



CONECTIVIDADE CEREBRAL COMO CARACTERÍSTICA PARA  
CLASSIFICAR TAREFAS MOTORAS DE MESMO SEGMENTO CORPORAL:  
INTERAÇÃO HUMANO-ROBÔ

Gustavo Fraga Millen da Silveira

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

Orientadores: Antonio Mauricio Ferreira Leite  
Miranda de Sá  
Carlos Julio Tierra-Criollo

Rio de Janeiro  
Junho de 2017

CONECTIVIDADE CEREBRAL COMO CARACTERÍSTICA PARA  
CLASSIFICAR TAREFAS MOTORAS DE MESMO SEGMENTO CORPORAL:  
INTERAÇÃO HUMANO-ROBÔ

Gustavo Fraga Millen da Silveira

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. Antonio Mauricio Ferreira Leite Miranda de Sá, D.Sc.

---

Prof. Carlos Julio Tierra-Criollo, D.Sc.

---

Prof. Flavio Fonseca Nobre, Ph.D.

---

Prof. Juliana Guimarães Martins Soares, Ph.D.

---

Prof. Paulo José Guimarães da Silva, D.Sc.

RIO DE JANEIRO, RJ – BRASIL  
JUNHO DE 2017

Silveira, Gustavo Fraga Millen da

Conectividade cerebral como característica para classificar tarefas motoras de mesmo segmento corporal: Interação humano-robô/Gustavo Fraga Millen da Silveira.

– Rio de Janeiro: UFRJ/COPPE, 2017.

XIX, 102 p.: il.; 29, 7cm.

Orientadores: Antonio Mauricio Ferreira Leite Miranda de Sá

Carlos Julio Tierra-Criollo

Dissertação (mestrado) – UFRJ/COPPE/Programa de Engenharia Biomédica, 2017.

Referências Bibliográficas: p. 87 – 97.

1. EEG. 2. Conectividade Cerebral. 3. Redes Neurais. 4. ICM. 5. Interação humano-robô. I. Sá, Antonio Mauricio Ferreira Leite Miranda de *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Biomédica. III. Título.

# Agradecimentos

Agradeço em primeiro lugar a Deus por me abençoar e me guiar em todas as etapas da minha vida.

Agradeço aos meus pais que sempre me incentivam a enfrentar de cabeça erguida os desafios da vida e me dão o exemplo de bondade e honestidade em tudo que fazem. Ao meu irmão, Jairo, que participa ativamente da minha formação com conselhos, ideias e seu aguçado senso crítico. Sou grato a ele e também à minha cunhada, Isabela, que sempre me acolhem com carinho quando preciso. Agradeço à minha namorada, Juliana, que, apesar da distância, está presente comigo em todos os momentos difíceis e sempre me apoiou em minhas decisões.

Sou grato aos meus orientadores, os professores Antonio Mauricio e Carlos Júlio, pela motivação em seguir trabalhando e buscando fazer o meu melhor.

Agradeço aos amigos que fiz no PEB, em especial os colegas do LAPIS, presentes em todas as etapas do mestrado e sempre me ajudando nas dificuldades.

Por fim, agradeço às agências CAPES, CNPq e FAPERJ pelo apoio financeiro que permitiu o desenvolvimento deste trabalho.

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

CONECTIVIDADE CEREBRAL COMO CARACTERÍSTICA PARA  
CLASSIFICAR TAREFAS MOTORAS DE MESMO SEGMENTO CORPORAL:  
INTERAÇÃO HUMANO-ROBÔ

Gustavo Fraga Millen da Silveira

Junho/2017

Orientadores: Antonio Mauricio Ferreira Leite Miranda de Sá  
Carlos Julio Tierra-Criollo

Programa: Engenharia Biomédica

A classificação de atividade motora baseada no Eletroencefalograma (EEG) tem sido amplamente estudada para auxiliar em aplicações de interfaces cérebro-máquina (ICMs). Classificar atividades motoras provenientes de mesmo membro corporal tem se mostrado um desafio, devido à representação espacial dessas atividades em locais próximos no córtex motor. Medidas de conectividade cerebral, tais como a Função de Transferência Direcionada (DTF) e a Coerência Direcionada Parcial (PDC), têm sido propostas para estimar os padrões de fluxo de informação no córtex durante a execução de diferentes tarefas motoras. O objetivo deste trabalho é investigar a DTF e a PDC como características para classificar, utilizando Redes Neurais Artificiais (ANN), a atividade motora de mesmo segmento de membro, bem como sua imaginação e observação. Os sinais de EEG de 12 indivíduos destros saudáveis foram coletados na tarefa de flexão e extensão de cotovelo seguindo um braço robótico como se fosse um espelho do seu próprio braço. A DTF e a PDC foram calculadas e comparadas estatisticamente em dois momentos: de um segundo antes da tarefa até seu início e do início da tarefa até dois segundos e meio depois. Foram encontradas diferenças significativas tanto para DTF quanto para PDC nos ritmos beta e gama do EEG. Finalmente, a DTF e PDC foram aplicadas separadamente como características em ANNs para classificar entre a imaginação, movimento e observação da flexão e extensão de cotovelo, e também a situação de repouso. O maior valor de acurácia encontrado utilizando a DTF foi de 90.6% no ritmo gama e utilizando a PDC foi de 97.0% no ritmo beta.

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 AS A FEATURE TO CLASSIFY SAME  
SEGMENT LIMB MOTOR TASKS: HUMAN-ROBOT INTERACTION

Gustavo Fraga Millen da Silveira

June/2017

Advisors: Antonio Mauricio Ferreira Leite Miranda de Sá  
Carlos Julio Tierra-Criollo

Department: Biomedical Engineering

Motor activity classification based on the Electroencephalogram (EEG) has been widely studied to assist brain-computer interfaces (BCIs). However, same limb motor activity classification still remains a challenge due to EEG close spatial representation on the motor cortex area in such case. Brain connectivity measurements, such as Directed Transfer Function (DTF) and Partial Directed Coherence (PDC), have been proposed to estimate information flow patterns in the cortex during different motor tasks. The objective of this paper is to evaluate both DTF and PDC as neuro network-based classification features for the same segment of limb motor activity (flexion and extension), and for both imagination and observation. EEG signals from 12 right-handed healthy subjects were recorded performing elbow flexion and extension following a robotic arm as if it were a mirror image of their own. The DTF and PDC were computed and statistically compared at two time instants: from 1 second before the task until the task and from the beginning of the task until 2.5 seconds later. Differences were found only in beta and gamma rhythms of EEG. Finally, both DTF and PDC were applied separately as features in ANN to classify between the imagination, movement and observation of elbow flexion and extension, and at rest. The highest accuracy using DTF was 90.6% achieved in the gamma rhythm and using PDC it was 97.0% in the beta rhythm.

# Sumário

<b>Lista de Figuras</b>	<b>ix</b>
<b>Lista de Tabelas</b>	<b>xv</b>
<b>Lista de Símbolos</b>	<b>xvi</b>
<b>Lista de Abreviaturas</b>	<b>xviii</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Objetivo . . . . .	4
1.1.1 Objetivos Específicos . . . . .	4
<b>2 Revisão Bibliográfica</b>	<b>5</b>
2.1 Fisiologia Neural do Sistema Motor . . . . .	5
2.1.1 Córtex Cerebral . . . . .	6
2.1.2 Eletroencefalografia . . . . .	8
2.1.3 Imagética Motora . . . . .	11
2.2 Interfaces Cérebro-Máquina . . . . .	11
2.2.1 Características utilizadas em ICMs . . . . .	14
2.3 Conectividade Cerebral . . . . .	15
2.3.1 Estimadores da Conectividade Cerebral . . . . .	16
2.3.2 Coerência . . . . .	17
2.3.3 Modelo Multivariado Autoregressivo . . . . .	17
2.3.4 Causalidade de Granger . . . . .	18
2.3.5 Função de Transferência Direcionada (DTF) . . . . .	19
2.3.6 Coerência Direcionada Parcial (PDC) . . . . .	20
2.4 Padrões de conectividade cerebral durante tarefas motoras . . . . .	21
2.5 Classificadores . . . . .	23
2.5.1 Árvores de Decisão . . . . .	24
2.5.2 Redes Neurais Artificiais . . . . .	27

<b>3</b>	<b>Materiais e Métodos</b>	<b>30</b>
3.1	Indivíduos . . . . .	30
3.2	Sinais de EEG . . . . .	31
3.3	Montagem do Experimento . . . . .	31
3.4	Tarefa Experimental . . . . .	32
3.5	Pré-processamento de Sinais . . . . .	32
3.6	Comparação da conectividade cerebral entre o momento anterior e a execução das tarefas motoras . . . . .	33
3.7	Classificação . . . . .	34
<b>4</b>	<b>Resultados</b>	<b>37</b>
4.1	Comparação da conectividade cerebral entre o momento anterior e a execução das tarefas motoras . . . . .	37
4.1.1	Função de Transferência Direcionada . . . . .	37
4.1.2	Coerência Direcionada Parcial . . . . .	57
4.2	Classificadores . . . . .	76
<b>5</b>	<b>Discussão e Conclusões</b>	<b>83</b>
	<b>Referências Bibliográficas</b>	<b>87</b>
<b>A</b>	<b>Artigo publicado no CBEB XXV - 2016</b>	<b>98</b>



# Lista de Figuras

2.1	Divisão do córtex cerebral segundo as áreas de Brodmann. Fonte: Henry Gray (1918) Anatomy of the Human Body. Domínio Público. As áreas de Brodmann indicam áreas do córtex com citoarquitetura diferente. Essa divisão é amplamente utilizada como referência para indicar funções e se referir às diferentes regiões do córtex. . . . .	6
2.2	Divisão do cérebro em lobos. Fonte: Henry Gray (1918) Anatomy of the Human Body. Domínio Público. . . . .	7
2.3	Distribuição de eletrodos para coleta de EEG segundo o sistema internacional 10-20. Domínio público. Os eletrodos no hemisfério esquerdo são identificados com números ímpares, os do hemisfério direito, com números pares, e os centrais, com a letra z. As primeiras letras dos eletrodos têm relação com as regiões da cabeça nas quais os eletrodos estão colocados em relação aos lóbulos cerebrais correspondentes. . .	10
2.4	Esquema da arquitetura de uma ICM. Com permissão de (ULLOA, 2013). O usuário veste uma touca de eletrodos conectada ao amplificador. Os dados de EEG são adquiridos no amplificador de biosinais onde ocorre a pré-filtragem e conversão analógico/digital. Os dados são passados ao computador, onde é feita a extração das características. Realiza-se a identificação de padrões das tarefas com base nas características. Um algoritmo de tradução classifica as tarefas e retorna ao atuador o comando de acordo com a tarefa identificada. . .	12
2.5	Exemplo de uma árvore de decisão binária com dados fictícios para demonstração. As entradas da árvore são altura (em cm) e peso (em kg). Os nós folha da árvore contém as variáveis de saída, os gêneros masculino e feminino. . . . .	24
2.6	Rede neural do tipo alimentação avante. Na estrutura de conexão da rede alimentação avante a informação é propagada somente em uma direção: partindo dos nós de entrada, através dos nós escondidos e chegando nos nós de saída. Não existem ciclos nem laços nesse tipo de estrutura. . . . .	28

3.1	Esquema de montagem do <i>setup</i> experimental, cadeira posicionada a 120 cm do braço robótico o que corresponde ao dobro do comprimento do braço que está preso a parede por um suporte tipo trilho (SILVA <i>et al.</i> , 2014). . . . .	31
3.2	Sequência de movimentos executados pelo robô durante a tarefa experimental. Com permissão de (ULLOA, 2013). O manipulador robótico aguarda por um tempo aleatório entre 8 e 12 segundos, realiza a flexão de cotovelo durante 2,5 segundos. Aguarda por um novo período aleatório entre 8 a 12 segundos e em seguida realiza a tarefa de extensão de cotovelo durante 2,5 segundos. A sequência é repetida 30 vezes para cada modalidade de tarefa (execução, imaginação e observação). . . . .	32
3.3	Topologia da ANN utilizada para classificar as tarefas. A rede apresenta 289 neurônios na camada de entrada, 10 neurônios na camada escondida e 7 neurônios na camada de saída. Os pesos e vieses da rede neural são representados por $W$ e $b$ , respectivamente. . . . .	36
4.1	Valores da DTF na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	39
4.2	Valores da DTF na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	40
4.3	Valores da DTF na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	42

4.4	Valores da DTF na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	43
4.5	Valores da DTF na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Movimento de Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	45
4.6	Valores da DTF na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Movimento de Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	46
4.7	Valores da DTF na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Movimento de Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	48
4.8	Valores da DTF na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Movimento de Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	49
4.9	Valores da DTF na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	51

4.10	Valores da DTF na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	52
4.11	Valores da DTF na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	54
4.12	Valores da DTF na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	55
4.13	Valores da PDC na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	58
4.14	Valores da PDC na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	59
4.15	Valores da PDC na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	61

4.16	Valores da PDC na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	62
4.17	Valores da PDC na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Movimento de Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	64
4.18	Valores da PDC na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Movimento de Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	65
4.19	Valores da PDC na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Movimento de Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	67
4.20	Valores da PDC na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Movimento de Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	68
4.21	Valores da PDC na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	70

4.22	Valores da PDC na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . . .	71
4.23	Valores da PDC na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . .	73
4.24	Valores da PDC na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa. . . .	74
4.25	Matriz de confusão geral do classificador por ANN do indivíduo S1 na banda gama, utilizando a PDC, em uma das classificações. As classes são de 1 a 7: IME, IMF, MVE, MVF, OBE, OBF, REP, respectivamente. . . . .	78

# Lista de Tabelas

4.1	Caminhos de fluxo de informação estatisticamente diferentes entre a momento anterior à execução da tarefa motora e sua execução, estimados pela DTF nos ritmos do EEG analisados. . . . .	38
4.2	Caminhos de fluxo de informação estatisticamente diferentes para a PDC nos ritmos do EEG analisados. . . . .	57
4.3	Acurácias e desvio padrão das Árvores de Decisão utilizando a DTF.	76
4.4	Acurácias e desvio padrão das Árvores de Decisão utilizando a PDC.	77
4.5	Acurácias e desvio padrão das Redes Neurais utilizando a DTF. . . .	79
4.6	Acurácia média das Redes Neurais utilizando a DTF, com diferentes números de amostras. . . . .	80
4.7	Acurácias e desvio padrão das Redes Neurais utilizando a PDC. . . .	80
4.8	Acurácia média das Redes Neurais utilizando a PDC, com diferentes números de amostras. . . . .	81
4.9	Acurácias e desvio padrão das Redes Neurais utilizando a energia do EEG. . . . .	82

# Lista de Símbolos

$A$	Coeficientes do modelo MVAR, p. 17
$E$	Erro de predição associado ao MVAR, p. 17
$G$	Custo Gini, p. 24
$G_{xx}$	Densidade espectral de $x$ , p. 16
$G_{xy}$	Densidade espectral cruzada, p. 16
$H$	Matriz de transferência do sistema do modelo MVAR na frequência, p. 17
$R(d)$	Estimativa de ressubstituição, p. 24
$R(d^k)$	Estimativa de erro numa $k$ -fold crossvalidation, p. 25
$\eta$	Taxa de aprendizagem do gradiente, p. 27
$\bar{A}_{ij}$	Coeficientes do modelo MVAR entre os canais $ij$ , p. 20
$\pi_{ij}$	Coerência Direcionada Parcial, p. 20
$\theta_{ij}^2$	DTF partindo do canal $j$ para o canal $i$ , p. 19
$\Delta w_{ij}$	Varição em cada peso calculada pelo Gradiente Descendente, p. 27
$\Sigma_w$	Matriz de covariância do vetor de inovações do modelo, p. 20
$\varepsilon(n)$	Erro na saída da rede neural, p. 27
$d^{(k)}$	Classificador da Árvore de Decisão calculado da sub amostra $Z - Z_k$ , p. 25
$d_j$	Valor alvo da rede, p. 27
$e_j$	Erro do nó de saída $j$ no dado $n$ , p. 27



$p$	Ordem do modelo MVAR, p. 17
$pk$	Número de instâncias de treinamento com classe $k$ no retângulo de interesse, p. 24
$y_j$	Valor produzido pelo <i>perceptron</i> , p. 27
$C_{xy}$	Coerência entre $x$ e $y$ , p. 16
$\gamma_{ij}^2$	Função de Transferência Direcionada normalizada, p. 19

# Lista de Abreviaturas

AIC	<i>Akaike Information Criterion</i> , p. 17
ANN	<i>Artificial Neural Networks</i> , p. 3
CART	<i>Classification and Regression Trees</i> , p. 21
CE	Conectividade Efetiva, p. 15
CF	Conectividade Funcional, p. 15
COEP	Comitê de Ética e Pesquisa, p. 28
CSP	<i>Common Spatial Patterns</i> , p. 14
DTF	<i>Directed Transfer Function</i> , p. 2
ECOG	Eletrocorticograma, p. 15
EEG	Eletroencefalograma, p. 2
EOG	Eletro-oculograma, p. 29
ERD	<i>Event Related Desynchronism</i> , p. 2
ERS	<i>Event Related Synchronism</i> , p. 2
FBCSP	<i>Filter-Bank Common Spatial Patterns</i> , p. 3
GCI	<i>Granger Causality Index</i> , p. 18
GDI	<i>Gini's Diversity Index</i> , p. 23
ICA	<i>Independent Component Analysis</i> , p. 58
ICM	Interfaces Cérebro-Máquina, p. 1
IME	Imaginação da extensão de cotovelo, p. 4
IMF	Imaginação da flexão de cotovelo, p. 4

IM	Imaginação Motora, p. 1
LAPIS	Laboratório de Processamento de Sinais e Imagens Médicas, p. 28
LDA	<i>Linear Discriminant Analysis</i> , p. 3
LFP	<i>Local Field Potentials</i> , p. 16
MEG	Magnetoencefalograma, p. 15
MLP	<i>Multilayer perceptron</i> , p. 26
MVAR	<i>Multivariate Autoregressive</i> , p. 2
MVE	Extensão de cotovelo, p. 4
MVF	Flexão de cotovelo, p. 4
OBE	Observação da extensão de cotovelo, p. 4
OBF	Observação da flexão de cotovelo, p. 4
PCA	<i>Principal Component Analysis</i> , p. 3
PDC	<i>Partial Directed Coherence</i> , p. 2
REP	Repouso, p. 4
RMS	<i>Root Mean Square</i> , p. 31
SNC	Sistema Nervoso Central, p. 6
SVM	<i>Support Vector Machines</i> , p. 3
Spec-CSP	<i>Spectrally Weighted Common Spatial Patterns</i> , p. 14
UFMG	Universidade Federal de Minas Gerais, p. 28
UFRJ	Universidade Federal do Rio de Janeiro, p. 28
fMRI	<i>Functional Magnetic Resonance Imaging</i> , p. 15

# Capítulo 1

## Introdução

Interfaces cérebro-máquina (ICMs) são sistemas que permitem controlar dispositivos eletrônicos ou atuadores eletromecânicos por meio de comandos identificados a partir de atividade cerebral voluntária. ICMs para assistência têm se mostrado uma opção viável para garantir uma melhor qualidade de vida a pessoas portadoras de limitações motoras, mas que possuem as funções cognitivas necessárias para usar uma ICM (BLASCO *et al.*, 2012; HOCHBERG *et al.*, 2012; MÜLLER *et al.*, 2011).

A identificação de um estado mental pela ICM depende da capacidade do usuário de controlar ou gerar uma resposta cerebral consistente e detectável por esta, assim como da capacidade da ICM lidar com eventuais variações nesta atividade. A baixa taxa de detecção ou classificação de estados mentais retarda o controle do dispositivo por meio de uma ICM, o que impede o funcionamento confortável e natural, levando ao cansaço e incômodo do usuário após certo tempo de uso (CECOTTI, 2011; WANG *et al.*, 2008).

ICMs baseadas na Imaginação Motora (IM) atualmente são limitadas pela imaginação de somente quatro movimentos: mão esquerda, mão direita, pé e língua (HAMEDDI *et al.*, 2016). Isso ocorre pois as áreas relacionadas às mãos, pés e língua são comparativamente grandes e topograficamente diferentes. Entretanto, ainda é um desafio o desenvolvimento de ICMs efetivas e flexíveis para controles complexos em aplicações práticas, devido ao limitado número de comandos no sistema. Mais comandos de controle permitiriam que uma ICM tivesse mais graus de liberdade.

A partir de sinais neurais adquiridos com eletrodos posicionados diretamente no tecido cortical (método invasivo), pesquisadores extraíram trajetórias e perfis de velocidade de movimentos da mão (HOCHBERG *et al.*, 2006; SERRUYA *et al.*, 2002; TAYLOR *et al.*, 2002; TRUCCOLO *et al.*, 2008; VELLISTE *et al.*, 2008; WESSBERG *et al.*, 2000). Cinemáticas da mão também foram extraídas

por potencial de campo intercraniano local obtidos através de eletrocorticografia (PISTOHL *et al.*, 2008; SANCHEZ *et al.*, 2008; SCHALK *et al.*, 2007).

A classificação da atividade motora baseada nos sinais de eletroencefalograma (EEG) é um tema amplamente estudado devido à sua relevância em aplicações de ICM (LIU *et al.*, 2015; YONG e MENON, 2015). Apesar de tal problema de classificação já ter sido bem estudado para sinais de atividades motoras em membros diferentes (CHEN *et al.*, 2012; LI *et al.*, 2013; SCHERER *et al.*, 2004; WANG *et al.*, 2006; WEI *et al.*, 2007), existem poucos estudos com resultados satisfatórios para atividades motoras no mesmo membro, pelo fato de que essas tarefas motoras ativam regiões que têm representações próximas na área do córtex motor (PLOW *et al.*, 2010; SANES *et al.*, 1995).

A partir de sinais de EEG, as análises do sincronismo (ERS, do inglês *Event Related Synchronism*) e o dessincronismo relacionados ao evento motor (ERD, do inglês *Event Related Desynchronism*) têm sido utilizadas para identificar a intenção de realizar ou imaginar uma determinada tarefa motora. Isso possibilitou o desenvolvimento de ICMs atuando num modelo tipo chave liga/desliga (PFURTSCHELLER e LOPES DA SILVA, 1999; PFURTSCHELLER e SOLIS-ESCALANTE, 2009; ULLOA, 2013). Contudo, utilizando-se somente esses parâmetros, não foi possível distinguir diferentes tarefas motoras realizadas pelo mesmo membro.

De modo a classificar diferentes tarefas motoras de mesmo segmento de membro de forma não invasiva, é necessário primeiramente serem estabelecidas características no dado sinal que permitam tal classificação. Alternativamente ao ERS e ERD, o mapeamento do controle motor por meio da conectividade entre regiões cerebrais vem sendo proposto (HAMED I *et al.*, 2016).

Entre as técnicas de análise da conectividade cerebral, métodos baseados na estimativa das funções de correlação/coerência entre atividades de pares de estruturas têm sido utilizadas. Técnicas multivariadas espectrais como a Função de Transferência Direcionada (DTF, do inglês *Directed Transfer Function*) (KAMINSKI e BLINOWSKA, 1991) e a Coerência Direcionada Parcial (PDC, do inglês *Partial Directed Coherence*) (BACCALÁ e SAMESHIMA, 1998) foram propostas para determinar as influências direcionais entre quaisquer pares de canais num conjunto de dados multivariado. Esses estimadores são capazes de avaliar relações de causalidade no domínio da frequência entre sinais cerebrais simultaneamente, requerendo somente que um modelo multivariado autoregressivo (MVAR) seja estimado para todos os canais de EEG gravados. Por causa disso, são capazes de decompor

as interações entre estruturas entre seus pares diretos de componentes, expondo detalhes adicionais da propagação do sinal entre estruturas. Diferentemente da coerência simples, a DTF e PDC não somente estimam a influência de dada região em outra, mas também a quantidade de energia transferida e a direção do fluxo de informação (BACCALÁ e SAMEISHIMA, 1998; KAMINSKI e BLINOWSKA, 1991).

Técnicas de estimativa da conectividade cerebral, como a DTF, foram utilizadas com sucesso na identificação do fluxo de informação nos sinais de EEG para a imaginação de movimentos do cotovelo em interação humano-robô, mostrando diferenças entre extensão, flexão e repouso baseado no fluxo de informação entre derivações centrais e frontais (SILVA *et al.*, 2014). Neste trabalho a DTF se mostrou promissora como característica para este tipo de aplicação, porém não foi realizada a classificação das tarefas motoras imaginadas.

Os dados de fluxo de informação obtidos por meio de estimadores de conectividade cerebral podem ser usados como um modelo a ser apresentado a um classificador para identificar que tipo de movimento deve ser executado pela ICM. Estudos mostram que classificadores como Redes Neurais Artificiais (ANN, do inglês *Artificial Neural Networks*), Máquinas de Vetores Suporte (SVM, do inglês *Support Vector Machines*), métodos que permitam a redução de dimensão, como a Análise de Componentes Principais (PCA, do inglês *Principal Component Analysis*) e o Discriminante Linear (LDA, do inglês *Linear Discriminant Analysis*), e Árvores de Decisão são usados para esse tipo de aplicação (KIM, 2010; YONG e MENON, 2015).

A classificação de diversas atividades motoras distintas no mesmo segmento corporal podem auxiliar ICMs com a capacidade de realizar comandos mais especializados. Este problema tem se apresentado como um desafio (HAMEDI *et al.*, 2016). Pesquisas recentes buscam resolvê-lo. A partir de sinais de EEG em tarefas de alcançar objetos com o braço, características extraídas por bancos de filtro para padrões especiais em comum (FBCSP, do inglês *Filter-Bank Common Spatial Patterns*) aplicadas a classificadores LDA levaram a acurácias de 50% para seis tarefas motoras diferentes (quatro possíveis alvos, retornar à posição inicial e repouso) (SHIMAN *et al.*, 2017). Utilizando características de sinais de EEG no domínio do tempo, pesquisadores chegaram a 74.2% de acurácia entre três classes de IM (repouso, aperto de mão e movimento de cotovelo) por meio de SVMs (TAVAKOLAN *et al.*, 2017). Os resultados apresentados nestes estudos são promissores, porém para aplicação confortável em ICM ainda não são ideais.

O estudo da interação humano-robô é fundamental para aplicações de ICMs que pretendem realizar diferentes tarefas motoras no mesmo segmento corporal. ULLOA (2013) investigou a ERS/ERD em sinais de EEG coletados em indivíduos guiados por um manipulador robótico nas seguintes modalidades de tarefa: execução, imaginação e observação da flexão e extensão de cotovelo. Porém esses parâmetros não permitiram a identificação entre a flexão e extensão de cotovelo e nem entre as diferentes modalidades de tarefas motoras (sete classes considerando o repouso). No protocolo anterior, a conectividade cerebral do ritmo alfa, estimada pela DTF, durante a imaginação dos movimentos foi estudada e encontrou-se diferentes padrões para flexão e extensão do cotovelo (SILVA *et al.*, 2014). Portanto, justifica-se a investigação do desempenho da conectividade cerebral, nos diferentes ritmos cerebrais, na classificação das sete classes supracitadas.

## 1.1 Objetivo

O objetivo principal deste trabalho é investigar a conectividade cerebral, estimada pela DTF e PDC, por meio dos sinais de EEG coletados em interação humano-robô, como característica para classificar diferentes tarefas: execução, imaginação e observação da flexão e extensão de cotovelo além do repouso, para auxiliar no desenvolvimento de ICMs com comandos de controle mais especializados.

### 1.1.1 Objetivos Específicos

- Investigar diferenças na conectividade cerebral, estimadas pela DTF e PDC, entre a preparação e a execução da tarefa.
- Desenvolver um classificador para identificar as sete tarefas motoras realizadas no mesmo segmento corporal: extensão e flexão do cotovelo direito (MVE e MVF), imaginação da extensão e flexão do cotovelo direito (IME e IMF), observação da extensão e flexão do cotovelo direito (OBE e OBF) e repouso (REP).
- Comparar os estimadores da conectividade cerebral: DTF e PDC, e a energia dos sinais de EEG como característica para o classificador.
- Comparar a classificação por Árvores de Decisão e por ANN.
- Investigar como a acurácia do classificador se comporta quando se altera o número de amostras por tarefa utilizadas como característica.

# Capítulo 2

## Revisão Bibliográfica

Nesta seção, são detalhados os fundamentos teóricos para a realização do trabalho.

### 2.1 Fisiologia Neural do Sistema Motor

O sistema motor abrange o conjunto de estruturas anatômicas e interações fisiológicas que permitem a execução de movimentos (KANDEL *et al.*, 2000). Nos humanos, assim como em outros seres vivos, o sistema motor tem uma organização hierárquica. Os músculos encarregados de produzir o movimento encontram-se em um dos extremos desta hierarquia. No outro extremo, encontra-se o encéfalo, cuja camada mais externa, o córtex cerebral, corresponde ao topo da hierarquia, onde são integradas informações sensoriais e memória para produzir a grande variedade de comportamentos motores que o ser humano é capaz de realizar (KANDEL, 2007; KANDEL *et al.*, 2000; PASCUAL-LEONE *et al.*, 2005).

Entre os extremos do sistema motor, músculos e córtex cerebral, encontra-se um sistema de suporte e funcionalidade progressivamente mais complexo e especializado. Após os músculos, circuitos motores na medula espinhal ligam vários tipos de neurônios. Esses circuitos estão encarregados de produzir movimentos reflexos, que podem ser regulados para gerar padrões de movimentos voluntários.

Subindo na hierarquia, o cerebelo, núcleos basais e outras estruturas localizadas no tálamo permitem a coordenação, modulação, percepção e aprendizado de comportamentos motores (BEAR *et al.*, 2007; KANDEL *et al.*, 2000). A seguir, é detalhado o córtex cerebral com ênfase no córtex motor, estrutura importante para este trabalho.



### 2.1.1 Córtex Cerebral

O córtex cerebral corresponde à camada mais externa do encéfalo humano e contém uma alta densidade de neurônios, sendo a parte do cérebro envolvida nos aspectos mais complexos de cognição humana, incluindo os comportamentos motores. Apesar de o córtex trabalhar de forma integrada, pode ser dividido de acordo com regiões especializadas em tarefas específicas. Essa especialização, chamada de segregação funcional do córtex, foi comprovada por experimentos usando estímulos aferentes (em direção ao SNC) ou eferentes (que parte do SNC) aplicados a diferentes regiões do córtex, que reportaram as áreas mais responsivas a esses estímulos (KANDEL *et al.*, 2000). Na figura 2.1, apresenta-se uma divisão do córtex, chamada de divisão por áreas de Brodmann, que indicam áreas do córtex com citoarquitetura diferente. As áreas de Brodmann são amplamente usadas como referência para indicar funções e se referir às diferentes regiões do córtex.




Figura 2.1: Divisão do córtex cerebral segundo as áreas de Brodmann. Fonte: Henry Gray (1918) *Anatomy of the Human Body*. Domínio Público. As áreas de Brodmann indicam áreas do córtex com citoarquitetura diferente. Essa divisão é amplamente utilizada como referência para indicar funções e se referir às diferentes regiões do córtex.

Uma tarefa motora, seja executada, observada ou imaginada (PINEDA *et al.*, 2000), gera padrões de atividade espalhada por grande parte do córtex com focos nas regiões central, pré-frontal, parietal e occipital (Figura 2.2). O córtex motor primário (área de Brodmann 4) está relacionado com aspectos mais básicos do movimento (por exemplo, direção e velocidade), sendo a área do córtex que comanda a execução do movimento voluntário. O córtex motor primário está ligado

diretamente com a medula espinhal, formando uma via mais longa de conexão neuromuscular, chamada de trato corticoespinhal, que vai desde o córtex e chega aos motoneurônios na medula, o que permite a execução de movimentos comandados diretamente pelo córtex cerebral (BEAR *et al.*, 2007; HOCHBERG *et al.*, 2012; KANDEL *et al.*, 2000).




Figura 2.2: Divisão do cérebro em lobos. Fonte: Henry Gray (1918) *Anatomy of the Human Body*. Domínio Público.

O córtex motor primário possui uma distribuição somatotópica, ou seja, diferentes partes do corpo estão representados em locais específicos dessa área. Neurônios em vários locais do córtex motor primário estão representados num mesmo local no corpo, sendo assim, a distribuição somatotópica dessa área não é um arranjo ordenado, mas um “mosaico”, que, presumidamente, ajuda na construção de comportamentos motores complexos (KANDEL *et al.*, 2000).

Outras regiões do córtex fortemente associadas com o movimento são as regiões pré-frontal e parietal. A área motora suplementar e área pré-motora (localizadas na área 6 de Brodmann) são consideradas como áreas de associação e preparação do movimento (FILHO *et al.*, 2009; KALCHER e PFURTSCHELLER, 1995; PFURTSCHELLER *et al.*, 1996). A resposta relacionada com a preparação do movimento é também refletida, porém com menor intensidade, no córtex motor primário (HATSOPOULOS *et al.*, 2004; KANDEL *et al.*, 2000; MACHADO, 2005; WESSBERG *et al.*, 2000).

A área motora pré-frontal e a área parietal ajudam na integração de informações sensoriais para a geração de comportamentos motores. As áreas 5 e 7 de Brodmann

estão envolvidas na atenção, integração sensorial múltipla e planejamento motor (BEHRMANN *et al.*, 2004). A área 46 de Brodmann projeta-se na parte ventral da área pré-motora e ajuda na memória de trabalho para o planejamento motor.

## 2.1.2 Eletroencefalografia

A eletroencefalografia (EEG) é uma técnica por meio da qual uma amostragem espacial da distribuição de potencial elétrico, gerado por grandes grupos de neurônios com árvores de dendritos perpendiculares ao crânio, é adquirida em diferentes regiões do escalpo. No EEG, a distribuição de potencial é captada no couro cabeludo, por meio do uso de eletrodos, gerada pelo campo eletromagnético produzido pelos potenciais pós-sinápticos (NIEDERMEYER e DA SILVA, 2005).

Para melhorar o contato entre a pele e o eletrodo, geralmente, é usado um gel ou pasta condutiva, que uniformiza e acopla a impedância na interface pele-eletrodo, além de permitir a transdução da corrente iônica, no neurônio, para corrente elétrica conduzida pelo eletrodo. Por causa da atenuação provocada pelas estruturas pelas quais o campo elétrico deve passar (osso, tecido e fluidos), o sinal de EEG tem uma amplitude que só alcança algumas dezenas de microvolts, em torno de dez vezes menor que a amplitude que pode ser registrada diretamente no córtex, motivo pelo qual o sinal captado no couro cabeludo por meio dos eletrodos deve ser amplificado e filtrado, devido ao ruído, antes de ser adquirido por um equipamento digital (ALLISON, 2003; CHAPMAN *et al.*, 2006; GULRAJANI, 1998; NUWER *et al.*, 1998).

Já no eletrodo, a corrente elétrica é conduzida ao equipamento de amplificação, que é também encarregado de isolar eletricamente o voluntário do equipamento, amplificar o sinal, filtrar as frequências baixas (especialmente a componente contínua presente pela polarização do eletrodo) e filtrar as componentes de alta frequência, adequando o sinal para a digitalização (NIEDERMEYER e DA SILVA, 2005).

Após passar por filtragem analógica, o sinal de EEG dos eletrodos é finalmente digitalizado. Para manter uma boa resolução na amplitude do EEG, é recomendável que a digitalização seja feita com um conversor de, no mínimo, 16 bits e, para registrarem os diferentes ritmos cerebrais, deve-se usar uma frequência de amostragem adequada para a frequência do EEG (entre 1 e 100 Hz), não maior que 1 kHz para estudos de respostas cognitivas (ALLISON, 2003; NUWER *et al.*, 1998).

O espalhamento da atividade elétrica do córtex através do líquido cefalorraquidiano, osso e tecido provoca também uma perda da especificidade das medições de EEG por uma sobreposição de atividade de várias áreas adjacentes sobre o sinal captado por um eletrodo (fenômeno conhecido como “volume condutor”). Assim, o sinal de cada eletrodo de EEG reflete atividade de uma região maior do que ele cobre e não somente a atividade da população de neurônios exatamente subjacente a ele. Apesar dessas limitações, o EEG é uma opção viável para registro de atividade cerebral por seu baixo custo, se comparado com outros métodos de medição de atividade cerebral, sua usabilidade, possibilidade de utilização em aplicações em tempo real, alta resolução temporal, e principalmente pelo fato de ser um método não invasivo (ALLISON, 2003; CHAPMAN *et al.*, 2006).

Como visto na seção anterior, várias áreas do córtex cerebral são mais responsivas do que outras a estímulos ou tarefas específicas. Assim, é desejável que um registro de EEG capte a atividade de várias áreas no couro cabeludo para explorar da melhor maneira possível as respostas geradas pelas atividades investigadas e as áreas associadas. O sistema internacional 10-20 de posicionamento de eletrodos para EEG é uma das opções para captação de EEG e o padrão usado neste projeto. O sistema 10-20 permite abranger quase todas as áreas com significado eletrofisiológico cerebral com poucos eletrodos. A figura 2.3 mostra a disposição de eletrodos para EEG segundo o sistema internacional 10-20. Os eletrodos no hemisfério esquerdo são identificados com números ímpares, os do hemisfério direito, com números pares, e os centrais, com a letra z (de zero para indicar posição sobre a linha média). As primeiras letras dos eletrodos têm relação com as regiões da cabeça nas quais os eletrodos estão colocados em relação aos lóbulos cerebrais correspondentes. Assim, F indica a região frontal, C a região central, T a região temporal, P a região parietal e O a região occipital (ALLISON, 2003; NUWER *et al.*, 1998).

O sinal de EEG é caracterizado por ritmos em diferentes bandas de frequência. Cada banda é associada a condições e funções particulares. É comum dividir o EEG em cinco bandas de frequência: (1) banda delta (0,1-4 Hz); (2) banda teta (4-8 Hz); (3) banda alfa (8-14 Hz); (4) banda beta (14-30 Hz) e (5) banda gama (maior que 30 Hz). Em um adulto neurologicamente saudável, existe presença do ritmo alfa em todas as regiões, assim como ritmos delta, beta e, ocasionalmente, teta na faixa de 6-7 Hz. A banda gama é difícil de ser encontrada nos registros de EEG, devido à sua baixa amplitude provocada pela atenuação do sinal do córtex até chegar à superfície (CHAPMAN *et al.*, 2006; LEBEDEV e NICOLELIS, 2006).




Figura 2.3: Distribuição de eletrodos para coleta de EEG segundo o sistema internacional 10-20. Domínio público. Os eletrodos no hemisfério esquerdo são identificados com números ímpares, os do hemisfério direito, com números pares, e os centrais, com a letra z. As primeiras letras dos eletrodos têm relação com as regiões da cabeça nas quais os eletrodos estão colocados em relação aos lóbulos cerebrais correspondentes.

Bandas de maior frequência apresentam progressivamente menor potência, possivelmente pelo fato de que menos neurônios são recrutados para realizar funções mais complexas e que requerem processamento mais especializado, localizado e rápido (VIDAL, 1973).

Devido à amplitude consideravelmente baixa, o sinal de EEG é altamente suscetível a interferências, chamadas de artefatos, de natureza variada. Movimentos (incluindo o movimento ocular) do usuário provocam componentes de alta amplitude, em relação à amplitude do sinal de EEG, em frequência baixa (menor que 10 Hz) assim como frequência alta (maior que 30 Hz). O movimento do usuário, especialmente de músculos próximos à cabeça, representa um artefato de difícil tratamento por se encontrar na banda de frequências responsivas do EEG, em especial as respostas presentes nos ritmos lentos menores que 10 Hz (CHAPMAN *et al.*, 2006; FATOURECHI *et al.*, 2007; NUWER *et al.*, 1998). Interferências externas, como equipamentos elétricos e eletromecânicos, provocam componentes na frequência da alimentação de energia (50 ou 60 Hz).

### 2.1.3 Imagética Motora

IM é a representação mental do movimento sem este ocorrer efetivamente. A imagética motora corresponde a uma operação cognitiva complexa, autogerada, que utiliza processos sensoriais e perceptuais, permitindo a reativação de ações motoras específicas, dentro da memória de trabalho (DICKSTEIN e DEUTSCH, 2007).

A imagética motora também pode ser definida como a capacidade de simular o movimento corporal, sem ser manifesta como movimento físico. Este processo apresenta uma variedade subjacente de comportamentos cognitivos e motores, incluindo a observação da ação, operação mental cognitiva e planejamento de movimentos em cadeia aberta (HANAKAWA *et al.*, 2008).

Estudos que medem atividade eletroencefalográfica, potenciais corticais motores evocados e fluxo sanguíneo cerebral mostram que, durante a prática mental, ativações correlativas ao movimento ocorrem ao nível cortical. O sistema neural utilizado no controle da ação é efetivamente ativado durante a imaginação dessas mesmas ações sem que ocorra movimento (DE VRIES e MULDER, 2007). As áreas motoras mais envolvidas na imagética motora são as áreas de planejamento da ação e de controle do movimento, incluindo o córtex pré-motor e pré-frontal, o córtex motor primário, a porção posterior do lobo parietal, o cerebelo e os gânglios da base (MILLER *et al.*, 2010).

Pesquisas de IM de tarefas complexas com atletas e não-atletas detectaram alterações nas respostas corticais ao redor do pico de alfa (STECKLOW *et al.*, 2010). Em indivíduos pós-AVC, a prática mental orientada à tarefa, quando associada à fisioterapia convencional, levou a melhoras, resultando em maior destreza e velocidade na execução de atividades diárias (SANTOS-COUTO-PAZ *et al.*, 2013). Recentemente, pesquisadores mostraram que a prática mental orientada à tarefa motora de marcha, permitiu que amputados transtibiais melhorassem o controle da prótese (CUNHA *et al.*, 2017).

## 2.2 Interfaces Cérebro-Máquina

Considera-se uma interface cérebro-máquina (ICM) todo tipo de dispositivo eletrônico ou eletromecânico que é comandado por meio de atividade cerebral de um usuário (CECOTTI, 2011; FATOURECHI *et al.*, 2007; LEBEDEV e NICOLELIS, 2006).

As ICMs, com base no seu método de registro da atividade cerebral, podem ser classificadas em dois grupos: invasivas e não invasivas. As primeiras fazem uso de eletrodos posicionados diretamente no córtex cerebral, registrando a atividade de grupos reduzidos de neurônios ou até mesmo de um único neurônio, o que fornece um registro da atividade cerebral altamente especializado (CHAPIN *et al.*, 1999; HOCHBERG *et al.*, 2012). As ICMs não invasivas registram a atividade cerebral por meio do EEG, com eletrodos colocados no couro cabeludo abrangendo milhões de neurônios, e dessa forma apresentam baixa especialização da atividade captada (ALLISON *et al.*, 2012; DOUD *et al.*, 2011; HWANG *et al.*, 2012; NUWER *et al.*, 1998).

A figura 2.4 apresenta um esquema da arquitetura de uma ICM, com base no proposto por (WOLPAW *et al.*, 2002).

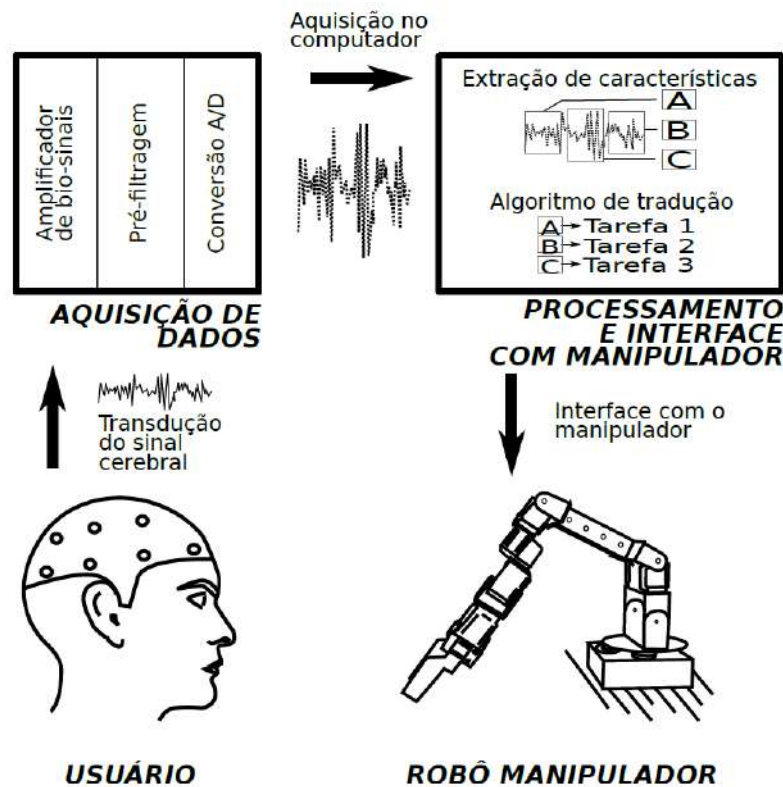


Figura 2.4: Esquema da arquitetura de uma ICM. Com permissão de (ULLOA, 2013). O usuário veste uma touca de eletrodos conectada ao amplificador. Os dados de EEG são adquiridos no amplificador de bio-sinais onde ocorre a pré-filtragem e conversão analógico/digital. Os dados são passados ao computador, onde é feita a extração das características. Realiza-se a identificação de padrões das tarefas com base nas características. Um algoritmo de tradução classifica as tarefas e retorna ao atuador o comando de acordo com a tarefa identificada.

A etapa de aquisição de dados tem como objetivo registrar e digitalizar a atividade cerebral do usuário da ICM tornando disponíveis os sinais para serem processados no computador. Após o registro dos sinais, estes podem ser processados e analisados para extrair características que estejam relacionadas àquele estado mental, permitindo então gerar comandos para controlar o dispositivo através da ICM. As características extraídas podem então ser classificadas por um algoritmo de detecção de padrões que então envia um comando para a execução de uma tarefa específica pelo dispositivo final (WOLPAW *et al.*, 2002).

A identificação do estado mental depende da capacidade do usuário de gerar uma resposta cerebral, assim como a capacidade da ICM de lidar com a variabilidade da atividade cerebral. Um dos problemas recorrentes dessas soluções é a dificuldade de controle dos dispositivos devido à baixa taxa de classificação dos estados mentais, o que deixa o usuário desconfortável após certo período de uso. A baixa taxa de detecção se dá, entre outros fatores, pela complexidade inerente à atividade cerebral humana (CECOTTI, 2011; WANG *et al.*, 2008).

A variabilidade entre indivíduos e a própria variabilidade do mesmo indivíduo fazem com que o uso de uma ICM dependa de um treinamento prévio para adaptar seu funcionamento ao usuário. Assim, o uso de uma ICM é considerada uma habilidade, e na medida em que o usuário se adapta ao sistema, ganha mais controle sobre ele ao conseguir aumentar a separabilidade dos padrões e diminuir a variabilidade das suas respostas cerebrais (WOLPAW *et al.*, 2002).

Métodos invasivos de captação dos sinais diretamente do córtex cerebral são uma opção para implementação de ICMs. O implante dos eletrodos utilizados nesses métodos requer um procedimento cirúrgico, devendo assim serem considerados seus riscos inerentes (HOCHBERG *et al.*, 2012).

A principal técnica de medição de atividade cerebral para o desenvolvimento de ICMs não invasivas é o EEG. Um dos desafios do desenvolvimento de ICMs desse tipo é a extração de características. A quantidade de interferências, tanto fisiológicas como ambientais, assim como a pouca seletividade das áreas registradas por meio de sinais de EEG (baixa resolução espacial do EEG), diminuem a qualidade e especificidade das fontes cerebrais dos sinais registrados, dificultando a identificação de padrões precisos. Porém, os avanços na tecnologia computacional têm viabilizado a aplicação de métodos matemáticos que permitem uma identificação e detecção aceitável de condições para o uso de ICMs (HWANG *et al.*, 2012; PFURTSCHELLER e LOPES DA SILVA, 1999). Ainda assim, muita pesquisa



e desenvolvimento são necessários para chegar em uma ICM para assistência de pessoas com deficiências motoras que seja confiável, segura e eficiente (CECOTTI, 2011).

### 2.2.1 Características utilizadas em ICMs

Esta seção tem como objetivo apresentar algumas das diversas características que têm sido estudadas para aplicações em ICMs, especialmente para realização de tarefas motoras de mesmo membro.

A maioria dos estudos de ICMs baseadas em IM utilizam como características extraídas: a energia de bandas de frequência do EEG (PFURTSCHELLER e NEUPER, 2001), coeficientes do modelo autoregressivo (ANDERSON *et al.*, 1998; DORNHEGE *et al.*, 2004; HUAN e PALANIAPPAN, 2004) e *Common Spatial Patterns* (MÜLLER-GERKING *et al.*, 1999; RAMOSER *et al.*, 2000).

No âmbito de ICMs de tarefas motoras de mesmo membro, diversas abordagens com sinais de EEG estão sendo investigadas. YONG e MENON (2015) buscaram classificar três modalidades de IM (repouso, aperto de mão e movimento de cotovelo) utilizando a energia do EEG em classificadores LDA, obtendo 60.7% de acurácia. TAVAKOLAN *et al.* (2017) utilizaram características temporais (coeficientes AR, comprimento de onda e valor RMS) em classificadores SVM para distinguir entre três modalidades de IM (repouso, aperto de mão e movimento do cotovelo), e obtiveram 74.2% de acurácia. Os autores também afirmaram que as características temporais superaram padrões especiais comuns (CSP, do inglês *Common Spatial Patterns*) e a energia do EEG no desempenho da classificação (aproximadamente 50% de acurácia para ambos). SHIMAN *et al.* (2015) estudaram inicialmente os padrões especiais comuns ponderados espectralmente (Spec-CSP, do inglês *Spectrally Weighted Common Spatial Patterns*) como característica em classificadores LDA, e obtiveram acurácia média de 39.5% para cinco movimentos de mesmo membro (alcançar quatro alvos com o braço, repouso). Em uma publicação mais recente, os pesquisadores utilizaram padrões especiais comuns com banco de filtros (FBCSP, do inglês *Filter Bank Common Spatial Patterns*) como característica em classificadores LDA e obtiveram 50% de acurácia para seis movimentos de mesmo membro (alcançar quatro alvos com o braço, retorno à posição inicial e repouso) (SHIMAN *et al.*, 2017).

Em protocolos com interação humano-robô e investigação de tarefas motoras de mesmo segmento de membro, a ERS/ERD de sinais de EEG coletados de voluntários guiados por um manipulador robótico, foi estudada por LANA *et al.* (2013). Porém, não foi possível distinguir entre as tarefas de execução, imaginação e observação da flexão e extensão de cotovelo. No protocolo anterior, a conectividade cerebral do ritmo alfa, estimada pela DTF, durante a imaginação dos movimentos foi estudada e encontraram-se diferentes padrões para flexão e extensão do cotovelo (SILVA *et al.*, 2014). Outro estudo recente, utilizando os mesmos sinais de EEG, foi realizado pelos presentes autores, e, utilizando a DTF em ANN, foi possível atingir acurácias próximas a 100% na classificação, de três classes, entre as tarefas de IM e repouso (SILVEIRA *et al.*, 2016). O artigo se encontra no anexo A desta dissertação.

No presente trabalho, serão analisadas sete modalidades de tarefa motora, compreendendo além das tarefas de execução, imaginação e repouso, também a observação. Pesquisadores analisaram recentemente a atividade espectral e conectividade cerebral durante a execução e observação de movimentos do braço e da perna (KLINE *et al.*, 2016). Na tarefa de observação dos movimentos não foram encontradas flutuações na atividade espectral, porém a conectividade cerebral exibiu flutuações para essa tarefa. Esses resultados suportam a relevância da análise da conectividade cerebral em prover informações verdadeiras da atividade cerebral, durante as diferentes modalidades de tarefa motora.

## 2.3 Conectividade Cerebral

A conectividade cerebral é definida como a interação entre as estruturas do cérebro e como estas influenciam ou são influenciadas durante tarefas sensoriais ou cognitivas, podendo ser dividida em conectividade funcional (CF) e conectividade efetiva (CE) (ROSSO *et al.*, 2013). Por CF entende-se a dependência entre eventos remotos baseados em cálculos estatísticos, ou seja, é regida pelos dados (FALLANI *et al.*, 2013). A CE é a influência direta, de uma estrutura ou grupo de estruturas, sobre outra região, sendo dada por um modelo causal ou noção intuitiva, ou seja, baseada em modelos predeterminados (FALLANI *et al.*, 2013; FRISTON, 2011).

Os meios mais utilizados para se mensurarem os parâmetros de conectividade cerebral são: a ressonância magnética funcional (fMRI) (FALLANI *et al.*, 2013; ROSSO *et al.*, 2013), eletrocorticograma (ECoG), eletroencefalograma (EEG) (FALLANI *et al.*, 2013; PAZ *et al.*, 2012) e magnetoencefalograma (MEG) (FALLANI *et al.*, 2013).

Desde o início dos anos oitenta, existiram diversas tentativas de se encontrar um estimador que descrevesse a propagação do sinal (INOUYE *et al.*, 1995; SAITO e HARASHIMA, 1981), entretanto, os estimadores propostos eram capazes de calcular somente o sentido entre dois canais por vez. Foi mostrado em (BLINOWSKA *et al.*, 2004; KUS *et al.*, 2004) que métodos bivariados de estimação do sentido da propagação podem fornecer resultados enganosos, não importando se são baseados nas fases das coerências bivariadas ou na medida de Causalidade de Granger bivariada (GRANGER, 1969).

Um estimador de propagação multivariado, chamado Função de Transferência Direcionada (DTF), é designado para um número arbitrário de canais e foi introduzido em 1991 (KAMINSKI e BLINOWSKA, 1991). A DTF foi aplicada com sucesso na identificação de focos epiléticos (FRANASZCZUK e BERGEY, 1998), na determinação da propagação de Potenciais de Campo Local (LFP, do inglês *Local Field Potentials*) entre estruturas do cérebro de animais em diferentes estados comportamentais (KORZENIEWSKA *et al.*, 1997) e para investigar a propagação do EEG em diferentes estados do sono (KAMIŃSKI *et al.*, 1997).

### 2.3.1 Estimadores da Conectividade Cerebral

De modo geral, estuda-se a conectividade cerebral utilizando-se a coerência ordinária entre sinais de EEG. Neste método é estimado o acoplamento de dois sinais em uma frequência, refletindo a cooperação destas regiões durante a execução de uma tarefa (KORZENIEWSKA *et al.*, 2003; LI *et al.*, 2013). Porém, analisar a conectividade por meio dos métodos de coerência não fornece parâmetros de sentido e intensidade do fluxo de informação entre as regiões (LI *et al.*, 2013).

Para se obterem tais parâmetros, atualmente, são utilizados métodos como a DTF (KAMINSKI e BLINOWSKA, 1991) e a PDC (BACCALÁ e SAMESHIMA, 1998), extensões da Causalidade de Granger (GRANGER, 1969).

### 2.3.2 Coerência

A coerência entre dois sinais  $x(t)$  e  $y(t)$  é uma função real que é definida como (BENDAT e PIERSOL, 2011):

$$C_{xy}(f) = \frac{|G_{xy}|^2}{G_{xx}(f)G_{yy}(f)} \quad (2.1)$$

Onde  $G_{xy}(f)$  é a densidade espectral cruzada entre  $x(t)$  e  $y(t)$ , e  $G_{xx}(f)$  e  $G_{yy}(f)$ , a densidade espectral de  $x(t)$  e  $y(t)$  respectivamente. A magnitude da densidade espectral é denotada  $|G|$ . Dadas as restrições (ergodicidade, linearidade) a função coerência estima a quantidade que  $y(t)$  pode ser predita por  $x(t)$  por uma função linear ótima de mínimos quadrados.

Valores de coerência são  $0 \leq C_{xy}(f) \leq 1$ . Se  $C_{xy}(f)$  é menor que um e maior que zero isso pode indicar que: ruído está presente nas medidas, a função assumida que relaciona  $x(t)$  e  $y(t)$  é não linear, ou que  $y(t)$  está produzindo aquela saída devido a entrada de  $x(t)$  bem como outras entradas. Se a coerência é igual a zero, é uma indicação que  $x(t)$  e  $y(t)$  são completamente descorrelacionados (BENDAT e PIERSOL, 2011).

A coerência de um sistema linear então representa o percentual que o sinal de saída é produzido pelo sinal de entrada naquela frequência. Pode-se também ver a quantidade  $(1 - C_{xy})$  como uma estimativa do percentual de energia da saída que não é contribuição da entrada numa dada frequência.

### 2.3.3 Modelo Multivariado Autoregressivo

Um processo de  $k$ -canais pode ser representado como a matriz  $\mathbf{X}$  de  $k$  sinais de EEG registrados no tempo:  $\mathbf{X}(t) = (X_1(t), X_2(t), \dots, X_k(t))^T$ , onde  $T$  denota a matriz transposta. Então o modelo MVAR pode ser expresso como:

$$\mathbf{X}(t) = \sum_{l=1}^p \mathbf{A}_1(l)\mathbf{X}(t-l) + \mathbf{E}(t) \quad (2.2)$$

Onde  $\mathbf{X}(t)$  é a matriz de dados no tempo  $t$ ,  $\mathbf{E}(t)$  é a matriz de valores do ruído branco residual,  $\mathbf{A}_1$  é uma matriz  $(k, p)$  com os coeficientes do modelo,  $p$  é a ordem do modelo e  $l$  é o atraso.

A ordem do modelo pode ser determinada por meio do critério de informação Akaike (AIC, do inglês *Akaike Information Criterion*) (AKAIKE, 1974) e os coeficientes do modelo são encontrados ao minimizar o ruído residual. No processo a matriz de correlação entre os sinais é calculada. Calculando-se a transformada de Fourier em ambos os lados da equação 2.2, o valor da transformada de  $\mathbf{X}(t)$  pode ser expresso como:

$$\mathbf{X}(f) = \mathbf{A}^{-1}\mathbf{E}(f) = \mathbf{H}(f)\mathbf{E}(f) \quad (2.3)$$

Onde  $\mathbf{A}$  é a matriz  $\mathbf{A}_1$  acrescida de uma primeira linha com  $p$  valores iguais a  $-1$ .  $\mathbf{H}(f)$  é a matriz de transferência do sistema, onde  $f$  denota frequência, ela contém informações a respeito das relações entre sinais e suas características espectrais.

### 2.3.4 Causalidade de Granger

WIENER (1956) reconheceu a importância da ordem temporal na inferência de relações causais partindo de um ponto de vista puramente estatístico e propôs que, para duas séries temporais medidas simultaneamente, uma série pode ser chamada causal à outra se é possível melhorar a predição da segunda série ao incorporar informações da primeira. Esse conceito foi adotado e formalizado mais tarde por GRANGER (1969) no contexto de modelos de regressão linear de processos estocásticos. Especificamente, se a variância do erro de predição da segunda série temporal no tempo presente é reduzida ao incluir medidas passadas da primeira série temporal no modelo de regressão linear, então é possível dizer que a primeira série temporal causa a segunda.

Sejam  $X_1(t)$  e  $X_2(t)$  séries temporais provenientes de dois canais de dados. Supõe-se que as dinâmicas temporais de  $X_1(t)$  e  $X_2(t)$  possam ser representadas no seguinte processo autorregressivo bivariado:

$$X_1(t) = \sum_{l=1}^p A_{11}(l)X_1(t-l) + \sum_{l=1}^p A_{12}(l)X_2(t-l) + E_1(t) \quad (2.4)$$

$$X_2(t) = \sum_{l=1}^p A_{21}(l)X_1(t-l) + \sum_{l=1}^p A_{22}(l)X_2(t-l) + E_2(t) \quad (2.5)$$

Se a variância do erro de predição  $E_1$  (ou  $E_2$ ) é reduzida pela inclusão dos termos  $X_2$  (ou  $X_1$ ) na primeira (ou segunda) equação, então, baseado na Causalidade de Granger, pode-se dizer que  $X_2$  (ou  $X_1$ ) causa  $X_1$  (ou  $X_2$ ).

As medidas baseadas no princípio da Causalidade de Granger são: Índice de Causalidade de Granger (GCI, do inglês *Granger Causality Index*), DTF e PDC. Essas medidas são definidas na estrutura do modelo MVAR (BLINOWSKA e KAMIŃSKI, 2006).

### 2.3.5 Função de Transferência Direcionada (DTF)

Na definição de Causalidade de Granger da seção anterior apenas dois canais são considerados. Aqui é descrito um método multivariado que fornece informação direcional par-a-par proveniente de um modelo MVAR que modela um grande número de canais. Seja  $\mathbf{X}(t) = [X_1(t), X_2(t), \dots, X_k(t)]^T$  a medida proveniente de  $k$  canais num tempo  $t$ . Aqui  $T$  denota a transposição do vetor. Suponha que  $\mathbf{X}(t)$  seja adequadamente descrito pelo seguinte modelo MVAR:

$$\mathbf{X}(t) = \sum_{l=1}^p \mathbf{A}(l)\mathbf{X}(t-l) + \mathbf{E}(t) \quad (2.6)$$

Transformando essa equação para o domínio da frequência traz:

$$\mathbf{A}(f)\mathbf{X}(f) = \mathbf{E}(f) \quad (2.7)$$

A equação pode então ser reescrita como:

$$\mathbf{X}(f) = \mathbf{A}^{-1}(f)\mathbf{E}(f) = \mathbf{H}(f)\mathbf{E}(f) \quad (2.8)$$

Onde  $\mathbf{H}$  é a matriz de transferência do sistema. Com base na medida de Causalidade de Granger bi canal no domínio da frequência, a DTF partindo do canal  $j$  para o canal  $i$ , representando a influência causal de  $j$  para  $i$ , é definida como:

$$\theta_{ij}^2(f) = |H_{ij}|^2 \quad (2.9)$$

A DTF normalizada foi definida por KAMINSKI e BLINOWSKA (1991), na forma:

$$\gamma_{ij}^2(f) = \frac{|H_{ij}|^2}{\sum_{m=1}^k |H_{im}|^2} \quad (2.10)$$

Onde  $H_{ij}(f)$  é um elemento da matriz de transferência do modelo MVAR. A DTF descreve a influência causal do canal  $j$  no canal  $i$  numa frequência  $f$ . A equação acima descreve a versão normalizada da DTF, que gera valores entre 0 e 1 que representam a razão entre o influxo do canal  $j$  para o canal  $i$  e todos os influxos em direção ao canal  $i$ .

### 2.3.6 Coerência Direcionada Parcial (PDC)

A coerência direcionada parcial introduzida por BACCALÁ e SAMESHIMA (1998) é uma descrição no domínio da frequência da relação linear direta entre pares de séries temporais  $X_i(t)$  e  $X_j(t)$  quando observadas simultaneamente a um conjunto de outras séries temporais. Sua introdução foi motivada pelo seu potencial em revelar aspectos cruciais da conectividade cerebral em neurociência, devido ao papel central que os ritmos neurais (alfa, beta, gama etc) apresentam na fisiologia neural.

Se um conjunto de séries temporais observadas simultaneamente

$$\mathbf{X}(t) = [X_1(t), X_2(t), \dots, X_k(t)]^T \quad (2.11)$$

São representadas adequadamente por um modelo MVAR de ordem  $p$ :

$$\mathbf{X}(t) = \sum_{l=1}^p \mathbf{A}(l)\mathbf{X}(t-l) + \mathbf{E}(t) \quad (2.12)$$

Onde  $\mathbf{A}(l)$  são os coeficientes  $a_{ij}(l)$  que relacionam a série  $ij$  num atraso  $l$  (descrevendo as interações entre os pares de séries ao longo do tempo) e onde

$$\mathbf{E}(t) = [E_1(t) \dots E_k(t)]^T \quad (2.13)$$

É o vetor de inovações do modelo (média zero e com matriz de covariância  $\Sigma_E$ ) levando à PDC expressa como (BACCALÁ e SAMESHIMA, 1998):

$$\pi_{ij} = \frac{\bar{A}_{ij}(f)}{\sqrt{\sum_{m=1}^k \bar{A}_{mj}(f) \bar{A}_{mj}^*(f)}} \quad (2.14)$$

Onde

$$\bar{A}_{ij}(f) = \delta_{ij} - \sum_{l=1}^p a_{ij}(l) e^{-2c\pi fl} \quad (2.15)$$

Onde  $\delta_{ij} = 1$  sempre que  $i = j$  e  $\delta_{ij} = 0$  caso contrário e  $c = \sqrt{-1}$ . Se a PDC for diferente de zero, implica na existência de uma conexão direta saindo de  $X_j(t)$  em direção a  $X_i(t)$  que não pode ser explicada por outras séries temporais observadas simultaneamente.

A PDC pode determinar a influência, dentro de uma aquisição multicanal, de um eletrodo sobre o outro, esta medida irá expressar o quanto o sinal de uma região ( $i$ ) é influenciado pelo sinal de outra região ( $j$ ), assim demonstra se  $i$  é destino de fluxo de informação de  $j$ . A DTF ao contrário, expressa o quanto o sinal da região  $j$  influencia a rede multicanal, expressando então a origem da informação sobre outras regiões  $i$  (LI *et al.*, 2013).

Ambas as técnicas são capazes de estimar o fluxo de informação em uma análise de sinais multicanais, tais como os sinais de EEG, porém alguns autores demonstram que a PDC possui melhores resultados quando comparada à DTF (GÜRKAN *et al.*, 2014; OMIDVARNIA *et al.*, 2011).

## 2.4 Padrões de conectividade cerebral durante tarefas motoras

Pesquisadores têm investigado a conectividade cerebral, durante a execução de diversas tarefas motoras, buscando encontrar padrões fisiológicos no fluxo de informação entre áreas do córtex cerebral.

NOLTE *et al.* (2004) investigaram a conectividade cerebral, a partir de sinais de EEG, utilizando a parte imaginária da coerência de nove indivíduos destros realizando movimentos dos dedos direitos ou esquerdos. Os pesquisadores encontraram que o fluxo de informação partia do hemisfério contralateral do movimento em direção ao ipsilateral quando investigaram o momento anterior à tarefa e o contrário ocorria quando analisaram o momento posterior à execução da tarefa.

Utilizando a DTF em sinais de EEG de alta resolução em conjunto com dados de fMRI, BABILONI *et al.* (2005) investigaram a conectividade cerebral na tarefa de movimentar quatro dedos da mão direita. Os pesquisadores encontraram que a banda alfa e beta do EEG tinham como fontes de fluxo de informação as áreas parietal direita (ipsilateral) e o córtex motor primário, e como destino de fluxo de informação as áreas: parietal, occipital, o córtex pré-motor e córtex pré-frontal.



Analisando a banda gama, as principais fontes de fluxo de informação foram as áreas parietal direita e o córtex pré-motor, tendo como destinos de fluxo as áreas occipital e pré-frontal de ambos os hemisférios do córtex.

Analisando o movimento dos indicadores direito e esquerdo e suas imaginações, GINTER *et al.* (2005) investigaram a conectividade cerebral, a partir de sinais de EEG, estimada pela SDTF. No ritmo beta do EEG, os pesquisadores detectaram um aumento do fluxo de informação partindo das derivações centrais em direção a outras regiões antes do movimento, seguido pela diminuição dos valores da SDTF durante o movimento e com novo incremento após o movimento. Para o movimento do dedo direito, o fluxo de informação partia de ambos os hemisférios do córtex, enquanto para o dedo esquerdo o fluxo partia contralateralmente. Para a banda gama do EEG, detectaram que o fluxo partia contralateralmente ao movimento nas derivações centrais. Os autores notaram também que, para a execução do movimento, a propagação do fluxo em gama foi rápida, enquanto para a imaginação do movimento, os fluxos foram observados por um tempo maior.

Para as tarefas de IM de mão direita e esquerda, GROSSE-WENTRUP (2009) investigou a conectividade cerebral de sinais de EEG utilizando a entropia de transferência. Não encontrou diferenças no fluxo de informação entre as tarefas de IM de mão esquerda e direita, mas notou diferenças significativas entre ambas as tarefas de IM e o repouso, especialmente na banda gama. As áreas do córtex que apresentaram maiores diferenças foram a frontal, pré-central e pós-central. O autor sugeriu que os estudos de conectividade cerebral devem levar em consideração bandas de maior frequência do EEG, como a gama, pois apresentam maiores diferenças entre diferentes tarefas motoras.

BLINOWSKA *et al.* (2010) utilizaram a SDTF para investigar a conectividade cerebral, em sinais de EEG, de indivíduos que deveriam apertar um botão com mão direita caso aparecessem duas imagens idênticas numa tela. Os pesquisadores encontraram que os fluxos de informação partiam de C3 (contralateral) após apertar o botão, em direção aos eletrodos frontais. Quando apareciam duas imagens diferentes, encontraram fluxo de informação que partia de F8 ou Fz em direção a C3, retratando uma possível inibição ativa do córtex motor pela área motora pré-suplementar. Os autores notaram uma forte presença do córtex frontal originando o fluxo de informação nas tarefas relacionadas a memória de trabalho, o que segundo eles foi devido à atenção necessária e a análise da memória de trabalho constante para saber se era necessária a realização do movimento ou não. Em algumas ocasiões esse fluxo de informação partia das

frontais em direção às parietais. Outra observação feita pelos autores foi a frequente transmissão de informação entre locais distantes do córtex como de F8 para C3, também considerado esperado pelos autores, pois existem relatos na literatura da inibição de estruturas motoras ser originada de conexões corticais de longa distância.

Analisando a atividade espectral e conectividade cerebral durante a execução e observação de movimentos do braço e da perna, KLINE *et al.* (2016) encontraram para a modalidade de observação somente flutuações na conectividade cerebral. Os fluxos de informação partiam do córtex pré-motor direito e córtex motor suplementar.

## 2.5 Classificadores

A classificação é o problema de identificar a qual conjunto de categorias uma nova observação pertence, tendo como base um conjunto de teste de dados contendo observações cuja categoria é conhecida. É um exemplo de reconhecimento de padrões (ALPAYDIN, 2014).

Em terminologia de aprendizado de máquina (ALPAYDIN, 2014), a classificação é considerada um caso do chamado aprendizado supervisionado, aquele no qual um conjunto de treino com observações corretamente identificadas existe. O processo não supervisionado é conhecido como *clustering*, e envolve o agrupamento de dados em categorias baseado em alguma medida de similaridade ou distância.

As observações individuais são analisadas num conjunto de propriedades quantificáveis conhecidas como variáveis explicatórias ou características. Um algoritmo que gera a classificação é conhecido como classificador. O termo também pode se referir à função matemática, que, contida no algoritmo, mapeia o dado de entrada em uma categoria. Exemplos de algoritmos de classificação incluem: LDA, SVM, árvores de decisão, ANN, entre outros.

## 2.5.1 Árvores de Decisão

Árvores de Classificação e de Regressão (CART, do inglês *Classification and Regression Trees*) é um termo introduzido por BREIMAN *et al.* (1984) para se referir a algoritmos de Árvore de Decisão que podem ser utilizados para classificação ou regressão de problemas de modelagem preditiva.

A representação para o modelo CART é uma árvore binária. Cada nó raiz representa uma variável de entrada simples ( $x$ ) e um ponto de divisão naquela variável (assumindo que a variável seja numérica).

Os nós folha da árvore contém uma variável de saída ( $y$ ) que é utilizada para fazer a previsão. Sendo um banco de dados com duas entradas ( $x$ ), altura em centímetros e peso em kilogramas, as saídas ( $y$ ) sendo o gênero masculino ou feminino, a Figura 2.5 dá um exemplo simples de uma árvore de decisão binária (completamente fictícia com propósito de demonstração somente). Na figura 2.5, se a variável altura é maior que 180 cm, a árvore classifica como gênero masculino. Caso a restrição não seja verdadeira é então analisada a segunda variável: o peso. Se a variável peso é maior que 80 kg, a árvore classifica como gênero masculino, caso contrário, gênero feminino.

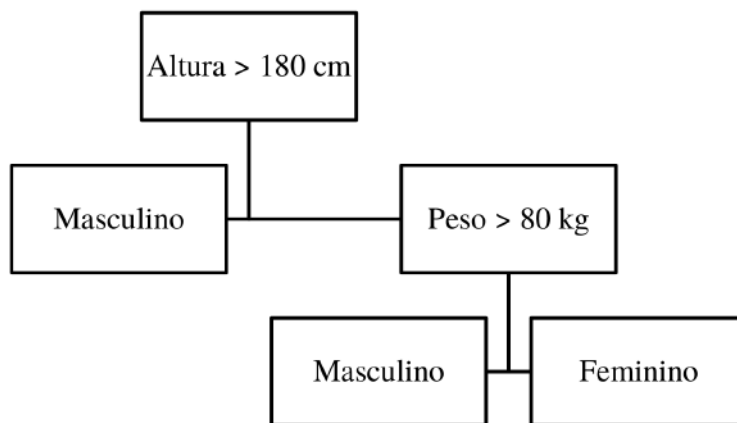


Figura 2.5: Exemplo de uma árvore de decisão binária com dados fictícios para demonstração. As entradas da árvore são altura (em cm) e peso (em kg). Os nós folha da árvore contém as variáveis de saída, os gêneros masculino e feminino.

Com a representação de árvore binária do modelo CART descrito anteriormente, é possível serem feitas previsões para novas entradas. Dada uma nova entrada, a árvore é percorrida se avaliando a partir do nó raiz da árvore.

Uma árvore de decisão é um particionamento do espaço de entradas. Pode-se pensar que cada variável de entrada é uma dimensão num espaço p-dimensional. A árvore de decisão divide esse espaço em retângulos (com p=2 variáveis de entrada) ou algum tipo de hiper-retângulos com mais entradas. Dados novos são filtrados através da árvore e chegam a um dos retângulos, sendo o valor de saída daquele retângulo a previsão feita pelo modelo.

A abordagem utilizada para se dividir o espaço de entradas é chamada de divisão binária recursiva. Este é um procedimento numérico em que todos os valores são alinhados e diferentes divisões são testadas utilizando uma função custo. A divisão que minimiza o custo é selecionada. Todas as variáveis de entradas são avaliadas e escolhidas na chamada *Greedy Splitting*, ou seja, o melhor ponto de divisão é escolhido a cada momento.

Para uma Árvore de Classificação, a função de custo Gini é utilizada. Esse critério de otimização também conhecido Índice de Diversidade Gini (GDI, do inglês *Gini's Diversity Index*) fornece uma indicação de quão “puro” são os nós folha (quão misturados os dados de treino designados a cada nó estão).

$$G = \sum pk * (i - pk) \tag{2.16}$$

Onde  $G$  é o custo Gini sobre todas as classes,  $pk$  é o número de instâncias de treinamento com classe  $k$  no retângulo de interesse. Um nó que tem todas as classes do mesmo tipo terá  $G = 0$  (pureza de classe perfeita), enquanto uma divisão 50-50 de classes numa classificação binária (pior pureza) terá um valor  $G = 0,5$ .

O procedimento de divisão binária recursiva utiliza, geralmente, como critério de parada a contagem mínima do número de instâncias de treinamento designadas a cada nó folha. Se a contagem é menor que algum mínimo, então a divisão não é aceita e o nó é tomado como nó folha final.

Para se estimar a acurácia do classificador pode-se calcular o erro de ressubstituição ou fazer uma validação cruzada.

A estimativa da ressubstituição dá a proporção de casos que são classificados erroneamente utilizando o conjunto amostral completo. Ela é computada da seguinte maneira:

$$R(d) = \frac{1}{N} \sum_{i=1}^N X(d(x_n) \neq j_n) \quad (2.17)$$

Onde  $d(x)$  é o classificador e  $X$  é uma função de indicação;  
 $X = 1$ , se  $X(d(x_n) \neq j_n)$  é verdadeiro;  
 $X = 0$ , se  $X(d(x_n) \neq j_n)$  é falso.

A estimativa da ressubstituição é calculada utilizando os mesmos dados que foram usados na construção do classificador  $d$ , por isso tende a ser muito otimista.

A *k-fold crossvalidation* divide o número total de casos em  $k$  sub amostras  $Z_1, Z_2, \dots, Z_k$  de tamanhos iguais. Ela estima a proporção de casos na sub amostra  $Z$  que são classificados erroneamente pelo classificador construído pela sub amostra  $Z - Z_k$ . Essa estimativa é computada da seguinte maneira: Seja a amostra de aprendizado  $Z$  de tamanho  $N$  ser particionada em  $k$  sub amostras  $Z_1, Z_2, \dots, Z_k$  de tamanhos  $N_1, N_2, \dots, N_k$ , respectivamente:

$$R(d^k) = \frac{1}{N_k} \sum_{(x_n, j_n) \in Z_k} X(d^{(k)}(x_n) \neq j_n) \quad (2.18)$$

Onde  $d^{(k)}(x)$  é calculado da sub amostra  $Z - Z_k$ .

A classificação por meio do CART tem como principais vantagens sua facilidade de compreensão e visualização e sua rapidez de construção e teste. Porém, para aplicações com conjuntos de dados maiores, classificadores mais avançados podem apresentar desempenho superior, apesar de apresentarem algoritmos de difícil visualização e manipulação.

## 2.5.2 Redes Neurais Artificiais

Redes neurais é uma abordagem computacional que busca, de forma geral, mimetizar a forma que o cérebro biológico resolve problemas com seus enormes grupos de neurônios conectados por axônios. Para isso são constituídas por uma grande coleção de unidades neurais, também chamadas de neurônios artificiais. Cada unidade neural é conectada a diversas outras e esses ligamentos podem forçar a ativação ou inibição nas unidades a ele conectadas (HAYKIN *et al.*, 2009). Assim como outros métodos de aprendizado de máquina, as redes neurais têm sido utilizadas para resolver uma grande variedade de tarefas, como visão computadorizada e reconhecimento de fala, que são difíceis de resolver utilizando somente programação lógica.

Uma Rede Neural Artificial (ANN) é tipicamente definida por três tipos de parâmetros:

1. Conexões entre as camadas;
2. Algoritmo de aprendizado;
3. Função de ativação.

O padrão de interconexão entre as camadas de neurônios pode ser de diversos tipos e, dependendo da complexidade da aplicação, podem ser necessárias diversas camadas de neurônios. No presente trabalho foi utilizada uma rede neural do tipo alimentação avante (*feedforward*, do inglês), na qual as conexões entre as unidades neurais não formam um ciclo (tal como as redes recorrentes). Nesta rede, a informação é propagada somente em uma direção, adiante, a partir dos nós de entrada, através dos nós escondidos e para os nós de saída, não existem ciclos nem laços nesse tipo de rede. Um exemplo de estrutura de conexão dessa rede pode ser visto na figura 2.6.

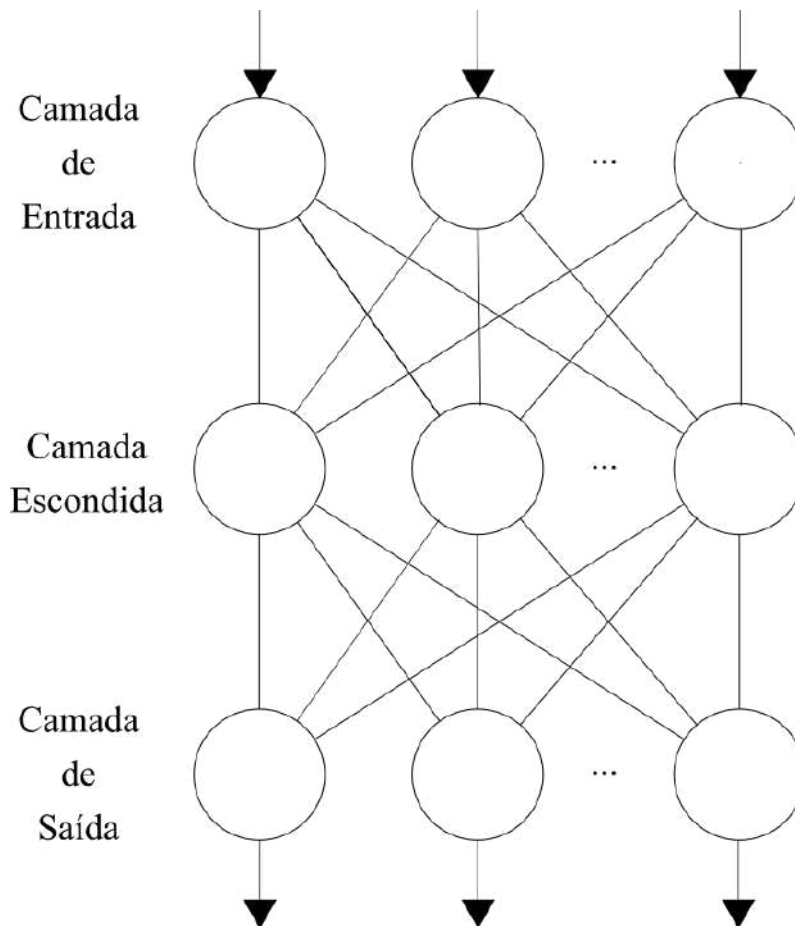


Figura 2.6: Rede neural do tipo alimentação avante. Na estrutura de conexão da rede alimentação avante a informação é propagada somente em uma direção: partindo dos nós de entrada, através dos nós escondidos e chegando nos nós de saída. Não existem ciclos nem laços nesse tipo de estrutura.

O tipo de rede com alimentação avante utilizado neste trabalho é chamado de Perceptron Multicamadas (*Multilayer perceptron* ou MLP, do inglês). A MLP consiste de múltiplas camadas de nós num grafo orientado, com cada camada totalmente conectada à próxima. Exceto pelos nós de entrada, cada nó é um neurônio (ou elemento processador) com uma função de ativação não linear. A MLP utiliza uma técnica de aprendizagem supervisionada chamada retro-propagação (*backpropagation*, do inglês) para treinar a rede (ROSENBLATT, 1961; RUMELHART *et al.*, 1985).

A maioria dos algoritmos de aprendizado segue alguma forma de Gradiente Descendente, tomando a derivada da função custo dos parâmetros da rede e então alterando esses parâmetros na direção do gradiente, minimizando o critério de custo. O aprendizado ocorre no classificador ao mudar os pesos das conexões após cada dado ser processado, baseando-se no erro na saída comparado ao resultado esperado.

Representando-se o erro do nó de saída  $j$  no  $n$ -ésimo dado por  $e_j(n) = d_j(n) - y_j(n)$ , onde  $d$  é o valor alvo e  $y$  é o valor produzido pelo *perceptron*. São então feitas correções nos pesos dos nós baseadas nas correções que minimizam o erro em toda a saída, dado por:

$$\varepsilon(n) = \frac{1}{2} \sum_j e_j^2(n) \quad (2.19)$$

Utilizando o Gradiente Descendente, encontra-se a mudança em cada peso como sendo:

$$\Delta w_{ij}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial v_j(n)} y_i(n) \quad (2.20)$$

Onde  $y_i$  é a saída do neurônio anterior,  $v_j$  é o potencial de ativação do neurônio  $j$  e  $\eta$  a taxa de aprendizagem, que é cuidadosamente escolhida para garantir que os pesos convirjam para uma resposta rápido o bastante, sem produzir oscilações (HAYKIN *et al.*, 2009). Neste trabalho foi utilizado o algoritmo de aprendizado chamado retro-propagação por gradiente conjugado escalado (*Scale Conjugate Gradient Backpropagation*, do inglês).

A função de ativação tem como característica importante a transição suave na mudança dos parâmetros de entrada. Ela é geralmente predefinida, como a tangente hiperbólica sigmoide. No presente trabalho foi utilizada a tangente hiperbólica sigmoide como função de ativação, que é da forma:

$$tansig(n) = \frac{2}{(1 + e^{(-2n)})} - 1 \quad (2.21)$$



# Capítulo 3

## Materiais e Métodos

Neste capítulo são detalhados os procedimentos que foram necessários para a realização do trabalho. As coletas de dados foram realizadas por (ULLOA, 2013) e (SILVA *et al.*, 2014) e são detalhadas nas seções: Indivíduos, Sinais de EEG e Tarefa Experimental. Em seguida, descreve-se o pré-processamento dos sinais. Após essas etapas, explica-se o procedimento seguido para a comparação da conectividade cerebral entre o momento anterior à execução e execução das tarefas motoras. Finalmente, descrevem-se os procedimentos realizados para a classificação das modalidades de tarefas motoras.

### 3.1 Indivíduos

Para a coleta de dados, foram escolhidos 12 voluntários destros saudáveis, com idades entre 23 e 32 anos. Os voluntários não se encontravam sob influência de fármacos que pudessem alterar os registros de EEG. Durante o experimento os voluntários foram colocados em uma cabine acusticamente isolada e com iluminação controlada, com temperatura mantida a  $25 \pm 1.5$  Celsius.

O registro dos sinais de EEG de seis participantes foi realizado no Laboratório de Engenharia Biomédica do Departamento de Engenharia Elétrica da UFMG e aprovado pelo Comitê de Ética em Pesquisa (COEP) da UFMG, por meio do parecer N ETIC 467/08 (ULLOA, 2013). Os demais foram registrados no Laboratório de Processamento de Sinais e Imagens Médicas (LAPIS) do Programa de Engenharia Biomédica do Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia (COPPE) da UFRJ e aprovado pelo Comitê de Ética do Hospital Universitário Clementino Fraga Filho (HUCFF/ UFRJ) sob o protocolo 44647715.1.0000.5257, data 14/06/2015.

## 3.2 Sinais de EEG

Os sinais de EEG dos voluntários foram registrados por meio de uma touca com 17 eletrodos (F7, F3, Fz, F4, F8, C3, Cz, C4, T3, T4, T5, P3, Pz, P4, T6, O1 e O2), colocados de acordo com o sistema internacional de posicionamento 10-20 (Figura 2.3), com referência nos lóbulos auriculares ( $\frac{A1+A2}{2}$ ) e o eletrodo de terra colocado na testa do voluntário. O sinal de EEG foi captado por meio do amplificador biológico de 36 canais BrainNet BNT-36 (EMSA, Rio de Janeiro, Brasil), com filtro passa-banda entre 0,1 e 100 Hz e frequência de amostragem de 600 Hz. O eletro-oculograma (EOG) foi registrado junto com o EEG, por meio de dois eletrodos de *Ag/AgCl* de 10 mm de diâmetro colocados em cima e por baixo do olho direito do voluntário. O movimento do robô também foi registrado concomitantemente ao EEG, assim como o movimento do voluntário para a tarefa de movimento, por meio de um acelerômetro ADXL335 (*Analog Devices*).

## 3.3 Montagem do Experimento

O braço robótico *AX18 Smart Robot Arm* (*Crust Crawler Robotics*, Arizona, EUA) foi fixado em uma plataforma de madeira com medidas 30x30 cm através de parafusos e porcas. A plataforma foi apoiada em dois suportes de ferro que se conectavam a trilhos presos a parede, estes trilhos possuem diversos furos que possibilitam a adequação da altura do braço robótico à altura do voluntário.

A cadeira foi posicionada a 120 cm do braço robótico, distância esta que corresponde ao dobro do comprimento máximo do braço para que não houvesse possibilidade de colisão com o voluntário (Figura 3.1).




Figura 3.1: Esquema de montagem do *setup* experimental, cadeira posicionada a 120 cm do braço robótico o que corresponde ao dobro do comprimento do braço que está preso a parede por um suporte tipo trilho (SILVA *et al.*, 2014).

### 3.4 Tarefa Experimental

Os voluntários foram instruídos a seguir os movimentos de um braço robótico (*AX18 Smart Robot Arm – Crust Crawler Robotics*, Arizona, EUA), de forma a espelhar o movimento com seu braço direito.

A tarefa foi executada conforme a Figura 3.2. A sequência de movimentos do robô manipulador começa com a execução do movimento de flexão, seguido por um intervalo aleatório entre 8 e 12 segundos sem movimento, a execução do movimento de extensão e finalmente outro intervalo aleatório sem movimento cuja duração também é de 8 a 12 segundos. Essa sequência foi repetida por cerca de 30 vezes para cada tarefa a ser realizada, com objetivo de ter disponível mais dados para a análise após a rejeição de artefatos. Foram gravadas as tarefas de execução, imaginação e observação da extensão e flexão do cotovelo direito.




Figura 3.2: Sequência de movimentos executados pelo robô durante a tarefa experimental. Com permissão de (ULLOA, 2013). O manipulador robótico aguarda por um tempo aleatório entre 8 e 12 segundos, realiza a flexão de cotovelo durante 2,5 segundos. Aguarda por um novo período aleatório entre 8 a 12 segundos e em seguida realiza a tarefa de extensão de cotovelo durante 2,5 segundos. A sequência é repetida 30 vezes para cada modalidade de tarefa (execução, imaginação e observação).

### 3.5 Pré-processamento de Sinais

Todo o processamento de sinais foi feito no programa *Mathworks MATLAB*. Inicialmente foi feita a identificação e rejeição de artefatos. O limiar de rejeição de artefatos foi determinado em 3 vezes o desvio padrão de um sinal de EEG espontâneo de 20 segundos de olhos abertos, considerado livre de artefatos. O trecho foi rejeitado nos casos em que 5% consecutivos ou 10% quaisquer das amostras excederam este limiar (TIERRA-CRIOLLO, 2001). Em média foram rejeitados 4 trechos por indivíduo.

### 3.6 Comparação da conectividade cerebral entre o momento anterior e a execução das tarefas motoras

Foram analisados dois momentos distintos: momento anterior à execução das tarefas motoras e sua execução. Para isso, os sinais de EEG foram divididos em duas épocas: de -1 segundo até o início da atividade e a partir do início da atividade até 2,5 segundos depois (PFURTSCHELLER e LOPES DA SILVA, 1999).

Cada segmento foi utilizado para gerar um modelo MVAR com características próprias de cada época de tarefa realizada. Esses modelos então foram utilizados para o cálculo da DTF e da PDC, como demonstrado na seção de revisão da literatura. As matrizes geradas a partir dos cálculos têm tamanho  $17 \times 17 \times 45 \times 25$ . Sendo  $17 \times 17$  devido ao número de eletrodos utilizados na coleta, representando 17 possíveis saídas e chegadas de fluxo de informação. O número 45 representa a faixa de frequência de 1 a 45 Hz ( $\Delta f = 1$  Hz) e 25 é o número de trechos para cada tarefa. Foram investigados os ritmos alfa (8-14 Hz), beta (15-30 Hz) e gama (30-45 Hz) do EEG.

A média do fluxo de informação dos 25 trechos do momento anterior à execução e execução da tarefa motora, estimados por meio da DTF e da PDC, foram comparados estatisticamente para cada indivíduo em cada caminho ( $17 \times 17 = 289$ ) e em cada banda. Uma vez que os dados não seguiam uma distribuição normal (Teste de Kolmogorov-Smirnov, nível de significância de 5%), aplicou-se um teste estatístico não-paramétrico. Foi realizado o teste de Wilcoxon para dados pareados, com nível de significância de 1%, comparando as características no momento anterior à execução da tarefa motora e execução da mesma.

Para simplificar a apresentação dos resultados, os caminhos de fluxo de informação, que apresentaram diferenças estatísticas para todos os 12 indivíduos, foram agrupados de acordo com os cinco lobos do córtex. Foi adotado o critério de seleção de maioria, tanto para as derivações de origem do fluxo de informação quanto para as derivações de destino. Por exemplo, se o fluxo se originava de três ou mais das cinco derivações do lobo frontal do córtex com destino a pelo menos uma derivação temporal, foi representado como “F → T”. Se o fluxo se originava de menos de três derivações frontais, e tinha como destino duas ou mais derivações centrais, foi representado como “F → C”, pois, apesar de não se originar da maioria das frontais, tinha como destino a maioria das centrais.

O objetivo dessa análise foi investigar os padrões de fluxo de informação que ocorrem entre as diferentes regiões cerebrais quando as tarefas são realizadas.

### 3.7 Classificação

Na classificação foram utilizados como variáveis todos os possíveis caminhos de fluxo de informação durante a execução da tarefa, estimados pela DTF e PDC. Os algoritmos de classificação atribuem pesos e vieses a cada variável de modo a otimizar a acurácia da classificação, dessa forma os próprios classificadores dão prioridade aos caminhos de fluxo de informação que retornem melhores resultados. Foram investigados separadamente os ritmos alfa, beta e gama do EEG. Os estimadores de conectividade cerebral, DTF e PDC, foram avaliados separadamente como característica para os classificadores.

De modo a permitir uma comparação com mesmo número de amostras por banda de frequência do EEG (pois as bandas apresentam larguras diferentes), foram tomadas cinco medidas que caracterizam os valores, da DTF e PDC, dentro do conjunto de cada uma:

1. Média da banda;
2. Valor máximo na banda;
3. Valor mínimo na banda;
4. Valor RMS da banda;
5. Desvio padrão da banda.

Os classificadores foram avaliados nas tarefas de discriminar o tipo de tarefa realizada entre sete classes:

1. Imaginação da extensão de cotovelo (IME);
2. Imaginação da flexão de cotovelo (IMF);
3. Movimento de extensão de cotovelo (MVE);
4. Movimento de flexão de cotovelo (MVF);
5. Observação da extensão de cotovelo (OBE);
6. Observação da flexão de cotovelo (OBF);
7. Repouso (REP).

Dessa forma, o número total de amostras, para serem utilizadas como características pelos classificadores, de cada indivíduo é de 875 (25 amostras caracterizadas por 5 medidas, em 7 classes diferentes).

As características extraídas a partir da DTF e PDC foram utilizadas inicialmente em classificadores por Árvores de Decisão, utilizando o algoritmo tradicional CART com critério de otimização sendo o GDI. Para avaliar o desempenho dos classificadores por Árvore de Decisão, foi calculado inicialmente o Erro de Ressubstituição, porém esse se mostrou tendencioso por se testar utilizando os dados usados na criação da árvore. Então foi calculada a *10-fold crossvalidation*, que mostra o desempenho real do classificador na presença de novos dados. Esse processo foi repetido cem vezes por indivíduo, ficando registrada a acurácia média e desvio padrão.

As mesmas características extraídas foram utilizadas em classificadores do tipo ANN. As redes foram criadas utilizando-se a *Neural Network Toolbox* do programa *MATLAB*. As redes criadas são MLPs, apresentando topologia com alimentação avante, com uma camada escondida contendo dez neurônios. O algoritmo de treinamento utilizado foi o de retro-propagação por gradiente conjugado escalado (*Scaled conjugate gradient backpropagation*, do inglês) (MØLLER, 1993) e a função de transferência utilizada foi a Tangente hiperbólica sigmoide (*tansig*).

Os dados foram divididos aleatoriamente na rede da forma:

- 70% para treino: são os dados apresentados à rede durante o treinamento, e a rede se ajusta de acordo com seu erro;
- 15% para validação: usados para mensurar a generalização da rede, e para interromper o treinamento quando a generalização para de melhorar;
- 15% para teste: estes não tem efeito no treinamento e dessa forma fornecem uma medida independente do desempenho da rede.

O total de 875 dados estava disponível para o treinamento de cada rede para cada indivíduo. Assim, a cada inicialização da rede, são divididas aleatoriamente: 613 amostras para treino, 131 amostras para validação e 131 amostras para teste. Como na inicialização de uma rede neural os pesos são distribuídos de forma aleatória pelas variáveis, o algoritmo foi executado cem vezes para cada indivíduo, registrando assim a média da acurácia e seu desvio padrão.

A topologia da rede neural pode ser vista na Figura 3.3. Ela apresenta 289 neurônios na entrada (cada possível caminho de fluxo de informação é uma variável), 10 neurônios na camada escondida e 7 neurônios na saída (representando as 7 possíveis classes). As letras W e b representam os pesos e vieses da rede, respectivamente.




Figura 3.3: Topologia da ANN utilizada para classificar as tarefas. A rede apresenta 289 neurônios na camada de entrada, 10 neurônios na camada escondida e 7 neurônios na camada de saída. Os pesos e vieses da rede neural são representados por  $W$  e  $b$ , respectivamente.

Também realizou-se a classificação utilizando a energia do EEG como característica nos ritmos alfa, beta e gama do EEG. Dessa forma, foi possível a comparação do desempenho da classificação utilizando essa característica, em relação ao uso das características provenientes dos estimadores de conectividade cerebral.

# Capítulo 4

## Resultados

Neste capítulo, serão apresentados os resultados da comparação da conectividade cerebral entre a momento anterior e a execução das tarefas motoras e os resultados das classificações.

### **4.1 Comparação da conectividade cerebral entre o momento anterior e a execução das tarefas motoras**

Nesta seção são mostrados os resultados da comparação estatística entre os fluxos de informação, estimados pela DTF e PDC, no momento anterior e a execução das tarefas motoras.

#### **4.1.1 Função de Transferência Direcionada**

A Tabela 4.1 exibe os resultados da análise estatística do fluxo de informação, comparando o momento anterior à execução da tarefa motora e durante sua execução, utilizando a DTF.

As derivações do EEG foram separadas em regiões para facilitar a leitura dos resultados. Foram consideradas para essa tabela somente as derivações que apresentavam diferenças estatísticas em todos os 12 indivíduos envolvidos no estudo.



Tabela 4.1: Caminhos de fluxo de informação estatisticamente diferentes entre a momento anterior à execução da tarefa motora e sua execução, estimados pela DTF nos ritmos do EEG analisados.

Tarefa	$\alpha$	$\beta$	$\gamma$
IME	-	$T \rightarrow P, T \rightarrow O$	$T \rightarrow P, C \rightarrow T, C \rightarrow P$
IMF	-	$F \rightarrow C, P \rightarrow T$	$F \rightarrow T, F \rightarrow C$
MVE	-	$F \rightarrow O$	$F \rightarrow Todas, O \rightarrow T, T \rightarrow C, T \rightarrow P, C \rightarrow P$
MVF	-	$O \rightarrow T, C \rightarrow P$	$F \rightarrow Todas, O \rightarrow T, T \rightarrow Todas$
OBE	-	$P \rightarrow T$	$O \rightarrow C, O \rightarrow F, P \rightarrow F, P \rightarrow T, C \rightarrow F$
OBF	-	$T \rightarrow O, C \rightarrow T$	$O \rightarrow C, O \rightarrow P, O \rightarrow T, C \rightarrow F, C \rightarrow T$

Observa-se, na tabela 4.1, que não foram encontradas diferenças estatísticas no fluxo de informação entre o momento anterior à execução e execução da tarefa no ritmo alfa do EEG. Por outro lado, nota-se que o ritmo gama apresentou mais caminhos de fluxo de informação com diferenças estatísticas para os dois momentos. Analisando-se o ritmo beta, para as tarefas de IM, é notável a inversão dos fluxos entre as derivações temporais e parietais, para a extensão ( $T \rightarrow P$ ) e flexão ( $P \rightarrow T$ ) de cotovelo. No ritmo gama, ambas as tarefas de movimento apresentaram diferenças partindo das derivações frontais em direção às demais. A tarefa de OBE apresentou diferenças significativas nos fluxos partindo das derivações parietais em beta e gama. Ambas as tarefas de observação (da extensão e flexão do braço robótico) mostraram diferenças significativas entre os momentos de não movimento e movimento do braço robótico, no ritmo gama, nos fluxos de informação partindo das derivações occipitais.

Utilizando os resultados do indivíduo 1 como exemplo, os gráficos a seguir mostram para cada tarefa motora os valores da DTF no momento anterior à execução (azul) e a execução da tarefa (vermelho). Para facilitar a visualização, as figuras seguintes mostram apenas os caminhos de fluxo de informação que mostraram diferença significativa ( $p < 0.01$ ) para esta análise.

**IM EXT**




Figura 4.1: Valores da DTF na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

**IM EXT**




Figura 4.2: Valores da DTF na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

Observa-se na figura 4.1, para a classe “imaginação da extensão de cotovelo” na banda beta, as diferenças da DTF saindo das derivações temporais em direção às occipitais e parietais para o ritmo beta do EEG. Notou-se o maior valor da DTF na execução da tarefa do que o momento anterior à execução, saindo das temporais e chegando na derivação O1, exceto partindo de T6. O mesmo ocorreu no fluxo de informação saindo das temporais em direção à derivação Pz, exceto para o fluxo entre T5 e Pz. O fluxo de informação partindo de T4 para P4 também foi maior na execução da tarefa comparado ao momento anterior à execução da mesma.

Pode-se observar na figura 4.2, para a classe “imaginação da extensão de cotovelo” na banda gama, as diferenças da DTF saindo das derivações temporais em direção às parietais e das centrais em direção às parietais e temporais para o ritmo gama do EEG. Destacaram-se as diferenças no fluxo de informação partindo das temporais em direção à Pz, com exceção de T6 para Pz. Observando o fluxo partindo das centrais, o destaque ficou na maior diferença entre os fluxos de informação partindo de Cz para T3. Pequenas diferenças foram notadas no fluxo de informação partindo das centrais para Pz e T5.

# IM FLEX




Figura 4.3: Valores da DTF na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

# IM FLEX




Figura 4.4: Valores da DTF na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

Na “imaginação da flexão de cotovelo” para o ritmo beta do EEG, como se observa na Figura 4.3, notaram-se diferenças de fluxo de informação nos caminhos partindo das derivações frontais em direção às centrais e partindo das parietais em direção às derivações temporais. Destacou-se a derivação Fz como origem do fluxo de informação com diferenças estatísticas em direção às centrais, onde notou-se maior DTF no momento anterior à execução da tarefa. Partindo de P3 e chegando a T5 também existiram diferenças em beta, tendo sido T5 também destino de Pz com maior valor da DTF no momento anterior à execução da tarefa.

Na “imaginação da flexão de cotovelo” para o ritmo gama do EEG, como se observa na Figura 4.4, notaram-se diferenças de fluxo de informação nos caminhos partindo das derivações frontais em direção às centrais e temporais. Destacou-se que foram encontradas diferenças entre os momentos principalmente no fluxo de informação partindo das derivações frontais em direção à Cz, com maior valor da DTF no momento anterior à execução da tarefa. Diferenças semelhantes foram encontradas chegando nas derivações T3, T4 e T5.




Figura 4.5: Valores da DTF na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Movimento de Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.





Observando-se a Figura 4.5 notaram-se as derivações frontais como caminhos de origem de fluxo de informação para a tarefa de “movimento de extensão de cotovelo” no ritmo beta do EEG. A derivação O1 foi destaque como destino de fluxo de informação partindo das frontais, em especial partindo de F4 e F7.

Observa-se na Figura 4.6 a tarefa de “movimento de extensão de cotovelo” no ritmo gama do EEG. O ritmo gama apresentou mais diferenças estatísticas entre os dois momentos na DTF para essa tarefa. Foi possível observar os fluxos de informação partindo das frontais para as centrais, occipitais, parietais e temporais, partindo das centrais para as parietais, partindo das occipitais para as temporais e partindo das temporais para as centrais e parietais. Notou-se as diferenças nos fluxos partindo das frontais e temporais em direção à derivação C3, com maior valor de DTF no momento antes da execução da tarefa. O mesmo foi observado nos fluxos partindo das occipitais e frontais em direção à T6. Outros caminhos de fluxo de informação com diferenças a se destacar são: C3 para Pz, F4 para T4 e O2 para T3 (maior DTF no momento de execução da tarefa motora).

### MV FLEX

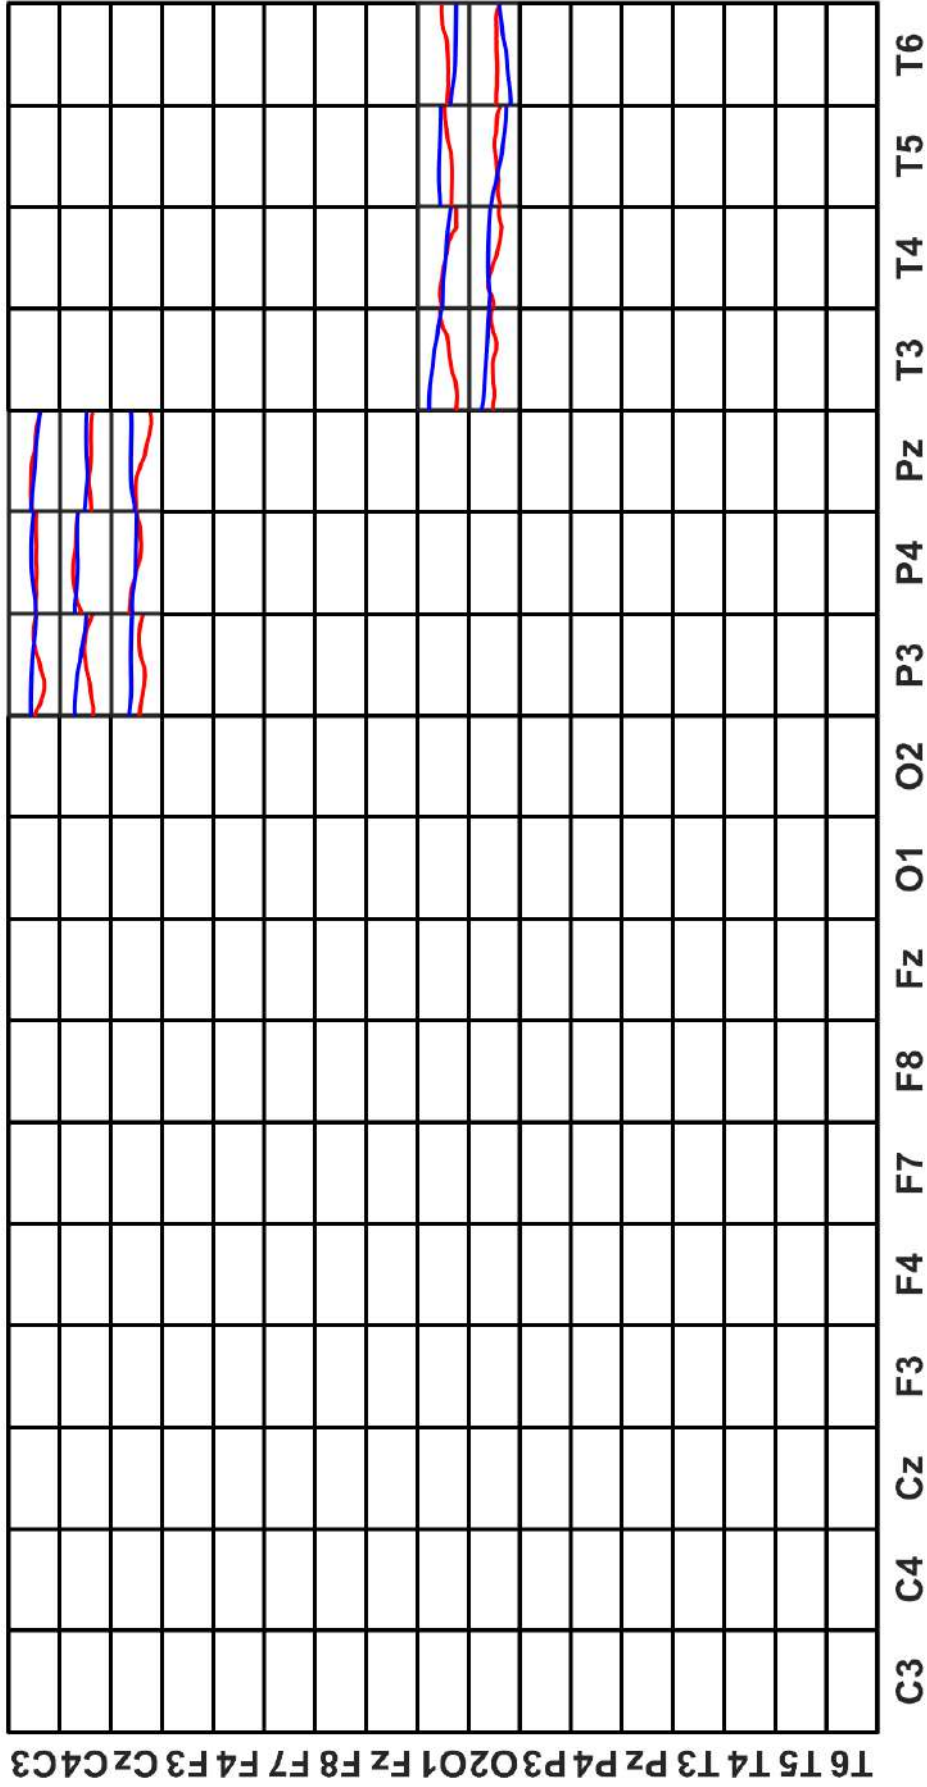


Figura 4.7: Valores da DTF na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Movimento de Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

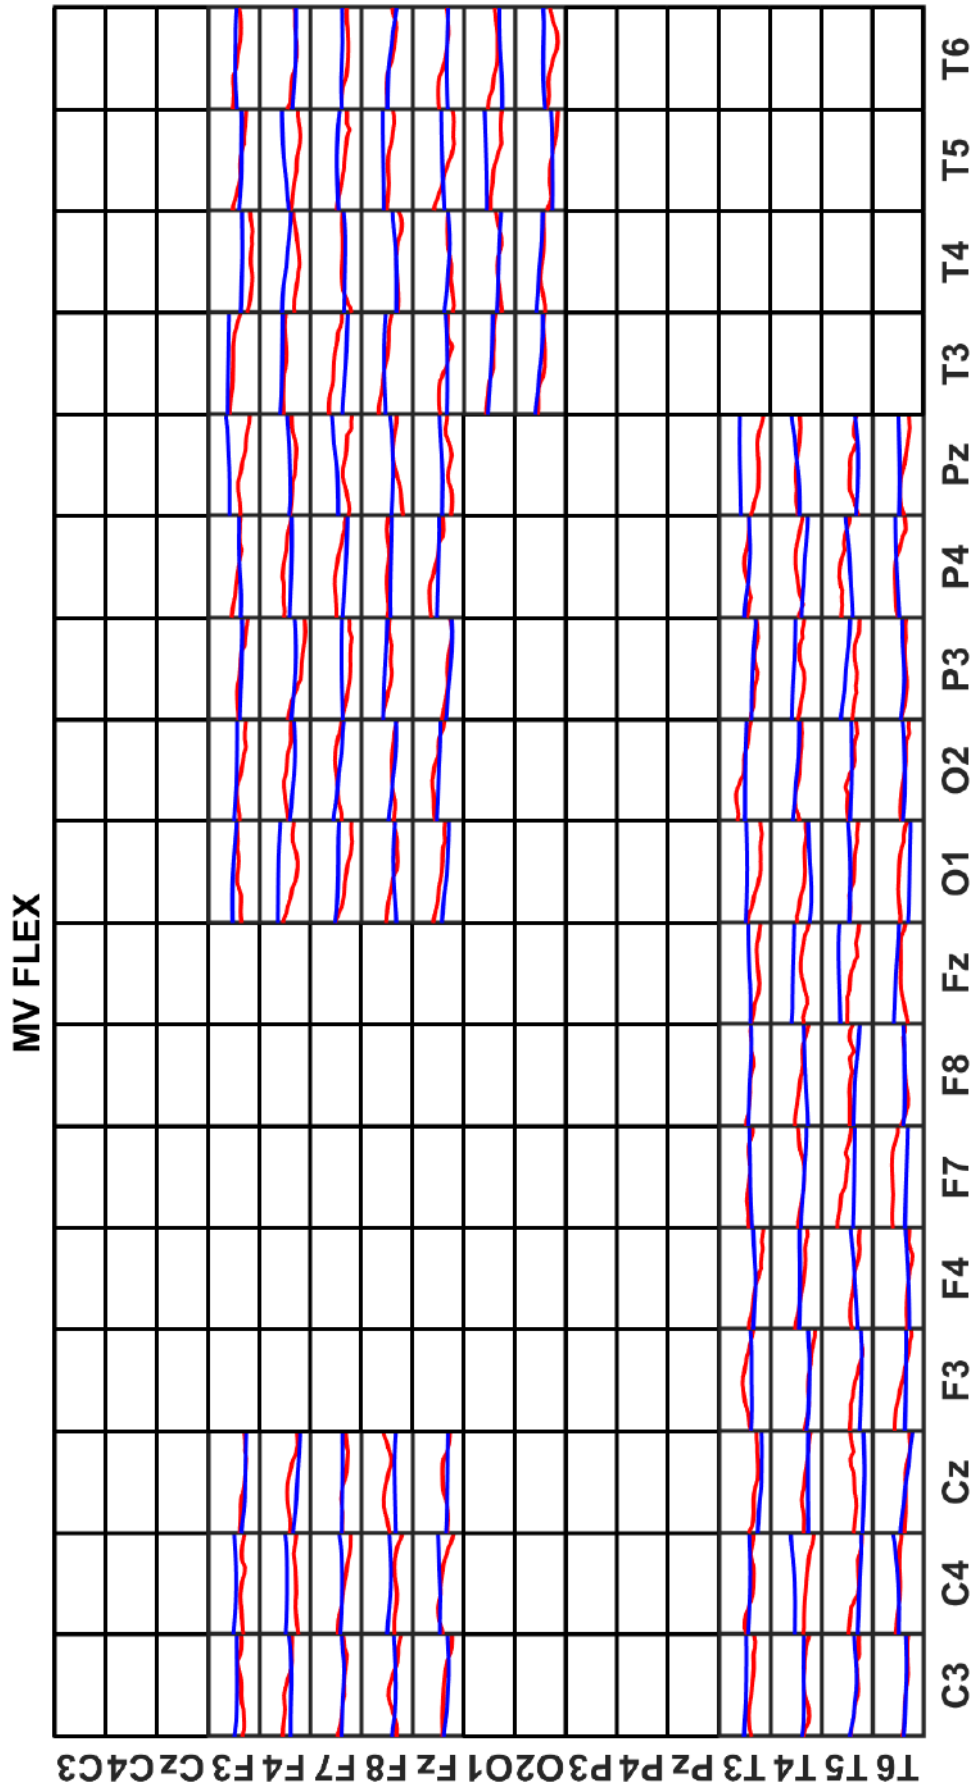


Figura 4.8: Valores da DTF na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Movimento de Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

A Figura 4.7 mostra os caminhos de fluxo de informação que diferenciam os momentos na tarefa de “movimento de flexão do cotovelo” no ritmo beta. Observaram-se os fluxos de informação com diferenças estatísticas entre os dois momentos partindo das centrais em direção às parietais e partindo das occipitais em direção às temporais. Destacou-se o fluxo partindo das centrais em direção à P3 e de Cz para Pz em ambos os casos com maior DTF no momento anterior à execução da tarefa. Partindo das occipitais, o destaque ficou para o fluxo entre O1 e T3, e entre O2 e T6 (maior DTF no momento de execução da tarefa).

A Figura 4.8 mostra os caminhos de fluxo de informação que diferenciam os momentos na tarefa de “movimento de flexão do cotovelo” no ritmo gama. Observaram-se os fluxos de informação com diferenças estatísticas entre os dois momentos partindo das frontais em direção à todas as outras, partindo das occipitais em direção às temporais e partindo das temporais em direção à todas as outras. Destacaram-se diversos caminhos com diferenças entre os momentos em que a DTF teve valor maior no momento anterior à execução da tarefa, entre eles: F4 e F7 para O1, F3 e F7 para Pz, F4 e O1 para T5, T4 para C4, T4 e T5 para Fz, T3 para O1 e T3 para Pz. Os caminhos de maior destaque em que o momento de execução da tarefa apresentou maior DTF foram: F7 para T3, T5 para Cz, T5 e T6 para F7 e T6 para O1.

**OB EXT**




Figura 4.9: Valores da DTF na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

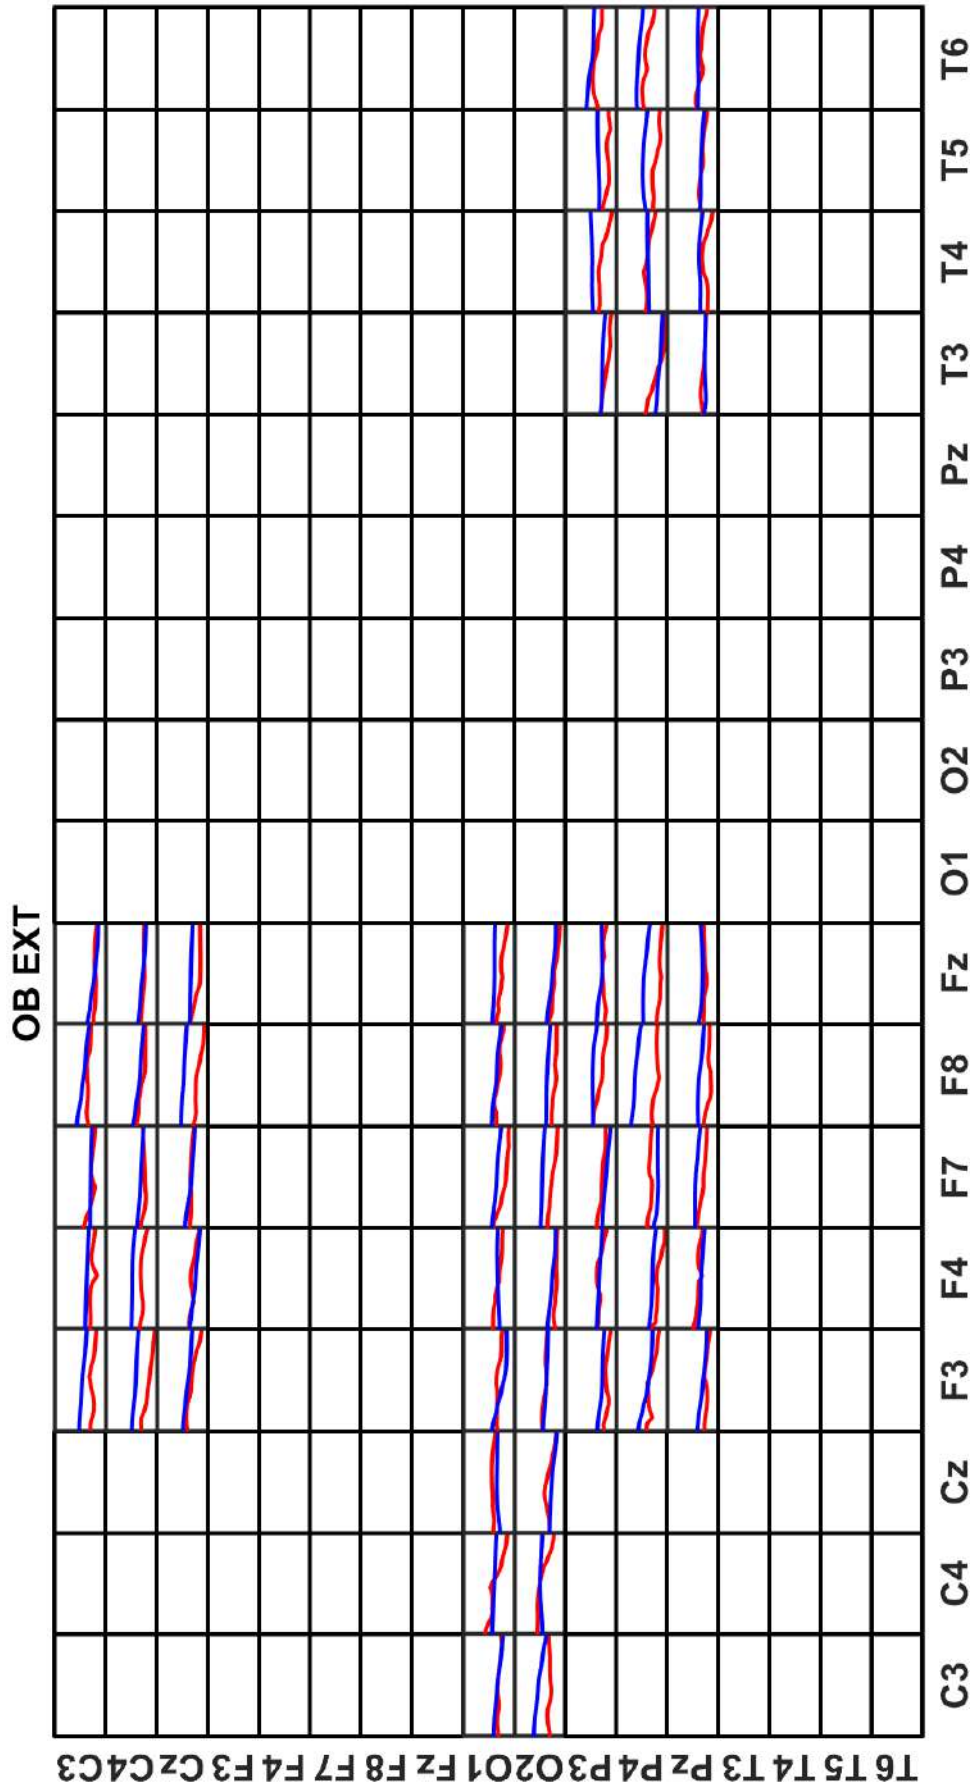


Figura 4.10: Valores da DTF na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

Para a tarefa de “observação da extensão de cotovelo”, utilizando-se a DTF na banda beta, como visto na Figura 4.9, foi possível observar os fluxos de informação com diferenças estatísticas entre os dois momentos partindo das derivações parietais em direção às temporais. Destacaram-se os caminhos de fluxo: P4 para T3 e P3 para T6.

Para a tarefa de “observação da extensão de cotovelo”, utilizando-se a DTF na banda gama, como visto na Figura 4.10, foi possível observar os fluxos de informação com diferenças estatísticas entre os dois momentos partindo das derivações centrais em direção às frontais, partindo das occipitais em direção às centrais e frontais e partindo das parietais em direção às frontais e temporais. Destacaram-se as derivações F3 e F8 como destino de fluxo partindo das centrais, sendo F8 também destino de destaque partindo das parietais. Outros caminhos de fluxo de informação com diferenças estatísticas a se notar: O2 para C3, O2 para F7, P4 para Fz, P3 para T4 e P4 para T5.



**OB FLEX**




Figura 4.11: Valores da DTF na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

**OB FLEX**




Figura 4.12: Valores da DTF na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

A Figura 4.11 mostra que, para a tarefa motora de “observação da flexão de cotovelo”, utilizando a DTF na banda beta, os fluxos com diferenças estatísticas foram observados partindo das centrais para as temporais e partindo das temporais para as occipitais. Destacou-se a derivação T5 como destino de fluxo de informação partindo das derivações centrais (maior valor de DTF para o momento anterior à execução da tarefa) e O1 como destino do fluxo de informação partindo das temporais (maior DTF para o momento de execução da tarefa). Também destacou-se o fluxo partindo de C4 e Cz em direção à T6.

A Figura 4.12 mostra que, para a tarefa motora de “observação da flexão de cotovelo”, utilizando a DTF na banda gama, os fluxos com diferenças estatísticas foram observados partindo das centrais para as frontais e temporais, e partindo das occipitais em direção às centrais, parietais e temporais. Destacou-se C3 como origem do fluxo de informação especialmente em direção às frontais e P4 e T5 como destino do fluxo partindo das occipitais. Alguns caminhos cujo valor de DTF foi maior no momento anterior à execução da tarefa: C3 para F7, F8 e Fz, C4 para F8, Fz e T5, O1 e O2 para P4 e T5. Caminhos cujo valor da DTF foi maior no momento de execução da tarefa a se destacar: C3 para F3, O1 e O2 para C3, O2 para C4 e P3.

### 4.1.2 Coerência Direcionada Parcial

A Tabela 4.2 mostra os resultados da análise estatística, novamente comparando o momento anterior à execução da tarefa motora e sua execução, desta vez utilizando-se a PDC.

Tabela 4.2: Caminhos de fluxo de informação estatisticamente diferentes para a PDC nos ritmos do EEG analisados.

Tarefa	$\alpha$	$\beta$	$\gamma$
IME	-	$F \rightarrow C, F \rightarrow T$	$T \rightarrow F, F \rightarrow C, F \rightarrow P$
IMF	-	$F \rightarrow C, P \rightarrow F, T \rightarrow F$	$F \rightarrow T, F \rightarrow C$
MVE	-	$C \rightarrow F, T \rightarrow F, T \rightarrow O$	$T \rightarrow F, T \rightarrow P, F \rightarrow C$
MVF	-	$O \rightarrow T, O \rightarrow C, F \rightarrow C$	$C \rightarrow F, C \rightarrow T, P \rightarrow F$
OBE	-	$F \rightarrow T, F \rightarrow O$	$F \rightarrow T, F \rightarrow C, O \rightarrow C$
OBF	-	$O \rightarrow T, O \rightarrow F, O \rightarrow C$	$F \rightarrow T, C \rightarrow T$

Observa-se, na tabela 4.2, que novamente não foram encontradas diferenças estatísticas entre os momentos no ritmo alfa do EEG. Nas tarefas de IM, em gama ocorreu a inversão da direção do fluxo de informação entre as temporais e frontais, na extensão ( $F \rightarrow T$ ) e flexão ( $T \rightarrow F$ ) de cotovelo. Nota-se, nas tarefas de movimento, a inversão de fluxo de informação em ambos os ritmos beta e gama, entre as centrais e frontais, na extensão ( $C \rightarrow F$ ) e flexão ( $F \rightarrow C$ ) de cotovelo. Para as tarefas de OB, no ritmo beta ocorreu a inversão da direção do fluxo entre occipitais e frontais, na extensão ( $F \rightarrow O$ ) e flexão ( $O \rightarrow F$ ) de cotovelo.

Utilizando novamente os resultados do indivíduo 1 como exemplo, os gráficos a seguir mostram para cada tarefa motora os valores da PDC nos dois momentos: em azul está retratada o momento anterior à execução da tarefa; e em vermelho o momento de execução da tarefa. Os caminhos de fluxo de informação que se mostraram estatisticamente diferentes são exibidos.

**IM EXT**




Figura 4.13: Valores da PDC na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

**IM EXT**




Figura 4.14: Valores da PDC na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

A tarefa de “imaginação da extensão do cotovelo” na banda beta da PDC, mostrada na Figura 4.13, apresentou diferenças nos caminhos de fluxo de informação, comparando os dois momentos, com origem nas derivações frontais em direção às centrais e temporais. Observou-se que a PDC foi maior no momento anterior à execução da tarefa especialmente nos caminhos de fluxo: Fz para C3, C4 e Cz, F3 e F4 para T3. A PDC apresentou valores superiores na execução da tarefa mais notavelmente nos caminhos de fluxo: F3 para C4, F7 para T3 e Fz para T4.

A tarefa de “imaginação da extensão do cotovelo” na banda gama da PDC, mostrada na Figura 4.14, apresentou diferenças nos caminhos de fluxo de informação, com origem nas derivações frontais em direção às centrais e parietais e com origem nas temporais em direção às frontais. Observaram-se as derivações C4, Cz e P4 como destino de fluxo partindo das frontais com diferenças mais notáveis. As derivações F4, F8 e Fz apresentaram também diferenças notáveis, porém com o fluxo de informação se originando das derivações temporais.

# IM FLEX




Figura 4.15: Valores da PDC na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.



# IM FLEX




Figura 4.16: Valores da PDC na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Imaginação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

Observando a Figura 4.15 em que está representada a tarefa “imaginação da flexão de cotovelo” na banda beta da PDC, notou-se o fluxo partindo das derivações frontais em direção às centrais e partindo das derivações parietais e temporais em direção às frontais. Os caminhos de fluxo de informação com diferenças estatísticas partindo das frontais podem ser notados com mais facilidade com destino à derivação Cz. As derivações F3 e F7 apresentaram diferenças entre os momentos partindo das parietais e temporais, em especial partindo de P3, P4, T4 e T5.

Observando a Figura 4.16 em que está representada a tarefa “imaginação da flexão de cotovelo” na banda gama da PDC, notou-se o fluxo partindo das derivações frontais em direção às derivações centrais e temporais. A maioria dos caminhos de fluxo com diferença apresentaram valores de PDC maiores no momento anterior à execução da tarefa, com exceção de F4 para T4, notou-se especialmente: Fz para Cz, F3 para T4 e T5, F7 para T3, T5 e T6, e F8 para C4.

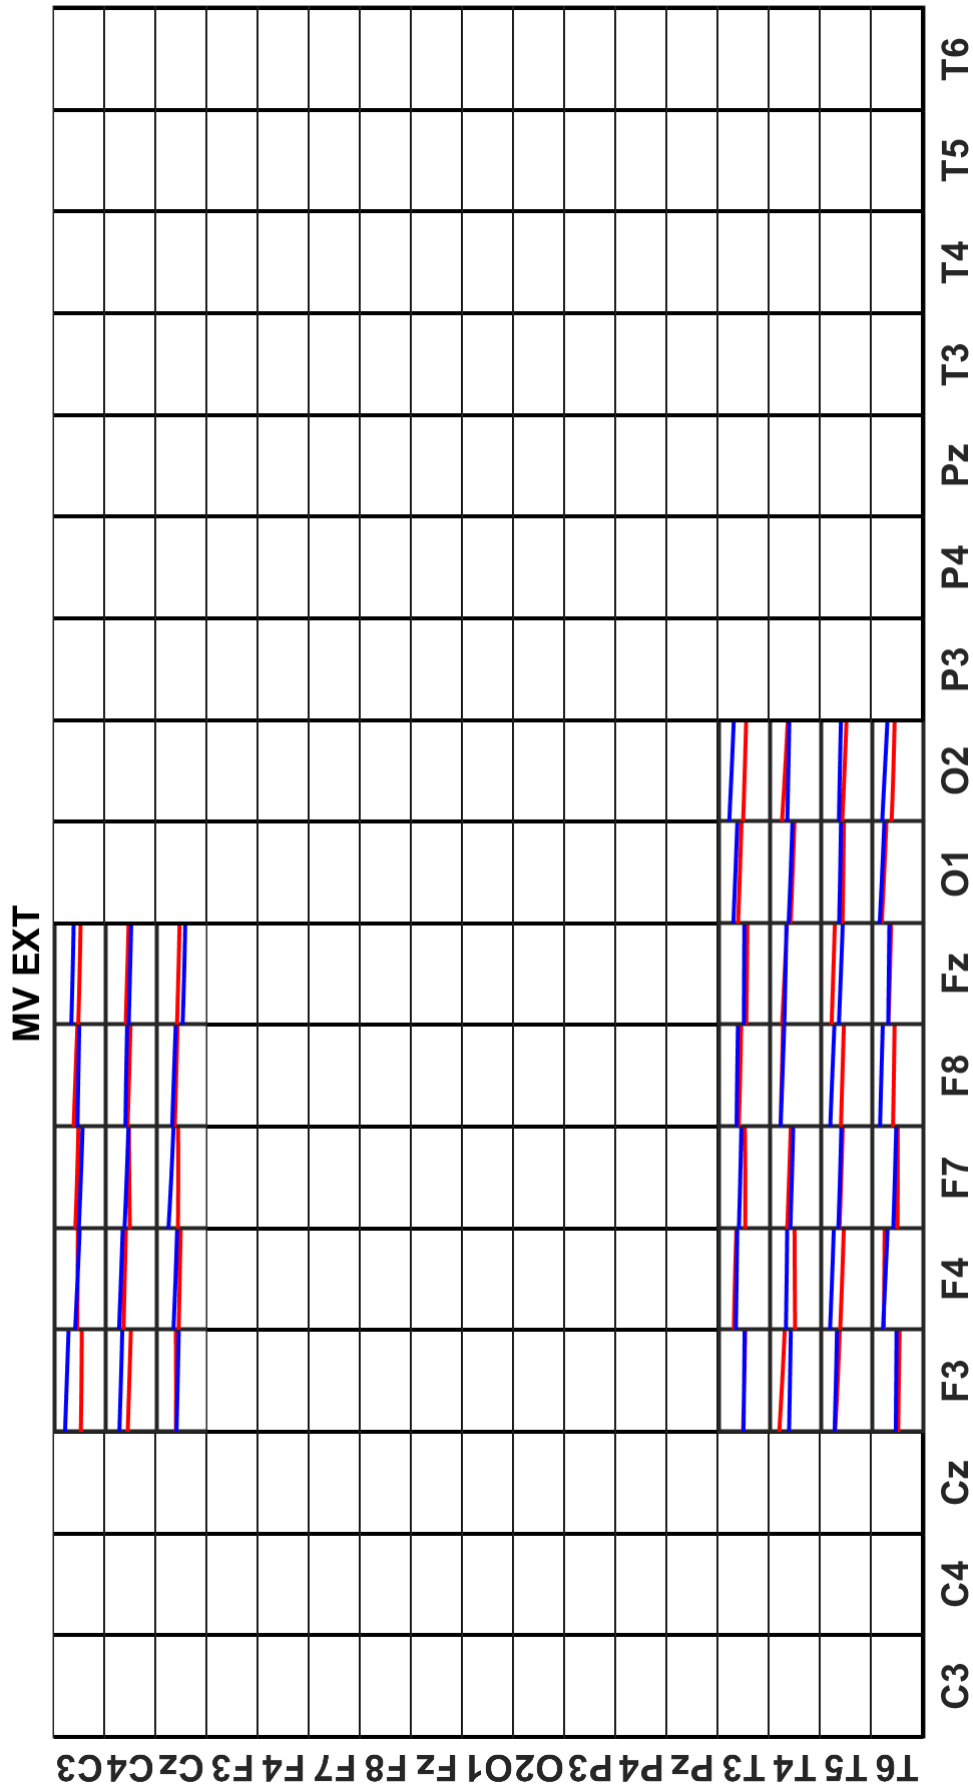


Figura 4.17: Valores da PDC na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Movimento de Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.




Figura 4.18: Valores da PDC na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Movimento de Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

Para o “movimento de extensão do cotovelo” na PDC na banda beta, visto em 4.17, foram observados fluxos partindo das derivações centrais em direção às frontais e partindo das derivações temporais em direção às frontais e occipitais. Os caminhos de fluxo de informação com diferenças estatísticas mais notáveis foram: C3 e C4 para F3, T5 e T6 para F8, e T3 e T6 para O2. Novamente, os maiores valores de PDC foram encontrados no momento anterior à execução da tarefa.

Para o “movimento de extensão do cotovelo” na PDC na banda gama, visto em 4.18, foram observados caminhos de fluxo de informação partindo das derivações frontais em direção às centrais e partindo das temporais em direção às frontais e parietais. Alguns caminhos apresentaram diferenças mais notáveis como: F4 e Fz para Cz, T5 para F4, T5 e T6 para F8, T5 para Fz, T3 e T4 para P4 (maior PDC na execução da tarefa) e T3 para Pz.

### MV FLEX




Figura 4.19: Valores da PDC na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Movimento de Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.




Figura 4.20: Valores da PDC na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Movimento de Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

A Figura 4.19, da tarefa “movimento de flexão de cotovelo” da PDC na banda beta, mostra os caminhos com diferenças estatísticas partindo das derivações frontais em direção às centrais e partindo das occipitais em direção às centrais e temporais. Novamente os caminhos com diferenças mais notáveis apresentaram maiores valores de PDC no momento anterior à execução da tarefa, com exceção de F4 e F8 para Cz e F7 para C4, podendo-se destacar: F3 para Cz, F8 para C3 e C4, Fz e O1 para Cz, O2 para C3, e O1 e O2 para T3.

A Figura 4.20, da tarefa “movimento de flexão de cotovelo” da PDC na banda gama, mostra os caminhos com diferenças estatísticas partindo das derivações centrais em direção às frontais e temporais e partindo das derivações parietais em direção às frontais. Notou-se que as derivações F4 e F7 mostraram maiores diferenças no destino de fluxo de informação partindo das parietais.






Figura 4.21: Valores da PDC na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

**OB EXT**




Figura 4.22: Valores da PDC na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Extensão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

Para a tarefa de “observação da extensão de cotovelo” da PDC na banda beta, vista na Figura 4.21, os caminhos que diferenciaram estatisticamente os dois momentos da tarefa se originaram das derivações frontais em direção às occipitais e temporais. Os maiores valores de PDC nos caminhos que apresentaram diferenças mais notáveis aconteceram no momento anterior à execução. Notou-se as derivações O1, O2, T3 e T6 em especial como destino do fluxo de informação partindo das frontais, com destaque para F3, F4 e F7.

Para a tarefa de “observação da extensão de cotovelo” da PDC na banda gama, vista na Figura 4.22, os caminhos que diferenciaram estatisticamente os dois momentos da tarefa se originaram das derivações frontais em direção às centrais e temporais. Os caminhos com diferenças estatísticas com diferenças mais notáveis foram: F8 e Fz para C4, F7 para T3 e F4 e F8 para T6.

## OB FLEX




Figura 4.23: Valores da PDC na banda beta nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

**OB FLEX**




Figura 4.24: Valores da PDC na banda gama nos caminhos de fluxo de informação que apresentaram diferenças estatísticas, para a classe “Observação da Flexão de cotovelo”, para o indivíduo 1. No eixo das ordenadas é mostrada a derivação de origem do fluxo de informação e no eixo das abscissas, a derivação de destino. Em azul está retratado um segundo antes da tarefa; e em vermelho o momento de execução da tarefa.

Na Figura 4.23, da tarefa “observação da flexão de cotovelo” da PDC na banda beta, observa-se os caminhos de fluxo de informação com diferenças estatísticas partindo das derivações occipitais em direção à todas as outras com exceção das parietais. As derivações temporais mostraram diferenças mais notáveis como destino de fluxo partindo de O1 e O2. Outros caminhos de destaque foram: O2 para C4, O1 para F8 e O2 para F7. Todos os caminhos com diferenças mais notáveis apresentaram maiores valores de PDC no momento anterior à execução da tarefa.

Na Figura 4.24, da tarefa “observação da flexão de cotovelo” da PDC na banda gama, observa-se os caminhos de fluxo de informação com diferenças estatísticas partindo das derivações centrais e frontais em direção às temporais. Como destino de fluxo de informação nas derivações temporais, somente T4 não apresentou diferenças tão marcantes entre os dois momentos. Destacou-se novamente o maior valor da PDC no momento anterior à execução da tarefa. As derivações C4, Cz, F3, F4, F8 e Fz apresentaram diferenças mais notáveis na origem do fluxo de informação em direção às derivações temporais.

## 4.2 Classificadores

Na classificação foram utilizados como características todos os possíveis caminhos de fluxo de informação durante a execução da tarefa, estimados pela DTF e PDC. Foram investigados separadamente os ritmos alfa, beta e gama do EEG. Os estimadores de conectividade cerebral, DTF e PDC, foram avaliados separadamente como característica para os classificadores.

Primeiramente, avaliou-se o processo de classificação utilizando Árvores de Decisão. A Tabela 4.3 exibe os resultados da classificação utilizando a DTF em cada banda de frequência e em cada indivíduo.

Tabela 4.3: Acurácias e desvio padrão das Árvores de Decisão utilizando a DTF.

Indivíduo	Acurácia $\pm$ dp % ( $\alpha$ )	Acurácia $\pm$ dp % ( $\beta$ )	Acurácia $\pm$ dp % ( $\gamma$ )
S1	48.4 $\pm$ 2.2	42.0 $\pm$ 2.0	45.0 $\pm$ 2.2
S2	45.8 $\pm$ 2.3	42.2 $\pm$ 1.9	50.5 $\pm$ 1.8
S3	51.1 $\pm$ 1.3	42.3 $\pm$ 1.7	48.1 $\pm$ 1.5
S4	56.9 $\pm$ 2.0	48.1 $\pm$ 1.5	51.0 $\pm$ 1.2
S5	47.3 $\pm$ 1.8	43.0 $\pm$ 2.1	58.7 $\pm$ 1.7
S6	52.3 $\pm$ 1.8	45.1 $\pm$ 1.6	50.6 $\pm$ 1.0
S7	55.5 $\pm$ 1.9	35.3 $\pm$ 3.2	35.4 $\pm$ 1.2
S8	57.3 $\pm$ 1.9	44.3 $\pm$ 1.2	45.6 $\pm$ 2.7
S9	51.3 $\pm$ 2.2	34.1 $\pm$ 1.8	39.0 $\pm$ 1.7
S10	51.2 $\pm$ 1.7	36.4 $\pm$ 1.9	38.9 $\pm$ 1.9
S11	56.1 $\pm$ 2.1	48.6 $\pm$ 2.0	56.4 $\pm$ 1.4
S12	54.1 $\pm$ 1.8	40.9 $\pm$ 1.7	42.2 $\pm$ 2.1
Média	52.3	41.9	46.8

Utilizando a DTF como característica nas Árvores de Decisão, os melhores resultados em média são obtidos no ritmo alfa do EEG, porém a maior acurácia geral foi obtida no ritmo gama pelo indivíduo S5, de 58.7%.

Na Tabela 4.4 são mostrados os resultados da classificação da PDC por Árvore de Decisão.

Tabela 4.4: Acurácias e desvio padrão das Árvores de Decisão utilizando a PDC.

Indivíduo	Acurácia $\pm$ dp % ( $\alpha$ )	Acurácia $\pm$ dp % ( $\beta$ )	Acurácia $\pm$ dp % ( $\gamma$ )
S1	72.5 $\pm$ 1.8	66.3 $\pm$ 1.8	65.3 $\pm$ 1.6
S2	73.6 $\pm$ 1.9	68.5 $\pm$ 1.8	67.4 $\pm$ 2.1
S3	74.7 $\pm$ 1.0	68.7 $\pm$ 1.5	68.1 $\pm$ 1.7
S4	75.5 $\pm$ 1.5	71.9 $\pm$ 1.3	74.1 $\pm$ 1.5
S5	74.6 $\pm$ 1.7	66.4 $\pm$ 1.5	69.3 $\pm$ 1.5
S6	71.9 $\pm$ 1.7	68.1 $\pm$ 1.8	68.7 $\pm$ 0.6
S7	67.5 $\pm$ 1.5	59.9 $\pm$ 2.1	62.7 $\pm$ 2.5
S8	68.5 $\pm$ 2.0	62.8 $\pm$ 1.7	64.2 $\pm$ 1.2
S9	66.5 $\pm$ 1.8	58.4 $\pm$ 1.9	62.0 $\pm$ 1.7
S10	67.6 $\pm$ 1.4	61.6 $\pm$ 1.6	62.6 $\pm$ 1.2
S11	64.4 $\pm$ 1.3	55.1 $\pm$ 2.6	58.8 $\pm$ 1.7
S12	69.1 $\pm$ 1.3	61.0 $\pm$ 2.0	63.1 $\pm$ 1.6
Média	70.5	64.1	65.5

Tendo como característica os valores de PDC nas Árvores de Decisão, os resultados são superiores do que utilizando a DTF. Novamente as acurácias são superiores quando se utiliza o ritmo alfa do EEG na classificação, atingindo o valor máximo de 75.5% para o indivíduo S4.

Posteriormente, as mesmas características extraídas por meio da DTF e PDC foram aplicadas à Redes Neurais e os resultados são exibidos a seguir. A Figura 4.25 exibe a matriz de confusão da rede neural para um dos indivíduos utilizando os caminhos de fluxo de informação no ritmo gama, calculados pela PDC, como característica.

As classes são ordenadas de 1 a 7:

1. Imaginação da extensão de cotovelo (IME);
2. Imaginação da flexão de cotovelo (IMF);
3. Movimento de extensão de cotovelo (MVE);
4. Movimento de flexão de cotovelo (MVF);
5. Observação da extensão de cotovelo (OBE);
6. Observação da flexão de cotovelo (OBF);
7. Repouso (REP).



### Matriz de confusão geral

Classes de saída	1	121 13.8%	5 0.6%	2 0.2%	4 0.5%	3 0.3%	0 0.0%	2 0.2%	88.3% 11.7%
	2	2 0.2%	112 12.8%	1 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	97.4% 2.6%
	3	0 0.0%	2 0.2%	117 13.4%	1 0.1%	6 0.7%	1 0.1%	1 0.1%	91.4% 8.6%
	4	2 0.2%	2 0.2%	3 0.3%	119 13.6%	3 0.3%	0 0.0%	1 0.1%	91.5% 8.5%
	5	0 0.0%	4 0.5%	2 0.2%	0 0.0%	112 12.8%	0 0.0%	0 0.0%	94.9% 5.1%
	6	0 0.0%	0 0.0%	0 0.0%	1 0.1%	1 0.1%	123 14.1%	0 0.0%	98.4% 1.6%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.1%	121 13.8%	99.2% 0.8%
			96.8% 3.2%	89.6% 10.4%	93.6% 6.4%	95.2% 4.8%	89.6% 10.4%	98.4% 1.6%	96.8% 3.2%
	Classes alvo	1	2	3	4	5	6	7	

Figura 4.25: Matriz de confusão geral do classificador por ANN do indivíduo S1 na banda gama, utilizando a PDC, em uma das classificações. As classes são de 1 a 7: IME, IMF, MVE, MVF, OBE, OBF, REP, respectivamente.

A diagonal principal da matriz de confusão mostra o número e porcentagem de classificações corretas da rede. Por exemplo, o primeiro quadrado dá a informação que 121 amostras foram corretamente classificadas como “imaginação da extensão de cotovelo” (classe número 1), e esse número de amostras corresponde a 13.8% das 875 amostras. Da mesma forma, o segundo quadrado da diagonal dá a informação que 112 amostras foram corretamente classificadas como “imaginação da flexão de cotovelo” (classe número 2), correspondendo a 12.8% do total de amostras. Os quadrados na última linha da matriz de confusão mostram o percentual de amostras que foram atribuídas corretamente a cada classe do total de amostras que existiam por classe (somando-se os números de cada coluna encontra-se sempre 125, que é o número de amostras por classe), por exemplo, para a classe “movimento de extensão de cotovelo” (classe número 3), das 125 amostras dessa classe, 93.6% foram classificadas corretamente e 6.4% foram atribuídas a outras classes. A última coluna da matriz de confusão fornece o percentual de amostras atribuídas a uma classe corretamente do total de amostras que o classificador escolheu para aquela classe, por exemplo, para a classe “movimento de flexão de cotovelo” (classe número

4), foram classificadas 91.5% das amostras corretamente (119 em 130) e obviamente 8.5% equivocadas (11 em 130). Observa-se a média da acurácia geral no canto inferior direito, nesse exemplo foi de 94.3% (825 amostras das 875 totais).

A matriz exibida na figura 4.25 exemplifica o processo de classificação para um indivíduo no ritmo de EEG gama e utilizando a PDC como característica. O mesmo processo foi feito para cada indivíduo e também utilizando a DTF como característica.

O processo de classificação foi realizado utilizando tanto a DTF quanto a PDC. Esse processo foi repetido 100 vezes para cada indivíduo em cada banda analisada para assegurar que as redes iniciassem com pesos diferentes a cada iteração. Numa situação de aplicação real, o classificador seria treinado para um indivíduo e seria escolhida a rede que obteve a melhor acurácia somente, porém é válida a análise da acurácia para diversas iterações para assegurar a robustez do método.

Na Tabela 4.5 são exibidos os resultados da classificação por redes neurais utilizando a DTF como característica.

Tabela 4.5: Acurácias e desvio padrão das Redes Neurais utilizando a DTF.

Indivíduo	Acurácia $\pm$ dp % ( $\alpha$ )	Acurácia $\pm$ dp % ( $\beta$ )	Acurácia $\pm$ dp % ( $\gamma$ )
S1	79.4 $\pm$ 16.9	78.7 $\pm$ 19.4	81.7 $\pm$ 16.8
S2	83.2 $\pm$ 13.7	82.1 $\pm$ 17.8	87.4 $\pm$ 6.6
S3	77.2 $\pm$ 19.1	80.9 $\pm$ 19.2	82.8 $\pm$ 18.2
S4	86.1 $\pm$ 12.1	88.0 $\pm$ 11.4	90.6 $\pm$ 7.0
S5	82.2 $\pm$ 15.4	85.8 $\pm$ 12.7	86.5 $\pm$ 14.4
S6	82.5 $\pm$ 9.2	82.5 $\pm$ 16.2	86.5 $\pm$ 9.6
S7	76.5 $\pm$ 18.1	61.0 $\pm$ 26.7	67.6 $\pm$ 24.9
S8	78.5 $\pm$ 16.9	75.5 $\pm$ 20.4	73.9 $\pm$ 21.2
S9	79.7 $\pm$ 14.9	71.2 $\pm$ 21.9	70.7 $\pm$ 25.4
S10	76.6 $\pm$ 20.9	69.6 $\pm$ 23.1	68.9 $\pm$ 22.0
S11	81.9 $\pm$ 16.9	86.7 $\pm$ 21.2	90.0 $\pm$ 15.6
S12	73.0 $\pm$ 22.0	71.1 $\pm$ 22.4	69.8 $\pm$ 25.0
Média	79.7	77.8	80.5

As acurácias obtidas utilizando a DTF em ANN se mostram superiores ao método de classificação por Árvores de Decisão. Em média a classificação utilizando o ritmo gama do EEG obtém maiores valores de acurácia, porém enquanto no ritmo alfa o indivíduo com menor acurácia S12 tem 73.0%, no ritmo gama do EEG o pior resultado, em S7, apresenta 67.6%, reforçando a ideia de que se deve “calibrar” para cada indivíduo para encontrar a faixa ideal para aplicação em uma ICM.

A tabela 4.6 mostra os resultados da classificação por redes neurais utilizando a DTF e variando o número de amostras de cada tarefa para o treinamento de cada rede.

Tabela 4.6: Acurácia média das Redes Neurais utilizando a DTF, com diferentes números de amostras.

Número de Amostras	Acurácia % ( $\alpha$ )	Acurácia % ( $\beta$ )	Acurácia % ( $\gamma$ )
1	18.1	29.0	19.3
5	33.8	39.2	36.8
10	48.2	55.3	55.1
15	63.9	68.0	68.7
20	72.6	73.7	79.7
25	79.7	77.8	80.5

A acurácia média da classificação aumenta progressivamente conforme mais amostras da mesma tarefa são inseridas na rede neural. Destaca-se que mesmo com apenas uma amostra por tarefa (uma execução da tarefa) a acurácia do classificador é superior a uma classificação aleatória, que teria probabilidade de um em sete (14.3%). A partir de vinte amostras por tarefa a rede já apresenta acurácias elevadas, apresentando uma menor proporção de melhora com a adição de mais amostras.

Na tabela 4.7 são exibidos os resultados da classificação por redes neurais utilizando a PDC como característica.

Tabela 4.7: Acurácias e desvio padrão das Redes Neurais utilizando a PDC.

Indivíduo	Acurácia $\pm$ dp % ( $\alpha$ )	Acurácia $\pm$ dp % ( $\beta$ )	Acurácia $\pm$ dp % ( $\gamma$ )
S1	84.5 $\pm$ 11.0	90.7 $\pm$ 11.7	89.7 $\pm$ 11.3
S2	91.5 $\pm$ 8.4	95.7 $\pm$ 14.3	94.5 $\pm$ 11.6
S3	88.5 $\pm$ 4.1	91.4 $\pm$ 16.8	91.4 $\pm$ 13.2
S4	87.3 $\pm$ 4.6	94.6 $\pm$ 4.7	93.9 $\pm$ 11.4
S5	91.3 $\pm$ 10.5	97.0 $\pm$ 10.0	93.5 $\pm$ 13.5
S6	87.3 $\pm$ 11.0	96.2 $\pm$ 4.8	93.4 $\pm$ 12.3
S7	78.1 $\pm$ 18.9	83.7 $\pm$ 19.8	77.2 $\pm$ 23.6
S8	80.4 $\pm$ 12.5	80.6 $\pm$ 18.1	83.2 $\pm$ 13.8
S9	81.9 $\pm$ 13.9	87.0 $\pm$ 13.2	80.7 $\pm$ 20.6
S10	79.7 $\pm$ 15.7	83.7 $\pm$ 14.4	76.1 $\pm$ 24.1
S11	89.5 $\pm$ 14.5	89.0 $\pm$ 23.5	85.9 $\pm$ 23.0
S12	79.2 $\pm$ 14.7	77.3 $\pm$ 22.1	74.7 $\pm$ 22.1
Média	84.9	88.9	86.2

Analisando-se os resultados das ANN utilizando a PDC como característica, pode-se observar que a maior média de acurácias ocorre quando se utiliza o ritmo beta do EEG. Essa combinação resulta na maior acurácia de classificação, sendo 97.0% para o indivíduo S5. A PDC se mostra, de modo geral, superior em todos os ritmos do EEG como característica para classificação das tarefas motoras utilizando ANN.

Novamente, a acurácia da classificação com redes neurais utilizando a PDC foi avaliada variando-se o número de amostras por tarefa. Os resultados são exibidos na tabela 4.8.

Tabela 4.8: Acurácia média das Redes Neurais utilizando a PDC, com diferentes números de amostras.

Número de Amostras	Acurácia % ( $\alpha$ )	Acurácia % ( $\beta$ )	Acurácia % ( $\gamma$ )
1	27.4	25.8	28.7
5	46.2	44.3	42.7
10	54.6	58.5	61.6
15	71.3	75.0	72.3
20	81.0	84.3	82.5
25	84.9	88.9	86.2

A mesma tendência observada para a DTF se repete aqui. A acurácia média do classificador aumenta conforme mais amostras de cada tarefa são adicionadas, mas não de forma linear. Ao se aproximar de quinze amostras por tarefa, a acurácia média atinge valores elevados e a adição de amostras aumenta, porém em menor proporção, a acurácia. Novamente, destaca-se que mesmo com apenas uma execução por tarefa a rede neural classifica com acurácia superior à uma classificação aleatória.

Além das classificações utilizando-se os estimadores de conectividade cerebral como característica, foram realizadas classificações por ANN utilizando-se a energia do EEG, buscando um critério de comparação com a literatura, utilizando a mesma base de dados. Os resultados dessa classificação podem ser vistos na Tabela 4.9.

Tabela 4.9: Acurácias e desvio padrão das Redes Neurais utilizando a energia do EEG.

Indivíduo	Acurácia $\pm$ dp % ( $\alpha$ )	Acurácia $\pm$ dp % ( $\beta$ )	Acurácia $\pm$ dp % ( $\gamma$ )
S1	28.1 $\pm$ 8.4	28.1 $\pm$ 9.1	18.1 $\pm$ 4.1
S2	44.5 $\pm$ 12.5	42.9 $\pm$ 14.4	32.6 $\pm$ 11.4
S3	29.3 $\pm$ 8.4	35.1 $\pm$ 12.5	40.9 $\pm$ 11.6
S4	52.1 $\pm$ 9.1	59.4 $\pm$ 9.3	59.8 $\pm$ 6.7
S5	48.6 $\pm$ 12.0	46.5 $\pm$ 11.7	59.4 $\pm$ 11.0
S6	24.6 $\pm$ 7.1	40.0 $\pm$ 9.3	18.2 $\pm$ 4.8
S7	16.8 $\pm$ 3.3	18.9 $\pm$ 4.0	19.2 $\pm$ 4.4
S8	17.6 $\pm$ 3.0	17.9 $\pm$ 3.7	19.2 $\pm$ 3.8
S9	17.3 $\pm$ 3.5	21.3 $\pm$ 5.1	19.7 $\pm$ 4.7
S10	16.7 $\pm$ 3.0	18.3 $\pm$ 3.9	19.0 $\pm$ 4.8
S11	18.7 $\pm$ 3.4	18.3 $\pm$ 3.7	16.8 $\pm$ 3.1
S12	16.3 $\pm$ 3.4	17.8 $\pm$ 3.5	18.3 $\pm$ 4.3
Média	27.6	30.4	26.8

Utilizando a energia do EEG como característica em ANN, como pode ser visto na tabela 4.9, os valores de acurácia de classificação médios encontrados foram próximos a 30%. A melhor média de acurácia foi encontrada utilizando a banda beta do EEG, 30.4%. A melhor acurácia individual ocorreu na banda gama para o indivíduo S5, 59.8%.

Resumindo os resultados de classificação encontrados pode-se afirmar que:

- Para o problema de classificação aqui investigado, o método de ANN apresenta acurácia superior ao método por Árvores de Decisão;
- Os desvios padrão das acurácias entre as várias iterações de classificação realizadas são superiores utilizando ANN em relação a Árvores de Decisão.
- Utilizando-se a PDC como característica para o classificador, encontra-se melhores resultados do que utilizando-se a DTF como característica.
- A acurácia do classificador aumenta conforme mais amostras de cada tarefa são adicionadas à ANN.
- A acurácia da classificação utilizando a energia do EEG como característica é inferior a classificação utilizando os métodos de estimativa de conectividade cerebral aqui investigados.

# Capítulo 5

## Discussão e Conclusões

Para tarefas motoras, como estudado em (KUŠ *et al.*, 2005; PFURTSCHELLER e NEUPER, 1997), os caminhos de fluxo de informação seguem contralateralmente ao movimento para a maioria dos indivíduos, os mesmos resultados foram observados neste trabalho.

Alguns autores (GINTER *et al.*, 2001; KUŠ *et al.*, 2005; SALMELIN e HARI, 1994) reportam a propagação em beta após o movimento partindo das derivações frontais, indicando a existência de uma fonte de atividade beta nessas áreas. Comparando-se estes resultados com as diferenças estatísticas apresentadas nas tabelas 4.1 e 4.2, as derivações frontais apresentam diferenças estatísticas entre o fluxo de informação entre o momento anterior à execução e o momento de execução da tarefa motora para o ritmo beta, especialmente analisando a PDC para a imagética motora e tarefas de execução do movimento.

Utilizando EEG de alta densidade para investigar tarefas de execução e observação do movimento das mãos e dos pés, pesquisadores não encontraram flutuações espectrais para a tarefa de observação, porém encontraram utilizando a conectividade cerebral (KLINE *et al.*, 2016). No presente trabalho ambos os estimadores de conectividade cerebral apresentaram diferenças significativas entre os dois momentos nas tarefas de observação nos ritmos beta e gama do EEG, principalmente nas regiões occipital, parietal e central, como esperado.

A maioria dos estudos que investigam padrões da conectividade cerebral se restringe a analisar as regiões do córtex mais relacionadas com a execução das tarefas motoras, o que torna difícil a comparação com os resultados aqui apresentados. Porém a análise de outras regiões do córtex cerebral é relevante, pois como citado por BLINOWSKA *et al.* (2010), frequentemente ocorrem transmissões de informação entre áreas consideradas distantes, principalmente devido a inibição de

estruturas motoras se originar de conexões corticais de longa distância.

Apesar das semelhanças com os resultados encontrados com os estudos citados, a análise dos padrões de fluxo de informação no momento anterior à execução e execução das tarefas utilizando os métodos aqui apresentados podem não ser ideais. Existem técnicas mais adequadas à esta análise como a *Short Time Directed Transfer Function* (SDTF) (BLINOWSKA *et al.*, 2010; GINTER *et al.*, 2005; KUŚ *et al.*, 2005), que investiga a variação da conectividade cerebral temporalmente. Trabalhos futuros também utilizarão esta técnica.

A literatura (GÜRKAN *et al.*, 2014; OMIDVARNIA *et al.*, 2011) sugere que o PDC é capaz de estimar caminhos de fluxo de informação melhor que a DTF. No trabalho aqui mostrado, a utilização da PDC como característica para o classificador levou a uma melhor separação das 7 classes, permitindo uma maior acurácia em todos os ritmos do EEG analisados.

Os resultados utilizando redes neurais apresentam um desvio padrão elevado, o que pode ter sido causado pelos pesos iniciais aleatórios que a rede escolheu. Em aplicações reais, a rede neural pode ser treinada e calibrada com cada indivíduo antes da aplicação ICM garantindo o melhor resultado. Isso também é importante pois a baixa amplitude e presença de ruído nos dados de EEG podem levar a inconsistência nos padrões entre indivíduos diferentes (ASENSIO-CUBERO *et al.*, 2013).

A classificação de tarefas motoras em membros diferentes é bem estudada, como em WANG *et al.* (2006) onde obteve-se uma acurácia de 96.13% utilizando-se a sincronia em larga escala e características da energia combinadas para a imaginação do movimento das mãos esquerda e direita. A mesma tarefa foi classificada em WEI *et al.* (2007) com 93.3% de acurácia utilizando coeficientes autoregressivos estimados de sinais EEG por algoritmo *Burg*. Utilizando ICA e PDC CHEN *et al.* (2012) obtiveram 86% e 92% de acurácia para a imaginação de mão esquerda e direita, respectivamente, para aplicações ICM. Em CHAKRABORTI *et al.* (2011), os autores encontraram acurácias entre 56% e 93% para o movimento dos braços direito e esquerdo, permitindo uma aplicação ICM.

O problema das tarefas motoras com ativação em áreas corticais adjacentes é investigado aqui devido à sua importância, como citado em HAMEDDI *et al.* (2016), a distinção entre outras tarefas de controle motor ou imaginação melhoraria substancialmente a confiabilidade das ICMs em aplicações reais.

Entretanto, poucos estudos investigam a classificação de atividade motora de mesmo membro, e estes apresentam resultados inferiores comparados ao método aqui apresentado. Como citado com mais detalhes na seção de características utilizadas em ICM: LANA *et al.* (2013) não conseguiram diferenciar movimentos de mesmo membro (extensão e flexão de cotovelo), YONG e MENON (2015) obtiveram acurácia de 60.7% entre três classes de IM (repouso, aperto de mão e movimento de cotovelo), TAVAKOLAN *et al.* (2017) obtiveram 74.2% para três classes de IM (repouso, aperto de mão e movimento do cotovelo), SHIMAN *et al.* (2015) obtiveram 39.5% para cinco tarefas motoras (alcançar quatro alvos com o braço, repouso) e, mais recentemente, SHIMAN *et al.* (2017) obtiveram 50% para seis tarefas motoras (alcançar quatro alvos com o braço, retorno à posição inicial e repouso). O método aqui investigado apresentou acurácia média de 88.9% utilizando a PDC no ritmo beta em ANN, para sete tarefas motoras (imaginação, execução e observação da extensão e flexão de cotovelo, e repouso).

Os trabalhos citados no parágrafo anterior, assim como o presente trabalho, utilizaram o momento da execução da tarefa para a classificação. Em trabalhos futuros também será investigada a utilização da conectividade cerebral, no momento anterior à execução da tarefa motora, como característica para a classificação. Essa classificação pode aumentar a rapidez na execução de tarefas por uma ICM.

O ritmo alfa do EEG estudado com a DTF mostrou resultados promissores na identificação de padrões em imagética motora (extensão e flexão do cotovelo) no córtex motor (SILVA *et al.*, 2014). Aqui, a classificação das 7 tarefas motoras utilizando a banda alfa, da DTF e também da PDC, apresentou acurácias superiores àquelas encontradas em beta e gama, na classificação por árvores de decisão.

Estudos tem demonstrado a importância de investigar a conectividade cerebral nas bandas mais altas do EEG, como o ritmo gama BLINOWSKA *et al.* (2010); GINTER *et al.* (2005); GROSSE-WENTRUP (2009); KUŚ *et al.* (2005). Segundo esses estudos, a conectividade cerebral na banda gama apresenta características particulares para diferentes tarefas motoras realizadas. Os melhores resultados de classificação deste trabalho foram encontrados utilizando a PDC das bandas beta e gama do EEG e redes neurais.

A maioria dos estudos de classificação de tarefa motora com sinais de EEG busca a classificação de imaginação motora. O método aqui utilizado foi também aplicado num estudo de classificação somente entre as tarefas de imaginação de



extensão e flexão de cotovelo e repouso, atingindo acurácias próximas de 100%, mostrando-se promissor para aplicações ICM (SILVEIRA *et al.*, 2016). Neste trabalho também foi discutida a influência do número de amostras de cada tarefa na acurácia da ANN e resultados semelhantes foram encontrados: valores elevados de acurácia a partir de 15 amostras por tarefa. O artigo publicado encontra-se no Anexo A.

A energia do EEG, que fora estudada em TAVAKOLAN *et al.* (2017); YONG e MENON (2015), também foi utilizada como característica aqui para ser comparada à DTF e PDC, e os resultados mostraram acurácias inferiores do que a utilização da conectividade cerebral como característica.

O desenvolvimento de uma ICM com capacidade de diferenciar o tipo de atividade motora realizada num mesmo segmento de membro seria importante para melhorar a qualidade de vida de pessoas com limitações motoras. Atualmente, a maioria das ICMs conseguem distinguir tarefas motoras de regiões topograficamente diferentes, como mãos, pés e língua, o que limita sua atuação (HAMEDİ *et al.*, 2016).

O estudo da interação humano-robô se mostra interessante para aplicações de ICMs que pretendem realizar diferentes tarefas motoras no mesmo segmento corporal. Um exemplo de aplicação da interação humano-robô seria uma prótese de braço robótica, que fosse capaz de identificar se o usuário está observando, imaginando ou executando uma tarefa, podendo atuar corretamente de acordo com cada situação.

O presente trabalho mostrou um método de classificação não-invasivo, utilizando sinais de EEG, que é promissor para aplicações ICM de controle de atividade motora realizada no mesmo segmento corporal. O desafio de desenvolver uma ICM com maior controle e flexibilidade de comandos ainda existe, e técnicas como a conectividade cerebral em conjunto com redes neurais, como investigado neste trabalho, se mostram promissoras para essa aplicação.

Nesta dissertação investigaram-se as etapas de extração de características e classificação das modalidades de tarefa motora. Para o desenvolvimento de uma ICM, a próxima etapa seria a implementação de um algoritmo de tradução. Este algoritmo transformaria a intenção do usuário em um comando, que ativaria a tarefa de assistência realizada, por exemplo, por um braço robótico.

# Referências Bibliográficas

- AKAIKE, H., 1974, “A new look at the statistical model identification”, *IEEE transactions on automatic control*, v. 19, n. 6, pp. 716–723.
- ALLISON, B., 2003, *P3 or not P3: Toward a Better P300 BCI*. Tese de Doutorado, University of California, San Diego.
- ALLISON, B. Z., BRUNNER, C., ALTSTÄTTER, C., et al., 2012, “A hybrid ERD/SSVEP BCI for continuous simultaneous two dimensional cursor control”, *Journal of neuroscience methods*, v. 209, n. 2, pp. 299–307.
- ALPAYDIN, E., 2014, *Introduction to machine learning*. MIT press.
- ANDERSON, C. W., STOLZ, E. A., SHAMSUNDER, S., 1998, “Multivariate autoregressive models for classification of spontaneous electroencephalographic signals during mental tasks”, *IEEE Transactions on Biomedical Engineering*, v. 45, n. 3, pp. 277–286.
- ASENSIO-CUBERO, J., GAN, J. Q., PALANIAPPAN, R., 2013, “Multiresolution analysis over simple graphs for brain computer interfaces”, *Journal of neural engineering*, v. 10, n. 4, pp. 046014.
- BABILONI, F., CINCOTTI, F., BABILONI, C., et al., 2005, “Estimation of the cortical functional connectivity with the multimodal integration of high-resolution EEG and fMRI data by directed transfer function”, *Neuroimage*, v. 24, n. 1, pp. 118–131.
- BACCALÁ, L. A., SAMESHIMA, K., 1998, “Directed coherence: a tool for exploring functional interactions among brain structures”, *Methods for neural ensemble recordings*, pp. 179–192.
- BEAR, M. F., CONNORS, B. W., PARADISO, M. A., 2007, *Neuroscience*, v. 2. Lippincott Williams & Wilkins.
- BEHRMANN, M., GENG, J. J., SHOMSTEIN, S., 2004, “Parietal cortex and attention”, *Current opinion in neurobiology*, v. 14, n. 2, pp. 212–217.

- BENDAT, J. S., PIERSOL, A. G., 2011, *Random data: analysis and measurement procedures*, v. 729. John Wiley & Sons.
- BLASCO, J. S., IÁÑEZ, E., UBEDA, A., et al., 2012, “Visual evoked potential-based brain-machine interface applications to assist disabled people”, *Expert Systems with Applications*, v. 39, n. 9, pp. 7908–7918.
- BLINOWSKA, K., KUS, R., KAMINSKI, M., et al., 2010, “Transmission of brain activity during cognitive task”, *Brain topography*, v. 23, n. 2, pp. 205–213.
- BLINOWSKA, K. J., KAMIŃSKI, M., 2006, “15 Multivariate Signal Analysis by Parametric Models”, *Handbook of Time Series Analysis: Recent Theoretical Developments and Applications*, p. 373.
- BLINOWSKA, K. J., KUŚ, R., KAMIŃSKI, M., 2004, “Granger causality and information flow in multivariate processes”, *Physical Review E*, v. 70, n. 5, pp. 050902.
- BREIMAN, L., FRIEDMAN, J., STONE, C. J., et al., 1984, *Classification and regression trees*. CRC press.
- CECOTTI, H., 2011, “Spelling with non-invasive Brain-Computer Interfaces—Current and future trends”, *Journal of Physiology-Paris*, v. 105, n. 1, pp. 106–114.
- CHAKRABORTI, T., SENGUPTA, A., BANERJEE, D., et al., 2011, “Implementation of EEG based control of remote robotic systems”. In: *Recent Trends in Information Systems (ReTIS), 2011 International Conference on*, pp. 203–208. IEEE.
- CHAPIN, J. K., MOXON, K. A., MARKOWITZ, R. S., et al., 1999, “Real-time control of a robot arm using simultaneously recorded neurons in the motor cortex”, *Nature neuroscience*, v. 2, n. 7, pp. 664–670.
- CHAPMAN, A., ALMEIDA, S., REIS, M., 2006, “EEG: leitura e interpretação”, *Petrópolis: EPUB*, v. 75.
- CHEN, D., LI, H., YANG, Y., et al., 2012, “Causal connectivity brain network: A novel method of motor imagery classification for brain-computer interface applications”. In: *Computing, Measurement, Control and Sensor Network (CMCSN), 2012 International Conference on*, pp. 87–90. IEEE.

- CUNHA, R. G., DA-SILVA, P. J. G., PAZ, C. C. D. S. C., et al., 2017, “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, pp. 28.
- DE VRIES, S., MULDER, T., 2007, “Motor imagery and stroke rehabilitation: a critical discussion”, *Journal of rehabilitation medicine*, v. 39, n. 1, pp. 5–13.
- DICKSTEIN, R., DEUTSCH, J. E., 2007, “Motor imagery in physical therapist practice”, *Physical therapy*, v. 87, n. 7, pp. 942.
- DORNHEGE, G., BLANKERTZ, B., CURIO, G., et al., 2004, “Boosting bit rates in noninvasive EEG single-trial classifications by feature combination and multiclass paradigms”, *IEEE Transactions on Biomedical Engineering*, v. 51, n. 6, pp. 993–1002.
- DOUD, A. J., LUCAS, J. P., PISANSKY, M. T., et al., 2011, “Continuous three-dimensional control of a virtual helicopter using a motor imagery based brain-computer interface”, *PloS one*, v. 6, n. 10, pp. e26322.
- FALLANI, F. D. V., PICHIORRI, F., MORONE, G., et al., 2013, “Multiscale topological properties of functional brain networks during motor imagery after stroke”, *Neuroimage*, v. 83, pp. 438–449.
- FATOURECHI, M., BASHASHATI, A., WARD, R. K., et al., 2007, “EMG and EOG artifacts in brain computer interface systems: A survey”, *Clinical neurophysiology*, v. 118, n. 3, pp. 480–494.
- FILHO, S. A. S., TIERRA-CRIOLLO, C. J., SOUZA, A. P., et al., 2009, “Magnitude Squared of Coherence to Detect Imaginary Movement”, *EURASIP J. Adv. Signal Process*, v. 2009 (jan.), pp. 5:1–5:12. ISSN: 1110-8657. doi: 10.1155/2009/534536. Disponível em: <<http://dx.doi.org/10.1155/2009/534536>>.
- FRANASZCZUK, P. J., BERGEY, G. K., 1998, “Application of the directed transfer function method to mesial and lateral onset temporal lobe seizures”, *Brain topography*, v. 11, n. 1, pp. 13–21.
- FRISTON, K. J., 2011, “Functional and effective connectivity: a review”, *Brain connectivity*, v. 1, n. 1, pp. 13–36.

- GINTER, J., BLINOWSKA, K., KAMIŃSKI, M., et al., 2001, “Phase and amplitude analysis in time–frequency space—application to voluntary finger movement”, *Journal of neuroscience methods*, v. 110, n. 1, pp. 113–124.
- GINTER, J., BLINOWSKA, K., KAMINSKI, M., et al., 2005, “Propagation of brain electrical activity during real and imagined motor task by directed transfer function”. In: *Neural Engineering, 2005. Conference Proceedings. 2nd International IEEE EMBS Conference on*, pp. 105–108. IEEE.
- GRANGER, C. W., 1969, “Investigating causal relations by econometric models and cross-spectral methods”, *Econometrica: Journal of the Econometric Society*, pp. 424–438.
- GROSSE-WENTRUP, M., 2009, “Understanding brain connectivity patterns during motor imagery for brain-computer interfacing”. In: *Advances in neural information processing systems*, pp. 561–568.
- GULRAJANI, R. M., 1998, *Bioelectricity and biomagnetism*. J. Wiley.
- GÜRKAN, G., AKAN, A., SEYHAN, T. Ö., 2014, “Analysis of brain connectivity changes after propofol injection by generalized partial directed coherence”, *Digital Signal Processing*, v. 25, pp. 156–163.
- HAMEDI, M., SALLEH, S.-H., NOOR, A. M., 2016, “Electroencephalographic motor imagery brain connectivity analysis for BCI: a review”, *Neural computation*.
- HANAKAWA, T., DIMYAN, M. A., HALLETT, M., 2008, “Motor planning, imagery, and execution in the distributed motor network: a time-course study with functional MRI”, *Cerebral cortex*, v. 18, n. 12, pp. 2775–2788.
- HATSOPOULOS, N., JOSHI, J., O’LEARY, J. G., 2004, “Decoding continuous and discrete motor behaviors using motor and premotor cortical ensembles”, *Journal of neurophysiology*, v. 92, n. 2, pp. 1165–1174.
- HAYKIN, S. S., HAYKIN, S. S., HAYKIN, S. S., et al., 2009, *Neural networks and learning machines*, v. 3. Pearson Upper Saddle River, NJ, USA:.
- HOCHBERG, L. R., SERRUYA, M. D., FRIEHS, G. M., et al., 2006, “Neural ensemble control of prosthetic devices by a human with tetraplegia”, *Nature*, v. 442, n. 7099, pp. 164–171.
- HOCHBERG, L. R., BACHER, D., JAROSIEWICZ, B., et al., 2012, “Reach and grasp by people with tetraplegia using a neurally controlled robotic arm”, *Nature*, v. 485, n. 7398, pp. 372–375.

- HUAN, N.-J., PALANIAPPAN, R., 2004, “Neural network classification of autoregressive features from electroencephalogram signals for brain–computer interface design”, *Journal of neural engineering*, v. 1, n. 3, pp. 142.
- HWANG, H.-J., LIM, J.-H., JUNG, Y.-J., et al., 2012, “Development of an SSVEP-based BCI spelling system adopting a QWERTY-style LED keyboard”, *Journal of neuroscience methods*, v. 208, n. 1, pp. 59–65.
- INOUYE, T., IYAMA, A., SHINOSAKI, K., et al., 1995, “Inter-site EEG relationships before widespread epileptiform discharges”, *International Journal of Neuroscience*, v. 82, n. 1-2, pp. 143–153.
- KALCHER, J., PFURTSCHELLER, G., 1995, “Discrimination between phase-locked and non-phase-locked event-related EEG activity”, *Electroencephalography and clinical neurophysiology*, v. 94, n. 5, pp. 381–384.
- KAMIŃSKI, M., BLINOWSKA, K., SZELENBERGER, W., 1997, “Topographic analysis of coherence and propagation of EEG activity during sleep and wakefulness”, *Electroencephalography and clinical neurophysiology*, v. 102, n. 3, pp. 216–227.
- KAMINSKI, M., BLINOWSKA, K. J., 1991, “A new method of the description of the information flow in the brain structures”, *Biological cybernetics*, v. 65, n. 3, pp. 203–210.
- KANDEL, E. R., 2007, *In search of memory: The emergence of a new science of mind*. WW Norton & Company.
- KANDEL, E. R., SCHWARTZ, J. H., JESSELL, T. M., et al., 2000, *Principles of neural science*, v. 4. McGraw-hill New York.
- KIM, T.-H., 2010, “Pattern recognition using artificial neural network: a review”. In: *International Conference on Information Security and Assurance*, pp. 138–148. Springer.
- KLINE, J. E., HUANG, H. J., SNYDER, K. L., et al., 2016, “Cortical Spectral Activity and Connectivity during Active and Viewed Arm and Leg Movement”, *Frontiers in neuroscience*, v. 10.
- KORZENIEWSKA, A., KASICKI, S., KAMIŃSKI, M., et al., 1997, “Information flow between hippocampus and related structures during various types of rat’s behavior”, *Journal of neuroscience methods*, v. 73, n. 1, pp. 49–60.

- KORZENIEWSKA, A., MAŃCZAK, M., KAMIŃSKI, M., et al., 2003, “Determination of information flow direction among brain structures by a modified directed transfer function (dDTF) method”, *Journal of neuroscience methods*, v. 125, n. 1, pp. 195–207.
- KUŚ, R., GINTER, J. S., BLINOWSKA, K. J., 2005, “Propagation of EEG activity during finger movement and its imagination.” *Acta neurobiologiae experimentalis*, v. 66, n. 3, pp. 195–206.
- KUS, R., KAMINSKI, M., BLINOWSKA, K. J., 2004, “Determination of EEG activity propagation: pair-wise versus multichannel estimate”, *IEEE transactions on Biomedical Engineering*, v. 51, n. 9, pp. 1501–1510.
- LANA, E. P., ADORNO, B. V., TIERRA-CRIOLLO, C. J., 2013, “An ERD/ERS analysis of the relation between human arm and robot manipulator movements”. In: *Biosignals and Biorobotics Conference (BRC), 2013 ISSNIP*, pp. 1–7. IEEE.
- LEBEDEV, M. A., NICOLELIS, M. A., 2006, “Brain–machine interfaces: past, present and future”, *TRENDS in Neurosciences*, v. 29, n. 9, pp. 536–546.
- LI, X., ONG, S.-H., PAN, Y., et al., 2013, “Connectivity pattern modeling of motor imagery EEG”. In: *Computational Intelligence, Cognitive Algorithms, Mind, and Brain (CCMB), 2013 IEEE Symposium on*, pp. 94–100. IEEE.
- LIU, Y., ZHAO, Q., ZHANG, L., 2015, “Uncorrelated multiway discriminant analysis for motor imagery EEG classification”, *International journal of neural systems*, v. 25, n. 04, pp. 1550013.
- MACHADO, A. B., 2005, *Neuroanatomia funcional*. Atheneu.
- MILLER, K. J., SCHALK, G., FETZ, E. E., et al., 2010, “Cortical activity during motor execution, motor imagery, and imagery-based online feedback”, *Proceedings of the National Academy of Sciences*, v. 107, n. 9, pp. 4430–4435.
- MØLLER, M. F., 1993, “A scaled conjugate gradient algorithm for fast supervised learning”, *Neural networks*, v. 6, n. 4, pp. 525–533.
- MÜLLER, S. M. T., BASTOS-FILHO, T. F., SARCINELLI-FILHO, M., 2011, “Implementação de uma ICC-SSVEP para o comando de uma cadeira de rodas robótica”, *Proceedings of X Simpósio Brasileiro de Automação Inteligente p.*

- MÜLLER-GERKING, J., PFURTSCHELLER, G., FLYVBJERG, H., 1999, “Designing optimal spatial filters for single-trial EEG classification in a movement task”, *Clinical neurophysiology*, v. 110, n. 5, pp. 787–798.
- NIEDERMEYER, E., DA SILVA, F. L., 2005, *Electroencephalography: basic principles, clinical applications, and related fields*. Lippincott Williams & Wilkins.
- NOLTE, G., BAI, O., WHEATON, L., et al., 2004, “Identifying true brain interaction from EEG data using the imaginary part of coherency”, *Clinical neurophysiology*, v. 115, n. 10, pp. 2292–2307.
- NUWER, M. R., COMI, G., EMERSON, R., et al., 1998, “IFCN standards for digital recording of clinical EEG”, *Electroencephalography and clinical Neurophysiology*, v. 106, n. 3, pp. 259–261.
- OMIDVARNIA, A., MESBAH, M., O’TOOLE, J. M., et al., 2011, “Analysis of the time-varying cortical neural connectivity in the newborn EEG: A time-frequency approach”. In: *Systems, Signal Processing and their Applications (WOSSPA), 2011 7th International Workshop on*, pp. 179–182. IEEE.
- PASCUAL-LEONE, A., AMEDI, A., FREGNI, F., et al., 2005, “The plastic human brain cortex”, *Annu. Rev. Neurosci.*, v. 28, pp. 377–401.
- PAZ, C. C. D. S. C., ERAZO-COSTA, F., SANTOS FILHO, S. A., et al., 2012, “The acute influence of mental practice on cortical delta oscillations: a pilot study”, *Revista Brasileira de Engenharia Biomédica*, v. 28, n. 4, pp. 375–386.
- PFURTSCHELLER, G., STANCAK, A., NEUPER, C., 1996, “Event-related synchronization (ERS) in the alpha band—an electrophysiological correlate of cortical idling: a review”, *International journal of psychophysiology*, v. 24, n. 1, pp. 39–46.
- PFURTSCHELLER, G., LOPES DA SILVA, F., 1999, “Event-related EEG/MEG synchronization and desynchronization: basic principles”, *Clinical neurophysiology*, v. 110, n. 11, pp. 1842–1857.
- PFURTSCHELLER, G., NEUPER, C., 1997, “Motor imagery activates primary sensorimotor area in humans”, *Neuroscience letters*, v. 239, n. 2, pp. 65–68.



- PFURTSCHELLER, G., NEUPER, C., 2001, “Motor imagery and direct brain-computer communication”, *Proceedings of the IEEE*, v. 89, n. 7, pp. 1123–1134.
- PFURTSCHELLER, G., SOLIS-ESCALANTE, T., 2009, “Could the beta rebound in the EEG be suitable to realize a “brain switch”?” *Clinical Neurophysiology*, v. 120, n. 1, pp. 24–29.
- PINEDA, J. A., ALLISON, B., VANKOV, A., 2000, “The effects of self-movement, observation, and imagination on/spl mu/rhythms and readiness potentials (RP’s): toward a brain-computer interface (BCI)”, *IEEE Transactions on Rehabilitation Engineering*, v. 8, n. 2, pp. 219–222.
- PISTOHL, T., BALL, T., SCHULZE-BONHAGE, A., et al., 2008, “Prediction of arm movement trajectories from ECoG-recordings in humans”, *Journal of neuroscience methods*, v. 167, n. 1, pp. 105–114.
- PLOW, E. B., ARORA, P., PLINE, M. A., et al., 2010, “Within-limb somatotopy in primary motor cortex—revealed using fMRI”, *Cortex*, v. 46, n. 3, pp. 310–321.
- RAMOSER, H., MULLER-GERKING, J., PFURTSCHELLER, G., 2000, “Optimal spatial filtering of single trial EEG during imagined hand movement”, *IEEE transactions on rehabilitation engineering*, v. 8, n. 4, pp. 441–446.
- ROSENBLATT, F., 1961, *Principles of neurodynamics. perceptrons and the theory of brain mechanisms*. Relatório técnico, DTIC Document.
- ROSSO, C., VALABREGUE, R., ATTAL, Y., et al., 2013, “Contribution of corticospinal tract and functional connectivity in hand motor impairment after stroke”, *PloS one*, v. 8, n. 9, pp. e73164.
- RUMELHART, D. E., HINTON, G. E., WILLIAMS, R. J., 1985, *Learning internal representations by error propagation*. Relatório técnico, DTIC Document.
- SAITO, Y., HARASHIMA, H., 1981, “Tracking of information within multichannel {EEG} record causal analysis in {EEG}”, *Yamaguchi N, Fujisawa K (eds) Recent advances in {EEG} and {EMG} data processing. Elsevier*, pp. 133–146.
- SALMELIN, R., HARI, R., 1994, “Spatiotemporal characteristics of sensorimotor neuromagnetic rhythms related to thumb movement”, *Neuroscience*, v. 60, n. 2, pp. 537–550.

- SANCHEZ, J. C., GUNDUZ, A., CARNEY, P. R., et al., 2008, “Extraction and localization of mesoscopic motor control signals for human ECoG neuroprosthetics”, *Journal of neuroscience methods*, v. 167, n. 1, pp. 63–81.
- SANES, J. N., DONOGHUE, J. P., THANGARAJ, V., et al., 1995, “Shared neural substrates controlling hand movements in human motor cortex”, *Science*, v. 268, n. 5218, pp. 1775.
- SANTOS-COUTO-PAZ, C. C., TEIXEIRA-SALMELA, L. F., TIERRA-CRIOLLO, C. J., 2013, “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, n. 6, pp. 564–571.
- SCHALK, G., KUBANEK, J., MILLER, K., et al., 2007, “Decoding two-dimensional movement trajectories using electrocorticographic signals in humans”, *Journal of neural engineering*, v. 4, n. 3, pp. 264.
- SCHERER, R., MULLER, G., NEUPER, C., et al., 2004, “An asynchronously controlled EEG-based virtual keyboard: improvement of the spelling rate”, *IEEE Transactions on Biomedical Engineering*, v. 51, n. 6, pp. 979–984.
- SERRUYA, M. D., HATSOPOULOS, N. G., PANINSKI, L., et al., 2002, “Brain-machine interface: Instant neural control of a movement signal”, *Nature*, v. 416, n. 6877, pp. 141–142.
- SHIMAN, F., LÓPEZ-LARRAZ, E., SARASOLA-SANZ, A., et al., 2017, “Classification of different reaching movements from the same limb using EEG.” *Journal of neural engineering*.
- SHIMAN, F., IRASTORZA-LANDA, N., SARASOLA-SANZ, A., et al., 2015, “Towards decoding of functional movements from the same limb using EEG”. In: *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE*, pp. 1922–1925. IEEE.
- SILVA, A., DE SÁ, A. M., TIERRA-CRIOLLO, C., 2014, “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*. CBEB.
- SILVEIRA, G. F. M., MIRANDA DE SA, A. M. F. L., TIERRA-CRIOLLO, C., 2016, “Conectividade cerebral na classificação da imaginação de movimentos no mesmo membro com EEG”. In: *Congresso Brasileiro de Engenharia Biomédica, CBEB XXV, 2016*, pp. 1618–1621. CBEB.

- STECKLOW, M. V., INFANTOSI, A. F. C., CAGY, M., 2010, “EEG changes during sequences of visual and kinesthetic motor imagery”, *Arquivos de neuro-psiquiatria*, v. 68, n. 4, pp. 556–561.
- TAVAKOLAN, M., FREHLICK, Z., YONG, X., et al., 2017, “Classifying three imaginary states of the same upper extremity using time-domain features”, *PloS one*, v. 12, n. 3, pp. e0174161.
- TAYLOR, D. M., TILLERY, S. I. H., SCHWARTZ, A. B., 2002, “Direct cortical control of 3D neuroprosthetic devices”, *Science*, v. 296, n. 5574, pp. 1829–1832.
- TIERRA-CRIOLLO, C., 2001, *Monitorização objetiva da resposta à estimulação somato-sensitiva utilizando parâmetros espectrais*. Tese de Doutorado, Tese de D. Sc., COPPE/UFRJ, Rio de Janeiro, Brasil.
- TRUCCOLO, W., FRIEHS, G. M., DONOGHUE, J. P., et al., 2008, “Primary motor cortex tuning to intended movement kinematics in humans with tetraplegia”, *Journal of Neuroscience*, v. 28, n. 5, pp. 1163–1178.
- ULLOA, E. P. L., 2013, *Estudo sobre interfaces cérebro-máquina e Interação humano-robô*. Tese de Mestrado, UFMG.
- VELLISTE, M., PEREL, S., SPALDING, M. C., et al., 2008, “Cortical control of a prosthetic arm for self-feeding”, *Nature*, v. 453, n. 7198, pp. 1098–1101.
- VIDAL, J. J., 1973, “Toward direct brain-computer communication”, *Annual review of Biophysics and Bioengineering*, v. 2, n. 1, pp. 157–180.
- WANG, Y., HONG, B., GAO, X., et al., 2006, “Phase synchrony measurement in motor cortex for classifying single-trial EEG during motor imagery”. In: *Engineering in Medicine and Biology Society, 2006. EMBS’06. 28th Annual International Conference of the IEEE*, pp. 75–78. IEEE.
- WANG, Y., GAO, X., HONG, B., et al., 2008, “Brain-computer interfaces based on visual evoked potentials”, *IEEE Engineering in medicine and biology magazine*, v. 27, n. 5.
- WEI, Q., WANG, Y., GAO, X., et al., 2007, “Amplitude and phase coupling measures for feature extraction in an EEG-based brain-computer interface”, *Journal of Neural Engineering*, v. 4, n. 2, pp. 120.
- WESSBERG, J., STAMBAUGH, C. R., KRALIK, J. D., et al., 2000, “Real-time prediction of hand trajectory by ensembles of cortical neurons in primates”, *Nature*, v. 408, n. 6810, pp. 361–365.

- WIENER, N., 1956, “The theory of prediction”, *Modern mathematics for engineers*, v. 1, pp. 125–139.
- WOLPAW, J. R., BIRBAUMER, N., MCFARLAND, D. J., et al., 2002, “Brain–computer interfaces for communication and control”, *Clinical neurophysiology*, v. 113, n. 6, pp. 767–791.
- YONG, X., MENON, C., 2015, “EEG classification of different imaginary movements within the same limb”, *PloS one*, v. 10, n. 4, pp. e0121896.

# Apêndice A

Artigo publicado no CBEB XXV -  
2016

## CONECTIVIDADE CEREBRAL NA CLASSIFICAÇÃO DA IMAGINAÇÃO DE MOVIMENTOS NO MESMO MEMBRO COM EEG

G. F. M. da Silveira\*, A. S. T. Silva\*, A. M. F. L. Miranda de Sá\* e C. J. Tierra-Criollo\*

\*Programa de Engenharia Biomédica, COPPE, Universidade Federal do Rio de Janeiro (UFRJ), Rio de Janeiro, Brasil.

e-mail: gustavosilveira@peb.ufrj.br

**Resumo:** A classificação de imagética motora (IM), com base no eletroencefalograma (EEG), é amplamente estudada devido à sua importância em aplicações de interface cérebro máquina (ICM) não invasiva. Classificar imaginação de diferentes movimentos no mesmo membro ainda é um desafio, devido à proximidade da representação espacial do EEG no córtex motor. A conectividade funcional cerebral (CFC) tem sido utilizada para estudar padrões de tarefas cognitivas e motoras. O objetivo deste trabalho é investigar a CFC como característica para classificar IM da flexão e extensão do cotovelo do mesmo membro. Sinais de EEG (Sistema 10/20) de seis indivíduos saudáveis foram utilizados. A CFC foi estimada pela função de transferência direcionada (DTF), que se baseia em modelos de causalidade de Granger. A DTF na banda alfa foi utilizada como característica num classificador com base em redes neurais artificiais. Para as classes extensão, flexão e repouso obteve-se uma acurácia de 98,68%, 83,68% e 68,56%, com 25, 15 e 5 imaginações, respectivamente. Estes resultados indicam a CFC como uma nova abordagem promissora para a identificação de diferentes movimentos de mesmo membro que pode ser aplicada a ICM não invasiva.

**Palavras-chave:** interface cérebro máquina, imagética motora, conectividade funcional cerebral, função de transferência direcionada, redes neurais artificiais.

**Abstract:** *Motor imagery classification based on electroencephalogram (EEG) has been widely studied in noninvasive brain machine interface (BMI) applications. The classification of different motor imagery in the same limb is a challenge, due to EEG close spatial representation on the motor cortex area. Cerebral functional connectivity (CFC) has been applied on cognitive and motor pattern identification. This paper aims at investigating CFC as a new characteristic to classify motor imagery of elbow flexion and extension in the same limb. EEG signals (10/20 international system) of six right-handed healthy subjects were collected. The CFC was estimated by the directional transfer function (DTF), which is based on the Granger causality models. The DTF of the alpha band was applied in a classifier based on artificial*

*neural networks. The accuracies of the extension, flexion and rest classes were 98,68%, 83,68% and 68,56%, with 25, 15 and 5 imaginations, respectively. These results indicate CFC as a new promising approach to identify different movements in the same limb, which can be applied to noninvasive BMI.*

**Keywords:** *brain machine interface, motor imagery, cerebral functional connectivity, directional transfer function, artificial neural networks.*

### Introdução

A classificação de atividade motora baseada em sinais eletroencefalográficos (EEG) é um assunto amplamente estudado devido à sua relevância em aplicações de interfaces cérebro máquina (ICM) não invasiva [1],[2].

Apesar de tal problema ser bem estudado para movimentos de membros diferentes [3], existem poucos estudos com resultados satisfatórios para movimentos no mesmo membro, devido ao fato dessas tarefas motoras ativarem regiões adjacentes do córtex motor [1], [4], [5].

A conectividade funcional cerebral (CFC), com base em sinais de EEG, tem-se mostrado como uma ferramenta relevante para identificar padrões de tarefas cognitivas como a imaginação motora (IM) [6], [7].

A CFC pode ser estimada com a função de transferência direcionada (DTF) [8], baseada no modelo de causalidade de Granger e prediz a quantidade de informação num eletrodo “A” que provém de outro eletrodo “B” mesmo se “A” e “B” forem conectadas por outra região desconhecida “C”.

O objetivo desse trabalho é investigar a DTF como característica para classificar com redes neurais artificiais (RNA) a IM de diferentes movimentos do mesmo membro.

### Materiais e métodos

**Banco de dados** – Os sinais de EEG foram registrados por Lana *et al.* [9] com o amplificador biológico BrainNet BNT-36 (EMSA, Rio de Janeiro, Brazil). Utilizou-se uma touca de EEG com os eletrodos

posicionados no sistema internacional 10/20, os sinais foram filtrados por um passa banda (0,1-100 Hz) e a frequência de amostragem de 600 Hz.

**Indivíduos** – Seis indivíduos destros sem problemas físicos ou neurológicos foram selecionados, com idades entre 23 e 32 anos. Durante o experimento, eles foram colocados numa sala de experimento acusticamente isolada e com iluminação controlada. Todos assinaram um termo de consentimento aprovado pelo comitê de ética da Universidade Federal de Minas Gerais.

**Tarefa experimental** – Os indivíduos foram instruídos a imaginar a mesma tarefa de flexão e extensão orientados por um braço robótico (*AX18 Smart Robot Arm – Crust Crawler Robotics*, Arizona, USA) (Fig. 1).

1. Flexão de cotovelo (FC) (duração 2,5 segundos).
2. Intervalo (tempo aleatório entre 8 e 12 segundos).
3. Extensão de cotovelo (EC) (duração 2,5 segundos).
4. Intervalo (tempo aleatório entre 8 e 12 segundos).




Figura 1 – Sequência de movimentos executados pelo robô durante a tarefa experimental. Modificado de [9].

Foram gravadas aproximadamente 35 imaginações de cada indivíduo durante a tarefa experimental. Após a rejeição de artefatos, 25 imaginações de cada indivíduo foram utilizadas.

**Processamento de sinais** – Os canais de EEG Cz, C3, C4, F3, F4, Fz, T3, T4 (sistema internacional 10/20) foram selecionados devido à sua proximidade a áreas relacionadas à execução da tarefa motora e preparação motora [4]. A análise DTF foi realizada com uma rotina criada no programa MATLAB®.

**Características extraídas** – Os valores de fluxo de informação na banda alfa (8-14 Hz), calculados pela DTF, da tarefa de imagética motora, que se originam das derivações: C3 em direção às derivações F3 e T3, C4 em direção às derivações T3 e T4 e Cz em direção à derivação F3 foram utilizados como característica para o classificador. Essas derivações sugeriram diferença da CFC na maioria de 6 indivíduos nas tarefas de IM de extensão e flexão de cotovelo [7].

**Função de Transferência Direcionada (DTF)** – No cálculo da DTF assume-se que os sinais de EEG são provenientes de um sistema multivariado auto regressivo (MVAR) acrescido de um erro, de acordo com a Equação 1 [10]:

$$x[k] = \sum_{i=0}^p A[i]x[k-i] + E[k] \quad (1)$$

Sendo  $x[k]$  o EEG multicanal,  $A[i]$ , os coeficientes do modelo MVAR e  $p$ , a ordem do modelo. A estimativa do ruído branco gaussiano,  $E[k]$ , é dada por:

$$E[k] = \sum_{i=0}^p \hat{A}[i]x[k-i] \quad (2)$$

Sendo  $\hat{A}[i] = -1$  para  $k=0$  e  $A[i]$ , para  $k>0$ . No domínio da frequência, tem-se:

$$E(f) = A(f)X(f) \quad (3)$$

Manipulando-se (3) pode-se estimar os valores de  $X(f)$ . Assumindo-se que  $G(f) = A(f)^{-1}$ , os valores de DTF são calculados pela Equação 4:

$$Y_{ij} = \frac{g_{ij}}{\sqrt{\sum_{k=1}^N |g_{ik}|^2}} \quad (4)$$

com  $Y_{ij}$  sendo o valor de fluxo de informação do eletrodo  $i$  em direção ao eletrodo  $j$  [6],[10].

São calculados 7 valores de fluxo de informação, cada um correspondente a um *bin* de frequência na faixa da banda alfa (8-14 Hz). Dessa forma, como estão sendo analisados 6 indivíduos, são gerados 42 valores para extensão de cotovelo, 42 valores para flexão de cotovelo e 84 valores para repouso.

**Classificador** – Uma rede neural supervisionada do tipo *feedforward* foi utilizada para classificar os dados entre três classes:

1. Extensão de cotovelo (Imagética).
2. Flexão de cotovelo (Imagética).
3. Repouso.

Os dados foram divididos aleatoriamente na rede, 70% para treinamento, 15% para validação e 15% para teste. O algoritmo de treinamento utilizado foi o Gradiente Conjugado Escalado e o desempenho foi avaliado por Entropia Cruzada. Foram utilizados 3 neurônios na camada escondida (figura 2).




Figura 2 – Topologia da rede neural utilizada no trabalho. Ela apresenta 6 neurônios na entrada, 3 neurônios na camada escondida e 3 neurônios na camada de saída.

As RNA foram treinadas inicialmente com 25 imaginações. Então, com 20, 15, 10 e 5 imaginações escolhidas aleatoriamente. O processo foi repetido 5 vezes para cada conjunto de dados.

## Resultados

A Figura 3 mostra a matriz de confusão para o caso de 25 imaginações por indivíduo (168 valores de DTF). Foram classificados corretamente 41 em 42 IM (97,6%) para a extensão (1) e flexão (2) do cotovelo, enquanto que para o repouso a classificação foi de 100% (84 em 84). A porcentagem média de acurácia do classificador para as 5 repetições foi de 98,68% (Tabela 1).

**Matriz de Confusão**

Classes de saída	1	41 24.4%	0 0.0%	0 0.0%	100% 0.0%
	2	1 0.6%	41 24.4%	0 0.0%	97.6% 2.4%
	3	0 0.0%	1 0.6%	84 50.0%	98.8% 1.2%
		97.6% 2.4%	97.6% 2.4%	100% 0.0%	98.8% 1.2%
	1	2	3	<b>Classes alvo</b>	

Figura 3 – Matriz de confusão do classificador utilizando 25 imaginações por indivíduo. As classes são: 1. Extensão de cotovelo, 2. Flexão de cotovelo e 3. Repouso.

A Figura 4 mostra a matriz de confusão para o caso de 5 imaginações. Neste caso, para a extensão (1) foram classificados corretamente 21 em 42 IM (50%), para a flexão (2) 23 de 42 IM (54,8%), e para o repouso 63 (75%). A porcentagem média de acurácia do classificador para as 5 repetições foi de 68,56% (Tabela 1).

**Matriz de Confusão**

Classes de saída	1	21 12.5%	0 0.0%	7 4.2%	75.0% 25.0%
	2	2 1.2%	23 13.7%	14 8.3%	59.0% 41.0%
	3	19 11.3%	19 11.3%	63 37.5%	62.4% 37.6%
		50.0% 50.0%	54.8% 45.2%	75.0% 25.0%	63.7% 36.3%
	1	2	3	<b>Classes alvo</b>	

Figura 4 – Matriz de confusão do classificador utilizando 5 imaginações por indivíduo. As classes são: 1. Extensão de cotovelo, 2. Flexão de cotovelo e 3. Repouso.

Tabela 1: Acurácia da rede neural artificial em relação ao número de imaginações por voluntário utilizado.

Imaginações por voluntário	Acurácia do classificador
25 imaginações	98,68%
20 imaginações	92,64%
15 imaginações	83,68%
10 imaginações	76,80%
5 imaginações	68,56%

## Discussão

A conectividade funcional das áreas do cérebro tem se mostrado uma relevante característica da imagética motora, sugerindo padrões para diferentes tipos de atividade motora imaginada [6],[7].

O número de imaginações por voluntário, como esperado, é determinante para a acurácia do classificador. Utilizando-se apenas 5 imaginações por voluntário a porcentagem de acertos de classificação foi de 68,56%, provavelmente pela baixa relação sinal-ruído. Incrementando-se o número de imaginações a 25, a acurácia do classificador chega muito próximo de uma classificação perfeita (98,68%).

A classificação da execução de tarefa motora de membros diferentes, estudada em [3], exibiu valores altos de acurácia (entre 56% e 93%), permitindo a aplicação em uma ICM.

Porém, para a classificação de imagética motora de mesmo membro a literatura exhibe poucos estudos, e estes apresentaram resultados inferiores ao método aqui apresentado. Como exemplo, em [1], foi utilizada a energia do EEG aplicada à Análise do Discriminante Linear e obteve-se 60,7% de acurácia na classificação



entre 3 classes de imagética motora. Em [9], não foi possível distinguir diferentes movimentos de mesmo membro analisando-se a desincronização/sincronização relacionado a eventos (ERD/ERS).

### Conclusão

Neste trabalho, a conectividade funcional cerebral foi proposta (calculada pela função de transferência direcionada - DTF) como característica para classificar a imaginação de diferentes movimentos de mesmo membro. Utilizando-se redes neurais artificiais obteve-se valores de acurácia superiores aos da literatura.

O trabalho mostra um novo método de classificação, com sinais de EEG não invasivos, que se mostra promissor para aplicações em interfaces cérebro máquina (ICM), para o controle de tarefas motoras realizadas no mesmo membro.

### Agradecimentos

A CAPES, CNPq, FAPERJ pelo apoio financeiro e ao Programa de Engenharia Biomédica da COPPE-UFRJ. Ao Professor Antonio Fernando Catelli Infantosi (in memoriam) pelos ensinamentos.

### Referências

- [1] Yong, Xinyi, and Carlo Menon. "EEG Classification of Different Imaginary Movements within the Same Limb." Edited by Bin He. PLOS ONE 10, no. 4 (April 1, 2015): e0121896. doi:10.1371/journal.pone.0121896.
- [2] Liu, Ye, Qibin Zhao, and Liqing Zhang. "Uncorrelated Multiway Discriminant Analysis for Motor Imagery EEG Classification." International Journal of Neural Systems 25, no. 4 (June 2015): 1550013. doi:10.1142/S0129065715500136
- [3] Chakraborti T, Sengupta A, Banerjee D, Konar A, Anwesa SB, Janarthanan R. Implementation of EEG based control of remote robotic systems. In: International Conference on Recent Trends in Information Systems. Kolkata, India; 2011. p. 203–208.
- [4] Sanes, J. N., J. P. Donoghue, V. Thangaraj, R. R. Edelman, and S. Warach. "Shared Neural Substrates Controlling Hand Movements in Human Motor Cortex." Science (New York, N.Y.) 268, no. 5218 (June 23, 1995): 1775–77.
- [5] Plow, Ela B., Pooja Arora, Megan A. Pline, Meagan T. Binenstock, and James R. Carey. "Within-Limb Somatotopy in Primary Motor Cortex--Revealed Using fMRI." Cortex; a Journal Devoted to the Study of the Nervous System and Behavior 46, no. 3 (March 2010): 310–21. doi:10.1016/j.cortex.2009.02.024.
- [6] Li X, Ong S-H, Pan Y, Ang KK. Connectivity pattern modeling of motor imagery EEG. 2013 IEEE Symposium on Computational Intelligence, Cognitive Algorithms, Mind, and Brain (CCMB). 2013. p. 94–100.
- [7] A. S. T. Silva, A. M. F. L. Miranda de Sá, C. J. Tierra-Criollo. Identificação da direção do fluxo de informação no EEG para movimentos do cotovelo durante integração humano robô. Congresso Brasileiro de Engenharia Biomédica – CBEB XXIV. 2014.
- [8] Friston KJ. Functional and effective connectivity: a review. Brain Connect. 2011;1(1):13–36.
- [9] E. P. Lana, B. V. Adorno, and C. J. Tierra-Criollo, "An ERD/ERS analysis of the relation between human arm and robot manipulator movements," in Biosignals and Biorobotics Conference (BRC), 2013 ISSNIP, 2013, pp. 1–7.
- [10] Kamiński M, Ding M, Truccolo WA, Bressler SL. Evaluating causal relations in neural systems: granger causality, directed transfer function and statistical assessment of significance. Biol Cybern. agosto de 2001;85(2):145–57.