho com este artefato. Para isto, um outro sinal foi escolhido após a aplicação do método de remoção de artefatos padrão e este sinal foi subtraído da versão deste sinal antes de ser limpo pelo método de remoção, desta forma sobrando um sinal apenas com os artefatos. Em seguida, foi escolhido um dos artefatos de piscada e todos os outros trechos do sinal foram zerados de maneira que restasse unicamente o artefato de piscada. Por fim, este trecho de sinal com o artefato foi somado a um outro sinal que não apresentava o artefato.

Após adicionado o artefato de piscada ao sinal, foi aplicado o método de remoção proposto neste trabalho. Os resultados obtidos pelo método foram comparados com o sinal que originalmente não apresentava o artefato de piscada, com o objetivo de verificar o quanto os resultados obtidos se assemelham com o sinal original sem artefato. Para isso, foi utilizado erro relativo percentual (equações (9) e (10)).

Em seguida, é feita a análise espectral do sinal original sem artefato, do sinal após a adição do artefato e do sinal resultante do método de remoção proposto, para verificar qual o efeito do método no espectro de frequência e, sobretudo, se as principais bandas de interesse para as aplicações de *Neurofeedback* (alfa e beta) são mantidas sem alterações significativas.

Para esta análise espectral foi utilizado o *toolbox* EEGLAB, especificamente utilizando a função *Plotting channel spectra and maps*. Nesta função é possível escolher o trecho de sinal no qual será realizado a análise espectral, bem como é possível definir a porcentagem de dados e as faixas de frequência limites. Neste caso, foi realizada a análise no trecho ao qual foi adicionado o artefato, utilizando-se 100% dos dados e na faixa de frequência de 1 Hz à 40Hz.

Uma outra importante análise realizada foi do tempo de execução do método proposto. Como o intuito é que o método de remoção de artefatos propostos seja realizado em tempo real para aplicações de *Neurofeedback*, é essencial conhecer o tempo necessário para executar esta atividade. Para isso, foram utilizadas as funções *Tic* e *Toc* do Matlab (em um computador com processador CORE i3 e 4GB de memória RAM), que mede o tempo gasto para execução de uma função. É importante ressaltar, que foi apenas considerado nesta medida o tempo da execução do algoritmo de remoção de artefato em tempo real, excluindo-se a etapa de geração das matrizes dos componentes, logo que esta fase é realizada anteriormente a remoção em tempo real.

Na etapa seguinte, é realizada a comparação quantitativa entre os resultados obtidos pelo método de referência e os do método proposto. Para isso foram utilizados dois tipos de cálculos de erros comuns na literatura (URIGÜEN; GARCIA-ZAPIRAIN, 2015). Estes erros foram o Erro Percentual Absoluto Médio e a Raiz Quadrada do Erro Quadrático Médio Normalizado (ou *Normalized root-mean-square-Error* - NRMSE).

O Erro Percentual Absoluto Médio é a média de todos os erros absolutos percentuais, fornecendo uma indicação do tamanho médio do erro, expresso como uma porcentagem do valor observado, independentemente do erro ser positivo ou negativo. Para realizar o cálculo deste erro, foram utilizadas e implementadas as equações (8) e (9). Onde $Z[n]$ é o valor de referência, $Z^*[n]$ é o valor com o qual se faz a comparação, EP é o erro percentual obtido da amostra, N é o número de amostras e $EPAM$ é a média dos erros percentuais das amostras.

$$EP = \left(\frac{Z[n] - Z^*[n]}{Z[n]} \right) \times 100 \quad (8)$$

$$EPAM = \frac{\sum_{n=1}^N |EP[n]|}{N} \quad (9)$$

Outro tipo de medida de comparação foi a Raiz Quadrada do Erro Quadrático Médio Normalizado. Ela é a raiz quadrada do erro médio quadrático da diferença entre a referência e o valor de comparação.

Para o seu cálculo, foram utilizadas as equações (10) e (11), onde $RMSE$ é a raiz quadrada do erro quadrático médio, $Z[n]$ e $Z^*[n]$ são respectivamente o valor de referência e o valor de comparação, N é o número total de amostras, \bar{Z} é a média de todas as amostras de referência e $NRMSE$ é o valor resultante da normalização do $RMSE$.

$$RMSE = \sqrt{\frac{\sum_{n=1}^N (Z[n] - Z^*[n])^2}{N}} \quad (10)$$

$$NRMSE = \frac{RMSE}{\bar{Z}} \quad (11)$$

Como o objetivo deste trabalho é desenvolver um método de remoção de artefatos capaz de ser utilizado em tempo real, em aplicações de *Neurofeedback*, por via de regra, o sinal de EEG, nesse caso, não é utilizado diretamente, mas sim após alguma medida que o

represente. Por isso, para a realização da comparação dos métodos com os cálculos dos erros, foi aplicado ao sinal o cálculo da potência do mesmo utilizando a Equação (12), considerando uma janela periódica de tempo de 0,5 s, na qual N é o número de amostras correspondentes ao tamanho desta janela e S é o sinal. O tempo desta janela foi definido com base nas aplicações de *Neurofeedback*.

$$P \triangleq \frac{1}{N} \sum_{n=1}^N S^2[n] \quad (12)$$

Neste caso é possível utilizar a média do valor de referência \bar{Z} na Equação 11, pois o erro é calculado na diferença entre as potências médias dos sinais e não do sinal propriamente dito. Se fosse o sinal de EEG de fato, esta média, \bar{Z} , tenderia a zero (sinal periódico) o que inviabilizaria o uso deste erro.

Um outro ponto importante da metodologia de comparação entre os resultados é que foi utilizada a validação cruzada (ou *Cross Validation*) por ser uma técnica bastante usual para medir a capacidade de generalização dos métodos. Neste trabalho é utilizado o método *k-fold*, que consiste em dividir o conjunto de dados em k subconjuntos de mesmo tamanho e, a partir disto, um subconjunto é utilizado para teste e os subconjuntos restantes ($k-1$) são utilizados para estimação e caracterização de parâmetros. Este processo é realizado uma quantidade de vezes igual ao número de subconjuntos alternando até que todos os subconjuntos tenham sido utilizados para teste.

Neste trabalho, os conjuntos de dados (36 sinais de 12 diferentes pessoas) são subdivididos em 3 subconjuntos com 12 sinais, em que cada um desses sinais é correspondente a uma pessoa diferente, ou seja, os grupos não possuem mais de um sinal da mesma pessoa.

Na Figura 24, é apresentada a divisão dos subgrupos, na qual as caixas laranjas são o grupo utilizado para estimação das fontes e as caixas em azul são os sinais dos subgrupos utilizados para teste e cada coluna é um ciclo de estimação e teste.

É utilizado um subgrupo para estimação das matrizes de fontes (utilizando o ICA-*infomax*) e o método de remoção proposto foi aplicado para testes nos dois outros grupos. Os resultados obtidos foram em seguida comparados com os resultados do método de referência. Em resumo, um sinal de um indivíduo é utilizado para estimar as matrizes de fontes (grupo de estimação), em seguida estas matrizes são utilizadas para testar o método de remoção em outro sinal do mesmo indivíduo (grupo de teste) para ser comparado com o resultado do

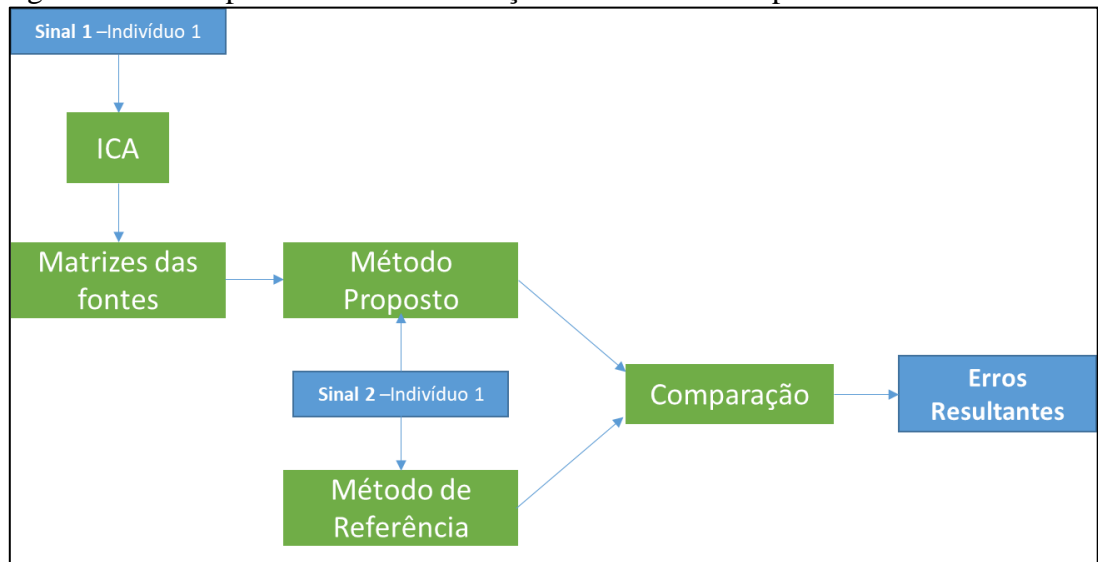
método de referência do sinal correspondente. Na Figura 25, é possível ver um exemplo deste ciclo aplicado ao indivíduo 1.

Figura 24 - Subgrupos criados para a estimação e realização de testes utilizando *k-fold* (Validação Cruzada). Em laranja, são os subgrupos de estimação e em azul são os subgrupos de teste.

Sinal 1 –Indivíduo 1	Sinal 1 –Indivíduo 1	Sinal 1 –Indivíduo 1
Sinal 1 –Indivíduo 2	Sinal 1 –Indivíduo 2	Sinal 1 –Indivíduo 2
Sinal 1 –Indivíduo 3	Sinal 1 –Indivíduo 3	Sinal 1 –Indivíduo 3
Sinal 1 –Indivíduo 4	Sinal 1 –Indivíduo 4	Sinal 1 –Indivíduo 4
Sinal 1 –Indivíduo 5	Sinal 1 –Indivíduo 5	Sinal 1 –Indivíduo 5
Sinal 1 –Indivíduo 6	Sinal 1 –Indivíduo 6	Sinal 1 –Indivíduo 6
Sinal 1 –Indivíduo 7	Sinal 1 –Indivíduo 7	Sinal 1 –Indivíduo 7
Sinal 1 –Indivíduo 8	Sinal 1 –Indivíduo 8	Sinal 1 –Indivíduo 8
Sinal 1 –Indivíduo 9	Sinal 1 –Indivíduo 9	Sinal 1 –Indivíduo 9
Sinal 1 –Indivíduo 10	Sinal 1 –Indivíduo 10	Sinal 1 –Indivíduo 10
Sinal 1 –Indivíduo 11	Sinal 1 –Indivíduo 11	Sinal 1 –Indivíduo 11
Sinal 1 –Indivíduo 12	Sinal 1 –Indivíduo 12	Sinal 1 –Indivíduo 12
Sinal 2–Indivíduo 1	Sinal 2–Indivíduo 1	Sinal 2–Indivíduo 1
Sinal 2–Indivíduo 2	Sinal 2–Indivíduo 2	Sinal 2–Indivíduo 2
Sinal 2–Indivíduo 3	Sinal 2–Indivíduo 3	Sinal 2–Indivíduo 3
Sinal 2–Indivíduo 4	Sinal 2–Indivíduo 4	Sinal 2–Indivíduo 4
Sinal 2–Indivíduo 5	Sinal 2–Indivíduo 5	Sinal 2–Indivíduo 5
Sinal 2–Indivíduo 6	Sinal 2–Indivíduo 6	Sinal 2–Indivíduo 6
Sinal 2–Indivíduo 7	Sinal 2–Indivíduo 7	Sinal 2–Indivíduo 7
Sinal 2–Indivíduo 8	Sinal 2–Indivíduo 8	Sinal 2–Indivíduo 8
Sinal 2–Indivíduo 9	Sinal 2–Indivíduo 9	Sinal 2–Indivíduo 9
Sinal 2–Indivíduo 10	Sinal 2–Indivíduo 10	Sinal 2–Indivíduo 10
Sinal 2–Indivíduo 11	Sinal 2–Indivíduo 11	Sinal 2–Indivíduo 11
Sinal 2–Indivíduo 12	Sinal 2–Indivíduo 12	Sinal 2–Indivíduo 12
Sinal 3–Indivíduo 1	Sinal 3–Indivíduo 1	Sinal 3–Indivíduo 1
Sinal 3–Indivíduo 2	Sinal 3–Indivíduo 2	Sinal 3–Indivíduo 2
Sinal 3–Indivíduo 3	Sinal 3–Indivíduo 3	Sinal 3–Indivíduo 3
Sinal 3–Indivíduo 4	Sinal 3–Indivíduo 4	Sinal 3–Indivíduo 4
Sinal 3–Indivíduo 5	Sinal 3–Indivíduo 5	Sinal 3–Indivíduo 5
Sinal 3–Indivíduo 6	Sinal 3–Indivíduo 6	Sinal 3–Indivíduo 6
Sinal 3–Indivíduo 7	Sinal 3–Indivíduo 7	Sinal 3–Indivíduo 7
Sinal 3–Indivíduo 8	Sinal 3–Indivíduo 8	Sinal 3–Indivíduo 8
Sinal 3–Indivíduo 9	Sinal 3–Indivíduo 9	Sinal 3–Indivíduo 9
Sinal 3–Indivíduo 10	Sinal 3–Indivíduo 10	Sinal 3–Indivíduo 10
Sinal 3–Indivíduo 11	Sinal 3–Indivíduo 11	Sinal 3–Indivíduo 11
Sinal 3–Indivíduo 12	Sinal 3–Indivíduo 12	Sinal 3–Indivíduo 12

Fonte: Arquivo do próprio autor (2017)

Figura 25 - Exemplo do ciclo de estimação e teste realizado para o indivíduo 1



Fonte: Arquivo do próprio autor (2017)

5 RESULTADOS


Neste capítulo, são apresentados e discutidos os resultados obtidos com todos os experimentos realizados. São apresentados os resultados alcançados desde a aquisição de sinais de EEG, bem como dos métodos de remoção de artefatos e das análises comparativas resultantes entre o método de referência e o método de tempo real proposto neste trabalho.

5.1 Resultados da análise comparativa visual

Para representar as aquisições dos sinais, na Figura 26 é apresentado um dos sinais adquiridos. O sinal desta figura é original e ainda sem ter passado por nenhum método de remoção de artefatos. Após serem adquiridos os sinais, foi iniciada a aplicação dos métodos de remoção e a comparação visual por um especialista em Neurociências. Em vermelho foram destacados alguns artefatos presentes no sinal.

De maneira geral, todos os sinais foram adquiridos sem grandes problemas, apenas com os artefatos já esperados.

Figura 26 - Exemplo de um sinal de EEG adquirido e que ainda não passou por nenhum método de remoção de artefatos.




Fonte: Arquivo do próprio autor (2017)

O primeiro método aplicado foi o método de remoção de referência da seção 4.2. Na Figura 27, é possível ver o resultado obtido da aplicação deste método no mesmo sinal da Figura 26. Comparando as duas figuras, pode-se notar que grande parte dos artefatos foram

removidos, sobretudo nos primeiros canais. O mesmo é feito para todos os sinais e foram obtidos resultados semelhantes a este.


Figura 27 - Mesmo sinal de EEG da Figura 26 após aplicado o método de remoção de artefatos de referência *offline* da Seção 4.2.



Fonte: Arquivo do próprio autor (2017)

Em seguida, foi aplicado o primeiro método proposto neste trabalho de tempo real da seção 4.3. Na Figura 28, é possível ver o mesmo sinal da Figura 26 após aplicado o método de remoção. Pode-se ver que grande parte dos artefatos foram removidos, o que demonstra a capacidade do mesmo para a utilização em *neurofeedback*. Além disso, comparando-se o resultado obtido da Figura 28, com o resultado do método de referência da Figura 27, nota-se que são semelhantes. Resultados semelhantes foram obtidos para todas as aquisições.


Figura 28 - Mesmo sinal de EEG da Figura 26 após aplicado o método de remoção de artefatos de tempo real da Seção 4.3.



Fonte: Arquivo do próprio autor (2017)

Para possibilitar uma análise mais detalhada, o sinal da Figura 26 foi expandido em uma janela de tempo menor e foi destacada uma parte deste sinal onde é possível ver artefatos de piscada dos olhos, obtendo-se o que pode ser visto na Figura 29, onde o círculo vermelho mostra um ponto deste artefato.


Figura 29 - Destaque dos artefatos de piscada presentes em um dos sinais de EEG adquiridos, anteriormente a utilização dos métodos de remoção de artefatos.



Fonte: Arquivo do próprio autor (2017)

O mesmo foi feito para o resultado obtido pelo método de remoção de referência. Na Figura 30 é destacado o mesmo trecho do sinal da Figura 29, onde é possível ver que os artefatos de piscada foram removidos sem necessidade de eliminação de sinal de EEG.

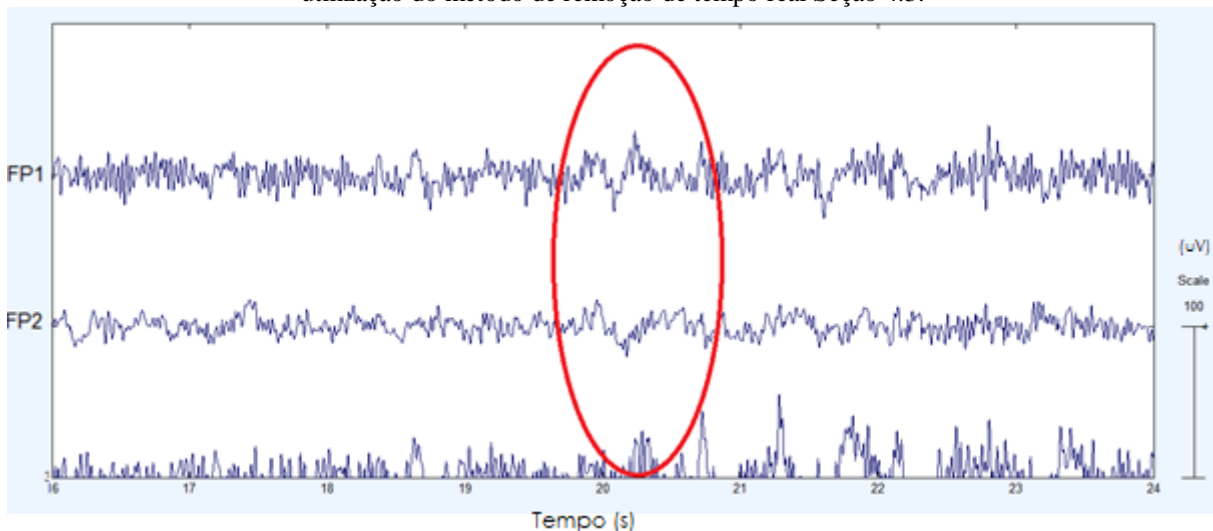
Figura 30 - Mesmo sinal de EEG da Figura 29 destacando os pontos onde haviam artefatos de piscada, após a utilização do método de referência *off-line* da Seção 4.2.



Fonte: Arquivo do próprio autor (2017)

Em seguida, foi feito o mesmo para o resultado da aplicação do método de tempo real. O trecho destacado é apresentado na Figura 31, onde é possível ver que os artefatos de origem ocular destacados na Figura 29 foram atenuados consideravelmente, demonstrando um bom resultado do método. Apesar do método de referência ter conseguido remover mais o artefato de piscada, o resultado obtido pelo método proposto foi considerado satisfatório pelo especialista em neurociências.


Figura 31 - Mesmo sinal de EEG da Figura 29 destacando os pontos onde haviam artefatos de piscada, após a utilização do método de remoção de tempo real Seção 4.3.



Fonte: Arquivo do próprio autor (2017)

Além dos artefatos de origem ocular, foi objetivo deste trabalho eliminar artefatos de origem muscular. Para apresentar os resultados obtidos neste sentido, um dos sinais adquiridos foi escolhido e um trecho apresentando o artefato de origem muscular foi destacado. Na Figura 32, apresenta-se o trecho de sinal com artefato de origem muscular.

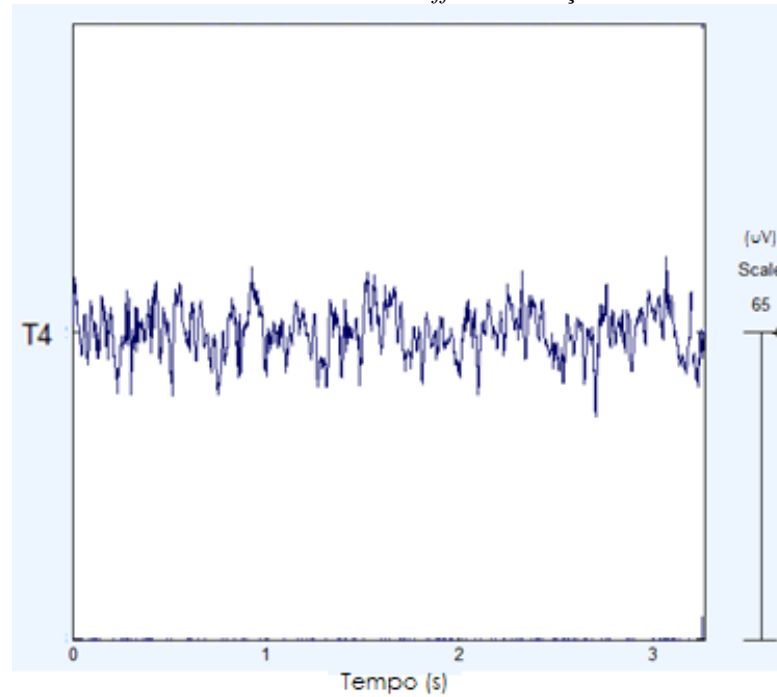
Figura 32 - Destaque de um artefato de EMG presente em um dos sinais de EEG adquiridos, anteriormente a utilização dos métodos de remoção de artefatos.



Fonte: Arquivo do próprio autor (2017)

Aplicando-se então o método de referência de remoção de artefatos ao sinal da Figura 32 e destacando o mesmo trecho, é possível ver na Figura 33 que o artefato de origem muscular foi removido do canal destacado.

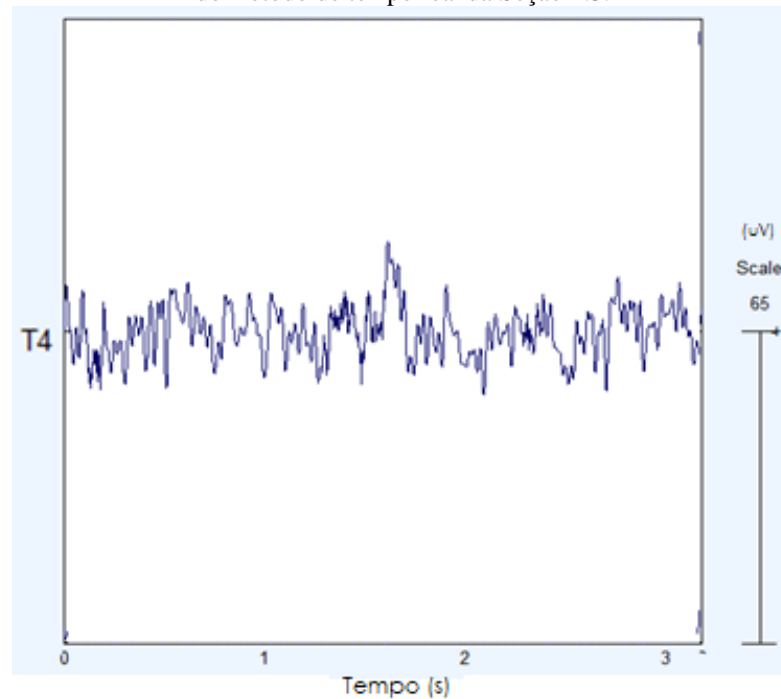
Figura 33 - Mesmo sinal de EEG da Figura 32 destacando o canal onde havia artefato de EMG, após a utilização do método de referência *off-line* da Seção 4.2.



Fonte: Arquivo do próprio autor (2017)

Da mesma maneira, foi aplicado o método de remoção de tempo real no mesmo sinal da Figura 32. Destacando-se o mesmo trecho para o resultado obtido, é possível ver na Figura 34 que o artefato de origem muscular foi atenuado no canal destacado. O resultado para a remoção deste artefato também foi considerado satisfatório pelo especialista em neurociências, que apesar não ter sido o mesmo do método de referência, conseguiu atenuar consideravelmente o artefato muscular.

Figura 34 - Mesmo sinal de EEG da Figura 32 destacando o canal onde havia artefato de EMG, após a utilização do método de tempo real da Seção 4.3.



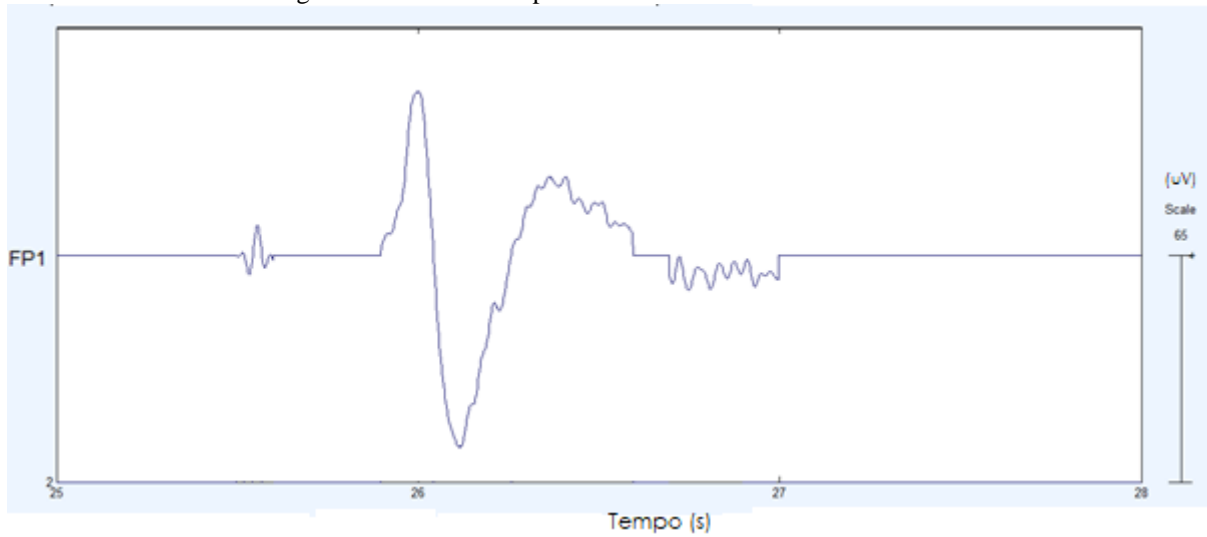
Fonte: Arquivo do próprio autor (2017)

5.2 Resultados da remoção do artefato artificial e análise espectral

Nesta seção, são apresentados e analisados os resultados obtidos a partir da remoção de um artefato ocular de piscada, introduzido artificialmente a um sinal de EEG “limpo”, com objetivo de avaliar se o método proposto é capaz de removê-lo corretamente sem causar alterações indevidas no sinal, além de analisar o espectro de frequência do sinal de EEG antes e após a remoção, para verificar se as frequências principais de interesse são modificadas ou não.

Desta forma, foi inicialmente criado, a partir de dados reais, um artefato de piscada dos olhos (EOG), obtendo-se o sinal demonstrado na Figura 35.

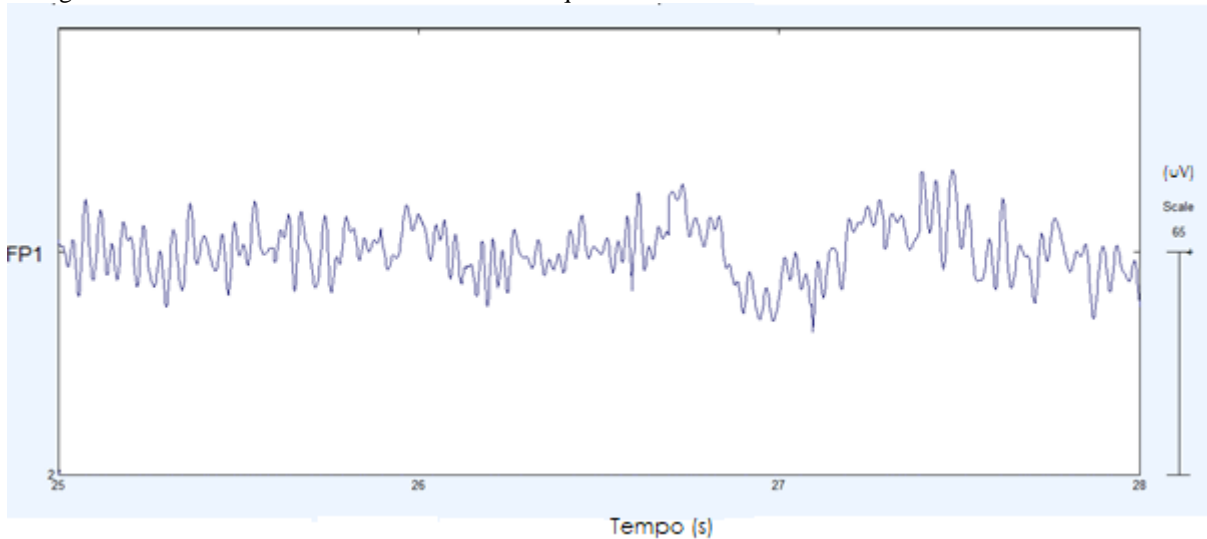
Figura 35 – Artefato de piscada de olhos criado artificialmente.



Fonte: Arquivo do próprio autor (2017)

Em seguida, na Figura 36, é apresentado o trecho do sinal de EEG ao qual foi adicionado artificialmente o artefato de piscada dos olhos. É possível notar, que este trecho do sinal, originalmente não apresenta o artefato de piscada.

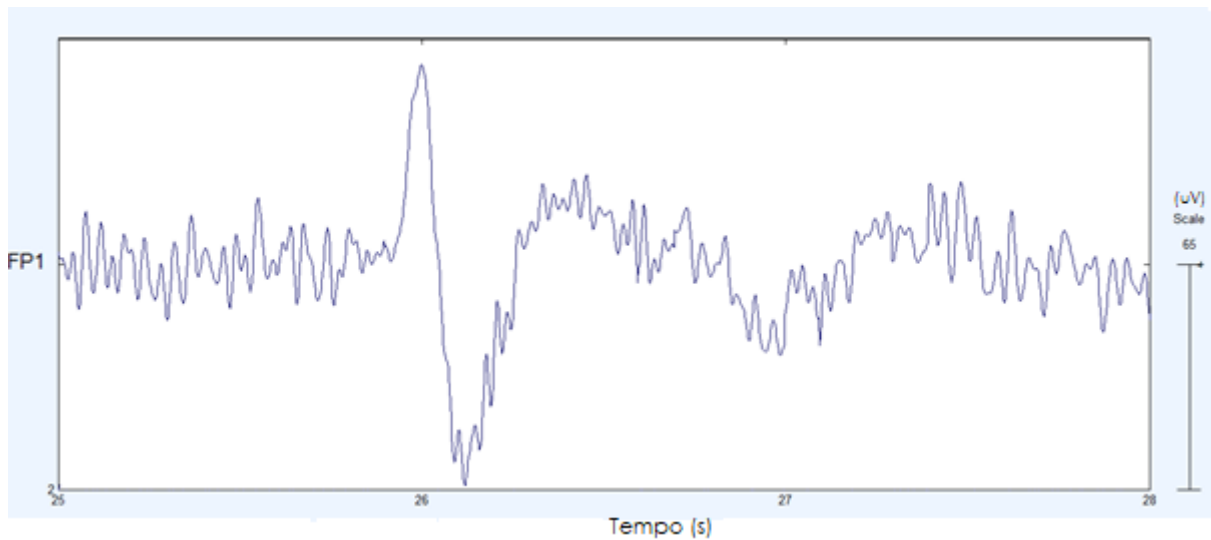
Figura 36 - Sinal de EEG sem artefato ocular ao qual foi adicionado o artefato ocular criado artificialmente.



Fonte: Arquivo do próprio autor (2017)

Já na Figura 37, é apresentado o resultado da inserção do artefato criado, no trecho do sinal de EEG demonstrado na Figura 36, onde é possível notar o nível de alteração causado por este artefato.

Figura 37 - Trecho do sinal de EEG após somado o artefato de piscada dos olhos.

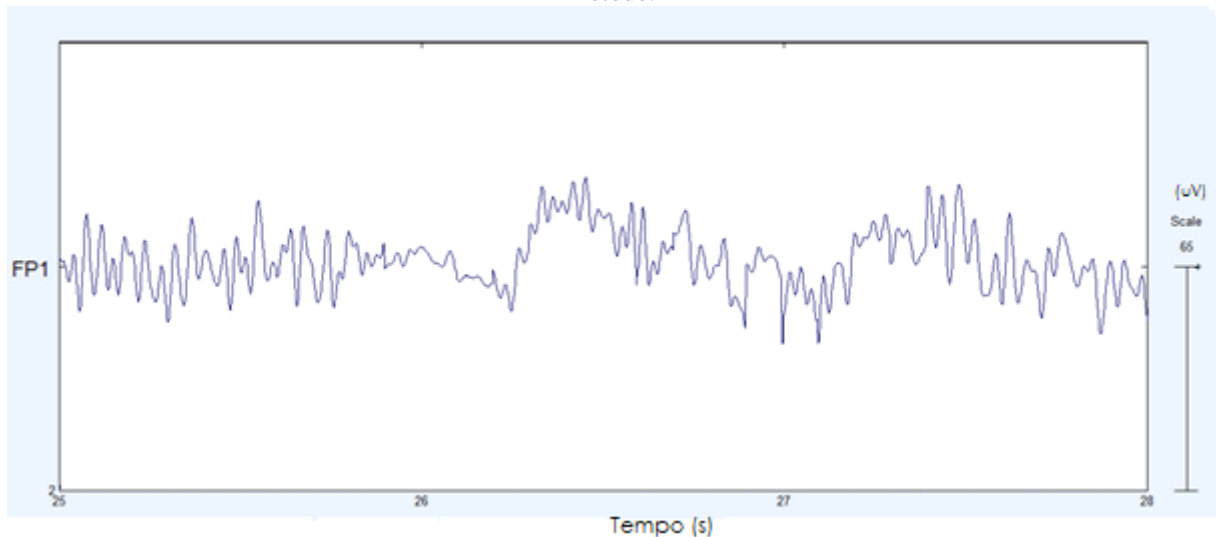


Fonte: Arquivo do próprio autor (2017)

Em seguida, foi aplicado o método de remoção proposto de tempo real, para verificar se este método é capaz de remover o artefato. Desta forma, na Figura 38, é possível ver o trecho do sinal de EEG resultante após a aplicação do método. Observando o sinal resultante, é possível dizer que o artefato de piscada foi corretamente atenuado no sinal sem distorcer ou afetar outras áreas do sinal.

É importante ressaltar que, apesar da região do sinal que foi mais afetada pela piscada, não ter ficado idêntica ao sinal original da Figura 36, o resultado foi considerado satisfatório na análise visual do especialista em neurociências, logo que em uma aplicação de *neurofeedback* a piscada alteraria consideravelmente os valores resultantes no momento do treinamento e após a aplicação do método, o sinal ficou sem esta influência.

Figura 38 - Trecho do sinal de EEG resultante após a remoção do artefato de piscada com a utilização do método.



Fonte: Arquivo do próprio autor (2017)

O passo seguinte foi a comparação entre os resultados obtidos pelo método proposto e o sinal original sem artefato da Figura 36, com o intuito de analisar se o método foi capaz de tornar o sinal com artefato semelhante ao sinal originalmente sem o artefato de piscada. Para isto foi utilizado o erro relativo percentual (Equações (9) e (10)), para calcular as diferenças entre o trecho original sem o artefato de piscada e o sinal obtido pelo método de remoção.

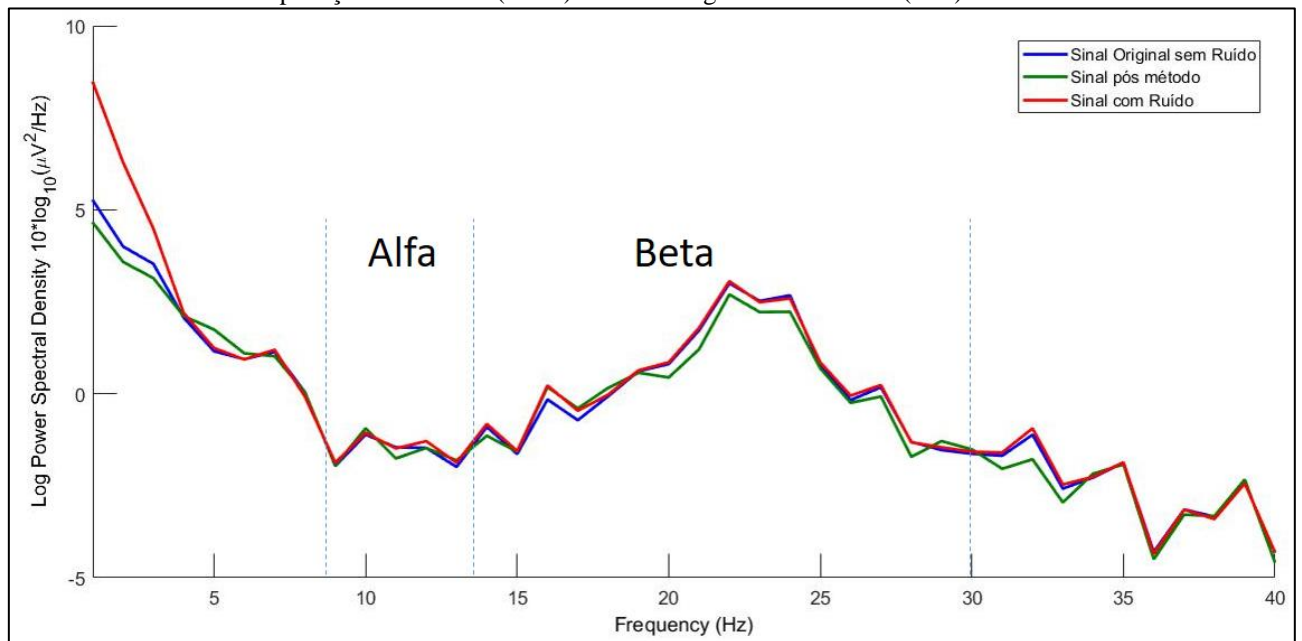
Na comparação entre o trecho do sinal original sem artefato, com o trecho do sinal resultante obtido pelo método de remoção de artefatos, o erro relativo percentual foi de 12,5%. O que pode ser considerado uma baixa diferença entre o sinal original e o sinal obtido pelo método de remoção.

Com o objetivo de verificar o quanto o sinal com artefato de piscada ficou diferente do sinal original, foi calculado também o erro relativo percentual entre o sinal original sem o artefato e o sinal após adição artificial do artefato, obtendo-se um erro de 74,3%. Isto enfatiza que o resultado obtido pelo método proposto conseguiu atenuar o artefato de piscada e se aproximar significativamente do sinal original sem artefato, já que a diferença entre o sinal diminuiu de 74,3% para 12,5%.

Em seguida, foi realizada a análise espectral do sinal original sem artefato, o sinal após a adição do artefato e do sinal resultante do método proposto, no trecho do sinal ao qual foi adicionado o artefato. Isto foi feito para verificar se os métodos propostos removeram o artefato adicionado, sem causar modificações significativas nas faixas de frequências mais utilizadas em *neurofeedback* que são a banda alfa (8Hz à 13Hz) e beta (13Hz à 30Hz).

Desta forma, na Figura 39, são apresentados os espectros de cada um dos sinais citados. É possível ver que as bandas de interesse, alfa e beta, permaneceram semelhantes entre cada um dos sinais, mas na parte de frequências mais baixas é possível observar uma maior diferença entre o espectro do sinal com artefato e dos sinais original sem artefato e pós aplicação do método proposto, o que se deve ao fato do artefato de piscada, atuar em baixas frequências. É possível ver que o resultado obtido pelo método proposto, aproximou-se do sinal original sem artefato em baixas frequências e não causou grandes alterações nas faixas de frequência que não apresentavam artefato.

Figura 39 - Espectro do sinal de EEG após adicionado o artefato de piscada (vermelho), do sinal resultante após a aplicação do método (verde) e o sinal original sem artefato (azul).



Fonte: Arquivo do próprio autor (2017)

5.3 Resultado do tempo de execução do método proposto e análise para embarcar o método proposto

Nesta seção, é apresentado o tempo de execução do método proposto. É importante ressaltar que foi considerado o tempo de execução do método para um sinal de duração de 1 s e para um único canal.

O método obteve um tempo de execução de 1,37 ms para um sinal de duração de 1 s e um único canal com frequência de amostragem de 512 Hz, executado em um computador com processador Intel CORE i3 e 4GB de memória RAM, com a utilização do Matlab. Ou seja, foram processados 512 pontos em 1,37 ms. Desta forma, o tempo para processar um dado

(0,0027 ms) é menor que o tempo para a aquisição de um dado (1,95 ms), o que permitiria a princípio a aplicação deste método em tempo real.

Foi também analisada a literatura, com o intuito de observar os tempos de execução de outros métodos de remoção de artefato em tempo real. Não é possível fazer uma comparação exata com todos os trabalhos da literatura neste sentido, porque seria necessário que todos fossem realizados em mesmas condições e em plataformas semelhantes, de toda forma, esta análise ainda é válida para obter-se uma tendência da média dos valores.

O primeiro é de Matijo, Beeby e Tudor (2013), com tempo de execução de 26,95 ms para um sinal de duração de 1 s com frequência de amostragem de 512 Hz. O segundo é de Yang, Duan e Zhang (2016), com tempo de execução de 12,5 ms para um sinal de duração de 1 s com frequência de amostragem de 250 Hz. O terceiro é de Zhang, C. et al (2015), com tempo de execução de 7,73 ms para um sinal com duração de 1 s com frequência de amostragem de 512 Hz. Desta forma, é possível ver que o método proposto obteve um tempo de execução equivalente e, possivelmente, melhor que os tempos encontrados na literatura.

Um ponto importante a ser ressaltado é que, apesar do método ter sido executado em um computador, é um objetivo que o mesmo seja possível ser adaptado para ser executado em um sistema embarcado. Analisando-se o método proposto, 4 equações seriam necessárias de serem embarcadas: (4), (5), (6) e (7).

Destas equações as que exigem mais processamento são a (4), (5) e (6) por se tratarem de multiplicações. A equação (7) é uma subtração, o que facilita para embarcá-la.

Para simplificar o processo da (4) e (5), como as matrizes são constantes, é possível torna-las em multiplicações por constantes relacionadas a um pequeno trecho do sinal de entrada para cada canal. Logo, é necessário analisar o número de canais que serão utilizados, já que quanto mais canais, mais processamento será exigido o que poderia não ser suportado por um sistema embarcado. Na equação (6) é realizada uma operação de potência ao quadrado do valor resultante da equação (5) e uma divisão por um número inteiro, N , que o tamanho da janela, o que exige um número menor de operações que a equação (5).

É então necessário encontrar um sistema embarcado que possa realizar essas operações aritméticas em tempo real, mas é importante notar no trabalho de Zhang, X. et al. (2014), foi embarcada em um sistema de *FPGA* (*Field-Programmable Gate Array*) a execução do *Second-Order Blind Identification (SOBI)*, que é um tipo de algoritmo de BSS, para aplicações de tempo real em neurociências, assim como em Li e Lin (2005) embarcaram o algoritmo de *Infomax* também em *FPGA*, o que demonstra a possibilidade de isso ser feito

com o método proposto neste trabalho, já que a implementação desses dois algoritmos (*SOBI* e *Infomax*) exige muito mais operações do que o proposto neste trabalho.

5.4 Resultados quantitativos de comparação entre os métodos propostos e o método de referência

Nesta seção, são apresentados os resultados obtidos dos testes quantitativos de comparação entre o método proposto neste trabalho e o método de referência, alcançados pela execução da estimação do erro relativo percentual e a raiz quadrada do erro quadrático médio normalizado (NRMSE).

Na Tabela 2, são apresentados os erros relativos percentuais e NRMSE da comparação entre os sinais resultantes de cada grupo de teste da validação cruzada para o método proposto e os sinais resultantes do método de referência, onde cada sinal recebeu um código de representação, de maneira que S1, S2 ou S3 significa uma das três aquisições realizadas e “IvX” representa um dos 12 indivíduos dos quais foram adquiridos o sinal.

Analisando a tabela é possível ver que alguns erros ficaram relativamente maiores que os outros para indivíduos diferentes e, em alguns casos, para aquisições diferentes de um mesmo indivíduo. Isso pode ser explicado pelos diferentes níveis de qualidade do sinal utilizado para a calibração do sinal. Como por exemplo no caso do indivíduo 5, onde para o primeiro teste (que utiliza a terceira aquisição como calibração), a diferença entre os métodos foi maior, já no segundo teste (que utiliza a segunda aquisição como calibração), os resultados foram consideravelmente mais semelhantes.

Analisando-se os casos no quais isso ocorreu foi notado que, quando o sinal de calibração utilizado apresentava mais artefatos, os sinais resultantes se aproximavam mais do resultado do método padrão. Isso pode ser explicado pelo fato de que, quando o sinal apresenta mais artefatos, mais fácil de identificá-los nos outros sinais e removê-los. Devido a isso, pode-se considerar no momento das aquisições de calibração, realizar artefatos proposadamente para poder identificá-los e, assim, removê-los melhor.


Tabela 2 - Resultados dos erros relativos percentual e NRMSE para cada grupo de teste da Validação Cruzada, da comparação entre o método de referência e o Método proposto.

Teste 1			Teste 2			Teste 3		
Sinal	Erro relativo (%)	NRMSE	Sinal	Erro relativo (%)	NRMSE	Sinal	Erro relativo (%)	NRMSE
S1-Iv1	20,39	0.2389	S1-Iv1	7.9336	0.104	S2-Iv1	14.1309	0.1691
S1-Iv2	14.02	0.1616	S1-Iv2	16.3685	0.1928	S2-Iv2	7.2266	0.0917
S1-Iv3	29.11	0.325	S1-Iv3	20.5946	0.2295	S2-Iv3	5.3289	0.1268
S1-Iv4	30.61	0.3219	S1-Iv4	26.7827	0.2863	S2-Iv4	21.4564	0.2342
S1-Iv5	19.12	0.2437	S1-Iv5	14.691	0.1991	S2-Iv5	39.4251	0.3948
S1-Iv6	3.43	0.0449	S1-Iv6	4.9171	0.0649	S2-Iv6	13.9015	0.2026
S1-Iv7	9.15	0.1139	S1-Iv7	11.6176	0.1442	S2-Iv7	7.6283	0.1321
S1-Iv8	9.0317	0.1353	S1-Iv8	12.5031	0.1632	S2-Iv8	35.443	0.3843
S1-Iv9	10.7711	0.1241	S1-Iv9	7.0392	0.0816	S2-Iv9	4.8153	0.0639
S1-Iv10	33.8226	0.345	S1-Iv10	32.434	0.3264	S2-Iv10	35.3971	0.3632
S1-Iv11	33.9261	0.3607	S1-Iv11	33.561	0.3456	S2-Iv11	33.5617	0.3829
S1-Iv12	39.2506	0.449	S1-Iv12	33.134	0.3789	S2-Iv12	12.7665	0.1604
S2-Iv1	17.7906	0.2016	S3-Iv1	31.221	0.3634	S3-Iv1	34.7563	0.3918
S2-Iv2	13.5355	0.1562	S3-Iv2	28.7798	0.3057	S3-Iv2	24.9652	0.3142
S2-Iv3	5.2299	0.0984	S3-Iv3	15.0658	0.1848	S3-Iv3	17.1775	0.2125
S2-Iv4	39.4221	0.4177	S3-Iv4	12.4254	0.1381	S3-Iv4	9.6019	0.1103
S2-Iv5	31.5659	0.379	S3-Iv5	7.4384	0.0854	S3-Iv5	16.7554	0.1808
S2-Iv6	22.903	0.2652	S3-Iv6	9.9069	0.1709	S3-Iv6	9.725	0.1294
S2-Iv7	0.6235	0.0125	S3-Iv7	6.7786	0.0789	S3-Iv7	12.8099	0.1902
S2-Iv8	35.3033	0.4148	S3-Iv8	3.7441	0.0462	S3-Iv8	8.2167	0.109
S2-Iv9	6.7961	0.0919	S3-Iv9	8.2565	0.1148	S3-Iv9	6.5499	0.0844
S2-Iv10	35.0941	0.3715	S3-Iv10	16.4047	0.2094	S3-Iv10	18.2427	0.2153
S2-Iv11	30.5591	0.3379	S3-Iv11	15.6222	0.1807	S3-Iv11	19.1165	0.2169
S2-Iv12	19.1019	0.2514	S3-Iv12	11.2617	0.1252	S3-Iv12	17.4352	0.2191

Fonte: Arquivo do próprio autor (2017)

A partir dos dados da Tabela 2, foram feitas as médias de cada teste, primeiramente para o erro relativo percentual que são compiladas no gráfico da Figura 40. Logo, no primeiro teste a média obtida foi de 21,27%, no segundo teste foi 16,19% e no terceiro teste foi 17,77%, obtendo-se uma média geral de 18,41% de erro relativo, que pode ser observado como 81,59% de semelhança entre os sinais resultantes do método de referência e dos sinais resultantes do método.


Figura 40 - Gráfico demonstrando as médias dos erros percentuais obtidos para cada teste da Validação Cruzada para o Método Proposto.



Fonte: Arquivo do próprio autor (2017)

Já na Figura 41, são apresentadas as médias dos testes de comparação do método com o método de referência do NRMSE. Desta forma, os valores obtidos para cada teste foi de 0,2467 para o primeiro teste, 0,1883 para o segundo teste e de 0,2116 para o terceiro teste. A média geral obtida foi de 0,2139, que se representada em percentual se assemelha ao resultado obtido pelo método anterior de comparação, demonstrando uma boa aproximação entre o método de tempo real com o método de referência.

Figura 41 - Gráfico demonstrando as médias dos NRMSE obtidos para cada teste da Validação Cruzada para o Método Proposto.



Fonte: Arquivo do próprio autor (2017)

Observando-se os resultados, é possível admitir que o método proposto neste trabalho obtive resultados semelhantes ao método de referência, tanto nas análises visuais como nos

testes quantitativos, demonstrando que a capacidade de remoção de artefatos, mesmo em tempo real, é semelhante ao método de referência que é *off-line*.

Além disso, nos dois tipos de erros calculados, os grupos de teste apresentaram resultados semelhantes, o que demonstra robustez no método proposto independente dos grupos de dados analisados.

6 CONCLUSÃO

Neste trabalho foram apresentadas técnicas de processamento digital de sinais capazes de remover artefatos dos sinais de eletroencefalografia, com um tempo de execução viável para aplicações em *Neurofeedback* e de baixo consumo computacional, permitindo que seja posteriormente embarcado em outros sistemas eletrônicos.

O método proposto é baseado na Análise de Componentes Independentes (ICA), para realizar a decomposição de fontes e encontrar as matrizes de componentes para utilizá-las como filtros espaciais.

O método utiliza uma matriz com apenas componentes de artefatos para detectar os artefatos e, posteriormente, uma multiplicação e uma subtração para remover o artefato, com um tempo de execução de 1,37 ms para um canal com um segundo de dados (com taxa de amostragem de 512 Hz) executado no Matlab em um computador com processador CORE i3 e 4GB de memória RAM. Os tempos de execução de outros métodos na literatura indicam ser maiores do que o método proposto, mas vale ressaltar que uma comparação mais precisa, em mesmas condições, precisaria ser feita.

Para observar a capacidade de remoção do método proposto, foi criado e inserido artificialmente um artefato de piscada dos olhos em um sinal de EEG que não apresentava este artefato. O método proposto foi então aplicado e demonstrou capacidade de atenuar o artefato, logo que, quando comparado com o sinal original sem artefato, apresentou um erro relativo percentual de 12,5%.

Em seguida, foi realizada a análise espectral do sinal de EEG original sem artefato, com o sinal após o artefato adicionado e do sinal resultante do método proposto, o que demonstrou que na faixa de frequência mais baixa (onde atua o artefato de piscada) houve diferenças entre o espectro do sinal original sem artefato e após adicionado o artefato, já o sinal resultante do método proposto aproximou-se nessa faixa de frequência sem apresentar grandes diferenças em outras faixas. O que nos permite concluir que o método é capaz de atenuar os artefatos de interesse sem causar alterações em faixas de frequência de sinal não relacionadas ao artefato.

Além disso, o método proposto foi comparado com um método de remoção de artefatos de referência que é *off-line*, com o objetivo de avaliar a capacidade do método proposto de remover artefatos

Desta forma, o método proposto apresentou uma semelhança de 81,59% com o método de referência ou um erro relativo percentual de 18,41%, além do NRMSE médio de

0,2139, que se representado percentual se aproxima do valor obtido com o erro relativo percentual.

Logo, pode-se dizer que o método proposto demonstra resultados bastante semelhantes ao método de referência, apresentando assim uma boa capacidade de remoção de artefatos para ser aplicado em tempo real.

Outro ponto a ser ressaltado quanto aos métodos de comparação quantitativos é que, o método proposto apresentou resultados semelhantes para todos os grupos de teste, o que permite concluir que o método possui boa capacidade de generalização.

Neste trabalho, também foi possível realizar a aquisição de sinais de EEG utilizando a touca de EEG da neuroUP e o eletroencefalógrafo Nexus32, com 12 diferentes indivíduos. Desta forma, todos os objetivos propostos inicialmente neste trabalho foram alcançados.

Como proposta de trabalho futuro, pode-se embarcar o algoritmo de remoção de artefatos em tempo real proposto em sistemas como *FPGA (Field-Programmable Gate Array)* para aplicações que não necessitem de computador, possibilitando maior mobilidade.

Ademais, propõe-se que a fase *off-line* de estimação das matrizes das componentes das fontes geradoras de sinal, seja substituída por matrizes de componentes padrões, geradas a partir de um banco de dados. Ou seja, em vez de estimar as matrizes individualmente para cada indivíduo, seriam geradas matrizes médias baseadas em um grupo de muitos indivíduos.

Por fim, outro possível trabalho futuro é a utilização de um algoritmo de BSS diferente do *Infomax*, como por exemplo o *SOBI (Second-Order Blind Identification)*, com objetivo de verificar qual dos algoritmos é capaz de separar melhor as fontes de artefatos.

REFERÊNCIAS

AIRES, M. M. **Fisiologia**. Rio de Janeiro: Editora Guanabara Koogan, 1997.

AKHTAR, M. T.; MITSUASHI, W.; JAMES, C. J. Employing spatially constrained ICA and wavelet denoising, for automatic removal of artifacts from multichannel EEG data. **Signal Processing**, v. 92, n. 2, p. 401–416, 2012.

ALL ABOUT CIRCUITS. 2017. 1 fotografia, P&B. Disponível em: <<https://www.allaboutcircuits.com/textbook/semiconductors/chpt-8/the-instrumentation-amplifier/>>. Acesso em: 21 de maio de 2017.

AMARI, S.; CICHOCKI, A.; YANG, H. H.. A new learning algorithm for blind signal separation. In: Neural information processing systems, 8., 1995, Denver. **Anais**. Denver: NIPS Proceedings, 1996. p. 757-763.

ARNS, M.; DE RIDDER, S.; STREHL, U.; BRETELER, M.; COENEN, A. Efficacy of Neurofeedback Treatment in ADHD: The Effects on Inattention, Impulsivity and Hyperactivity: A Meta-Analysis. **Clinical EEG and Neuroscience**, v. 40, n. 3, p. 180–189, 2009.

BELL, A. J.; SEJNOWSKI, T. J. An information-maximization approach to blind separation and blind deconvolution. **Neural computation**, v. 7, n. 6, p. 1129-1159, 1995.

BERTEMES FILHO, P. **Proposta de um sistema telemétrico para registro de potencias bioelétricos**. 1998. 149 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade Federal de Santa Catarina, Santa Catarina, 1998.

BIO-MEDICAL. 2017. 1 fotografia, color. Disponível em: <<https://bio-medical.com/waveguard-connect-19-channel-eeeg-cap.html> >. Acesso em: 08 de maio de 2017.

BRONZINO, J. D. Principles of electroencephalography. In:_____. (Org.). **The biomedical engineering handbook**. Nova York: CRC Press, 1995. p. 191-200.

BUTTON, V. L. S. N. **Instrumentação Biomédica**. Campinas: DEB/FEEC Unicamp, 2003.

CAPARELLI, T. B. **Projeto e desenvolvimento de um sistema multicanal de biotelemetria para detecção de sinais de ECG, EEG e EMG**. 2007. 58 f. Dissertação (Mestrado em Engenharia Elétrica), Universidade Federal de Uberlândia, Uberlândia, 2007.

CHANG, W.D.; LIM, J.H.; IM, C.H. An unsupervised eye blink artifact detection method for real-time electroencephalogram processing. **Physiological Measurement**, v. 37, n. 3, p. 401–417, 2016.

CHATRIAN, G. E.; LETTICH, E.; NELSON, P. L. Ten percent electrode system for topographic studies of spontaneous and evoked EEG activities. **American Journal of EEG technology**, v. 25, n. 2, p. 83-92, 1985.

CHEN, X.; WANG, Z. J. Design and Implementation of a Wearable, Wireless EEG Recording System. In: INTERNATIONAL CONFERENCE ON BIOINFORMATICS AND BIOMEDICAL ENGINEERING, 5., 2011, Wuhan. **Anais...** . Wuhan: ICBBE, 2011. p. 1 – 4.

CHI, Y. M.; JUNG, T.-P.; CAUWENBERGHS, G. Dry-contact and Non-contact Biopotential Electrodes, **IEEE Reviews in Biomedical Engineering**, v. 3, n. 1, p. 106–119, 2010.

ÇINAR, S.; ACIR, N. A novel system for automatic removal of ocular artefacts in EEG by using outlier detection methods and independent component analysis, **Expert Systems With Applications**, v. 68, p. 36–44, 2017.

COGNIONICS (San Diego). **COGNIONICS**. 2011. Disponível em: <<http://www.cognionics.com/index.php>>. Acesso em: 21 maio 2017.

COHEN, A. Biomedical Signals: Origin and Dynamic Characteristics; Frequency Domain Analysis. In: BRONZINO, J. D. **The Biomedical Engineering Handbook**. Nova York: CRC Press, 1995. Cap. 54. p. 805-827.

CORREA, A Garcés et al. Artifact removal from EEG signals using adaptive filters in cascade. In: ARGENTINE BIOENGINEERING CONGRESS, 16., 2007, San Juan. Artifact removal from EEG signals using adaptive filters in cascade. San Juan: Iop Publishing, 2007. v. 90, p. 1 - 4.

CRESPO-GARCIA, M.; ATIENZA, M.; CANTERO, J. L. Muscle artifact removal from human sleep EEG by using independent component analysis. **Annals of biomedical engineering**, v. 36, n. 3, p. 467-475, 2008.

CROFT, R. J.; CHANDLER, J. S.; BARRY, R. J.; COOPER, N. R.; CLARKE, A. R. EOG correction: A comparison of four methods. **Psychophysiology**, v. 42, n. 1, p. 16–24, 2005.

DALY, I.; BILLINGER, M.; SCHERER, R.; MUELLER-PUTZ, G. On the automated removal of artifacts related to head movement from the EEG. **IEEE Transactions on Neural Systems And Rehabilitation Engineering**, v. 21, n. 3, p. 427–434, 2013.

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

DELORME, A.; PALMER, J.; ONTON, J; OOSTENVELD, R.; MAKEIG, S. Independent EEG Sources Are Dipolar, **PLoS ONE**, v. 7, n. 2, 2012.

DUTRA, O. O. **Um Amplificador Neural de baixo ruído e baixa potência utilizando uma topologia Folded Cascode OTA com malha de realimentação PID e ganho ajustável para EEG SoC Arrays**. 2012. 85 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade Federal de Itajubá, Itajubá, 2012.

EMOTIV (São Francisco). **Emotiv Epoch**. 2017. Disponível em: <<https://www.emotiv.com/epoc/>>. Acesso em: 21 maio 2017.

ESTEPP, J. R., CHRISTENSEN, J. C., MONNIN, J. W.; DAVIS, I. M.; WILSON, G. F. Validation of a dry electrode system for EEG. In: **Proceedings of the Human Factors and Ergonomics Society Annual Meeting**. Los Angeles, CA, USA: Sage Publications, v. 53, n. 18, p. 1171–1175, 2009.

FATOURECHI, M.; BASHASHATI, A.; WARD, R. K.; BIRCH, G. E. EMG and EOG artifacts in brain computer interface systems: A survey. **Clinical Neurophysiology**, v. 118, n. 3, p. 480–494, 2007.

FIELDTRIP. 2017. 1 fotografia, P&B. Disponível em: <http://www.fieldtriptoolbox.org/_media/template/easycapm11.png> Acesso em: 18 de maio de 2017.

G.TEC (Áustria). **G.Nautilus**. [2015]. Disponível em: <<http://www.gtec.at/Products/Hardware-and-Accessories/g.Nautilus-Specs-Features>>. Acesso em: 21 maio 2017.

GEDDES, L. A.; BAKER, L. E. **Principles of Applied Biomedical Instrumentation**. 3. ed. [Nova York]: John Wiley & Sons, 1989.

GONCHAROVA, I. I.; MCFARLAND, D. J.; VAUGHAN, T. M.; WOLPAW, J. EMG contamination of EEG: spectral and topographical characteristics, **Journal of Clinical Neurophysiology**, v. 114, n. 9, p. 1580–1593, 2003.

GRATTON, G.; COLES, M. G. H.; DONCHIN, E. A new method for off-line removal of ocular artifact. **Electroencephalography and Clinical Neurophysiology**, v. 55, n. 4, p. 468–484, 1983.

GUERRERO-MOSQUERA, C.; VAZQUEZ, A. N. Automatic removal of ocular artifacts from EEG data using adaptive filtering and independent component analysis. In: SIGNAL PROCESSING CONFERENCE, 17., 2009, Santorini. **Anais...** . [Santorini]: IEEE, 2009. p. 2317 - 2321.

GUYTON, A. C.; HALL, J. E. **Tratado de Fisiología Médica**. 12a. ed. [S.l.]: Elsevier, 2011.

HAAS, L. F. Hans Berger (1873–1941), Richard Caton (1842–1926), and electroencephalography. **Journal of Neurology, Neurosurgery & Psychiatry**, v. 74, n. 1, p. 9-9, 2003.

HAMMOND, D. C. What Is Neurofeedback?. **Journal of Neurotherapy**, v. 10, n. 4, p. 25-36, 2007.

HOFF, H. E.; GEDDES, L. A. Graphic recording before Carl Ludwig: An historical summary. **Archives internationales d'histoire des sciences**, v. 12, p. 3-25, 1959.

HSU, S.-H.; MULLEN, T. R.; JUNG, T. P.; CAUWENBERGHS, G. Real-Time Adaptive EEG Source Separation Using Online Recursive Independent Component Analysis. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, v. 24, n. 3, p. 309-319, 2016.

HYVARINEN, A.; KARHUNEN, J.; OJA, E. **Independent Component Analysis**. John Wiley and Sons, Inc., 1 ed., 2001.

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

JASPER, H. H. The ten twenty electrode system of the international federation, **Electroencephalography and clinical neurophysiology**, v. 10, p. 371-375, 1958.

JOHAL, P. K.; JAIN, N. Artifact removal from EEG: A comparison of techniques. In: INTERNATIONAL CONFERENCE ON ELECTRICAL, ELECTRONICS, AND

OPTIMIZATION TECHNIQUES, 1., 2016, Chennai. **Anais...** . Chennai: IEEE, 2016. p. 2088 - 2091.

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, 2004.

JUNG, T. P.; MAKEIG, S.; HUMPHRIES, C.; LEE, T. W.; MCKEOWN, M. J.; IRAGUI, V.; SEJNOWSKI, T. J. Removing electroencephalographic artifacts by blind source separation, **Psychophysiology**, v. 37, n. 2, p. 163–178, 2000.

KANDEL, E. R.; SCHWARTZ, J. H.; JESSELL, T. M. **Principles of Neural Science**. 4. ed. Nova York: McGraw-Hill, 2000.

KIRKOVE, M.; FRANOIS, C.; VERLY, J. Comparative Evaluation of Existing and New Methods for Correcting Ocular Artifacts in Electroencephalographic Recordings, **Signal Processing**, v. 98, p. 102–120, 2014.

LANGLOIS, D.; CHARTIER, S.; GOSSELIN, D. An introduction to independent component analysis: InfoMax and FastICA algorithms. **Tutorials in Quantitative Methods for Psychology**, v. 6, n. 1, p. 31-38, 2010.

LANTYER, A. S.; VIANA, M. B.; PADOVANI, R. C. Biofeedback no tratamento de transtornos relacionados ao estresse e à ansiedade: uma revisão crítica. **Psico-USF**, v. 18, n. 1, p. 131-140, 2013.

LI, Z.; LIN, Q. FPGA implementation of Infomax BSS algorithm with fixed-point number representation. In: **Neural Networks and Brain, 2005. ICNN&B'05**. International Conference on. IEEE, 2005. p. 889-892.

LIAO, L.; CHEN, C.-Y.; WANG, I.-J.; CHEN, S.-F.; LI, S.-Y.; CHEN, B.-W.; CHANG, J.-Y.; LIN, C.-T. Gaming control using a wearable and wireless EEG-based brain-computer interface device with novel dry foam-based sensors, **Journal of neuroengineering and rehabilitation**, v. 9, n. 5, 2012.

LIAO, L.-D., I.-J. WANG, S.-F. CHEN, C. JYH-YEONG, AND C.-T. LIN. Design, Fabrication and Experimental Validation of a Novel Dry-Contact Sensor for Measuring

Electroencephalography Signals without Skin Preparation, **Sensors**, v. 11, n. 6, p. 5819–5834, 2011.

LIN, C.-T.; KO, L.-W.; CHIOU, J.-C.; DUANN, J.-R.; HUANG, R.-S.; LIANG, S.-F.; CHIU, T.-W.; JUNG T.-P. Noninvasive Neural Prostheses Using Mobile and Wireless EEG, **Proceedings of the IEEE**, v. 96, n. 7, p.1167–1183, 2008.

LOPEZ-GORDO, M. A.; SANCHEZ-MORILLO, D.; PELAYO-VALLE, F. Dry EEG electrodes. **Sensors**, v. 14, n. 7, p. 12847–12870, 2014.

LUDWIG, K. A.; MIRIANI, R. M.; LANGHALS, N. B.; JOSEPH, M. D.; ANDERSON, D. J.; KIPKE, D. R. Using a common average reference to improve cortical neuron recordings from microelectrode arrays. **Journal of neurophysiology**, v. 101, n. 3, p. 1679-1689, 2009.

MACKENZIE, James. **Diseases of the Heart**. Oxford University Press, 1910.

MAJMUDAR, C. A.; MORSHED, B. I. Autonomous OA removal in real-time from single channel EEG data on a wearable device using a hybrid algebraic-wavelet algorithm. **ACM Transactions on Embedded Computing Systems (TECS)**, v. 16, n. 1, p. 20, 2016.

MAKEIG, S. et al. Independent Component Analysis of Simulated ERP Data. In: NAKADA, T. (Ed.). **Integrated Human Brain Science:: Theory, Methods and Application (Music)**. [Michigan]: Elsevier, 2000. p. 1-24.

MAKEIG, S.; BELL, A. J.; JUNG, T.-P.; SEJNOWSKI, T. J. Independent component analysis of electroencephalographic data. **Advances in Neural Information Processing Systems**, p. 145–151, 1996.

MATIKO, J. W.; BEEBY, S.; TUDOR, J. Real time eye blink noise removal from EEG signals using morphological component analysis. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (EMBC), 35., 2013, Osaka. **Anais...** . Osaka: IEEE, 2013. p. 13 - 16.

MCMENAMIN, B. W.; SHACKMAN, A. J.; MAXWELL, J. S.; BACHHUBER, D. R. W.; KOPPENHAVER, A. M.; GREISCHAR, L. L.; DAVIDSON, R. J. Validation of ICA-based myogenic artifact correction for scalp and source-localized EEG. **Neuroimage**, v. 49, n. 3, p. 2416–2432, 2010.

MIHAJLOVIĆ, V.; GRUNDLEHNER, B.; VULLERS, R.; PENDERS, J. Wearable, Wireless EEG Solutions in Daily Life Applications: What are we Missing?. **IEEE Journal of Biomedical and Health Informatics**, v. 19, n. 1, p. 6-21, 2015.

MIOVIC, B.; DE VOS, M.; GLIGORIJEVIC, I.; TAELEMAN, J.; VAN HUFFEL, S. Source Separation From Single-Channel Recordings by Combining Empirical-Mode Decomposition and Independent Component Analysis. **IEEE Transactions in Biomedical Engineering**, v. 57, n. 9, p. 2188– 2196, 2010.

MINDMEDIA. 2017. 1 fotografia, color. Disponível em: < <http://www.mindmedia.info>>. Acesso em 27 de julho de 2017.

MINGUILLON, J.; LOPEZ-GORDO, M. A.; PELAYO, F. Trends in EEG-BCI for daily-life: Requirements for artifact removal. Elsevier, **Biomedical Signal Processing and Control**, v. 31, p. 407-418, 2017.

MORIKAWA, K. et al. Compact Wireless EEG System with Active Electrodes for Daily Healthcare Monitoring. In: IEEE INTERNATIONAL CONFERENCE ON CONSUMER ELECTRONICS (ICCE), 3., 2013, Las Vegas. **Compact Wireless EEG System with Active Electrodes for Daily Healthcare Monitoring**. Las Vegas: IEEE, 2013. p. 204 - 205.

NEUROELECTRICS (Espanha). **ENOBIO**. 2017. Disponível em: <<http://www.neuroelectrics.com/products/enobio/>>. Acesso em: 21 maio 2017.

NEUROSKY (EUA). **MindWave**. 2017. Disponível em: <<http://neurosky.com/biosensors/eeeg-sensor/biosensors>>. Acesso em: 21 maio 2017.

NOACHTAR, S.; RÉMI, J. The Role of EEG in epilepsy: A critical review. Elsevier, **Epilepsy & Behavior**, v. 15, n. 1, p. 22–33, 2009.

NOVA ELETRÔNICA. 2017. 1 fotografia, P&B. Disponível em: <<http://blog.novaeletronica.com.br/o-que-e-um-amplificador-operacional>>. Acesso em 21 de maio de 2017.

NR SIGN. 2017. 1 fotografia, P&B. Disponível em: <<https://www.nrsign.com/eeeg-10-20-system/>>. Acesso em 18 de maio de 2017.

NUNEZ, P. L.; SRINIVASAN, R. **Electric Fields of the Brain: The Neurophysics of EEG**. 2. ed. Nova York: Oxford University Press, 2005.

OOSTENVELD, R.; PRAAMSTRA, P. The five percent electrode system for high-resolution EEG and ERP measurements. **Clinical neurophysiology**, v. 112, n. 4, p. 713–719, 2001.

PHAN, K., L.; WAGER T.; TAYLOR S., F.; LIBERZON I. Functional Neuroanatomy of Emotion: A Meta-Analysis of Emotion Activation Studies in PET and fMRI, Elsevier, **NeuroImage Journal**, v. 16, n. 2, p. 331–348, 2002.

PISARENCO, I.; CAPORRO, M.; PROSPERETTI, C.; MANCONI, M. High-density electroencephalography as an innovative tool to explore sleep physiology and sleep related disorders. **International Journal of Psychophysiology**. v. 92, n. 1, p. 8–15, 2014.

RODRIGUES, M. A. B. **Desenvolvimento de um Instrumento Virtual para Aquisição de Análise de Sinais Bioelétricos**. 1997. 155 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, 1997.

ROMERO, S.; MAÑANAS, M. A.; BARBANOJ, M. J. A comparative study of automatic techniques for ocular artifact reduction in spontaneous EEG signals based on clinical target variables: A simulation case. **Computers in Biology and Medicine**, v. 38, n. 3, p. 348–360, 2008.

ROMERO, S.; MAÑANAS, M. A.; BARBANOJ, M. J. Ocular reduction in EEG signals based on adaptive filtering, regression and blind source separation. **Annals of biomedical engineering**, v. 37, n. 1, p. 176-191, 2009.

ROSA, I. G. **Detecção Automática De Contração Muscular Utilizando A Eletromiografia De Superfície**. 2005. 83 f. Dissertação (Mestrado) - Curso de Ciências em Engenharia Biomédica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2005.

SAFIEDDINE, D.; KACHENOURA, A.; ALBERA, L. BIROT, G.; KARFOUL, A.; PASNICU, A.; BIRABEN, A.; WENDLING, F.; SENHADJI, L.; MERLET, I. Removal of muscle artifact from EEG data: comparison between stochastic (ICA and CCA) and deterministic (EMD and wavelet-based) approaches. **EURASIP Journal on Advances in Signal Processing**, v. 127, p. 1-15, 2012.

SANEI, S.; CHAMBERS, J. A. **EEG Signal Processing**. West Sussex: John Wiley & Sons, 2007.

SANTOS FILHO, S. A.; PROVENZANO, F.; CAMÊLO, P. M.; XAVIER, P. A. M.; TIERRA-CRIOLLO, C. J. Acionamento de uma garra mecânica por meio do Eletrooculograma. In: CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA, 21., 2008, Salvador. **Anais...** . Salvador: SBEB, 2008. p. 425 - 455.

SILVA, M. G. N. M. **Redes Neurais Artificiais para o Reconhecimento de padrões de EEG durante o Movimento e Imaginação do Movimento das mãos**. 2014. 148 f. Tese (Doutorado) - Curso de Engenharia Elétrica, Universidade Federal de Pernambuco, Recife, 2014.

SMITH, S. J. M. EEG in neurological conditions other than epilepsy: when does it help, what does it add? **Journal of Neurology Neurosurgery and Psychiatry**, v. 76, n. 2, p. ii8–ii12, 2005.

SÖRNMO, L.; LAGUNA, P. **Bioelectrical Signal Processing in Cardiac and Neurological Applications**. San Diego: Elsevier Academic Press, 2005.

SPECKMANN, E. J.; WALDEN, J. Mechanisms underlying the generation of cortical field potentials. **Acta Oto-Laryngologica**, v. 111, n. sup491, p. 17-24, 1991

SULLIVAN, T. J.; DEISS, S. R.; JUNG, T.-P.; CAUWENBERGHS, G. A brain-machine interface using dry-contact, low-noise EEG sensors. In: IEEE TRANSACTIONS ON INFORMATION TECHNOLOGY IN BIOMEDICINE, 23., 2008, Seattle. **Anais...** . Seattle: IEEE, 2008. p. 1986 - 1989.

SWEENEY, K. T.; WARD, T. E.; MCLOONE, S. F. Artifact Removal in Physiological Signals – Practices and Possibilities, **IEEE Transactions on Information Technology in Biomedicine**, v. 16, n. 3, p. 488–500, 2012.

TENG, C.; YANYAN, Z.; GANG, W. The removal of EMG artifact from EEG signals by the multivariate empirical mode decomposition. In: SIGNAL PROCESSING, COMMUNICATIONS AND COMPUTING (ICSPCC), 23., 2014, Guilin. **Anais...** . Guilin: IEEE, 2014. p. 873-876.

TEXAS INSTRUMENTS (Dallas). **ECG and EEG Applications**. 2012. Disponível em: <<http://www.ti.com/lit/sg/slyt416/slyt416.pdf>>. Acesso em: 15 jun. 2017.

UNSER, M.; ALDROUBI, A. A Review of Wavelets in Biomedical Applications. **Proceedings of the IEEE**, v. 84, n. 4, p. 626–638, 1996.

URIGÜEN, J.A.; GARCIA-ZAPIRAIN, B.. EEG artifact removal-state-of-the-art and guidelines. **Journal of neural engineering**, v. 12, n. 3, p. 031001, 2015.

VAN ERP, J.; LOTTE, F.; TANGERMANN, M. Brain-Computer Interfaces: Beyond Medical Applications, **Computer**, v. 45, n. 4, p. 26– 34, 2012.

VERNON, D.; DEMPSTER, T.; BAZANOVA, O.; RUTTERFORD, N.; PASQUALINI, M.; ANDERSEN, S. Alpha Neurofeedback Training for Performance Enhancement: Reviewing the Methodology. **Journal of Neurotherapy**, v. 13, n. 4, p. 214–227, 2009.

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

VIGÁRIO, R.; OJA, E. BSS and ICA in Neuroinformatics: From Current Practices to Open Challenges. **IEEE Reviews in Biomedical Engineering**, v. 1, p. 50–61, 2008.

WANG, Y.; WANG, Y.; JUNG, T. A cell-phone-based brain–computer interface for communication in daily life. **Journal of Neural Engineering**, v. 8, n. 2, 2011.

WIDMAIER, E. P.; RAFF, H.; STRANG, K. T. **Fisiologia Humana: Os mecanismos das funções corporais**. Rio de Janeiro: Editora Guanabara Koogan, 2006.

WORLD HEALTH ORGANIZATION (WHO). Global Health Estimates: Depression and Other Common Mental Disorders. Geneva, WHO, 2017. Disponível em: <<http://apps.who.int/iris/bitstream/10665/254610/1/WHO-MSD-MER-2017.2-eng.pdf>>.

Acesso em: 20 de jun., 2017

YANG, B.; DUAN, K; ZHANG, T. Removal of EOG Artifacts from EEG Using a Cascade of Sparse: Autoencoder and Recursive Least Squares Adaptive Filter, **Neurocomputing**, v. 214, p. 1053-1060, 2016.

ZENG, H.; SONG, A.; YAN, R.; QIN, H. EOG Artifact Correction from EEG Recording Using Stationary Subspace Analysis and Empirical Mode Decomposition. **Sensors**, v. 13, n. 11, p. 14839-14859, 2013.

ZHANG, C.; TONG L.; ZENG, Y.; JINGFANG J., BU, H.; YAN, B.; LI, J. Automatic Artifact Removal from Electroencephalogram Data Based on A Priori Artifact Information. **BioMed Research International**, v. 2015, 2015.

ZHAO, Q.; HU, B.; SHI, Y.; LI, Y.; MOORE, P.; SUN, M.; PENG, H. Automatic Identification and Removal of Ocular Artifacts in EEG—Improved Adaptive Predictor Filtering for Portable Applications. **IEEE Transactions on NanoBioscience**, v. 13, n. 2, p. 109-117, 2014.

ZIAI, W. C.; SCHLATTMAN, D.; LLINAS R.; VENKATESHA, S.; TRUESDALE, M.; SCHEVCHENKO, A.; KAPLAN, P. W. Emergent EEG in the Emergency Department in Patients with Altered Mental States. Elsevier, **Clinical Neurophysiology**, v. 123, n 5, p. 910–917, 2012.