



CONECTIVIDADE CEREBRAL PARA O CONTROLE ONLINE DE INTERFACES
CÉREBRO-MÁQUINA

Éric Kauati Saito

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

Orientadores: Carlos Julio Tierra Criollo

Antonio Mauricio Ferreira Leite Miranda
de Sá

Rio de Janeiro

Junho de 2019

CONECTIVIDADE CEREBRAL PARA O CONTROLE ONLINE DE INTERFACES
CÉREBRO-MÁQUINA

Éric Kauati Saito

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

Examinada por:

Prof. Carlos Julio Tierra Criollo, D.Sc.

Prof. Roberto Macoto Ichinose, D.Sc.

Prof. Marco Antonio Meggiolaro, Ph.D.

RIO DE JANEIRO, RJ – BRASIL

JUNHO DE 2019

Saito, Éric Kauati

Conectividade Cerebral para o Controle Online de Interfaces Cérebro-Máquina/ Éric Kauati Saito. – Rio de Janeiro: UFRJ/COPPE, 2019.

XI, 83 p.: il.; 29,7 cm.

Orientadores: Carlos Julio Tierra Criollo

Antonio Mauricio Ferreira Leite Miranda de Sá

Dissertação (mestrado) – UFRJ/ COPPE/ Programa de Engenharia Biomédica, 2019.

Referências Bibliográficas: p. 61-67.

1. Interface Cérebro-Máquina. 2. EEG. 3. Conectividade. 4. Online. 5. Redes Neurais Artificiais. I. Tierra Criollo, Carlos Julio *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Biomédica. III. Título.

Agradecimentos

Primeiramente agradeço minha mãe, Adriana Kauati, por ter colocado a minha educação como prioridade e por ter me dado ótimos conselhos durante o mestrado. Sou grato também pela minha namorada, Marie Sakata, que mesmo pela distância continuou me apoiando em todos os momentos, difíceis ou não.

Sou grato aos meus orientadores, Carlos Júlio e Antonio Maurício, pelo auxílio e ao apoio. E a todos os professores do PEB que me auxiliaram em relação as diversas dúvidas que eu tive durante o mestrado.

Agradeço também aos amigos que fiz no PEB, principalmente a Ana, o Mateus, a Paula, o Vinicius e o Wellington, que me acompanharam e me ajudaram ao longo do mestrado.

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

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

CONNECTIVIDADE CEREBRAL PARA O CONTROLE ONLINE DE INTERFACES CÉREBRO-MÁQUINA

Éric Kauati Saito

Junho/2019

Orientadores: Carlos Julio Tierra Criollo

Antonio Mauricio Ferreira Leite Miranda de Sá

Programa: Engenharia Biomédica

A classificação de diferentes tarefas de Imagética Motora (IM) no mesmo membro ainda é um grande desafio utilizando Eletroencefalografia (EEG), uma vez que a sua representação no córtex motor é muito próxima espacialmente. As técnicas que consideram o fluxo de informação, como a Coerência Direcionada Parcial (PDC), têm se mostrado promissoras para Interface Cérebro-Máquina (ICM) do mesmo membro. O objetivo deste trabalho é identificar *online* a IM da flexão e extensão do cotovelo para acionamento de um braço robótico numa interface cérebro-máquina síncrona. Parâmetros e técnicas de pré-processamento foram estudados em classificação *offline* antes da sua aplicação *online*. Os sinais de EEG de dois participantes foram registrados durante a IM da flexão e extensão do cotovelo, seguindo o braço robótico. A função de conectividade foi utilizada para obter as características para o treinamento da Rede Neural Artificial (RNA) para cada voluntário. Então, quatro sessões *online* foram executadas. Na validação *online* (3 classes: IM de flexão e extensão do cotovelo e da situação de repouso), os melhores valores de acurácia foram 48,0%, para o primeiro voluntário (na terceira sessão) e 58,0% para o segundo voluntário (na quarta sessão). Assim, a conectividade direcionada se mostra promissora para o desenvolvimento de ICM *online* para a classificação de tarefas de imaginação no mesmo membro.

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

CEREBRAL CONNECTIVITY FOR ONLINE CONTROL OF BRAIN COMPUTER INTERFACES

Éric Kauati Saito

June/2019

Advisors: Carlos Julio Tierra Criollo

Antonio Mauricio Ferreira Leite Miranda de Sá

Department: Biomedical Engineering

The classification of different Motor Imagery (MI) tasks of the same limb remains a challenge using electroencephalography (EEG), since its representation in the motor cortex area is very close spatially. Methods that consider the information flow, like Partial Directed Coherence (PDC), have shown to be promising for brain-computer interface (BCI) of the same limb. The objective of this thesis is to identify the MI of elbow flexion and extension to activate a robotic arm with a synchronous BCI. Parameters and preprocessing methods were study in offline classification before their online application. EEG signals of two volunteers were recorded performing during the MI of the elbow flexion and extension, following a robotic arm. For each volunteer, the connectivity function was used to obtain the characteristics for artificial neural network (ANN) training. Four online session were performed. In online validation (3 class: MI elbow flexion and extension and rest), the best accuracy for the first volunteer was 48.0% (third session), and 58.0% for the second volunteer (fourth session). Therefore, directed connectivity looks promising for the development of online BCI for the classification of MI of the same limb.

Sumário

Lista de abreviaturas e siglas	x
1 Introdução.....	1
1.1 Objetivos.....	3
1.2 Objetivos específicos	3
1.3 Estrutura do trabalho	4
2 Fundamentação teórica	5
2.1 Fisiologia neural do sistema motor.....	5
2.1.1 Eletroencefalografia (EEG)	7
2.1.2 Movimento voluntário	10
2.1.3 Imagética motora	11
2.2 Interface cérebro-máquina (ICM).....	12
2.3 Conectividade cerebral	13
2.3.1 Coerência.....	13
2.3.2 Causalidade de Granger.....	14
2.3.3 Modelo multivariado autorregressivo (MVAR).....	14
2.3.4 Função de transferência direcionada (DTF)	16
2.3.5 Coerência direcionada parcial (PDC)	18
2.4 Artefatos	19
2.5 Redes neurais artificiais (RNA).....	20
3 Revisão da literatura	25
3.1 Imagética motora (IM).....	25
3.2 Interface cérebro-máquina.....	26
3.3 Classificadores.....	27
3.4 Classificação de movimentos do mesmo membro	28

3.5 Conectividade cerebral	29
4 Materiais e Métodos	30
4.1 Análise preliminar	30
4.2 Participantes.....	32
4.3 Montagem do experimento	33
4.3.1 Sistema de aquisição.....	34
4.3.2 Eletroencefalograma.....	35
4.4 Treinamento <i>offline</i>	36
4.4.1 O sistema de coleta para o treinamento	36
4.4.2 Protocolo experimental para o treinamento.....	37
4.4.3 Pré-processamento offline	38
4.4.4 Conectividade cerebral	39
4.4.5 Extração de características e classificação	40
4.5 Validação do sistema <i>online</i>	43
5 Resultados.....	45
5.1 Comparação das características	45
5.2 Treinamento <i>offline</i>	46
5.3 Validação do sistema <i>online</i>	50
6 Discussão e conclusões.....	58
7 Referências bibliográficas	61
Apêndice A – XXVI Brazilian Congress on Biomedical Engineering	68
Apêndice B – Resultados preliminares.....	69
Apêndice C – Exemplo de gráficos da gPDC.....	70
ANEXO A – MIQ-R (Revised Movement Imagery Questionnaire) em português	73
ANEXO B – Inventário de Edinburgh	82

ANEXO C – Especificações do manipulador robótico AX18	83
---	----

Lista de abreviaturas e siglas

AIC – *Akaike Information Criterion*

AMS – Área Motora Suplementar

APM – Área Pré-Motora

AVE – Acidente Vascular Encefálico

BA – *Brodman's Area*

BCI – *Brain-Computer Interface*

CAEE – Certificado de Apresentação para Apreciação Ética

CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior

CE – Conectividade Efetiva

CEP – Comitê de Ética em Pesquisa (UFRJ)

CF – Conectividade Funcional

CNPq – Conselho Nacional de Desenvolvimento Científico e Tecnológico

COEP – Comitê de Ética em Pesquisa (UFMG)

Coppe – Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia

CSP – *Common Spatial Patterns*

DC – *Directed Coherence*

DTF – *Directed Transfer Function*

EEG – Eletroencefalografia

EOG – Electrooculografia

FAPERJ – Fundação de Amparo à Pesquisa do Estado do Rio de Janeiro

fMRI – *functional Magnetic Resonance Imaging*

gPDC – *generalized Partial Directed Coherence*

HUCFF – Hospital Universitário Clementino Fraga Filho

ICA – *Independent Component Analysis*

ICM – Interface Cérebro-Máquina

IM – Imagética Motora

LAPIS – Laboratório de Processamento de Sinais e Imagens

LDA – *Linear Discriminant Analysis*

LED – *Ligth-Emitting Diode*

MEG – Magnetoencefalografia

MIQ-RV – *Movement Imagery Questionnaire-Revised*

MLP – *Multilayer Perceptron*

MVAR – *Multivariate Autoregressive model*

PCA – *Principal Components Analysis*

PDC – *Partial Directed Coherence*

PEB – Programa de Engenharia Biomédica

PET – Positron Emission Tomography

RNA – Redes Neurais Artificiais

SBC – *Schwarz's Bayesian Criterion*

SVM – *Support Vector Machine*

UFRJ – Universidade Federal Do Rio De Janeiro

UFMG – Universidade Federal de Minas Gerais

USB – *Universal Serial Bus*

1 Introdução

As interfaces cérebro-máquina (ICM) vêm sendo estudadas por se mostrarem uma opção de melhorar a qualidade de vida de pessoas portadoras de limitações motoras (CURRAN; STOKES, 2003; LEBEDEV; NICOLELIS, 2006; WOLPAW *et al.*, 2002). De acordo com Daly e Wolpaw (2008), a melhora pode ser obtida de duas maneiras: a utilização de ICM como substituto ou facilitador da limitação motora, ou a utilização na reabilitação, podendo ajudar a restaurar funções motoras.

Um dos métodos não invasivos mais utilizados para identificação de padrões provenientes do córtex cerebral em aplicações de ICM é a eletroencefalografia (EEG), sendo um dos motivos para tal a facilidade do seu uso e seu mais baixo custo em relação a outras tecnologias como a imagem por ressonância magnética funcional (fMRI – *functional Magnetic Resonance Imaging*). Porém, um dos problemas desse método é a suscetibilidade a ruídos e a baixa resolução espacial devido ao volume condutor entre as fontes (LEBEDEV; NICOLELIS, 2006; SANTOS FILHO *et al.*, 2009).

A ICM é um sistema interativo que necessita de uma realimentação do resultado dos esforços realizados, de modo que o usuário possa avaliar sua performance, permitindo a correção de eventuais erros. Portanto, é necessário que o sistema possa apresentar essa realimentação enquanto o usuário realiza os esforços (BLANKERTZ *et al.*, 2008; MCFARLAND; WOLPAW, 2011).

A deficiência motora é a limitação mais comum causada pelo acidente vascular encefálico (AVE). Algumas técnicas de reabilitação visam ao aprimoramento das funções motoras (DIMYAN; COHEN, 2011). Uma técnica que vem sendo estudada é a imagética motora (IM) que é uma técnica na qual o indivíduo tenta simular uma determinada ação sem uma resposta muscular (HANAKAWA; DIMYAN; HALLETT, 2008). É um processo cognitivo complexo que vem sendo usado em diversos casos de reabilitação, como, por exemplo, em pacientes pós-AVE, que tiveram o seu sistema motor comprometido (PAZ, 2012). Outro exemplo da sua utilização em reabilitação é com pacientes que tiveram o membro amputado, buscando uma melhoria no controle da prótese (CUNHA *et al.*, 2017). Além disso, estudos sugerem que existe uma relação entre as diferentes áreas ativas no córtex durante a execução do movimento voluntário e a

prática de IM (DECETY; JEANNEROD, 1995; GREZES; DECETY, 2001). A IM tem sido uma maneira de treinar os usuários a ter controle da ICM (CURRAN; STOKES, 2003; DALY; WOLPAW, 2008). De acordo com Curran e Stokes (2003) diversos estudos em ICM utilizam a IM pois causam mudanças dos padrões dos sinais de EEG que se assemelham aos padrões que ocorrem no planejamento do movimento.

A densidade espectral de potência de ritmos cerebrais, o potencial relacionado a evento (COSTA, 2012), análise do sincronismo e dessincronismo relacionados ao evento (ULLOA, 2013) têm sido utilizados como características para reconhecimento de padrões. Porém, movimentos diferentes de um mesmo membro são de difícil distinção com base nessas características, uma vez que as suas representações no córtex motor são muito próximas espacialmente.

Técnicas que consideram a conectividade cerebral, definida como a interação entre as estruturas cerebrais e como elas se relacionam já se mostraram úteis para a detecção da tarefa de IM. Santos Filho *et al.* (2009) utilizaram a função de coerência quadrática para a detecção do movimento imaginado. Assim como a utilização de IM para o controle de ICM, porém essa técnica não permite discernir a sentido do fluxo de informação.

Os trabalhos de Silva (2016) e de Silveira (2017) mostraram que técnicas que consideram o fluxo de informação, como a coerência direcionada parcial (PDC – *Partial Directed Coherence*) (BACCALÁ; SAMESHIMA, 2001) e a função de transferência direcionada (DTF – *Directed Transfer Function*) (KAMINSKI; BLINOWSKA, 1991), são promissoras para o seu uso em ICM do mesmo membro. Porém, não foi aplicado em um sistema *online*. Para resolver os problemas associados à não normalização das séries temporais da PDC, a gPDC (*generalized Partial Directed Coherence*) foi apresentada por Baccalá, Sameshima e Takahashi (2007).

O controle de uma ICM utilizando EEG se baseia no uso de algoritmos de classificação de padrões para executar comandos. Devido à sua importância, Lotte *et al.* (2007, 2018) fizeram duas revisões desses algoritmos classificadores para o uso em ICMS. Alguns desses algoritmos de classificação que foram utilizados para sinais de EEG são: análise de discriminante linear (LDA – *Linear Discriminant Analysis*), máquina de vetores de suporte (SVM – *Support Vector Machine*), *Common Spatial Patterns* (CSP) e

Redes Neurais Artificiais (RNA) (LOTTE; GUAN, 2011; SUBASI; ISMAIL GURSOY, 2010; YONG; MENON, 2015). Porém, deve-se ressaltar que foram utilizadas técnicas diferentes de pré-processamento e extração de características entre os trabalhos.

O tipo de RNA mais utilizada para ICM é o *Multilayer Perceptron* (MLP) (LOTTE *et al.*, 2007; NICOLAS-ALONSO; GOMEZ-GIL, 2012). Esse classificador tem se mostrado promissor para o uso com a conectividade cerebral direcionada para classificação de movimentos do mesmo membro (SILVEIRA, 2017).

Entretanto os estudos de avaliação de algoritmos de classificação para ICMs são muitas vezes apenas avaliados em um sistema *offline*, como dito por Lotte *et al.* (2007, 2018), e sem utilizar como característica a conectividade cerebral. A utilização de um sistema para uma ICM *online* tem que levar em consideração alguns problemas, como, por exemplo, interferências, que são de difícil avaliação *offline* (MCFARLAND; WOLPAW, 2011).

1.1 Objetivos

Identificar *online* a imaginação da flexão e extensão do cotovelo a partir de sinais de EEG para acionamento de um manipulador robótico numa interface cérebro-máquina síncrona.

1.2 Objetivos específicos

- Avaliação de técnicas de tratamento de artefatos na classificação.
- Avaliação da utilização de parâmetros da conectividade cerebral direcionada como característica para a classificação.
- Implementação da rede neural artificial como classificador para a identificação das tarefas de imaginação.
- Implementação de uma ICM síncrona para o controle *online* de um manipulador robótico por indivíduos sem disfunções motoras

1.3 Estrutura do trabalho

Esse trabalho está dividido em seis capítulos: introdução, fundamentação teórica, revisão da literatura, materiais e métodos, resultados, discussão e conclusões.

O capítulo 2 introduz os conceitos teóricos utilizados no trabalho. São apresentados, primeiramente, os conceitos de fisiologia neural do sistema motor. Seguidos de uma introdução a interfaces cérebro-máquina, os conceitos de conectividade cerebral, artefatos em sinais de EEG e a teoria de redes neurais artificiais.

O capítulo 3 apresenta uma revisão da literatura, dando ênfase nos seguintes temas: imagética motora, interface cérebro-máquina, classificadores, classificação de movimentos do mesmo membro e conectividade cerebral.

O capítulo 4 expõe os materiais e métodos utilizados nesse trabalho. Esse capítulo possui uma análise preliminar realizada para tomada de decisões. Uma explicação da escolha dos participantes, a montagem do experimento e o sistema de aquisição. Ainda são explicados o treinamento *offline* do sistema e a validação do sistema *online*.

O capítulo 5 apresenta os resultados obtidos da comparação das características, do treinamento *offline* e da validação do sistema *online*.

O capítulo 6 aborda uma discussão e conclusão acerca dos resultados obtidos, assim como hipóteses e sugestões para trabalhos futuros.

2 Fundamentação teórica

Nessa seção serão abordados os fundamentos teóricos para a realização do trabalho.

2.1 Fisiologia neural do sistema motor

O sistema motor consiste em todos os conjuntos de músculos e neurônios que os comandam, bem como as interações fisiológicas que permitem a execução do movimento (BEAR; CONNORS; PARADISO, 2002; KANDEL *et al.*, 2014). O sistema motor segue uma arquitetura hierárquica de modo a simplificar o processamento. Os níveis mais altos são onde ocorre o planejamento mais geral acerca dos objetivos. Enquanto os níveis mais baixos estão relacionados com a execução desses objetivos (KANDEL *et al.*, 2014). Essa hierarquia pode ser dividida de acordo com Bear, Connors e Paradiso (2002) em três níveis que estão relacionados com a sua função. Começando do nível mais alto, relacionado com a função de estratégia, formado pelas áreas de associação neocórtex e gânglios da base. E tem como funcionalidade a estratégia para atingir o objetivo. O nível intermediário é a função de tática, que comanda a sequência dos músculos necessários para atividade, representado pelo córtex motor e pelo cerebelo. E o nível mais baixo, representado pela medula espinhal e pelo tronco encefálico, está relacionado com a função de execução. (BEAR; CONNORS; PARADISO, 2002).

O principal responsável pelo planejamento do movimento voluntário e cognitivo é o córtex cerebral, sendo a área que corresponde à camada mais externa do encéfalo humano e que possui uma alta densidade de neurônios. Dada a complexidade desse sistema, o córtex cerebral foi dividido em diversas regiões que são especializadas em determinadas tarefas, tal mapeamento foi depois comprovado por meio da resposta a estímulos elétricos (KANDEL *et al.*, 2014).

A divisão apresentada na Figura 2.1 foi originalmente feita por Alfred Campbell e Korbinian Brodmann. As áreas citoarquitetônicas foram escolhidas pelas suas características anatomicamente distintas, sendo essa divisão numerada de 1 a 52, utilizada como referência (BEAR; CONNORS; PARADISO, 2002; KANDEL *et al.*, 2014).

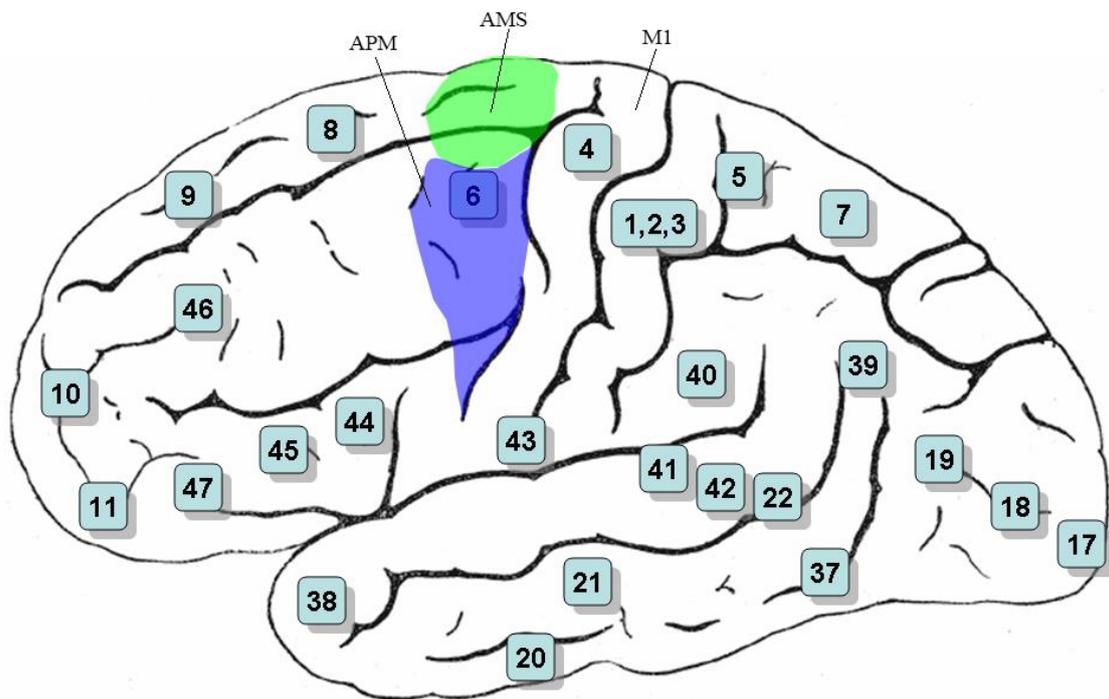


Figura 2.1 – Divisão do córtex cerebral segundo as 52 áreas de Brodmann, vista lateral do hemisfério esquerdo. Área pré-motora e área motora suplementar. Fonte: Henry Gray (1918) Anatomy of the Human Body. Domínio público editado.

A área de Brodmann 4 (BA 4) denominada também como córtex motor primário é a região que está relacionada com o comando da execução do movimento voluntário. Essa região está ligada diretamente com a medula espinhal permitindo assim uma execução direta dos movimentos voluntários. Essa região contém um mapa somatotópico preciso, e estimulações em diversas partes dessa região produzem movimentos contralaterais localizados em determinadas regiões do corpo como podem ser visto na Figura 2.2 (KANDEL *et al.*, 2014).

A área de Brodmann 6 (BA 6) não é homogênea, possuindo subáreas distintas que têm conexões específicas entre elas mesmas e as outras regiões do córtex cerebral, sendo então divididas em cinco ou seis áreas funcionais (KANDEL *et al.*, 2014). Duas áreas que parecem desempenhar papéis semelhantes, mas em diferentes grupos de músculos são a área motora suplementar (AMS) e a área pré-motora (APM). As regiões podem ser vistas na Figura 2.1, AMS em verde e a APM em amarelo. Sendo que a AMS inerva unidades

motoras distais e a APM está conectada com neurônios que inervam as unidades motoras proximais. Essas duas áreas possuem funções que são relacionadas com o planejamento do movimento (BEAR; CONNORS; PARADISO, 2002).

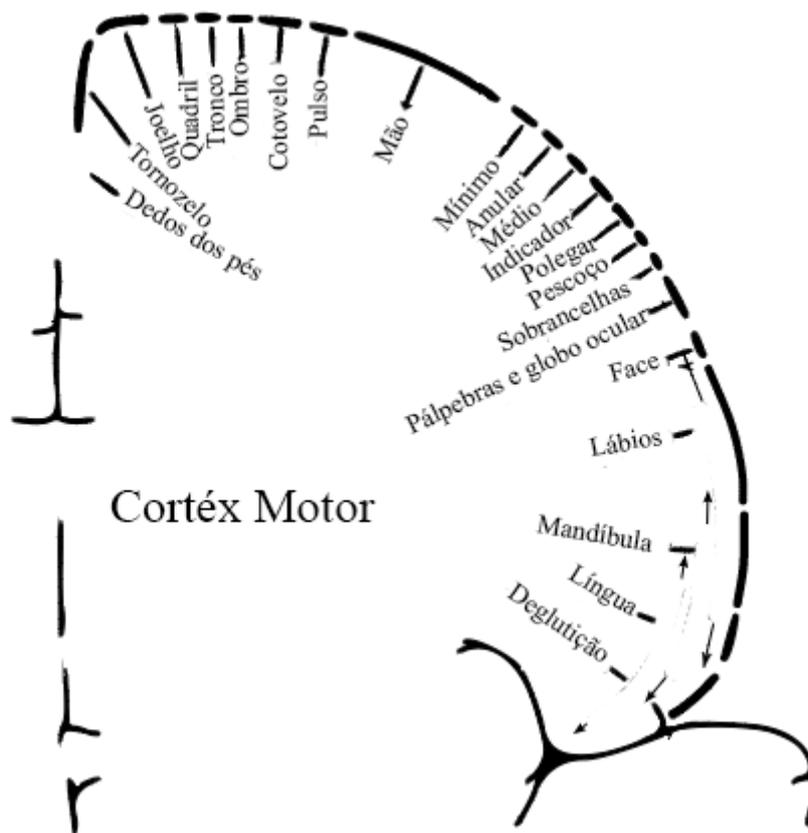


Figura 2.2 – Mapa somatotópico do córtex motor, giro pré-central. Fonte: Domínio público modificado.

2.1.1 Eletroencefalografia (EEG)

A eletroencefalografia (EEG) é o processo não invasivo de registro de sinais de atividade elétrica cerebral no couro cabeludo. Essa atividade é gerada devido ao potenciais de ação pós-sinápticos de atividades corticais e subcorticais (BLINOWSKA; DURKA, 2006).

O sinal de EEG pode ser separado por diferentes bandas de frequências que são associadas a diferentes atividades. Têm-se então cinco grandes divisões: banda delta (0,5-4 Hz), banda teta (4-8 Hz), banda alfa (8-13 Hz), banda beta (13-30 Hz) e banda gama

(acima de 30 Hz). No caso do movimento voluntário, as bandas mais ativas são a alfa e a gama (BLINOWSKA; DURKA, 2006).

O sinal de EEG se altera conforme as propriedades condutoras, tanto do material do qual o eletrodo é feito, quanto dos tecidos entre o eletrodo e a fonte. Para melhorar a condutividade pode ser utilizado um gel ou uma pasta condutora, de modo a melhor casar a impedância elétrica entre a pele e o eletrodo. Por causa da atenuação causada pelos diferentes tecidos entre a fonte e os eletrodos, o sinal de EEG tem uma amplitude da ordem de microvolts, em uma pessoa acordada na faixa de 10-100 μ V (ALLISON, 2003; BLINOWSKA; DURKA, 2006; PASSOS, 2016).

O espalhamento da atividade elétrica através das diferentes estruturas presentes no meio provoca a sobreposição de campos de áreas próximas sobre o sinal captado, processo conhecido como volume condutor (HAMED; SALLEH; NOOR, 2016; INFANTOSI *et al.*, 1998; TIERRA-CRIOLLO; SIMPSON; INFANTOSI, 1997). Logo o sinal medido de EEG é a superposição de diferentes atividades de diversas fontes do córtex.

O sistema internacional 10-10 é um dos padrões para a colocação de eletrodos no couro cabeludo. Esse sistema utiliza a distância entre marcos anatômicos como base para a localização de eletrodos, sendo referido em relação à distância total em porcentagem, 10% é a distância entre os eletrodos em relação à distância total. Outro padrão é o sistema 10-20 que utiliza distâncias de 10% e 20% entre os eletrodos (KLEM *et al.*, 1999; PASSOS, 2016). As Figura 2.3 e Figura 2.4 mostram a disposição dos eletrodos para a utilização na captação do EEG utilizando o sistema internacional 10-20 e 10-10 respectivamente. As regiões são identificadas pelas letras F (frontal), P (parietal), O (occipital), T (temporal), C (central), Fp (frontal polar) e A (pavilhão auricular), e os números pares são relativos ao hemisfério direito e os ímpares, ao esquerdo. Tem-se que as regiões AF, FC, FT, CP, TP e PO, no sistema 10-10, são as regiões intermediárias entre os eletrodos do sistema 10-20.

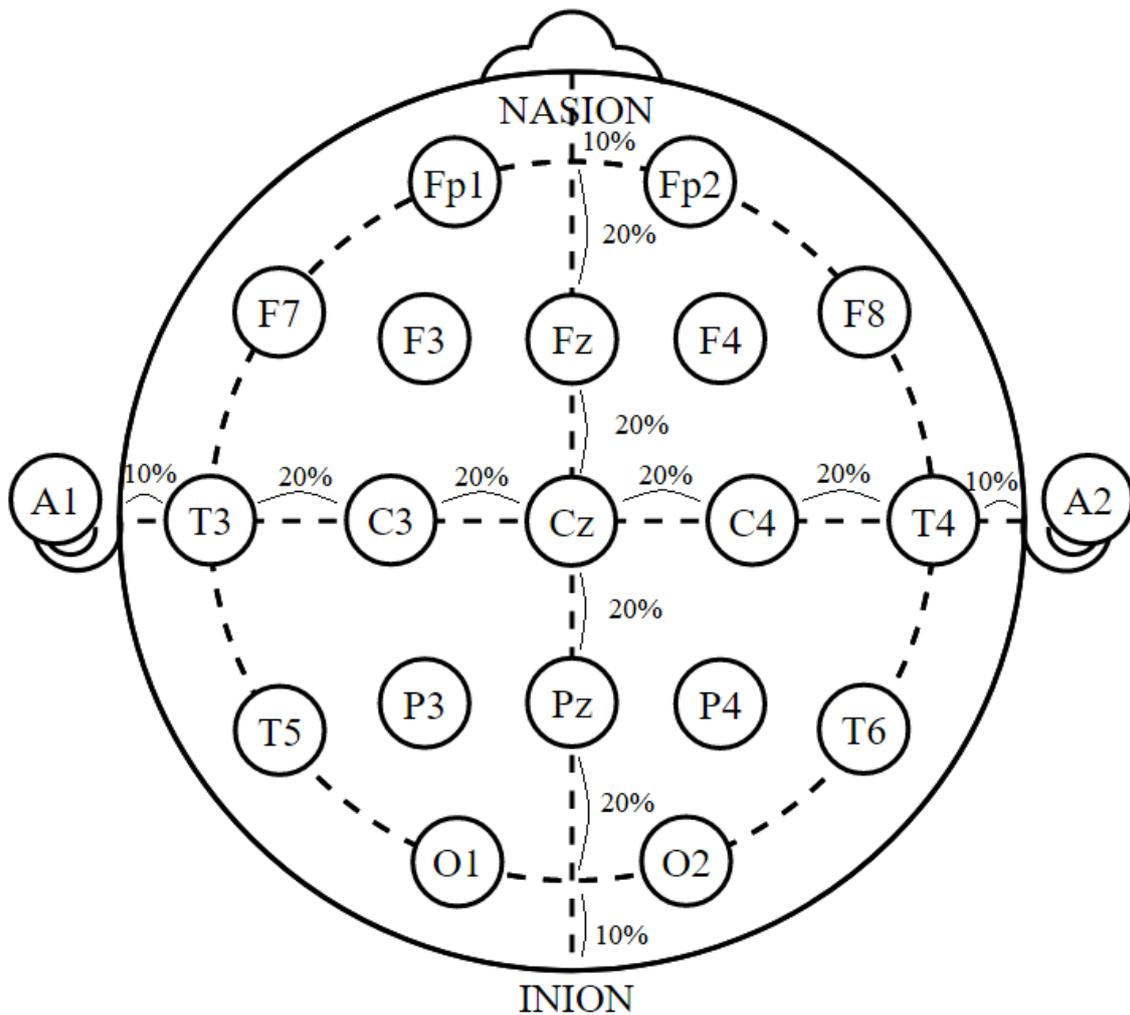


Figura 2.3 – Sistema internacional 10-20 para colocação de eletrodos de EEG.
 Domínio público editado.

A comparação da posição dos eletrodos no sistema internacional em relação às regiões anatômicas, como as áreas de Brodmann, vem avançando cada vez mais com o auxílio de tecnologias como a ressonância magnética (KOESSLER *et al.*, 2009; OKAMOTO *et al.*, 2004). A pesquisa de Okamoto *et al.* (2004) relaciona o sistema 10-20 com as áreas de Brodmann, pode-se observar que BA 4 e 6 são muito pouco representados, sendo o eletrodo que está mapeando a área 4 é o C3. Já o trabalho de Koessler *et al.* (2009) relaciona com o sistema 10-10, onde é possível constatar uma maior representação de BA 4 e 6, em treze eletrodos (F1, Fz, F2, FC5, FC3, FC1, FCz, FC2, FC4, FC6, C1, Cz, C2,).

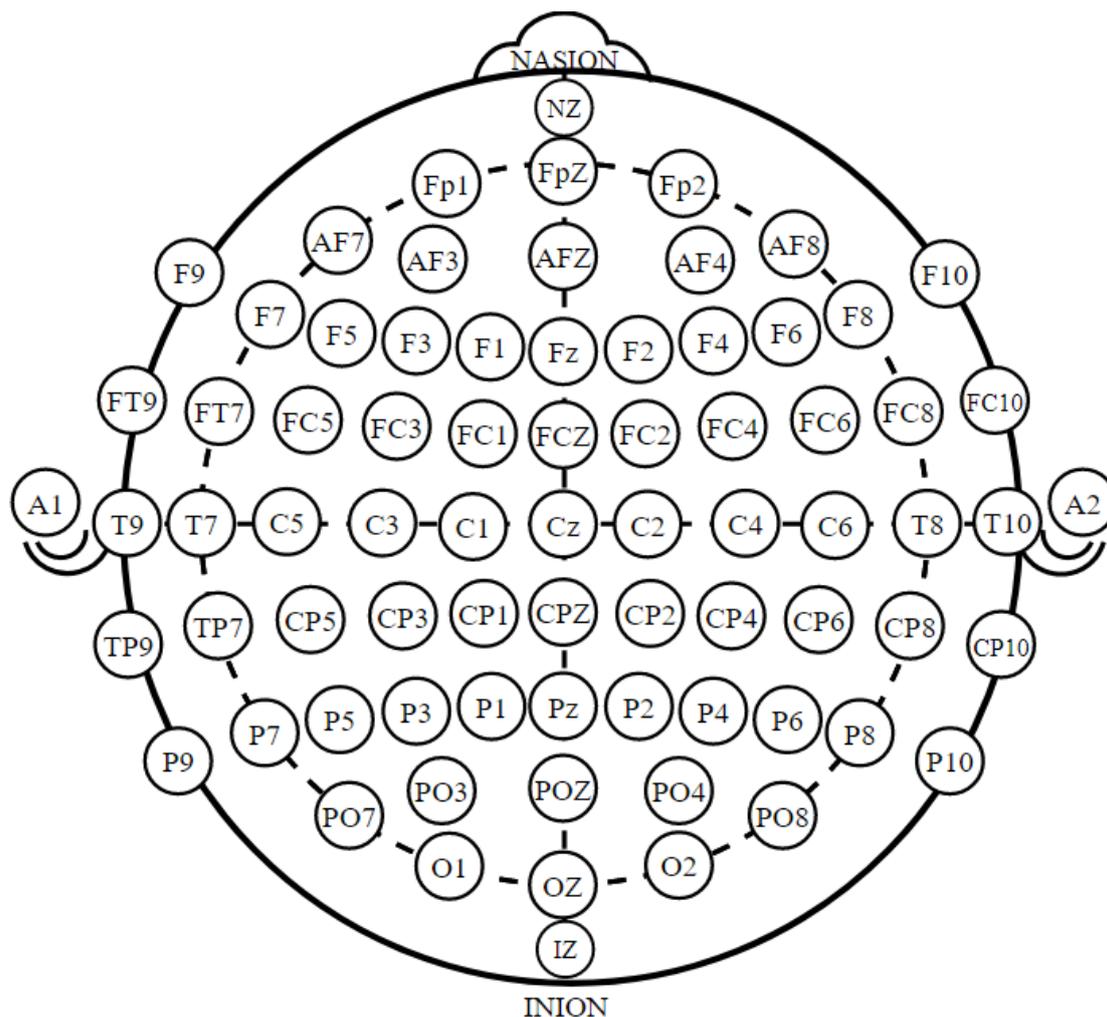


Figura 2.4 – Sistema internacional 10-10 para colocação de eletrodos de EEG.

Domínio público.

A utilização de eletrodos no couro cabeludo possui algumas complicações para aquisição de sinais. Além dos problemas apresentados anteriormente, existem certas interferências que são denominadas artefatos. Essas interferências podem ser causadas por ruídos da rede elétrica e ruídos biológicos, causados pelo próprio indivíduo, como por exemplo, a atividade do coração, o movimento ocular e até mesmo a movimentação muscular próxima à cabeça do indivíduo (ALLISON, 2003; AMABILE et al., 2008; MCFARLAND; WOLPAW, 2011).

2.1.2 Movimento voluntário

Os movimentos iniciados por uma decisão, ou seja, intencionais, são definidos como sendo o movimento voluntário. Essa ação voluntária envolve a tomada de decisões

entre alternativas, podendo acontecer ou não, de modo a alcançar algum objetivo. Esses movimentos diferem do reflexo que são movimentos em resposta a estímulos externos (KANDEL et al., 2014).

Voltando à ideia de hierarquia apresentada anteriormente, tem-se que, no nível mais baixo, a realimentação sensorial é utilizada para manter a postura, a extensão e a tensão muscular durante o movimento. No nível intermediário, a memória das informações sensoriais de movimento passado é utilizada para a tomada de decisões. E, por fim, no nível mais alto, a localização espacial é feita por meio de informações sensoriais (BEAR; CONNORS; PARADISO, 2002).

Dada a complexidade do controle do movimento voluntário tem-se ainda que a eficiência e a natureza podem se alterar conforme a experiência, ou seja, pode-se aprender novas estratégias ou novas reações de modo a modificar a resposta comportamental para que seja possível atingir o objetivo (KANDEL et al., 2014).

2.1.3 Imagética motora

A imagética motora (IM) pode ser definida como o estado dinâmico no qual o indivíduo simula, com o auxílio da memória de trabalho, uma determinada ação sem uma resposta muscular (DECETY; JEANNEROD, 1995). Esse é um processo cognitivo complexo que é auto gerado a partir da utilização de processos sensoriais e perceptivos, de modo a permitir a reativação de ações motoras específicas (DICKSTEIN; DEUTSCH, 2007; SHARMA; POMEROY; BARON, 2006).

Estudos de IM sugerem que existe uma relação entre a execução do movimento e a prática da IM, sendo que já foi observado que algumas áreas ativas se sobrepõem quando comparadas ambas as atividades (DECETY; JEANNEROD, 1995; GREZES; DECETY, 2001), produzindo reações fisiológicas similares, como o aumento significativo da frequência cardíaca e a taxa de respiração. Foi comprovada também uma melhora no desempenho de atletas de alta performance que se utilizaram de treinamento com base em práticas que envolviam IM (SHARMA; POMEROY; BARON, 2006). Além disso, a IM tem se mostrada útil na reabilitação motora de indivíduos pós-AVE (CUNHA et al., 2017; SANTOS-COUTO-PAZ; TEIXEIRA-SALMELA; TIERRA-CRIOLLO, 2013) e no melhor controle de próteses em amputados (CUNHA et al., 2017).

Existem dois principais tipos de IM, uma onde o indivíduo é um espectador, sendo necessária uma informação espacial e visual associada à tarefa. Podendo essa informação visual ser o próprio indivíduo ou em terceira pessoa, imagética visual (ou externa ou terceira pessoa). O outro tipo é uma simulação mental da tarefa, que está associada com a sensação cinestésica do movimento por parte do indivíduo, imagética cinestésica (ou interna ou primeira pessoa). A IM requer uma representação do corpo gerando as ações e não apenas os efeitos que essas ações causam (SOLODKIN et al., 2004).

2.2 Interface cérebro-máquina (ICM)

Interface cérebro-máquina (ICM, ou BCI, do inglês: *Brain-Computer Interface*) é um sistema que permite ao usuário o seu controle utilizando a atividade cerebral, não requerendo uma atividade muscular (DALY; WOLPAW, 2008; LOTTE et al., 2007; MÜLLER et al., 2008). A ICM pode ser concebida de duas formas: assíncrona, quando o usuário tem livre escolha de quando ele deseja realizar o movimento; e síncrona, quando o usuário recebe um comando para realizar o movimento, tendo uma janela fixa e pré-definida de atuação.

O controle de uma ICM pode depender tanto da capacidade de adaptação do usuário para produzir diferentes padrões de respostas de atividade cerebral, de modo que possa ser identificado pelo sistema e então codificado em comandos, quanto pode depender da capacidade de adaptação do sistema para o usuário, de modo que os parâmetros do sistema sejam atualizados com as características do usuário (SHENOY et al., 2006).

Um grande desafio é a extração de características do sinal proveniente da atividade cerebral, de modo a fornecer ao sistema de classificação, os dados mais adequados para o controle da ICM. Existem diversos fatores que podem afetar a variabilidade das respostas cerebrais como o estado emocional, a atenção a concentração e até a memória, essa variabilidade aumenta quando se compara diferentes usuários. Assim, a performance do sistema depende não só da extração de características do sinal, de modo a melhor representar as informações que sejam relevantes, como também da precisão dessa extração (CURRAN; STOKES, 2003; DALY; WOLPAW, 2008; MÜLLER et al., 2008).

2.3 Conectividade cerebral

De acordo com Friston (2011) a conectividade cerebral pode ser definida como a interação entre as estruturas cerebrais e como estas se relacionam durante tarefas motoras, sensoriais ou cognitivas. Podendo ser dividida em conectividade funcional (CF) e conectividade efetiva (CE). Sendo que a CF pode ser definida como a dependência estatística entre séries temporais de eventos que estão espacialmente distante fisiologicamente e a CE como sendo a quantificação da influência direta que um sistema neural exerce sobre outro, sendo esse dependente do modelo pré-determinado (FRISTON, 2011; WANG et al., 2014).

Uma maneira de representar a conectividade cerebral é por meio do uso de grafos, onde os nós representam as áreas corticais e subcorticais e as arestas correspondem às conexões (WANG et al., 2014). Para obtenção dos sinais necessários para a estimação da conectividade, diversas técnicas não invasivas estão sendo utilizadas para a mensuração como: o Magnetoencefalografia (MEG) (FALLANI et al., 2013), o eletroencefalografia (EEG) (SILVA; SÁ; TIERRA-CRIOLLO, 2014), a tomografia por emissão de pósitrons (PET – *Positron Emission Tomography*) (FRISTON, 1994), a imagem por ressonância magnética funcional (fMRI – *functional Magnetic Resonance Imaging*) (GREZES; DECETY, 2001; ROSSO et al., 2013).

Uma das possíveis divisões entre os estimadores de conectividade cerebral é em relação à sua direcionalidade, mais precisamente se o estimador quantifica a direção da influência (BASTOS; SCHOFFELEN, 2016).

2.3.1 Coerência

A função de coerência é um estimador não direcional e Bendat e Piersol (2011) definem essa função entre dois sinais $x(t)$ e $y(t)$ como:

$$\gamma_{xy}^2(f) = \frac{|S_{xy}(f)|^2}{S_{xx}(f)S_{yy}(f)} \gamma_{xy}^2(f) = \frac{|S_{xy}(f)|^2}{S_{xx}(f)S_{yy}(f)} \quad (1)$$

Onde, $S_{xy}(f)$ é a densidade espectral cruzada entre $x(t)$ e $y(t)$, e $S_{xx}(f)$ e $S_{yy}(f)$ a densidade autoespectral de $x(t)$ e $y(t)$ respectivamente. Seus valores estão limitados entre zero e um, sendo que o valor nulo pode indicar que $x(t)$ e $y(t)$ são completamente

descorrelacionados. Porém se o valor for maior que 0 e menor do que 1, existem três possíveis situações: existência de um ruído na medida, o sistema que relaciona os sinais é não linear, e/ou a saída $y(t)$ é causada pela entrada $x(t)$ assim como outras entradas (BENDAT; PIERSOL, 2011).

Assim sendo, para um sistema linear, a função de coerência pode ser entendida como a contribuição do valor médio quadrático da saída $y(t)$ devido a uma entrada $x(t)$ numa dada frequência.

2.3.2 Causalidade de Granger

A Causalidade de Granger parte do seguinte conceito: uma série temporal $x[n]$ possui uma relação causal (nesse trabalho, emprega-se o termo *causal* para representar a causalidade de Granger) a outra série temporal $y[n]$, se o conhecimento de amostras passadas de $x[n]$ consegue melhorar a predição futura de $y[n]$. Esse conceito foi formalizado por Granger (1969) no contexto de modelos de regressão linear de processos estocásticos. Esse método é um estimador direcional e bivariado.

Dadas duas séries temporais e estacionárias de média zero, $x_1[n]$ e $x_2[n]$. Pode-se modelar como.

$$\begin{cases} x_1[n] = \sum_{\tau=1}^p A_{11}[\tau] x_1[n - \tau] + \sum_{\tau=1}^p A_{12}[\tau] x_2[n - \tau] + e_1[n] \\ x_2[n] = \sum_{\tau=1}^p A_{21}[\tau] x_1[n - \tau] + \sum_{\tau=1}^p A_{22}[\tau] x_2[n - \tau] + e_2[n] \end{cases} \quad (2)$$

Onde, os $A[\tau]$ são os coeficientes do modelo autorregressivo multivariado (MVAR – *Multivariate Autoregressive model*), p é a ordem do modelo e $e_1[n]$ e $e_2[n]$ são os erros de predição, considerados como ruído branco gaussiano. Baseando-se na Casualidade de Granger, pode-se dizer que se o erro de predição $e_1[n]$ é reduzido ao incluir termos da segunda série $x_2[n]$ na primeira $x_1[n]$, então $x_2[n]$ possui uma influência causal em $x_1[n]$. De forma semelhante pode-se dizer sobre a redução do erro de predição $e_2[n]$. A série $x_1[n]$ ter uma influência causal em $x_2[n]$ não implica que o contrário é verdadeiro, que $x_2[n]$ é causal a $x_1[n]$.

2.3.3 Modelo multivariado autorregressivo (MVAR)

Algumas das tentativas de se encontrarem estimadores de conectividade são realizadas por meio de modelos bivariados. Porém, como foi mostrado por Blinowska *et*

al (2004), métodos bivariados de estimação podem fornecer resultados errôneos, como no caso nas quais as séries são mutualmente dependentes.

Um modelo autorregressivo é um método paramétrico linear, sendo uma representação de uma relação de entrada e saída de modo recursivo. Esse corresponde a um sistema de filtros recursivos onde a entrada são ruídos brancos. Ou seja, a saída do modelo depende linearmente da soma dos seus próprios valores passados (LÜTKEPOHL, 2005).

Seja um processo de múltiplas séries temporais representado como uma matriz \mathbf{x} de N sinais provenientes de N canais no tempo t :

$$\mathbf{x}[n] = [x_1[n], x_2[n], x_3[n], \dots, x_N[n]]^T \quad (3)$$

Onde, $x[n] = x(n/Fs)$, onde Fs é a frequência de amostragem em Hz. O modelo multivariado autorregressivo pode ser então expresso como:

$$\mathbf{x}[n] = \sum_{\tau=1}^p \mathbf{A}[\tau] \mathbf{x}[n - \tau] + \mathbf{e}[n] \quad (4)$$

Onde, $\mathbf{x}[n]$ é a matriz de sinais, $\mathbf{A}[\tau]$ são p matrizes $N \times N$ dos coeficientes do modelo, p é a ordem do modelo, τ é o atraso e $\mathbf{e}[n]$ é a matriz de ruído branco gaussiano não correlacionado de média zero, denominado também de processo de inovação. A predição do erro pode ser estimada conforme a equação apresentada a seguir:

$$\mathbf{e}[n] = \sum_{\tau=0}^p \hat{\mathbf{A}}[\tau] \mathbf{x}[n - \tau] \quad (5)$$

Onde a matriz $\hat{\mathbf{A}}[\tau] = -1$ para $\tau = 0$ e $\hat{\mathbf{A}}[\tau] = \mathbf{A}[\tau]$ para $\tau > 0$. Transformando-se para o domínio da frequência tem-se:

$$\mathbf{E}(f) = \mathbf{A}(f) \mathbf{X}(f) \quad (6)$$

$$\mathbf{X}(f) = \mathbf{A}(f)^{-1} \mathbf{E}(f) = \mathbf{H}(f) \mathbf{E}(f) \quad (7)$$

Onde, $\mathbf{H}(f)$ é a matriz da função de transferência do sistema.

A ordem do modelo é a quantidade de observações passadas que será usada para a representação do sinal. Uma das maneiras de determinar a ordem do modelo é por meio do critério de informação de Akaike (AIC, do inglês: *Akaike Information Criterion*) (AKAIKE, 1974), ou do critério Bayesiano de Schwarz (SCB, do inglês *Schwarz's Bayesian Criterion*) (SCHWARZ, 1978).

2.3.4 Função de transferência direcionada (DTF)

O seguinte método é formulado a partir do modelo MVAR. É um método que fornece o sentido da informação, sendo desenvolvido para quatro ou mais canais (KAMINSKI; BLINOWSKA, 1991). Ou seja, é um estimador direcional de conectividade cerebral.

A partir do modelo MVAR apresentado na seção 2.3.3, tem-se que o valor do fluxo de informação da fonte i até j normalizado é dado por:

$$\gamma_{ij}^2(f) = \frac{|H_{ij}(f)|^2}{\sum_{m=1}^N |H_{im}(f)|^2} \quad (8)$$

O fato de a matriz H não ser simétrica mostra que a transmissão do canal i e j não é igual se o caminho for inverso, esse sentido único sugere uma direção no fluxo de informação.

$\gamma_{ij}(f)$ é a função de transferência direta que possui propriedades similares a coerência. Essa versão normalizada gera valores no intervalo de 0 a 1, representando a razão entre o fluxo de informação da fonte j até i e todos os fluxos em i . Pode ser interpretado como uma descrição estrutural de todos os caminhos que conectam duas fontes (BACCALÁ; SAMESHIMA, 2001).

A Figura 2.5 é um exemplo de conectividade, representada por três séries temporais e a influência de uma na outra, dada por:

$$\begin{cases} x_1[n] = 0,7x_1[n-1] - 0,9x_1[n-2] + w_1[n] \\ x_2[n] = 0,5x_1[n-1] - 0,5x_2[n-1] + w_2[n] \\ x_3[n] = -0,4x_2[n-1] + 0,25x_3[n-2] + w_3[n] \end{cases} \quad (9)$$

Onde, $w[n]$ é um ruído branco. Nesse caso, tem-se que a série $x_3[n]$ é calculada usando-se os seus valores passados mais os valores passados da série $x_2[n]$. A série $x_2[n]$ é calculada usando seus valores passados e os valores passados da série $x_1[n]$, essa por sua vez apenas utiliza seus próprios valores passados.

E a Figura 2.6 é o conjunto de gráficos resultantes da DTF, desse exemplo. Em cada gráfico tem-se, no eixo X, a frequência em Hz e no eixo Y, os valores normalizados como explicado anteriormente, indicando o fluxo de informação. Nesse conjunto de gráficos as colunas representam as fontes do fluxo de informação e na linha o destino, por

exemplo, no gráfico da coluna 1 linha 2 temos o fluxo de informação de 1 para 2. E na diagonal principal temos o auto espectro normalizado.

Essa figura mostra uma característica da DTF, de apresentar todos os caminhos de uma série a outra independente se o caminho de influência é direto ou indireto. Nesse caso têm-se os caminhos diretos da série 1 para 2, linha 2 coluna 1, e da série 2 para 3, coluna 2 linha 3, e o caminho indireto de 1 para 3, coluna 1 linha 3.

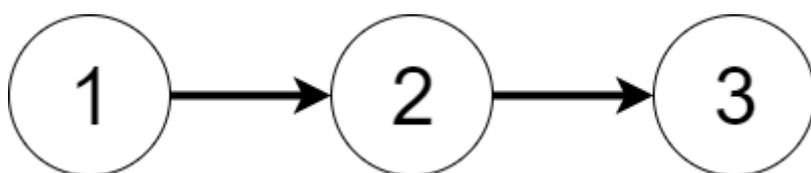


Figura 2.5 – Três séries temporais e a influência entre elas

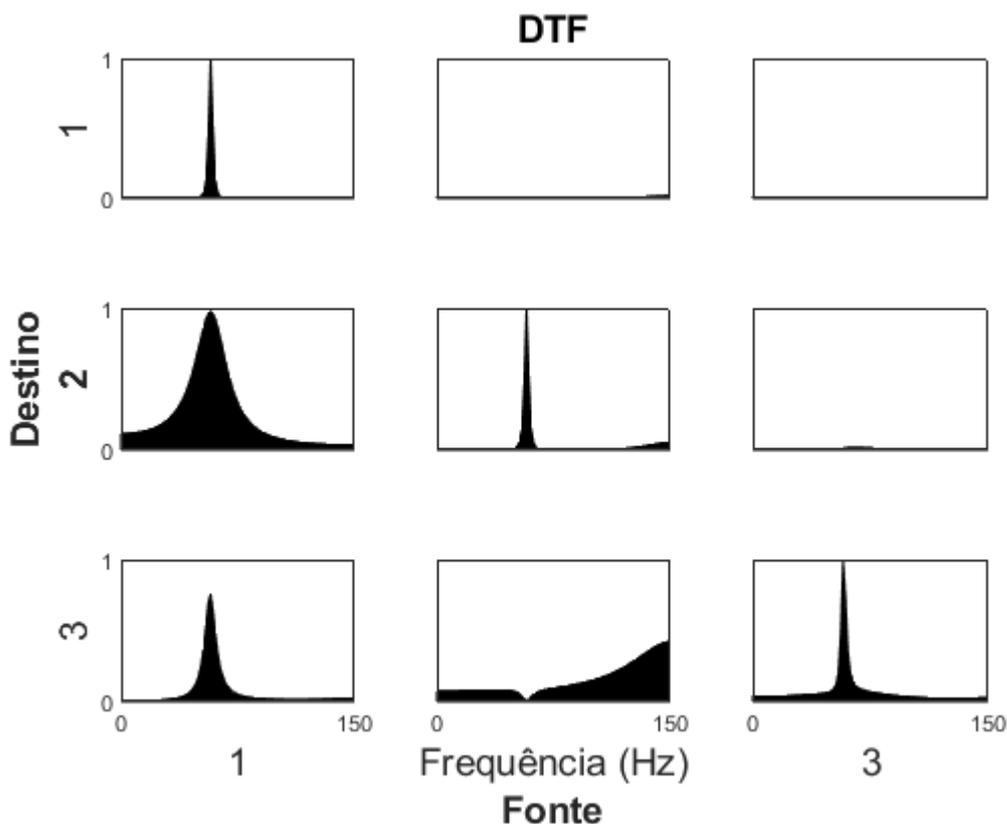


Figura 2.6 – Gráfico da DTF do caso da Figura 2.5. No eixo X, a frequência em Hz e no eixo Y, os valores normalizados da DTF, indicando o fluxo de informação. Nesse conjunto de gráficos as colunas representam as fontes e as linhas o destino do fluxo de informação. E na diagonal principal temos o auto espectro normalizado.

2.3.5 Coerência direcionada parcial (PDC)

O método da coerência direcionada parcial descrito por Baccalá e Sameshima (2001) se baseia na Casualidade de Granger e na generalização da coerência direcionada (DC, do inglês *Directed Coherence*) de Saito e Harashima (1981), e é dado como:

$$\pi_{ij}(f) = \frac{\bar{A}_{ij}(f)}{\sqrt{\sum_{k=1}^N \bar{A}_{kj}(f) \bar{A}_{kj}^*(f)}} \quad (10)$$

Onde, o sobescrito (*) é a transposição e o conjugado complexo e a_j é a j -ésima coluna da matriz:

$$\bar{A}(f) = I - A(f) = [\bar{a}_1(f) \bar{a}_2(f) \bar{a}_3(f) \dots \bar{a}_N(f)] \quad (11)$$

Sendo que $\bar{A}_{ij}(f)$ é o i do j -ésimo elemento de $\bar{A}(f)$, e

$$\bar{A}_{ij}(f) = \phi - \sum_{r=1}^p a_{ij}(r) e^{-2i\pi fr} \quad (12)$$

Sendo $\phi = 1$ quando $i = j$ e $\phi = 0$ caso contrário. A PDC possui valores no intervalo de 0 a 1. Sendo que um valor diferente de 0 indica que há uma alimentação direta, implicando que provavelmente existe uma conexão física e direta ativa entre as fontes (BACCALÁ; SAMESHIMA, 2001). Logo, a PDC determina a influência de uma fonte em relação a outra quando comparado as demais.

Enquanto a DTF é normalizada em relação à fonte que recebe o fluxo de informação, a PDC é normalizada em respeito a fonte que originou o sinal (BACCALÁ; SAMESHIMA, 2001).

Uma modificação da PDC, a gPDC (*generalized Partial Directed Coherence*) foi apresentada por Baccalá, Sameshima e Takahashi (2007) para resolver os problemas associados à não normalização das séries temporais, e é definido como:

$$\pi_{ij}^{(w)}(f) = \frac{\frac{1}{\sigma_i} \bar{A}_{ij}(f)}{\sqrt{\sum_{k=1}^N \frac{1}{\sigma_k^2} \bar{A}_{kj}(f) \bar{A}_{kj}^*(f)}} \quad (13)$$

Onde, σ_i^2 é a variância do processo de inovação.

A Figura 2.7 é o conjunto de gráficos resultantes da gPDC, do exemplo apresentado na Figura 2.5, e segue a mesma configuração da Figura 2.6. Pode-se perceber

que no caso da GPDC, diferentemente da DTF, são apenas apresentados os caminhos que representam a influência direta entre duas séries. Nesse caso, série 1 para 2, coluna 1 linha 2, e série 2 para 3, coluna 2 linha 3.

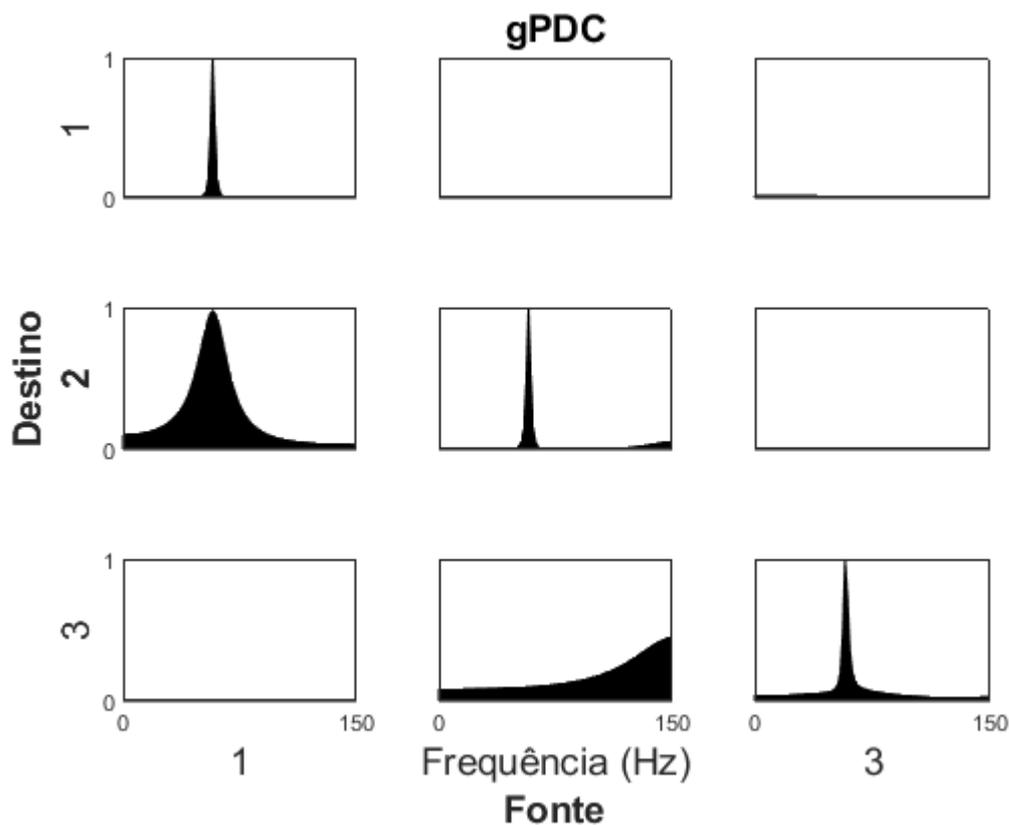


Figura 2.7 – Gráfico da gPDC do caso da Figura 2.5. No eixo X, a frequência em Hz e no eixo Y, os valores normalizados da gPDC, indicando o fluxo de informação. Nesse conjunto de gráficos as colunas representam as fontes e as linhas o destino do fluxo de informação. E na diagonal principal temos o auto espectro normalizado.

2.4 Artefatos

A presença de artefatos (seção 2.1.1) pode trazer diversos problemas para a análise dos sinais de EEG gerando interpretações errôneas, diminuindo assim a eficácia do ICM. Existem diversos métodos que são utilizados para tratar os artefatos, podendo ser *online* ou *offline*.

Pode-se também separar os métodos de processamento de artefatos em três principais abordagens: evitar, rejeitar e remover. A primeira delas consiste em pedir ao

voluntário que evite piscar ou se mover durante o experimento. A segunda delas é um conjunto de métodos de rejeição de segmentos do sinal a partir de inspeção visual, ou a partir de um limiar de rejeição, esse é um exemplo de método *offline*. Essa abordagem acaba por reduzir a quantidade de amostras podendo gerar complicações para a análise, principalmente para casos onde o número de amostras já é reduzido, ou casos cuja atividade estudada possui muitos artefatos (ALLISON, 2003; NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Um exemplo de método *online* de rejeição de segmentos feito a partir de um limiar é com base no desvio padrão. O limiar pode ser definido, dependendo da sua aplicação, como n vezes o desvio padrão de um sinal de EEG espontâneo (repouso) de t segundos de olhos abertos. Porém essa prática de rejeição de segmento causa uma perda momentânea do controle do sistema (NICOLAS-ALONSO; GOMEZ-GIL, 2012).

Outra abordagem mais complexa seria não rejeitar os segmentos, mas remover os artefatos do sinal. Alguns exemplos desses métodos envolvem técnicas como: análise de componentes independentes (ICA, do inglês *Independent Component Analysis*), análise de componentes principais (PCA, do inglês *Principal Component Analysis*), *Wavelets*, *Local Singular Spectrum Analysis* (AMABILE et al., 2008; BLANKERTZ et al., 2008; DELORME; MAKEIG; SEJNOWSKI, 2001; SHAO et al., 2009; URIGÜEN; GARCIA-ZAPIRAIN, 2015).

2.5 Redes neurais artificiais (RNA)

A classificação é um problema de construção de procedimentos para identificar à qual classe, pré-definida, a nova observação pertence, com base em um conjunto de atributos ou características. Pode ser entendido como um exemplo de reconhecimento de padrões, análise discriminante, ou de aprendizado supervisionado (MICHIE; SPIEGELHALTER; TAYLOR, 1994). Alguns exemplos de classificadores são: análise de discriminante linear (LDA, do inglês *Linear Discriminant Analysis*) (MARTINEZ; KAK, 2001), máquina de vetores de suporte (SVM, do inglês *Support Vector Machines*) (SUBASI; ISMAIL GURSOY, 2010), redes neurais artificiais (RNA) (KRIESEL, 2007).

As redes neurais artificiais (RNA) são modelos estatísticos que podem ser utilizados para reconhecimento de padrões, tendo como uma das principais vantagens a

criação de regiões de decisão não lineares (ENGELBRECHT, 2007; KRIESEL, 2007). Sendo que uma das suas características fundamentais é a capacidade de auto aprendizado, ou seja, a auto adaptação do sistema para diferentes dados através de uma sequência de procedimentos de treinamento. As RNA já foram aplicadas para a resolução de diversos problemas em áreas como otimização, *data mining*, reconhecimento de padrões (KRIESEL, 2007).

A RNA pode ser vista como um conjunto de células de processamento de informação, denominado neurônio artificial, que estão em uma rede onde as conexões entre as células possuem um peso, como apresentado na Figura 2.8.

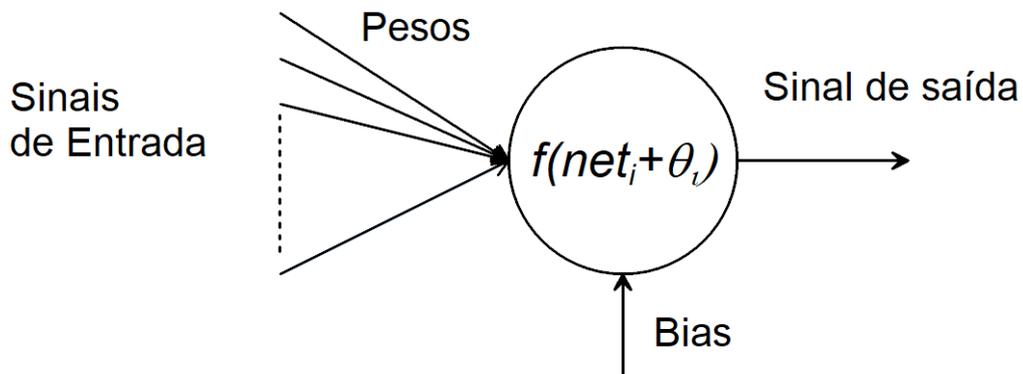


Figura 2.8 – Unidade elementar da RNA, neurônio artificial.

A modelagem desse sistema é dividida então em duas partes. A primeira, a função de propagação, é dado pela combinação linear das entradas com um peso para cada conexão, dado por:

$$net_j = \sum_{i=1}^N w_{ij}x_i \quad (14)$$

Onde x_i é a entrada e w_{ij} é o peso das conexões de entrada. Ou seja, cada neurônio i está influenciando o neurônio j através de uma conexão que é influenciado por um peso associado com o neurônio j .

A segunda parte corresponde ao estímulo mínimo necessário de ativação. A função correspondente a essa parte é dada por:

$$y_i = f(net_i + \theta_i) \quad (15)$$

Onde θ_i é o limiar mínimo para ativação, denominado bias.

A seguir são apresentados dois exemplos de funções de ativação, a função logística e a tangente hiperbólica respectivamente:

$$f(net) = \frac{1}{1+e^{-\lambda(\alpha-\theta)}} \quad (16)$$

$$f(net) = \frac{e^{\lambda(\alpha-\theta)} - e^{-\lambda(\alpha-\theta)}}{e^{\lambda(\alpha-\theta)} + e^{-\lambda(\alpha-\theta)}} \quad (17)$$

O outro parâmetro que caracteriza a RNA é a organização dos neurônios, ou seja, como eles são interligados, também conhecida como a topologia da rede. Essa organização está diretamente relacionada com o algoritmo de aprendizagem. A seguir serão apresentadas algumas das topologias, a direta e a recorrente.

Na topologia direta os neurônios são organizados em camadas, uma de entrada, n intermediárias, e uma de saída. Sendo que os neurônios estão conectados com os da camada anterior, ou à entrada caso seja a camada de entrada, e com a seguinte, ou à saída caso seja a última camada (ENGELBRECHT, 2007). A Figura 2.9 mostra um exemplo de uma RNA direta de três camadas.

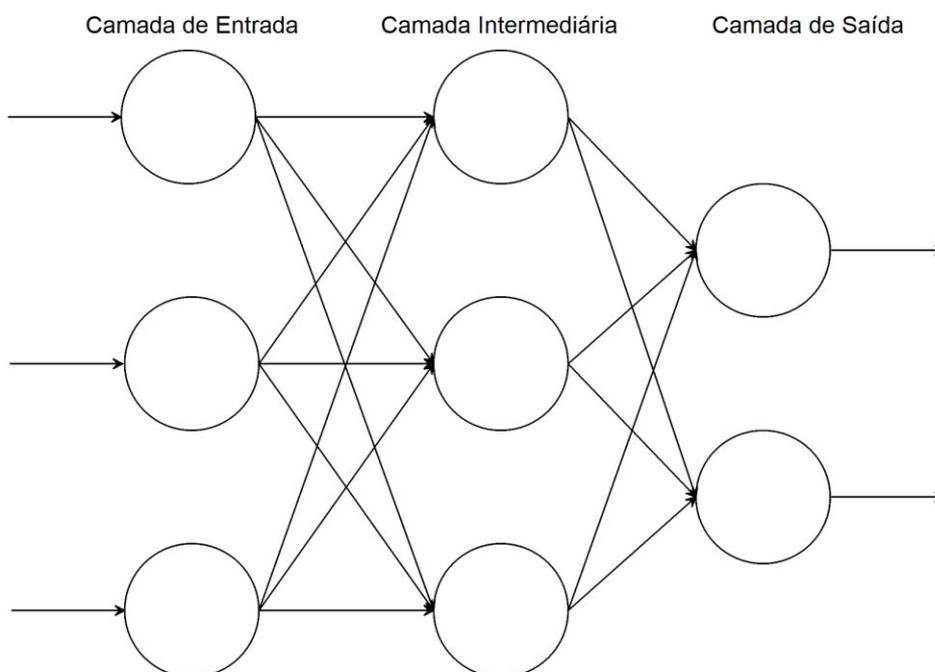


Figura 2.9 – Exemplo de uma RNA de topologia direta de três camadas.

Uma outra topologia é a recorrente, um sistema não linear e dinâmico que possui memória interna desse modo a rede consegue aprender características temporais (ENGELBRECHT, 2007). Essa topologia é feita por meio da realimentação de um neurônio com ele mesmo, de forma a reforçar ou inibir ele próprio. Um exemplo dessa rede é a rede de Jordan (KRIESEL, 2007).

A última característica de uma rede é o algoritmo de treinamento. Podendo ser definida como sendo um conjunto de algoritmos que a partir de um processo de estimulação consegue se adaptar, essa adaptação é feita a partir de modificações de parâmetros da rede. De acordo com Kriesel (2007) as seguintes modificações podem ser feitas:

- Criar conexões;
- Desfazer conexões;
- Ajustar os pesos das conexões;
- Modificar o limiar dos neurônios;
- Modificar as funções dos neurônios (exemplo: função de ativação);
- Criar neurônios;
- Desfazer neurônios.

A aprendizagem possui diferentes meios de ser abordado, sendo que nesse trabalho será apresentado a aprendizagem por correção de erro. Haykin (2007) descreve a existência de cinco abordagens básicas entre eles temos: correção de erro, baseada em memória, *hebbiana*, competitiva e de Boltzmann.

Uma das abordagens é a aprendizagem por correção de erro na qual a modificação é feita com base no sinal de erro, sendo que é feito o ajuste nos pesos conforme a seguinte equação (HAYKIN, 2007; KRIESEL, 2007):

$$w_{ij}(n + 1) = w_{ij}(n) + \Delta w_{ij}(n) \quad (18)$$

Onde $\Delta w_{ij}(n)$ é o ajuste com base no sinal de erro que depende do algoritmo empregado para o treinamento da rede.

Um dos tipos algoritmos de treinamento da rede é o supervisionado, que se baseia em conjuntos de pares de treinamento. Esse treinamento consiste em apresentar dados de saídas a rede que sejam as soluções desejadas para os dados de entrada que também são apresentadas a rede, sendo necessário um conhecimento sobre o sistema a ser trabalhado. A partir desses dados, são ajustados os pesos da rede conforme o sinal de erro, que é dado pela diferença entre o sinal desejado e o sinal real.

Um exemplo desses algoritmos é o *backpropagation*, dado pela equação a seguir (KRIESEL, 2007):

$$w_{ij}(n + 1) = w_{ij}(n) + \eta \left(-\frac{de}{dw} \right) \quad (19)$$

Onde η é a taxa de aprendizagem e $\frac{de}{dw}$ é o gradiente ou a derivada do erro em relação ao peso, sendo que o erro e é dado por:

$$e = \frac{1}{2} (d_j - y_j)^2 \quad (20)$$

Sendo d a saída desejada e y o valor real obtido pela rede.

3 Revisão da literatura

3.1 Imagética motora (IM)

Jeannerod (1994) definia imagética motora como uma habilidade de simular os movimentos do corpo sem produzir algum movimento. Desde essa definição até os tempos atuais, diversas pesquisas utilizando neuroimagem foram feitas tentando entender melhor esse conceito, que na época já não era novo. Grezes e Decety (2001) fizeram uma meta-análise de estudos em IM utilizando fMRI e PET, relatando de forma consistente uma sobreposição das atividades corticais e subcorticais de áreas motoras relacionadas à execução do movimento.

Outras pesquisas, como a de Hanakawa, Dimyan e Hallett (2008) mostraram que a atividade de imagética motora está mais associada com a etapa de pré-execução do movimento do que a própria execução do movimento em si.

A imagética motora é um processo cognitivo complexo que vem sendo usado em diversos casos de reabilitação como por exemplo em pacientes pós-AVE, que tiveram o seu sistema motor comprometido (FROLOV et al., 2017; PAZ, 2012). Uma vez que os estudos relatam que a prática mental, técnica de estratégia cognitiva baseado na repetição extensiva de tarefas de IM, pode afetar a plasticidade, a capacidade de reorganização do sistema nervoso, em diferentes níveis (ANG et al., 2015; CUNHA et al., 2017; DALY; WOLPAW, 2008; PAZ, 2012).

Outro exemplo da sua utilização em reabilitação é em pacientes que tiveram o membro amputado, buscando uma melhoria no controle da prótese. Trabalhos mostraram que a prática mental, em conjunto com outras técnicas de reabilitação, apresentaram resultados que justificam o seu uso, como por exemplo o melhor controle da prótese (CUNHA et al., 2017; PAZ, 2012). A IM tem sido também uma maneira de treinar os usuários a ter controle da ICM (CURRAN; STOKES, 2003; DALY; WOLPAW, 2008). E de acordo com Curran e Stokes (2003) diversos estudos em ICM utilizam a IM pois causam mudanças dos padrões dos sinais de EEG que se assemelham aos padrões que ocorrem no planejamento do movimento.

3.2 Interface cérebro-máquina

Um dos primeiros a utilizar o termo ICM foi Vidal (1977), na década de 1970, e utilizava o potencial relacionado a evento para o controle da ICM. No seu sistema, o voluntário observava quatro alvos vermelhos no formato de um diamante que era iluminado, cada um deles representando um comando, que era utilizado para que o usuário se movesse dentro de um labirinto gerado no computador. Essa ICM possuía uma fase de treinamento a qual era necessária para ter dados para treinar o classificador.

Os avanços da tecnologia permitiram trabalhos como os de Wolpaw et al. (1991) que utilizaram ritmos sensório-motor para o controle de um cursor numa tela. Esse sistema se diferenciava dos anteriores pois necessitava que o voluntário fizesse mudanças rápidas nos seus padrões de EEG, diferente dos trabalhos anteriores que era necessário que o usuário mantivesse os padrões durante um tempo prolongado.

Poucos anos depois, um grupo de Graz, Áustria, Kalcher et al. (1996) utilizando o sinal de EEG para controlar uma ICM, conseguiram discriminar três tarefas: mão direita; mão esquerda e; pé direito. Na qual os voluntários eram instruídos a fazer o movimento nas primeiras sessões e nas últimas eram instruídos a imaginar o movimento. Obtendo resultados de acurácia variados (próximos de 50%), chegando até 60%, utilizando o *Learning Vector Quantisation* para a classificação.

Em 1999, acontecia o primeiro encontro internacional de ICM, em New York, onde foram vistas as diferentes abordagens de cada grupo de pesquisas ao redor do mundo. Durante essa conferência foi discutido se a habilidade de controlar uma ICM deveria ser totalmente automatizada ou não, porém não chegaram a uma conclusão (CURRAN; STOKES, 2003).

As pesquisas com interface cérebro-máquina vêm ganhando popularidade pois estas têm se mostrado uma opção de melhorar a qualidade de vida de pessoas portadoras de limitações motoras, como por exemplo em pacientes pós-AVE (CHAUDHARY; BIRBAUMER; RAMOS-MURGUIALDAY, 2016; CURRAN; STOKES, 2003; DALY; WOLPAW, 2008; LEBEDEV; NICOLELIS, 2006; MONGE-PEREIRA et al., 2017).

De acordo com Daly e Wolpaw (2008), essa melhora pode ser feita de duas maneiras: a utilização de ICM como substituto, ou facilitador, da limitação motora; ou a utilização na reabilitação, podendo ajudar a restaurar funções motoras.

Um dos métodos não invasivos mais utilizados para medição de padrões no córtex cerebral em aplicações de ICM é a eletroencefalografia. Um dos motivos é a facilidade do seu uso e seu relativo baixo custo. Porém, a suscetibilidade a ruídos e a baixa resolução espacial devido ao volume condutor entre as fontes, são alguns dos principais problemas desse método (LEBEDEV; NICOLELIS, 2006; SANTOS FILHO et al., 2009).

O impacto da utilização de uma realimentação visual para o usuário para melhorar o controle da ICM ainda está sendo investigado (ZAPAŁA et al., 2018). Porém, resultados promissores da sua utilização em conjunto com técnicas terapêuticas já vem sendo apresentados (FROLOV et al., 2017).

3.3 Classificadores

O controle de uma ICM utilizando sinais de EEG se baseia no uso de algoritmos classificadores para identificar e executar os comandos. Devido à sua importância, uma revisão desses algoritmos para o seu uso em ICMs foi feita por Lotte et al. (2007). Alguns desses algoritmos de classificação que foram utilizados para sinais de EEG são: análise de discriminante linear (LDA, do inglês *Linear Discriminant Analysis*), máquina de vetores de suporte (SVM, do inglês *Support Vector Machine*), *common spatial patterns* (CSP) e redes neurais artificiais (RNA) (LOTTE; GUAN, 2011; SUBASI; ISMAIL GURSOY, 2010; YONG; MENON, 2015).

Entretanto os estudos de avaliação de algoritmos de classificação para o ICM como o trabalho feito por Lotte et al. (2007) são muitas vezes apenas avaliados em um sistema *offline* e sem utilizar como característica a conectividade cerebral. Uma nova revisão dos algoritmos classificadores foi feita por Lotte et al. (2018), onde ele aponta que ainda a maioria das pesquisas avaliam apenas em sistemas *offline*, mesmo que o foco atual esteja em classificadores que possam ser usados para sistemas *online*. Um dos algoritmos citados que pode ser utilizado em sistemas *online* é a RNA, sendo que o tipo mais utilizada para ICM é o *multilayer perceptron* (MLP) (LOTTE et al., 2007; NICOLAS-ALONSO; GOMEZ-GIL, 2012). Um dos motivos, dessa discrepância nas

pesquisas voltados para sistemas *offlines*, apontados McFarland e Wolpaw (2011) é que a maioria dessas pesquisas foi realizada utilizando os bancos de dados livres.

A utilização de um sistema para uma ICM *online* tem que levar em consideração diversos problemas que são de difícil avaliação em um sistema *offline*, como por exemplo, as interferências fisiológicas e do ambiente e a não estacionariedade (MCFARLAND; WOLPAW, 2011; NICOLAS-ALONSO; GOMEZ-GIL, 2012; SHENOY et al., 2006).

Uma solução que está sendo abordada para resolver os problemas de sistemas *online* é o uso de classificadores adaptativos, cujo parâmetros são atualizados *online*. Essa abordagem tem como função resolver o problema de não estacionariedade, assim como a limitação da quantidade de dados para treinamento. Outra solução para a limitação de dados é a transferência de aprendizagem (em inglês, *transfer learning*) (LOTTE et al., 2018; NICOLAS-ALONSO; GOMEZ-GIL, 2012; SHENOY et al., 2006).

3.4 Classificação de movimentos do mesmo membro

A classificação de tarefas de IM em diferentes membros é bastante estudada, obtendo resultados de acurácias acima de 80% (LOTTE et al., 2007). Alguns estudos obtiveram resultados acima de 90%, como é o caso de Wang et al (2006), que obteve uma acurácia de 96.13% para imaginação do movimento das mãos direita e esquerda utilizando LDA.

Porém, a classificação de diferentes tarefas de IM no mesmo membro ainda é um grande desafio, uma vez que as representações no córtex motor são muito próximas espacialmente. Por isso, diversos estudos com diferentes abordagens estão sendo feitos na classificação de tarefas motoras do mesmo membro (IBÁÑEZ et al., 2015; SHIMAN et al., 2017; YONG; MENON, 2015). Como por exemplo, no trabalho de Tavakolan et al (2017), eles tiveram uma acurácia de 74,2% utilizando *Support Vector Machine* (SVM) na classificação de três tarefas de IM, repouso, aperto de mão e movimento do cotovelo (do mesmo membro).

Os trabalhos de Silva (2016), Silva, Sá e Tierra-criollo (2014), Silveira, (2017) e Silveira et al. (2016) mostraram que as técnicas de estimação de conectividade, como a coerência direcional parcial (PDC, do inglês *partial directed coherence*) (BACCALÁ;

SAMESHIMA, 2001) e função de transferência direcionada (DTF, do inglês *directed transfer function*) (KAMINSKI; BLINOWSKA, 1991) conseguiram fazer a distinção dos diferentes movimentos do mesmo membro, flexão e extensão do cotovelo, obtendo uma acurácia média de 88.9% (SILVEIRA, 2017). Sendo promissoras para o seu uso em ICM.

3.5 Conectividade cerebral

A ideia de causalidade, como utilizada no estudo da conectividade, se iniciou com os trabalhos de Wiener (1956), que introduziu a ideia de que uma variável pode ser dita causal a uma segunda se a previsão dos valores da segunda variável melhora utilizando a informação da primeira, e de Granger (1969), que formalizou esse conceito de medição de causalidade utilizando a teoria de sistemas lineares.

Saito e Harashima (1981) introduziram a noção de uma coerência direcionada com um modelo bivariado, sendo que não foi possível estender para um modelo multivariado. Os trabalhos de Akaike (1968) e Lütkepohl (1993) foram de grande influência nos modelos multivariados de conectividade que foram descritos por Kaminski e Blinowska (1991) e Baccalá e Sameshima (2001).

Devido à importância desses estimadores para análise de conectividade, Bastos e Schoffelen (2016) fizeram um estudo de revisão e tutorial de diversas estimadores. Um trabalho de revisão mais extenso analisando 42 métodos distintos foi feito por Wang et al. (2014). Uma revisão com foco em métodos de conectividade direcionada para análise de multicanais foi feita por Blinowska (2011). Devido aos resultados da utilização da conectividade para o controle de ICM através de tarefas de IM, uma revisão foi feita por (HAMED; SALLEH; NOOR, 2016).

Os métodos de estimação de conectividade como a PDC e a DTF dependem em grande parte da estimação de modelos multivariados auto regressivos. Logo, dado a importância de encontrar modelos que melhor representem os dados, uma comparação de vários estimadores foi feita por Schlögl (2006). Nesse trabalho os algoritmos ARfit e Nuttal-Strand obtiveram resultados similares quando tinha um número de amostras suficiente. Porém, quando o número era limitado o Nuttal-Strand possuía resultados melhores.

4 Materiais e Métodos

Nesse capítulo se descrevem os procedimentos executados no presente trabalho. Inicialmente, detalha-se a análise preliminar realizada. E em seguida, como foi realizada a seleção dos voluntários e a preparação dos materiais para a parte experimental. Apresenta-se a metodologia para a coleta dos sinais para o treinamento *offline* e a validação *online*.

4.1 Análise preliminar

Antes de propor o protocolo experimental para a ICM *online* foi necessária uma análise preliminar, para a tomada de decisões. Maiores detalhes dessa análise podem ser encontrados no artigo no Apêndice A.

Para esta etapa utilizou-se o banco de dados de sinais de EEG de Lana, Adorno e Tierra-criollo (2013). Os sinais de EEG de seis voluntários foram coletados durante as tarefas de execução de flexão e extensão do cotovelo, com intervalos de períodos aleatórios (8-12s) entre as execuções, aprovado pelo Comitê de Ética em Pesquisa (COEP) da Universidade Federal de Minas Gerais (UFMG - N ETIC 467/08). Esses sinais foram adquiridos com uma frequência de amostragem de 600 Hz e filtro passa-banda de 0,1 a 100 Hz.

Avaliou-se o desempenho das técnicas de remoção e rejeição de artefatos na classificação do movimento de flexão e extensão do cotovelo. Primeiramente, utilizou-se os sinais sem filtragem, em seguida os sinais foram filtrados utilizando um filtro passa alta de 1 Hz e um passa baixa de 40 Hz, tipo *Butterworth* de segunda ordem e fase zero. Esses sinais foram segmentados utilizando o sinal de *trigger* do início da execução do movimento.

A técnica de rejeição elimina épocas com base em um limiar correspondente a três vezes o desvio padrão de 20 s de sinal de EEG (selecionado visualmente) considerada livre de artefatos (TIERRA-CRIOLLO, 2001).

A técnica de remoção de artefato (não elimina épocas) utiliza a análise de componente independentes (ICA – *Independent Component Analysis*). Sendo que a

remoção das componentes foi feita se o valor do quarto momento estatístico (kurtosis) estivesse fora de um intervalo de $\pm 1,64$ (BARBATI et al., 2004), uma vez que para uma distribuição gaussiana tem-se uma kurtosis de valor zero.

Utilizaram-se diferentes classificadores para a comparação entre as seguintes situações: o sinal sem a filtragem (EEG), com a filtragem de 1 a 40 Hz (Filtro Passa Faixa), com a rejeição de artefatos por limiar (Rejeição de Artefatos) e com a remoção (Remoção de Artefatos) de artefatos por ICA (Figura 4.1). Os classificadores utilizados foram: árvore de decisão, *random forest* e SVM.

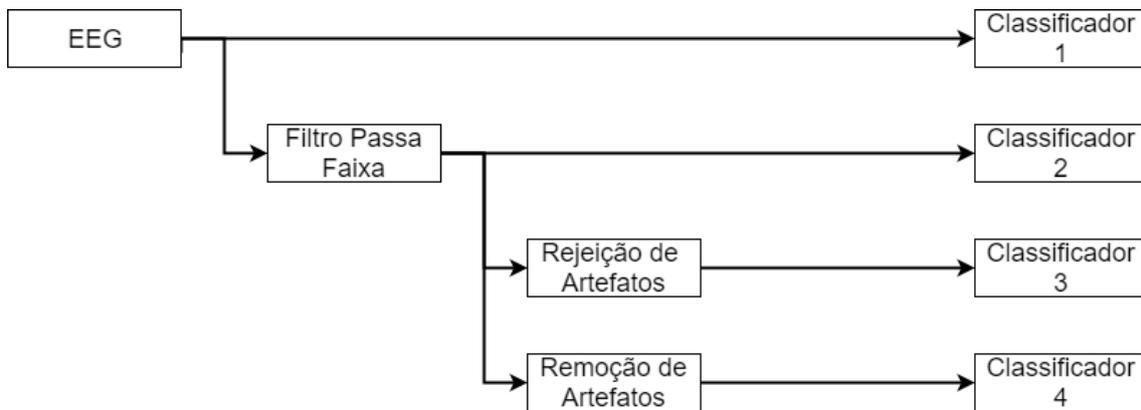


Figura 4.1 – Diagrama da comparação feita entre as diferentes situações.

Essa avaliação foi repetida utilizando como características a potência das bandas (Band Power), alfa (8-13 Hz), beta (13-30 Hz) e gama (30-40 Hz) (Figura 4.2).

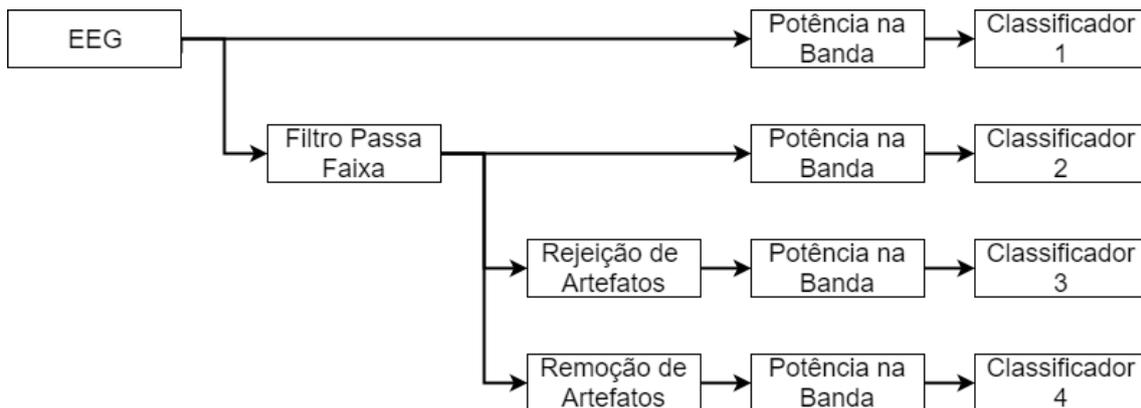


Figura 4.2 – Diagrama da comparação feita entre as diferentes técnicas, utilizando extração de características.

Essa avaliação de técnicas de rejeição e remoção de artefatos resultou em um artigo publicado (KAUATI-SAITO et al., 2019). Os melhores resultados, sem a extração

de característica, foram obtidos quando o sinal foi apenas filtrado, utilizando o *random forest* e o SVM (48,33% e 50,01%) ou quando os artefatos foram removidos (48,41% e 50,12%). Mais detalhes e resultados estão apresentados no artigo. No Apêndice A se encontra o *abstract* do artigo.

A partir dos resultados obtidos, não foi identificada a necessidade de se usar nenhuma das técnicas testadas de remoção e rejeição de artefato, sendo então utilizada apenas a filtragem passa faixa. Uma das hipóteses para este achado é a diminuição na quantidade de dados para a classificação quando é feita a rejeição de artefatos. No caso da remoção de artefatos, informação necessária para a classificação pode também ter sido removida.

De acordo com Blinowska (2011), os filtros espaciais alteram a correlação estrutural entre os sinais de EEG. Assim, os autores não recomendam seu uso para estimar a conectividade direcional. Outra recomendação dos mesmos autores, é que o sinal deve ser referenciado em relação a um canal que não faz parte da estimação do modelo. Portanto, neste trabalho não foi aplicada a filtragem espacial.

4.2 Participantes

O experimento para treinamento e validação do sistema *online* foi realizado no Laboratório de Processamento de Sinais e Imagens Médicas (LAPIS) do Programa de Engenharia Biomédica (PEB) do Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia (Coppe) da Universidade Federal do Rio de Janeiro (UFRJ), aprovado pelo Comitê de Ética em Pesquisa (CEP) do Hospital Universitário Clementino Fraga Filho (HUCFF/UFRJ) sob o Certificado de Apresentação para Apreciação Ética (CAEE) 01143318.6.0000.5257, 13/12/2018.

Para a coleta de dados, foram escolhidos quatro voluntários saudáveis, com idade de 26 a 30 anos. Esses voluntários não estavam sob a influência de fármacos que poderiam de alguma forma alterar os registros de EEG. Os indivíduos foram colocados em uma sala com iluminação e temperatura controlada, de modo a diminuir qualquer interferência com o sinal de EEG obtido no experimento.

Foi pedido para os voluntários o preenchimento do questionário para avaliação da capacidade imaginativa, MIQ-RV (*Movement Imagery Questionnaire-Revised*), encontra-se no ANEXO A. Esse questionário foi utilizado como critério de exclusão (score < 15). Solicitou-se também o preenchimento do teste de lateralidade manual, com base no inventário de Edinburgh (ANEXO B).

4.3 Montagem do experimento

A montagem do experimento foi feita com base na descrição no trabalho do Silveira (2017). O braço robótico (Figura 4.3) *AX18 Smart Robot Arm (Crust Crawler Robotics, Arizona, EUA)*, detalhes do robô no ANEXO C, foi fixado em uma plataforma de madeira de 30x30 cm (Figura 4.4). A plataforma foi apoiada em dois suportes de ferro que se conectam a trilhos presos à parede, estes trilhos permitem modificar a configuração da altura de modo a melhor se adequar à altura do voluntário.



Figura 4.3 – Foto do braço robótico.

A cadeira por sua vez foi posicionada de modo que a distância seja de 120 cm, o que corresponde ao dobro do comprimento do braço, evitando a colisão com o voluntário.

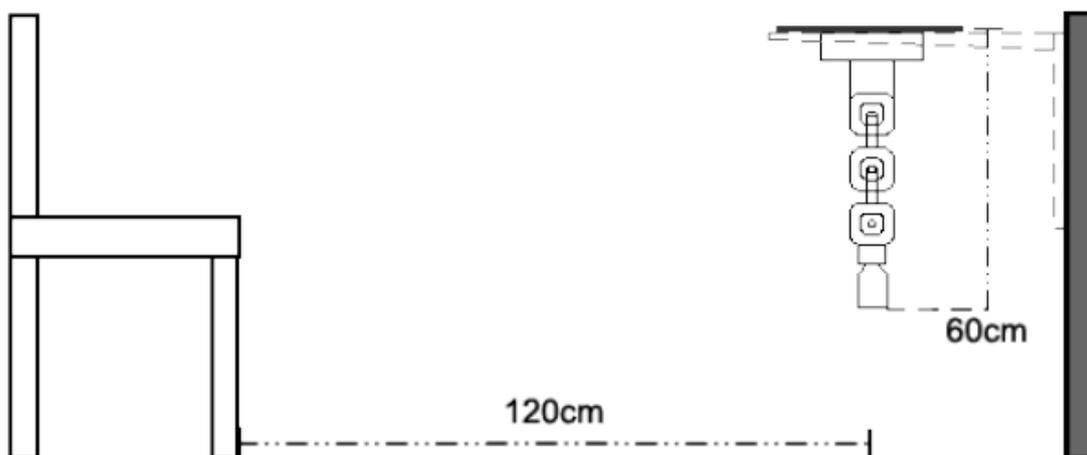


Figura 4.4 – Representação do experimento (SILVA; SÁ; TIERRA-CRIOLLO, 2014).

4.3.1 Sistema de aquisição

O sistema de aquisição (Figura 4.5) utilizado foi desenvolvido no Laboratório de Processamento de Sinais e Imagens (LAPIS) do Programa de Engenharia Biomédica (PEB) da Universidade Federal do Rio de Janeiro (UFRJ).

O sistema possui uma placa de aquisição que atualmente utiliza dois Conversores Analógico-Digital ADS1299 (Texas Instruments) que possuem uma resolução de 24 bits, e possibilitam o uso de 16 canais de aquisição com configuração monopolar ou bipolar, e uma frequência de amostragem de até 16 kHz (CEVALLOS-LARREA et al., 2015).



Figura 4.5 – Sistema de aquisição.

O módulo de controle e comunicação do sistema teve seu *firmware* programado na linguagem C++ e implementado no DSP STM32F407VG (*STMicroelectronics*). Os comandos do módulo de interface com o usuário são transmitidos via *ethernet* utilizando o protocolo UDP (CEVALLOS-LARREA et al., 2015).

O sistema de aquisição do sinal do acelerômetro e controle dos avisos luminosos, *trigger*, nomeada módulo híbrido, foi implementado com um STM32F4DISCOVERY que possui o microcontrolador STM32F407VG (*STMicroelectronics*, França - Itália) e o módulo de comunicação, STM32F4DIS-BB da mesma empresa.

4.3.2 Eletroencefalograma

Os sinais de EEG dos voluntários foram registrados a partir da utilização de uma touca com eletrodos (Figura 4.6) posicionados conforme o sistema 10-10. A Figura 4.7 mostra a localização das derivações utilizadas (F3, Fz, F4, FC3, FCZ, FC4, C3, C4, P3, Pz, P4) com referência em Cz. A terra (GND) foi posicionada na testa do voluntário. Além disso, foi registrado o sinal da electrooculografia (EOG). Os sinais foram digitalizados com uma frequência de amostragem de 2 kHz. A impedância máxima pele-eletrodo aceita foi de 10 kOhms.



Figura 4.6 – Touca de eletrodos para aquisição do sinal de EEG.

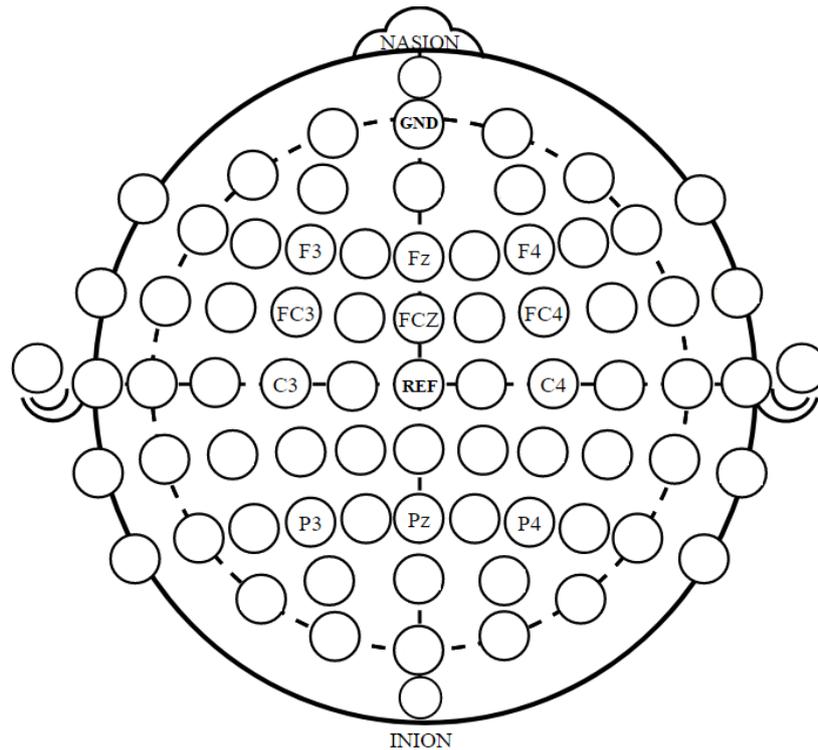


Figura 4.7 – Derivações utilizados na coleta.

4.4 Treinamento *offline*

O treinamento *offline* consistiu na etapa de aquisição de sinais de EEG durante a tarefa de treinamento, no pré-processamento dos sinais, a conectividade e a extração de características e treinamento do classificador.

4.4.1 O sistema de coleta para o treinamento

A interface de comunicação entre o computador e o manipulador robótico foi desenvolvida utilizando o software *MATLAB* (*MathWorks*, EUA), por meio de bibliotecas fornecidas pela fabricante do manipulador.

A comunicação entre os sistemas foi feita por meio de um adaptador RS-232 /USB. Utilizou-se uma porta COM configurada a partir de funções já implementadas anteriormente no *MATLAB* (ULLOA, 2013).

A Figura 4.8 mostra o diagrama de blocos conceitual do sistema. O módulo híbrido (Figura 4.9) faz a aquisição do sinal do acelerômetro, envia um sinal de

sincronismo para o sistema de aquisição do sinal de EEG e um sinal para ativação do LED (*Ligth-Emitting Diode*), além disso controla os comandos do braço robótico.

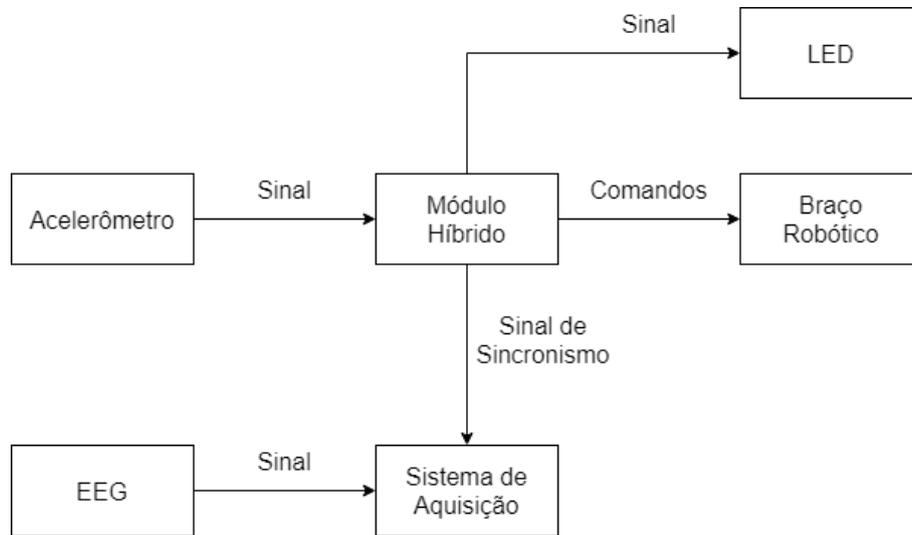


Figura 4.8 – Funcionamento do sistema de coletas

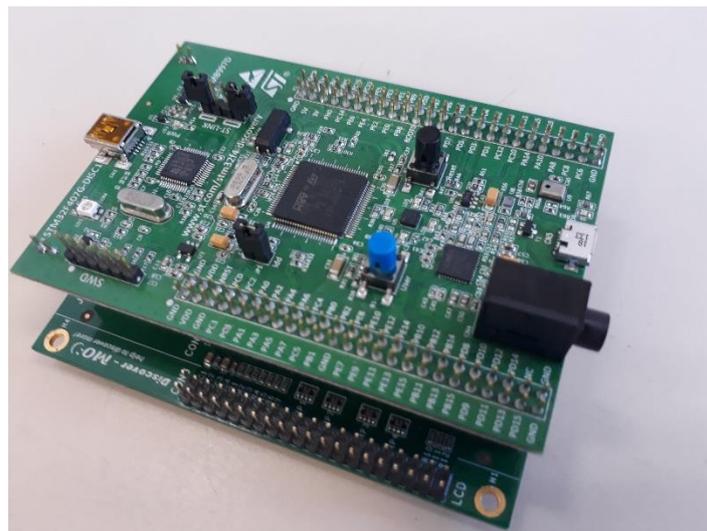


Figura 4.9 – Módulo híbrido.

4.4.2 Protocolo experimental para o treinamento

Na primeira etapa, os voluntários foram instruídos a realizar o movimento de flexão e extensão do cotovelo (vinte e cinco vezes), acompanhando o tempo de movimentação do braço robótico. Essa etapa tem como objetivo a familiarização do voluntário com o sistema e com a velocidade do robô. Posicionou-se um acelerômetro no

braço do voluntário para sincronizar o início do movimento com o sinal de EEG. Os sinais também foram amostrados a 2 kHz e serão analisados em trabalhos futuros.

Em seguida, os voluntários foram instruídos a imaginar a movimentação (imagética cinestésica) quando um aviso visual se ativasse (LED), acompanhando a velocidade do movimento do robô, mantendo o braço imóvel. Esta etapa tem como objetivo levantar os parâmetros para o treinamento do sistema de classificação.

A sequência de movimentos do robô é apresentada a seguir (Figura 4.10):

- a) Aviso visual (LED) de atenção, tempo aleatório de 2 a 4 segundos;
- b) Execução do movimento de flexão, tempo de 1 segundo;
- c) Intervalo aleatório de 8 a 12 segundos sem movimento;
- d) Aviso visual (LED) de atenção, tempo aleatório de 2 a 4 segundos;
- e) Execução do movimento de extensão, tempo de 1 segundo;
- f) Intervalo aleatório de 8 a 12 segundos sem movimento;

Essa sequência foi repetida 50 vezes para cada movimento, feito em dois dias diferentes.

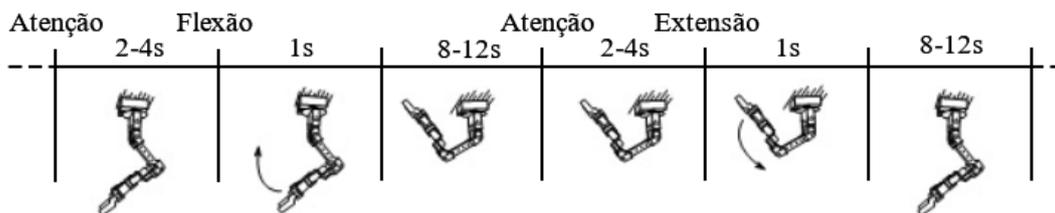


Figura 4.10 – Sequência de movimentos realizada pelo robô durante a tarefa experimental.

4.4.3 Pré-processamento offline

O processamento dos sinais foi realizado utilizando-se o programa *MATLAB*. Os sinais de EEG foram filtrados com um passa-alta de 0,5 Hz e passa baixa de 40 Hz, do tipo *Butterworth* de segunda ordem de fase zero (direta e inversamente). Não foi utilizado um filtro *notch* para rejeitar o artefato da rede elétrica de 60 Hz.

Os sinais de EEG foram segmentados em épocas, sincronizadas com o sinal do LED (*trigger*). O tamanho das épocas foi escolhido a partir dos resultados obtidos da comparação do desempenho do classificador (3 classes: flexão, extensão e repouso) com RNA. Três tamanhos foram avaliados: (a) de 4 segundos, 1 segundo antes do aviso visual até 3 segundos depois (-1 a 3 s); (b) de 2 segundos (0 a 2 s); (c) de 1,5 segundos (0 a 1,5 s). As épocas da classe repouso, consideradas sem atividade relacionado à IM, foram selecionadas 4 s depois do *trigger*.

Maiores detalhes de como foi feita essa avaliação encontram-se no Apêndice B. A partir dos resultados obtidos, escolheu-se épocas de 1,5 segundos, devido à pouca diferença entre os resultados e de que a tarefa de IM demora 1 segundo mais o tempo de reação do voluntário.

4.4.4 Conectividade cerebral

A técnica da gPDC (2.3.5) foi utilizada para estimar a conectividade cerebral. O modelo MVAR, para cada época, foi obtido empregando-se o algoritmo ARfit (SCHNEIDER; NEUMAIER, 2001; SILVEIRA, 2017) - que utiliza o método dos mínimos quadrados com passos variáveis - com os seguinte parâmetros:

- g) Ordem mínima da estimação: 1;
- h) Ordem máxima da estimação: 40;
- i) Critério para seleção da ordem: SBC (*Schwarz's Bayesian Criterion*);
- j) Frequência máxima de 40 Hz;
- k) 40 componentes de frequência.

O resultado desta estimação fornece matrizes de dimensões $11 \times 11 \times 40 \times 50$ para cada classe. Onde 11 é o número de canais que foi usado, 40 é o número de componentes de frequência e 50 é o número de época.

A estimação da conectividade cerebral foi feita utilizando a biblioteca proporcionada por Omidvarnia et al. (2014) no site da *Mathworks*.

4.4.5 Extração de características e classificação

Na etapa de classificação utilizou-se como variáveis, os resultados de todos os caminhos de fluxo de informação que foram estimados (11x11), com exceção do auto espectro de potência (11).

De modo a diminuir o número de características para o classificador, foram utilizados três parâmetros da função de conectividade:

- a) Média;
- b) Desvio padrão;
- c) Centroide espectral.

Assim sendo, o número total de características, para cada voluntário foi igual a 330, os 3 parâmetros da conectividade para cada um dos 110 caminhos ($11 \times 11 - 11$).

Na Figura 4.11 apresenta-se as etapas do processamento *offline* que precedem a classificação.

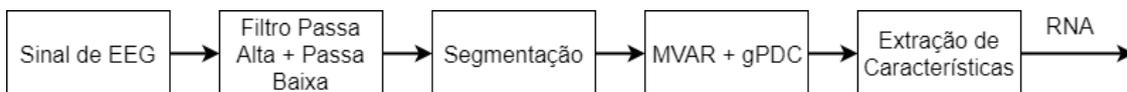


Figura 4.11 – Etapas do processamento *offline*.

O classificador foi implementado para reconhecer três classes:

- a) Imaginação da flexão do cotovelo;
- b) Imaginação da extensão do cotovelo;
- c) Repouso.

As entradas da rede neural artificial (RNA) foram normalizadas de -1 e +1, e foram removidas as linhas com valores constantes.

A rede neural artificial empregada possui topologia direta de múltiplas camadas, utilizou-se a função de treinamento *Scaled Conjugate Gradient* (MØLLER, 1993), que é um treinamento supervisionado, a função de ativação foi a função logística e a performance desejada de 0,01 (erro máximo). A função de treinamento e os parâmetros apresentados acima foram escolhidos após vários testes.

A estrutura lógica utilizada para o treinamento e escolha da rede é representada como um fluxograma na Figura 4.12. Inicialmente é necessário à randomização do *seed* de modo a dividir de maneira aleatória os grupos de treinamento, validação e teste. Os dados foram divididos seguindo a seguinte proporção: 70% para treinamento, 10% para validação e 20% para testes. Em seguida, é feito à randomização do *seed* para a criação e configuração das redes, de modo a modificar os valores iniciais.

No total realizou-se, 10 diferentes combinações de conjuntos de dados, de 1 até 150 neurônios na camada intermediária e repetidas 100 vezes para cada neurônio.

A rede que teve a melhor performance no grupo de teste foi a escolhida. Essa lógica foi repetida para cada voluntário.

As três características (média, desvio padrão e centroide) propostas no presente trabalho foram comparadas com as utilizadas (média, desvio padrão, valor RMS, máximo e mínimo) no trabalho de Silveira (2017). O banco de dados de sinais de EEG (LANA; ADORNO; TIERRA-CRIOLLO, 2013) também foi utilizado.

A performance destas características foi obtida para as bandas alfa, beta e na faixa de 1 a 40 Hz. A rede que teve a melhor performance no grupo de teste foi a escolhida. Essa lógica foi repetida para cada voluntário.

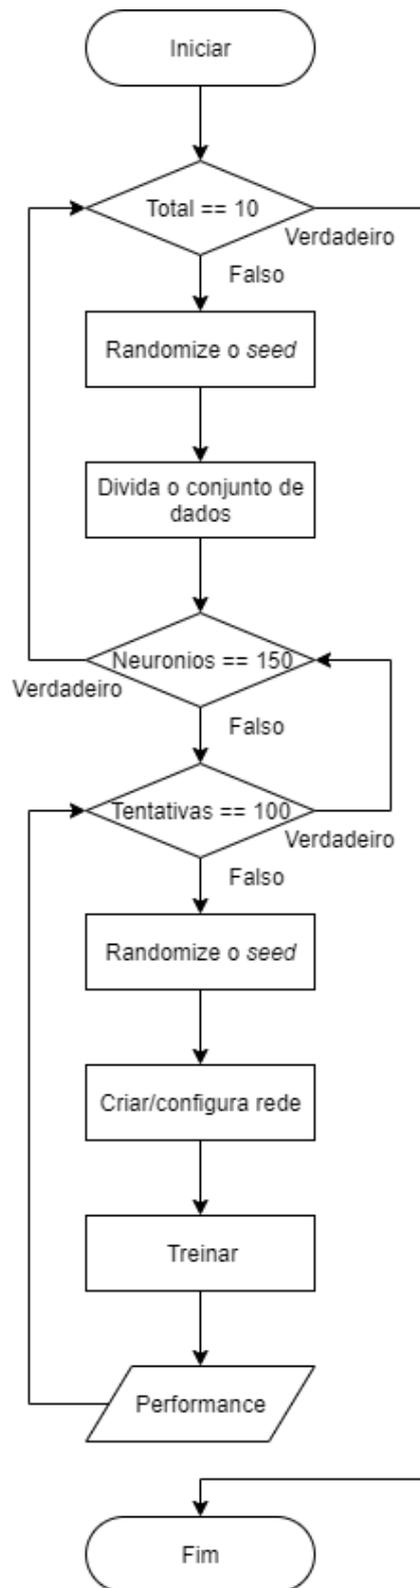


Figura 4.12 – Fluxograma que representa a lógica utilizada para o treinamento e escolha da RNA

4.5 Validação do sistema *online*

A segunda etapa da tarefa experimental, realizada em outro dia, foi a validação do sistema *online*. Para esta etapa se utilizou dois avisos visuais utilizando LEDs, um verde, para indicar a atenção de duração igual a primeira etapa (2-4 segundos aleatoriamente) e outro vermelho, para indicar a execução da imaginação, de duração igual ao do tempo de execução do movimento (1 segundo).

Quando o resultado do classificador era igual à imaginação desejada (flexão ou extensão), o braço robótico realizava o movimento e o LED de atenção (verde) se acendia, indicando assim o sucesso. No caso de falha, o braço robótico realizava o movimento 3 segundos depois do início da imaginação, de modo a ficar na posição inicial para a próxima imaginação (movimento contrário), sem o LED de atenção acender, indicando que não teve sucesso.

Antes de iniciar a atividade, foi apresentado aos voluntários um conjunto de movimentos de flexão e extensão realizados pelo braço robótico, sendo solicitado que acompanhassem o movimento com o próprio braço prestando atenção ao movimento, de modo a lembrar a velocidade.

O sistema *online* segue a seguinte estrutura (Figura 4.13): primeiramente a coleta de uma janela de sinal de EEG do usuário de 1,5 segundos, em seguida, o pré-processamento deste sinal (filtragem de 0,5 a 40 Hz), a estimação da conectividade e a extração das características, e por último o sistema classificador gera um comando para o robô.



Figura 4.13 – Estrutura do sistema *online*.

Na Figura 4.14 apresenta-se a comunicação do sistema *online*. O sistema de aquisição, implementada no *LabVIEW* (*National Instruments*, EUA) por meio da comunicação TCP/IP envia para o *MATLAB* uma janela do sinal de EEG já filtrado. Onde é feito o processamento, estimação da conectividade, extração de característica e

classificação. Além disso, codifica-se o resultado para enviar um comando ao módulo híbrido via TCP/IP. O módulo híbrido, implementado também no *LabVIEW*, recebe o comando e controla o braço robótico por meio de funções no *MATLAB* via comunicação serial RS-232.

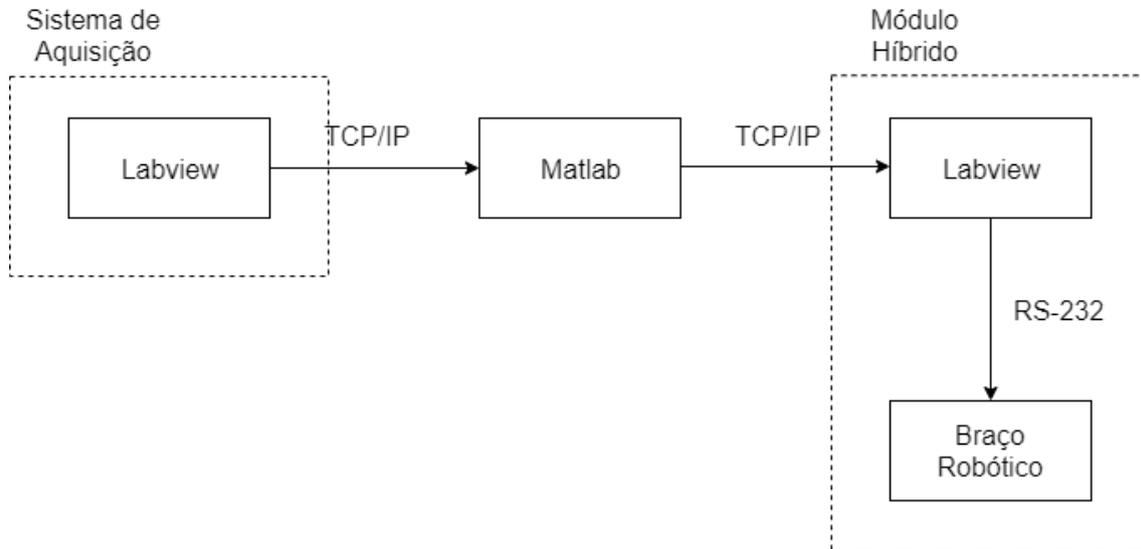


Figura 4.14 – Comunicação entre as partes do sistema online.

5 Resultados

Os resultados da análise preliminar (seção 4.1) mostraram que a rejeição ou remoção de artefatos não influenciaram a classificação o suficiente para justificar o seu uso, apenas uma filtragem na banda de interesse foi necessária. Maiores detalhes desta análise podem ser encontrados no artigo do Apêndice A.

Na continuação, se apresentam os resultados da comparação das características, do treinamento *offline* e da validação do sistema *online*.

5.1 Comparação das características

As cinco características utilizadas em Silveira (2017) - médias, desvio padrão, valor RMS, valor máximo e valor mínimo - nas bandas alpha (**Alpha 1**) e beta (**Beta 1**) foram comparadas com as três características propostas nesse trabalho - média, desvio padrão e centroide espectral - nas mesmas bandas (**Alpha 2** e **Beta 2**, respectivamente) e na faixa de frequência de 0,5 a 40 Hz (**Todos**). Na comparação se utilizou os dados do voluntário #2 e de seis voluntários (S1-S6) do banco de dados de sinais de EEG (seção 4.4.5).

Os resultados dessa comparação para o voluntário #2 são apresentados na Tabela 1. Nessa tabela, pode-se observar que na maioria das vezes a utilização das três características apresenta resultado próximo ou superior ao de cinco características. No caso da utilização de toda a banda de frequência obteve um resultado melhor ou igual ao da utilização da banda alpha, porém teve um resultado inferior ao da banda beta.

Tabela 1 – Resultado da comparação das características para o voluntário #2.

Característica / Medida	Alpha 1	Beta 1	Alpha 2	Beta 2	Todos
Valor Máximo (%)	83,33	90,00	86,67	90,00	86,67
Média (%)	38,30	49,86	43,50	48,40	44,17
Desvio Padrão (%)	16,58	19,81	18,79	19,52	17,99

A Tabela 2 apresenta os resultados de valores máximos para os seis voluntários do banco de dados. Assim como o resultado anterior, a utilização das três características, em geral, parece ter uma melhora a acurácia da classificação. Além disso, quando usada toda a faixa de frequência (**Todos**) teve melhor desempenho, exceto para o voluntário S3. Sendo que a acurácia está entre 78,57% e 93,75%.

Tabela 2 – Resultado da comparação (valor máximo) das características para seis voluntários do trabalho anterior.

Voluntário / Medida	Alpha 1	Beta 1	Alpha 2	Beta 2	Todos
S1 (%)	90,63	87,50	93,75	90,63	93,75
S2 (%)	83,33	85,71	80,95	85,71	85,71
S3 (%)	76,19	80,95	83,33	80,95	78,57
S4 (%)	78,57	80,95	83,33	80,95	85,71
S5 (%)	80,95	88,10	80,95	88,10	90,48
S6 (%)	78,57	78,57	80,95	80,95	90,48

5.2 Treinamento *offline*

Nessa etapa foram utilizados somente sinais de EEG de dois participantes devido a problemas na aquisição nos outros dois participantes.

A seguir os resultados obtidos no treinamento dos classificadores (com três características) para os dois voluntários (#2 e #4). A Figura 5.1 e a Figura 5.2 mostram as matrizes de confusão da rede neural do grupo de treinamento e do grupo de teste, respectivamente, do voluntário #2. As classes são apresentadas na seguinte ordem:

1. Imaginação da flexão do cotovelo;
2. Imaginação da extensão do cotovelo;
3. Repouso.

Matriz de Confusão

Classes de Saída	1	2	3	90.9% 9.1%
	1	2	3	90.9% 9.1%
	4	2	33	84.6% 15.4%
	85.7% 14.3%	88.2% 11.8%	91.7% 8.3%	88.6% 11.4%
	1	2	3	
	Classes Alvo			

Figura 5.1 – Matriz de confusão do grupo de treinamento do classificador do voluntário #2. As classes são: IM flexão, IM extensão e repouso.

Na matriz de confusão utilizando o grupo de treinamento (Figura 5.1), cada linha (1,2 e 3) representa a classe de saída, ou a prevista, do classificador, enquanto a coluna (1,2 e 3) representa a classe alvo, ou a esperada como resposta. Em cada quadrado, apresenta-se o número de observações e a porcentagem em relação ao número total de observações (105). Na diagonal principal têm-se as observações que foram classificados de forma correta de cada classe (30/105 = 28,6%). Fora da diagonal mostra-se as observações que foram erroneamente classificadas.

A última coluna na direita (cinza) se observa a precisão (ou valor preditivo positivo) de cada classe, a razão dos resultados preditos corretamente de cada classe, com os resultados preditos totais da classe. Por exemplo para a classe 1 foi de 90,9% (30/33).

A última linha na base (cinza) é a sensibilidade (ou taxa de verdadeiros positivos) de cada classe, que representa a taxa de predição correta daquela classe para todas as observações daquela classe. Na classe 1, a sensibilidade foi de 85,7% (30/35). Finalmente, no último quadrado da diagonal (cinza escuro) têm-se o valor de acurácia total de 88,6% para o grupo de treinamento.

A acurácia total da RNA do grupo de teste (Figura 5.2) foi próximo (90,0%) ao do grupo anterior.

Os resultados de precisão do grupo de treinamento foram bem homogêneos entre as classes, ficando por volta dos 90%. Diferentemente do grupo de testes, onde a classe 2 (75,0%) e classe 1 (100,0%) tiveram resultados diferentes. Por outro lado, a sensibilidade da classe 1 foi menor no grupo de treinamento (85,7%), enquanto no grupo de teste (92,9%) foi maior.

Matriz de Confusão

Classes de Saída	1	13 43.3%	0 0.0%	0 0.0%	100% 0.0%
	2	1 3.3%	6 20.0%	1 3.3%	75.0% 25.0%
	3	0 0.0%	1 3.3%	8 26.7%	88.9% 11.1%
			92.9% 7.1%	85.7% 14.3%	88.9% 11.1%
		Classes Alvo			
		1	2	3	

Figura 5.2 – Matriz de confusão do grupo de teste do classificador do voluntário #2. As classes são: IM flexão, IM extensão e repouso.

A estrutura da rede neural correspondente aos resultados apresentados anteriormente possui 123 neurônios na camada escondida (*Hidden*), 3 na camada de saída (*Output*) e 330 (*Input*) entradas (Figura 5.3). Esta RNA foi utilizada para a validação *online* para o voluntário #2.

A Figura 5.4 e a Figura 5.5 mostram as matrizes de confusão da rede neural do grupo de treinamento e teste, respectivamente, do voluntário #4.

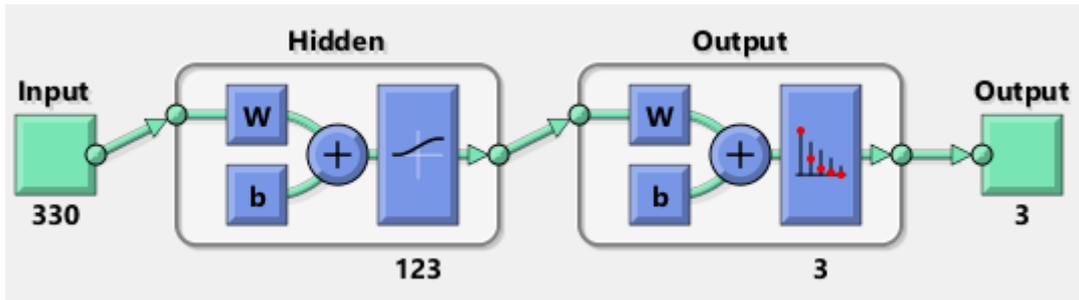


Figura 5.3 – Estrutura da RNA do voluntário #2.

Matriz de Confusão

Classes de Saída	1	30 28.6%	0 0.0%	2 1.9%	93.8% 6.3%
	2	5 4.8%	30 28.6%	8 7.6%	69.8% 30.2%
	3	2 1.9%	1 1.0%	27 25.7%	90.0% 10.0%
		81.1% 18.9%	96.8% 3.2%	73.0% 27.0%	82.9% 17.1%
		1	2	3	
		Classes Alvo			

Figura 5.4 – Matriz de confusão do grupo de treinamento do classificador do voluntário #4. As classes são: IM flexão, IM extensão e repouso.

Os resultados de acurácia, do voluntário #4, entre o grupo de treinamento (Figura 5.4) e de teste (Figura 5.5) foram próximos (82,9% e 80,0% respectivamente). Nas matrizes de confusão pode-se perceber a heterogeneidade dos resultados em ambos os grupos. Sendo que no grupo de treinamento, a precisão da classe 2 (69,8%) foi inferior as demais (90,0% e 93,8%). Porém a classe 2 teve a maior sensibilidade (96,8%) em relação as outras (81,1% e 73,0%). Esse mesmo padrão ocorre no grupo de teste, na qual a precisão da classe 2 (76,5%) é inferior em relação as demais (85,7% e 83,3%), porém a sensibilidade foi maior (92,9%).

Matriz de Confusão

Classes de Saída	1	6 20.0%	1 3.3%	0 0.0%	85.7% 14.3%
	2	1 3.3%	13 43.3%	3 10.0%	76.5% 23.5%
	3	1 3.3%	0 0.0%	5 16.7%	83.3% 16.7%
		75.0% 25.0%	92.9% 7.1%	62.5% 37.5%	80.0% 20.0%
		1 3.3%	2 6.7%	3 10.0%	
		Classes Alvo			

Figura 5.5 – Matriz de confusão do grupo de teste do classificador do voluntário #4. As classes são: IM flexão, IM extensão e repouso.

A RNA que gerou esses resultados é apresentada na Figura 5.6. Essa RNA possui 109 neurônios na camada escondida (*Hidden*), 3 na camada de saída (*Output*) e 330 (*Input*) entradas. Essa RNA será utilizada para a validação *online* do voluntário #4.

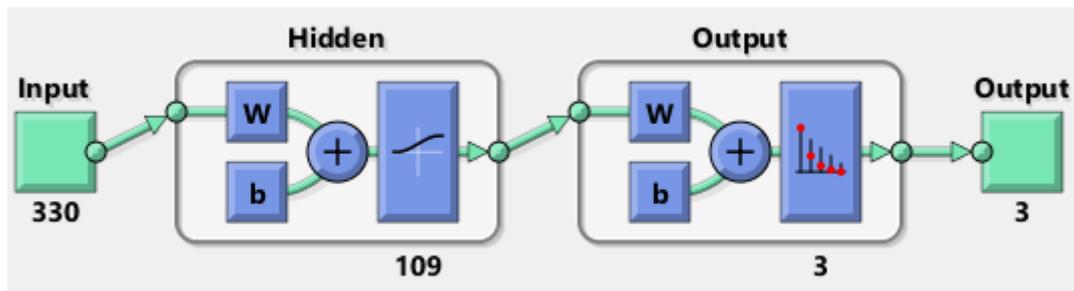


Figura 5.6 – Estrutura da RNA do voluntário #4.

5.3 Validação do sistema *online*

Nessa etapa é apresentado os resultados obtidos da validação do sistema *online*. Primeiro, apresenta-se o resultado de todas as quatro seções e em seguida, os resultados para cada sessão.

A Figura 5.7 apresenta o resultado geral da validação do voluntário #2. No total a acurácia foi de 39,1%, uma diferença grande quando comparado ao valor obtido no grupo de teste do treinamento *offline* (90,0%). A precisão entre as duas classes 1 e 2 se manteve homogêneo (57,9% e 50,0%). Enquanto a sensibilidade, mostrou uma diferença maior (10,0% e 68,2% respectivamente) entre essas classes. O classificador teve como saída a classe 3, 51 vezes, sendo que a validação teve zero observações de repouso, pois não se utilizou nenhum trecho em repouso.

Matriz de Confusão

Classes de Saída	1	11 5.0%	8 3.6%	0 0.0%	57.9% 42.1%
	2	75 34.1%	75 34.1%	0 0.0%	50.0% 50.0%
	3	24 10.9%	27 12.3%	0 0.0%	0.0% 100%
		10.0% 90.0%	68.2% 31.8%	NaN% NaN%	39.1% 60.9%
		↖	↘	↻	
		Classes Alvo			

Figura 5.7 – Resultado geral da validação do voluntário #2.

Na primeira sessão de validação (Figura 5.8) obteve-se zero acertos da classe de imaginação de flexão (classe 1) e 48,7% de precisão da classe 2 com 76,0% de sensibilidade, sendo acurácia de 38,0%.

Na segunda sessão de validação (Figura 5.9), em geral os parâmetros aumentaram. Enquanto a precisão da classe 1 foi a mais alta (75,0%), a sensibilidade foi a mais baixa (8,6%). Por outro lado, na classe 2, a precisão foi (52,0%) menor quando comparado com a sensibilidade (74,3%). A acurácia foi de 41,4%.

Matriz de Confusão

Classes de Saída	1	0 0.0%	1 2.0%	0 0.0%	0.0% 100%
	2	20 40.0%	19 38.0%	0 0.0%	48.7% 51.3%
	3	5 10.0%	5 10.0%	0 0.0%	0.0% 100%
		0.0% 100%	76.0% 24.0%	NaN% NaN%	38.0% 62.0%
		1	2	3	
		Classes Alvo			

Figura 5.8 – Resultado da primeira validação do voluntário #2.

Matriz de Confusão

Classes de Saída	1	3 4.3%	1 1.4%	0 0.0%	75.0% 25.0%
	2	24 34.3%	26 37.1%	0 0.0%	52.0% 48.0%
	3	8 11.4%	8 11.4%	0 0.0%	0.0% 100%
		8.6% 91.4%	74.3% 25.7%	NaN% NaN%	41.4% 58.6%
		1	2	3	
		Classes Alvo			

Figura 5.9 – Resultado da segunda validação do voluntário #2.

Matriz de Confusão

Classes de Saída	1	6 12.0%	1 2.0%	0 0.0%	85.7% 14.3%
	2	14 28.0%	18 36.0%	0 0.0%	56.3% 43.8%
	3	5 10.0%	6 12.0%	0 0.0%	0.0% 100%
		24.0% 76.0%	72.0% 28.0%	NaN% NaN%	48.0% 52.0%
		1	2	3	
		Classes Alvo			

Figura 5.10 – Resultado da terceira validação do voluntário #2.

Matriz de Confusão

Classes de Saída	1	2 4.0%	5 10.0%	0 0.0%	28.6% 71.4%
	2	17 34.0%	12 24.0%	0 0.0%	41.4% 58.6%
	3	6 12.0%	8 16.0%	0 0.0%	0.0% 100%
		8.0% 92.0%	48.0% 52.0%	NaN% NaN%	28.0% 72.0%
		1	2	3	
		Classes Alvo			

Figura 5.11 – Resultado da quarta validação do voluntário #2.

Na terceira sessão de validação (Figura 5.10), houve uma melhora na sensibilidade da classe 1 (24,0%), e em todos os outros parâmetros teve uma pequena melhora. Tanto a precisão (56,3%) quanto a sensibilidade (72,0%) da classe 2 se mantiveram próximo da segunda validação. Houve uma melhora na acurácia (48,0%).

O resultado da quarta sessão de validação (Figura 5.11) foi o pior em relação a acurácia (28,0%). Tendo uma sensibilidade na classe 1 muito baixa (8,0%). Tanto a sensibilidade (48,0%) quanto a precisão (41,4%) da classe 2 tiveram uma queda considerável comparado as validações anteriores.

Matriz de Confusão

Classes de Saída	1	38 19.0%	32 16.0%	0 0.0%	54.3% 45.7%
	2	31 15.5%	42 21.0%	0 0.0%	57.5% 42.5%
	3	31 15.5%	26 13.0%	0 0.0%	0.0% 100%
		38.0% 62.0%	42.0% 58.0%	NaN% NaN%	40.0% 60.0%
		1	2	3	
		Classes Alvo			

Figura 5.12 – Resultado geral da validação do voluntário #4.

A Figura 5.12 apresenta o resultado geral da validação do voluntário #4. Teve um resultado de acurácia total de 40%, e resultados de valores de precisão inferiores a 60% (54,3% e 57,5%) nas classes 1 e 2. Apresenta ainda resultados de sensibilidade inferiores a 50% (38,0% e 42,0%).

A primeira sessão de validação (Figura 5.13), teve os piores resultados de acurácia (20,0%) nesse voluntário, sensibilidade inferiores a 25% (24,0% e 16,0%) e precisão de 46,2% e 33,3%.

Matriz de Confusão

Classes de Saída	1	6 12.0%	7 14.0%	0 0.0%	46.2% 53.8%
	2	8 16.0%	4 8.0%	0 0.0%	33.3% 66.7%
	3	11 22.0%	14 28.0%	0 0.0%	0.0% 100%
		24.0% 76.0%	16.0% 84.0%	NaN% NaN%	20.0% 80.0%
		1	2	3	
		Classes Alvo			

Figura 5.13 – Resultado da primeira validação do voluntário #4.

Matriz de Confusão

Classes de Saída	1	12 24.0%	11 22.0%	0 0.0%	52.2% 47.8%
	2	5 10.0%	9 18.0%	0 0.0%	64.3% 35.7%
	3	8 16.0%	5 10.0%	0 0.0%	0.0% 100%
		48.0% 52.0%	36.0% 64.0%	NaN% NaN%	42.0% 58.0%
		1	2	3	
		Classes Alvo			

Figura 5.14 – Resultado da segunda validação do voluntário #4.

Matriz de Confusão

Classes de Saída	1	5 10.0%	6 12.0%	0 0.0%	45.5% 54.5%
	2	13 26.0%	15 30.0%	0 0.0%	53.6% 46.4%
	3	7 14.0%	4 8.0%	0 0.0%	0.0% 100%
		20.0% 80.0%	60.0% 40.0%	NaN% NaN%	40.0% 60.0%
		1 2 3	Classes Alvo		

Figura 5.15 – Resultado da terceira validação do voluntário #4.

Matriz de Confusão

Classes de Saída	1	15 30.0%	8 16.0%	0 0.0%	65.2% 34.8%
	2	5 10.0%	14 28.0%	0 0.0%	73.7% 26.3%
	3	5 10.0%	3 6.0%	0 0.0%	0.0% 100%
		60.0% 40.0%	56.0% 44.0%	NaN% NaN%	58.0% 42.0%
		1 2 3	Classes Alvo		

Figura 5.16 – Resultado da quarta validação do voluntário #4.

Na segunda sessão de validação (Figura 5.14) obteve-se uma melhora na acurácia total (42,0%). Obtendo valores de precisão superiores a 50% (52,2% e 64,3%). Porém valores de sensibilidade inferiores a 50% (48,0% e 36,0%), porém ainda superiores aos valores da primeira validação.

Enquanto, na terceira sessão de validação (Figura 5.15), teve-se uma acurácia total próxima a sessão anterior (40,0%), mantendo uma precisão melhor na classe 2 (53,6%) mas com uma diferença menor em relação a classe 1 (45,5%), sendo um pouco mais homogêneo. Porém, a sensibilidade foi mais heterogênea entre a classe 1 (20,0%) e a classe 2 (60,0%).

Finalmente, na quarta sessão de validação (Figura 5.16), obteve-se o melhor resultado de acurácia total (58,0%). Valores de precisão homogêneos e superiores a 60%, principalmente na classe 2 (73,7%). E valores de sensibilidade também homogêneos, de 60,0% na classe 1 e 56,0% na classe 2.

6 Discussão e conclusões

Na maioria das pesquisas em ICM (BRUNNER et al., 2006; HAZRATI; ERFANIAN, 2010; NICOLAS-ALONSO; GOMEZ-GIL, 2012; SHIMAN et al., 2017) é realizado o tratamento de artefatos. Entretanto, Tavakolan et al. (2017) relatam que apenas a filtragem na faixa de interesse seria adequada para o pré-processamento do sinal de EEG. Neste trabalho, verificou-se que a utilização de técnicas de rejeição e remoção de artefatos apresentavam resultados similares a uma simples filtragem na faixa de interesse. Contudo, mais estudos são necessários para entender melhor a influência de técnicas para tratamento de artefatos com as técnicas de conectividade direcionada, assim como mais estudos da influência do uso de filtros espaciais.

A partir dos resultados da comparação das características selecionou-se, a média, o desvio padrão e a centroide espectral da função de conectividade, calculadas para toda a banda de frequência (1 a 40 Hz). Uma vez que, na maioria dos casos, se obtiveram resultados melhores ou próximos na classificação, quando comparados a outras características e bandas. Uma hipótese desse resultado é a informação redundante que pode existir entre as cinco características, média, desvio padrão, valor RMS, máximo e mínimo usadas por Silveira (2017). Além disso, a escolha das três características reduz o número de entradas para a rede neural artificial, de 550 para 330. Mais estudos são necessários sobre técnicas de redução de dimensionalidade e escolha de características, como a escolha de derivações de EEG.

A classificação de tarefas de IM em diferentes membros tem atingido uma acurácia acima de 90%. Wang et al (2006) obteve 96.13% para a imaginação dos movimentos das mãos direita e esquerda. Porém, a classificação de diferentes tarefas de IM do mesmo membro é um grande desafio, devido à sua proximidade espacial na representação do córtex motor. Recentemente, Yong e Menon (2015) obteve uma acurácia de 60,7% para a classificação de três imaginações, aperto de mão, movimento do cotovelo e repouso. Tavakolan et al. (2017) obteve 74,2% de acurácia para o mesmo conjunto de imaginações. No trabalho de Silveira (2017) obteve-se um valor de acurácia de 88,9% utilizando a PDC e como classificador RNA, para sete diferentes classes, imaginação, execução e observação da extensão e da flexão do cotovelo e repouso.

Os resultados apresentados anteriormente são provenientes de sistemas *offline*. Neste trabalho, obteve-se com a gPDC e a RNA uma acurácia, no grupo de teste do sistema *offline*, de 90,0% para o voluntário #2 e 80,0% para o voluntário #4, para três imaginações (flexão e extensão do cotovelo e repouso). Mesmo que uma comparação com outros sistemas seja complicada, devido as diferentes tarefas de IM e protocolos, os resultados mostram-se melhores ou similares quando comparados com os sistemas de classificação de tarefas de IM do mesmo membro. O limitante dessa comparação é o número de voluntários, para trabalhos futuros serão coletados mais dados para confirmar esses achados.

Brunner et al. (2006), utilizando apenas 2 derivações de EEG, fizeram um sistema *online* para classificação, utilizando LDA, de três tarefas de imaginação (mão esquerda, mão direita e pé). Os autores obtiveram acurácia entre 49% e 54% na primeira sessão de validação e entre 60% e 67% na terceira sessão. Hazrati e Erfanian (2010) apresentaram um sistema *online* utilizando redes neurais adaptativa probabilística, utilizando 6 derivações, para a classificação de duas tarefas de imaginação (abertura e fechamento da mão). Os autores obtiveram resultados de acurácia média de 75,4% na primeira sessão e de 83,8%, na oitava sessão.

No presente trabalho, o sistema *online*, utilizando 11 derivações, apresentou uma acurácia média de 39,1% e 40,0% para os participantes #2 e #4, respectivamente, para três classes. No voluntário #2 se teve melhora gradativa na performance, atingindo o seu melhor resultado de acurácia na terceira sessão com 48,0%, porém teve o seu pior resultado na quarta sessão (28,0%). Por outro lado, o voluntário #4 teve uma melhora ao longo das quatro seções. Partindo do seu pior resultado, na primeira sessão (20,0%) e alcançando o melhor na quarta sessão (58,0%). Essa melhora com o passar das seções corrobora com os resultados dos trabalhos de Brunner et al. (2006) e Hazrati e Erfanian (2010). Sendo que, a piora na performance do voluntário #2 na última sessão de validação, pode ter sido causado pelo cansaço do experimento. Esses resultados também são de difícil comparação com os trabalhos citados acima, por serem tarefas de imaginação e protocolos diferentes.

Uma hipótese para a diferença entre os resultados obtidos pelo treinamento *offline* e pela validação *online*, é a diferença da observação do braço robótico. A observação do

braço robótico se mexendo durante a coleta para o treinamento *offline* pode ajudar na tarefa de imagética, facilitador que durante a etapa de validação não existe. Para verificar essa influência, em trabalhos futuros sugere-se que a coleta para o treinamento seja feita sem o braço robótico se mexendo durante a tarefa de imagética. Além disso, estudos futuros devem ser feitos para verificar a influência do tempo entre a coleta para o treinamento e a validação do sistema *online*. O voluntário #2 teve um intervalo maior a 30 dias entre o treinamento e a validação, enquanto para o voluntário #4 esse intervalo foi de 2 dias.

Nesse trabalho ainda, não se testou na sessão de validação do sistema *online* nenhuma atividade de repouso, o que pode ter interferido nos resultados dos classificadores. A não utilização do auto espectro normalizado na classificação pode ter uma explicação para a grande quantidade de observações serem erroneamente classificadas como repouso, uma vez que se espera que a atividade de repouso tenha um auto espectro diferente das tarefas de IM.

O presente trabalho mostra que a conectividade direcionada, em conjunto com a rede neural artificial, é promissora para o desenvolvimento de ICM *online* para a classificação de tarefas de imaginação no mesmo membro.

A próxima etapa seria a investigação do uso de técnicas adaptativas para a classificação, de modo que o sistema possa ir se adaptando ao usuário e melhorando conforme as seções. Assim como a implementação de uma possível ICM assíncrona. Para isso, uma avaliação mais detalhada de modelos multivariado autorregressivos e das técnicas de conectividade é vista necessária para possíveis trabalhos futuros.

7 Referências bibliográficas

AKAIKE, H. On the use of a linear model for the identification of feedback systems. **Annals of the Institute of statistical mathematics**, v. 20, n. 1, p. 425–439, 1968.

AKAIKE, H. A new look at the statistical model identification. **IEEE transactions on automatic control**, v. 19, n. 6, p. 716–723, 1974.

ALLISON, B. **P3 or not P3: Toward a Better P300 BCI**. Tese de Doutorado—San Diego: University of California, 2003.

AMABILE, R. A. et al. **Remoção automática de artefatos em sinais de EEG usando Local SSA**. . In: XVII CONGRESSO BRASILEIRO DE AUTOMÁTICA. 2008

ANG, K. K. et al. A randomized controlled trial of EEG-based motor imagery brain-computer interface robotic rehabilitation for stroke. **Clinical EEG and neuroscience**, v. 46, n. 4, p. 310–320, 2015.

BACCALÁ, L. A.; SAMESHIMA, K. Partial directed coherence: a new concept in neural structure determination. **Biological cybernetics**, v. 84, n. 6, p. 463–474, 2001.

BACCALÁ, L. A.; SAMESHIMA, K.; TAKAHASHI, D. Y. **Generalized partial directed coherence**. 2007 15th International Conference on Digital Signal Processing. **Anais...**Cardiff: IEEE, 2007

BARBATI, G. et al. Optimization of an independent component analysis approach for artifact identification and removal in magnetoencephalographic signals. **Clinical Neurophysiology**, v. 115, n. 5, p. 1220–1232, 2004.

BASTOS, A. M.; SCHOFFELÉN, J.-M. A Tutorial Review of Functional Connectivity Analysis Methods and Their Interpretational Pitfalls. **Frontiers in Systems Neuroscience**, v. 9, p. 175, 2016.

BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. **Neurociências Desvendando o Sistema Nervoso**. 2. ed. Porto Alegre: Artmed, 2002.

BENDAT, J. S.; PIERSOL, A. G. **Random data: analysis and measurement procedures**. 4. ed. [s.l.] John Wiley & Sons, 2011. v. 729

BLANKERTZ, B. et al. **Invariant common spatial patterns: Alleviating nonstationarities in brain-computer interfacing**. . In: ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS. 2008

BLINOWSKA, K.; DURKA, P. Electroencephalography (EEG). In: **Wiley Encyclopedia of Biomedical Engineering**. [s.l.] American Cancer Society, 2006.

BLINOWSKA, K. J. Review of the methods of determination of directed connectivity from multichannel data. **Medical & biological engineering & computing**, v. 49, n. 5, p. 521–529, 2011.

BLINOWSKA, K. J.; KUŚ, R.; KAMIŃSKI, M. Granger causality and information flow in multivariate processes. **Physical Review E**, v. 70, n. 5, p. 050902, 2004.

BRUNNER, C. et al. Online control of a brain-computer interface using phase synchronization. **IEEE Transactions on Biomedical Engineering**, v. 53, n. 12, p. 2501–2506, 2006.

CEVALLOS-LARREA, P. et al. Sistema Modular para Avaliação da Resposta Auditiva em Regime Permanente. **VII Simpósio de Instrumentação e Imagens Médicas / VI Simpósio de Processamento de Sinais**, v. 2, p. 109–112, 2015.

CHAUDHARY, U.; BIRBAUMER, N.; RAMOS-MURGUIALDAY, A. Brain-computer interfaces for communication and rehabilitation. **Nature Reviews Neurology**, v. 12, n. 9, p. 513, 2016.

COSTA, F. J. E. **Efeito da Prática Mental no Eletroencefalograma Durante Tarefas Visuo-motoras**. Dissertação de Mestrado—Belo Horizonte: UFMG, 2012.

CUNHA, R. G. et al. Influence of functional task-oriented mental practice on the gait of transtibial amputees: a randomized, clinical trial. **Journal of NeuroEngineering and Rehabilitation**, v. 14, n. 1, p. 28, Abril 2017.

CURRAN, E. A.; STOKES, M. J. Learning to control brain activity: A review of the production and control of EEG components for driving brain-computer interface (BCI) systems. **Brain and Cognition**, v. 51, n. 3, p. 326–336, Abril 2003.

DALY, J. J.; WOLPAW, J. R. Brain-computer interfaces in neurological rehabilitation. **The Lancet Neurology**, v. 7, n. 11, p. 1032–1043, 2008.

DECETY, J.; JEANNEROD, M. Mentally simulated movements in virtual reality: does Fitt's law hold in motor imagery? **Behavioural brain research**, v. 72, n. 1, p. 127–134, 1995.

DELORME, A.; MAKEIG, S.; SEJNOWSKI, T. J. **Automatic artifact rejection for EEG data using high-order statistics and independent component analysis**. Proceedings of the third international ICA conference. **Anais...**San Diego: 2001

DICKSTEIN, R.; DEUTSCH, J. E. Motor imagery in physical therapist practice. **Physical therapy**, v. 87, n. 7, p. 942–953, 2007.

DIMYAN, M. A.; COHEN, L. G. Neuroplasticity in the context of motor rehabilitation after stroke. **Nature Reviews Neurology**, v. 7, n. 2, p. 76–85, 2011.

ENGELBRECHT, A. P. **Computational intelligence: an introduction**. [s.l.] John Wiley & Sons, 2007.

FALLANI, F. D. V. et al. Multiscale topological properties of functional brain networks during motor imagery after stroke. **Neuroimage**, v. 83, p. 438–449, 2013.

FRISTON, K. J. Functional and effective connectivity in neuroimaging: a synthesis. **Human brain mapping**, v. 2, n. 1-2, p. 56–78, 1994.

FRISTON, K. J. Functional and effective connectivity: a review. **Brain connectivity**, v. 1, n. 1, p. 13–36, 2011.

FROLOV, A. A. et al. Post-stroke rehabilitation training with a motor-imagery-based brain-computer interface (BCI)-controlled hand exoskeleton: a randomized controlled multicenter trial. **Frontiers in neuroscience**, v. 11, p. 400, 2017.

GRANGER, C. W. J. Investigating Causal Relations by Econometric Models and Cross-spectral Methods. **Econometrica**, v. 37, n. 3, p. 424–438, 1969.

GREZES, J.; DECETY, J. Functional anatomy of execution, mental simulation, observation, and verb generation of actions: a meta-analysis. **Human brain mapping**, v. 12, n. 1, p. 1–19, 2001.

HAMEDI, M.; SALLEH, S.-H.; NOOR, A. M. Electroencephalographic motor imagery brain connectivity analysis for BCI: a review. **Neural computation**, v. 28, n. 6, p. 999–1041, 2016.

HANAKAWA, T.; DIMYAN, M. A.; HALLETT, M. Motor Planning, Imagery, and Execution in the Distributed Motor Network: A Time-Course Study with Functional MRI. **Cerebral Cortex**, v. 18, n. 12, p. 2775–2788, Dezembro 2008.

HAYKIN, S. **Redes neurais: princípios e prática**. [s.l.] Bookman Editora, 2007.

HAZRATI, M. K.; ERFANIAN, A. An online EEG-based brain–computer interface for controlling hand grasp using an adaptive probabilistic neural network. **Medical engineering & physics**, v. 32, n. 7, p. 730–739, 2010.

IBÁÑEZ, J. et al. Predictive classification of self-paced upper-limb analytical movements with EEG. **Medical & biological engineering & computing**, v. 53, n. 11, p. 1201–1210, 2015.

INFANTOSI, A. et al. Avaliação do desempenho de técnicas de interpolação no mapeamento cerebral utilizando simulação. **RBE Caderno de Engenharia Biomédica**, v. 14, n. 2, p. 71–96, 1998.

JEANNEROD, M. The representing brain: Neural correlates of motor intention and imagery. **Behavioral and Brain sciences**, v. 17, n. 2, p. 187–202, 1994.

KALCHER, J. et al. Graz brain-computer interface II: towards communication between humans and computers based on online classification of three different EEG patterns. **Medical & Biological Engineering & Computing**, v. 34, n. 5, p. 382–388, set. 1996.

KAMINSKI, M. J.; BLINOWSKA, K. J. A new method of the description of the information flow in the brain structures. **Biological Cybernetics**, v. 65, n. 3, p. 203–210, 1 jul. 1991.

KANDEL, E. R. et al. **Princípios de Neurociências**. 5. ed. Porto Alegre: McGraw-Hill, 2014.

KAUATI-SAITO, É. et al. **Classification of Motor Tasks from EEG Signals Comparing Preprocessing Techniques**. (R. Costa-Felix, J. C. Machado, A. V. Alvarenga, Eds.)XXVI Brazilian Congress on Biomedical Engineering. **Anais...Armação de Buzios**: Springer Singapore, 2019

KLEM, G. H. et al. The ten-twenty electrode system of the International Federation. **Electroencephalogr Clin Neurophysiol**, v. 52, n. 3, p. 3–6, 1999.

KOESSLER, L. et al. Automated cortical projection of EEG sensors: anatomical correlation via the international 10–10 system. **Neuroimage**, v. 46, n. 1, p. 64–72, 2009.

KRIESEL, D. **A brief Introduction on Neural Networks**. [s.l: s.n.].

LANA, E. P.; ADORNO, B. V.; TIERRA-CRIOLLO, C. J. **An ERD/ERS analysis of the relation between human arm and robot manipulator movements**. 2013 ISSNIP Biosignals and Biorobotics Conference: Biosignals and Robotics for Better and Safer Living (BRC). **Anais...Rio de Janeiro**: IEEE, 2013

LEBEDEV, M. A.; NICOLELIS, M. A. L. Brain–machine interfaces: past, present and future. **Trends in Neurosciences**, v. 29, n. 9, p. 536–546, Setembro 2006.

LOTTE, F. et al. A review of classification algorithms for EEG-based brain–computer interfaces. **Journal of neural engineering**, v. 4, n. 2, p. R1, 2007.

LOTTE, F. et al. A review of classification algorithms for EEG-based brain–computer interfaces: a 10 year update. **Journal of neural engineering**, v. 15, n. 3, p. 031005, 2018.

LOTTE, F.; GUAN, C. Regularizing common spatial patterns to improve BCI designs: unified theory and new algorithms. **IEEE Transactions on biomedical Engineering**, v. 58, n. 2, p. 355–362, 2011.

LÜTKEPOHL, H. **Introduction to Multiple Time Series Analysis**. 2. ed. Berlin: Springer-Verlag Berlin Heidelberg, 1993.

LÜTKEPOHL, H. **New introduction to multiple time series analysis**. Berlin: Springer Science & Business Media, 2005.

MARTINEZ, A. M.; KAK, A. C. PCA versus LDA. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 23, n. 2, p. 228–233, fev. 2001.

MCFARLAND, D. J.; WOLPAW, J. R. Brain-computer Interfaces for Communication and Control. **Commun. ACM**, v. 54, n. 5, p. 60–66, Maio 2011.

MICHIE, D.; SPIEGELHALTER, D. J.; TAYLOR, C. C. **Machine learning, neural and statistical classification**. [s.l.: s.n.].

MØLLER, M. F. A scaled conjugate gradient algorithm for fast supervised learning. **Neural networks**, v. 6, n. 4, p. 525–533, 1993.

MONGE-PEREIRA, E. et al. Use of electroencephalography brain-computer interface systems as a rehabilitative approach for upper limb function after a stroke: a systematic review. **PM&R**, v. 9, n. 9, p. 918–932, 2017.

MÜLLER, K.-R. et al. Machine learning for real-time single-trial EEG-analysis: from brain-computer interfacing to mental state monitoring. **Journal of neuroscience methods**, v. 167, n. 1, p. 82–90, 2008.

NICOLAS-ALONSO, L. F.; GOMEZ-GIL, J. Brain computer interfaces, a review. **sensors**, v. 12, n. 2, p. 1211–1279, 2012.

OKAMOTO, M. et al. Three-dimensional probabilistic anatomical cranio-cerebral correlation via the international 10–20 system oriented for transcranial functional brain mapping. **Neuroimage**, v. 21, n. 1, p. 99–111, 2004.

OMIDVARNIA, A. et al. Measuring time-varying information flow in scalp EEG signals: orthogonalized partial directed coherence. **IEEE transactions on biomedical engineering**, v. 61, n. 3, p. 680–693, 2014.

PASSOS, P. R. C. **Análise do beta rebound no EEG durante imagética motora com base no teste F-espectral**. Dissertação de Mestrado—Rio de Janeiro: UFRJ, 2016.

PAZ, C. C. DOS S. C. **Prática mental orientada a tarefas funcionais na recuperação de indivíduos com acidente vascular encefálico**. Tese de Doutorado—Belo Horizonte: UFMG, mar. 2012.

ROSSO, C. et al. Contribution of Corticospinal Tract and Functional Connectivity in Hand Motor Impairment after Stroke. **PLOS ONE**, v. 8, n. 9, p. e73164, Setembro 2013.

SAITO, Y.; HARASHIMA, H. **Tracking of information within multichannel EEG record: Causal analysis in EEG**. . In: RECENT ADVANCES IN EEG AND EMG DATA PROCESSING. Amsterdam: Elsevier: 1981

SANTOS FILHO, S. A. et al. Magnitude squared of coherence to detect imaginary movement. **EURASIP Journal on Advances in Signal Processing**, v. 2009, n. 1, p. 534536, 2009.

SANTOS-COUTO-PAZ, C. C.; TEIXEIRA-SALMELA, L. F.; TIERRA-CRIOLLO, C. J. The addition of functional task-oriented mental practice to conventional physical therapy improves motor skills in daily functions after stroke. **Brazilian Journal of Physical Therapy**, v. 17, p. 564–571, 2013.

SCHLÖGL, A. A comparison of multivariate autoregressive estimators. **Signal processing**, v. 86, n. 9, p. 2426–2429, 2006.

SCHNEIDER, T.; NEUMAIER, A. Algorithm 808: ARfit—A Matlab package for the estimation of parameters and eigenmodes of multivariate autoregressive models. **ACM Transactions on Mathematical Software (TOMS)**, v. 27, n. 1, p. 58–65, 2001.

SCHWARZ, G. Estimating the dimension of a model. **The annals of statistics**, v. 6, n. 2, p. 461–464, 1978.

SHAO, S.-Y. et al. Automatic EEG artifact removal: a weighted support vector machine approach with error correction. **IEEE Transactions on Biomedical Engineering**, v. 56, n. 2, p. 336–344, 2009.

SHARMA, N.; POMEROY, V. M.; BARON, J.-C. Motor Imagery. **Stroke**, v. 37, n. 7, p. 1941, 1 jul. 2006.

SHENOY, P. et al. Towards adaptive classification for BCI. **Journal of neural engineering**, v. 3, n. 1, p. R13, 2006.

SHIMAN, F. et al. Classification of different reaching movements from the same limb using EEG. **Journal of neural engineering**, v. 14, n. 4, p. 046018, 2017.

SILVA, A. DE S. T. DA. **Estudo da conectividade funcional cerebral em sinais de EEG durante interação humano robô**. Dissertação de Mestrado—Rio de Janeiro: UFRJ, 2016.

SILVA, A. DE S. T. DA; SÁ, A. M. F. L. M. DE; TIERRA-CRIOLLO, C. J. **Identificação da direção do fluxo de informação no EEG para movimentos do cotovelo durante interação humano robô**. . In: CONGRESSO BRASILEIRO DE ENGENHARIA BIOMÉDICA, CBEB XXIV. 2014

SILVEIRA, G. F. M. DA et al. **Conectividade Cerebral na Classificação da Imaginação de Movimentos no Mesmo Membro com EEG**. XXV Congresso Brasileiro de Engenharia Biomédica. **Anais...**Uberlandia: 2016

SILVEIRA, G. F. M. DA. **Conectividade cerebral como característica para classificar tarefas motoras de mesmo segmento corporal: interação humano-robô**. Dissertação de Mestrado—Rio de Janeiro: UFRJ, jun. 2017.

SOLODKIN, A. et al. Fine Modulation in Network Activation during Motor Execution and Motor Imagery. **Cerebral Cortex**, v. 14, n. 11, p. 1246–1255, 1 nov. 2004.

SUBASI, A.; ISMAIL GURSOY, M. EEG signal classification using PCA, ICA, LDA and support vector machines. **Expert Systems with Applications**, v. 37, n. 12, p. 8659–8666, Dezembro 2010.

TAVAKOLAN, M. et al. Classifying three imaginary states of the same upper extremity using time-domain features. **PloS one**, v. 12, n. 3, p. e0174161, 2017.

TIERRA-CRIOLLO, C. J. Monitorização objetiva da resposta à estimulação somato-sensitiva utilizando parâmetros espectrais. **Rio de Janeiro-Brasil: Universidade Federal do Rio de Janeiro**, 2001.

TIERRA-CRIOLLO, C.; SIMPSON, D.; INFANTOSI, A. Resolución Espacial y Técnicas de Interpolación para Mapas Cerebrales con Derivación de la Fuente utilizando Simulaciones. **Revista Mexicana de Ingeniería Biomédica**, v. 18, n. 4, p. 21–28, 1997.

ULLOA, E. P. L. **Estudo sobre interfaces cérebro-máquina e Interação humano-robô**. Dissertação de Mestrado—Belo Horizonte: UFMG, 2013.

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.

VIDAL, J. J. Real-time detection of brain events in EEG. **Proceedings of the IEEE**, v. 65, n. 5, p. 633–641, 1977.

WANG, H. E. et al. A systematic framework for functional connectivity measures. **Frontiers in Neuroscience**, v. 8, p. 405, 2014.

WANG, Y. et al. **Phase synchrony measurement in motor cortex for classifying single-trial EEG during motor imagery**. Engineering in Medicine and Biology Society, 2006. EMBS'06. 28th Annual International Conference of the IEEE. **Anais...IEEE**, 2006

WIENER, N. The theory of prediction. **Modern mathematics for engineers**, 1956.

WOLPAW, J. R. et al. An EEG-based brain-computer interface for cursor control. **Electroencephalography and clinical neurophysiology**, v. 78, n. 3, p. 252–259, 1991.

WOLPAW, J. R. et al. Brain–computer interfaces for communication and control. **Clinical Neurophysiology**, v. 113, n. 6, p. 767–791, 1 jun. 2002.

YONG, X.; MENON, C. EEG Classification of Different Imaginary Movements within the Same Limb. **PLOS ONE**, v. 10, n. 4, p. e0121896, Abril 2015.

ZAPAŁA, D. et al. The impact of different visual feedbacks in user training on motor imagery control in BCI. **Applied psychophysiology and biofeedback**, v. 43, n. 1, p. 23–35, 2018.

Apêndice A – XXVI Brazilian Congress on Biomedical Engineering

[XXVI Brazilian Congress on Biomedical Engineering](#) pp 109-113 | [Cite as](#)

Classification of Motor Tasks from EEG Signals Comparing Preprocessing Techniques

Authors

[Authors and affiliations](#)

Éric Kauati-Saito , Gustavo F. M. da Silveira, Paulo J. G. Da-Silva, Antonio Mauricio F. L. Miranda de Sá, Carlos Julio Tierra-Criollo

Conference paper

First Online: 16 May 2019

Part of the [IFMBE Proceedings](#) book series (IFMBE, volume 70/2)

Abstract

The electroencephalogram (EEG) has been used to control non-invasive brain-computer interface (BCI). EEG Signal is very susceptible to artifact that can interfere on the performance of the classifiers used in BCI system. There are many methods used to identify, reject, and remove artifacts. However, no consensual standard metrics for performance evaluation of these methods is available. The aim of this work is to study the performance of the different preprocessing techniques in classification, using raw EEG data and power spectra. Here, the preprocessing is the bandpass filtering, filtering and artifact removal by Independent Components Analysis (ICA), and filtering and rejection of artifacts by threshold. EEG signals from six right-handed healthy volunteers were divided in three tasks: observation (elbow flexion and extension); elbow flexion movement; elbow extension movement. According to the results without feature extraction (raw EEG), filtering and artifact removal by ICA had better accuracy. In addition, with feature extraction (power spectra), the bandpass filtering is preferred because of simplicity and no loss of data, even if it showed a slightly worse performance.

Apêndice B – Resultados preliminares

A seguir serão apresentados resultados de testes preliminares para a escolha do tamanho da janela do sinal de EEG.

A avaliação do tamanho do segmento foi feita, utilizando os dados de um indivíduo, seguindo a estrutura apresentada em 4.4.5. Os resultados obtidos são apresentados na Tabela 3. A janela de 2 segundos teve a melhor performance (valor máximo 83,33%), porém na média a janela de 1,5 segundos apresentou a melhor performance (46,98%).

A partir desses resultados escolheu-se o tamanho de segmentação de 1,5 segundos. Devido à pouca diferença entre o seu valor máximo (80,00%) e de que a tarefa de IM demora 1 segundo, mais o tempo de reação do voluntário.

Devido a diferença na duração do movimento (2,5 segundos) do robô em relação ao trabalho de Silveira (2017) não foi feita uma comparação com esses dados.

Tabela 3 – Resultados da comparação do tamanho da segmentação.

Tamanho do Segmento / Medida	1 segundo	1,5 segundos	2 segundos	4 segundos
Valor Máximo (%)	80,00	80,00	83,33	76,67
Média (%)	43,04	46,98	45,24	42,90
Desvio Padrão (%)	11,34	11,31	11,22	10,33

Apêndice C – Exemplo de gráficos da gPDC

Nesse apêndice são apresentados alguns exemplos de gráficos dos resultados da gPDC de um dos sinais de EEG durante o treinamento *offline*.

A Figura 7.1 é um conjunto de gráficos resultante da gPDC de uma observação da atividade de IM da extensão (azul) e da flexão (vermelho). É apresentado apenas algumas das derivações utilizadas (C3, C4, FC4, P3, FCz).

Em cada gráfico tem-se, no eixo X, a frequência em Hz e no eixo Y, os valores normalizados da gPDC. Nesse conjunto de gráficos as colunas representam as fontes e as linhas o destino do fluxo de informação. E na diagonal principal temos o auto espectro normalizado.

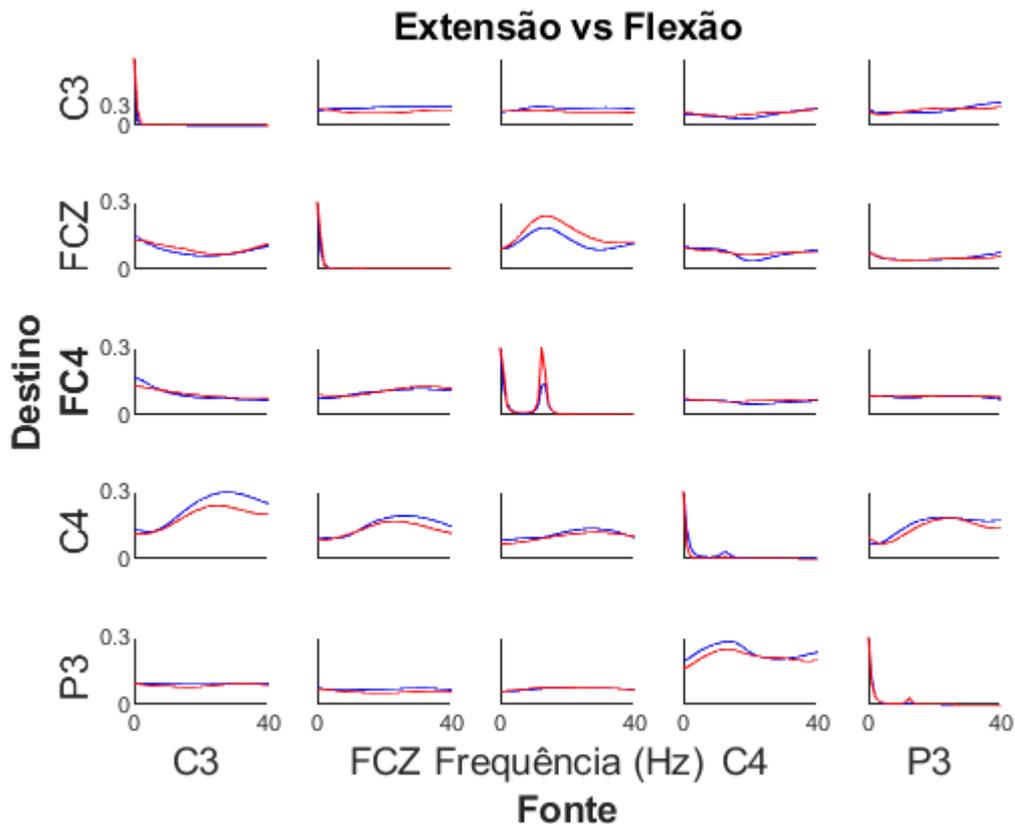


Figura 7.1 – Gráfico da gPDC de uma IM da extensão (azul) e da flexão (vermelho) voluntário #2. No eixo X, a frequência em Hz e no eixo Y, os valores normalizados da gPDC. Nesse conjunto de gráficos as colunas representam as fontes e as linhas o destino do fluxo de informação. E na diagonal principal temos o auto espectro normalizado.

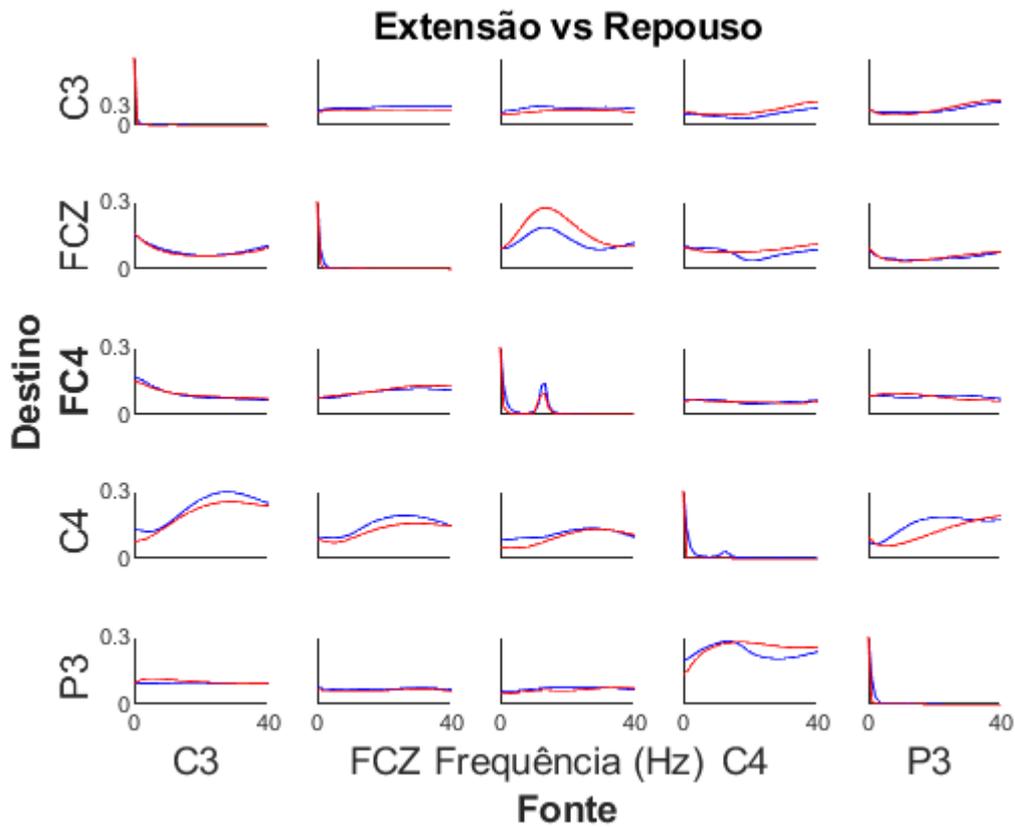


Figura 7.2 – Gráfico da gPDC de uma IM da extensão (azul) e do repouso (vermelho) voluntário #2. No eixo X, a frequência em Hz e no eixo Y, os valores normalizados da gPDC. Nesse conjunto de gráficos as colunas representam as fontes e as linhas o destino do fluxo de informação. E na diagonal principal temos o auto espectro normalizado.

Na Figura 7.2, o conjunto de gráficos resultante da gPDC é da mesma observação de IM, porém da extensão (azul) e do repouso (vermelho). Finalmente, na Figura 7.3, o conjunto de gráficos resultante da gPDC é da mesma observação de IM, porém da flexão (azul) e do repouso (vermelho).

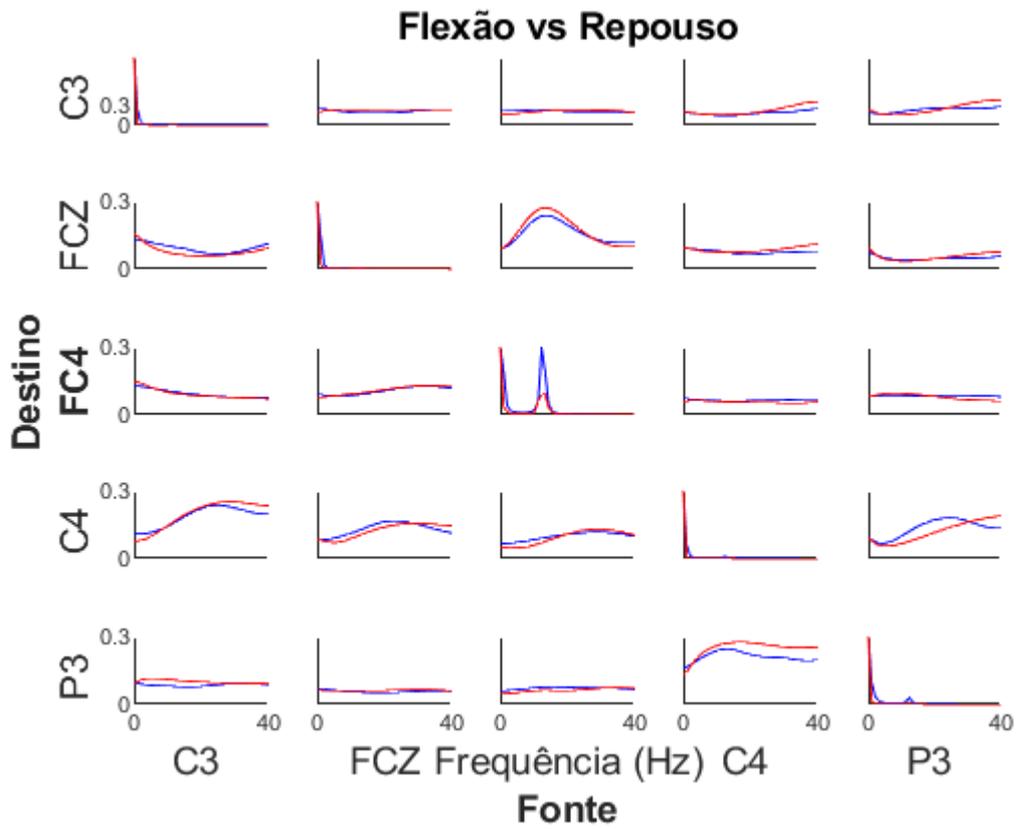


Figura 7.3 – Gráfico da gPDC de uma IM da flexão (azul) e do repouso (vermelho) do voluntário #2. No eixo X, a frequência em Hz e no eixo Y, os valores normalizados da gPDC. Nesse conjunto de gráficos as colunas representam as fontes e as linhas o destino do fluxo de informação. E na diagonal principal temos o auto espectro.

ANEXO A – MIQ-R (Revised Movement Imagery Questionnaire) em português

Cada um dos seguintes enunciados descreve uma ação ou movimento particular. Ouça cada enunciado cuidadosamente e então execute o movimento como descrito. Somente execute o movimento uma única vez após o comando “execute o movimento agora”. Após executar o movimento retorne à posição de partida anterior à execução, exatamente como se esperasse para executar o movimento uma segunda vez. Então, dependendo das questões que serão solicitadas para a sua execução:

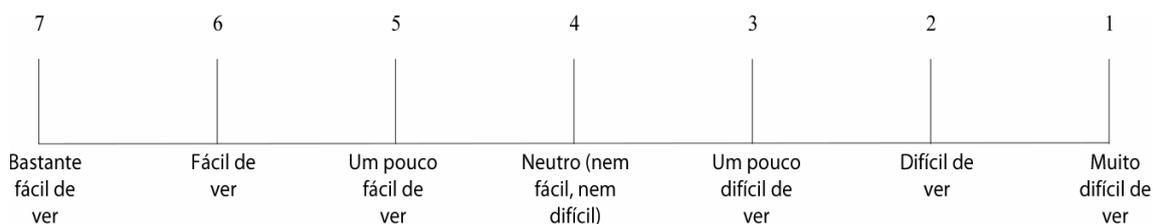
Forme uma imagem a mais clara e nítida possível do movimento executado

Preste atenção para sentir-se realizando o movimento sem executá-lo efetivamente.

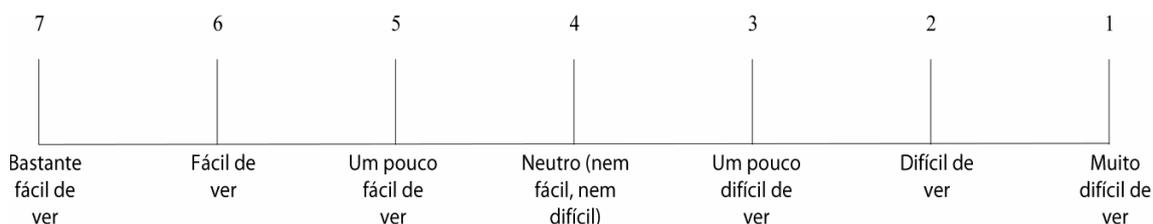
Somente inicie as tarefas mentais solicitadas após os comandos “feche os olhos e se veja AGORA” ou “Feche os olhos e sinta-se AGORA”

Após ter completado o teste mental proposto classifique em fácil/difícil com relação a sua habilidade na execução de acordo com as escalas abaixo

Escala de Imagética Visual



Escala de Imagética Cenestésica



Início do Teste

1	Posição Inicial	Permaneça de pé com os pés juntos e os braços ao longo do corpo
	Ação	<p>Em 1 segundo será solicitada a execução do seguinte movimento.</p> <p>Flexione seu joelho direito o máximo possível de maneira que você permaneça de pé apoiado na perna esquerda com a perna direita totalmente flexionada. Finalmente abaixe sua perna direita até retornar a posição inicial de apoio com ambos os pés no solo.</p> <p>Execute o movimento AGORA. <i>10 segundos</i></p>
	Tarefa Mental	<p>Assuma a posição inicial.</p> <p>Em 1 segundo você será instruído a sentir-se executando o movimento anterior sem realizá-lo de fato, da maneira mais clara e nítida possível.</p> <p>Feche seus olhos e sinta-se executando AGORA. <i>10 segundos</i></p> <p>Agora, classifique a facilidade/dificuldade encontrada na realização desta tarefa mental. <i>10 segundos</i></p>
2	Posição Inicial	Permaneça de pé com suas mãos ao longo do corpo

	<p>Ação</p>	<p>Em 1 segundo você será instruído a realizar o seguinte movimento.</p> <p>Curve-se para baixo e então salte em linha reta para cima o mais alto possível com ambos os braços estendidos acima da cabeça.</p> <p>Aterrise com os pés afastados e abaixe os braços até que retornem a posição ao longo do corpo</p> <p>Execute o movimento AGORA. <i>10 segundos</i></p>
	<p>Tarefa Mental</p>	<p>Assuma a posição inicial.</p> <p>Em 1 segundo você será instruído a visualizar-se realizando a tarefa anterior sem realizá-lo de fato, da maneira mais clara e nítida possível.</p> <p>Feche seus olhos e visualize-se executando AGORA. <i>10 segundos</i></p> <p>Agora, classifique a facilidade/dificuldade encontrada na realização desta tarefa mental. <i>10 segundos</i></p>

3	Posição Inicial	Estenda o braço de sua mão não-dominante para o lado do corpo de maneira que ele fique paralelo ao solo com a palma da mão para baixo
	Ação	<p>Em 1 segundo você será instruído a realizar o seguinte movimento.</p> <p>Mova seu braço para frente do corpo permanecendo paralelo ao solo. Mantenha seu braço estendido durante o movimento executando vagarosamente.</p> <p>Execute o movimento <i>AGORA. 10 segundos</i></p>
	Tarefa Mental	<p>Assuma a posição inicial</p> <p>Em 1 segundo você será instruído a sentir-se executando o movimento anterior sem realizá-lo de fato.</p> <p>Feche seus olhos e sinta-se executando <i>AGORA. 10 segundos</i></p> <p>Agora, classifique a facilidade/dificuldade encontrada na realização desta tarefa mental. <i>10 segundos</i></p>
4	Posição Inicial	Permaneça com seus pés afastados e seus braços completamente estendidos acima da cabeça

	Ação	<p>Em 1 segundo você será instruído a realizar o seguinte movimento.</p> <p>Lentamente curve seu corpo para frente pela cintura tentando alcançar o dedão do pé ou o solo com a ponta dos dedos das mãos e então retorne a posição inicial permanecendo ereto com seus braços estendidos sobre a cabeça.</p> <p>Execute o movimento AGORA. <i>10 segundos</i></p>
	Tarefa Mental	<p>Assuma a posição inicial.</p> <p>Em 1 segundo você será instruído a visualizar-se realizando a tarefa anterior da maneira mais clara e nítida possível.</p> <p>Feche seus olhos e visualize-se AGORA. <i>10 segundos</i></p> <p>Agora, classifique a facilidade/dificuldade encontrada na realização desta tarefa mental. <i>10 segundos</i></p>
5	Posição Inicial	Permaneça com os pés unidos e os braços ao longo do corpo.
	Ação	Em 1 segundo você será instruído a realizar o seguinte movimento.

		<p>Curve-se para baixo e então salte em linha reta para cima o mais alto possível com os braços estendidos acima da cabeça.</p> <p>Aterrise com os pés afastados e abaixe os braços até que retornem a posição ao longo do corpo.</p> <p>Realize o movimento AGORA. <i>10 segundos</i></p>
	Tarefa Mental	<p>Assuma a posição inicial</p> <p>Em 1 segundo você será instruído a sentir-se executando o movimento anterior sem realizá-lo de fato.</p> <p>Feche seus olhos e sinta-se executando AGORA <i>10 segundos</i></p> <p>Agora, classifique a facilidade/dificuldade encontrada na realização desta tarefa mental <i>10 segundos</i></p>
6	Posição Inicial	<p>Permaneça com seus pés e pernas unidos e seus braços ao longo do corpo.</p>
	Ação	<p>Em 1 segundo será solicitada a execução do seguinte movimento.</p> <p>Flexione seu joelho direito o máximo possível de maneira que você permaneça de pé apoiado na perna</p>

		<p>esquerda com a perna direita totalmente flexionada. Finalmente abaixe sua perna direita até que retorne a posição inicial de apoio com ambos os pés no solo.</p> <p>Execute essas ações vagarosamente. Execute o movimento AGORA. <i>10 segundos</i></p>
	Tarefa Mental	<p>Assuma a posição inicial.</p> <p>Em 1 segundo você será instruído a visualizar-se realizando a tarefa anterior da maneira mais clara e nítida possível.</p> <p>Feche seus olhos e visualize-se AGORA. <i>10 segundos</i></p> <p>Agora, classifique a facilidade/dificuldade encontrada na realização desta tarefa mental. <i>10 segundos</i></p>
7	Posição Inicial	<p>Permaneça com os pés unidos e os braços ao longo do corpo.</p>
	Ação	<p>Em 1 segundo você será instruído a realizar o seguinte movimento.</p> <p>Lentamente curve seu corpo para frente pela cintura tentando alcançar o dedão do pé ou o solo com a ponta dos dedos das mãos e então retorne a posição</p>

		<p>inicial permanecendo ereto com seus braços estendidos sobre a cabeça.</p> <p>Execute o movimento AGORA. <i>10 segundos</i></p>
	Tarefa Mental	<p>Assuma a posição inicial</p> <p>Em 1 segundo você será instruído a sentir-se executando o movimento anterior sem realizá-lo de fato.</p> <p>Feche seus olhos e sinta-se executando AGORA <i>10 segundos</i></p> <p>Agora, classifique a facilidade/dificuldade encontrada na realização desta tarefa mental</p> <p><i>10 segundos</i></p>
	Posição Inicial	<p>Estenda o braço de sua mão não-dominante para o lado do corpo de maneira que ele fique paralelo ao solo com a palma da mão para baixo</p>
	Ação	<p>Em 1 segundo você será instruído a realizar o seguinte movimento.</p> <p>Mova seu braço para frente até a frente do corpo permanecendo paralelo ao solo. Mantenha seu braço estendido durante o movimento e faça execute-o vagorosamente.</p>

		Execute o movimento AGORA. <i>10 segundos</i>
	Tarefa Mental	<p>Assuma a posição inicial.</p> <p>Em 1 segundo você será instruído a visualizar-se realizando a tarefa anterior da maneira mais clara e nítida possível.</p> <p>Feche seus olhos e visualize-se AGORA. <i>10 segundos</i></p> <p>Agora, classifique a facilidade/dificuldade encontrada na realização desta tarefa mental. <i>10 segundos</i></p>

ANEXO B – Inventário de Edinburgh

Você já teve algumas tendências em ser canhoto? () S / () N

Existe algum canhoto na sua família? () S / () N

Indicar a preferência manual nas seguintes atividades, assinalando + na coluna apropriada. Se não existir, assinale + nas duas colunas.

	ESQUERDA	DIREITA
Escrever		
Desenhar		
Jogar uma pedra		
Usar uma tesoura		
Usar um pente		
Usar uma escova de dentes		
Usar uma faca (sem o uso do garfo)		
Usar uma colher		
Usar um martelo		
Usar uma chave de fenda		
Usar uma raquete de tênis		
Usar uma faca (com garfo)		
Usar uma vassoura (mão superior)		
Usar um ancinho (mão superior)		
Acender um fósforo		
Abrir um vidro com tampa (mão que segura a tampa)		
Dar cartas		
Enfiar a linha na agulha (mão que segura o que se move)		
Com que pé você prefere chutar?		

ANEXO C – Especificações do manipulador robótico AX18

O manipulador robótico é o robô manipulador do modelo AX18, do fabricante *CrustCrawler Robotics* (Arizona, EUA). E utiliza servomotores Dynamixel AX18A, do fabricante *Robotis* (Seul, Coréia do Sul). O manipulador possui cinco graus de liberdade, controlado por sete servomotores, e um efetuador final, controlado por dois servomotores. A seguir algumas características:

- Tensão de alimentação: 9 V.
- Tensão de alimentação do servomotor: 9 – 12 V.
- Protocolo de comunicação serial.
- Realimentação do servomotor: posição, velocidade, temperatura, carga, tensão de entrada.
- Resolução do servomotor: 0,29°.
- Torque do servomotor: 18 kgf.cm (12 V e 2,2 A).
- Velocidade do motor sem carga: 97 rpm (12 V).
- Intervalo de operação do servomotor: 0 - 300°.

A comunicação do manipulador com o computador é feita por meio de um conversor USB2Dynamixel utilizando uma porta USB. O código do manipulador foi desenvolvido no software *MATLAB* (*MathWorks*, EUA), usando-se de funções prontas.