CENTRO UNIVERSITÁRIO DA FEI

RICARDO CAINÉ CARACILLO

ESTUDO DE BIOPOTENCIAIS CEREBRAIS PARA IDENTIFICAÇÃO DE MOVIMENTOS DO BRAÇO HUMANO

São Bernardo do Campo

2014

RICARDO CAINÉ CARACILLO

ESTUDO DE BIOPOTENCIAIS CEREBRAIS PARA IDENTIFICAÇÃO DE MOVIMENTOS DO BRAÇO HUMANO

Dissertação de Mestrado apresentada ao Centro Universitário da FEI para obtenção do título de Mestre em Engenharia Elétrica, na Área de Inteligência Artificial aplicada à Automação, orientada pela Prof. Dra. Maria Claudia Ferrari de Castro.

São Bernardo do Campo

2014

Caracillo, Ricardo Cainé.
Estudo de biopotenciais cerebrais para identificação de movimentos do braço humano / Ricardo Cainé Caracillo. São Bernardo do Campo, 2014.
189 f. : il.

Dissertação - Centro Universitário da FEI.
Orientador: Profª Maria Claudia Ferrari de Castro.

1. EEG. 2. Análise discriminante linear. 3. Máquina de vetores de suporte. I. Castro, Maria Claudia Ferrari de, orient. II. Título.

CDU 621.38:007.5

Centro Universitário da **FEI**

APRESENTAÇÃO DE DISSERTAÇÃO
ATA DA BANCA JULGADORA

PGE-10

Programa de Mestrado de Engenharia Elétrica

Aluno: Ricardo Cainé Caracillo **Matrícula:** 111119-4

Título do Trabalho: Estudo de biopotenciais cerebrais para identificação de movimentos do braço humano.

Área de Concentração: Inteligência Artificial Aplicada à Automação

Orientador: Prof.ª Dr.ª Maria Claudia Ferrari de Castro

Data da realização da defesa: 14/02/2014

ORIGINAL ASSINADA

A Banca Julgadora abaixo-assinada atribuiu ao aluno o seguinte:

APROVADO ☒ REPROVADO ☐

São Bernardo do Campo, 14 de Fevereiro de 2014.

MEMBROS DA BANCA JULGADORA

Prof.ª Dr.ª Maria Claudia Ferrari de Castro

Ass.: _____

Prof. Dr. Carlos Eduardo Thomaz

Ass.: _____

Prof. Dr. Diogo Coutinho Soriano

Ass.: _____

VERSÃO FINAL DA DISSERTAÇÃO

ENDOSSO DO ORIENTADOR APÓS A INCLUSÃO DAS RECOMENDAÇÕES DA BANCA EXAMINADORA

_____

Aprovação do Coordenador do Programa de Pós-graduação

_____

Prof. Dr. Carlos Eduardo Thomaz

AGRADECIMENTOS

Gostaria de agradecer à FEI, pela excelente instituição de ensino que tem sido a mim, desde que ingressei no curso de engenharia, à minha orientadora Prof. Dra. Maria Claudia Ferrari de Castro, à minha esposa, que muita paciência teve e muito me apoiou durante o difícil período da realização desta pesquisa, à minha filha, que só por existir já me torna uma pessoa melhor e feliz, aos meus pais por terem me proporcionado a educação que viabilizou as oportunidades profissionais que tive em minha carreira e a Deus, que a tudo dá sentido.

RESUMO

Esta pesquisa visa explorar a atividade cerebral, por meio do Eletroencefalograma (EEG), com o objetivo de identificar uma fonte de dados robusta e que demande menor esforço por parte dos usuários de tecnologias assistivas na utilização desses sistemas. As atividades motoras, objeto de estudo desta pesquisa, são os movimentos de flexão dos braços e os movimentos de abertura das mãos. O estudo foi realizado a partir dos dados eletroencefalográficos adquiridos de três voluntários durante a realização de uma sequência de quatro movimentos com os membros superiores. O potencial elétrico cerebral foi mensurado por meio de doze eletrodos, dispostos segundo o padrão 10-20, que forneceram oito diferenças de potenciais não convencionais a um sistema de amplificação e digitalização, o qual, por sua vez, amostrou os dados com uma frequência de 1000 Hz. Os dados digitalizados foram submetidos a técnicas de processamento de sinais para a determinação da Potência Espectral Média por Faixas de Frequência ($PSDM_{f_i}$) e posteriormente submetida a classificadores baseados em Análise de Discriminantes Lineares e em Máquina de Vetores de Suporte, ambos combinados ou não com Análise de Componentes Principais. Os movimentos foram segmentados nas fases de planejamento, execução e posição estática para compor vetores de dados de 1 s e 2 s que, combinados com Seleção Espacial de Características, permitiram demonstrar que as melhores taxas de classificação são obtidas, na maioria dos casos, com os dados da fase de planejamento do movimento, seguidas pelos dados da posição estática. Segmentar as fases do movimento dentro de vetores de dados com 1 e 2 s de duração foi um grande desafio, pois, além de resultar em baixa resolução da Densidade Espectral de Potência (PSD) devido a curta duração do sinal em relação às frequências envolvidas, implicou na sobreposição de dados das diferentes fases do movimento, o que dificulta o trabalho dos classificadores. Adicionalmente, a Seleção Espacial de Características indicou que áreas não motoras atuaram como fontes de informação, sugerindo que também devem ser consideradas. Também se observou que essa técnica apresenta resultados particulares a cada voluntário, mostrando que a configuração das funções cerebrais varia amplamente entre indivíduos e que há informação útil aos classificadores em frequências acima daquelas usualmente utilizadas nos experimentos. Na medida em que se aumentou a frequência máxima do EEG de 40 a 80 Hz, pode-se constatar uma discreta melhora na taxa média de acerto dos classificadores. A melhor taxa de classificação obtida nos experimentos, para um voluntário específico, foi 90,4%, para distinguir entre mãos e braços, independentes de serem do lado direito ou do lado esquerdo, e na discriminação entre quatro classes, um cenário

difícil quando comparado com a literatura, obteve-se 78,8% de taxa de acerto no melhor caso. Considerando-se as melhores taxas de classificação entre todos os experimentos, a fase de planejamento foi aquela que levou a esse resultado em 80% das vezes. Esses resultados sugerem que é possível usar sinais de EEG da fase de planejamento do movimento para melhorar a velocidade de classificação e precisão de um sistema de Interface Computador Cérebro (BCI).

Palavras-chave: EEG. Análise Discriminante Linear. Máquina de Vetores de Suporte.

ABSTRACT

This research aims to explore brain activity through electroencephalogram (EEG), with the goal to identify a robust data source that requires less effort from assistive technology users when handling these systems. The motor activities, objects of this research, are flexion of the arms and closing of the hands. The study was conducted using EEG data acquired from three volunteers while performing a sequence of four movements with their upper limbs. The electrical potential was measured by twelve electrodes arranged according to the 10-20 standard pattern, which provided eight unconventional potential differences to the amplification and digitalization system, which, in turn, sampled data at 1000 Hz frequency. The digitalized data was submitted to digital signal processing techniques to determine the Mean Potential Spectral Density ($PSDM_{f_i}$) of seven frequency bands that have been presented to classifiers based on Linear Discriminant Analysis and Support Vector Machines, both combined or not with Principal Component Analysis. Movement's phases were split into planning, execution and steady position to compose 1 s and 2 s data vectors that, combined with Spatial Feature Selection, allowed to demonstrate that the best classification rates are obtained from planning phase data, followed by steady position data. To segment the phases of movement from data vectors with 1 and 2 s of duration was a challenge because, beside Potential Spectral Density (PSD) low resolution due to short signal duration in comparison with its frequencies components, it resulted in overlapping of data from different movement phases, which makes harder the work of classifiers. Additionally, Spatial Feature Selection indicated that non-motor areas worked as information source, suggesting that they should also be considered. It has also been observed that this technique provided particular outcomes for each volunteer, proving that the configuration of brain functions can vary widely among individuals. The experiments showed that frequencies above those usually used can also provide useful information to the classifiers. Insofar as increasing the maximum frequency of the EEG from 40 to 80 Hz, a slight improvement in the average classification rates could be observed. The Best classification rate obtained in the experiments, for one particular volunteer, was 90.4% when distinguishing between hands and arms, regardless of being left or right ones, and to distinguish among four classes, a hard task when comparing with the literature, the classification rate was 78.8%. Considering all best classification rates through all the experiments, planning phase was the one that leaded to this result in 80% of the cases. These results suggest that it is possible to use EEG signals from movement planning phase to

anticipate subject´s intentions and improve a Brain Computer Interface system (BCI) classification speedy and precision.

Keywords: EEG. Linear Discriminant Analysis. Support Vector Machines.

LISTA DE TABELAS

Tabela 1 - Pesquisas baseadas em execução de movimento. 13
Tabela 2 - Pesquisas baseadas em imaginação do movimento. 13
Tabela 3 – Montagens eletroencefalográficas (adaptados de Duffy, Iyer w Surwillo, 1999). 15
Tabela 4 - Funções Kernel utilizadas pelas Máquinas de Vetores de Suporte. 31
Tabela 5 - Mapeamento dos canais do sistema de aquisição 38
Tabela 6 - Configuração dos canais do sistema de aquisição 40
Tabela 7 - Matriz de posição dos canais no MATLAB 41
Tabela 8 - Faixas de frequência de EEG (adaptada de DIEZ et al., 2009). 45
Tabela 9- Eletrodos e regiões cerebrais mais importantes. 56
Tabela 10 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA para discriminar entre membros superiores. 128
Tabela 11 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA com PCA para discriminar entre membros superiores. 129
Tabela 12 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM para discriminar entre membros superiores. 129
Tabela 13 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM com PCA para discriminar entre membros superiores. 130
Tabela 14 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA para discriminar entre lados. 130
Tabela 15 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA com PCA para discriminar entre lados. 131
Tabela 16 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM para discriminar entre lados. 131
Tabela 17 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM com PCA para discriminar entre lados. 132
Tabela 18 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA para discriminar entre mãos. 132
Tabela 19 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA com PCA para discriminar entre mãos. 133
Tabela 20 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM para discriminar entre mãos. 133
Tabela 21 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM com PCA para discriminar entre mãos. 134
Tabela 22 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA para discriminar entre braços. 134
Tabela 23 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA com PCA para discriminar entre braços. 135
Tabela 24 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM para discriminar entre braços. 135
Tabela 25 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM com PCA para discriminar entre braços. 136

Tabela 26 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA para discriminar entre quatro classes. 136
Tabela 27 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA com PCA para discriminar entre quatro classes. 137
Tabela 28 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM para discriminar entre quatro classes. 137
Tabela 29 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM com PCA para discriminar entre quatro classes. 138

LISTA DE ILUSTRAÇÕES

Figura 1 - Esquema geral de um BCI (adaptado de HOFFMANN; VESIN; EBRAHIMI, 2007). 4
Figura 2 – EEG e as camadas do córtex cerebral (adaptada de TEPLAN, 2002). 14
Figura 3 - Sistema de posicionamento 10-20 de eletrodos (adaptado de HOFFMANN, VESIN e EBRAHIMI, 2007). 15
Figura 4 - Regiões do córtex cerebral (adaptada de http://neuro.sofiatopia.org/brainmind_brain.htm). 17
Figura 5 - Modelo de referência de sistema de digitalização de sinais. 18
Figura 6 - Formas de onda típicas em um sistema de digitalização. 19
Figura 7 - Resposta em frequência de filtro passa-baixa. 20
Figura 8 - Filtro passa-baixa analógico. 21
Figura 9 - Resposta em frequência de filtro passa-alta. 22
Figura 10 - Filtro passa-alta analógico. 22
Figura 11 - Resposta em frequência de filtro passa-baixa. 23
Figura 12 - Filtro rejeita faixa analógico 24
Figura 13 - Resposta em frequência de filtro rejeita faixa. 24
Figura 14 – Exemplo de dados no espaço de entradas. 27
Figura 15 – Dados de treinamento no espaço de características e respectivos vetores de suporte. 28
Figura 16 – Dados de teste separados no espaço de características. 28
Figura 17 – Hiperplano de separação dos dados e vetores de Suporte. 29
Figura 18 - Sistema de aquisição. 36
Figura 19 - Circuito eletrônico dos sensores. 37
Figura 20 - Posicionamento dos sensores. 37
Figura 21 - Posicionamento dos eletrodos. 38
Figura 22 - Variáveis exportadas do LabChart 7 ao MATLAB. 40
Figura 23 - Relação entre as fases do movimento captada pelos sensores e a serial do PC-1 e seus respectivos vetores de dados. 43
Figura 24 - Níveis de tensão dos sensores de movimento. 44
Figura 25 – Experimentos de Classificação. 47
Figura 26 - Dimensionalidade dos dados 48
Figura 27 - Ocorrências acumuladas em função da quantidade de configurações de eletrodos que a Seleção Espacial de Características resultou na melhor taxa de classificação 51
Figura 28 - Ocorrências acumuladas de eletrodos com os quais a Seleção Espacial de Características obteve na melhor taxa de classificação, por voluntário e por fase do movimento, independente da técnica utilizada, do cenário de classificação ou do tamanho do vetor de dados. 52
Figura 29 - Ocorrências acumuladas de eletrodos com os quais a Seleção Espacial de Características obteve na melhor taxa de classificação, por voluntário e por cenário de classificação, independente da técnica utilizada, da fase do movimento ou do tamanho do vetor de dados. 53

Figura 30 - Ocorrências acumuladas de eletrodos com os quais a Seleção Espacial de Características obteve na melhor taxa de classificação, por voluntário e por técnica de classificação, independente do cenário de classificação, da fase do movimento ou do tamanho do vetor de dados. 54
Figura 31 - Quantidade de ocorrências de pares de eletrodos. 55
Figura 32 - Incremento na taxa de acerto individual entre a configuração com todos os eletrodos e a configuração que produziu a melhor taxa de acerto. 57
Figura 33 - Variação entre as taxas de classificação média e máxima na discriminação em quatro classes em função da variação da frequência máxima do sinal considerada. 59
Figura 34 - Variação entre as taxas de classificação média e máxima na discriminação entre lados em função da variação da frequência máxima do sinal considerada. 60
Figura 35 - Variação entre as taxas de classificação média e máxima na discriminação entre membros em função da variação da frequência máxima do sinal considerada. 60
Figura 36 - Variação entre as taxas de classificação média e máxima na discriminação entre mãos em função da variação da frequência máxima do sinal considerada. 61
Figura 37 - Variação entre as taxas de classificação média e máxima na discriminação entre braços em função da variação da frequência máxima do sinal considerada. 61
Figura 38 - Taxas de classificação individual média utilizando LDA para discriminar entre quatro classes. 63
Figura 39 - Taxas de classificação média entre os três voluntários utilizando LDA para discriminar entre quatro classes. 64
Figura 40 - Taxas de classificação individual média utilizando LDA com PCA para discriminar entre quatro classes. 65
Figura 41 - Taxas de classificação média entre os três voluntários utilizando LDA com PCA para discriminar entre quatro classes. 66
Figura 42 - Taxas de classificação individual média utilizando SVM para discriminar entre quatro classes. 67
Figura 43 - Taxas de classificação média entre os três voluntários utilizando SVM para discriminar entre quatro classes. 68
Figura 44 - Taxas de classificação individual média utilizando SVM com PCA para discriminar entre quatro classes. 69
Figura 45 - Taxas de classificação média entre os três voluntários utilizando SVM com PCA para discriminar entre quatro classes. 70
Figura 46 – Visão geral do desempenho de classificação das fases do movimento em função da técnica utilizada. 71
Figura 47 - Desempenho de classificação de cada fase do movimento para cada técnica e cenário de classificação considerada. 72
Figura 48 - Melhor taxa de certo individual e média para todos os cenários de classificação. 73
Figura 49 - Desempenho da PCA em função dos cenários de classificação. 74
Figura 50 - Desempenho de classificação de cada técnica utilizada. 75
Figura 51 - Taxas de classificação individual média utilizando LDA para discriminar entre membros superiores. 96
Figura 52 - Taxas de classificação média entre os três voluntários utilizando LDA para discriminar entre membros superiores. 97

Figura 53 - Taxas de classificação individual média utilizando LDA com PCA para discriminar entre membros superiores. 98
Figura 54 - Taxas de classificação média entre os três voluntários utilizando LDA com PCA para discriminar entre membros superiores. 99
Figura 55 - Taxas de classificação individual média utilizando SVM para discriminar entre membros superiores. 100
Figura 56 - Taxas de classificação média entre os três voluntários utilizando SVM para discriminar entre membros superiores. 101
Figura 57 - Taxas de classificação individual média utilizando SVM com PCA para discriminar entre membros superiores. 102
Figura 58 - Taxas de classificação média entre os três voluntários utilizando SVM com PCA para discriminar entre membros superiores. 103
Figura 59 - Taxas de classificação individual média utilizando LDA para discriminar entre lados. 104
Figura 60 - Taxas de classificação média entre os três voluntários utilizando LDA para discriminar entre lados 105
Figura 61 - Taxas de classificação individual média utilizando LDA com PCA para discriminar entre lados 106
Figura 62 - Taxas de classificação média entre os três voluntários utilizando LDA com PCA para discriminar entre lados 107
Figura 63 - Taxas de classificação individual média utilizando SVM para discriminar entre lados. 108
Figura 64 - Taxas de classificação média entre os três voluntários utilizando SVM para discriminar entre lados 109
Figura 65 - Taxas de classificação individual média utilizando SVM com PCA para discriminar entre lados 110
Figura 66 - Taxas de classificação média entre os três voluntários utilizando SVM com PCA para discriminar entre lados 111
Figura 67 - Taxas de classificação individual média utilizando LDA para discriminar entre mãos. 112
Figura 68 - Taxas de classificação média entre os três voluntários utilizando LDA para discriminar entre mãos 113
Figura 69 - Taxas de classificação individual média utilizando LDA com PCA para discriminar entre mãos 114
Figura 70 - Taxas de classificação média entre os três voluntários utilizando LDA com PCA para discriminar entre mãos. 115
Figura 71 - Taxas de classificação individual média utilizando SVM para discriminar entre mãos. 116
Figura 72 - Taxas de classificação média entre os três voluntários utilizando SVM para discriminar entre mãos 117
Figura 73 - Taxas de classificação individual média utilizando SVM com PCA para discriminar entre mãos 118
Figura 74 - Taxas de classificação média entre os três voluntários utilizando SVM com PCA para discriminar entre mãos 119

Figura 75 - Taxas de classificação individual média utilizando LDA para discriminar entre braços. 120
Figura 76 - Taxas de classificação média entre os três voluntários utilizando LDA para discriminar entre braços 121
Figura 77 - Taxas de classificação individual média utilizando LDA com PCA para discriminar entre braços 122
Figura 78 - Taxas de classificação média entre os três voluntários utilizando LDA com PCA para discriminar entre braços. 123
Figura 79 - Taxas de classificação individual média utilizando SVM para discriminar entre braços. 124
Figura 80 - Taxas de classificação média entre os três voluntários utilizando SVM para discriminar entre braços 125
Figura 81 - Taxas de classificação individual média utilizando SVM com PCA para discriminar entre braços 126
Figura 82 - Taxas de classificação média entre os três voluntários utilizando SVM com PCA para discriminar entre braços. 127

LISTA DE ABREVIATURAS

ANN – Rede Neural Artificial.

BCI – Interface Computador Cérebro.

EEG – Eletroencefalograma.

ERP – Potencial Relacionado a Evento.

FFT – Transformada Rápida de Fourier.

FIR – Resposta Finita a Impulso.

ICA – Análise de Componentes Independnetes.

IIR – Resposta Infinita a Impulso.

LDA – Análise Discriminante Linear.

PCA – Análise de Componente Principal.

PSD – Densidade Espectral de Potência.

$PSDM_{f_i}$ – Potência Espectral Média por Faixas de Frequência

RBF – Função Radial Gaussiana.

SVM – Máquina de Vetores de Suporte

SUMÁRIO

1. INTRODUÇÃO 1

2. REVISÃO BIBLIOGRÁFICA 4

2.1 Visão geral 4
2.2 Extração de características 9
2.3 Técnicas de reconhecimento de padrões 10
2.4 Estado da arte 13

3. TEORIA 14

3.1 Eletroencelafograma 14
3.2 Digitalização de sinais 18
3.3 Filtragem de sinais 19
3.3.1 Filtro passa-baixa *20*
3.3.2 Filtro passa-alta *22*
3.3.3 Filtro passa-faixa *23*
3.3.4 Filtro rejeita faixa *23*
3.4 Extração de características 24
3.4.1 Densidade espectral de potência *24*
3.4.2 Potência espectral média *25*
3.4.3 Seleção espacial de características *25*
3.5 Classificadores 26
3.5.1 Classificador baseado em LDA *26*
3.5.2 Classicador baseado em SVM *27*
3.6 Análise de Componentes Principais 31
3.6.1 Validação cruzada com leave one out *33*

4. METODOLOGIA 35

4.1 Aquisição de dados 35
4.1.1 Voluntários *35*
4.1.2 Configuração do sistema de aquisição de dados *35*
4.1.3 Procedimento de aquisição dos dados *39*
4.2 Seleção e tabulação dos dados 39
4.2.1 Formato dos dados *39*
4.2.2 Pré-análise do movimento *42*
4.3 Extração de características 45
4.4 Técnica de classificação 46
4.5 Experimentos de classificação 46

5. RESULTADOS 49

5.1 Seleção espacial de características 51
5.2 Influência do espectro na discriminação 58
5.3 Discriminação entre lados e membros – 4 classes 62
5.3.1 LDA *63*

5.3.2 LDA com PCA *65*
5.3.3 SVM *67*
5.3.4 SVM com PCA *69*
5.4 Desempenho das fases do movimento 71
5.5 Comparativo entre técnicas 73
6. DISCUSSÃO 76
7. CONCLUSÕES E TRABALHOS FUTUROS 84
REFERÊNCIAS BIBLIOGRÁFICAS 87
APÊNDICE A – Termo de consentimento livre e esclarecido 92
APÊNDICE B – Resultados dos cenários de classificação em duas classes 96
APÊNDICE C – Mapeamento das Regiões Cerebrais em Função dos Resultados da Seleção Espacial de Características 128
APÊNDICE D – Códigos MATLAB 139
APÊNDICE E – Sistema de Automatização do Procedimento de Aquisição de dados .. 162

1. INTRODUÇÃO

Segundo Millán et al. (2010), diversos estudos científicos na área de Interface Cerebral por Computador (BCI) têm trazido avanços significativos à medicina diagnóstica, ao tratamento de pacientes incapazes ou com deficiências físicas e à criação de ferramentas que supram, mesmo que parcialmente, as habilidades motoras que lhes faltam. Tais ferramentas são consideradas como uma das formas do que hoje se denominam, genericamente, tecnologias assistivas.

Dentre as diversas técnicas disponíveis para a detecção de atividade cerebral, tais como, Magnetoencefalografia, Ressonância Magnética Funcional, Potencial Evocado entre outras, esta pesquisa fará uso do Eletroencefalograma (EEG) na detecção de padrões de potenciais elétricos cerebrais relacionados ao movimento dos braços e das mãos.

Enquanto a maioria das pesquisas tem mantido o foco na detecção de padrões cerebrais relacionados à imaginação ou a outras ações relacionadas às áreas cognitivas do cérebro, esta pesquisa irá trabalhar com as ondas ligadas efetivamente à execução de uma atividade motora.

O principal motivador para essa decisão de linha de pesquisa é contribuir para a superação de três grandes obstáculos que a área vem enfrentando: segundo Teplan (2002), a grande variabilidade dos padrões das ondas cerebrais entre diferentes indivíduos sugere que há uma espécie de assinatura individual nessas ondas; os usuários das tecnologias assistivas têm grande dificuldade em aprender a utilizá-las, tendo que se submeter a longos processos de treinamento que, muitas vezes, não cumprem plenamente seu objetivo; e o uso de cognição nessas tecnologias requer níveis de atenção dos usuários que muitas vezes os impedem de realizar outras atividades, resultando em baixa eficiência e tornando-se, segundo Hoffmann, Vesin e Ebrahimi (2007), um fator de desmotivação.

Além disso, existem diversas condições clínicas nas quais os pacientes possuem capacidade parcial de movimentação dos membros devido a, por exemplo, distrofias musculares, que segundo a Associação Brasileira de Distrofia Muscular existem mais de trinta tipos, ou ainda doenças como esclerose lateral amiotrófica, Amiotrofia Muscular Espinhal, Artrite Reumatoide, entre outras, e lesões musculares e/ou ósseas, pacientes esses que podem se beneficiar de um sistema de BCI baseado em sinais cerebrais associados à atividade

motora. Tais sistemas poderiam controlar cadeira de rodas, próteses e outros dispositivos utilizando os sinais efetivamente ligados aos movimentos desejados, tornando o processo mais intuitivo e natural aos pacientes. Outro aspecto, não explorado nesta pesquisa, mas cuja possibilidade se abre, é que mesmo em doenças que impedem os movimentos ou em casos de membros amputados, o cérebro permanece perfeitamente funcional e sistemas como este poderiam ser aplicáveis (MILLAN et al., 2010; LEBEDEV e NICOLELIS, 2006).

Segundo Stastný (2007), a utilização de informações de EEG referentes à execução de movimentos possui outras vantagens que corroboram com essa linha de raciocínio. Dentre elas, o autor cita ser natural controlar um sistema assistivo utilizando essas informações porque é dessa forma que naturalmente interagimos com o ambiente. Além disso, apesar da imaginação do movimento ser suficiente para produzir os padrões cerebrais necessários, o cérebro modifica mais rapidamente os estados relacionados com o movimento do que com outras atividades mentais.

O que se observa nos sistemas BCI da atualidade é que o treinamento dos usuários é complexo e demorado, que há grande variabilidade nos padrões cerebrais entre indivíduos, que a retroalimentação de informações ao usuário é peça chave para o funcionamento do conjunto cérebro/BCI/sistema controlado e que o cérebro apresenta elevada plasticidade.

Espera-se que, por não estarem diretamente ligadas ao pensamento e à consciência, as ondas cerebrais ligadas à execução de atividade motora forneçam uma fonte mais robusta e que demandem menor esforço por parte do usuário. Os resultados obtidos pelo sistema de BCI invasivo de Carmena et al. (2003) corroboram essa crença. Um dos pontos importantes desse trabalho é que mostrou ser possível se realizar uma previsão precisa dos parâmetros motores em tempo real.

Neste contexto, a presente pesquisa apresenta uma comparação do desempenho de um classificador baseado em Análise Discriminante Linear (LDA) visando reconhecer dados de EEG relacionados à execução de movimentos de flexão dos braços e fechamento das mãos em três diferentes fases do movimento consideradas, a saber: planejamento, execução de movimento e posição estática. Para isso, a Potência Espectral Média por Faixas de Frequência ($PSDM_{f_i}$) foi utilizada como característica para alimentar o classificador. Também foi investigado o efeito da Seleção Espacial de Características e de dois tamanhos diferentes de vetor de dados na taxa de classificação. Dessa forma, objetiva-se identificar padrões cerebrais

referentes ao movimento utilizando EEG, buscando prover uma fonte mais robusta de informação e que não demande esforço de treinamento do usuário.

2. REVISÃO BIBLIOGRÁFICA

2.1 Visão geral

Um grande número de estudos científicos e aplicações práticas têm surgido no campo da neurociência desde que Vladimir Pravdich-Neminsky, inspirado nas descobertas sobre a atividade elétrica cerebral de Richard Caton e de Adolf Beck no século XIX, publicou, em 1913, o primeiro estudo de potenciais cerebrais utilizando a técnica de aquisição de dados atualmente conhecida por Eletroencefalografia.

Além da medicina diagnóstica, o biopotencial cerebral representa uma promissora fonte de informações em aplicações na área de BCI produzindo tecnologias assistivas que beneficiam deficientes físicos nas áreas de comunicação e controle, substituição motora, e até mesmo aplicações visando o entretenimento (LEBEDEV e NICOLELIS, 2006).

Em alto nível, um BCI pode ser descrito pela Figura 1.

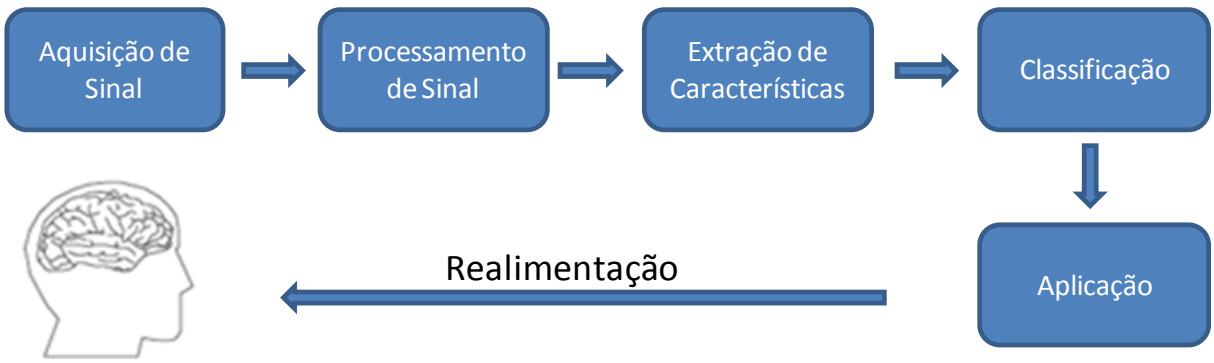

Figura 1 - Esquema geral de um BCI (adaptado de HOFFMANN; VESIN; EBRAHIMI, 2007).

Os sistemas baseados em BCI provêm novas formas de transmitir informações do cérebro para o mundo. Segundo Wolpaw (2007) podem funcionar de duas maneiras: controlando direta e completamente um processo ou indicando apenas a intenção do indivíduo e deixando a realização da ação para o sistema (busca por objetivo). No controle de processo, todo o sistema é comandado através de sinais do córtex cerebral, que, além de estar sujeito a variações, corresponde apenas a uma parte da atividade cerebral do usuário que controla e coordena a função motora e outras funções mentais. Desta forma, o resultado costuma ser inferior ao que se obtêm naturalmente, situação em que todo o sistema de controle biológico está interagindo. A segunda maneira é mais simples e tende a ser mais eficiente, pois o

sistema necessita somente detectar a intenção do usuário para conduzi-lo, automaticamente, ao objetivo. O resultado é uma atividade mais próxima ao que se consegue naturalmente, uma vez que pode ser realizada artificialmente por um sistema tão robusto quanto o sistema biológico, conforme afirma Royer et al. (2009). Veen (2009) traz um comparativo entre o desempenho de diversos sistemas de BCI, e os resultados claramente confirmam que a busca por objetivo é o método mais adotado apesar das taxas de acerto de ambos os métodos terem se mostrado equivalentes (em torno de 80% – 90%). Os sistemas de BCI também podem ser classificados entre aqueles que fazem uso de potenciais cerebrais gerados voluntariamente pelo indivíduo ou potenciais induzidos a partir de um estímulo que pode ser interno ou externo, recebendo a denominação, respectivamente endógenos ou exógenos, sendo, este último, comumente denominado Potencial Relacionado a Evento (ERP) (VEEN, 2009).

Um dos primeiros sistemas de BCI foi desenvolvido por Birbaumer et al. (1999) para tecnologia assistiva e demonstrou que pacientes sofrendo de esclerose lateral amiotrófica são capazes de utilizar potenciais corticais lentos (1-2 Hz) para controlar um dispositivo de comunicação, após longas sessões de treinamento. Os pacientes foram treinados a utilizar o potencial cerebral para controlar um cursor que lhes permitiam selecionar letras na tela de um computador para formar palavras e frases. O sistema atingiu 75% de taxa de classificação para alguns usuários.

Um dos poucos aspectos padronizados na Eletroencefalografia é o arranjo dos eletrodos em convenções denominadas 10-10 e 10-20, embora muitos experimentos adotem variações que utilizam maior quantidade de eletrodos que os previstos no padrão, intercalando os eletrodos entre as posições padronizadas. Um caso é o do experimento realizado por Hoffmann (2007), que utilizou a Análise Discriminante Linear Bayesiana Esparsa para determinar, a partir dos dados adquiridos, o subconjunto de eletrodos mais interessantes entre um conjunto de até 32 eletrodos. Nesse experimento, o autor mostrou que as taxas de acerto obtiveram melhorias à medida que se acrescentava eletrodos. Uma variante desse método, citada por Hoffmann, Vesin e Ebrahimi (2007), utilizou o algoritmo de Padrões Espaciais Comuns e Análise de Componentes Independentes (ICA) para correlacionar características de sinais adquiridos por diferentes eletrodos. O bom funcionamento desses métodos, segundo Blinowska et al. (2008), se deve ao fato de que os sinais cerebrais parecem estar conectados entre distintas regiões do cérebro.

Outros aspectos, como frequência de amostragem, técnicas de extração de características, algoritmos de classificação dos sinais, quantidade de indivíduos e quantidade de repetições dos experimentos sofrem ampla variação. Teplan (2002) e Veen (2009) apresentam uma discussão geral dessas características e as práticas mais comuns em experimentos envolvendo aquisição por Eletroencefalografia são:

- Uso de touca de eletrodos já no padrão 10-20 com gel condutor, ou sistema discreto com eletrodos de disco de Ag-AgCl com pasta condutora para o posicionamento no mesmo padrão. Comumente, os experimentos utilizam os eletrodos C3 e C4 ou são multicanais.
- Amplificadores com ganho de amplificação variando entre 100 e 100.000, com impedâncias de entrada de pelo menos 100 M Ohms e relação de rejeição de modo comum de pelo menos 100 dB.
- Filtros analógicos integrados na unidade com filtro passa-alta com frequência de corte na faixa de 0,1-0,7 Hz e filtro passa-baixa com frequência de corte inferior à metade da taxa de amostragem. Na verdade, salvo quando se trabalha com potencial evocado, frequências acima de 50 Hz raramente são utilizadas, já que contribuem de maneira insignificante com o espectro de potência do EEG.
- Conversor A/D de no mínimo 12 bits com precisão inferior ao ruído geral (0,3 - 2 μV pp.) e frequência de amostragem normalmente entre 128 – 1024 Hz.
- Filtro digital FIR passa-alta com frequência de corte semelhante à do filtro passa-alta analógico.

O estudo do sistema nervoso central é uma ciência altamente experimental, pois, embora já se tenha acumulado muito conhecimento a seu respeito, a ignorância sobre seu funcionamento é maior. Em função disso, a parametrização dos experimentos tem grande variabilidade e é muito baseada no conhecimento prático.

No experimento de Carmena et al. (2003), os potenciais cerebrais motores de macacos adquiridos invasivamente foram utilizados para acionar um braço mecânico. Notavelmente, após algumas sessões de treinamento, os animais perceberam não ser necessário movimentar os braços para controlar o sistema e passaram a fazê-lo somente com o potencial cerebral. O sistema foi desenvolvido para identificar a posição e velocidade da mão e a força de aperto. Essas características foram modeladas utilizando sistemas lineares com dados selecionados da fase de treinamento dos animais e a previsão em tempo real foi feita utilizando filtro Weiner.

Nos animais bem treinados, os modelos lineares idenfiticaram corretamente até 85% da variação da posição de mão, 80% da velocidade, 95% da força de aperto e 61% de atividades cerebrais múltiplas.

Apesar do processo de aquisição do sinal poder ser invasivo ou não, segundo Millán et al. (2010), nas aplicações atuais, não há necessidade de se utilizar sistemas invasivos. Por essa razão, o EEG, que é obtido de maneira não invasiva, é um método largamente utilizado em sistemas de BCI, apesar de não permitir um processamento veloz devido às baixas taxas de informação fornecidas por essa técnica.

O sistema desenvolvido por Hoffmann (2007) mostrou que é possível utilizar o ERP que ocorrem na faixa de Alfa e Mu, especificamente o P300, que é uma onda positiva que ocorre 300 ms após um estímulo ou evento, para o controle de uma BCI sem requerer treinamento do usuário. Esses sinais também têm como característica a capacidade de prover baixas taxas de informação extraída pela BCI, em torno de 25 a 30 bits/min, segundo (DORNHEGE et al., 2004; LEBEDEV e NICOLELIS, 2006).

Além do P300, que é o ERP mais comumente utilizado em experimentos, existem outros que seguem a mesma metodologia de classificação em função da polaridade (P para positivo ou N para negativo) e em função do tempo em que se manifestam após a ocorrência do estímulo (P300 significa positivo e após 300 ms).

Sistemas baseados em potenciais evocados por estímulos visuais também têm apresentado resultados de significativa assertividade, tal como demonstrado por Kelly et al. (2005). No entanto, a taxa de classificação apresentou grande variação entre os indivíduos, tendo uma média de 89,2% no melhor caso e 31,9% no pior caso.

Em uma variante do método anterior, denominada potenciais evocados por estímulos visuais em estado estacionário, uma resposta periódica provocada pela apresentação repetitiva de um estímulo visual a uma taxa ligeiramente superior a 6-8 Hz foi utilizada com sucesso para controlar um jogo 3D, tal como observado por Lalor et al. (2005). A extração de características do sinal foi feita utilizando Transformada Discreta de Fourrier em frequências discretas considerando 4 segundos do sinal e a classificação foi feita utilizando LDA e o teorema de Bayes. Segundo os autores, o bom resultado desse método se deve à sua alta resiliência à interferência, tal como piscar de olhos, movimentos inconscientes, e ao baixo

grau de interferência de eventos relacionados à pulsação, que estão em frequências bem mais baixas.

A imaginação de movimentos também tem sido fonte de muitos trabalhos na área de BCI. Por exemplo, Lemm, Schäfer e Curio (2004) utilizaram Wavelets de Morlet para extração de características e o teorema de Bayes para classificação de sinais de ritmo pericentral, obtendo claros sinais de atividade próximos a 10 Hz na região pós-central do córtex somatossensorial e 20 Hz na região pré-central do córtex motor. O experimento envolveu a classificação de movimentos imaginados da mão esquerda e direita e obteve taxa de classificação em dois grupos de até 89,3%.

Diversos outros trabalhos envolvendo imaginação estão disponíveis na literatura. Dentre eles, pode-se citar o de Vuckovic e Sepulveda (2006), que utilizaram ICA para reduzir a dimensionalidade dos dados e Coeficientes de Gabor para produzir as características apresentadas a duas Redes Neurais Artificiais, que classificaram, respectivamente, entre lado direito ou lado esquerdo e posteriormente entre os movimentos de extensão e flexão, pronação e supinação do punho. Nesse trabalho, foi utilizada uma rede de 64 eletrodos, dispostos segundo padrão 10-10 e as taxas de acerto variaram entre 43% a 92% para discriminar movimentos do punho em quatro classes, apresentando uma média de 73,25% e com ampla variação entre movimentos e indivíduos. Um aspecto importante desse trabalho é que mostra haver informações úteis na faixa gama superior, entre 50 a 80 Hz, para a classificação de intenção de movimento.

Outro trabalho envolvendo imaginação de quatro movimentos realizado por Chin et al. (2009) obteve taxas de classificação entre 54% e 79% para identificar entre movimentos da mão esquerda, mão direita, pé e língua. Os autores utilizaram os algoritmos Padrões Espaciais Comuns (CSP) e Banco de Filtros de Padrões Espaciais Comuns (FBSCP) para discriminar com base em características temporais e espaciais específicas de cada indivíduo. Também compararam os métodos de validação um contra todos, em pares (pair-wise) e divisão e conquista e constataram não haver diferença estatisticamente significativa entre eles.

No trabalho de Sleight et al. (2009), um classificador baseado em SVM foi utilizado para classificar entre movimentos imaginados da mão direita e da mão esquerda. Obteve 64% de taxa média de acerto utilizando como característica a potência espectral das faixas Alfa, Beta e Teta e foi baseado no trabalho feito por Stastný (2007). Distinguir entre movimentos de membros muito próximos, como Stastný (2007) tentou fazer entre a flexão do dedo

indicador direito e a flexão do dedo mínimo direito, é uma tarefa muito difícil. Neste estudo, apesar de utilizar um sistema de aquisição de alta resolução com 41 eletrodos, o autor não conseguiu atingir satisfatoriamente este objetivo. Só foi possível distinguir entre algum movimento e a posição de descanso. Neste experimento, utilizou o modelo oculto de Markov, obtendo taxas de classificação entre 60% a 74% nessa condição.

No entanto, alguns trabalhos vêm mostrando que a intenção de movimento, extraída de sinais de EEG, pode ser usada para antecipar ações futuras baseado no fato de que há informações disponíveis antes de uma decisão consciente de realizar um movimento (TRAVENA e MILLER, 2002; BAI et al., 2007; MORASH et al., 2008). O trabalho de Travena e Miller (2002) sugeriu que o Potencial de Prontidão o Potencial de Prontidão Lateral podem ser utilizados para detectar o início do processo de decisão de se executar um movimento e que isso ocorre frações de segundos antes da efetiva execução do movimento, sem, embora, indicar claramente um tempo padrão.

O diferencial no desempenho entre os diversos sistemas deve-se à variabilidade das ondas cerebrais entre indivíduos e à grande diversidade de técnicas de processamento, que podem ser segmentadas em extração de características e classificação de padrões.

2.2 Extração de características

As técnicas de extração de características têm como objetivo selecionar as informações relevantes dos dados adquiridos, que representam o sinal original, para permitir a distinção entre os sinais cerebrais de interesse daqueles referentes à atividade cerebral de fundo e de forma a permitir a segmentação desses sinais em classes.

Segundo Xiao, Mu e Hu (2009), as técnicas mais utilizadas atualmente são o cálculo de Potência Espectral de Banda, Modelos Auto Regressivos Adaptativos, Filtros Espaciais Comuns e as transformadas Wavelet. Os autores também mencionam que a entropia da energia, em conjunto com as transformadas Wavelet, também vem sendo uma ferramenta empregada com bons resultados em estudos recentes. Nesse trabalho, os autores obtiveram taxa de classificação média de 92,6% para distinguir entre dois movimentos dentre mão direita, mão esquerda, pé e língua, utilizado dados de EEG da BCI Competition 2003 disponíveis publicamente, adquiridos utilizando 64 eletrodos.

Sun, Chang e Tang (2006) propuseram um método para a extração de características baseado na entropia de Shannon, denominado Entropia de Pacotes Wavelet, cujos resultados superaram os tradicionalmente obtidos por decomposição em Wavelets e permitiram o isolamento de ERP com maior precisão.

Diez et. al. (2009) investigaram como o desempenho de diversos classificadores é afetado em função da característica utilizada para o reconhecimento de padrões e mostraram que a potência real do sinal adquirido propicia melhor desempenho geral ao sistema do que a potência média. Além disso, mostraram que os métodos espectrais Periodograma de Welch e Método de Burg podem ser preferidos em relação ao Periodograma Padrão por proporcionarem desempenho ligeiramente superior aos classificadores, cerca de 1 a 2pp.

Aplicando a Entropia da Energia sobre a Transformada de Fourier de Tempo Curto (STFFT), Xiao, Mu e Hu (2009a) disponibilizaram um método para extrair características do sinal cerebral relativo à imaginação do movimento das mãos, dos pés e da língua. Nesse trabalho, utilizaram LDA para classificação dos sinais e obtiveram taxas de classificação entre 82,4% e 88% para distinguir entre combinações de duas classes compostas por dois dentre os quatro movimentos.

Dornhege et al. (2004) utilizaram LDA para classificar a imaginação de movimentos obtida com 128 canais de EEG de 7 voluntários. Foram realizados experimentos de classificação da imaginação de movimentos da mão esquerda ou da mão direita ou do pé ou da imaginação de uma sensação auditiva, visual ou tátil em 2, 3, 4, 5 e 6 classes utilizando Potenciais Relacionados a Movimentos e Dessincronização Relacionada a Evento para obter uma taxa média de classificação de 48% para discriminar em duas classes e de 54% para três. Os resultados das classificações em maior quantidade de classes foram apresentados somente para até dois indivíduos, aparentando representar somente os melhores casos e por essa razão não foram aqui relatados. Os autores utilizaram combinação de características para elevar os índices de duas e três classes em 25% em média.

2.3 Técnicas de reconhecimento de padrões

O reconhecimento de padrões tem como objetivo classificar as informações obtidas pela extração de características dos sinais em uma das classes de interesse, e pode ser feito utilizando Rede Neural Artificial (ANN), Análise Discriminante Linear (LDA), Rede Neural

Probabilística (PNN), Lógica Nebulosa, entre outros. Recentemente, as Máquina de Vetores de Suporte também passaram a ser empregadas com bons resultados. Segundo Hoffman et al. (2007), um levantamento compreensivo destes algoritmos pode ser encontrado no artigo de Bashashati et al. (2007).

No estudo desenvolvido por Hoffman (2007), os autores compararam Análise Discriminante Linear Bayesiana Esparsa (SBDA) com LDA, mostrando que o primeiro método apresenta melhor eficiência no reconhecimento de padrões. Para realizar essa comparação, os autores utilizaram o ERP P300, obtido de quatro indivíduos saudáveis e de quatro deficientes físicos. Os dados foram agrupados em blocos de 2 e 4 s para serem submetidos aos classificadores. Tendo como métrica a precisão por bloco introduzida pelo autor, após cinco blocos, a LDA obteve taxa média de acerto de 56%, com desvio padrão de 12 pp. (pontos percentuais), enquanto que, para a SBDA, a taxa de classificação foi de 69% com desvio padrão de 11 pp. Para a LDA, a taxa de classificação atingiu 100% para os indivíduos saudáveis e foi superior a 95% para os deficientes físicos após vinte blocos, enquanto que, para a SBDA, isso ocorreu com menos de dez blocos.

Uma SVM em conjunto com Entropia de Pacotes Wavelet foi utilizada por Zhiwei e Minfen (2007) em um experimento de classificação de tarefas mentais, tais como contar, multiplicar, escrever carta etc., e obtiveram melhores resultados do que aqueles alcançados por Rede Neural Artificial com extração de parâmetros utilizando modelos auto-regressivos, as quais são uma combinação comumente utilizada. O experimento contou com dois voluntários e a taxa média de acerto da SVM com três diferentes funções kernel foi de 93% para o primeiro indivíduo e 87.5% para o segundo para classificar os dados em dois grupos. Os autores avaliaram adicionalmente as taxas de acerto para a classificação em três e quatro grupos e observaram que as técnicas por eles propostas também se mantiveram superiores nestas condições.

Bai et al. (2007) comparou várias técnicas e a melhor classificação média foi de 63%, alcançada por ICA, PSD e SVM para distinguir entre os movimentos da mão esquerda e direita, utilizando um conjunto de 122 canais de EEG.

Morash et al. (2008) atingiu cerca de 40% de classificação para distinguir entre movimentos da mão direita, mão esquerda, língua e do pé, enquanto que para dois movimentos, essa taxa aumentou para 65%, no melhor caso. Os autores utilizaram ICA e Transformada Wavelet Discreta para obter as características a serem submetidas a um

classificador Bayesiano. O melhor conjunto de treinamento para esse classificador foi identificado utilizando um algoritmo genético e o experimento contou com um sistema de 29 canais de aquisição.

Taxas de classificação entre 70% e 96% foram obtidas por Navarro, Sepulveda e Hubai (2005) na distinção de movimentos do punho esquerdo e direito utilizando imaginação e execução de movimentos. O melhor resultado foi obtido com Perceptron Multicamada (MLP), treinado com retroalimentação, e ICA. Entretanto, o estudo não obteve sucesso superior a 35% para distinguir subclasses, por exemplo, entre flexão e extensão, embora os autores utilizassem um sistema de 21 canais para obter boa resolução espacial do EEG.

Diez et. al (2009) utilizou dados de imaginação abstrata para comparar o desempenho de classificação dos algoritmos LDA, Aprendizado de Quantização Vetorial, ANN e SVM e mostrou que, para os dados considerados, LDA e ANN foram os algoritmos que obtiveram as melhores taxas de acerto, em tordo de 88% a 90%.

Embora não se proponha a identificar movimentos, mas para diagnosticar epilepsia, Mahajan, Vargantwar e Rajput (2011) compararam o uso de ICA com Análise de Componentes Principais (PCA) na redução de dimensionalidade das características de EEG extraídas utilizando Transformada Discreta de Wavelet e obtiveram taxas de classificação corretas muito próximas para ambos os casos, com 96,75% e 93, 63% para ICA e PCA, respectivamente. Os autores utilizaram 128 canais de EEG e uma rede neural para realizar a classificação.

Entretanto, apesar da pesquisa acima sugerir que PCA e ICA obtém desempenhos semelhantes na classificação de sinais de EEG, Bugli e Lambert (2006) realizaram uma comparação entre ambas as técnicas na identificação de um ERP conhecido como P300 a partir de EEG adquirido com 28 canais. Os autores concluíram que a técnica ICA foi mais eficiente no reconhecimento do P300 do que o PCA, porém este permitiu maior redução de dimensionalidade.

Os potenciais cerebrais têm sido amplamente estudados e classificados, gerando uma ampla fonte de informações para sistemas de BCI. No entanto, são sinais de baixa energia e altamente ruidosos, que variam entre indivíduos e ao longo do tempo para um mesmo indivíduo, tornando sua complexa sua aplicação em sistemas práticos. Além disso, muitos sistemas de BCI demandam longas e desmotivadoras sessões de treinamento de seus usuários.

Em função disso, uma ampla variedade de técnicas de extração de características e de reconhecimento de padrões vem sendo aplicada com crescente sucesso para vencer esses obstáculos.

2.4 Estado da arte

As tabelas 1 e 2 resumem os trabalhos consultados na literatura à época da elaboração da presente pesquisa e que possuem maior proximidade com a presente pesquisa.

Tabela 1 - Pesquisas baseadas em execução de movimento.

Movimentos	Características	Classificador	Canais	Taxa de classificação	Fonte
mão direita, mão esquerda, língua e pé	ICA, DWT	BSC	29	4 classes = 42% 2 classes = 63%	Morash et al. (2008)
mão esquerda e direita	PCA, ICA, SLD, PSD, DWT	LMD, QMD, BSC, ANN, PNN, SVM	128	2 classes = 63%	Bai et al. (2007)
flexão, extensão, pronação e supinação do punho	ICA sobre características do EEG no domínio do tempo e da frequência.	LDA, QDA, ANN, PNN	21	4 classes = 32% a 35%	Navarro et al. (2005)
dedos mínimo e polegar direito e esquerdo	FFT, AR	Hidden Markov models	41	2 classes = 49% a 58% 4 classes=sem sucesso	Stastný (2007)

Tabela 2 - Pesquisas baseadas em imaginação do movimento.

Movimentos	Características	Classificador	Canais	Taxa de classificação	Fonte
extensão, flexão, pronação e supinação do punho	ICA e Coeficientes de Gabor	ANN	64	4 classes = 43% a 92% (média 73,25%)	Vuckovic e Sepulveda (2006)
mão direita, mão esquerda, língua e pé	CSP	multi-classe FBSCP (One-versus-Rest, Pair-Wise and Divide-and-Conquer)	88	4 classes = 54% a 79%	Chin et al. (2009)
mão direita e mão esquerda	Wavelets de Morlet	teorema de Bayes	2 (C3,C4)	2 classes = 89% (máxima)	Lemm, Schäfer e Curio (2004)
mão esquerda, mão direita, pé ou sensação visual, auditiva ou tátil.	AR, CSP	LDA	128	2 classes = 59% 3 classes = 67%	Dornhege et al. (2004)
mão direita e mão esquerda	PSD via Periodograma Padrão, Welch e Burg. PSDMfi Média e RMS.	LQV, ANN, SVM	3 (C3,C4, Cz)	2 classes = 45%-90%	Diez et al. (2009)
mão direita, mão esquerda, pé e língua	Entropia da Energia, STFT	LDA, ANN, SVM	64	2 classes=82% a 88%	Xiao, Mu e Hu (2009)
mão direita e mão esquerda	PSD, PCA	IT2FLS, T1FLS, SVM_{lin}, SVM_{Gauss}	2 (C3,C4)	2 classes=60% a 73%	Herman, Prasad e McGinnity (2008)

3. TEORIA

3.1 Eletroencelafograma

A eletroencefalografia consiste em uma técnica para a medição de potenciais do cérebro por meio de eletrodos posicionados no couro cabeludo sobre a região do córtex cerebral, configurando, portanto, uma técnica não invasiva. As medições são sempre realizadas por diferença de potencial entre dois eletrodos, conhecido como Eletroencefalograma (EEG), conforme ilustrado na Figura 2.

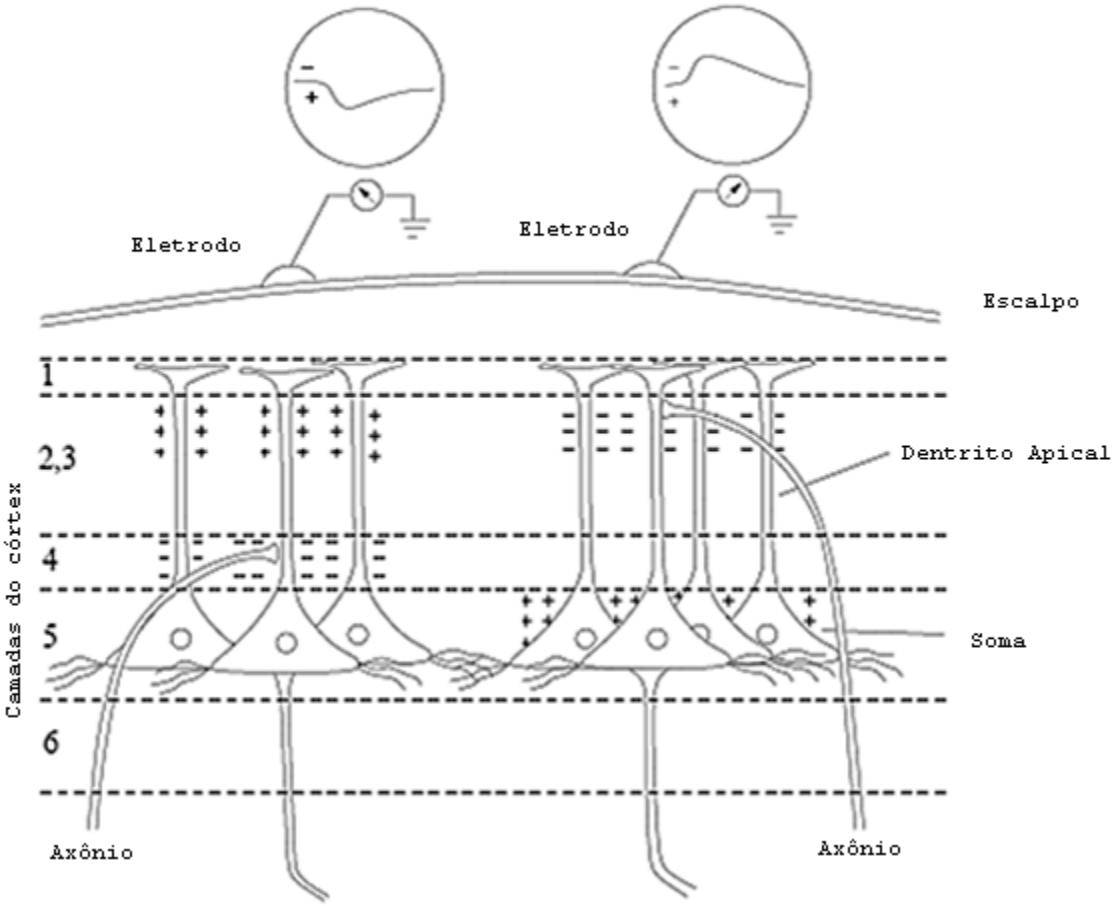

Figura 2 – EEG e as camadas do córtex cerebral (adaptada de TEPLAN, 2002).

Os eletrodos são dispostos segundo padrões internacionais pré-estabelecidos. A Figura 3 ilustra o padrão de posicionamento 10-20, sendo que os números ímpares indicam os eletrodos localizados no lado esquerdo da cabeça, os números pares indicam os localizados no lado direito, o índice "z" indica a região central e as letras maiúsculas indicam a zona cortical: frontal (F), Central (C), Parietal (P), Temporal (T), Occipital (O), Polo Frontal (Fp) e

Auricular (A). A designação 10-20 vem da distância de separação entre os eletrodos (HOFFMANN, VESIN e EBRAHIMI, 2007).

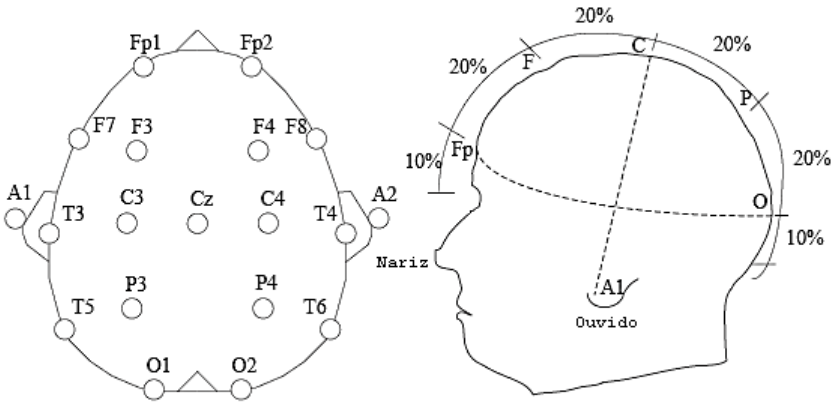

Figura 3 - Sistema de posicionamento 10-20 de eletrodos (adaptado de HOFFMANN, VESIN e EBRAHIMI, 2007).

Segundo Duffy, Iyer e Surwillo (1999), as montagens eletroencefalográficas podem ser de três tipos: de forma bipolar no sentido longitudinal, bipolar no sentido transversal ou unipolar com referência nos lobos auriculares direito (A1) ou esquerdo (A2), conforme mostra a Tabela 3.

Tabela 3 – Montagens eletroencefalográficas (adaptados de Duffy, Iyer w Surwillo, 1999).

Bipolar longitudinal	Bipolar transversal	Referenciais nos lobos auriculares
Fp1 - F7	F7-Fp1	F7-A1
F7-T3	Fp2 - F8	T3-A1
T3-T5	F7-F3	T5-A1
T5-O1	F3-Fz	F8-A2
Fp2 - F8	Fz-F4	T4-A2
F8-T4	F4-F8	T6-A2
T4-T6	T3-C3	Fp1-A1
T6-O2	C3-Cz	F3-A1
Fp1 - F3	Cz-C4	C3-A1
F3-C3	C4-T4	P3-A1
C3-P3	T5-P3	O1 -A1
P3-O1	P3-Pz	Fp2 - A2
Fp2 - F4	Pz-P4	F4-A2
F4-C4	P4-T6	C4-A2
C4-P4	T5-O1	P4-A2
P4-O2	O2-T6	O2-A2

A atividade oscilatória de um EEG é também classificada em diferentes faixas de frequência. Segundo Teplan (2002) e Duffy, Iyer e Surwillo (1999), as mais comumente observadas são:

- Delta: É um sinal de alta amplitude que ocorre na região frontal, com frequências de 1 a 4 Hz e está relacionada com sono e atividades de atenção contínua. Durante sono profundo, observam-se também sinais com frequência iniciando em 0,5 Hz.
- Teta: Com frequências entre 4 e 8 Hz, é observado em regiões não motoras durante estado de relaxamento ou sonolência e excitação, sendo também associado a memória e atividades cognitivas. Geralmente também é associado à inibição de resposta.
- Mu: É um potencial relacionado à atividade motora de descanso observado em frequências entre 8 e 13 Hz na região somatossensorial. O termo mu ritmo é usado para a atividade oscilatória com frequências nessa faixa, que sofre atenuação ou bloqueio quando da movimentação das extremidades, como o ato de fechar a mão.
- Alfa: O termo alfa ritmo é mais geral que o anterior e é utilizado para potenciais na faixa de frequência 8-13 Hz, associados ao relaxamento com olhos fechados, sendo observado na região central (C3 e C4), ou atividades inibitórias em diferentes áreas cerebrais, situação na qual é observado nas regiões posteriores do cérebro, em ambos os lados e com altas amplitudes do lado contralateral. Esses sinais são atenuados quando da abertura dos olhos ou por esforço mental.
- Beta: São potenciais de baixas amplitudes observados em ambos os lados do cérebro e de forma mais evidente na região frontal, apresentando frequências entre 13 e 35 Hz. Ocorrem em estado de alerta ou ansiedade e durante atividade mental de concentração.
- Gama: Apresenta frequências entre 25 e 40 Hz e ocorre na região somatossensorial. Está relacionado com percepção sensorial e com memória de reconhecimento de objetos, sons e sensações táteis. Sinais acima de 40 Hz são denominados de gama alta e associados a potencias evocados.
- Lambda: são ondas transitórias com durações de 0,1 a 0,250 s que ocorrem nas regiões occipitais quando a pessoa está de olhos abertos e realizando exploração visual, podendo ocorrer simetricamente em ambos os lados ou apenas em um dos lados. Essas ondas desaparecem imediatamente após o fechamento dos olhos.

Embora sejam padrões comumente observados, a atividade cerebral pode variar entre indivíduos e num mesmo indivíduo conforme a idade. Por exemplo, em crianças, as ondas alfa na região posterior predominam em frequências entre 8 e 9 Hz, porém em adolescentes esse ritmo pode alcançar 11 Hz (DUFFY, IYER E SURWILLO, 1999).

A necessidade da disposição espacial advém do fato de cada região do cérebro ser responsável por uma função específica, conforme ilustrado na Figura 4. Nota-se que a região motora é ainda subdividida conforme região ou membro que controla.

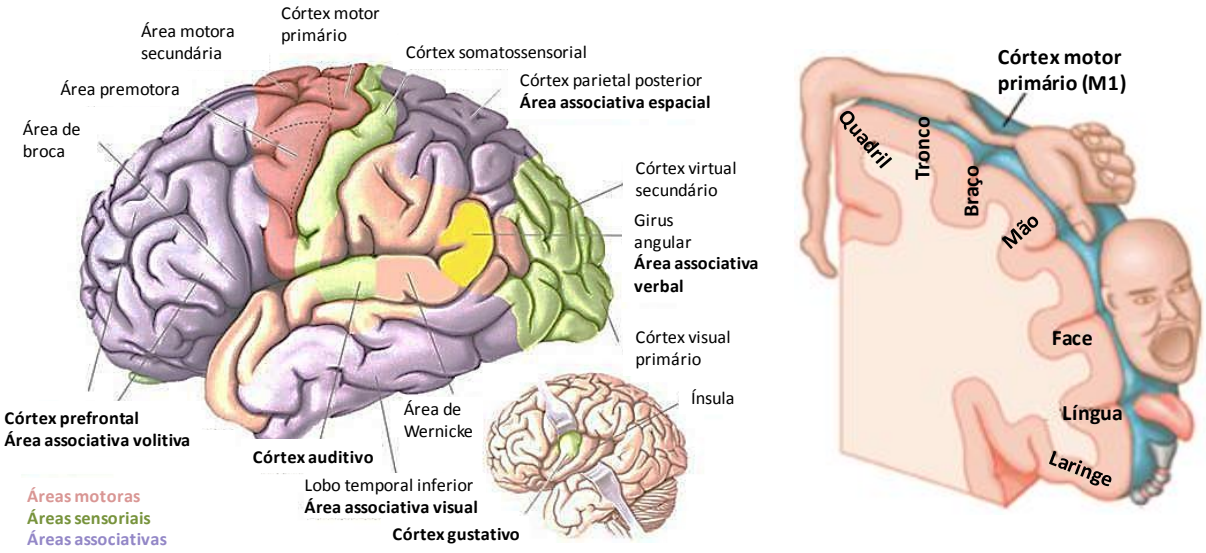

Figura 4 - Regiões do córtex cerebral (adaptada de http://neuro.sofiatopia.org/brainmind_brain.htm).

Além de serem classificados segundo a região cerebral na qual foram captados, os sinais cerebrais também são caracterizados por terem respostas correlacionadas no tempo com os eventos que o geram, conhecidos como Potenciais Relacionados a Eventos (ERP). Dentre exemplos desses potenciais, pode-se citar N100, N200, N170, N400, P200, P300 e P600. Embora existam designações específicas, a designação desses potenciais é feita tendo-se como padrão a letra P ou N, para indicar diferenças de potenciais positivas ou negativas, seguidas pelo instante em que ocorrem após a exposição do cérebro ao evento, expressas em milissegundos. Dietrich e Kanso (2010) apresentam uma relação dos principais ERPs, bem como suas características e aplicações e um compilado completo e atualizado pode ser obtido em Luck e Kappenman (2011).

O pré-processamento e a técnica de extração de características são peças fundamentais para garantir um bom desempenho do sistema, pois os sinais cerebrais são suscetíveis a interferências externas e internas, possuem pequena amplitude (100µV de pico a pico), baixa frequência (0,5 a 40 Hz) e fornecem baixa taxa de informação, (LEBEDEV e NICOLELIS, 2006). Exemplos comuns de interferências externas são aquelas causadas pela indução de 60 Hz oriunda da rede elétrica e como interferências internas pode-se citar o movimento dos olhos, do couro cabeludo, pulsação, sinais de regiões não diretamente relacionadas à atividade

de interesse, mas presentes no cérebro e que podem ser captadas no sinal resultante obtido externamente.

3.2 Digitalização de sinais

A digitalização de sinais consiste na conversão de sinais analógicos, contínuos no tempo, em uma sequência de números discreta ao longo do tempo, que o representa de forma aproximada. Esse processo consiste de duas etapas, amostragem e quantização.

A amostragem consiste em se tomar uma parcela do sinal original $x(t)$, a cada intervalo de tempo ou intervalo de amostragem T_s, através do produto com o sinal de amostragem $s_a(t)$, produzindo um sinal $x_a(t)$ ainda contínuo no tempo. A partir do intervalo de amostragem, obtém-se a frequência de amostragem f_s. A equação 1 representa esse processo.

$$x_a(t) = x(t).s_a(t) \tag{1}$$

Segundo o critério de Nyquist, a frequência de amostragem f_s, dada pelo inverso do intervalo de amostragem T_s, deve ser no mínimo o dobro da máxima frequência do sinal a ser amostrado para garantir que não haja perda de informação.

O processo de representação numérica das amostras é denominado quantização, cuja precisão é dada em função da quantidade de bits para representar numericamente as amostras, resultando no sinal quantificado x(n). A Figura 5 ilustra o sistema descrito.

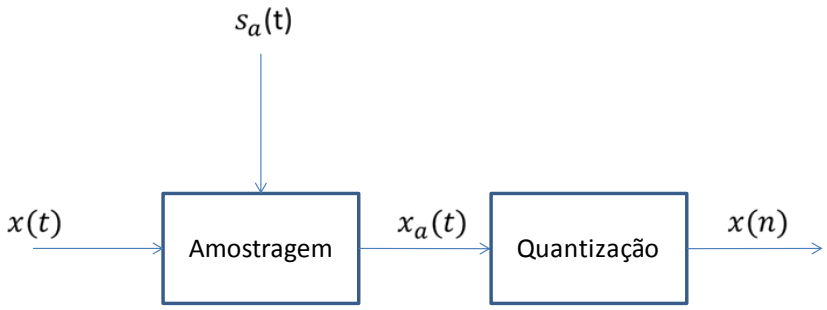

Figura 5 - Modelo de referência de sistema de digitalização de sinais.

As formas de onda dos sinais, em cada etapa do sistema apresentado, podem ser vistas na Figura 6.

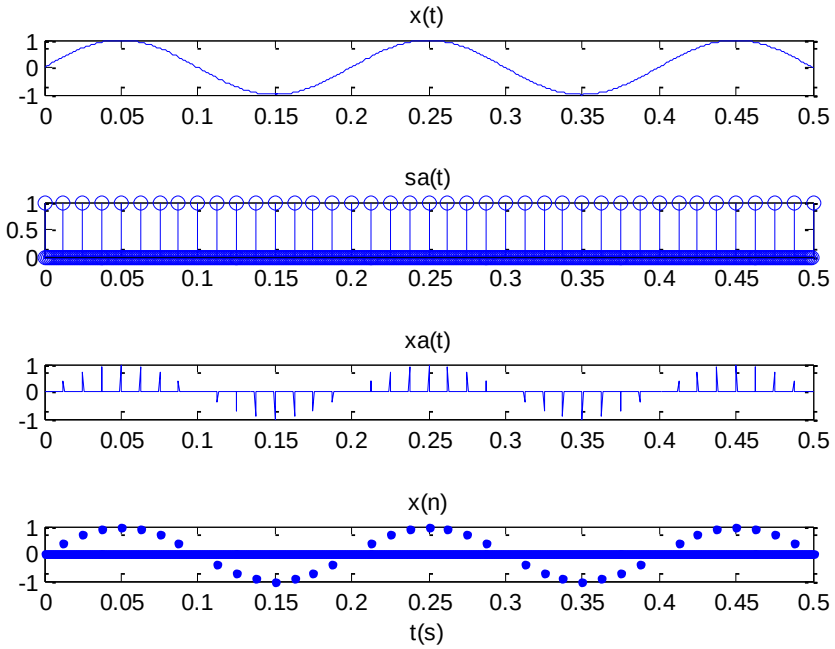

Figura 6 - Formas de onda típicas em um sistema de digitalização.

Em função da quantidade de bits utilizado no processo de quantização obtém-se uma determinada precisão, que é dita resolução do sistema, e pode-se definir um erro de quantização. Sendo B a quantidade de bits e $X_{a_{max}}$ o valor de pico do sinal amostrado, as equações (2) e (3) representam a resolução R e o erro percentual de quantização ∈ do sistema, respectivamente.

$$R = \frac{2.X_{a_{max}}}{2^B - 1} \tag{2}$$

$$\in = \frac{R}{4.X_{a_{max}}} \tag{3}$$

3.3 Filtragem de sinais

A filtragem de sinais é um amplo assunto que envolve complexa matemática e por isso este capitulo se restringirá a abordar exclusivamente as técnicas utilizadas nessa pesquisa. Um maior detalhamento teórico é apresentado no item 3.3.1, sendo os demais itens focados somente nos aspectos específicos a cada tipo de filtro que aborda.

Todas as informações apresentadas neste item e seus respectivos subitens foram baseados em Boylestad e Nasheksky (1994) e em Malvino (1986).

3.3.1 Filtro passa-baixa

Um filtro passa-baixa é aquele que se destina a permitir a passagem das componentes de frequência de um sinal até uma determinada frequência máxima, denominada frequência de corte, rejeitando o resto do sinal. Na prática, há duas frequências em torno da frequência de corte de interesse: frequência de passagem e frequência de corte que correspondem, respectivamente, à frequência que define o limite superior da faixa de passagem e à frequência que define o início da faixa de rejeição.

As componentes abaixo da frequência de passagem pertencentes à faixa de passagem sofrerão uma pequena atenuação, definida por A_{pass}, e as componentes acima da frequência de rejeição serão fortemente atenuadas, definidas por A_{stop}. Há ainda uma zona de transição em torno da frequência de corte, que sofrerão atenuação gradativa, conforme mostra a curva da resposta em frequência da Figura 7.

.

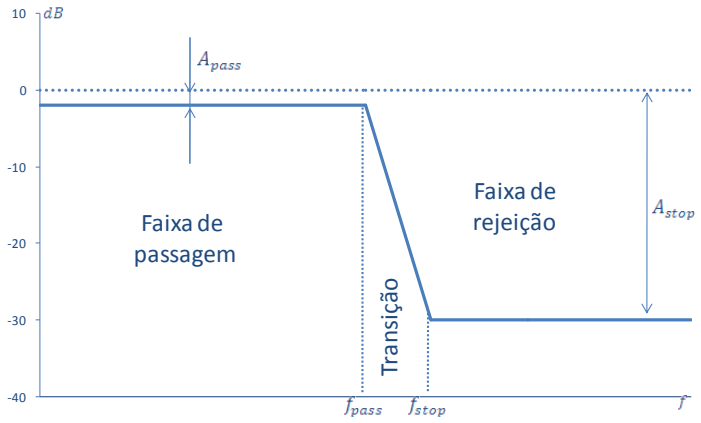

Figura 7 - Resposta em frequência de filtro passa-baixa.

Todo filtro possui uma característica conhecida como ordem, que define a inclinação de sua zona de transição contida entre f_{stop} e f_{pass}. A relação entre ordem e essa diferença de frequências é inversamente proporcional.

Se construído de forma discreta ou digital, um filtro pode ser do tipo de Resposta Infinita a Impulso (IIR) ou de Resposta Finita a Impulso (FIR). Sendo X(z) o sinal discreto de entrada de um sistema com função de transferência H(z) e Y(z) o sinal de saída, a equação (4) traz a função de transferência de um filtro digital, sendo que no caso do filtro IIR $n_b = 0$ e $b(1) = 1$ e para o filtro FIR $n_a = 0$ e $a(1) = 1$.

$$Y(z) = H(z).X(z) = \frac{\sum_{n=0}^{n_b} b\,(n+1)z^{-n}}{\sum_{n=0}^{n_a} a\,(n+1)z^{-n}}.X(z) \tag{4}$$

Nota-se que a função de transferência do filtro é um polinômio de grau n_a ou n_b, dependendo se for do tipo FIR ou IIR, sendo que para uma mesma ordem o último é mais eficiente que o primeiro, isto é, possui banda de transição mais íngreme e menor defasagem entre entrada e saída. Entretanto, os filtros IIR são mais eficientes que os filtros FIR, isto é, para uma mesma ordem possuem banda da rejeição mais íngreme, porém este último apresenta outras vantagens: podem ter resposta em fase exatamente linear, são sempre estáveis, possuem implementação eficiente em hardware e os transitórios iniciais têm duração finita.

Um filtro passa-baixa analógico típico de primeira ordem pode ser observado na Figura 8, sendo sua frequência de corte f_c e ganho G dados pelas equações (5) e (6), onde R_1, R_2 e C são os valores dos componentes eletrônicos utilizados no circuito e V_{in} e V_{out} são os sinais de entrada e saída.

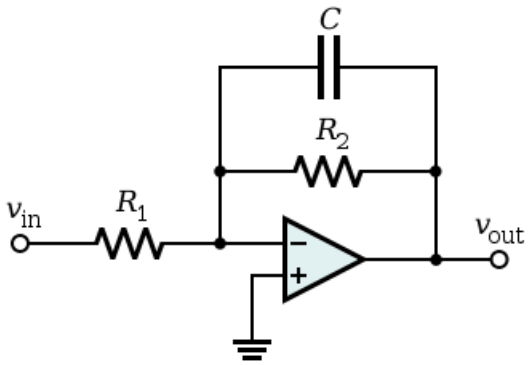

Figura 8 - Filtro passa-baixa analógico.

$$f_c = \frac{1}{2\pi R_2 C} \tag{5}$$

$$G = \frac{-R_2}{R_1} \tag{6}$$

3.3.2 Filtro passa-alta

Conceitualmente análogo ao filtro passa-baixa, descrito no item 3.3.1, o filtro passa-alta tem como objetivo rejeitar as componentes inferiores a f_{stop} e permitir à passagem de componentes de frequência de um sinal que sejam superiores a f_{pass}. A curva de resposta em frequência do filtro é apresentada na Figura 9.

.

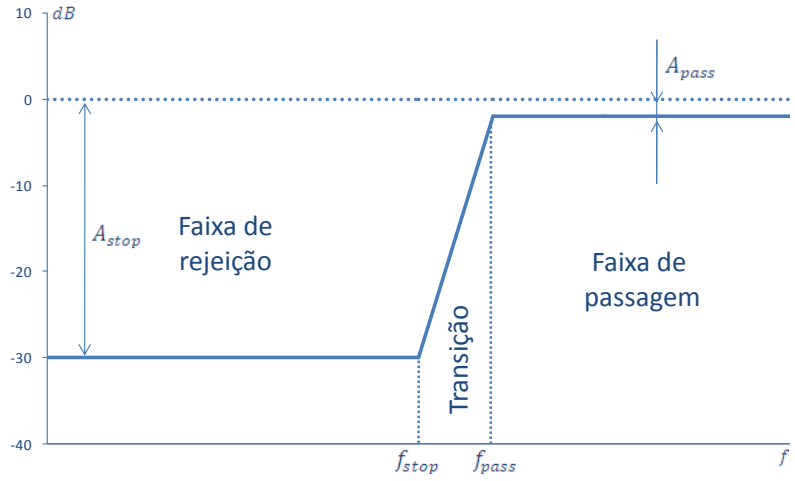

Figura 9 - Resposta em frequência de filtro passa-alta.

Um filtro passa-alta analógico típico de primeira ordem pode ser observado na Figura 10, sendo sua frequência de corte f_c e ganho G dados pelas equações (7) e (8), onde R_1, R_2 e C são os valores dos componentes eletrônicos utilizados no circuito e V_{in} e V_{out} são os sinais de entrada e saída.

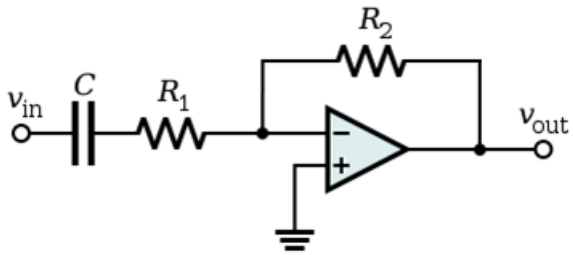

Figura 10 - Filtro passa-alta analógico.

$$f_c = \frac{1}{2\pi R_1 C} \tag{7}$$

$$G = \frac{-R_2}{R_1} \tag{8}$$

3.3.3 Filtro passa-faixa

Esse tipo de filtro se propõe a permitir a passagem das componentes de frequência de um sinal que estiverem contidas entre duas frequências de corte, conforme ilustra Figura 11.

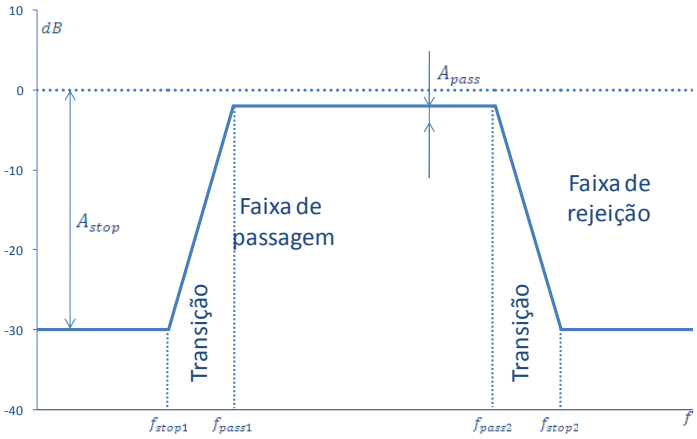

Figura 11 - Resposta em frequência de filtro passa-baixa.

Um filtro passa-faixa pode ser construído pelo cascateamento de um filtro passa-alta com um filtro passa-baixa. Em sua versão analógica, será constituído por um circuito eletrônico como o apresentado no item 3.3.2 com o circuito do item 3.3.1, enquanto que na versão discreta ou digital contará com os polinômios do denominador e numerador da equação **(4)**, ou seja, $n_a > 0$ e $n_b > 0$.

3.3.4 Filtro rejeita faixa

Um filtro do tipo rejeita faixa se propõe e atenuar componentes de frequência do sinal situadas entre dois limiares de frequência determinados, conforme mostra a Figura 13 e é construído a partir do cascateamento de um filtro passa-alta com um passa-baixa em sua versão digital e na analógica a Figura 12 apresenta duas possíveis configurações.

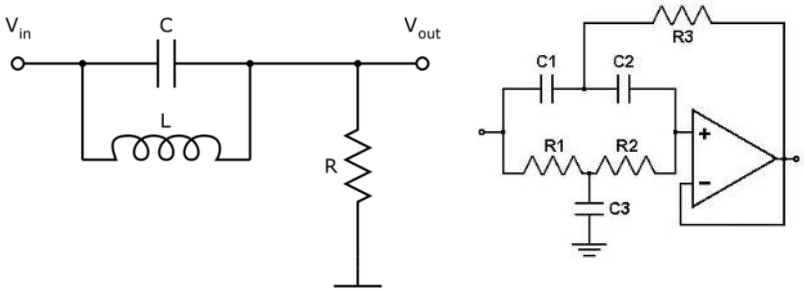

Figura 12 - Filtro rejeita faixa analógico

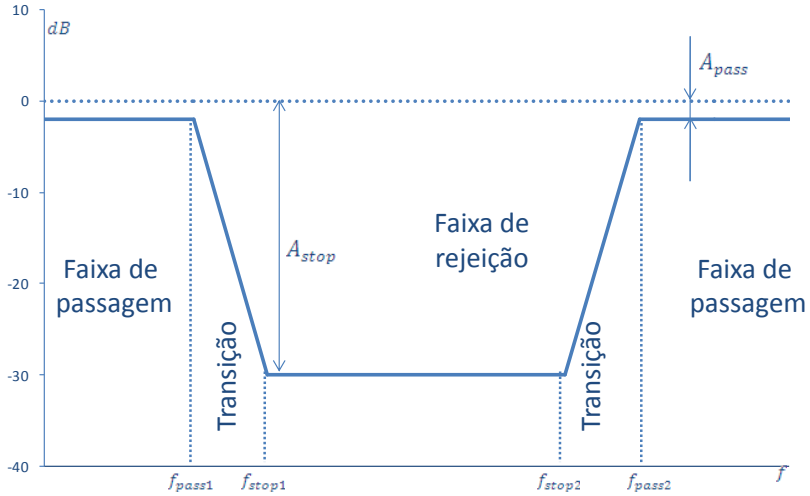

Figura 13 - Resposta em frequência de filtro rejeita faixa.

3.4 Extração de características

3.4.1 Densidade espectral de potência

A Densidade Espectral de Potência (PSD) ou Periodograma Padrão pode ser obtida utilizando a equação (9), onde $S_p(f)$ é o estimativa da densidade espectral do sinal, T_s é o intervalo de amostragem, N é o número de amostras do sinal, f é a frequência do sinal, x[n] é a amplitude discreta de cada amostra do sinal e S(k) é a PSD propriamente dita (STOICA e MOSES, 1997). O sinal x[n] pode ser delimitado a partir do sinal analógico discretizado utilizado uma janela retangular.

$$\boldsymbol{S(k) = \left(S_p(f)\right)^2 = \frac{T_s}{N}\left(\sum_{n=1}^{N} x[n] e^{-j2\pi f n T_s}\right)^2} \quad (9)$$

Por ser baseada em transformada rápida de Fourrier, a relação entre a quantidade de amostras N e a frequência do sinal resulta na melhor resolução possível do sinal no domínio da frequência sem que haja sobreposição de janela na transformada.

3.4.2 Potência espectral média

A Potência Espectral Média (PSDM) é obtida a partir da PSD utilizando a equação (10) (adaptada de DIEZ et al., 2009.), sendo f_1 e f_2 as frequências mínima e máxima do sinal considerado e S(k) o Periodograma Padrão.

$$PSDM = \sum_{k=f_1}^{f_2} S(k) \tag{10}$$

A Potência Espectral Média por Faixa de Frequência ($PSDM_{f_i}$) pode ser adaptada a partir da equação (11), sendo f_{i_1} e f_{i_2} as frequências iniciais e finais de cada faixa de frequência.

$$PSDM_{f_i} = \frac{1}{f_{i_2} - f_{i_1}} \sum_{k=f_{i_1}}^{f_{i_2}} S(k) \tag{11}$$

3.4.3 Seleção espacial de características

O posicionamento de cada eletrodo no couro cabeludo permite captar sinais oriundos de regiões específicas do cérebro, que são responsáveis por funções específicas. O EEG adquirido com mais pares de eletrodos permite o mapeamento simultâneo de diversas regiões do cérebro.

Considerando-se subconjuntos dos eletrodos utilizados em uma aquisição, pode-se determinar a influência da atividade cerebral de áreas distintas do cérebro nos resultados de um classificador em função do posicionamento dos eletrodos de cada subconjunto. Dado que se está variando a posição da região do cérebro na aquisição do EEG em cada subconjunto, a técnica aqui descrita denomina-se de Seleção Espacial de Características (HOFFMANN, VESIN e EBRAHIMI, 2007).

3.5 Classificadores

3.5.1 Classificador baseado em LDA

A LDA ou Análise Discriminante Linear de Fisher é uma técnica utilizada para o reconhecimento de padrões que separa amostras de um conjunto de dados em classes projetando-as em um espaço de maneira a separá-las linearmente. A LDA é uma técnica multi-classes.

Para isso, busca maximizar a variabilidade entre classes (S_b) e minimizar a variabilidade das amostras dentro das classes (S_w), definidas pelas equações (12) e (13), onde: g é o número de classes, N_i é a quantidade de amostras da classe X_i, N é a quantidade total de dados de todas as classes, $\bar{x}_i$ é a média da classe X_i e $\bar{x}$ é a média geral de todas as classes (TREVENA e MILLER, 2002; BELHUMEUR, HESPANHA e KRIEGMAN, 1997).

$$S_b = \sum_{i=1}^{g} N_i (x_i - \bar{x})\,(x_i - \bar{x})^T, \bar{x} = \frac{1}{N}\sum_{i=i}^{g}\sum_{k=1}^{N_1} x_k \tag{12}$$

$$S_w = \sum_{i=1}^{g}\sum_{k=1}^{N_i} \left(x_{i_k} - \bar{x_i}\right)\left(x_{i_k} - \bar{x_i}\right)^T,\ \bar{x_i} = \frac{1}{N_i}\sum_{k=1}^{N_i} x_k \tag{13}$$

A LDA consegue definir os limites que separam os grupos através de uma matriz de projeção que maximiza a razão do determinante definido pela equação (14), onde w^* é função de custo obtida a partir razão da variância entre classes pela variância das classes. Tendo-se a premissa que S_w é uma matriz não singular, pelo critério de Fisher, pode-se maximizá-la quando a matriz de projeção w^* é composta pelos autovetores de ${S_w}^{-1}S_b$ com pelo menos $(g-1)$ autovalores não nulos (TREVENA e MILLER, 2002; BELHUMEUR, HESPANHA e KRIEGMAN, 1997).

$$w^* = argmax_w \frac{wS_bw}{w^T S_w w} \tag{14}$$

Utilizando-se então distância euclidiana entre os dados projetados e a centroide de cada classe e determina-se a qual pertencem cada dado em função da proximidade entre estes.

3.5.2 Classicador baseado em SVM

Uma SVM ou Máquina de Vetores de Suporte é uma ferramenta de classificação binária disponibilizada pela teoria de aprendizagem estatística que é particularmente útil na discriminação de dados de grande dimensão e não separáveis linearmente, ou seja, as diferentes classes de dados apresentam sobreposições (HASTIE, 2011a).

Para atingir esse objetivo, as SVM mapeiam uma parcela do conjunto de dados, denominado conjunto de treinamento, de seu espaço original, o espaço de entradas, para um espaço de maior dimensão, conhecido como espaço de características. As Figuras 14, 15 e 16 ilustram esse conceito.

A Figura 14, que apresenta os dados no espaço de entrada, utilizou dados obtidos no experimento da presente pesquisa e mostra que há uma região na qual a discriminabilidade em classes é difícil.

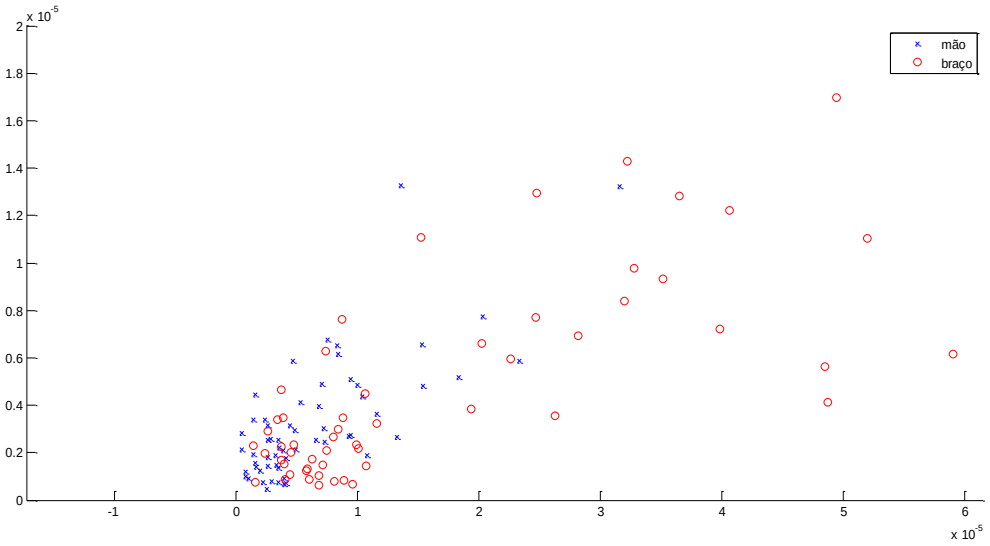

Figura 14 – Exemplo de dados no espaço de entradas.

A Figura 15 mostra os dados de treinamento projetados no espaço de características, sendo que todos os pontos apresentados constituem os vetores de suporte e a linha do hiperplano de separação.

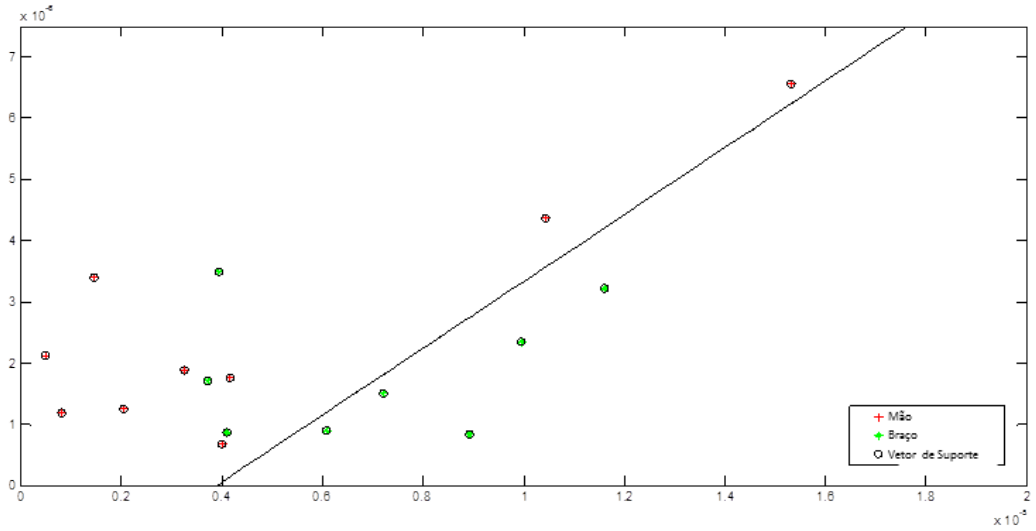

Figura 15 – Dados de treinamento no espaço de características e respectivos vetores de suporte.

A Figura 16 traz os dados de teste projetados no espaço de características sobre os vetores de suporte, mostrando como este os separa nessa dimensão. Os dados aqui apresentados foram obtidos nos experimentos da presente pesquisa. A partir dos dados de treinamento, a SVM estima uma função que corretamente classifique os dados de teste, considerando uma classe de funções que minimize o erro de teste, evitando sobre-treinamento (over-fitting).

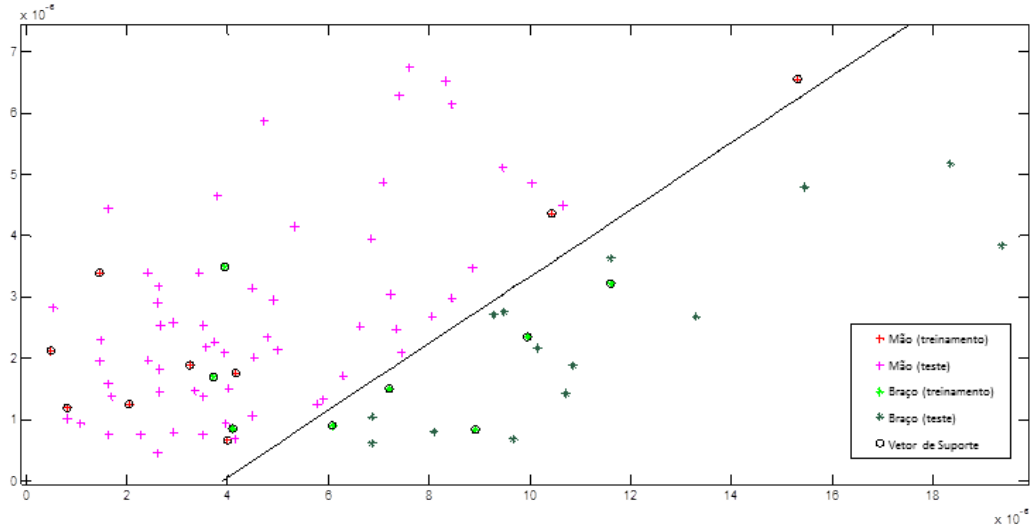

Figura 16 – Dados de teste separados no espaço de características.

A minimização do erro de teste é baseada no princípio da Minimização do Risco Estrutural, que afirma que essa taxa é delimitada pela somatória dos erros de treinamento e pela dimensão Vapnik-Chervonenkis (VC) (VAPNIK, 2000), que depende da função de classe adotada. A dimensão VC é também uma forma de medir a capacidade de generalização

de uma função e é definida como o maior número de pontos que pode ser separado em todas as maneiras possíveis.

Geometricamente, essa técnica busca encontrar um hiperplano que linearmente separe os dados de forma ótima em uma dimensão maior do que a do espaço original, maximizando a espessura da margem entre classes, pois é conhecido que essa maximização melhora a capacidade de generalização. Os vetores de suporte correspondem aos dados de treinamento que se localizam mais próximos ao hiperplano de separação, conforme ilustra a Figura 17 (HASTIE, 2011a).

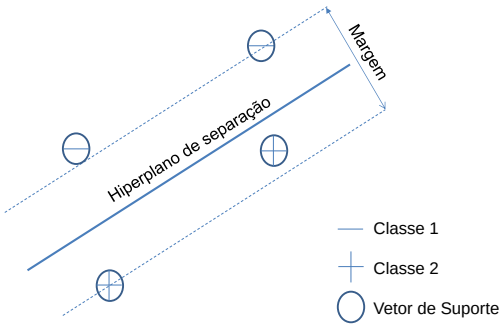

Figura 17 – Hiperplano de separação dos dados e vetores de Suporte.

A classificação dos dados de teste é feita em pela distância em que se encontram relação ao hiperplano de separação dos dados. A distância de cada ponto corresponde ao comprimento da reta normal que o interliga ao hiperplano.

No caso mais simples, ou seja, padrões linearmente separáveis, a determinação desse hiperplano busca separar perfeitamente os dados de treinamento e com a maior margem possível (HASTIE, 2011a). A equação (15) define esse hiperplano, onde w ∈ R^nrepresenta o vetor de pesos e b é o desvio (bias), de forma que um vetor xj pertencente à classe yj satisfaça a equação (16).

$$(x.w) + b = 0{,}1 \tag{15}$$

$$y_j\left((w.x_j) + b\right) \geq 1 \tag{16}$$

Para maximizar a margem do hiperplano, basta minimizar ‖w‖na determinação da distância Euclidiana entre o hiperplano e os vetores de suporte, dada pela equação (17). Nota-se que os vetores de suporte ocorrem na condição em que (16) é igual a 1.

$$\frac{y_j\left((w.x_j) + b\right)}{\|w\|} = \frac{1}{\|w\|} \tag{17}$$

Busca-se então um conjunto de pontos $\{(x_1, y_1), \ldots (x_N, y_N)\}$ que resultem na condição em que a equação (16) seja satisfeita e que e função de custo **(18)** seja minimizada.

$$\theta(w) = \frac{1}{2}(w.w) \tag{18}$$

A partir da formulação primal dada por (15), aplicando-se a teoria de Lagrange, deve-se determinar os multiplicadores $\alpha_i$ótimos para que J seja maximizado em (19), satisfazendo ainda a equação (20), sendo N a quantidade de amostras.

$$J(w, b, \alpha) = -\frac{1}{2}\sum_{i,j}^{N} \alpha_i \alpha_j y_i y_j (x_i x_i) + \sum_{i=1}^{N} \alpha_i y_i - b \sum_{i=i}^{N} \alpha_i \tag{19}$$

$$\sum_{i=1}^{N} \alpha_i y_i = 0 \; e \; \alpha_i > 0 \tag{20}$$

Considerando-se dados não separáveis linearmente, a condição estabelecida por (16) não é mais possível de ser garantida porque não existe um hiperplano que separe corretamente todos os pontos, causando a ocorrência de erros ε. Para contornar essa condição, introduz-se o uso de variáveis soltas e o conceito de margens de separação suaves. Com isso, uma classificação passa a ser dita correta quando a expressão (21) é verdadeira.

$$y_j \left((w.x_j) + b \right) + \varepsilon_j \geq 1, para \; j = 1 \ldots N \tag{21}$$

Nesse caso, os pontos em que $\varepsilon > 1$ são considerados como incorretamente classificados, $\sum \varepsilon_j$ representa o erro de treinamento máximo e a função de custo passa a ser representada pela equação (22), onde C representa uma constante de regularização.

$$\theta(w, \varepsilon) = \frac{1}{2}(w.w) + C \sum_{j=1}^{N} \varepsilon_j \tag{22}$$

Analogamente ao método aplicável a padrões linearmente separáveis, devem-se determinar os multiplicadores $\alpha_i$ótimos para que J seja maximizado em (23), satisfazendo ainda a (24).

$$J(\alpha) = -\frac{1}{2}\sum_{i,j}^{N} \alpha_i \alpha_j y_i y_j (x_i x_i) + \sum_{i=i}^{N} \alpha_i \tag{23}$$

$$\sum_{i=1}^{N} \alpha_i y_i = 0 \; e \; 0 \leq \alpha_i \leq C \tag{24}$$

Entretanto, é possível aplicar o método mais simples para padrões não separáveis linearmente fazendo uso de funções de Kernel, calculadas no espaço original e que emulam a

projeção dos dados em um espaço aonde estes são linearmente separáveis, garantindo melhor desempenho computacional do que realmente mapear os dados em um espaço de maior dimensionalidade. As mais comumente utilizadas são a linear ou de produto matricial, quadrática, polinomial, Radial Gaussiana e Perceptron Multicamadas, as quais estão apresentadas na Tabela 4 (HASTIE, 2011a).

Tabela 4 - Funções Kernel utilizadas pelas Máquinas de Vetores de Suporte.

Tipo	Função
Linear	$K(x,y) = a\langle x,y\rangle + b$
Quadrática	$K(x,y) = a\langle x,y\rangle^2 + b\langle x,y\rangle + c$
Polinomial	$K(x,y) = (1 + \langle x,y\rangle)^d$
Radial Gaussiana (RBF)	$K(x,y) = e^{-\frac{\langle (x-y),x-y\rangle}{2\sigma^2}}$
Perceptron Multicamada	$\tanh(p_1\langle x,y\rangle + p_2)$

3.6 Análise de Componentes Principais

Quando há um aumento exponencial da complexidade computacional de um problema em função do aumento de sua dimensionalidade ocorre um fenômeno conhecido como maldição da dimensionalidade. Isso implica que deve haver uma quantidade razoável de exemplos de treinamento frente à dimensionalidade do vetor de características para que um classificador tenha um desempenho satisfatório, ou seja, que o erro seja pequeno.

Uma consequência da maldição da dimensionalidade é um comportamento conhecido como Fenômeno de Pico, pois a adição de novas características é benéfica até o ponto em que se atinge um erro mínimo e, a partir deste, passa a influenciar negativamente no desempenho. A técnica da PCA contribui para minimizar esse problema, pois pode ser utilizada para reduzir a dimensionalidade de um problema, permitindo que as componentes mais significativas em termos de informação sejam extraídas e aplicadas como treinamento de um classificador.

A PCA ou Análise de Componentes Principais é uma técnica estatística de extração de características que busca explicar a estrutura da covariância de um conjunto de variáveis por meio de uma pequena quantidade de combinações lineares destas. Com isso, permite identificar um subconjunto de dados de maior relevância na representação do todo,

destacando similaridades e diferenças neles contidas, reduzindo o volume e a complexidade dos dados.

A PCA identifica as direções nas quais as projeções dos dados maximizam sua variabilidade, de forma a poder se desprezar as direções que contenham menor variabilidade dos dados, e com isso permite que se ignorem informações redundantes ou pouco representativas, reduzindo assim sua dimensionalidade. Pela redução de dimensionalidade dos dados, porém trabalhando dentro de limites de perda de informação ou representatividade pré-estabelecidos, a PCA é capaz de comprimir os dados eliminando informações de pouca relevância.

A PCA é construída utilizando-se o seguinte algoritmo:

1. Considerando-se os dados dispostos em uma matriz de tamanho DxN, sendo D sua dimensionalidade e N_i a quantidade de amostras de cada dimensão, deve-se calcular a média $\bar{d}_i$ para cada coluna D, conforme equação (25).

$$\bar{d}_i = \frac{1}{N_i}\sum_{k=1}^{N_i} d_{i_k},\ i \in \mathbb{N} \rightarrow 1 \leq i \leq D \tag{25}$$

2. Subtraia a média de cada dimensão de forma a produzir nova matriz D' de tamanho DxN, conforme equação (26). Calcule sua matriz de covariâncias S.

$$S = cov(D'), sendo\ D' = D - \bar{d}, i \in \mathbb{N} \rightarrow 1 \leq i \leq D \tag{26}$$

   Nota: a covariância é calculada para cada par de colunas da matriz D', sendo que a covariância entre duas colunas pode ser calculada por:

$$cov(D_1, D_2) = \frac{1}{N-1}\sum_{i=1}^{N}\left(d_{1_i} - \overline{d_1}\right)\left(d_{2_i} - \overline{d_2}\right)$$

3. Calcule os autovalores e autovetores da matriz de covariâncias. Os autovalores λ são as raízes da equação (27) e v é o autovetor, de tamanho *1*x*N*.

$$S.v = \lambda.v \tag{27}$$

4. Ordene os autovetores em ordem decrescente de seus autovalores, os quais representam a variância dos dados.
5. Construa o vetor de características a partir dos autovetores, ignorando alguns de menor significância. O vetor resultante passa a ser denominado de componentes principais e corresponde aos maiores autovalores.

   a. Nesse passo, recomenda-se uma análise empírica para determinar o montante a ser ignorado em função do impacto no resultado final do processo ao qual se aplicarão os novos dados.
   b. Somando-se os autovalores correspondentes às componentes presentes no vetor de componentes principais obtém-se a representatividade em relação aos dados ou, mais precisamente, sua variabilidade acumulada.
6. Obtenha o novo conjunto de dados multiplicando o vetor de componentes principais transposto pela matriz de dados ajustada transposta.

Esse item foi baseado em (HASTIE, 2011b).

3.6.1 Validação cruzada com leave one out

A validação cruzada é uma técnica que permite avaliar a capacidade de generalização de um classificador a partir de um conjunto de dados, que são segmentados em dois subconjuntos mutuamente exclusivos, denominados conjunto de treinamento e conjunto de teste.

Os métodos mais difundidos são o holdout, k-fold e leave-one-out, este último um caso específico do anterior no qual k é igual ao tamanho do conjunto de dados. O leave-one-out é um método simples e que é útil quando se dispõe de pequena quantidade de amostras e, adicionalmente, Chin et al. (2009) mostrou que não há diferenças estatisticamente significativas entre diversos métodos de validação.

O leave-one-out é definido da seguinte maneira:

1. Seja uma população de dados composta de N amostras que podem ser subdivididas em M classes ($C_1, C_2 \dots G_M$) de igual tamanho;
2. Deve-se aleatoriamente tomar 1 amostra de cada classe para compor um conjunto de teste com M indivíduos da população, um de cada uma das M classes. Os N-M indivíduos restantes representarão o conjunto de treinamento;
3. Ambos os subconjuntos são submetidos ao classificador a ser avaliado, sendo N-M indivíduos destinados ao treinamento do algoritmo e M ao teste de classificação.
4. Os resultados obtidos são comparados com os esperados e então contabilizados como positivos verdadeiros (P_V), positivos falsos (P_F), negativos verdadeiros (N_V) e negativos falsos (N_F). Resultados positivos são aqueles que se classifica o dado como

pertencente à classe em questão e resultados negativos representa a situação oposta, podendo, em ambos os casos, a classificação estar correta, isto é, verdadeira, ou incorreta, ou seja, falsa.

5. O processo é repetido N vezes para que se testem todos os indivíduos da população, sendo que a cada repetição M indivíduos distintos dos considerados anteriormente irão compor novo grupo de teste.
6. Os resultados da comparação devem ser cumulativamente contabilizados a cada repetição, de forma ao final produzirem a taxa de acerto média T de todas as classes, que é dada pela equação (28).

$$T = \frac{1}{N}\sum_{C=1}^{N}\frac{P_{V_C}}{P_{V_C} + P_{F_C} + N_{V_C} + N_{F_C}} \tag{28}$$

4. METODOLOGIA

4.1 Aquisição de dados

4.1.1 Voluntários

Participaram dos experimentos três indivíduos do sexo masculino, entre 30 e 45 anos, todos destros, calvos e sem restrições mentais ou físicas, na condição de voluntários, após assinar Termo de Consentimento Livre e Esclarecido (ANEXO A), baseado em protocolo experimental, aprovada pelo COEP - USJT -No.088/2011. Cabe observar que um dos indivíduos apresentava dificuldade em movimentar o pulso esquerdo devido a vir de uma recuperação de uma lesão nesse local.

4.1.2 Configuração do sistema de aquisição de dados

O sistema de aquisição de dados utilizado nos experimentos contou com a seguinte lista de materiais:

- Dois computadores PC convencionais doravante denominados PC-1 e PC-2;
- Dois conjuntos de sensores constituídos de chaves eletrônicas do tipo botão de pressão e respectivo circuito eletrônico;
- Uma touca de eletrodos no padrão 10-20 com gel redutor de impedância;
- Uma mesa e cadeira com base de apoio para os sensores e braços dos voluntários;
- Sistema de aquisição de dados da Ad Instruments, composta por:
    - Amplificador Octal BioAmp com 8 canais;
    - Sistema de aquisição 16/30 PowerLab com 16 canais de entradas analógicas;
    - Software LabChart 7 de controle do sistema;

O computador PC-1 rodou um software desenvolvido especificamente para o experimento que é responsável por apresentar aos voluntários uma lista de instruções indicando o movimento que deve ser realizado. Esse computador se conecta a uma entrada analógica do sistema de aquisição por meio de sua interface RS-232, utilizada para enviar um sinal de sincronismo ao sistema de aquisição sempre que uma instrução é apresentada ou retirada da tela (MESSMER, 1999). Já o computador PC-2 roda o software LabChart 7 que é

responsável por configurar e controlar o processo de aquisição, conversão e armazenamento dos dados para o formato do software MATLAB.

A touca de eletrodos é conectada às entradas analógicas do BioAmp que amplifica o sinal do potencial cerebral e o entrega ao sistema de aquisição, que aplica um primeiro conjunto de filtros e o digitaliza. A este sistema também são interligados os dois conjuntos de sensores. O diagrama da Figura 18 ilustra o sistema descrito.

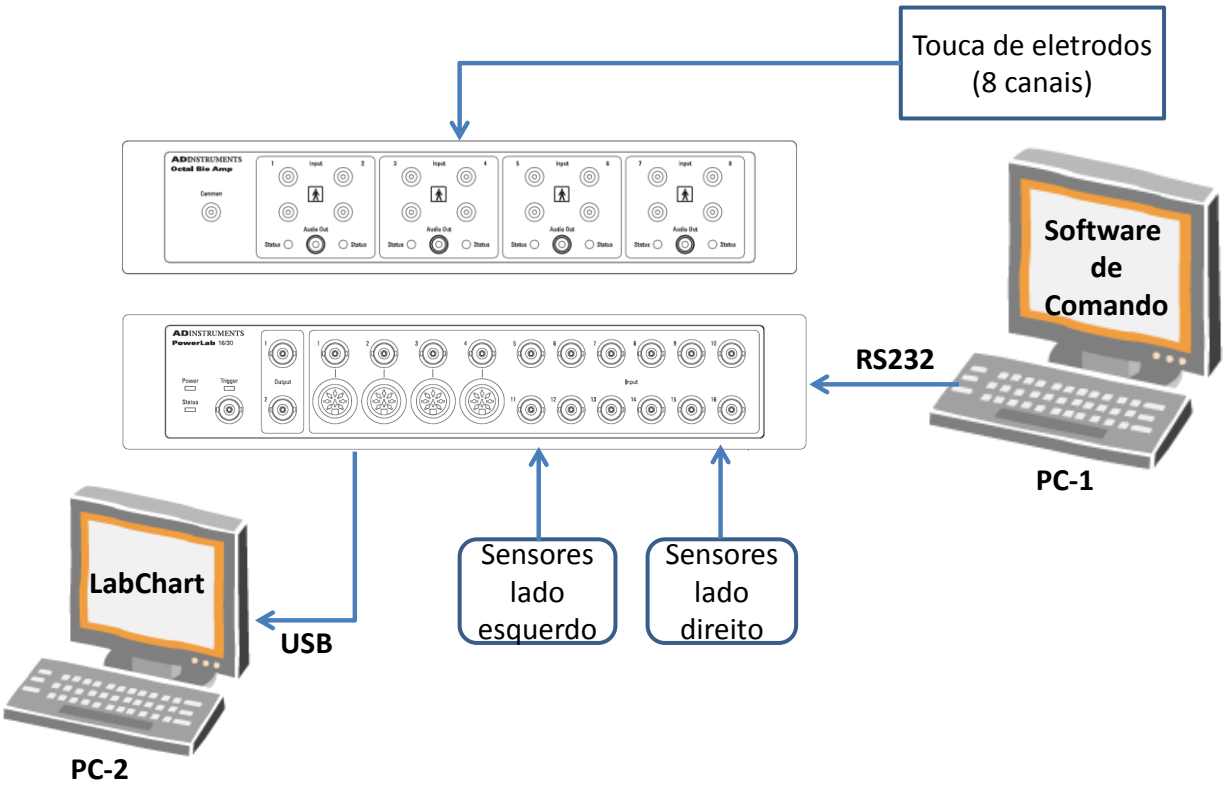

Figura 18 - Sistema de aquisição.

Os sensores correspondem a um conjunto de resistores e chaves em configuração baseada em ponte de Wheatstone, alimentados por baterias de 9 V, conforme mostra o diagrama esquemático da Figura 19. A alimentação por baterias visa garantir segurança aos voluntários.

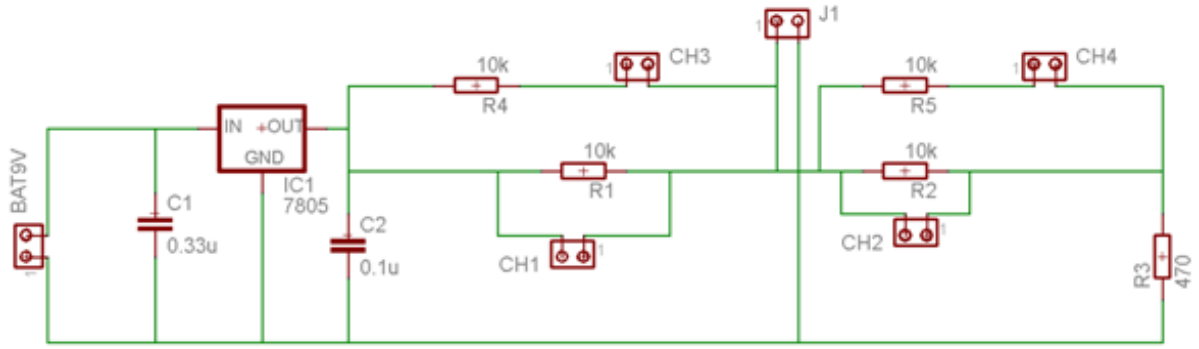

Figura 19 - Circuito eletrônico dos sensores.

As chaves são fixadas à base de apoio, nas mãos e nos braços dos voluntários conforme indicado na Figura 20. Essa solução, baseada em sensores, resulta em níveis de tensão na saída J1 distintos para cada movimento executado, permitindo uma checagem de consistência com as instruções apresentadas aos voluntários e também viabilizam a identificação das fases dos movimentos. O item 4.2.2 detalha como é feito esse processo.

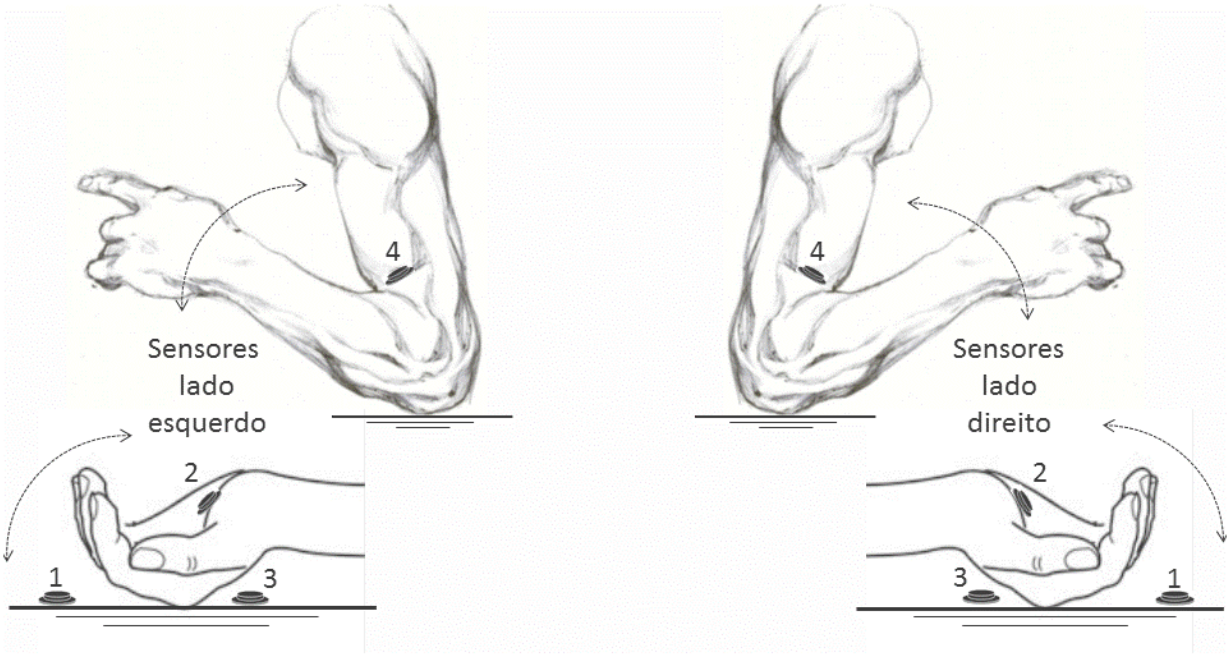

Figura 20 - Posicionamento dos sensores.

A touca de eletrodos, montada com base no padrão 10-20 de disposição de eletrodos, foi interligada ao amplificador de maneira a mensurar diferenças de potenciais não convencionais. Uma configuração de oito canais utilizando os eletrodos F3, F4, C3, C4, P3, P4, O1 e O2, com relação aos eletrodos centrais Fz, Cz, Pz e Oz foi utilizada, conforme indicado na Figura 21, sendo baseada na configuração conhecida como bipolar transversal, apresentada no item 3. Embora essa configuração difira do praticado na literatura em relação

ao sentido das diferenças de potencial, que são tomadas no sentido longitudinal, e a razão para isto é permitir que se realizassem as medições de forma mais localizada sobre o córtex motor, além de ser uma configuração clinicamente utilizada.

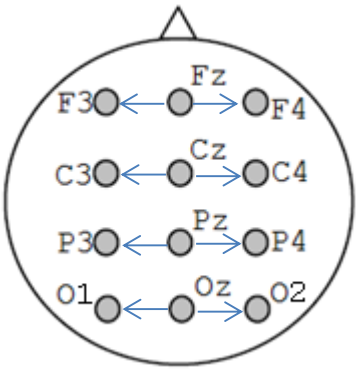

Figura 21 - Posicionamento dos eletrodos.

Os eletrodos, a interface RS-232 do PC-1 e os sensores foram interligados ao sistema de aquisição conforme indicado na Tabela 5. Foram mapeadas as regiões do córtex frontal, responsável pela memória associativa, intenção e decisão; do córtex motor primário e secundário, associados à execução de movimento; da região somatossensorial, do córtex parietal, responsável pela memória e associação verbal e espacial; e do córtex visual primário e secundário.

Tabela 5 - Mapeamento dos canais do sistema de aquisição

Canal	Par de Eletrodo/Sensor	Região Cerebral
1	F_3-F_z	Córtex Frontal, região da memória associativa, vinculada a intenção e decisão.
2	F_4-F_z	
3	C_3-C_z	Córtex motor primário e secundário e córtex somatossensorial, associado a execução de movimento.
4	C_4-C_z	
5	P_3-P_z	Córtex parietal, associado a memória e áreas de associação verbal e espacial.
6	P_4-P_z	
7	O_1-O_z	Córtex visual primário e secundário.
8	O_2-O_z	
9	Ch Direito	
10	Ch Esquero	
11	Serial PC	

O sistema de aquisição PowerLab foi configurado com um filtro rejeita faixa de segunda ordem com frequência de corte de centrada em 60 Hz e atenuação de -32 dB na faixa de rejeição, ligado em cascata com um filtro passa-baixa com frequências de corte de 0,5 Hz e 120 Hz, com taxa de amostragem de 1 kHz para a conversão A/D de 16 bis de resolução. O sistema de aquisição permite a digitalização de sinais entre ± 2 mV até ± 10 V, ajustável em

12 intervalos, e, com o amplificador acoplado, permite entre ± 5 μV até 100 mV, ajustável em 14 intervalos.

4.1.3 Procedimento de aquisição dos dados

Os voluntários sentaram individualmente e separadamente em frente ao PC-1, com ambas as mãos e braços em posição de repouso sobre a base de apoio.

Inicialmente, solicitou-se aos voluntários que relaxassem e fechassem os olhos por dez segundos, tendo sido adquirido o EEG referente a esse período. Os dados obtidos neste procedimento correspondem a primeira aquisição.

A partir dessa aquisição inicial, quatro conjuntos de 15 instruções, constituídos de fechamento da mão esquerda, fechamento da mão direita, flexão do braço esquerdo e flexão do braço direito, foram apresentadas ao voluntário, totalizando 60 instruções.

Ao lhe ser apresentada a instrução, o voluntário deveria executar o movimento solicitado e manter-se na nova posição. No momento em que a instrução fosse retirada da tela, o voluntário deveria retornar à posição de repouso. As instruções foram apresentadas ao voluntário com fonte branca e fundo preto para minimizar o impacto sobre a atividade na região do córtex visual do cérebro.

Cada instrução foi apresentada ao voluntário por um período de 5 segundos e com intervalos de 4 segundos entre cada nova instrução, resultando em uma primeira sessão de aquisição com duração aproximada de 9 minutos. O procedimento foi repetido 3 vezes, resultando em um total de 180 instruções com duração total de 27 minutos, completando mais três aquisições.

4.2 Seleção e tabulação dos dados

4.2.1 Formato dos dados

Os dados de EEG, adquiridos pelo sistema descrito anteriormente, estão segmentados em onze canais, conforme configuração apresentada na Tabela 6.

Tabela 6 - Configuração dos canais do sistema de aquisição

Canal	Par de Eletrodo/Sensor	Escala (Vpp)	Frequência de Amostragem (Hz)	Filtro
1	F3-Fz	500µV	1000	Filtros rejeita faixa frequência de corte de 60 Hz e passa faixa com frequências de corte de 0,5 Hz e 120 Hz.
2	F4-Fz	500µV	1000	
3	C3-Cz	500µV	1000	
4	C4-Cz	500µV	1000	
5	P3-Pz	500µV	1000	
6	P4-Pz	500µV	1000	
7	O1-Oz	500µV	1000	
8	O2-Oz	500µV	1000	
9	Sensor Direito	5V	1000	Filtro digital passa baixa com frequência de corte de 5 Hz
10	Sensor Esquero	5V	1000	
11	Serial PC	5V	1000	

Utilizando o LabChart 7, os dados foram exportados para um arquivo MATLAB que pôde ser importado diretamente deste, produzindo o conjunto de variáveis e matrizes na área de trabalho do MATLAB apresentados na Figura 22. Os dados foram exportados com precisão de 32 bits utilizando operações de ponto flutuante.

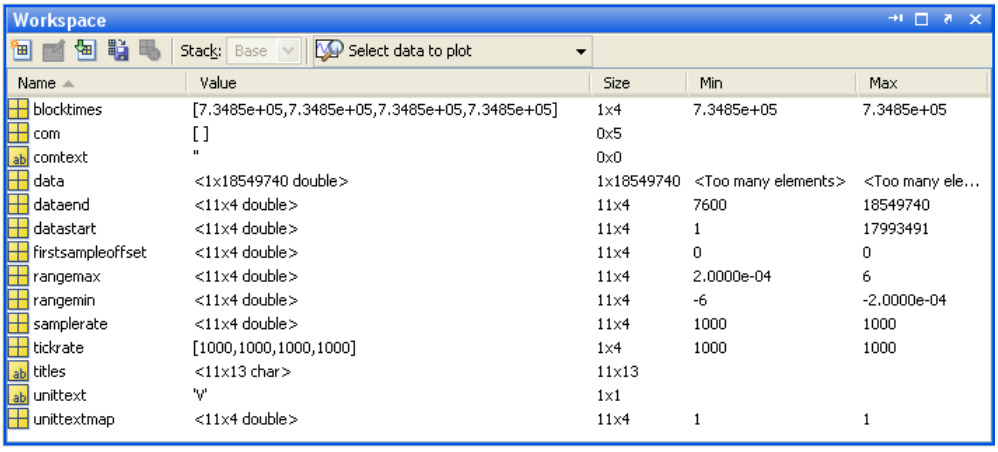

Figura 22 - Variáveis exportadas do LabChart 7 ao MATLAB.

Os dados estão contidos no vetor denominado “data”, que é um vetor linha contendo todos os dados adquiridos. Cada uma das quatro aquisições descritas no item 4.1.3 constitui um bloco de dados que contém os onze canais, sendo que todas as amostras de cada bloco e canal são combinadas sequencialmente, varrendo primeiro os blocos e depois os canais.

As matrizes “datastart” e “dataend” contêm as posições iniciais e finais, respectivamente, de cada bloco e canal no vetor “data”. Tendo-se em conta que foram realizadas quatro aquisições com onze canais cada, os vetores de posição resultam nas matrizes 11x4 observadas na Figura 22, sendo cada coluna relativa a um bloco de aquisição e

cada linha referente a um canal. As aquisições contendo os movimentos realizados encontram-se nos blocos 2, 3 e 4.

Para obterem-se os dados relativos a um determinado canal, deve-se, a partir da posição especificada nas matrizes “datastart” e “dataend”, endereçar no vetor “data” as posições desejadas. Por exemplo, se desejarmos associar os dados do oitavo canal da segunda aquisição a um novo vetor para posterior processamento, seria feito com x=data(datastart(8,2):dataend(8,2)). Os dados da Tabela 7 referem-se à aquisição realizada com um dos voluntários.

A matriz “samplerate” também é uma matriz 11x4 e contém as frequências de amostragem utilizadas em cada canal, que foi de 1 KHz em todo experimento, e o vetor “tickrate” é um vetor coluna que contém a maior frequência de amostragem de cada bloco de aquisição. O LabChart disponibiliza esse vetor que deve ser útil quando as frequências de amostragem dos canais não são iguais, sendo que, neste experimento, estava sempre preenchido com o valor 1000.

Tabela 7 - Matriz de posição dos canais no MATLAB

```
>> datastart
datastart =
           1       83601     6276491    12430991
        7601      646591     6835991    12987241
       15201     1209581     7395491    13543491
       22801     1772571     7954991    14099741
       30401     2335561     8514491    14655991
       38001     2898551     9073991    15212241
       45601     3461541     9633491    15768491
       53201     4024531    10192991    16324741
       60801     4587521    10752491    16880991
       68401     5150511    11311991    17437241
       76001     5713501    11871491    17993491
>> dataend
dataend =
        7600      646590     6835990    12987240
       15200     1209580     7395490    13543490
       22800     1772570     7954990    14099740
       30400     2335560     8514490    14655990
       38000     2898550     9073990    15212240
       45600     3461540     9633490    15768490
       53200     4024530    10192990    16324740
       60800     4587520    10752490    16880990
       68400     5150510    11311990    17437240
       76000     5713500    11871490    17993490
       83600     6276490    12430990    18549740
```

A matriz “unittextmap” contém fatores multiplicativos de cada canal e está relacionada com o vetor “unittext”, o qual especifica a unidade dos dados adquiridos, no caso, Volts.

O vetor “titles” é um vetor coluna que contém os nomes de cada canal, conforme demonstrado a seguir.

```
>> titles
titles =
```

```
F3-Fz
F4-Fz
C3-Cz
C4-Cz
P3-Pz
P4-Pz
O1-Oz
O2-Oz
Mov. Direito
Mov. Esquerdo
Comando
```

As matrizes “scaleunits” e “scaleoffset” somente seriam consideradas se os dados tivessem sido exportados com precisão de 16 bits e o vetor “blocktime” contém a hora do dia que cada bloco de aquisição foi gravado, não sendo necessário para os processamentos realizados nesta pesquisa.

4.2.2 Pré-análise do movimento

As fases de movimento definidas neste estudo como planejamento, movimento e posição estática requerem a determinação dos instantes em que cada um dos sensores é acionado pelos voluntários e dependem também do seu tempo de reação a uma instrução que lhe é apresentada, determinado pelo atraso entre a apresentação de uma instrução e o momento em que é executada.

Pela relação entre os níveis de tensão da interface RS-232 do PC-1 e dos sensores baseados nas chaves de pressão é possível determinar esses instantes de tempo, conforme ilustrado na Figura 23. Esses sinais são digitalizados diretamente pelo sistema de aquisição da PowerLab, dando origem aos três canais de controle de comandos previstos no experimento.

A determinação do instante em que uma instrução é apresentada ao voluntário foi considerada como sendo o momento de transição entre os estados de verdadeiro e falso da interface RS-232 do PC-1. Sabendo-se que o padrão EIA RS-232 define que um sinal lógico verdadeiro é representado por uma tensão entre -3 e -15 V e um sinal lógico falso é representado por uma tensão entre +3 e +15V e que a taxa de variação (*slew rate*) deve ser no mínimo 30 V / μs, e levando-se em consideração que o sistema de aquisição PowerLab 16/30 admite até 10 Vpp, possui 16 bits de resolução e que a frequência de amostragem foi 1 kHz, pode-se assumir que quaisquer valores amostrados nos limiares de transição terão no máximo 1 ms de erro.

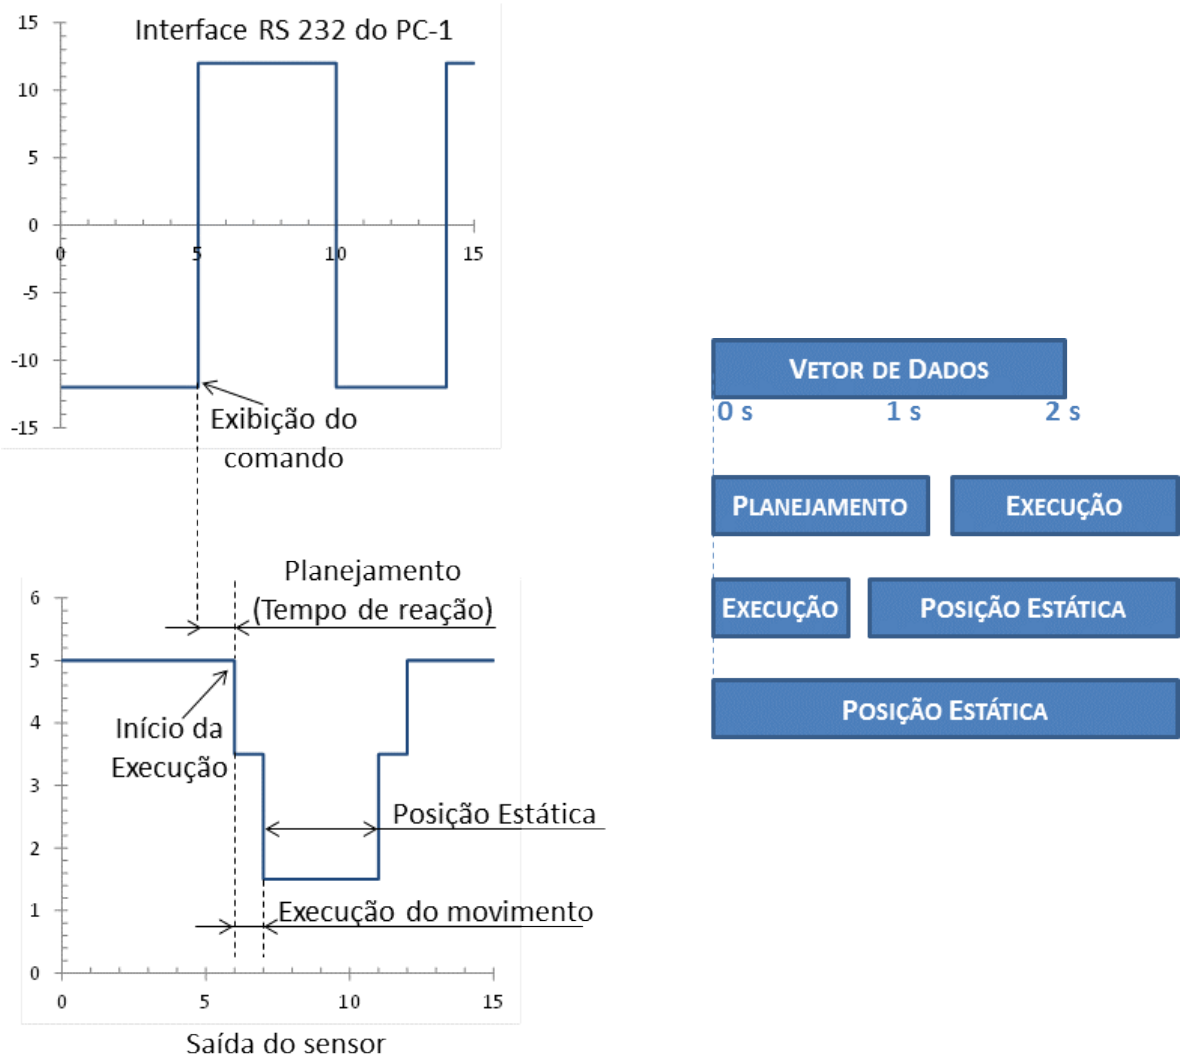

Figura 23 - Relação entre as fases do movimento captada pelos sensores e a serial do PC-1 e seus respectivos vetores de dados.

Tendo-se que o período entre a apresentação da instrução a um voluntário e o momento em que sua execução é iniciada representa a fase de planejamento, fez-se um estudo estatístico a partir dos dados amostrados a fim de determinar empiricamente esses valores. Desconsiderando-se alguns casos que ultrapassaram os 9 segundos entre instruções consecutivas, considerados como movimentos inválidos, verificou-se que esse tempo variou entre 228 ms e 8284 ms.

Esse intervalo de tempo contempla os processos cerebrais relativos à visão, interpretação, tomada de decisão em relação aos movimentos a serem executados, planejamento e início do movimento, culminando com o envio de ordens do córtex motor ao conjunto de músculos a serem acionados. Devido à grande diferença entre o maior e o menor valor verificados, e visando evitar a ocorrência de sobreposições entre o retorno à posição de

repouso com a execução do próximo movimento, considerou-se que o menor valor dentre as amostras representa aproximadamente o tempo de reação do voluntário do ponto de vista do córtex motor.

Analogamente, o estudo estatístico relativo à execução do movimento revelou intervalos de tempos com valores tão baixos quanto 40 ms até 2,7 s. Novamente, observou-se grande variabilidade entre os valores.

Claramente, percebe-se que não é possível delinear com exatidão a duração de cada fase, embora seja possível determinar o início da fase de movimento e da posição estática, acarretando na sobreposição de dados entre as fases. Em face desse cenário, na elaboração dos algoritmos desenvolvidos em MATLAB que este estudo fez uso, adotaram-se vetores de dados com 1 s e 2 s de duração, iniciando a partir dos pontos indicados na Figura 23, com o objetivo de avaliar a influência dessa sobreposição nos resultados dos classificadores. Para o tempo de planejamento, foram adotados 250 ms para os experimentos que consideram o vetor de dados com 1s de duração e 500 ms no caso do vetor de dados de 2 s em função dos tempos observados nos experimentos e de não haver clara indicação na literatura sobre esse aspécto.

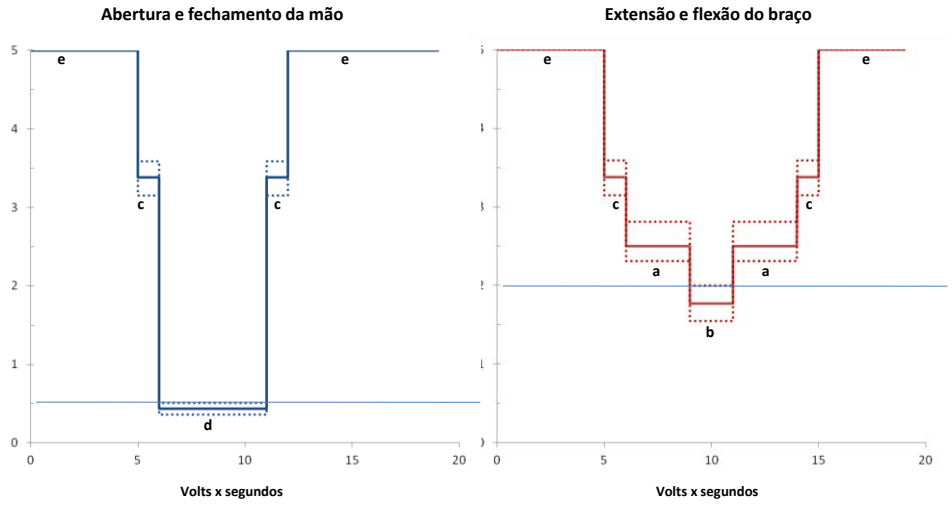

Figura 24 - Níveis de tensão dos sensores de movimento.

Utilizando um algoritmo especializado e lógica Fuzzy para considerar as variações de tensão resultantes das tolerâncias dos componentes utilizados no circuito eletrônico, foi possível também verificar se os movimentos executados foram os efetivamente apresentados aos voluntários, pois a rede resistiva utilizada no circuito eletrônico dos sensores produz formas de onda específicas para cada movimento. Esses valores podem ser observados na Figura 24. Os movimentos considerados incorretos foram expurgados de análises posteriores.

Nos casos em que se utilizou PCA para reduzir a dimensionalidade dos dados, adotou-se a quantidade de componentes fixa igual a 8 para todos os experimentos para simplificar os algoritmos e as análises. Esse valor foi adotado por se ter experimentalmente observado que representou no mínimo 99% da variabilidade dos dados para todos os experimentos realizados.

4.3 Extração de características

Fundamentalmente, a característica dos sinais de EEG utilizada como fonte de informação para alimentar os classificadores nesta pesquisa foi a PSD utilizando o método do Periodograma, conforme descrito no item 3.4.1.

Sobre a PSD, foi calculada a Potência Espectral Média por Faixas de Frequência ($PSDM_{f_i}$), conforme apresentado na Tabela 8. Faixas de frequência similares foram sugeridas por Diez et al. (2009), alegando que essa segmentação melhora a taxa de classificação dos movimentos, porém com γ_2 iniciando em 32 Hz e indo até 80 Hz.

Tabela 8 - Faixas de frequência de EEG (adaptada de DIEZ et al., 2009).

Faixas de frequência		
Faixa	**$F_{INICIAL}$**	**F_{FINAL}**
δ	0	4
Pre-α	4	8
α	8	12
β_1	12	14
β_2	14	18
β_3	18	25
γ_1	25	32
γ_2	32	80

Utilizou-se a Seleção Espacial de Características para avaliar a contribuição que cada eletrodo descrito na Tabela 5 apresentou sobre o resultado da classificação, tendo sido consideradas todas as 255 combinações possíveis com as 8 diferenças de potencial.

As características descritas neste item também foram avaliadas considerando a frequência máxima do sinal γ_2 variando entre 40 e 80 Hz, a fim de avaliar o comportamento dos classificadores em função da variação do espectro do sinal.

A resolução da PSD foi de 1 Hz para o vetor de dados de 1 s e de 0,5 Hz para o vetor de dados de 2 s em função do tamanho de cada um dos vetores.

4.4 Técnica de classificação

Foram aplicadas as técnicas LDA e SVM com função Kernel Radial Gaussiana (RBF), descritas no capítulo 3.5, para os dados com vetores de 1 e 2 s de duração e para as fases de planejamento, movimento e posição estática descritas, considerando a característica $PSDM_{f_i}$ descrita no item 3.4.2, para os três voluntários do experimento. Esses cenários foram estudados com e sem a aplicação de PCA e utilizando Seleção Espacial de Características, considerando-se a frequência máxima do sinal variando entre 40 e 80 Hz.

Para validar a classificação, foi adotada a técnica conhecida como *"leave one out",* uma vez que o trabalho de Chin et al. (2009) mostrou que não há diferenças estatisticamente significativas entre diversos métodos de validação. Além disso, como o tamanho da amostra de dados de cada movimento não é grande, esta técnica possibilita um melhor treinamento do algoritmo.

Como um dos objetivos dessa pesquisa é comparar diferentes técnicas de processamento, diferentes sinais cerebrais e diversas configurações de eletrodos, a técnica de "leave one out" foi utilizada para a definição de dados de treinamento e de teste para que o processo fosse mais simples.

4.5 Experimentos de classificação

Com o objetivo de avaliar a discriminabilidade dos dados adquiridos, estes foram submetidos a diferentes combinações de classes e técnicas de classificação. Utilizando os dados das três fases de movimento e os vetores de 1 s e 2s e aplicando Seleção Espacial de Características, buscou-se discriminar entre quatro movimentos (mão esquerda, mão direita, braço esquerdo e braço direito), entre membros (mãos versus braços, sendo que para isso os dados foram agrupados), entre lados direito e esquerdo (analogamente agrupados), entre mãos (mão direita da esquerda) e entre braços (braço direito do esquerdo).

Em todos esses cenários de classificação foram utilizadas as técnicas LDA, LDA com PCA, SVM e SVM com PCA sobre a $\mathrm{PSDM_{f_i}}$, com classificação por distância Euclidiana e validação cruzada Leave One Out. A Figura 25 ilustra o quadro completo.

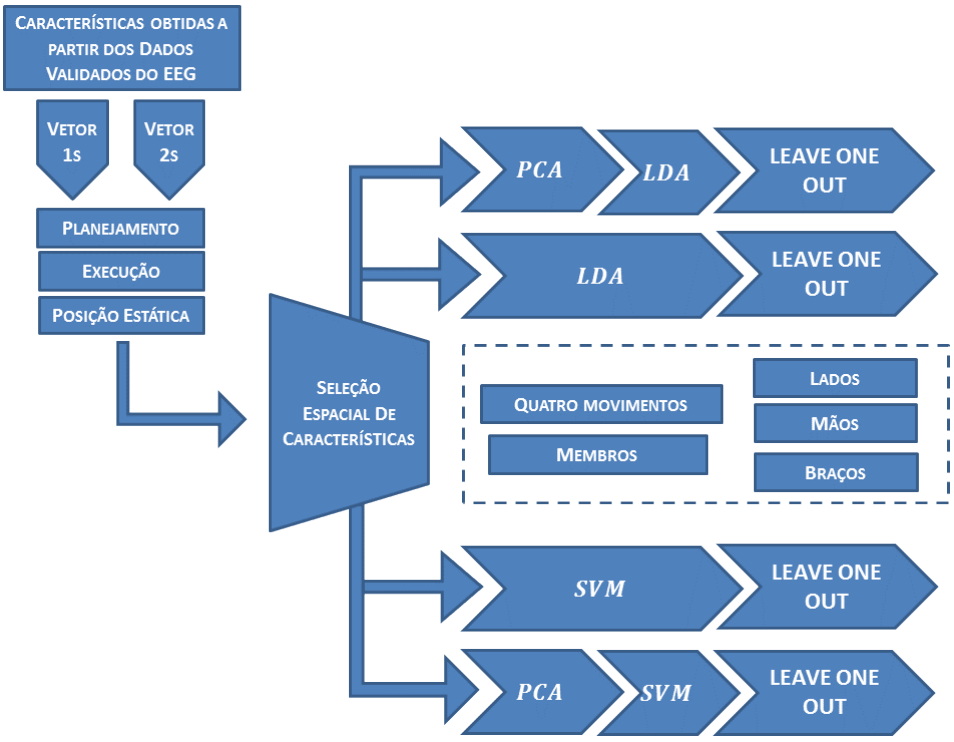

Figura 25 – Experimentos de Classificação.

Uma vez extraída a PSD e calculada a $PSDM_{f_i}$, são disponibilizados aos classificadores vetores de dados contendo 64 campos correspondendo a 8 faixas de frequência para cada um dos oito canais do EEG. Conforme descrito no item 4.1.3, o procedimento de aquisição gerou 180 amostras, segmentadas em 4 grupos de 45 cada, resultando em matrizes de dados com dimensionalidade de 64 x 180 que são subdivididas conforme o cenário de classificação. Os cenários de discriminação entre mãos e entre braços resultam em matrizes de dados com dimensões de 64 x 90 e entre lados, membros e 4 movimentos resulta em matrizes de 64 x 180, sendo que somente este último preconiza a classificação em 4 grupos e os demais em 2. A Figura 26 ilustra o exposto.

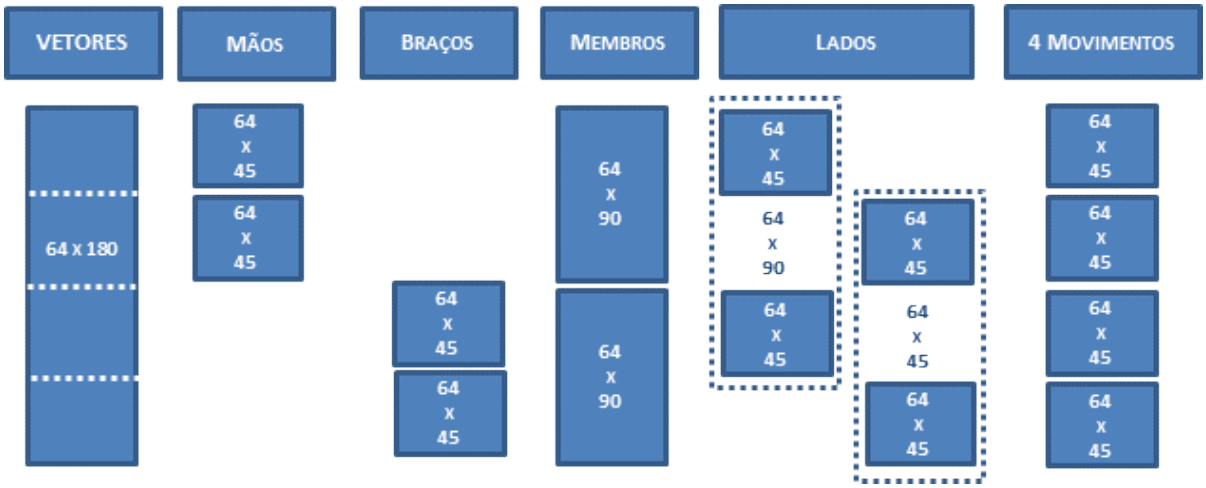

Figura 26 - Dimensionalidade dos dados

A aplicação da Seleção Espacial de Características pode reduzir a dimensão de tamanho igual a 64 da matriz de dados para até 8, em passos de 8 em 8, considerando todas as 255 possíveis combinações de diferenças de potencial providas pelo conjunto de 12 eletrodos aos 8 canais do sistema de aquisição.

5. RESULTADOS

Esse item apresenta os resultados obtidos na presente pesquisa, detalhando o cenário de classificação em 4 classes, com os respectivos resultados de cada técnica utilizada em subitens. Os demais cenários de classificação podem ser encontrados no apêndice B. As taxas de classificação apresentadas correspondem aos valores médios obtidos utilizando a técnica de validação *Leave One Out*.

Primeiramente são apresentados os resultados do estudo da influência da variação da frequência máxima do espectro do sinal considerado na construção dos vetores de características sobre as taxas de acerto. Nesse estudo observou-se que na medida em que se aumenta a frequência máxima até 80 Hz, ocorrem discretas variações positivas nas taxas de acerto para praticamente todos os cenários de classificação. Embora essa melhora não seja unânime, ela sempre ocorre para o cenário de classificação em quatro classes, situação mais complexa e principal objetivo de classificação dessa pesquisa. Em função disso, todos os demais estudos relatados adotaram 80 Hz como frequência máxima do sinal.

No detalhamento, para cada cenário de classificação são primeiramente apresentadas as taxas de acerto mínima, média e máxima de cada voluntário para as 255 configurações de eletrodos providas pela Seleção Espacial de Características para cada fase de movimento. Na sequência são apresentadas as taxas mínimas, média e máxima considerando simultaneamente os três indivíduos e as 255 configurações.

Em seguida encontram-se os resultados da avaliação do desempenho de cada fase de movimento, apontando, percentualmente, qual delas resultou nas melhores taxas de classificação em função da aplicação da técnica de *Leave One Out* para cada indivíduo. Essa avaliação foi feita para cada tamanho de vetor de dados e para todas as configurações de eletrodos providas pela Seleção Espacial de Características.

Ainda no mesmo item é apresentada uma visão a respeito dos conjuntos de eletrodos que propiciaram as melhores taxas de classificação para cada indivíduo, contendo o detalhamento de cada fase de movimento. Nessa avaliação, identificaram-se os eletrodos presentes na melhor taxa de classificação de cada indivíduo e também se contabilizaram quantas vezes cada par de eletrodos esteve presente na ocorrência da melhor taxa de classificação, a fim de possibilitar a eventual identificação de padrões entre os diversos experimentos realizados.

Em itens à parte apresentam-se um comparativo entre os melhores resultados de cada técnica e, nessa ótica, o desempenho geral de cada fase de movimento, e uma visão geral dos resultados da Seleção Espacial de Características no que se refere à ocorrência das configurações de eletrodos na melhor taxa de classificação.

5.1 Seleção espacial de características

A Seleção Espacial de Caraterísticas, tendo como base 8 diferenças de potencial, possibilita 255 combinações válidas de eletrodos. Sabendo-se que cada combinação foi testada com as 360 possibilidades de experimento entre 5 cenários de classificação, com 4 opções de classificadores, com 3 fases de movimento, com 2 vetores de dados e com 3 indivíduos, foram realizados 91.800 experimentos.

Se a Seleção Espacial de Características obtivesse somente em uma única combinação de eletrodos que resultasse na maior taxa de acerto, haveria somente 360 casos. Entretanto, alguns desses experimentos obtiveram a melhor taxa de classificação em duas ou mais combinações de eletrodos distintas, resultando em 422 ocorrências. Dado que há combinações de eletrodos coincidentes entre estas, a quantidade de configurações únicas que levaram à melhor taxa de acerto foi 180. Esse resultado mostra não haver concentração de configurações de eletrodos que levam à melhor taxa de acerto.

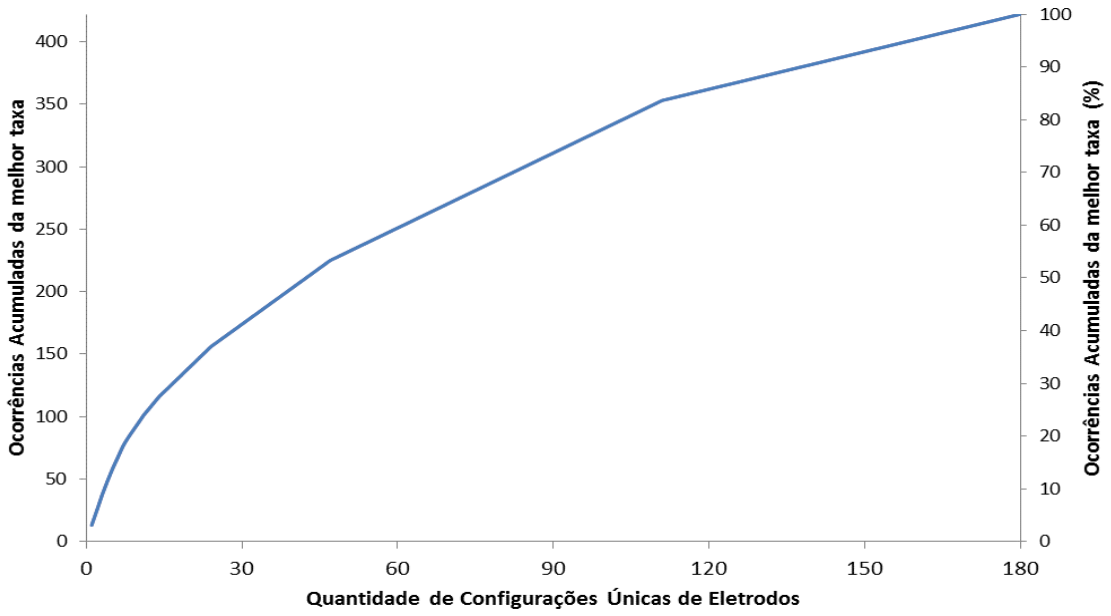

Figura 27 - Ocorrências acumuladas em função da quantidade de configurações de eletrodos que a Seleção Espacial de Características resultou na melhor taxa de classificação

Por exemplo, para que se contabilize 80% dos 422 cenários que levaram à melhor taxa de classificação, é necessário considerar 104 configurações diferentes de eletrodos, ou as 30 configurações de eletrodos com maior quantidade de ocorrências representam 41,2% ou 194 ocorrências acumuladas. A Figura 27 mostra a quantidade de ocorrências que resultaram na melhor taxa de classificação em função da quantidade de configurações de eletrodos distintas.

As Figuras 28, 29 e 30 apresentam, respectivamente, a quantidade de vezes que cada diferença de potencial apareceu na melhor taxa de acerto sob uma visão de fase de movimento, de cenário de classificação e de técnica utilizada, sempre considerando os resultados individuais de cada voluntário.

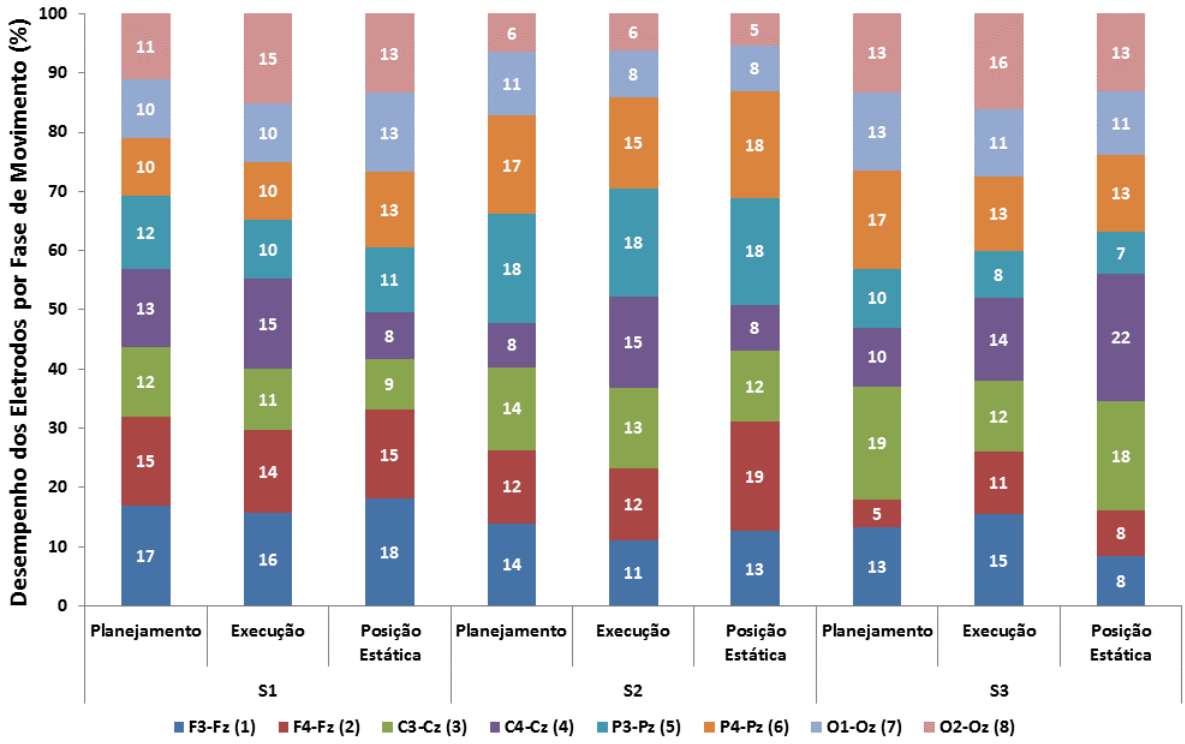

Figura 28 - Ocorrências acumuladas de eletrodos com os quais a Seleção Espacial de Características obteve na melhor taxa de classificação, por voluntário e por fase do movimento, independente da técnica utilizada, do cenário de classificação ou do tamanho do vetor de dados.

Tendo-se como critério considerar as quatro diferenças de potencial que apresentam maior quantidade de ocorrência na melhor taxa de classificação para determinar os eletrodos mais importantes ou relevantes para esse processo, nota-se que, na ótica das fases do movimento, que os eletrodos Frontais, Central direito e Parietal esquerdo são os que mais estiveram presentes na melhor taxa de classificação da fase de planejamento para o indivíduo S1, enquanto que para o S2 isso ocorreu para os eletrodos Parietais, seguidos pelo Frontal e Central esquerdos, e para o S3 foi mais representativos o eletrodo Central esquerdo, seguido pelo Parietal direito, Frontal esquerdo e ambos Occipitais. No caso da fase de execução de movimento, para os indivíduos S1 e S3, os eletrodos mais importantes foram os Frontais esquerdos, seguidos pelo Occipital direito e Central esquerdo, enquanto que para o indivíduo S2 os eletrodos Parietais e Centrais foram os que mais vezes resultaram nas melhores taxas de acerto. A posição estática foi a mais heterogênea, tendo sido os eletrodos mais importantes os

Frontais, seguidos pelos Occipitais, para o indivíduo S1, os Parietais e os Frontais para o S2 e ambos os Centrais, seguidos pelo Occipital e Parietal direitos, para o S3.

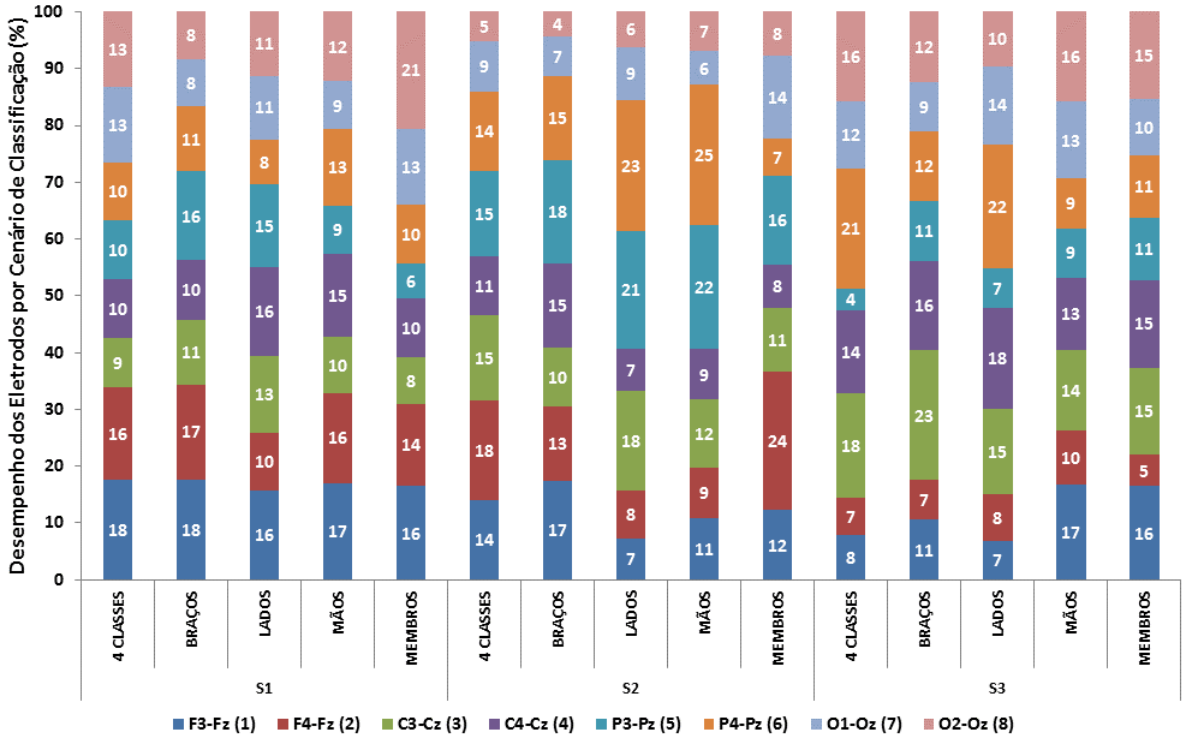

Figura 29 - Ocorrências acumuladas de eletrodos com os quais a Seleção Espacial de Características obteve na melhor taxa de classificação, por voluntário e por cenário de classificação, independente da técnica utilizada, da fase do movimento ou do tamanho do vetor de dados.

Considerando-se os cenários de classificação, para a discriminação em quatro classes, os eletrodos Frontais e Occipitais foram os mais importantes para o indivíduo S1, porém para S2 foram os eletrodos Frontal e Central do lado direito e por ambos os Parietais, e para S3 foram o Parietal direito, seguido pelos Centrais e Occipital esquerdo. Na discriminação entre braços, os eletrodos que mais vezes levaram às melhores taxas de classificação foram os Frontais e os Parietais para o indivíduo S1, enquanto que para S2 os eletrodos mais relevantes foram os Parietal e Frontal esquerdos, seguidos pelos Parietal e Central direitos, e para S3 os mais importantes foram os Centrais, seguidos pelos Occipital e Parietal direitos. No cenário de discriminação entre lados, os eletrodos Centrais, Frontal direito e Occipitais foram os mais importantes para S1, porém para o indivíduo S2 os mais relevantes foram os Parietais e o Central direito e no caso de S3 os mais importantes foram os eletrodos Parietal e Central direitos, seguidos pelos Central e Occipital esquerdos. Analisando-se os resultados relativos ao cenário de classificação entre mãos, os eletrodos mais importantes para o indivíduo S1 foram os Frontais e os Parietais, enquanto que para S2 os Parietais, seguidos pelos Frontal e Parietal esquerdos, foram os mais relevantes e para S3 isso ocorreu para os eletrodos Frontal

esquerdo, Occipital direito, Central esquerdo e Occipital esquerdo. A discriminação entre membros teve como eletrodos mais importantes os Occipitais e Frontais para o indivíduo S1, para S2 os eletrodos mais relevantes foram os Frontais, seguidos pelos Parietal e Occipital esquerdos e para S3 esses eletrodos foram os Centrais, Frontal esquerdo e Occipital direito.

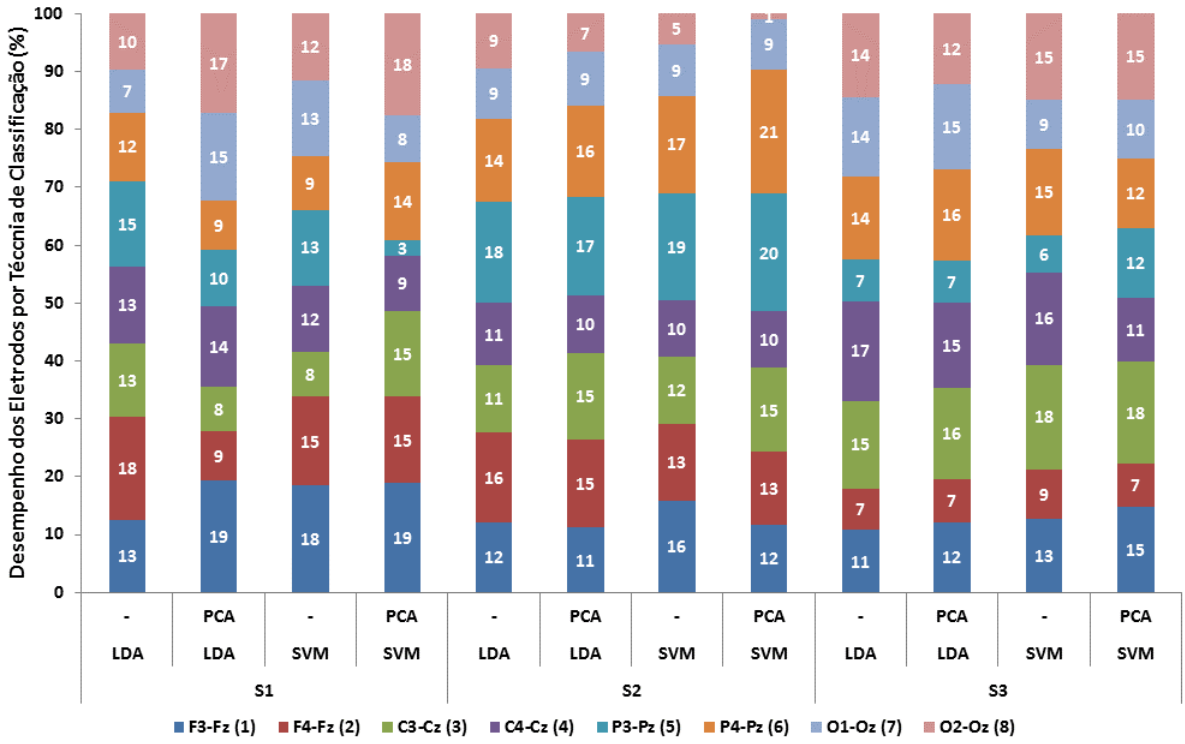

Figura 30 - Ocorrências acumuladas de eletrodos com os quais a Seleção Espacial de Características obteve na melhor taxa de classificação, por voluntário e por técnica de classificação, independente do cenário de classificação, da fase do movimento ou do tamanho do vetor de dados.

Fazendo-se uma avaliação comparativa entre as técnicas de classificação, sem considerar outros fatores, observa-se ampla variação nas configurações de eletrodos mais importantes entre os voluntários. No caso da LDA, os eletrodos mais importantes para o indivíduo S1 foram os Frontais, os Centrais e o Parietal esquerdo, enquanto que para S2 os foram os Parietais e os Frontais e para S3 foram os Centrais e os Occipitais. A aplicação da PCA mudou substancialmente esse cenário, passando a serem os eletrodos mais importantes para S1 os Occipitais, o Frontal esquerdo e o Central direito, para S2 os Parietais, o Frontal esquerdo e o Central direito e no caso de S3 os Centrais, o Parietal direito e o Occipital esquerdo. Já com a SVM, os eletrodos Frontais, Parietal e Occipital esquerdos foram os mais importantes para S1, mas para S2 os mais importantes são os Parietais, o Frontal direito e o Central esquerdo e para S3 os Centrais, o Parietal e o Occipital direitos foram os mais importantes. Com a aplicação da PCA em conjunto com a SVM, os eletrodos mais importantes para S1 foram os Frontais, o Central esquerdo e o Occipital direito, enquanto que

no caso de S2 esses eletrodos foram os Parietais, o Frontal direito e o Central esquerdo e para S3 foram o Occipital direito, o Central e o Frontal esquerdos e os Parietais.

A Figura 31 apresenta a quantidade de ocorrências de cada par de eletrodos na melhor taxa de classificação para cada indivíduo S1, S2 e S3, independentemente da técnica ou fase de movimento considerada. Claramente não se identificou um padrão único entre indivíduos ou entre fases de movimento, podendo-se somente inferir quanto a importância de determinado eletrodo para os experimentos realizados, podendo-se indicar quais pares de eletrodos ocorreram com frequência acima e abaixo da média de 57,1 ocorrências.

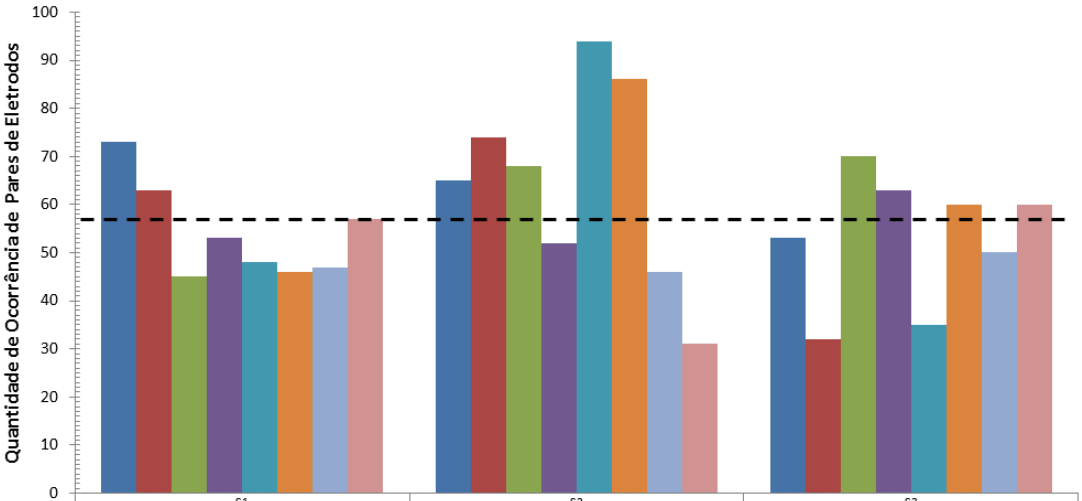

	S1	S2	S3
F3-Fz (1)	73	65	53
F4-Fz (2)	63	74	32
C3-Cz (3)	45	68	70
C4-Cz (4)	53	52	63
P3-Pz (5)	48	94	35
P4-Pz (6)	46	86	60
O1-Oz (7)	47	46	50
O2-Oz (8)	57	31	60

Figura 31 - Quantidade de ocorrências de pares de eletrodos.

O apêndice traz um conjunto de tabelas que representam o mapeamento das regiões cerebrais em função dos resultados da Seleção Espacial de Características. Com base nestas tabelas e somando-se a quantidade de ocorrências de cada par de eletrodos, fase de movimento e cenário e técnica de classificação, considerando-se em cada somatória todos os voluntários e tamanhos de vetores de dados, e arranjando os eletrodos em pares por região cerebral que monitoram, obtém-se uma tendência geral que indica as diferenças de potenciais mais relevantes do sinal do EEG. Tendo-se como critério apontar os dois pares de eletrodos com maior quantidade de ocorrências, ou somente o primeiro, caso os dois próximos sejam numericamente iguais, ou os dois primeiros, caso sejam iguais, obtém-se a Tabela 9.

Tabela 9- Eletrodos e regiões cerebrais mais importantes.

CENÁRIO	TÉCNICA		FASE DO MOVIMENTO		
			Planejamento	Execução	Posição Estática
4 CLASSES	LDA	-	Frontais e Centrais	Centrais	Frontais e Centrais
		PCA	Frontais e Centrais	Frontais	Parietais e Occipitais
	SVM	-	Frontais e Occipitais	Frontais e Parietais	Parietais
		PCA	Centrais e Parietais	Frontais	Centrais e Parietais
BRAÇOS	LDA	-	Centrais e Parietais	Centrais	Frontais e Parietais
		PCA	Centrais	Frontais e Centrais	Centrais e Parietais
	SVM	-	Frontais e Parietais	Frontais e Centrais	Parietais e Occipitais
		PCA	Parietais	Frontais e Parietais	Frontais e Centrais
LADOS	LDA	-	Centrais e Parietais	Centrais e Occipitais	Centrais e Parietais
		PCA	Parietais e Occipitais	Parietais	Centrais e Parietais
	SVM	-	Centrais e Parietais	Centrais	Frontais e Parietais
		PCA	Centrais e Parietais	Centrais	Centrais e Parietais
MÃOS	LDA	-	Centrais e Occipitais	Centrais e Parietais	Frontais e Parietais
		PCA	Centrais e Parietais	Parietais e Occipitais	Centrais e Parietais
	SVM	-	Frontais e Parietais	Centrais e Parietais	Frontais e Centrais
		PCA	Parietais e Occipitais	Frontais e Occipitais	Centrais e Parietais
MEMBROS	LDA	-	Frontais e Centrais	Centrais e Occipitais	Frontais e Occipitais
		PCA	Frontais e Occipitais	Frontais e Parietais	Centrais e Occipitais
	SVM	-	Frontais e Occipitais	Frontais e Centrais	Frontais e Occipitais
		PCA	Occipitais	Frontais e Parietais	Frontais e Centrais

A partir dessa análise, observa-se que os pares de eletrodos Centrais e Parietais, conjuntamente, ocorrem com maior frequência nas melhores taxas de acerto para a fase de planejamento do movimento, seguidos pelos pares de eletrodos Frontais e Centrais e pelos pares Frontais e Occipitais. Os eletrodos Occipitais, entretanto, nunca ocorrem de forma independente para essa fase. Esses resultados indicam haver uma predominância do sinal de EEG nas regiões motora, de memória associativa espacial e na cognitiva quando se utiliza os dados da fase de planejamento, porém pouca influência da região sensorial visual.

Considerando-se os dados da execução do movimento, a concentração de ocorrências migra para os pares de eletrodos Frontais e Parietais, considerados conjuntamente, e para os pares de eletrodos Centrais, em igual teor, seguidos pelos pares Frontais e Centrais, considerados conjuntamente. Os eletrodos Occipitais nunca ocorrem de forma independente para essa fase.

Os pares de eletrodos Centrais e Parietais, considerados conjuntamente, mais a distância seguidos pelos Frontais e Centrais e pelos Frontais e Parietais, também considerados conjuntamente, são as configurações predominantes durante a posição estática para as melhores taxas de acerto. Entretanto, os eletrodos Frontais, Centrais e Occipitais nunca ocorrem de forma independente nessa situação. Esses resultados apontam para uma influência predominante das regiões motora e cognitiva com alguma atividade da área de memória associativa espacial.

Embora a Seleção Espacial de Características não tenha possibilitado a identificação de uma configuração comum de eletrodos que resultasse na melhor taxa de acerto para cada indivíduo e fase de movimento, essa técnica foi fundamental para melhorar substancialmente essas taxas, conforme mostra a Figura 32. Esse gráfico mostra a variação percentual entre a taxa de acerto média dos três voluntários, obtida com todos os eletrodos presentes, e a melhor taxa obtida pela Seleção Espacial de Característica dentre os três indivíduos, apresentando os valores médios dos três indivíduos, máximos e o desvio padrão sobre a média em uma linha vertical. Adicionalmente, é apresentado o incremento médio entre todas as situações consideradas, cujo valor é 26%.

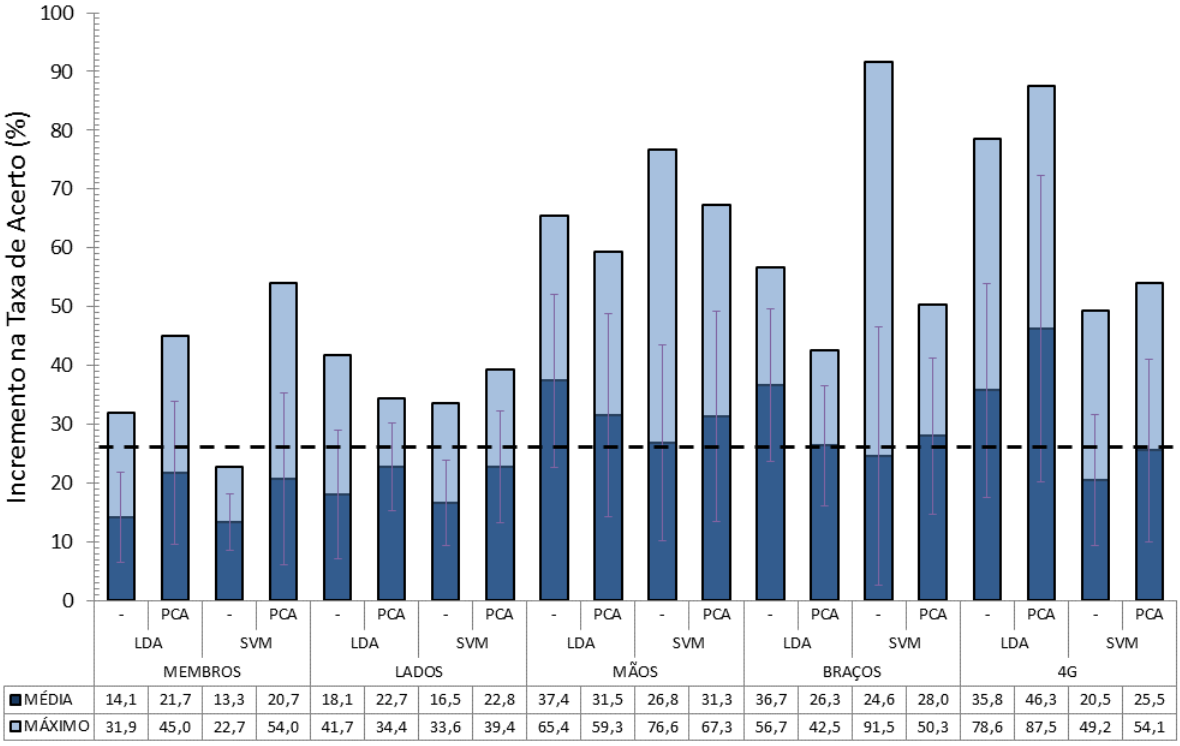

	MEMBROS				LADOS				MÃOS				BRAÇOS				4G			
	LDA		SVM		LDA		SVM		LDA		SVM		LDA		SVM		LDA		SVM	
	-	PCA	-	PCA	-	PCA	-	PCA	-	PCA	-	PCA	-	PCA	-	PCA	-	PCA	-	PCA
MÉDIA	14,1	21,7	13,3	20,7	18,1	22,7	16,5	22,8	37,4	31,5	26,8	31,3	36,7	26,3	24,6	28,0	35,8	46,3	20,5	25,5
MÁXIMO	31,9	45,0	22,7	54,0	41,7	34,4	33,6	39,4	65,4	59,3	76,6	67,3	56,7	42,5	91,5	50,3	78,6	87,5	49,2	54,1

Figura 32 - Incremento na taxa de acerto individual entre a configuração com todos os eletrodos e a configuração que produziu a melhor taxa de acerto.

5.2 Influência do espectro na discriminação

Nesse item é apresentada a influência da variação do espectro considerado nas taxas de acerto obtidas nos diversos cenários de classificação. Os resultados apresentados neste item não distinguem entre vetores de dados de 1 ou 2 s e entre fases de movimento, tendo enfoque em prover uma visão do desempenho de classificação em função da frequência máxima do sinal considerada.

As medições foram realizadas a partir da taxa de classificação média de cada voluntário, provida pela técnica Leave One Out, para os diversos cenários de classificação avaliados pela presente pesquisa, apresentando para estes o resultado médio e máximo das 255 configurações de eletrodos produzidas pela Seleção Espacial de Características, para cada técnica de classificação. Os resultados representam a variação percentual da taxa de classificação média, para cada frequência máxima considerada, em relação à taxa de classificação média obtida com a frequência inicial de 40 Hz, sendo que estas foram segmentadas nas faixas apresentadas no item 4.3.

A Figura 33 traz uma visão dos resultados para o cenário de classificação em quatro classes. Observa-se que, com exceção do classificador SVM, para todas as técnicas houve aumento nas taxas de classificação na medida em que se incrementou a frequência máxima.

Na Figura 34 são apresentados os resultados obtidos para a classificação entre lados e pode-se observar que sempre houve uma melhoria discreta na taxa de classificação média para todos os classificadores. Nas taxas máximas também ocorreram casos de incremento, porém também houve ocasiões de redução.

Os resultados obtidos com a discriminação entre membros estão apresentados na Figura 35 e observa-se que houve melhoria nas taxas de acerto média para todos os classificadores utilizados e que isso só não foi verdade para a taxa máxima obtida com o classificador SVM.

Sempre houve incremento, embora discreto, nas taxas de classificação média na discriminação entre mãos, conforme mostra a Figura 36. Entretanto, nas taxas de classificação máxima ocorreram reduções com diversas técnicas de classificação, com exceção da LDA.

A Figura 37 mostra que para a discriminação entre braços o incremento da frequência máxima sempre trouxe melhorias nas taxas de classificação média e máxima com os diversos classificadores utilizados.

Em função dos resultados observados neste item, todos os demais experimentos foram realizados utilizando 80 Hz como frequência máxima do sinal.

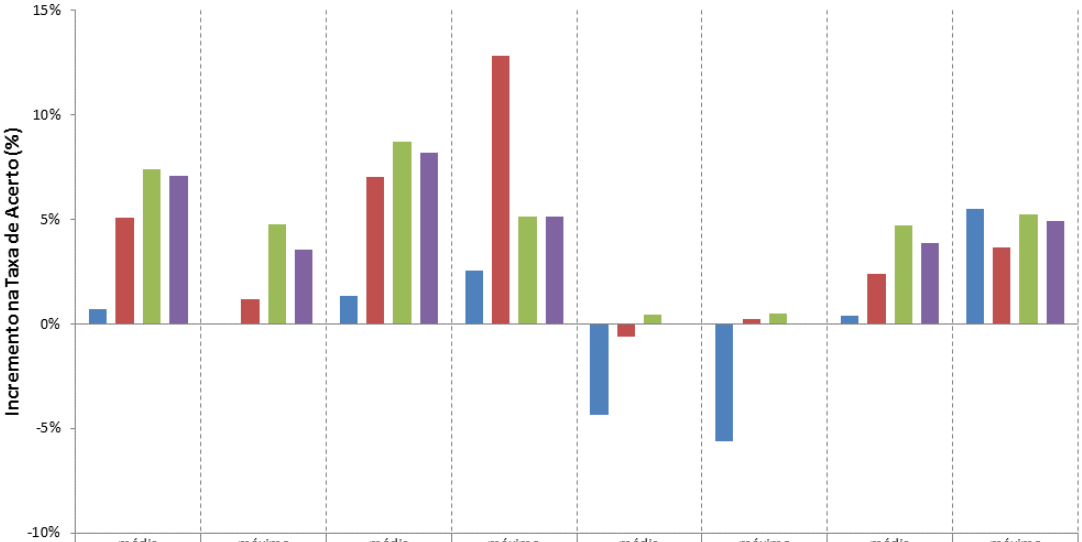

	média	máximo	média	máximo	média	máximo	média	máximo
	LDA		LDA + PCA		SVM		SVM+PCA	
50 Hz	1%	0%	1%	3%	-4%	-6%	0%	6%
60 Hz	5%	1%	7%	13%	-1%	0%	2%	4%
70 Hz	7%	5%	9%	5%	0%	1%	5%	5%
80 Hz	7%	4%	8%	5%	0%	0%	4%	5%

Figura 33 - Variação entre as taxas de classificação média e máxima na discriminação em quatro classes em função da variação da frequência máxima do sinal considerada.

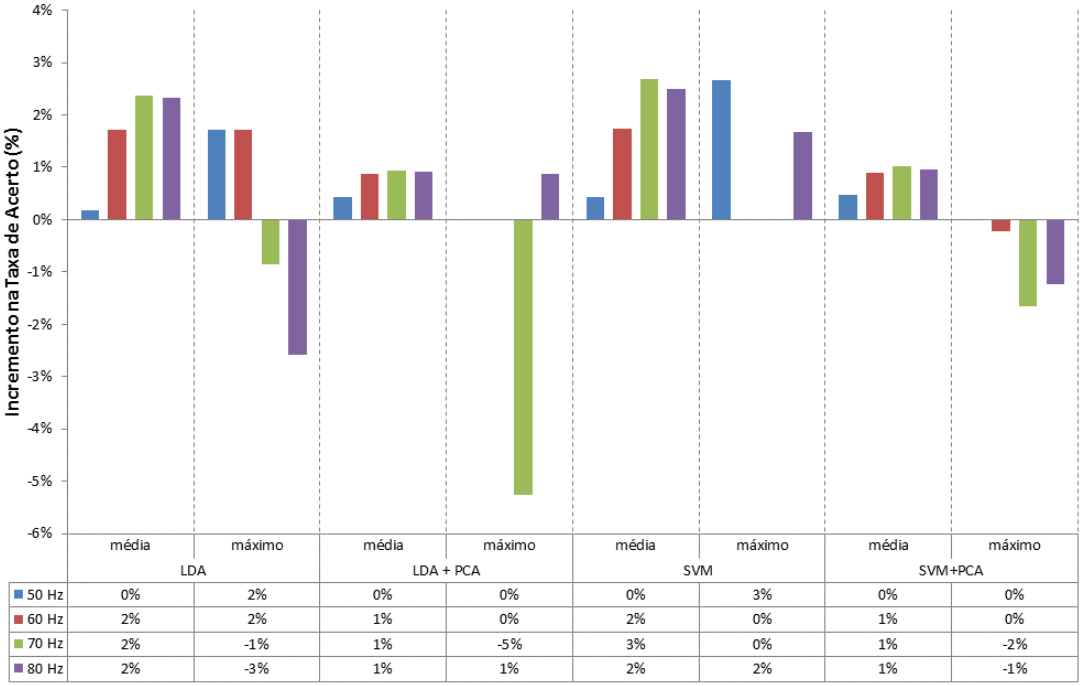

	média	máximo	média	máximo	média	máximo	média	máximo
	LDA		LDA + PCA		SVM		SVM+PCA	
50 Hz	0%	2%	0%	0%	0%	3%	0%	0%
60 Hz	2%	2%	1%	0%	2%	0%	1%	0%
70 Hz	2%	-1%	1%	-5%	3%	0%	1%	-2%
80 Hz	2%	-3%	1%	1%	2%	2%	1%	-1%

Figura 34 - Variação entre as taxas de classificação média e máxima na discriminação entre lados em função da variação da frequência máxima do sinal considerada.

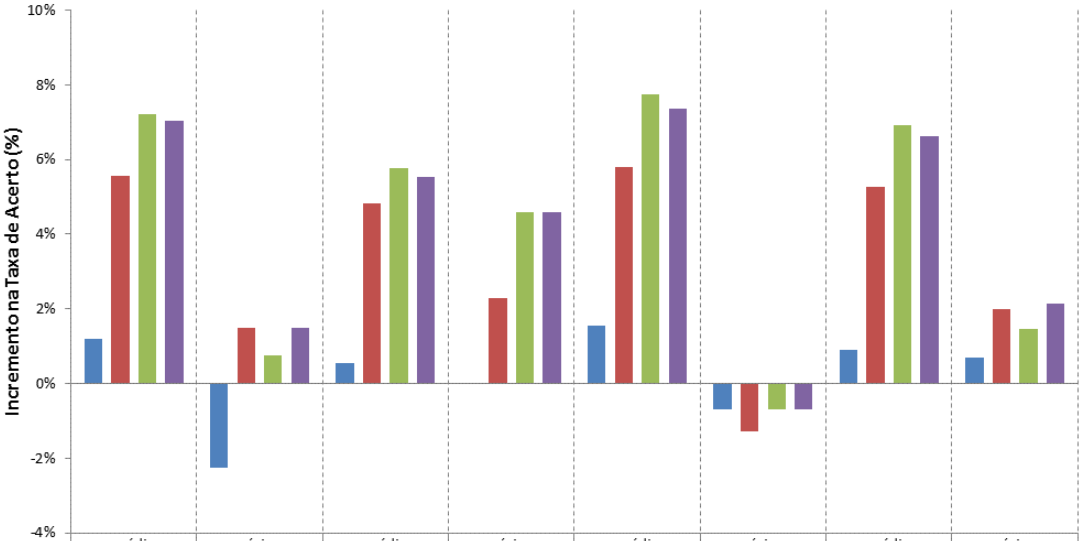

	média	máximo	média	máximo	média	máximo	média	máximo
	LDA		LDA + PCA		SVM		SVM+PCA	
50 Hz	1%	-2%	1%	0%	2%	-1%	1%	1%
60 Hz	6%	2%	5%	2%	6%	-1%	5%	2%
70 Hz	7%	1%	6%	5%	8%	-1%	7%	1%
80 Hz	7%	2%	6%	5%	7%	-1%	7%	2%

Figura 35 - Variação entre as taxas de classificação média e máxima na discriminação entre membros em função da variação da frequência máxima do sinal considerada.

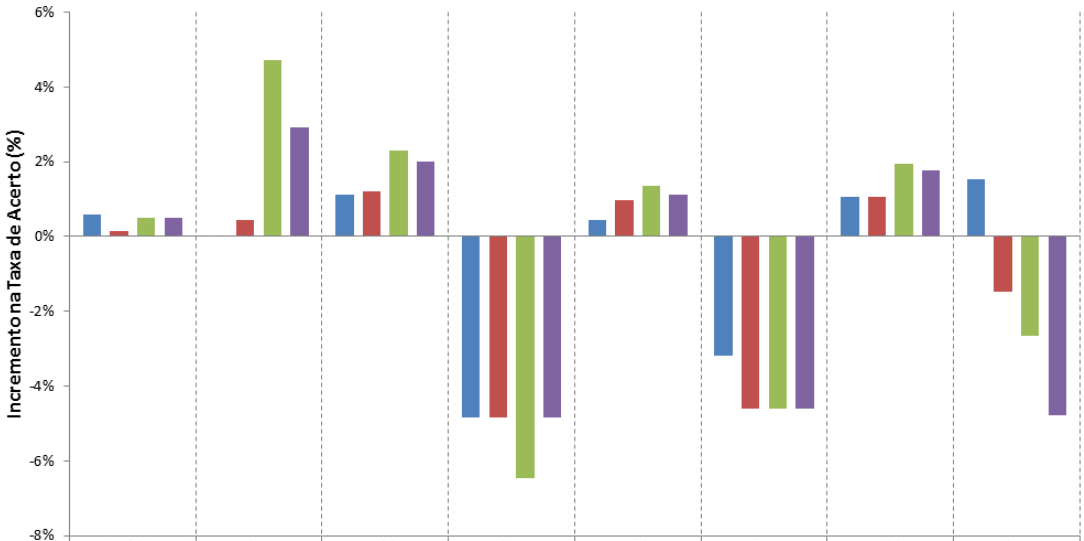

	média	máximo	média	máximo	média	máximo	média	máximo
	LDA		LDA + PCA		SVM		SVM+PCA	
50 Hz	1%	0%	1%	-5%	0%	-3%	1%	2%
60 Hz	0%	0%	1%	-5%	1%	-5%	1%	-1%
70 Hz	1%	5%	2%	-6%	1%	-5%	2%	-3%
80 Hz	0%	3%	2%	-5%	1%	-5%	2%	-5%

Figura 36 - Variação entre as taxas de classificação média e máxima na discriminação entre mãos em função da variação da frequência máxima do sinal considerada.

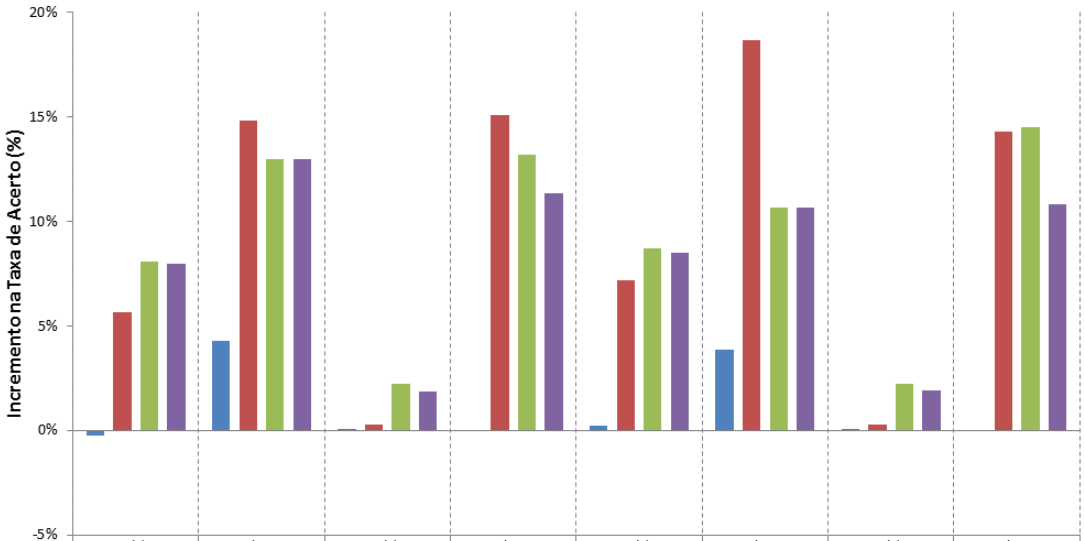

	média	máximo	média	máximo	média	máximo	média	máximo
	LDA		LDA + PCA		SVM		SVM+PCA	
50 Hz	0%	4%	0%	0%	0%	4%	0%	0%
60 Hz	6%	15%	0%	15%	7%	19%	0%	14%
70 Hz	8%	13%	2%	13%	9%	11%	2%	14%
80 Hz	8%	13%	2%	11%	8%	11%	2%	11%

Figura 37 - Variação entre as taxas de classificação média e máxima na discriminação entre braços em função da variação da frequência máxima do sinal considerada.

5.3 Discriminação entre lados e membros – 4 classes

Este item apresenta as taxas de classificação obtidas na discriminação entre mão direita, mão esquerda, braço direito e braço esquerdo. A Seleção Espacial de Características foi empregada para determinar a influência de cada um dos possíveis conjuntos de eletrodos na taxa de classificação, para cada fase de movimento e para cada indivíduo (S1, S2, S3), bem como para determinar as taxas máximas e mínimas. A seguir, encontram-se os resultados para cada uma das técnicas utilizadas.

5.3.1 LDA

A Figura 38 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

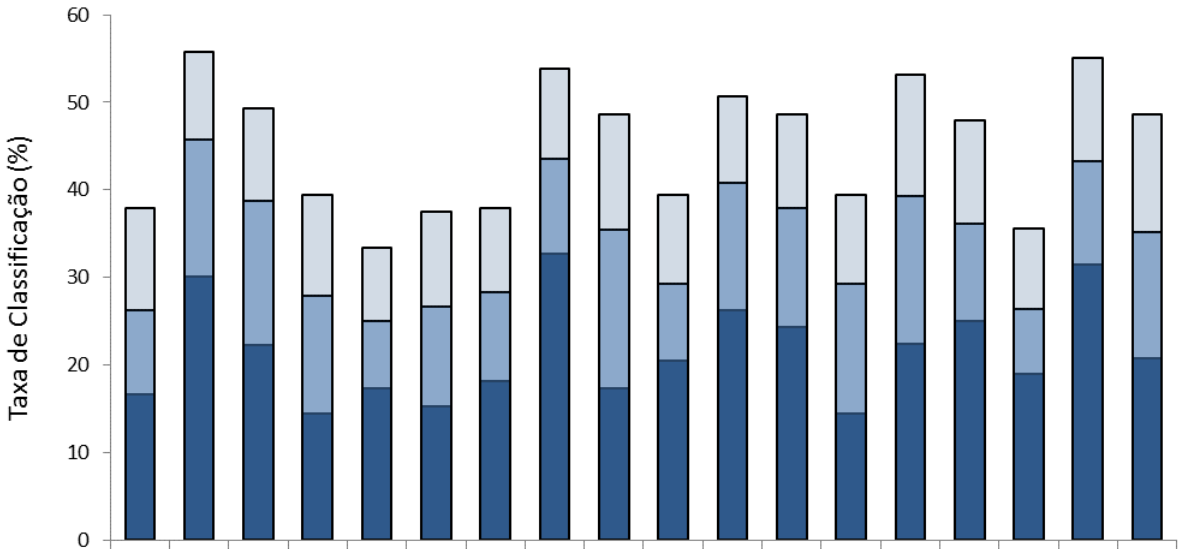

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
	Planejamento			Movimento			Posição Estática			Planejamento			Movimento			Posição Estática		
	Duração 1s									Duração 2s								
Mínima	16,7	30,1	22,2	14,4	17,3	15,3	18,2	32,7	17,4	20,5	26,3	24,3	14,4	22,4	25,0	18,9	31,4	20,8
Média	26,2	45,7	38,7	27,9	25,0	26,7	28,2	43,5	35,4	29,3	40,8	37,9	29,3	39,2	36,1	26,3	43,3	35,1
Máximo	37,9	55,8	49,3	39,4	33,3	37,5	37,9	53,8	48,6	39,4	50,6	48,6	39,4	53,2	47,9	35,6	55,1	48,6

Figura 38 - Taxas de classificação individual média utilizando LDA para discriminar entre quatro classes.

Analogamente ao apresentado acima, na Figura 39 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 55,8% e 36,9%, respectivamente, sendo que ambas ocorreram para a fase de planejamento e com vetor de dados de 1 s. O pior resultado foi 14,4%, abaixo do mínimo ao acaso, e ocorreu para a execução do movimento e com vetor de dados de 1 s e de 2 s. O indivíduo que obteve a melhor taxa de acerto foi S2 e a pior foi S1.

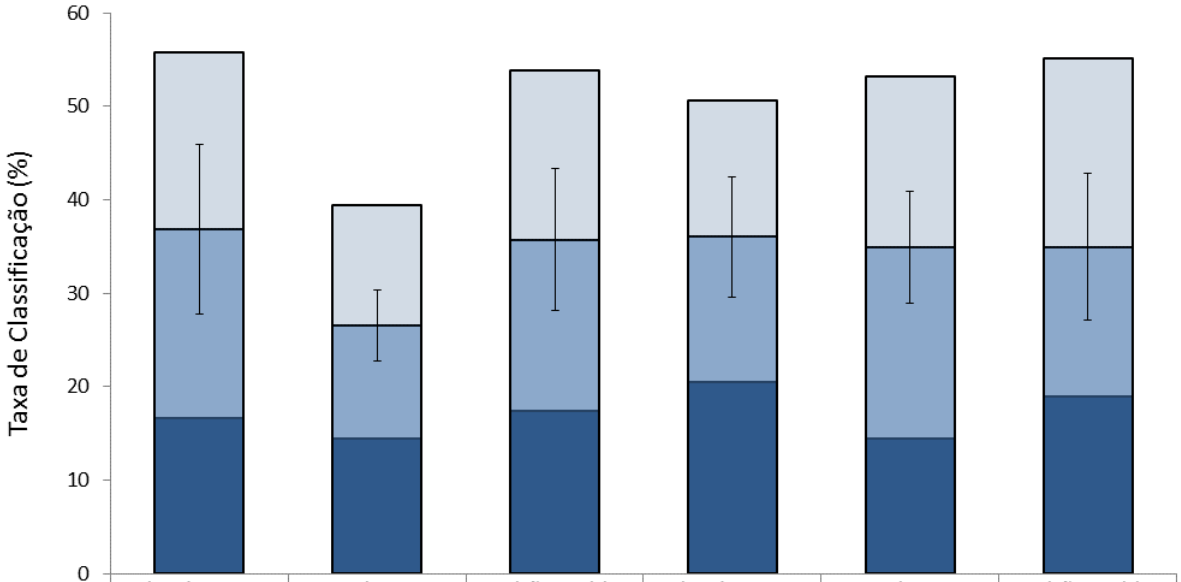

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	16,7	14,4	17,4	20,5	14,4	18,9
Média	36,9	26,5	35,7	36,0	34,9	34,9
Máximo	55,8	39,4	53,8	50,6	53,2	55,1

Figura 39 - Taxas de classificação média entre os três voluntários utilizando LDA para discriminar entre quatro classes.

5.3.2 LDA com PCA

A Figura 40 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

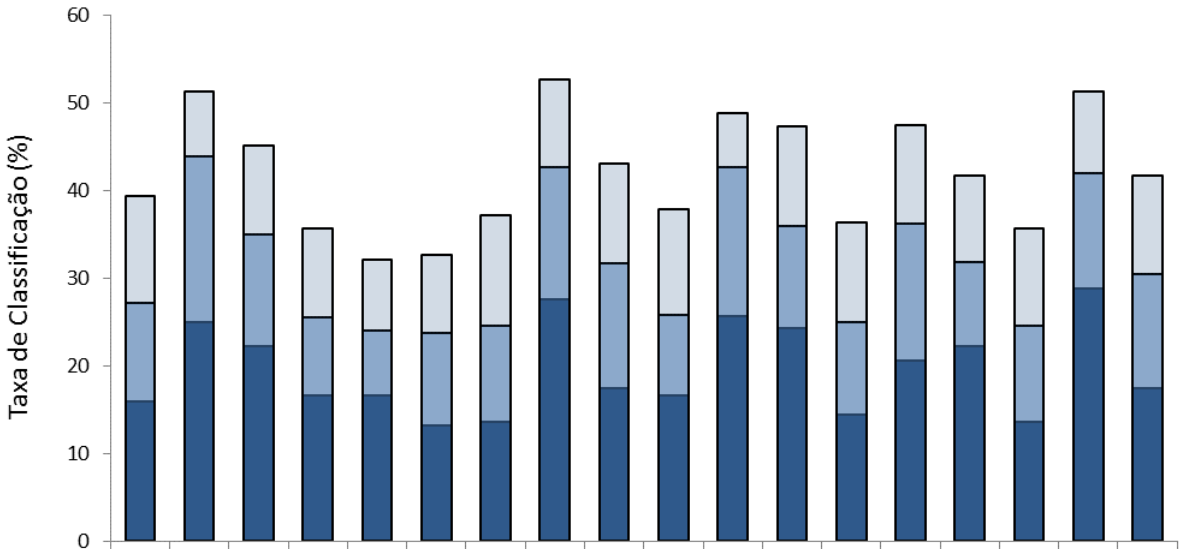

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
	Planejamento			Movimento			Posição Estática			Planejamento			Movimento			Posição Estática					
	Duração 1s									Duração 2s											
Mínima	15,9	25,0	22,2	16,7	16,7	13,2	13,6	27,6	17,4	16,7	25,6	24,3	14,4	20,5	22,2	13,6	28,8	17,4			
Média	27,2	43,8	34,9	25,5	24,0	23,7	24,5	42,6	31,6	25,7	42,6	35,9	25,0	36,2	31,8	24,5	41,9	30,4			
Máximo	39,4	51,3	45,1	35,6	32,1	32,6	37,1	52,6	43,1	37,9	48,7	47,2	36,4	47,4	41,7	35,6	51,3	41,7			

Figura 40 - Taxas de classificação individual média utilizando LDA com PCA para discriminar entre quatro classes.

Analogamente ao apresentado acima, na Figura 41 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 51,3% e 35,3%, respectivamente, sendo que a primeira ocorreu para a fase de planejamento e para a posição estática, respectivamente com vetor de dados de 1 s e de 2 s, e a segunda para a fase de planejamento com vetor de dados de 1 s. O pior resultado foi 13,2%, abaixo do mínimo ao acaso, e ocorreu para a execução do movimento e com vetor de dados de 1 s. O indivíduo que obteve a melhor de taxa acerto foi S2, em dois experimentos distintos, e a pior foi S3.

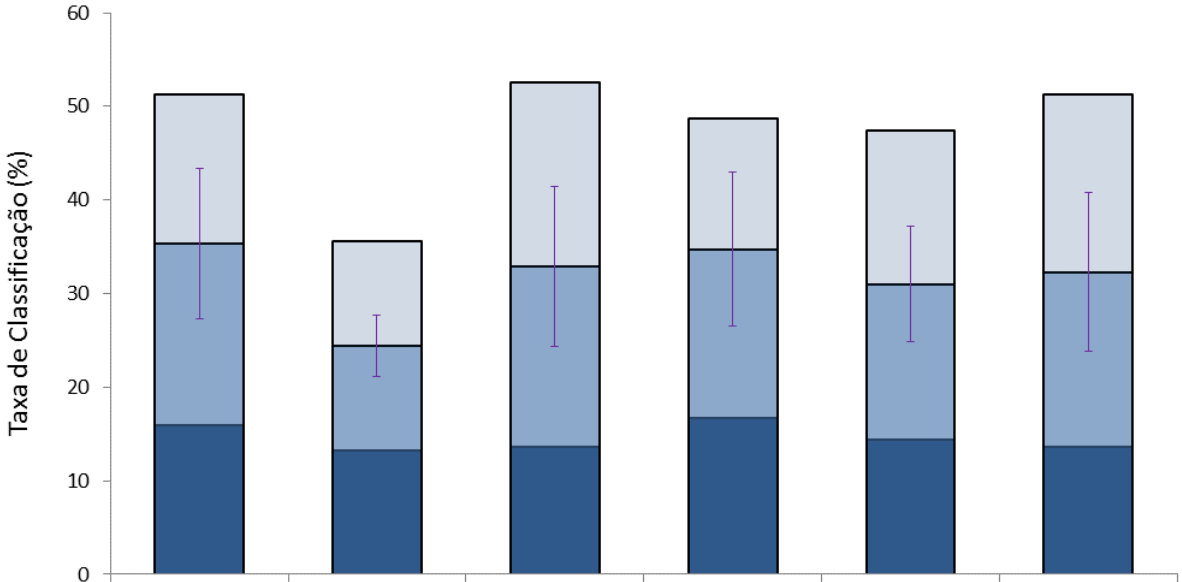

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	15,9	13,2	13,6	16,7	14,4	13,6
Média	35,3	24,4	32,9	34,7	31,0	32,3
Máximo	51,3	35,6	52,6	48,7	47,4	51,3

Figura 41 - Taxas de classificação média entre os três voluntários utilizando LDA com PCA para discriminar entre quatro classes.

5.3.3 SVM

A Figura 42 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

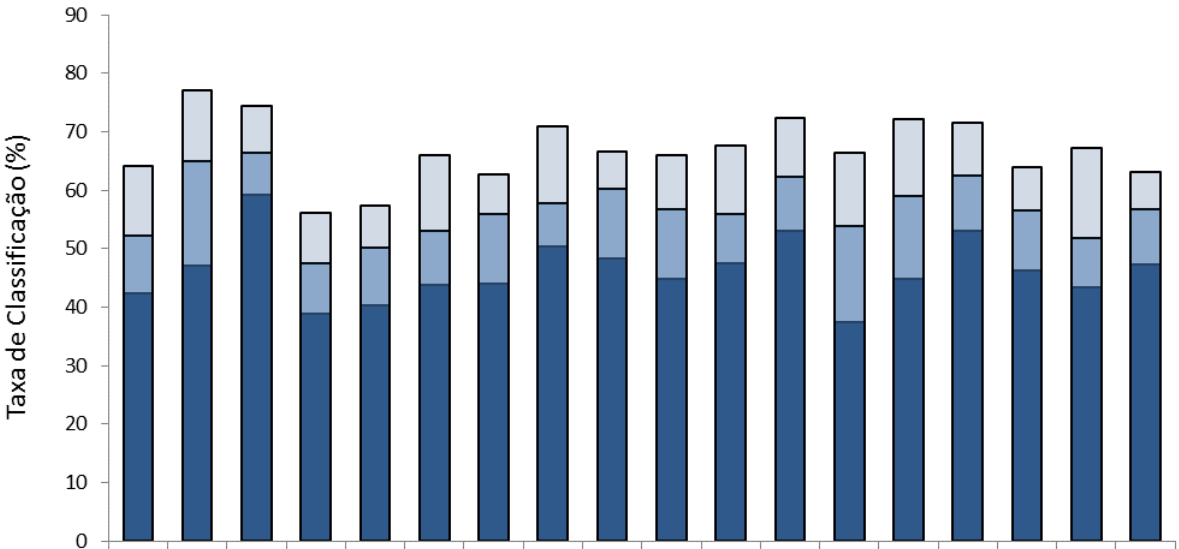

	Duração 1s									Duração 2s								
	Planejamento			Movimento			Posição Estática			Planejamento			Movimento			Posição Estática		
	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
Mínima	42,3	47,2	59,3	38,8	40,3	43,8	44,0	50,3	48,4	44,8	47,5	53,0	37,4	44,9	52,9	46,2	43,4	47,3
Média	52,2	65,0	66,3	47,5	50,2	53,1	55,9	57,7	60,2	56,7	55,9	62,3	53,9	59,0	62,5	56,6	51,9	56,8
Máximo	64,2	77,0	74,5	56,1	57,4	65,9	62,7	70,8	66,6	65,9	67,6	72,4	66,5	72,2	71,5	64,0	67,2	63,1

Figura 42 - Taxas de classificação individual média utilizando SVM para discriminar entre quatro classes.

Analogamente ao apresentado acima, na Figura 43 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 77,0% e 61,2%, respectivamente, sendo que ambas ocorreram para a fase de planejamento e com vetor de dados de 1 s. O pior resultado foi 37,4%, acima do mínimo ao acaso, e ocorreu para a execução do movimento e com vetor de dados de 2 s. O indivíduo que obteve a melhor taxa de acerto foi S2 e a pior foi S1. É importante ressaltar que de todos os resultados de experimentos previamente apresentados até então, este experimento foi o único que não obteve nenhuma taxa de acerto abaixo do mínimo ao acaso.

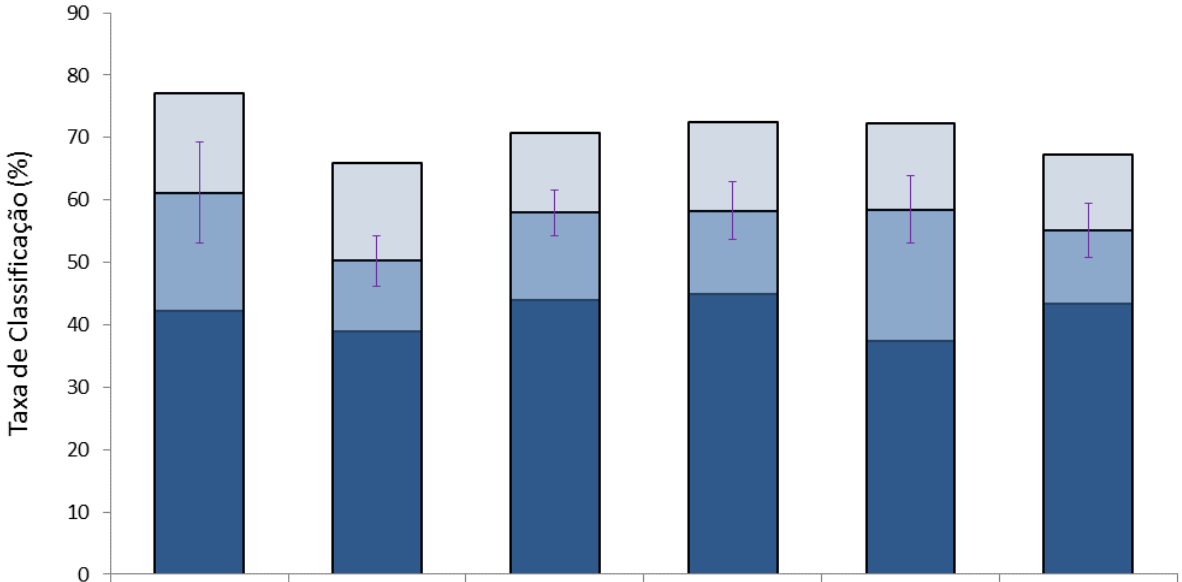

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	42,3	38,8	44,0	44,8	37,4	43,4
Média	61,2	50,2	57,9	58,3	58,5	55,1
Máximo	77,0	65,9	70,8	72,4	72,2	67,2

Figura 43 - Taxas de classificação média entre os três voluntários utilizando SVM para discriminar entre quatro classes.

5.3.4 SVM com PCA

A Figura 44 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

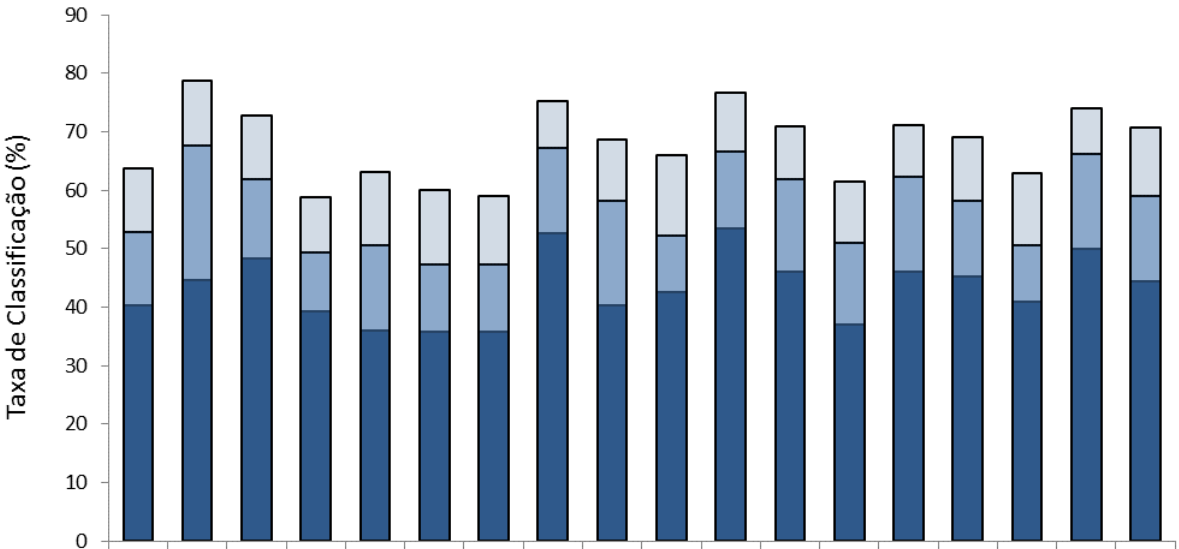

	Duração 1s									Duração 2s								
	Planejamento			Movimento			Posição Estática			Planejamento			Movimento			Posição Estática		
	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
Mínima	40,4	44,6	48,2	39,2	36,1	35,9	35,8	52,7	40,2	42,6	53,5	46,0	37,1	46,1	45,3	41,0	50,0	44,4
Média	52,9	67,5	61,9	49,3	50,6	47,3	47,2	67,2	58,2	52,2	66,6	61,8	50,9	62,3	58,2	50,6	66,2	59,0
Máximo	63,7	78,8	72,7	58,8	63,1	60,0	59,0	75,2	68,7	65,9	76,8	70,8	61,4	71,0	69,1	62,9	73,9	70,8

Figura 44 - Taxas de classificação individual média utilizando SVM com PCA para discriminar entre quatro classes.

Analogamente ao apresentado acima, na Figura 45 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 78,8% e 60,8%, respectivamente, sendo que ambas ocorreram para a fase de planejamento, e ambas com vetor de dados de 1 s. O pior resultado foi 35,8%, e ocorreu para a execução do movimento e com vetor de dados de 1 s. O indivíduo que obteve a melhor taxa de acerto foi S2 e a pior foi S3. Novamente, este experimento obteve taxa de acerto mínima acima do mínimo ao acaso, fazendo do SVM a única técnica a obter esse resultado na presente pesquisa.

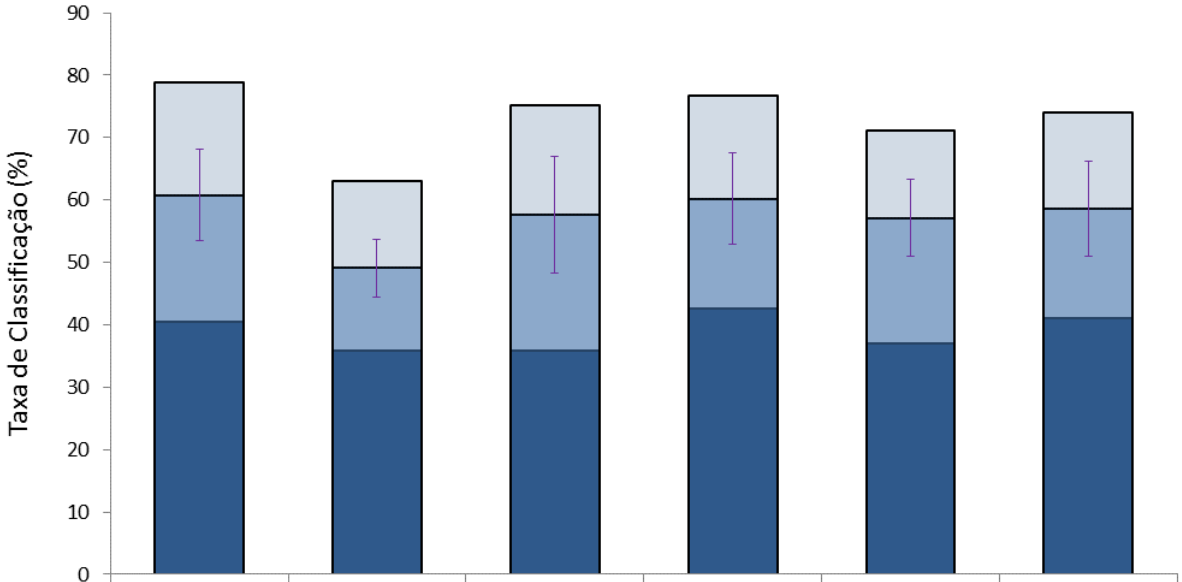

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	40,4	35,9	35,8	42,6	37,1	41,0
Média	60,8	49,1	57,5	60,2	57,1	58,6
Máximo	78,8	63,1	75,2	76,8	71,0	73,9

Figura 45 - Taxas de classificação média entre os três voluntários utilizando SVM com PCA para discriminar entre quatro classes.

5.4 Desempenho das fases do movimento

Esse item apresenta o desempenho obtido por cada fase de movimento, tendo-se em mente que, nesta pesquisa, conceitua-se desempenho como a parcela dos experimentos em que determinada fase do movimento obteve a melhor taxa de classificação em relação a quantidade total de experimentos considerados na comparação.

A Figura 46 traz uma visão geral do desempenho das fases de movimento, mostrando, percentualmente, quantas vezes em relação ao total de experimentos cada fase do movimento resultou na melhor taxa de classificação, considerando-se somente os melhores resultados obtidos em função da Seleção Espacial de Característica para cada técnica de classificação.

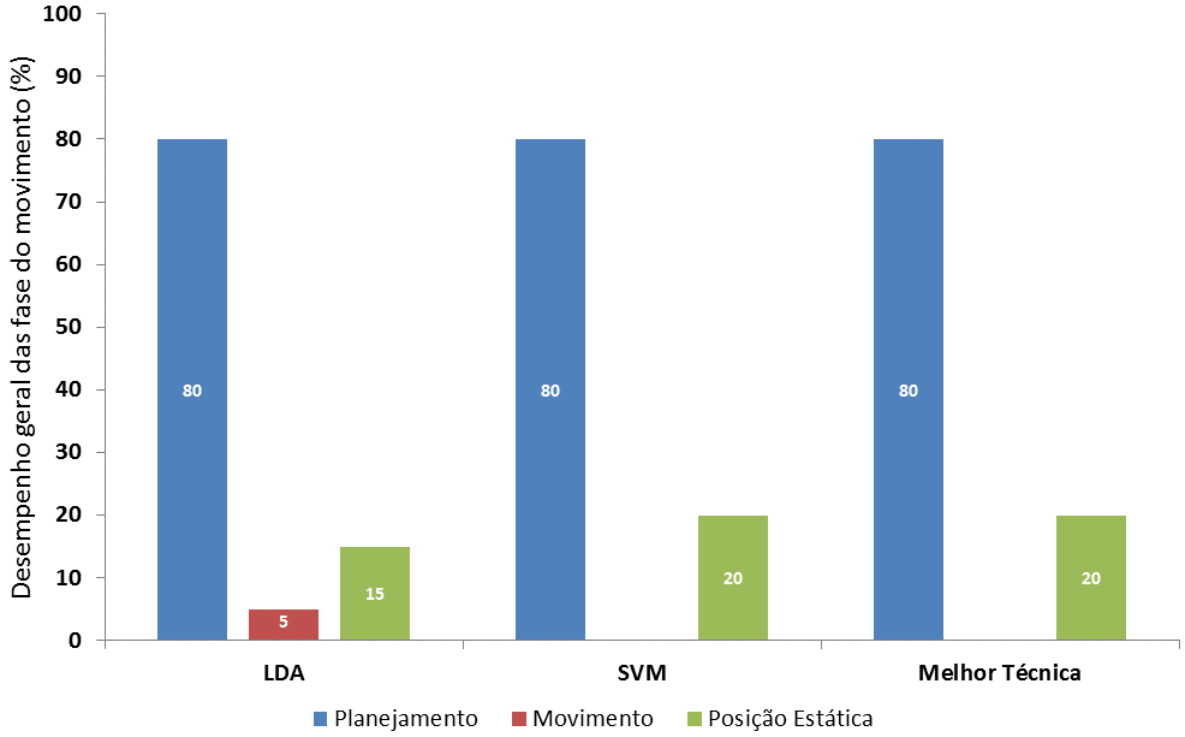

Figura 46 – Visão geral do desempenho de classificação das fases do movimento em função da técnica utilizada.

Pode-se observar que a fase planejamento foi a que propiciou o melhor resultado na maioria dos casos, em 80% das vezes, seguida pela posição estática com 20%, considerando-se a melhor taxa de classificação dentre as técnicas utilizadas. No caso da LDA, a execução do movimento aparece com 5% enquanto que a fase de planejamento e a posição estática obtiveram 80% e 15%, respectivamente. Já a SVM obteve exatamente o mesmo resultado que o melhor dentre as técnicas utilizadas, pois esta também foi a técnica de melhor desempenho.

A Figura 47 detalha os resultados apresentados acima, mostrando o desempenho das fases de movimento para cada técnica de discriminação e cenário de classificação considerada pela presente pesquisa. Foram realizados 4590 experimentos para cada uma das 4 técnicas e para cada um dos 5 cenários de classificação, tendo sido considerados os resultados individuais e todas as combinações de eletrodos proporcionadas pela Seleção Espacial de Características (3 indivíduos x 3 fases de movimento x 2 tamanhos de vetores x 255 diferentes combinações de eletrodos). Observa-se que a fase de planejamento é a que mais vezes propiciou a melhor taxa de classificação, seguida pela posição estática e pela execução do movimento, em todos os casos.

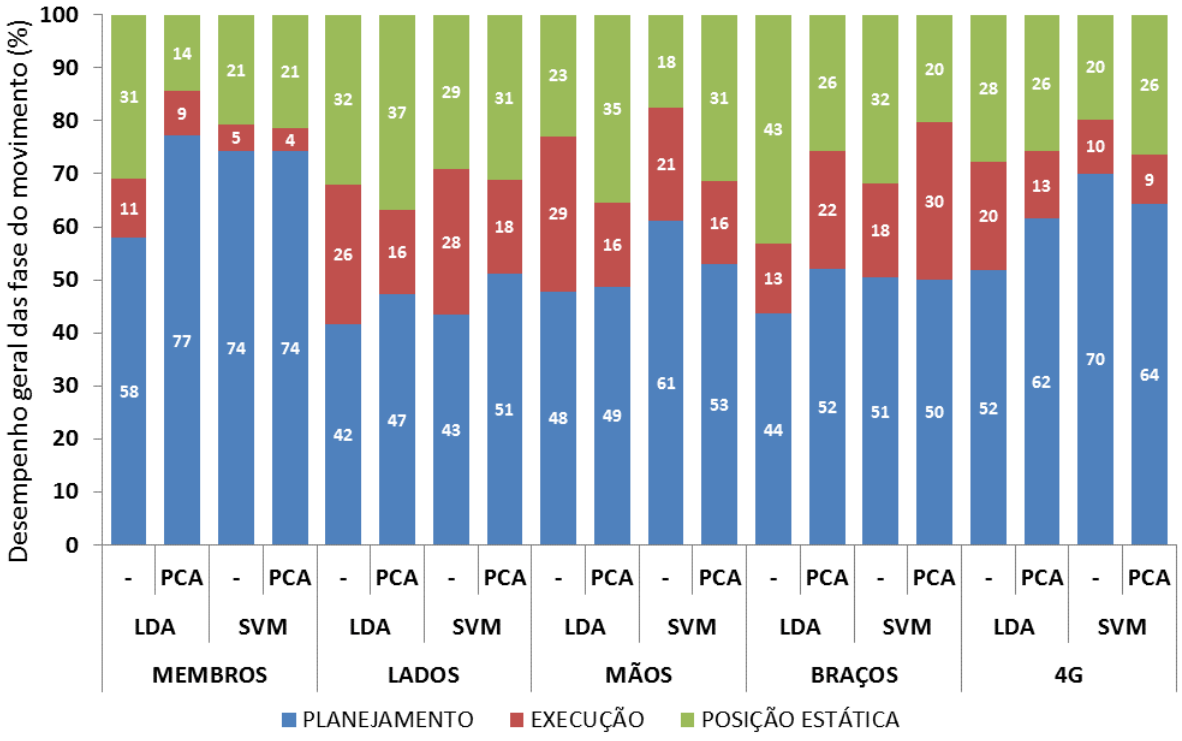

Figura 47 - Desempenho de classificação de cada fase do movimento para cada técnica e cenário de classificação considerada.

5.5 Comparativo entre técnicas

A Figura 48 apresenta as melhores taxas de classificação médias entre os três indivíduos e as melhores taxas individuais para todas as técnicas consideradas pela presente pesquisa e, logo a seguir, a Figura 49 mostra a influência do uso da técnica de PCA nos diferentes cenários de classificação. Cabe ressaltar que a média entre os indivíduos foi calculada sobre a taxa média resultante da aplicação cumulativa das técnicas de "Leave One Out" e de Seleção Espacial de Característica.

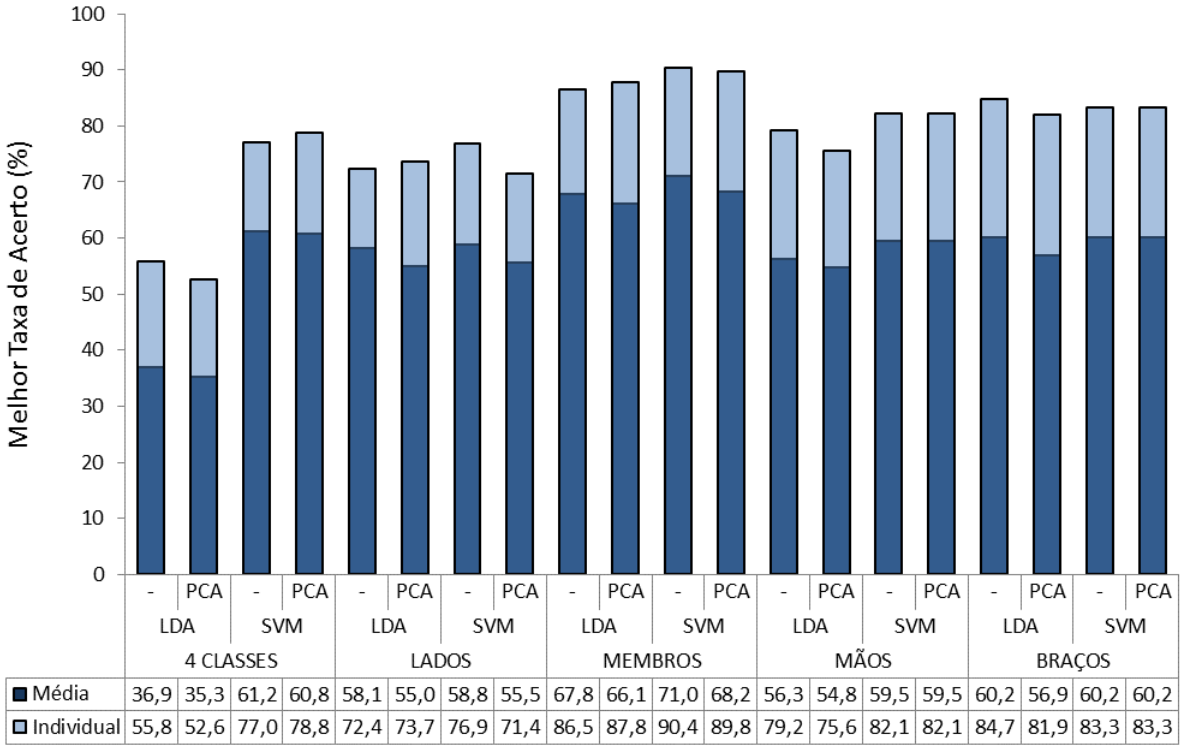

	-	PCA	-	PCA	-	PCA	-	PCA	-	PCA	-	PCA	-	PCA	-	PCA	-	PCA	-	PCA
	LDA		SVM		LDA		SVM		LDA		SVM		LDA		SVM		LDA		SVM	
	4 CLASSES				LADOS				MEMBROS				MÃOS				BRAÇOS			
Média	36,9	35,3	61,2	60,8	58,1	55,0	58,8	55,5	67,8	66,1	71,0	68,2	56,3	54,8	59,5	59,5	60,2	56,9	60,2	60,2
Individual	55,8	52,6	77,0	78,8	72,4	73,7	76,9	71,4	86,5	87,8	90,4	89,8	79,2	75,6	82,1	82,1	84,7	81,9	83,3	83,3

Figura 48 - Melhor taxa de certo individual e média para todos os cenários de classificação.

Para discriminação em 4 classes, a melhor taxa média entre os três indivíduos foi de 61,2%, obtida com SVM, e a melhor taxa individual foi de 78,8%, obtida com a SVM e PCA. As diferenças de potencial representadas pelos eletrodos F3-Fz, C4-Cz, P3-Pz e O1-Oz foram as consideradas na obtenção da melhor taxa individual.

A discriminação entre lados obteve 58,8% como melhor taxa média entre os três indivíduos e 76,9% na melhor taxa individual, ambas com SVM, enquanto que a discriminação entre membros chegou a 71,0% na melhor taxa média e 90,4% na melhor taxa individual também utilizando SVM. Estavam presentes os eletrodos F3-Fz, F4-Fz, C3-Cz, P3-Pz, P4-Pz e O2-Oz na obtenção da melhor taxa individual de classificação entre lados e entre membros só não estiveram presentes os eletrodos C4-Cz e O2-Oz nessa situação.

A melhor taxa média entre os três indivíduos e a melhor taxa individual foi de 59,5% e 82,1%, respectivamente, na discriminação entre mãos, utilizando a técnica SVM, independentemente da aplicação da PCA, tendo ocorrido com todos os pares de eletrodos exceto C3-Cz e O2-Oz no caso da melhor taxa individual. No caso da discriminação entre braços essas taxas foram de 84,7% e 60,2%, tendo o primeiro caso sido obtido com a LDA e tendo ocorrido uma coincidência numérica para o segundo entre as técnicas LDA, SVM e SVM com PCA.

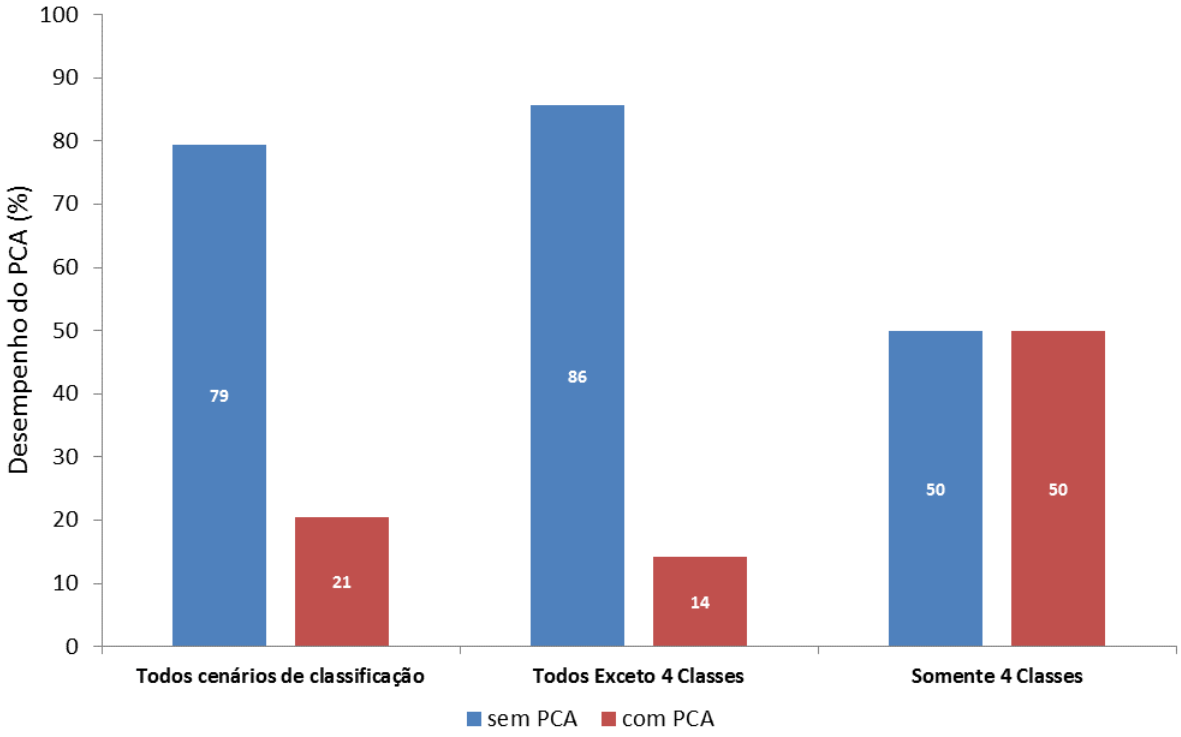

Figura 49 - Desempenho da PCA em função dos cenários de classificação.

O uso da PCA resultou na melhor taxa de classificação em 50% dos casos para se discriminar os movimentos em quatro classes. Entretanto, excluindo-se esse cenário de classificação, a PCA contribuiu para a melhor taxa de classificação em somente 14% dos experimentos. Em função disso, considerando-se o panorama geral, com todos os cenários de classificação, a PCA contribuiu para a obtenção da melhor taxa de classificação em 21% dos experimentos. Esses resultados sugerem que a redução de dimensionalidade em cenários de classificação em dois grupos, nas quais os vetores de dados utilizados são naturalmente menores, reduz a taxa de classificação.

Observa-se na Figura 50 a representatividade percentual de cada técnica na obtenção da melhor taxa de classificação. Nos cenários em que se discriminou em 4 classes, a SVM

sempre obteve a melhor taxa, porém, excluindo-se esse cenário de classificação, houve um perfeito equilíbrio entre a LDA e a SVM. Dada a vantagem da SVM sobre a LDA nos cenários de discriminação em 4 classes, a primeira manteve uma vantagem sobre a outra, representando 59% contra 41% dos cenários avaliados.

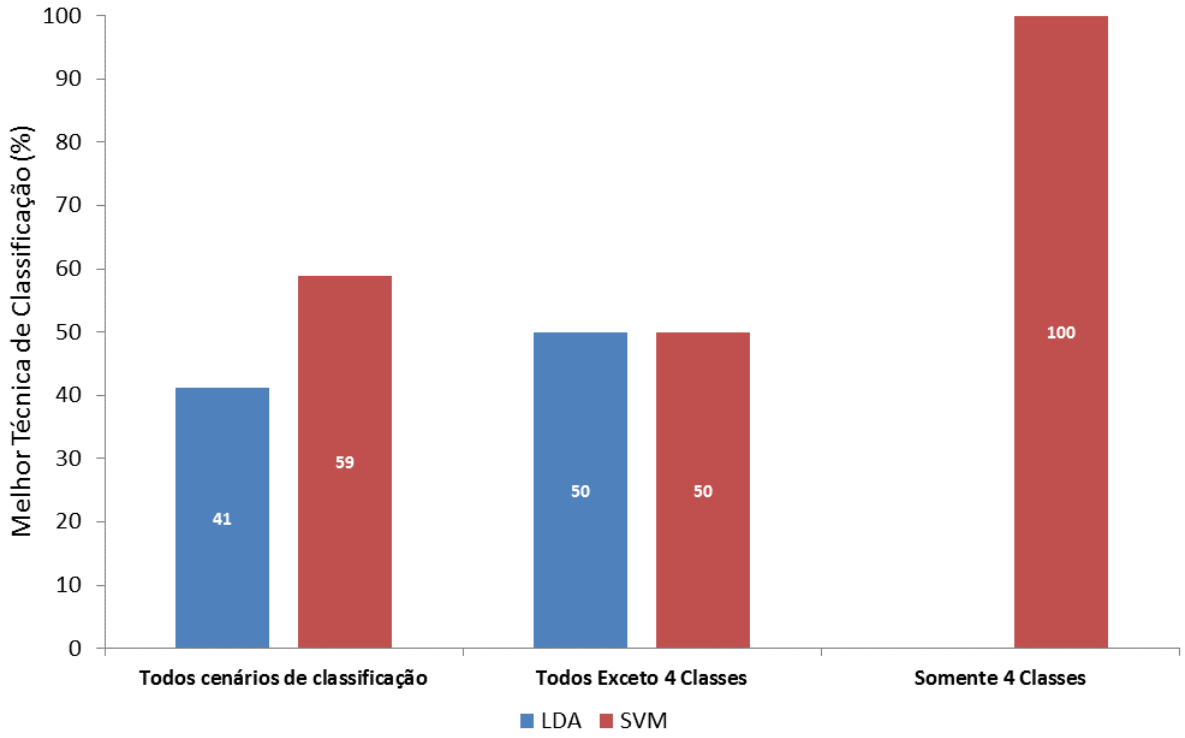

Figura 50 - Desempenho de classificação de cada técnica utilizada.

6. DISCUSSÃO

O primeiro aspecto avaliado, pela presente pesquisa, foi a inclusão de frequências até 80 Hz da PSD, já englobando a faixa gama alta, o que está em concordância com o trabalho de Vuckovic e Sepulveda (2006), que sugerem que a faixa gama alta possui um papel de destaque no processo de classificação.

Considerando-se as técnicas LDA e SVM, combinadas com a PCA, para a discriminação dos movimentos nos cinco cenários de classificação avaliados pela presente pesquisa, observou-se que a fase de planejamento sempre figura como a que mais contribui para as melhores taxas de classificação. Utilizando-se a LDA para distinguir entre os membros superiores, esta fase foi a melhor em 57,9% das vezes, porém, a aplicação da PCA sobre essa técnica favoreceu a fase de planejamento e esse valor subiu para 77,2%. Com a técnica de SVM, a PCA não beneficiou a fase de planejamento frente às outras, mas essa fase apresentou resultados similares aos alcançados utilizando-se a LDA com PCA, tendo sido de 74,3% com SVM e 74,4% com SVM combinada com PCA.

No caso da discriminação entre lados, a fase de planejamento também se apresentou como a que mais contribuiu para as melhores taxas de acerto, porém, com menor representatividade que o apresentado acima, tendo obtido 41,6% utilizando-se LDA, 47,3% com LDA e PCA, 43,4% com SVM e 51,2% com SVM e PCA. A distinção entre mãos apresentou resultados próximos dos obtidos na discriminação entre lados com as técnicas de LDA e LDA com PCA, obtendo, respectivamente, 47,9% e 48,8%, ou seja, com similar representatividade e a fase de planejamento novamente foi a que mais contribuiu para as melhores taxa de acerto. Porém, utilizando-se SVM o resultado para a fase de planejamento foi melhor e esse percentual subiu para 61,2%, mas ao se aplicar a PCA sobre essa técnica, o valor reduziu para 52,9%. Os resultados foram muito similares para discriminação entre braços, com 43,6% utilizando-se LDA, 52,0% com LDA e PCA, 50,5% com SVM e 50,1% com SVM e PCA.

Ainda no que se refere ao desempenho das fases de planejamento, a discriminação em quatro classes apresentou comportamento similar em relação aos obtidos nas avaliações realizadas com os outros cenários de classificação, que buscaram estudar os efeitos dos movimentos separadamente. A fase de planejamento foi a que mais vezes obteve as melhores taxas de acerto em relação às demais fases para todos os cenários de classificação, sendo que

a LDA foi a técnica que menos favoreceu esta fase. Aplicando-se a PCA sobre a LDA, percebe-se que a fase de planejamento foi favorecida em todos cenários, exceto na discriminação entre mãos. Embora a SVM tenha favorecido a fase de planejamento no sentido em que esta obtivesse melhores taxas de acerto, a PCA nem sempre favoreceu essa técnica como o fez para a LDA.

Em linha com o apresentado, outros trabalhos vêm mostrando que a intenção de movimento, extraída de sinais de EEG, pode ser usada para antecipar ações futuras baseado no fato de que há informações disponíveis antes de uma decisão consciente de realizar um movimento (TRAVENA e MILLER, 2002; BAI et al., 2007; MORASH et al., 2008), o que corresponderia ao que na presente pesquisa chamamos de fase de planejamento. O trabalho de Travena e Miller (2002) sugeriu que o Potencial de Prontidão e o Potencial de Prontidão Lateral podem ser utilizados para detectar o início do processo de decisão de se executar um movimento e que isso ocorre frações de segundos antes da efetiva execução do movimento, sem, embora, indicar claramente um tempo padrão.

A melhor taxa de classificação média entre os três voluntários na discriminação entre os membros superiores foi de 71,0% utilizando SVM e ocorreu na fase de planejamento com vetor de dados de 1 s e na discriminação entre lados essa taxa foi de 58,8% com SVM, que também ocorreu na fase de planejamento com vetor de dados de 1 s. Já na discriminação entre mão esquerda e mão direita essa classificação foi de 59,5% e ocorreu na fase de planejamento com vetor de dados de 1 s utilizando SVM ou SVM com PCA, enquanto que para classificar entre braço esquerdo e direito a melhor classificação média foi de 60,2% e ocorreu na posição estática com vetor de dados de 1 s utilizando LDA ou SVM ou ainda SVM com PCA, enquanto a distinção entre os quatro movimentos obteve a melhor taxa média de 61,2% utilizando SVM e 36,9% com LDA, ambos na fase de planejamento com vetor de dados de 1 s. Esses índices de classificação são similares aos observados por Morash et al. (2008), Bai et al. (2007) e Navarro et al. (2005), embora os movimentos considerados e técnicas de extração de características e classificadores sejam distintos. O primeiro trabalho utilizou Transformada Wavelet Discreta com Análise de Componentes Independentes para fornecer características e um algoritmo genérico com validação cruzada e distâncias de Bhattacharyya para obter aproximadamente 40% de taxa de classificação na discriminação entre os movimentos da mão direita, mão esquerda, língua e pé. Considerando apenas dois desses movimentos, essa taxa aumentou para 65%. O segundo utilizou Análise de Componentes Independentes, PSD e SVM para distinguir entre os movimentos da mão esquerda e direita, obtendo 63% de taxa de

classificação. Enquanto o terceiro grupo obteve entre 32% e 35% para classificar os movimentos de flexão, extensão, pronação e supinação do punho, utilizando Análise de Componentes Independentes sobre características do EEG no domínio do tempo e da frequência. Isto mostra que há grande dificuldade na classificação entre um conjunto maior de movimentos.

Considerando-se as taxas médias de acerto entre os três voluntários já apresentadas e comparando com os resultados obtidos individualmente, a discriminação entre membros mostrou-se mais eficiente do que a entre lados. As taxas de acerto máximas foram de 90,4% com SVM para distinguir entre membros, 76,9% com SVM para distinguir entre lados, 79,2% com LDA para distinguir entre mãos e 84,7% com LDA para distinguir entre braços. A discriminação em quatro classes obteve taxa de acerto máxima de 78,8% quando se utilizou SVM com PCA. Esses resultados foram apresentados na Figura 48.

A literatura consultada sugere que é mais fácil distinguir entre lados do que movimentos dos membros, o que é contradito pelos resultados obtidos nessa pesquisa. Uma hipótese é que esse comportamento se deve as diferenças de potencial entre os eletrodos terem sido tomadas de forma transversal enquanto que os trabalhos consultados adotaram a longitudinal, mas esse é um ponto que merece maior aprofundamento. Por exemplo, a taxa de classificação média para a distinção entre membros obteve um resultado superior em relação à classificação entre lados, alcançando uma média de 71,0% contra 58,8%, ambas na fase de planejamento do movimento com vetor de dados de 1 s. A distribuição da representação das partes do corpo no córtex cerebral e o sentido da diferença de potencial transversal na presente pesquisa podem ter favorecido a distinção entre braço e mão em detrimento dos lados, em comparação às demais pesquisas que utilizaram as diferenças de potencial no sentido longitudinal ou com o eletrodo auricular como referência.

Considerando-se que a resolução da PSD utilizada nesta pesquisa foi de 0,5 Hz com vetor de dados de 2 s e 1 Hz com vetor de dados de 1 s e que, em geral, as pesquisas utilizam entre 0,1 e 0,2 Hz de resolução, a proximidade dos resultados acima é bastante satisfatória, dado que a taxa de classificação torna-se inferior na medida em que a resolução diminui.

Além da baixa resolução da PSD, as sobreposições de dados entre as fases distintas do movimento, devido à pequena duração dos vetores de dados, constituem um problema prático ainda não superado que, apesar da contribuição negativa para os resultados, impedindo a

exploração de todo o potencial do método proposto nesta pesquisa, não implicou em resultados inferiores aos observados na literatura.

Outro aspecto importante a se considerar a respeito das taxas de acerto é que nos cenários em que se discriminou em 4 classes, a SVM sempre obteve a melhor taxa, porém nos demais houve um perfeito equilíbrio entre a LDA e a SVM, conforme mostra a Figura 50. Esse comportamento se deve à natureza binária da SVM que, para discriminar em cenários multi-classes, o faz por meio de discriminações entre duas classes sucessivas até que todas sejam avaliadas, o que pode representar uma melhora com menor significado prático dos índices de classificação quando se compara essa técnica com a LDA, que é um classificador multi-classes por natureza. Nesse sentido, a comparação somente dos resultados da LDA com a literatura também se mostra satisfatória.

O número de eletrodos utilizados nesta pesquisa foi significativamente inferior aos utilizados nas pesquisas de Navarro et al. (2005), de Morash et al. (2008), Vuckovic e Sepulveda (2006) e Bai et al. (2007), que utilizaram 21, 29, 64 e 122 canais respectivamente. Com melhor resolução espacial e com disponibilidade de maior quantidade de informações úteis de outras regiões do cérebro, esses trabalhos obtiveram resultados similares aos aqui obtidos, mostrando que o método utilizado aponta para um caminho promissor.

A Seleção Espacial de Características mostrou que outras áreas além da região motora, coincidente com a dos eletrodos da região central (C), devem ser consideradas, pois contribuíram para melhorar as taxas de classificação, conforme se observou nas Figura 27 até Figura 32. A discriminação entre membros obteve a melhor classificação individual na fase de planejamento do movimento utilizando ambos os eletrodos Frontais, ambos Parietais, o Central direito e o Occipital esquerdo. A melhor taxa média de classificação entre lados também ocorreu na fase de planejamento do movimento, sendo que todos os eletrodos, exceto C4-Cz e O2-Oz, estavam presentes. Já a discriminação entre braços obteve melhor taxa de classificação na fase de planejamento com os eletrodos Centrais e Parietais, ambos do lado esquerdo. Na discriminação entre mãos a melhor taxa só não dependeu dos eletrodos Centrais esquerdos e Occipitais direitos e ocorreu na fase de planejamento. As diferenças de potencial representadas pelos eletrodos F3-Fz, C4-Cz, P3-Pz e O1-Oz estavam presentes na melhor taxa média de classificação no cenário de discriminação em quatro classes. Esses resultados sugerem haver uma maior intensidade de atividade cerebral sobre a região motora, embora

ainda haja atividade residual nas áreas de memória espacial e cognitiva, durante a execução do movimento, havendo ainda pouca influência da região sensorial visual.

Xiao, Mu e Hu (2009a) utilizaram Entropia da Energia para identificar, a partir dos dados de 64 canais de EEG, qual conjunto de eletrodos provia a maior quantidade de informações útil ao classificador adotado, automatizando assim o processo de Seleção Espacial de Características e obtendo até 95% de taxa de classificação para discriminar entre dois grupos de imaginação de movimentos da mão direita, mão esquerda, pé e língua. Comparando-se com a taxa discretamente inferior de 90,4% obtidos pela presente pesquisa para distinguir entre movimentos da mão e do braço, tendo-se em consideração que a resolução espacial do EEG foi muito inferior, os resultados obtidos podem ser considerados satisfatórios do ponto de vista de eficácia de classificação. Cabe observar que a distinção entre lados obteve a melhor taxa média de classificação com os eletrodos TP8 e P3 no trabalho de Xiao, Mu e Hu (2009a), enquanto que na presente pesquisa isso ocorreu com todos os pares de eletrodos, exceto C4-Cz e O2-Oz. Outro ponto importante a ser observado nessa comparação é que os autores utilizaram a imaginação de movimentos enquanto que a presente pesquisa utilizou atividade motora, o que naturalmente tende a introduzir maior nível de ruído nos sensores, uma vez que o voluntário está se movimentando.

Bai et al. (2007) utilizaram um algoritmo genético para buscar as características de frequência mais relevantes dentre os 122 canais de EEG e 32 faixas de frequência, pois a varredura de todas as 3094 combinações se torna inviável. Para discriminar os movimentos da mão esquerda e direita obtiveram 63% de taxa média de classificação. A presente pesquisa obteve 59,5% para a mesma discriminação, porém adotou uma estratégia de busca exaustiva em função da pequena quantidade de combinações consideradas (255 configurações distintas de eletrodos). São taxas muito próximas, especialmente quando se leva em consideração que esta pesquisa não explorou diferentes combinações de faixas de frequência e contou com um número reduzido de eletrodos.

Utilizando Classificador de Naïve Bayes com Janela de Parsen (NBPW) e Banco de Filtros de Padrão Espacial Comum (FBCSP) para seleção de características e para classificação, Chin et al. (2009) obteve taxas médias de classificação entre 54% e 79% para identificar entre a imaginação de movimentos da mão esquerda, mão direita, pé e língua. Segundo os autores, a seleção de características de frequência realizada pelo algoritmo multi-classes FBCSP propicia ao classificador NBPW excelente melhora nas taxas de classificação,

o que poderia ser utilizado para elevar os 36,9% e 51,2% de taxa de classificação média para quatro grupos obtidos na presente pesquisa com LDA e SVM, respectivamente, combinado com a Seleção Espacial de Características. No entanto, o trabalho desses autores utilizou imaginação de movimento, com 9 voluntários e sessões de EEG com 288 repetições, o que provê uma quantidade de amostras muito superior à utilizada nesta pesquisa, que foi de 3 voluntários com 45 repetições, e baseada na execução de movimentos. Entretanto, a adoção da SVM coloca os resultados da presente pesquisa dentro da faixa obtida pelos autores mencionados.

É difícil distinguir entre movimentos muito próximos, como, por exemplo, tentou fazer Stastný (2007), sem atingir sucesso. O autor tentou distinguir entre a flexão do dedo indicador direito e a flexão do dedo mínimo direito, mas só conseguiu distinguir entre algum movimento e nenhum movimento, obtendo taxas de classificação entre 60% a 74%. Logo, nas comparações entre a presente pesquisa com o trabalho de Chin et al. (2009) também devem pesar esse aspecto, pois os movimentos considerados por esses autores são controlados por regiões mais geometricamente distantes do cérebro. Para discriminar em dois grupos, seja entre lados, membros, mãos ou braços, a presente pesquisa obteve entre 55% e 68,2%.

Dornhege et al. (2004) utilizaram um sistema de EEG de alta resolução espacial para obter taxa média de classificação de 48% para duas classes e 54% para três. Ao implementar combinação de características, os autores conseguiram elevar esses índices em 25% em média, atingindo 59% e 67%, respectivamente. A seleção espacial de características melhorou os resultados em 26% em média e em até 91,5%, comparando-se o pior com o melhor caso, conforme mostra a Figura 32. Além disso, a taxa média de classificação de 71,0% obtida pela presente pesquisa para discriminar em duas classes os movimentos dos membros superiores foi superior aos resultados desses autores.

Para a distinção entre lado esquerdo e lado direito, a melhor taxa de classificação individual, com todos os eletrodos, ocorreu utilizando SVM para o voluntário S2 e na posição estática e foi de 69,3 %. A Seleção Espacial de Características elevou esse número para 76,9%, o que coincide com o melhor resultado entre todos os indivíduos e técnicas para esse cenário de classificação. No caso da classificação entre membros, mão esquerda e mão direita, braço esquerdo e braço direito e para quatro classes, essa diferença foi de, respectivamente, 85,4% para 89,8%, 73,6% para 82,1%, 75,7% para 83,3% e de 73,2% para 78,8%. Lemm, Schäfer e Curio (2004), utilizando Wavelets de Morlet para extração de características e o

teorema de Bayes para classificação de sinais de ritmo pericentral, obtiveram 89,3% para diferenciar entre os movimentos da mão direita e mão esquerda. Note-se que, com exceção da classificação entre lados, a presente pesquisa obteve resultados superiores a 80% e próximos aos obtidos pelos autores recém-mencionados nos demais cenários de discriminação em duas classes. Mesmo a classificação em quatro classes obteve resultados próximos a 80%, uma taxa também muito próxima se considerar-se que é um cenário de discriminação mais complexa.

Em todos os cenários de classificação, a fase de planejamento se mostrou aquela que, na maioria das vezes, resultou na melhor taxa de classificação, inclusive em diversos casos sendo superior a soma das outras duas fases. Considerando-se o quadro geral, isto é, as melhores taxas de classificação dentre todos os cenários considerados nesta pesquisa, a fase de planejamento foi a melhor em 80% dos casos, independente da técnica utilizada, conforme mostra a Figura 46. Stastný (2007) utilizou um sistema de eletrodos de alta resolução espacial com 41 elementos para identificar informações do EEG que precedem o movimento, denominadas Dessincronização Relacionada a Evento (ERD), referentes ao planejamento do movimento em até 2 s antes do início da execução do movimento e obteve taxas de classificação entre 48,8% e 57,8% para diferenciar os movimentos do dedo indicador direito do esquerdo. Levando-se em conta que a presente pesquisa obteve taxas de classificação de até 55,8% com LDA e 78,8% com SVM e PCA para discriminar entre os quatro movimentos, fazendo uso de informações da fase de planejamento do movimento a partir de um EEG de baixa resolução espacial, pode-se considerar que os resultados foram muito positivos e inclusive superiores aos deste autor.

Observou-se grande variação dos resultados entre os indivíduos, tanto no que se refere às taxas de classificação obtidas quanto no resultado da Seleção Espacial de Características, o que está condizente com o observado nos demais trabalhos disponíveis na literatura. Entretanto, a literatura pesquisada sugere que a aplicação de PCA em geral melhora as taxas de acerto, o que só se verificou de forma moderada no cenário de classificação em 4 classes, no qual isso foi verdadeiro para 50% dos casos, enquanto que nos demais casos, excluindo-se 4 classes, isso representou 14%. Uma possível explicação para esse resultado é que a adoção da $PSDM_{f_i}$ em conjunto com a Seleção Espacial de Características, uma vez que ambas atuam com uma redução de dimensionalidade, podem estar reduzindo demasiadamente a dimensão dos dados quando associadas à PCA, a ponto de eliminar informações relevantes aos classificadores e prejudicando seu desempenho. Em uma situação limite, por exemplo, na discriminação entre mãos considerando-se somente um par de eletrodos, a matriz de dados de

treinamento dos algoritmos chega ter dimensão de 8 x 90, sobre a qual ainda se aplicou a PCA. Esses resultados sugerem que a redução de dimensionalidade em cenários de classificação em dois grupos, nas quais os vetores de dados utilizados são naturalmente menores, reduz a taxa de classificação.

Outro aspecto que merece destaque é o fato de que a presente pesquisa não contou com realimentação do resultado de classificação ao voluntário, ou seja, os participantes não tinham ciência sobre a influência do seu padrão cerebral sobre o experimento. Em sua grande maioria, os trabalhos observados na literatura são baseados em imaginação do movimento e contam com essa realimentação, explicitando aos usuários do BCI informações sobre os efeitos dos seus padrões cerebrais sobre o sistema controlado. Além disso, a realimentação permite que se dê treinamento para os voluntários que participarão dos experimentos com o intuito de melhorar a assertividade geral do sistema, que não houve na presente pesquisa. Apesar dessas duas diferenças importantes, as taxas de acerto observadas na presente pesquisa podem ser consideradas próximas às da literatura sob essa ótica. Na verdade, um dos objetivos dessa pesquisa foi explorar a fase de planejamento do movimento para verificar se nela há informação suficiente para compensar a ausência desses dois aspectos e os resultados obtidos sinalizam positivamente nesse sentido.

7. CONCLUSÕES E TRABALHOS FUTUROS

Essa pesquisa sugere ser possível utilizar informações da região motora do córtex cerebral, em conjunto com regiões responsáveis por visão e cognição, para construir uma BCI que permita o controle de tecnologias assistivas.

Também foi visto ser possível utilizar informações da fase de planejamento do movimento para acelerar o processo de classificação e, consequentemente, criar um sistema que possa se antecipar ao movimento e apresentar a resposta final sobre a intenção do sujeito de maneira global mais rápida. Os resultados sugerem que essa fase de planejamento do movimento também é uma das mais discriminantes no aspecto geral, pois é a que resulta na melhor taxa de classificação em 80% dos experimentos realizados.

No cenário de classificação mais complexo, em 4 classes, e principal objetivo de investigação desta pesquisa, foram obtidas taxas de acerto médias entre os voluntários de 37% até 61% e taxas individuais até 79%, considerando as diversas técnicas de classificação empregadas.

As técnicas de classificação LDA e SVM obtiveram taxas de acerto similares nos cenários de classificação mais simples (lados, membros, mãos e braços), mas na discriminação entre 4 classes o SVM apresentou resultados até 65% superiores, em média, e sempre foi o algoritmo que obteve a melhor taxa de acerto neste cenário. O uso da PCA contribuiu na obtenção de melhores taxas de acerto em 50% dos casos para o cenário de classificação em 4 classes, tendo tido menor representatividade nos demais cenários, somente 14%.

A Seleção Espacial de Características trouxe resultados que sugerem que áreas não motoras devem ser consideradas como fontes de informação, uma vez que também contribuem para melhorar as taxas de acerto do classificador. Por exemplo, durante a fase de planejamento do movimento os eletrodos centrais raramente ocorrem independentemente nas melhores taxas de acerto, ocorrendo com maior frequência conjuntamente com os Parietais. Mas na execução do movimento os eletrodos Centrais ocorrem de forma independente com maior frequência do que em conjunto com outros e na posição estática nunca ocorrem sozinhos, voltando os Parietais a ter um papel importante. Porém, como os resultados mostraram ampla variabilidade entre indivíduos, um ponto a ser futuramente pesquisado, no sentido de tornar esse processo mais eficaz e independentemente do voluntário, seria utilizar

um processo automatizado com algoritmos que identifiquem, a partir do EEG, os canais que contenham informação mais relevante à identificação do movimento. No entanto, é possível recomendar que se considerem informações do córtex motor e das regiões parietal e da frontal, desprezando a occipital, como uma configuração ótima para efeitos de classificação dos movimentos dos membros superiores.

As durações dos vetores de dados de 1 e 2 s implicaram em um desafio à parte a esta pesquisa, pois impuseram a baixa resolução da PSD de 0,5 e 1 Hz. Além disso, ocorreu sobreposição de dados entre as distintas fases de movimento em virtude da pequena duração dos vetores de dados. A adoção da $PSDM_{f_i}$ em conjunto com a Seleção Espacial de Características pode ter reduzido demasiadamente a dimensionalidade dos dados, especialmente quando associadas à PCA, a ponto de eliminar informações relevantes aos classificadores e limitando seu desempenho. Apesar desses fatos, foram obtidas taxas de classificação compatíveis com as apresentadas na literatura atual, o que sugere haver um grande potencial nos métodos utilizados nessa pesquisa, pois certamente os resultados obtidos atingiram taxas de acerto menores frente a esses problemas.

As diferenças de potenciais não convencionais, no sentido transversal, utilizadas nessa pesquisa abrem novas possibilidades de exploração de EEG, pois, além de terem apresentado resultados tão bons quanto os disponíveis na literatura, obtiveram taxas de classificação superiores para a distinção entre membros do que entre lados, um resultado não esperado.

Embora os resultados sejam promissores, pesquisas adicionais podem contribuir para melhorar as taxas de classificação, considerando, por exemplo:

- Trabalhar com características extraídas por Wavelet de forma a se ter informações de variação no tempo e na frequência.
- Utilizar como característica a Potência Real no lugar da Potência Média da PSD para cada faixa de frequência.
- Comparar os resultados utilizando Análise de Componentes Independentes ao invés de Análise de Componentes Principais. Segundo Bugli e Lambert (2007), a ICA provê melhor discriminabilidade do que a PCA, embora esta última tenha maior poder de redução de dimensionalidade.
- Repetir procedimento de aquisição do EEG com um maior número de canais e/ou com a aquisição da diferença de potencial segundo a direção usual.

- Utilizar entropia da energia para automatizar o processo de Seleção Espacial de Características.
- Ampliar a quantidade de voluntários para que se tenha uma amostragem mais significativa.

Adicionalmente, durante o processo de aquisição do EEG e realização dos experimentos, foi possível identificar alguns pontos passíveis de melhoria nesta pesquisa que podem refletir em melhores resultados:

- Espaçar mais os comandos para permitir melhor resolução da FFT, que é utilizada na obtenção da PSD.
- Melhorar os sensores baseados em chave de pressão, utilizando chave magnética, para evitar que o voluntário precise realizar esforço para mantê-las pressionadas ou que tenha dificuldade em localizar o ponto a ser pressionado.

REFERÊNCIAS BIBLIOGRÁFICAS

BAI, O.; LIN, P.; VORBACH, S.; LI, J.; FURLANI, S. HALLET, M. Exploration of computational methods for classification of movement intention during human voluntary movement from single trial EEG. **Clinical Neurophysiology**, v. 118, n. 12, p. 2637-2655, 2007.

BASHASHATI, A.; FATOURECHI, M.; WARD, R. K.; BIRCH, G. E. A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals. **Journal of Neural Engineering**, v. 4, n. 2, p. 32–57, 2007.

BELHUMEUR, P.; HESPANHA, J.; KRIEGMAN, D. Eigenfaces vs. Fisherfaces: recognition using class specific linear projection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 19, n. 7, p. 711–720, 1997.

BIRBAUMER, N.; GHANAYIM, N.; HINTERBERGER, T.; IVERSEN, I.; KOTCHOUBEY, B.; KÜBLER, A.; PERELMOUTER, J.; TAUB, E.; FLOR, H. A spelling device for the paralysed. **Nature**, v. 398, p. 297-298, 1999.

BLINOWSKA, K. J.; KAMINSKI, M.; KUS, R.; GINTER, J. Transmission of brain activity in cognitive and motor tasks. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 30, 2008, p. 3508 – 3511, 2008.

BOYLESTAD, R.; NASHELSKY, L. **Dispositivos Eletrônicos e Teoria de Circuitos**, 5 ed., Prentice-Hall do Brasil., p. 618-632, 1994.

BUGLI C.; LAMBERT P. Comparison between Principal Component Analysis and Independent Component Analysis in Electroencephalograms Modelling. **Biometrial Journal,** v. 49, 2 ed., p. 312-327, 2007.

CARMENA, J. M.; LEBEDEV, M. A.; CRIST R. E.; O'DOHERTY, J. E.; SANTUCCI, D. M.; DIMITROV, D. F.; PATIL, P. G.; HENRIQUEZ, C. S.; NICOLELIS, M. A. L. Learning to Control a Brain–Machine Interface for Reaching and Grasping by Primates. **PLoS Biology**, v. 1, n. 2, p. 1-16, 2003.

CHIN, Z. Y.; ANG, K. K.; WANG, C.; GUAN, C.; ZHANG, H.; Multi-class filter bank common spatial pattern for four-class motor imagery BCI. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 31, 2009, p. 571–574, 2009.

DIETRICH, A.; KANSO, R. A Review of EEG, ERP, and Neuroimaging Studies of Creativity and Insight. **Psychological Bulletin**, v. 136, n. 5, p. 822–848, 2010.

DIEZ, F. P.; LACIAR, E.; MUT, V.; AVILA, E.; TORRES, A. Classification of Mental Tasks using Different Spectral Methods. **Biomedical Engineering**, Carlos Alexandre Barros de Mello (Ed.), ISBN 978-953-307-013-1, InTech, Disponível em: http://www.intechopen.com/books/biomedical-engineering/classification-of-mental-tasks-using-different-spectral-estimation-methods, p. 287-206, 2009.

DORNHEGE, G.; BLANKERTZ, B.; CURIO, G.; MULLER, K. R. Boosting bit rates in non-invasive EEG single-trial classifications by feature combination and multi-class paradigms. **IEEE Transactions on Biomedical Engineering**, v. 51, n. 6, p. 993–1002, 2004.

DUFFY, F. H.; IYER, V.G.; SURWILLO, W. W. **Eletroencefalografia clínica e mapeamento cerebral topográfico**. Livraria e Editora Revinter, p. 77-83, 1999.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. Capítulo 12. Support Vector Machines and Flexible Discriminants, In: _ _ _. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. Springer, 2. ed., ISBN 978-0387848570, p. 417-451, 2011.

_____. Capítulo 14.5. Principal Components, Curves and Surfaces, In: _ _ _. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. Springer, 2. ed., ISBN 978-0387848570, p. 534-552, 2011.

HOFFMANN, U. **Bayesian Machine Learning Applied in a Brain-Computer Interface for Disabled Users**. 2007. 136 f., Tese nº 3924 - École Polytechinique Fédérale de Lausanne. Disponível em: <http://infoscience.epfl.ch/record/111341/files/EPFL_TH3924.pdf>.

HOFFMANN, U.; VESIN, J. M.; EBRAHIMI, T. Recent Advances in Brain-Computer Interfaces. In: IEEE INTERNATIONAL WORKSHOP ON MULTIMEDIA SIGNAL PROCESSING, 9, 2007, p. 1-8, 2007.

KELLY, S. P.; LALOR, E. C.; FINUCANE, C.; MCDARBY, G.; REILLY, R. B. Visual Spatial Attention Control in an Independent Brain-Computer Interface. **IEEE Transactions on Biomedical Engineering**, v. 52, n. 9, p. 1588-1596, 2005.

LALOR, E. C.; KELLY, S. P.; FINUCANE, C.; BURKE, R.; SMITH, R.; REILLY, R. B.; MCDARBY, G. Steady-State VEP-Based Brain-Computer Interface Control in an Immersive 3D Gaming Environment. **EURASIP Journal on Applied Signal Processing**, v. 2005, n. 19, p. 3156-3164, 2005.

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

LEMM, S.; SCHAEFER, C.; CURIO, G. BCI Competition 2003 – Data Set III - Probabilistic Modeling of Sensorimotor mu-Rhythms for Classification of Imaginary Hand Movements. **IEEE Transactions on Biomedical Engineering**, v. 51, n. 6, p. 1077-1080, 2004.

LUCK, S. J.; KAPPENMAN, E. S. **The Oxford Handbook of Event-Related Potential Components**. New York, EUA: Oxford University Press, 2012.

MAHAJAN K.; VARGANTWAR M.R.; RAPJUT S. M. Classification os EEG using PCA, ICA and Neural Network. **International Journal of Engineering and Advanced Technology (IJEAT)**, v. 1, p. 80-83, 2011.

MALVINO A. P. **Eletrônica**, McGraw-Hill, v. 2, p. 643-656, 1986.

MESSMER, H.P. **The Indispensable PC Hardware Book.** Local: Addison-Wesley Professional, 3 ed., ISBN 978-0201403992, p. 941-977, 1999.

MILLÁN, J. D. R.; RUPP, R.; MÜLLER-PUTZ, G. R.; MURRAY-SMITH, R.; GIUGLIEMMA, C.; TANGERMANN, M.; VIDAURRE, C.; CINCOTTI, F.; KÜBLER, A.; LEEB, R.; NEUPER, C.; MÜLLER, K. R.; MATTIA, D. Combining Brain-Computer Interfaces and Assistive Technologies: State-of-the-Art and Challenges. **Frontiers in Neuroscience**, v. 4, n. 161, p. 1-15, DOI: 10.3389/fnins.2010.00161, 2010.

MORASH, V.; BAI, O; FURLANI, S.; LIN, P.; HALLETT, M. Classifying EEG signals preceding right hand, left hand, tongue, and right foot movements and motor imageries. **Clinical Neurophysiology**, v. 119, n. 11, p. 2570-2578, 2008.

NAVARRO, I.; SEPULVEDA, F.; HUBAIS, B. A Comparison of Time, Frequency and ICA Based Features and Five Classifiers for Wrist Movement Classification in EEG Signals**.** In: ANNUAL CONFERENCE IEEE ENGINEERING IN MEDICINE AND BIOLOGY, 27, 2005, p. 2118-2121, 2005.

ROYER, A. S.; MCCULLOUGH, A.; HE, B. A Sensorimotor Rhythm based Goal Selection Brain-Computer Interface. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 2009, p. 575 – 577, 2009.

SLEIGHT, J.; PILLAI, P.; MOHAN, S. Classification of Executed and Imagined Motor Movement EEG Signals. **Computer Science and Engineering**, University of Michigan, Ann Arbor, p. 1-10, 2009.

STASTNÝ, J. High-Resolution Movement EEG Classification. **Czech Technical University in Prague,, Biosignal Processing Laboratory, Department of Circuit Theory, Faculty of Electrotechnical Engineering**, Article ID 54925, p. 1-30, 2007.

STOICA P; MOSES R. **Introduction to spectral analysis.** Prentice-Hall, 1 ed., p. 22-36, 1997.

SUN, L.; CHANG, G.; TANG, H. Wavelet Packet Entropy in the Analysis of EEG Signals. In: INTERNATIONAL CONFERENCE ON SIGNAL PROCESSING, 8, 2006, v. 4, p. 3292-3295, 2006.

TEPLAN, M. Fundamentals of EEG Measurement. **Measurement Science Review**, v. 2, Section 2, p. 1-11, 2002.

THOMAZ, C. E.; GILLIES, D. F. A Maximum Uncertainty LDA-Based Approach for Limited Sample Size Problems — With Application to Face Recognition. In: BRAZILIAN SYMPOSIUM ON COMPUTER GRAPHICS AND IMAGE PROCESSING, 18, 2005, p. 89-96, 2005.

TREVENA, J.; MILLER, J. Cortical Movement Preparation before and after a Conscious Decision to Move. **Consciousness and Cognition**, v. 11, n. 2, p. 162–190, 2002.

VAPNIK, V. An Overview of Statistical Learning Theory. **IEEE Transactions on Neural Networks**, v. 10, p. 988-999, 2002.

_____. **The Nature of Statistical Learning Theory**. Springer, 2 ed., 2000.

VEEN, E. R. G. V. D. V. Survey of state-of-the-art EEG-based BCI systems as reliable computer interface mechanisms. In: TWENTY STUDENT CONFERENCE ON IT, UNIVERSITY OF TWENTY, FACULTY OF ELECTRICAL ENGINEERING, MATHEMATICS AND COMPUTER SCIENCE, 11, 2009, p. 1-7, 2009.

VUCKOVIC, A.; SEPULVEDA, F. EEG-Based Eight Class, Single Trial Classification of Imaginary Wrist Movements. In: BIOMEDICAL CIRCUITS AND SYSTEMS CONFERENCE, 2006, p. 77-80, 2006.

WOLPAW, J. R. Brain–computer interfaces as new brain output pathways. **The Journal of Physiology**, v. 579, p. 613 – 619, 2007.

XIAO, D.; MU, Z.; HU, J. A linear discrimination method used in motor imagery EEG classification**.** In: INTERNATIONAL CONFERENCE ON NATURAL COMPUTATION, 5, 2009, p. 94-98, 2009.

_____. Classification of motor imagery EEG signals based on energy entropy. In: INTERNATIONAL SYMPOSIUM ON INTELLIGENT UBIQUITOUS COMPUTING AND EDUCATION, 2009, p. 61-64, 2009.

ZHIWEI, L.; MINFEN, S. Classification of Mental Task EEG Signals Using Wavelet Packet Entropy and SVM. In: INTERNATIONAL CONFERENCE ON ELECTRONIC MEASUREMENT AND INSTRUMENTS, 8, 2007, p. 3906 – 3909, 2007.

APÊNDICE A – Termo de consentimento livre e esclarecido

CENTRO UNIVERSITÁRIO DA FEI

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

Protocolo – Ondas Cerebrais

I - DADOS DE IDENTIFICAÇÃO DO SUJEITO DA PESQUISA

1. NOME DO PACIENTE :

DOCUMENTO DE IDENTIDADE Nº : SEXO : .M Ž F Ž

DATA NASCIMENTO (dd/mm/aaaa) :

ENDEREÇO Nº
Comp.:

BAIRRO: CIDADE

CEP: TELEFONE: DDD ( )

II - DADOS SOBRE A PESQUISA CIENTÍFICA

1. TÍTULO DO PROTOCOLO DE PESQUISA: **Reconhecimento de Padrões – Ondas Cerebrais.**

PESQUISADOR: Ricardo Cainé Caracillo

ORIENTADOR DA PESQUISA: PROFA. DRA. MARIA CLAUDIA FERRARI DE CASTRO

CARGO/FUNÇÃO: PROFESSOR ADJUNTO I DO DEPTO. DE ENGENHARIA ELÉTRICA DA FEI – LABORATÓRIO DE ENGENHARIA BIOMÉDICA RG. 22697291-4 / CREA: 5060015556

3. AVALIAÇÃO DO RISCO DA PESQUISA:

SEM RISCO Ž RISCO MÍNIMO X RISCO MÉDIO Ž

RISCO BAIXO Ž RISCO MAIOR Ž

(probabilidade de que o indivíduo sofra algum dano como consequência imediata ou tardia do estudo)

4. DURAÇÃO DA PESQUISA : 12 meses

III - REGISTRO DAS EXPLICAÇÕES DO PESQUISADOR AO VOLUNTÁRIO:

1. Justificativa e os objetivos da pesquisa: **Você está sendo convidado a participar de um estudo denominado: "Reconhecimento de Padrões – Ondas Cerebrais", cujo objetivo é detectar padrões cerebrais relacionados ao movimento e a imaginação de movimento dos braços e das mãos.**

2. Procedimentos que serão utilizados e propósitos, incluindo a identificação dos procedimentos que são experimentais: **O procedimento de teste constará basicamente da monitoração do sinal Eletroencefalográfico com a utilização de uma touca para o posicionamento correto dos eletrodos. Será utilizado gel específico para aumentar a condutibilidade dos eletrodos, configurando 8 canais de aquisição localizados na parte superior e posterior da cabeça. O procedimento será feito em duas etapas separadas, e intercaladas e, em cada uma delas será solicitado que, conjuntamente com a aquisição do sinal eletroencefalográfico, você execute 1 atividade. Na primeira etapa, a atividade corresponde à realização de movimentos de flexão do braço (direito ou esquerdo), e fechamento da mão (direita ou esquerda), sempre com o acionamento de chaves no final do movimento. Durante a execução dessa atividade você deve estar concentrado no movimento que está sendo realizado. Esses movimentos serão executados 15 vezes cada um, em uma ordem aleatória e repetidos em 3 séries. O comando será dado através de uma mensagem de texto no monitor do computador, e quando a mensagem se apagar você deve retornar à posição inicial estendendo o braço ou abrindo a mão e acionando novamente chaves no final do movimento. Na segunda etapa, você deverá apenas imaginar que está realizando os movimentos iguais aos da primeira etapa. As séries de comandos serão as mesmas, e nesta etapa o seu grau de concentração deve ser maior, tentando visualizar o movimento sendo executado, mas sem executá-lo fisicamente. Durante o experimento nenhum outro movimento deve ser executado ou imaginado além do indicado na mensagem de comando.**

3. Desconfortos e riscos esperados: **A sua participação nesta pesquisa é voluntária e a avaliação não determinará qualquer risco, nem trará desconforto.**

4. Benefícios que poderão ser obtidos: **A sua participação não trará qualquer benefício direto, mas proporcionará um melhor conhecimento à respeito de padrões específicos do sinal eletroencefalográfico e técnicas de processamento de sinais.**

IV - ESCLARECIMENTOS DADOS PELO PESQUISADOR SOBRE GARANTIAS DO SUJEITO DA PESQUISA CONSIGNANDO:

1. Acesso, a qualquer tempo, às informações sobre procedimentos, riscos e benefícios relacionados à pesquisa, inclusive para dirimir eventuais dúvidas: **Informo que o Sr(a). tem a garantia de acesso, em qualquer etapa do estudo, sobre qualquer esclarecimento de eventuais dúvidas, bem como o acesso aos resultados parciais e totais da pesquisa.**

2. Liberdade de retirar seu consentimento a qualquer momento e de deixar de participar do estudo: **Também é garantida a liberdade da retirada de consentimento, a qualquer momento, deixando de participar do estudo.**

3. Salvaguarda da confidencialidade, sigilo e privacidade: **A equipe se compromete a utilizar os dados coletados somente para pesquisa e os resultados serão veiculados através de artigos científicos em revistas especializadas e/ou em encontros científicos e congressos, sem nunca tornar possível a sua identificação, garantindo o sigilo de sua participação.**

4. Disponibilidade de assistência, por eventuais danos à saúde, decorrentes da pesquisa: **O presente estudo oferece risco mínimo à saúde, mas os pesquisadores se disponibilizam a dar assistência por eventuais intercorrências.**

5. Viabilidade de indenização por eventuais danos à saúde decorrentes da pesquisa: **Sim, através de recursos próprios dos pesquisadores.**

V. INFORMAÇÕES DE NOMES, ENDEREÇOS E TELEFONES DOS RESPONSÁVEIS PELO ACOMPANHAMENTO DA PESQUISA, PARA CONTATO EM CASO DE INTERCORRÊNCIAS CLÍNICAS E REAÇÕES ADVERSAS.

VII - CONSENTIMENTO PÓS-ESCLARECIDO

Declaro que, após convenientemente esclarecido pelo pesquisador e ter entendido o que me foi explicado, consinto em participar do presente Protocolo de Pesquisa.

São Bernardo do Campo, de de 2011.

_____	_____
sujeito da pesquisa	orientador da pesquisa

APÊNDICE B – Resultados dos cenários de classificação em duas classes

DISCRIMINAÇÃO ENTRE MEMBROS

Este item apresenta as taxas de classificação obtidas na discriminação entre mãos e braços, sem diferenciar entre membros superiores do lado direito dos do lado esquerdo. A Seleção Espacial de Características foi empregada para determinar a influência de cada um dos possíveis conjuntos de eletrodos na taxa de classificação, para cada fase de movimento e para cada indivíduo (S1, S2, S3), bem como para determinar as taxas máximas e mínimas. A seguir, encontram-se os resultados para cada uma das técnicas utilizadas.

LDA

A Figura 51 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

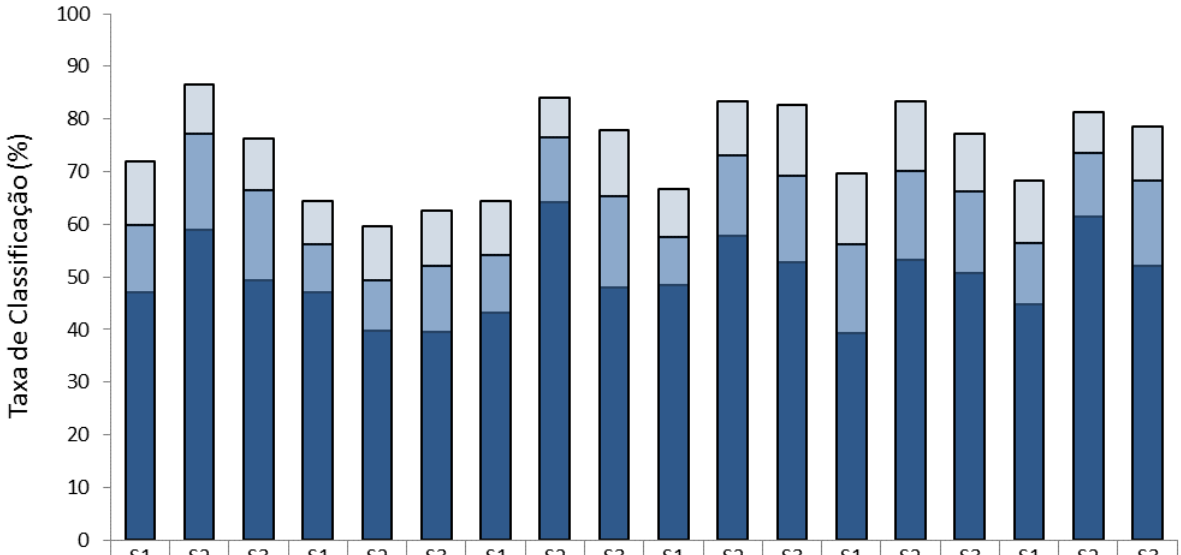

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
	Planejamento			Movimento			Posição Estática			Planejamento			Movimento			Posição Estática		
	Duração 1s									Duração 2s								
Mínima	47,0	59,0	49,3	47,0	39,7	39,6	43,2	64,1	47,9	48,5	57,7	52,8	39,4	53,2	50,7	44,7	61,5	52,1
Média	59,9	77,1	66,4	56,3	49,3	52,1	54,0	76,4	65,3	57,6	73,0	69,2	56,2	70,0	66,2	56,5	73,6	68,4
Máximo	72,0	86,5	76,4	64,4	59,6	62,5	64,4	84,0	77,8	66,7	83,3	82,6	69,7	83,3	77,1	68,2	81,4	78,5

Figura 51 - Taxas de classificação individual média utilizando LDA para discriminar entre membros superiores.

Analogamente ao apresentado acima, na Figura 52 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual,

estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 86,5% e 67,8%, respectivamente, sendo que ambas ocorreram na fase de planejamento e com vetor de dados de 1 s. O pior resultado foi 39,4%, abaixo do mínimo ao acaso, e ocorreu para a execução do movimento e com vetor de dados de 2 s. O indivíduo que obteve a melhor taxa de acerto foi S2 e a pior foi S1.

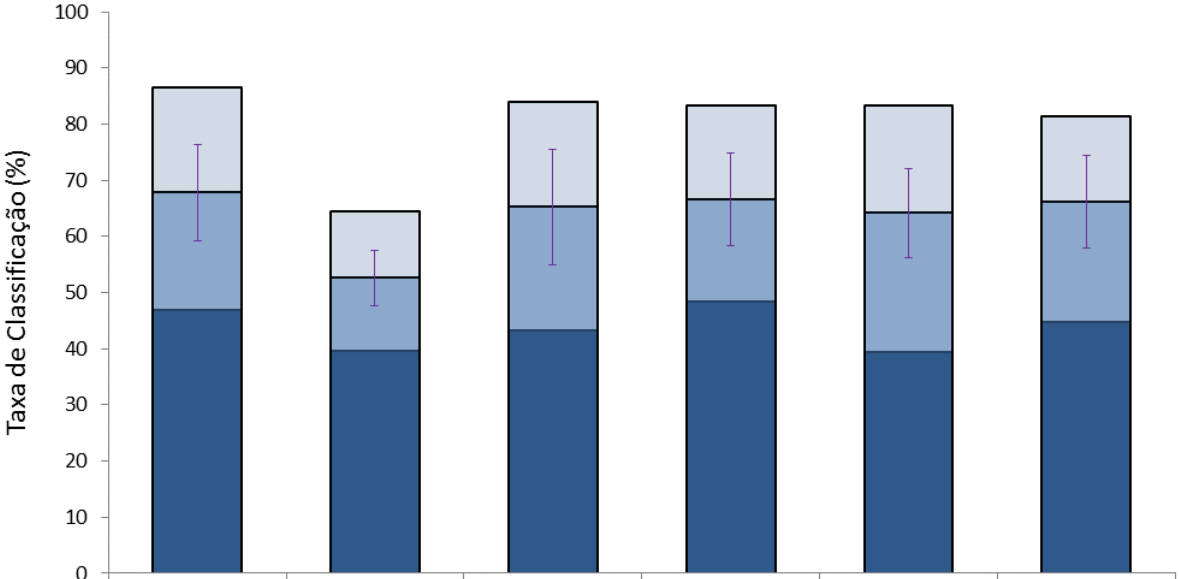

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	47,0	39,6	43,2	48,5	39,4	44,7
Média	67,8	52,6	65,3	66,6	64,1	66,2
Máximo	86,5	64,4	84,0	83,3	83,3	81,4

Figura 52 - Taxas de classificação média entre os três voluntários utilizando LDA para discriminar entre membros superiores.

LDA COM PCA

A Figura 53 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

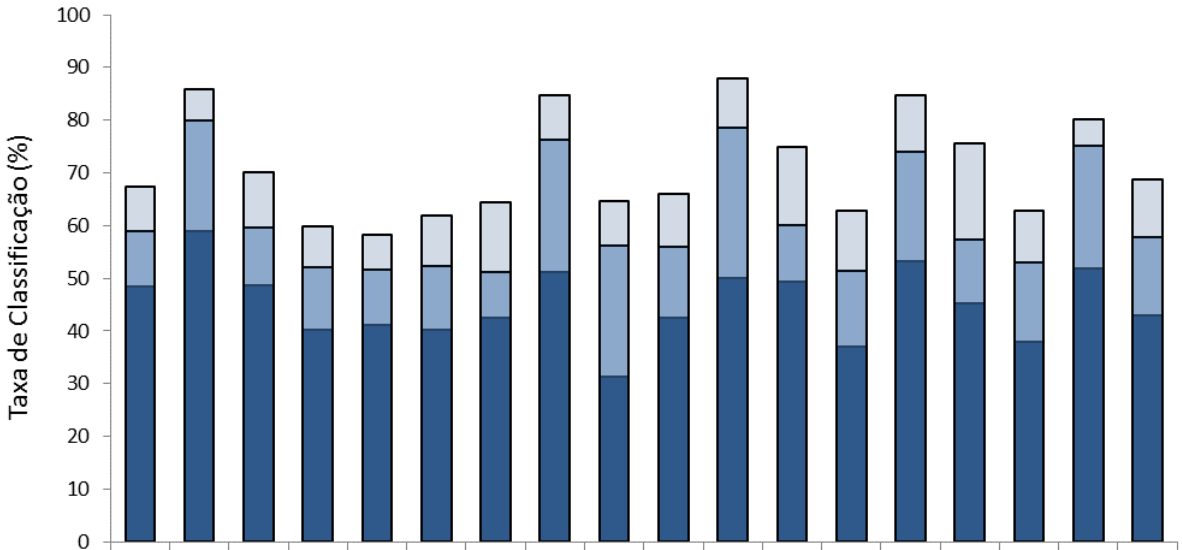

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
Mínima	48,5	59,0	48,6	40,2	41,0	40,3	42,4	51,3	31,3	42,4	50,0	49,3	37,1	53,2	45,1	37,9	51,9	43,1
Média	58,9	79,8	59,6	52,0	51,5	52,4	51,2	76,3	56,2	56,0	78,5	60,1	51,5	73,9	57,2	52,9	75,1	57,8
Máximo	67,4	85,9	70,1	59,8	58,3	61,8	64,4	84,6	64,6	65,9	87,8	75,0	62,9	84,6	75,7	62,9	80,1	68,8

Figura 53 - Taxas de classificação individual média utilizando LDA com PCA para discriminar entre membros superiores.

Analogamente ao apresentado acima, na Figura 54 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 87,8% e 66,1%, respectivamente, sendo que a primeira ocorreu na fase de planejamento e com vetor de dados de 2 s e a outra também ocorreu na mesma fase, porém com vetor de dados de 1 s. O pior resultado foi 31,3%, abaixo do mínimo ao acaso, e ocorreu para a execução do movimento e com vetor de dados de 1 s. O indivíduo que obteve a melhor taxa de acerto foi S2 e a pior foi S3.

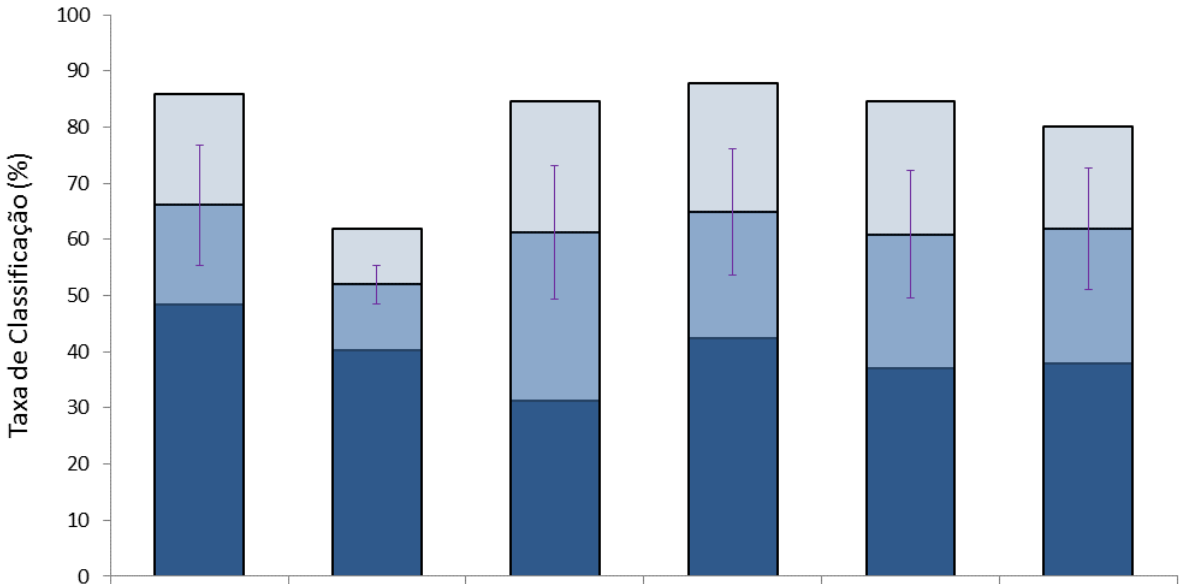

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	48,5	40,2	31,3	42,4	37,1	37,9
Média	66,1	52,0	61,3	64,9	60,9	61,9
Máximo	85,9	61,8	84,6	87,8	84,6	80,1

Figura 54 - Taxas de classificação média entre os três voluntários utilizando LDA com PCA para discriminar entre membros superiores.

SVM

A Figura 55 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

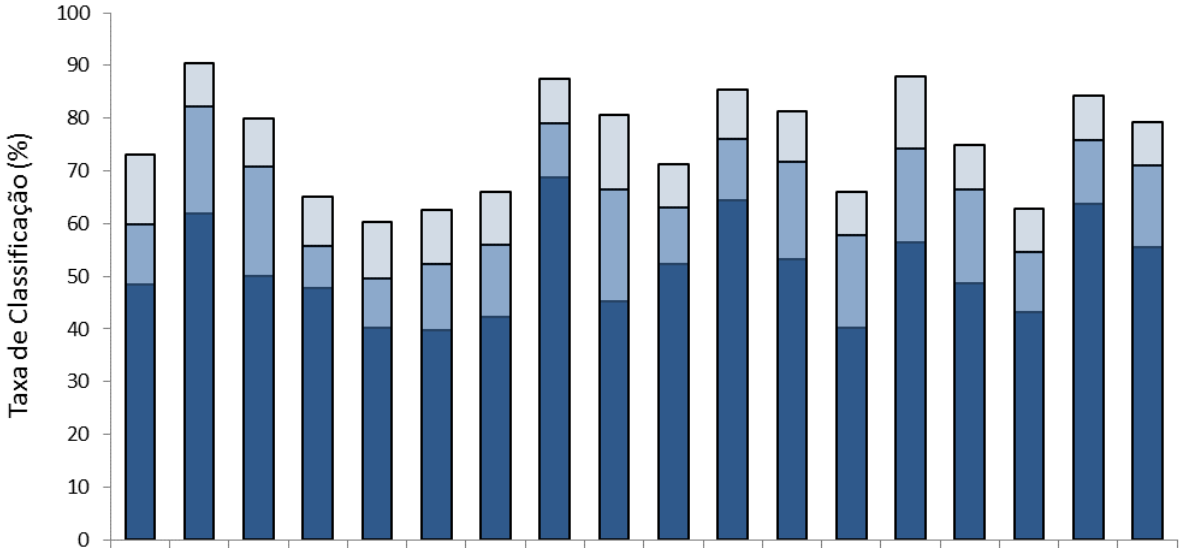

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
Planejamento																		
Movimento																		
Posição Estática																		
Duração 1s																		
Duração 2s																		
Mínima	48,5	61,8	50,0	47,7	40,3	39,7	42,2	68,8	45,1	52,3	64,4	53,1	40,1	56,4	48,6	43,2	63,6	55,6
Média	59,9	82,2	70,9	55,8	49,5	52,3	56,0	79,1	66,4	63,1	76,1	71,7	57,8	74,1	66,5	54,7	75,7	71,1
Máximo	73,1	90,4	80,0	65,2	60,3	62,6	66,0	87,4	80,6	71,2	85,5	81,3	65,9	87,8	75,0	62,9	84,3	79,2

Figura 55 - Taxas de classificação individual média utilizando SVM para discriminar entre membros superiores.

Analogamente ao apresentado acima, na Figura 56 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 90,4% e 71,0%, respectivamente, sendo que ambas ocorreram na fase de planejamento e com vetor de dados de 1 s. O pior resultado foi 39,7%, abaixo do mínimo ao acaso, e ocorreu para a execução do movimento e com vetor de dados de 1 s. O indivíduo que obteve a melhor taxa de acerto foi S2 e a pior foi S3.

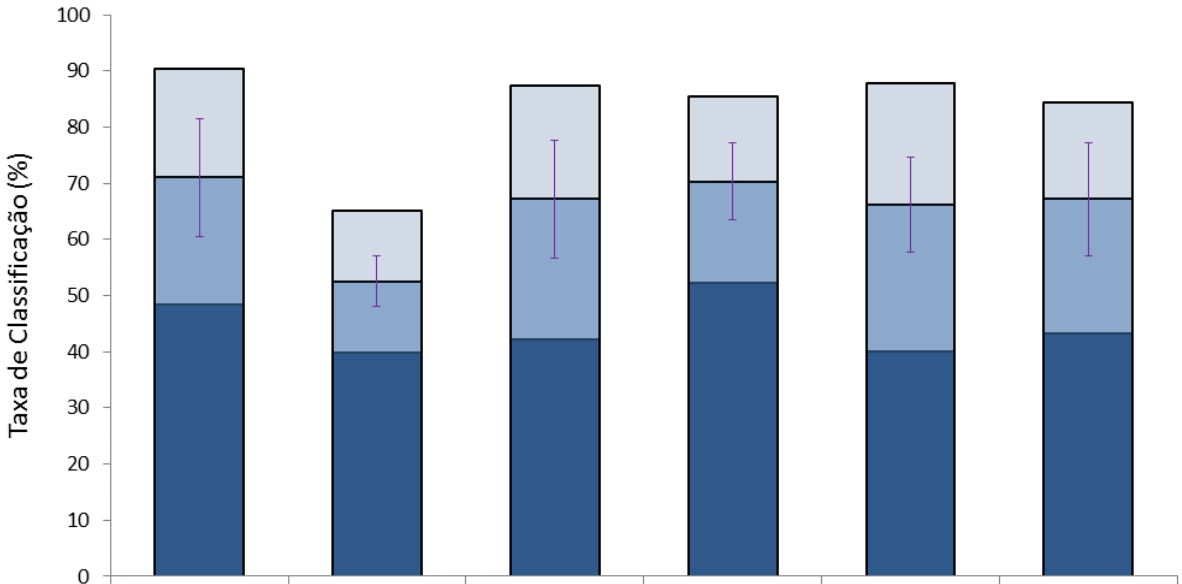

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	48,5	39,7	42,2	52,3	40,1	43,2
Média	71,0	52,5	67,2	70,3	66,1	67,2
Máximo	90,4	65,2	87,4	85,5	87,8	84,3

Figura 56 - Taxas de classificação média entre os três voluntários utilizando SVM para discriminar entre membros superiores.

SVM COM PCA

A Figura 57 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

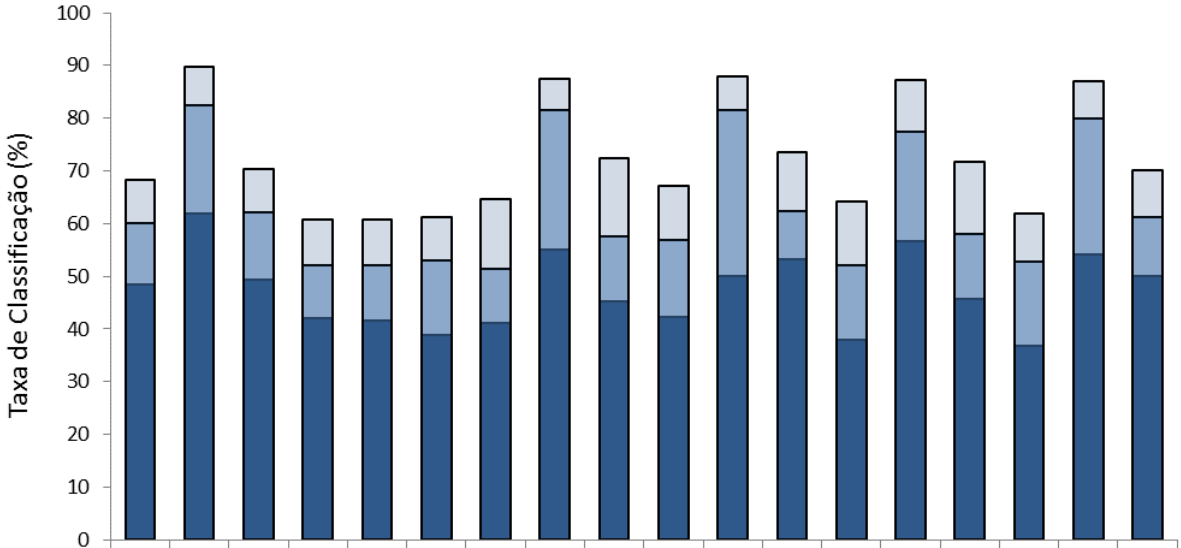

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
	Planejamento			Movimento			Posição Estática			Planejamento			Movimento			Posição Estática		
	Duração 1s									Duração 2s								
Mínima	48,4	61,8	49,2	42,0	41,6	38,8	41,0	55,0	45,1	42,4	50,0	53,1	37,8	56,7	45,8	36,9	54,1	50,0
Média	60,0	82,5	62,2	52,1	52,1	52,9	51,3	81,5	57,5	57,0	81,4	62,3	52,0	77,3	58,1	52,9	80,0	61,2
Máximo	68,4	89,8	70,3	60,9	60,7	61,1	64,7	87,5	72,4	67,0	88,0	73,6	64,1	87,2	71,6	61,9	87,1	70,2

Figura 57 - Taxas de classificação individual média utilizando SVM com PCA para discriminar entre membros superiores.

Analogamente ao apresentado acima, na Figura 58 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 89,8% e 68,2%, respectivamente, sendo que ambas ocorreram na fase de planejamento e com vetor de dados de 1 s. O pior resultado foi 36,9%, abaixo do mínimo ao acaso, e ocorreu para a posição estática e com vetor de dados de 2 s. O indivíduo que obteve a melhor taxa de acerto foi S2 e a pior foi S1.

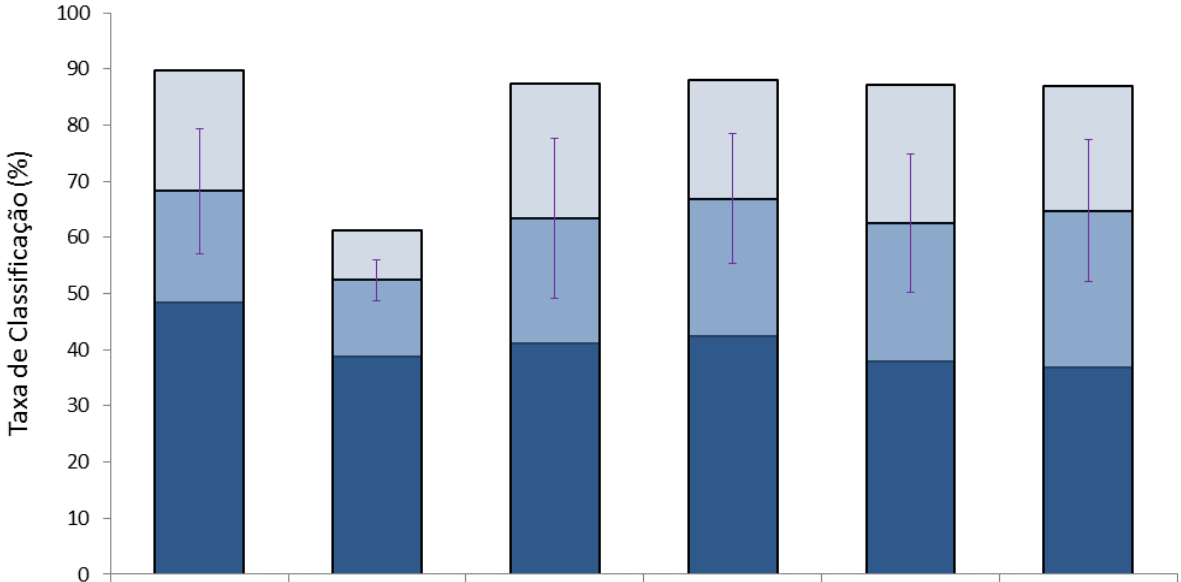

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	48,4	38,8	41,0	42,4	37,8	36,9
Média	68,2	52,4	63,4	66,9	62,5	64,7
Máximo	89,8	61,1	87,5	88,0	87,2	87,1

Figura 58 - Taxas de classificação média entre os três voluntários utilizando SVM com PCA para discriminar entre membros superiores.

DISCRIMINAÇÃO ENTRE LADOS

Este item apresenta as taxas de classificação obtidas na discriminação entre membros superiores do lado direito dos do lado esquerdo, sem diferenciar entre mãos e braços. A Seleção Espacial de Características foi empregada para determinar a influência de cada um dos possíveis conjuntos de eletrodos na taxa de classificação, para cada fase de movimento e para cada indivíduo (S1, S2, S3), bem como para determinar as taxas máximas e mínimas. A seguir, encontram-se os resultados para cada uma das técnicas utilizadas.

LDA

A Figura 59 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

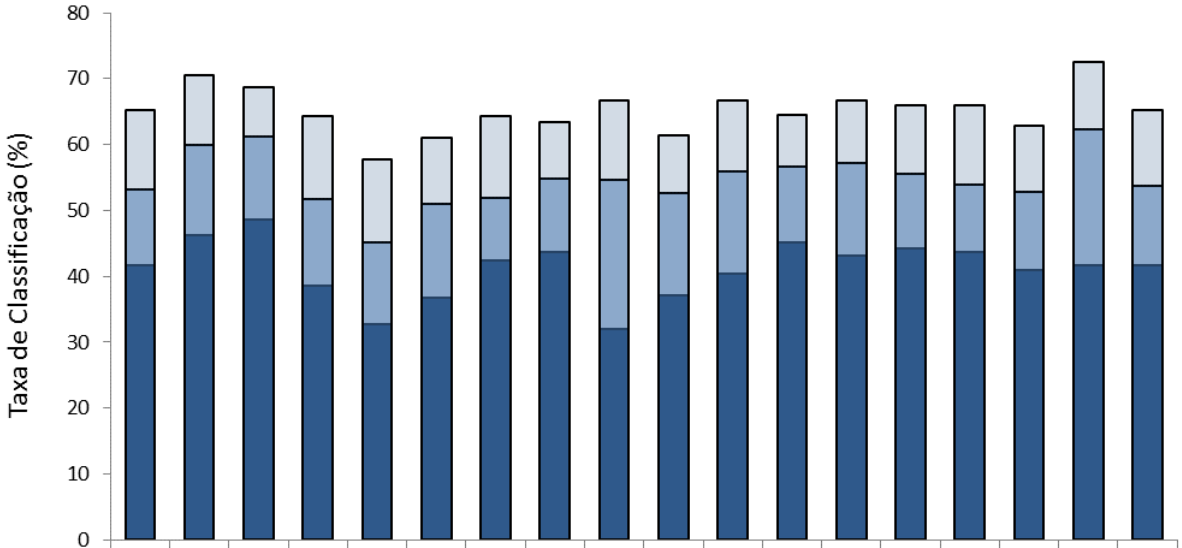

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
Mínima	41,7	46,2	48,6	38,6	32,7	36,8	42,4	43,6	31,9	37,1	40,4	45,1	43,2	44,2	43,8	40,9	41,7	41,7
Média	53,1	59,9	61,2	51,7	45,2	50,9	51,9	54,8	54,7	52,6	55,8	56,6	57,3	55,5	54,0	52,9	62,4	53,6
Máximo	65,2	70,5	68,8	64,4	57,7	61,1	64,4	63,5	66,7	61,4	66,7	64,6	66,7	66,0	66,0	62,9	72,4	65,3

Figura 59 - Taxas de classificação individual média utilizando LDA para discriminar entre lados.

Analogamente ao apresentado acima, na Figura 60 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 72,4% e 58,1%, respectivamente, sendo que a primeira ocorreu na fase de planejamento e com vetor de dados de 2 s, porém a outra ocorreu na fase de planejamento e com vetor de dados de 1 s. O pior resultado foi 31,9%, abaixo do mínimo ao acaso, e ocorreu para a posição estática e com vetor de dados de 1 s. O indivíduo que obteve a melhor taxa de acerto foi S2 e a pior foi S3.

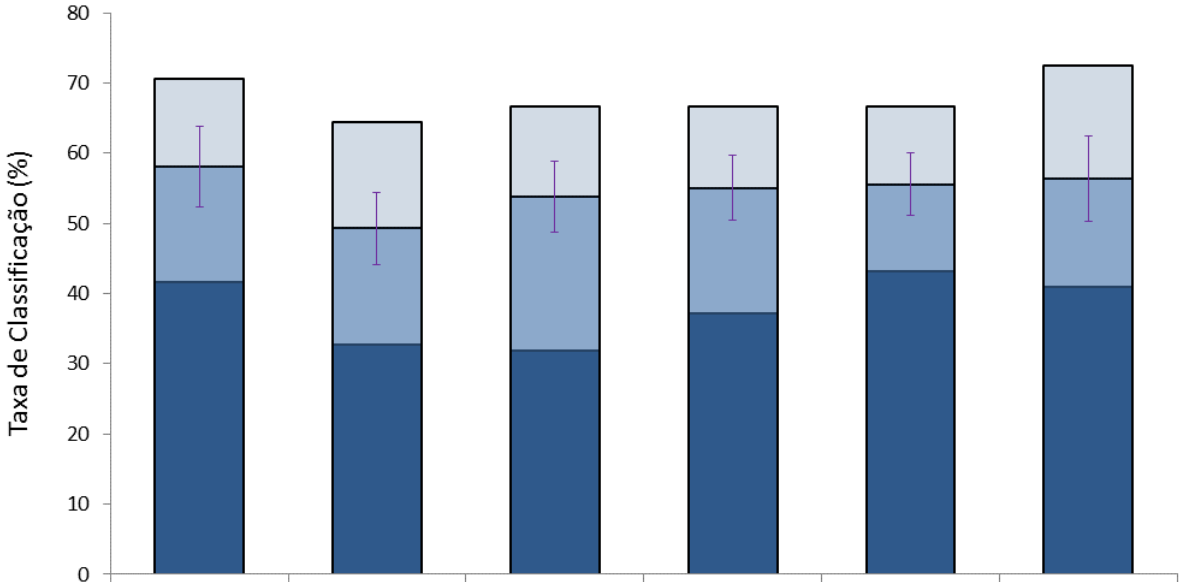

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	41,7	32,7	31,9	37,1	43,2	40,9
Média	58,1	49,3	53,8	55,0	55,6	56,3
Máximo	70,5	64,4	66,7	66,7	66,7	72,4

Figura 60 - Taxas de classificação média entre os três voluntários utilizando LDA para discriminar entre lados.

LDA COM PCA

A Figura 61 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

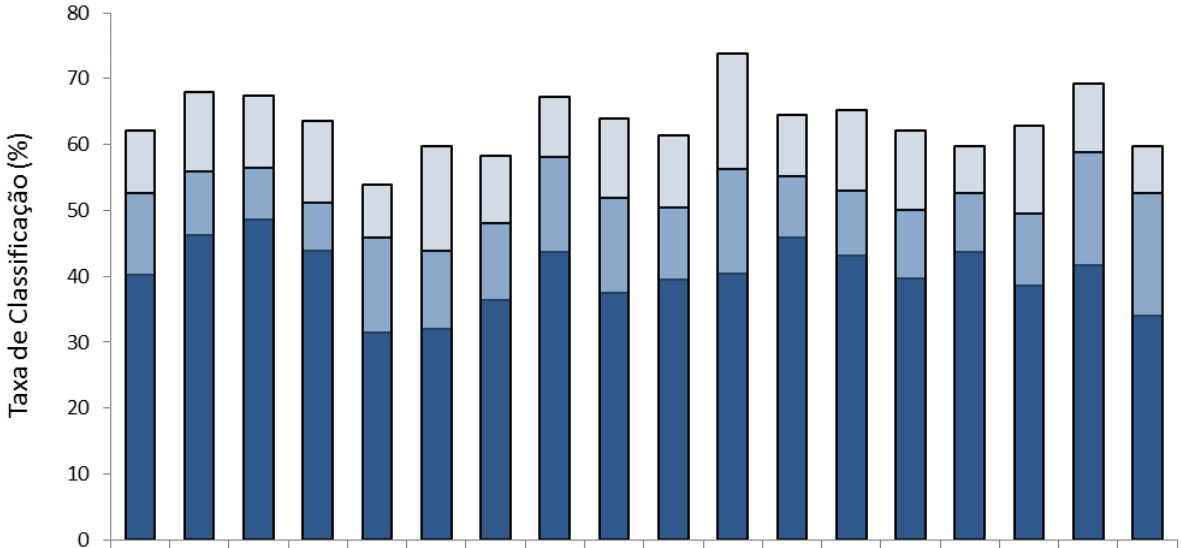

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
Mínima	40,2	46,2	48,6	43,9	31,4	31,9	36,4	43,6	37,5	39,4	40,4	45,8	43,2	39,7	43,8	38,6	41,7	34,0
Média	52,6	56,0	56,5	51,2	45,8	43,9	48,0	58,1	51,9	50,5	56,2	55,2	52,9	50,1	52,6	49,4	58,9	52,7
Máximo	62,1	67,9	67,4	63,6	53,8	59,7	58,3	67,3	63,9	61,4	73,7	64,6	65,2	62,2	59,7	62,9	69,2	59,7

Figura 61 - Taxas de classificação individual média utilizando LDA com PCA para discriminar entre lados.

Analogamente ao apresentado acima, na Figura 62 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 73,7% e 55,0%, respectivamente, sendo que ambas ocorreram na fase de planejamento, porém, a primeira com vetor de dados de 2 s e a segunda com vetor de 1 s. O pior resultado foi 31,4%, abaixo do mínimo ao acaso, e ocorreu para a execução do movimento e com vetor de dados de 1 s. O indivíduo que obteve a melhor taxa de acerto foi S2 e a pior foi S3.

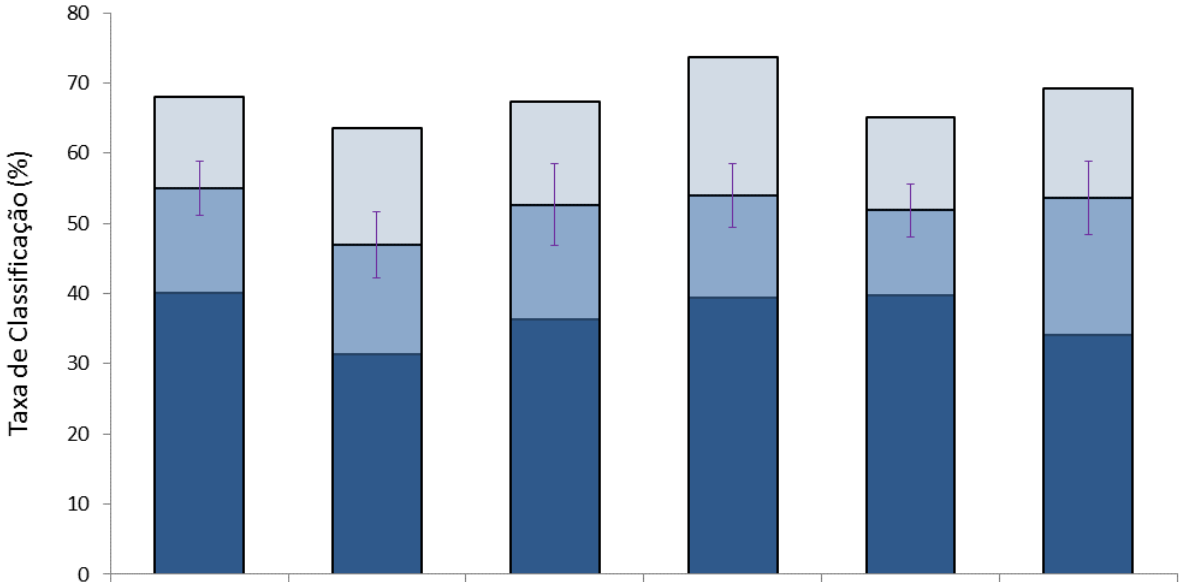

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	40,2	31,4	36,4	39,4	39,7	34,0
Média	55,0	47,0	52,7	54,0	51,9	53,7
Máximo	67,9	63,6	67,3	73,7	65,2	69,2

Figura 62 - Taxas de classificação média entre os três voluntários utilizando LDA com PCA para discriminar entre lados.

SVM

A Figura 63 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

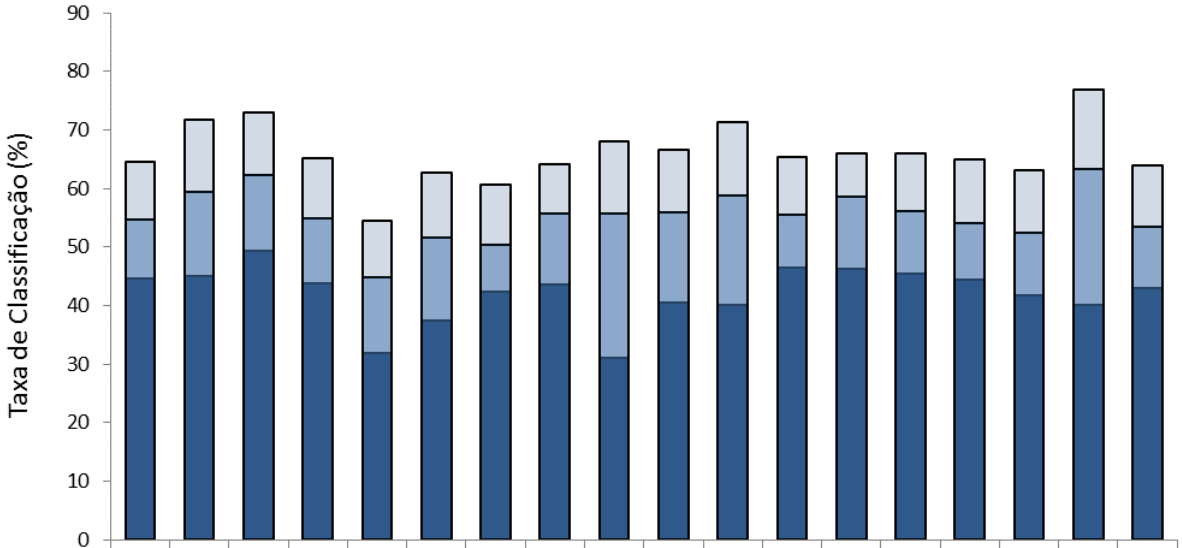

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
Mínima	44,7	45,1	49,3	43,8	31,9	37,3	42,4	43,6	31,2	40,6	40,0	46,5	46,2	45,5	44,3	41,7	40,1	43,0
Média	54,6	59,4	62,3	55,0	44,9	51,5	50,4	55,6	55,7	55,9	58,7	55,5	58,5	56,0	54,2	52,5	63,3	53,4
Máximo	64,5	71,8	73,0	65,2	54,5	62,7	60,7	64,1	68,1	66,7	71,2	65,4	65,9	66,0	64,9	63,0	76,9	63,9

Figura 63 - Taxas de classificação individual média utilizando SVM para discriminar entre lados.

Analogamente ao apresentado acima, na Figura 64 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 76,9% e 58,8%, respectivamente, sendo que a primeira ocorreu para a posição estática e com vetor de dados de 2 s e a outra ocorreu na fase de planejamento e com vetor de dados de 1 s. O pior resultado foi 31,2%, abaixo do mínimo ao acaso, e ocorreu para a execução do movimento e com vetor de dados de 1 s. O indivíduo que obteve a melhor de taxa acerto foi S2 e a pior foi S3.

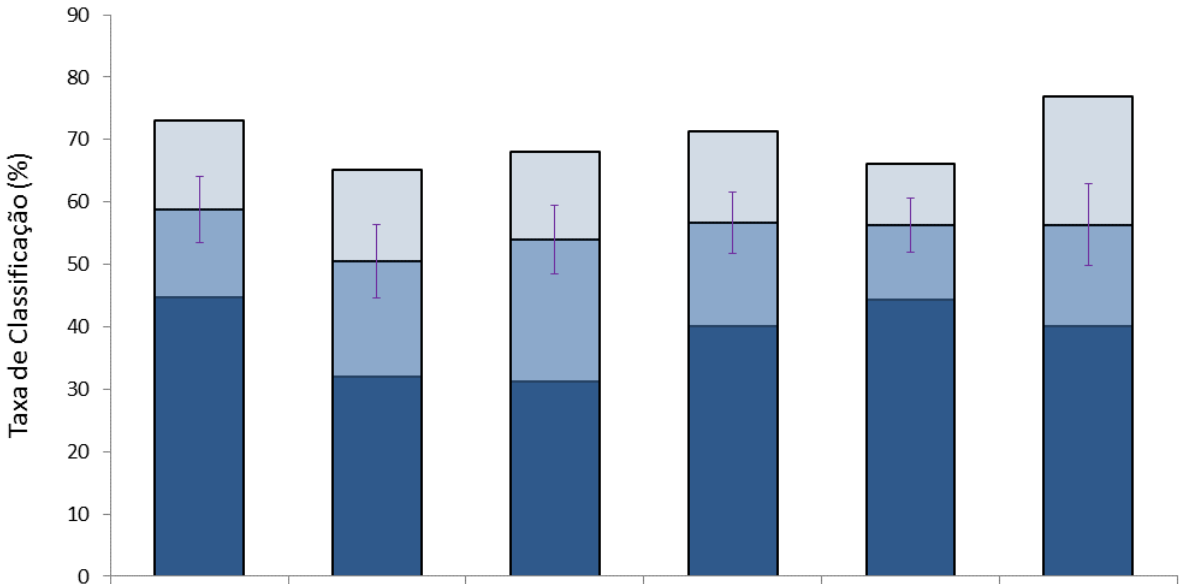

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	44,7	31,9	31,2	40,0	44,3	40,1
Média	58,8	50,5	53,9	56,7	56,2	56,4
Máximo	73,0	65,2	68,1	71,2	66,0	76,9

Figura 64 - Taxas de classificação média entre os três voluntários utilizando SVM para discriminar entre lados.

SVM COM PCA

A Figura 65 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

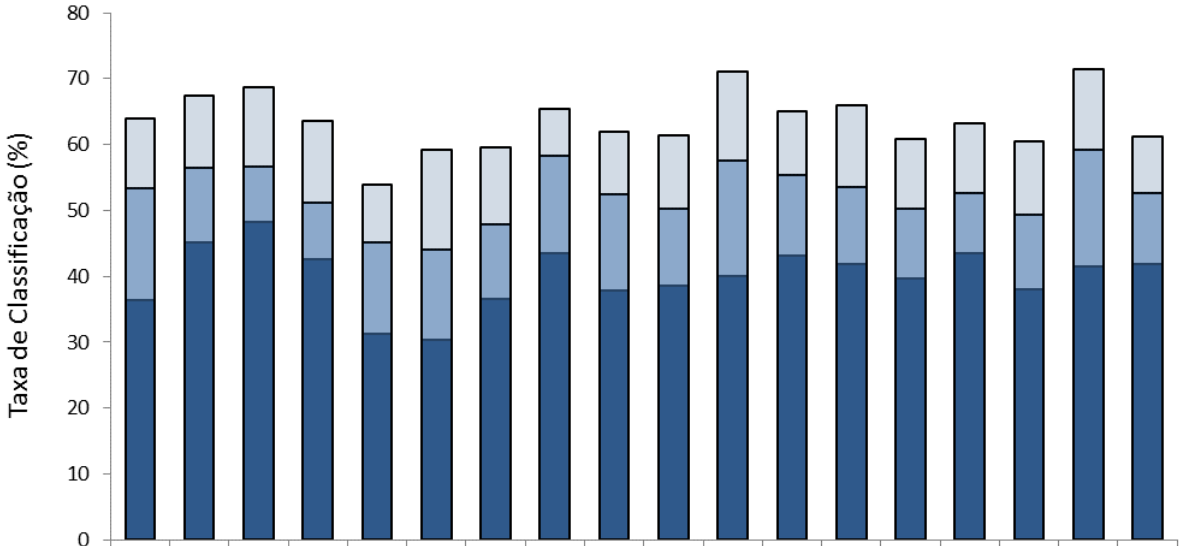

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
Mínima	36,3	45,0	48,2	42,5	31,3	30,4	36,6	43,5	37,7	38,5	40,0	43,1	41,8	39,6	43,4	38,0	41,4	41,9
Média	53,3	56,5	56,6	51,1	45,0	43,9	47,8	58,3	52,4	50,3	57,5	55,3	53,4	50,2	52,6	49,3	59,1	52,6
Máximo	63,9	67,3	68,7	63,6	53,8	59,1	59,5	65,4	61,8	61,4	71,0	65,0	66,0	60,8	63,1	60,3	71,4	61,1

Figura 65 - Taxas de classificação individual média utilizando SVM com PCA para discriminar entre lados.

Analogamente ao apresentado acima, na Figura 66 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 71,4% e 55,5%, respectivamente, sendo que a primeira ocorreu para a posição estática e com vetor de dados de 2 s e a outra ocorreu para a fase de planejamento e com vetor de dados de 1 s. O pior resultado foi 30,4%, abaixo do mínimo ao acaso, e ocorreu para a execução do movimento e com vetor de dados de 1 s. O indivíduo que obteve a melhor taxa de acerto foi S2 e a pior foi S3.

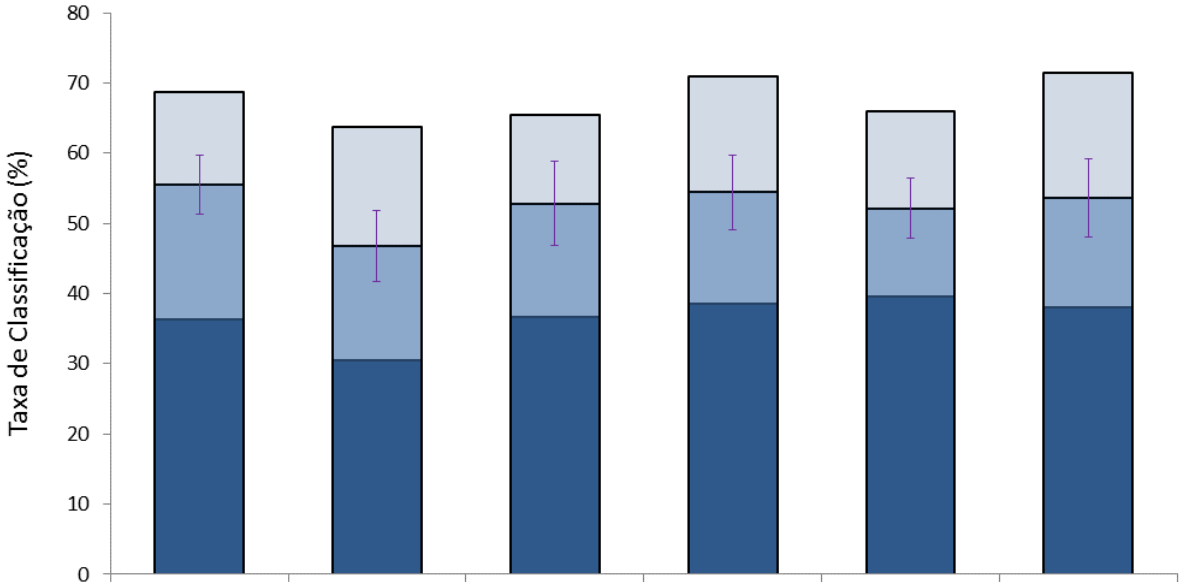

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	36,4	30,4	36,6	38,5	39,6	38,0
Média	55,5	46,7	52,9	54,4	52,1	53,7
Máximo	68,8	63,6	65,5	71,0	66,0	71,4

Figura 66 - Taxas de classificação média entre os três voluntários utilizando SVM com PCA para discriminar entre lados.

DISCRIMINAÇÃO ENTRE MÃOS

Este item apresenta as taxas de classificação obtidas na discriminação entre mão direita e mão esquerda. A Seleção Espacial de Características foi empregada para determinar a influência de cada um dos possíveis conjuntos de eletrodos na taxa de classificação, para cada fase de movimento e para cada indivíduo (S1, S2, S3), bem como para determinar as taxas máximas e mínimas. A seguir, encontram-se os resultados para cada uma das técnicas utilizadas.

LDA

A Figura 67 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

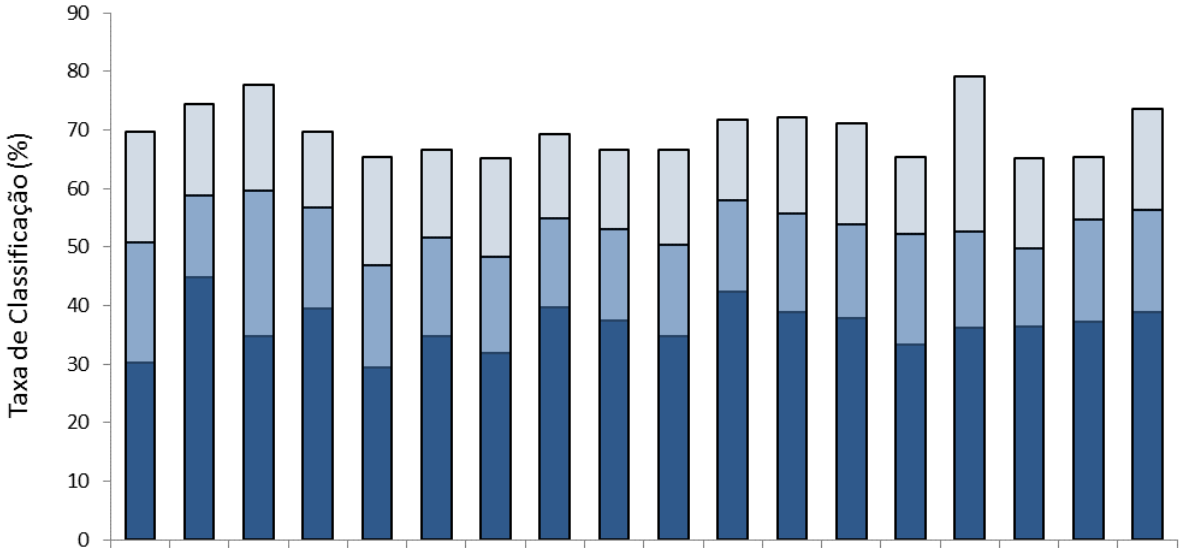

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
Mínima	30,3	44,9	34,7	39,4	29,5	34,7	31,8	39,7	37,5	34,8	42,3	38,9	37,9	33,3	36,1	36,4	37,2	38,9
Média	50,7	58,7	59,6	56,7	46,9	51,6	48,3	54,9	53,1	50,4	58,0	55,7	53,8	52,2	52,7	49,7	54,6	56,3
Máximo	69,7	74,4	77,8	69,7	65,4	66,7	65,2	69,2	66,7	66,7	71,8	72,2	71,2	65,4	79,2	65,2	65,4	73,6

Figura 67 - Taxas de classificação individual média utilizando LDA para discriminar entre mãos.

Analogamente ao apresentado acima, na Figura 68 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 79,2% e 56,3%, respectivamente, sendo que a primeira ocorreu para a execução do movimento com vetor de dados de 2 s e a outra ocorreu para a fase de planejamento e com vetor de dados de 1 s. O pior resultado foi 29,5%, abaixo do mínimo ao acaso, e ocorreu para a execução do movimento e com vetor de dados de 1 s. O indivíduo que obteve a melhor taxa de acerto foi S3 e a pior foi S2.

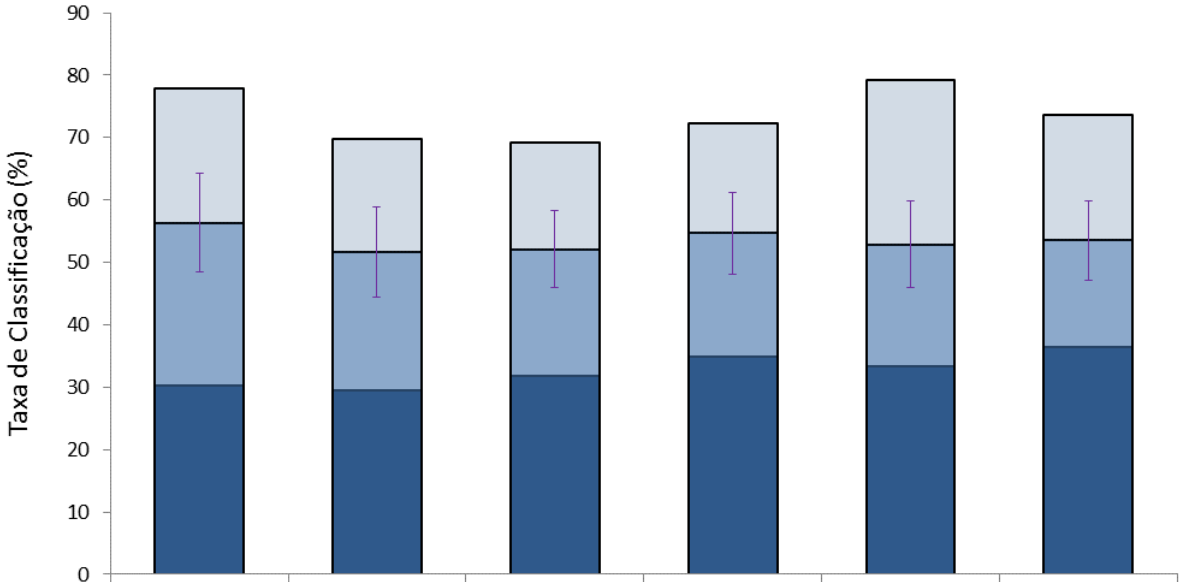

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	30,3	29,5	31,8	34,8	33,3	36,4
Média	56,3	51,7	52,1	54,7	52,9	53,5
Máximo	77,8	69,7	69,2	72,2	79,2	73,6

Figura 68 - Taxas de classificação média entre os três voluntários utilizando LDA para discriminar entre mãos.

LDA COM PCA

A Figura 69 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

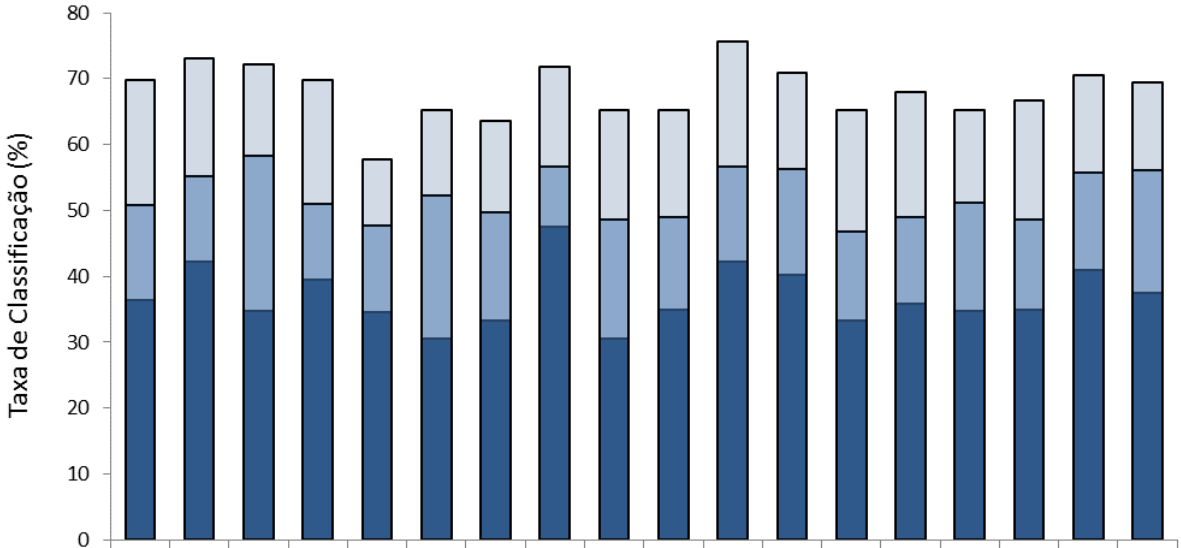

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
	Planejamento			Movimento			Posição Estática			Planejamento			Movimento			Posição Estática		
	Duração 1s									Duração 2s								
Mínima	36,4	42,3	34,7	39,4	34,6	30,6	33,3	47,4	30,6	34,8	42,3	40,3	33,3	35,9	34,7	34,8	41,0	37,5
Média	50,8	55,3	58,2	50,9	47,7	52,2	49,8	56,6	48,7	49,0	56,6	56,4	46,8	48,9	51,1	48,5	55,8	56,0
Máximo	69,7	73,1	72,2	69,7	57,7	65,3	63,6	71,8	65,3	65,2	75,6	70,8	65,2	67,9	65,3	66,7	70,5	69,4

Figura 69 - Taxas de classificação individual média utilizando LDA com PCA para discriminar entre mãos.

Analogamente ao apresentado acima, na Figura 70 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 75,6% e 54,8%, respectivamente, sendo que ambas ocorreram para a fase de planejamento, a primeira com vetor de dados de 1 s e a outra com vetor de dados de 1 s. O pior resultado foi 30,6%, abaixo do mínimo ao acaso, e ocorreu para a execução do movimento e para a posição estática, ambas com vetor de dados de 1 s. O indivíduo que obteve a melhor taxa de acerto foi S2 e a pior foi S3.

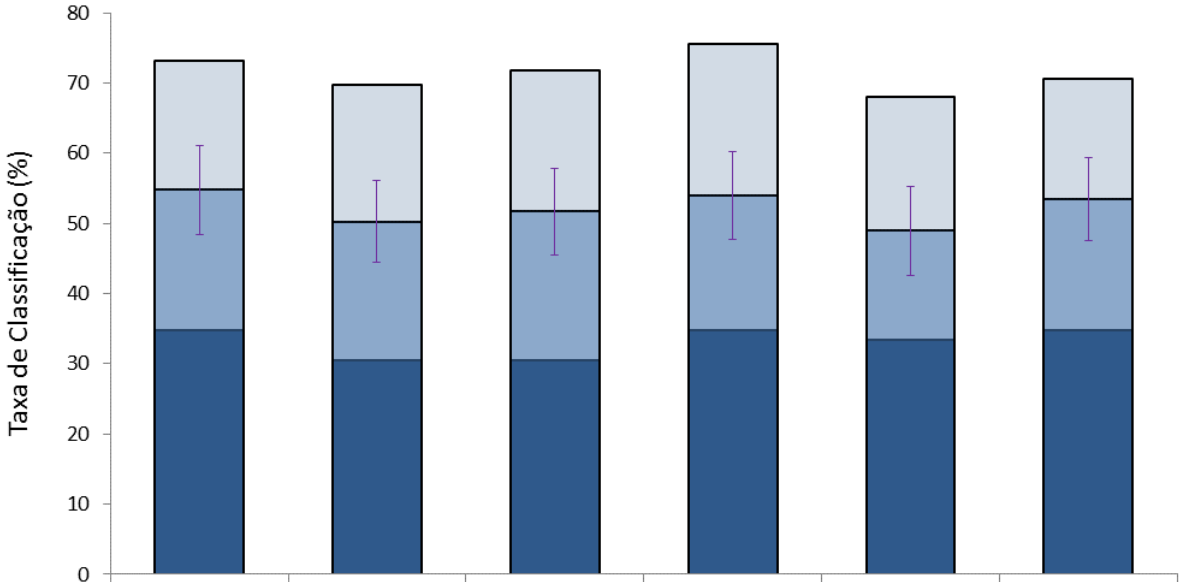

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	34,7	30,6	30,6	34,8	33,3	34,8
Média	54,8	50,3	51,7	54,0	48,9	53,4
Máximo	73,1	69,7	71,8	75,6	67,9	70,5

Figura 70 - Taxas de classificação média entre os três voluntários utilizando LDA com PCA para discriminar entre mãos.

SVM

A Figura 71 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

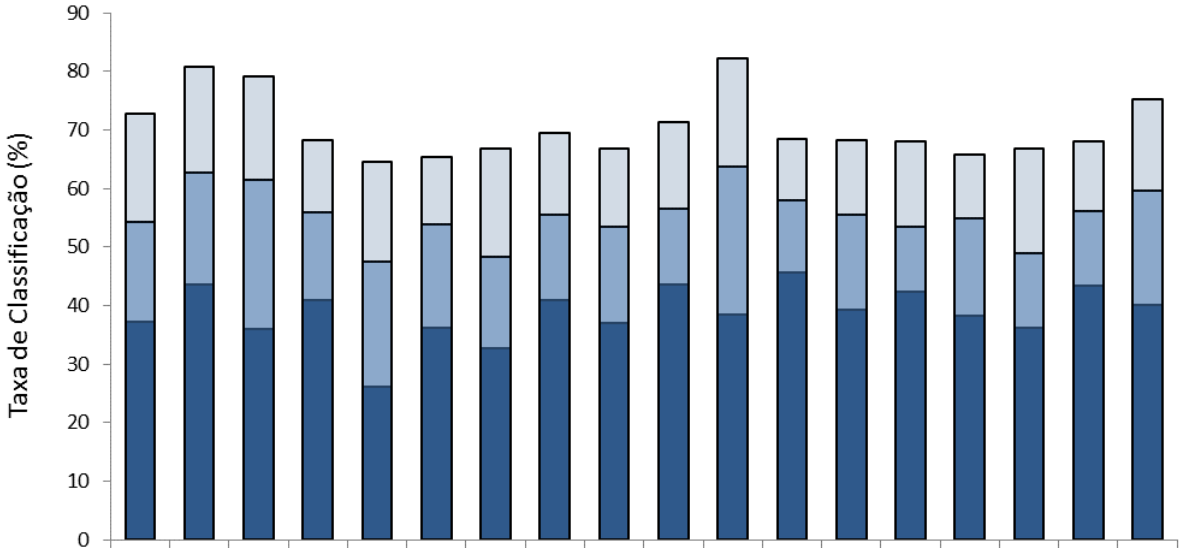

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
	Planejamento			Movimento			Posição Estática			Planejamento			Movimento			Posição Estática		
	Duração 1s									Duração 2s								
Mínima	37,3	43,5	36,0	40,9	26,1	36,1	32,7	40,9	37,0	43,6	38,4	45,5	39,2	42,3	38,3	36,1	43,3	40,0
Média	54,2	62,7	61,4	55,9	47,3	53,7	48,3	55,5	53,4	56,5	63,6	58,0	55,4	53,4	54,8	48,8	56,1	59,6
Máximo	72,8	80,7	79,1	68,3	64,4	65,3	66,7	69,4	66,7	71,3	82,1	68,4	68,3	67,9	65,8	66,7	67,9	75,3

Figura 71 - Taxas de classificação individual média utilizando SVM para discriminar entre mãos.

Analogamente ao apresentado acima, na Figura 72 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 82,1% e 59,5%, respectivamente, sendo que ambas ocorreram para a fase de planejamento, sendo a primeira com vetor de dados de 2 s e a outra com vetor de 1 s. O pior resultado foi 26,1%, abaixo do mínimo ao acaso, e ocorreu para a execução do movimento e com vetor de dados de 1 s. O indivíduo que obteve a melhor taxa de acerto foi S2 e, curiosamente, também apresentou a pior taxa.

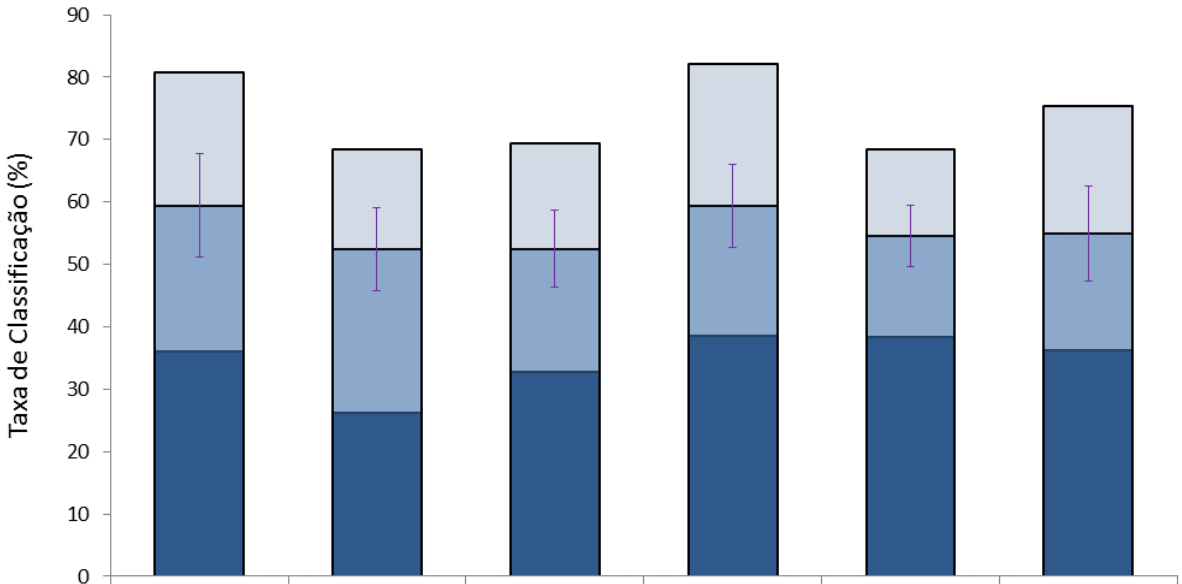

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	36,1	26,2	32,8	38,5	38,3	36,2
Média	59,5	52,4	52,5	59,4	54,6	54,9
Máximo	80,8	68,3	69,4	82,1	68,3	75,3

Figura 72 - Taxas de classificação média entre os três voluntários utilizando SVM para discriminar entre mãos.

SVM COM PCA

A Figura 73 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

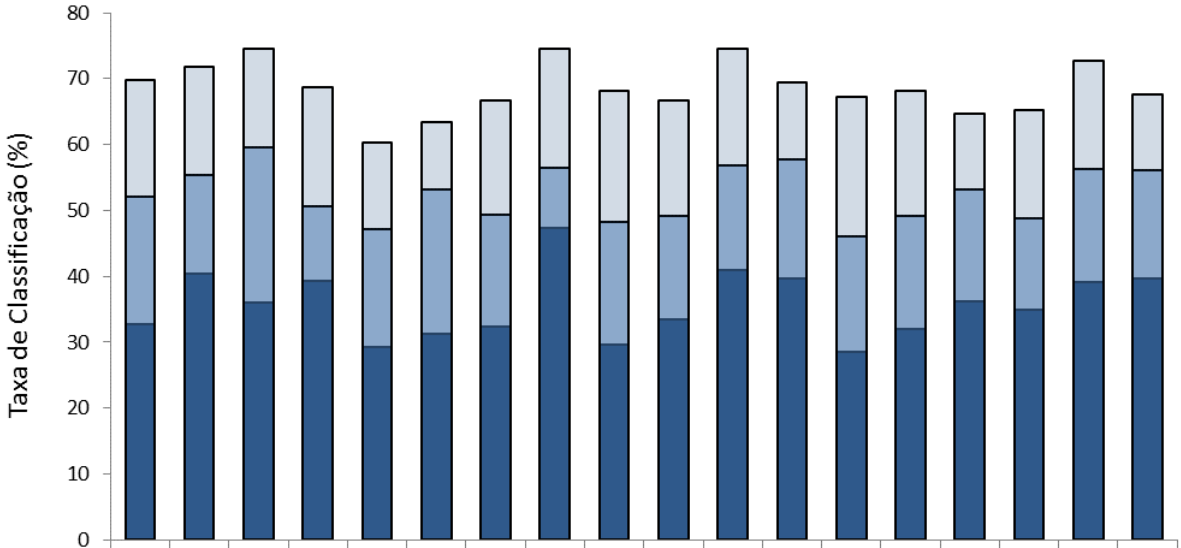

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
	Planejamento			Movimento			Posição Estática			Planejamento			Movimento			Posição Estática					
	Duração 1s									Duração 2s											
Mínima	32,8	40,4	36,1	39,2	29,2	31,2	32,3	47,4	29,5	33,4	41,0	39,6	28,5	31,9	36,2	34,8	39,2	39,6			
Média	52,0	55,3	59,6	50,6	47,1	53,2	49,4	56,5	48,2	49,1	56,9	57,7	46,0	49,1	53,2	48,8	56,3	56,1			
Máximo	69,7	71,9	74,5	68,6	60,3	63,3	66,7	74,6	68,1	66,7	74,6	69,5	67,2	68,1	64,6	65,2	72,8	67,5			

Figura 73 - Taxas de classificação individual média utilizando SVM com PCA para discriminar entre mãos.

Analogamente ao apresentado acima, na Figura 74 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 74,6% e 55,6%, respectivamente, sendo que ambas ocorreram para a fase de planejamento, sendo a primeira com vetor de dados de 2 s e a outra com vetor de 1 s. O pior resultado foi 28,5%, abaixo do mínimo ao acaso, e ocorreu para a execução do movimento e com vetor de dados de 2 s. O indivíduo que obteve a melhor taxa de acerto foi S2 e a pior foi S1.

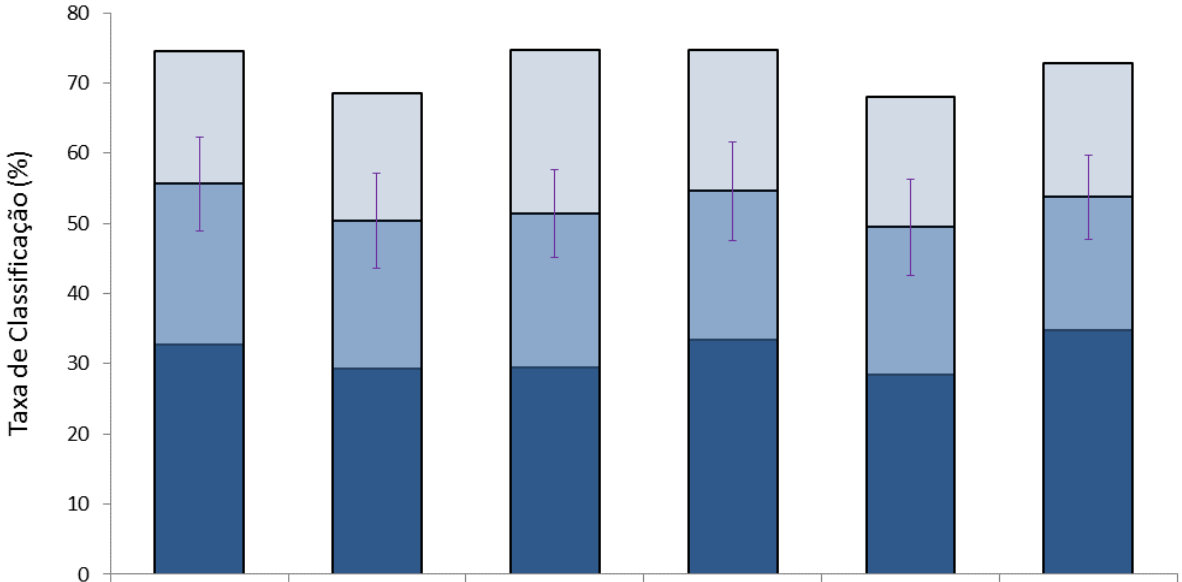

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	32,8	29,2	29,5	33,4	28,5	34,8
Média	55,6	50,3	51,4	54,6	49,5	53,7
Máximo	74,5	68,6	74,6	74,6	68,1	72,8

Figura 74 - Taxas de classificação média entre os três voluntários utilizando SVM com PCA para discriminar entre mãos.

DISCRIMINAÇÃO ENTRE BRAÇOS

Este item apresenta as taxas de classificação obtidas na discriminação entre braço direito e braço esquerdo. A Seleção Espacial de Características foi empregada para determinar a influência de cada um dos possíveis conjuntos de eletrodos na taxa de classificação, para cada fase de movimento e para cada indivíduo (S1, S2, S3), bem como para determinar as taxas máximas e mínimas. A seguir, encontram-se os resultados para cada uma das técnicas utilizadas.

LDA

A Figura 75 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

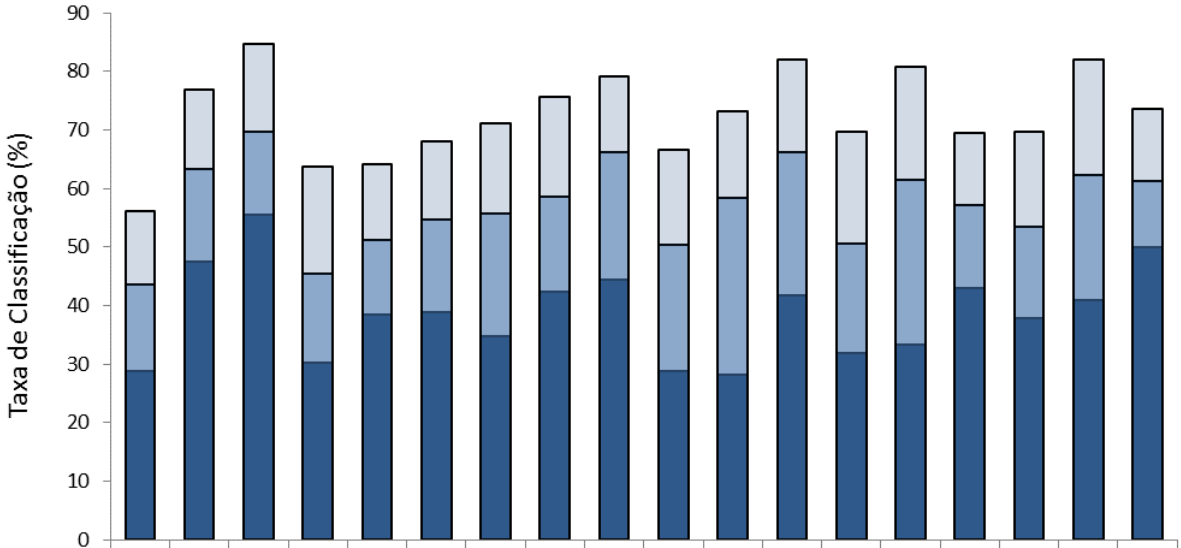

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
	Planejamento			Movimento			Posição Estática			Planejamento			Movimento			Posição Estática		
	Duração 1s									Duração 2s								
Mínima	28,8	47,4	55,6	30,3	38,5	38,9	34,8	42,3	44,4	28,8	28,2	41,7	31,8	33,3	43,1	37,9	41,0	50,0
Média	43,7	63,2	69,7	45,5	51,3	54,7	55,7	58,7	66,1	50,3	58,3	66,1	50,6	61,5	57,2	53,4	62,2	61,3
Máximo	56,1	76,9	84,7	63,6	64,1	68,1	71,2	75,6	79,2	66,7	73,1	81,9	69,7	80,8	69,4	69,7	82,1	73,6

Figura 75 - Taxas de classificação individual média utilizando LDA para discriminar entre braços.

Analogamente ao apresentado acima, na Figura 76 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 84,7% e 60,2%, respectivamente, sendo que a primeira ocorreu para a fase de planejamento e a outra para a posição estática, ambas com vetor de 1 s. O pior resultado foi 28,2%, abaixo do mínimo ao acaso, e ocorreu para a fase de planejamento e com vetor de dados de 2 s. O indivíduo que obteve a melhor taxa de acerto foi S3 e a pior foi S2.

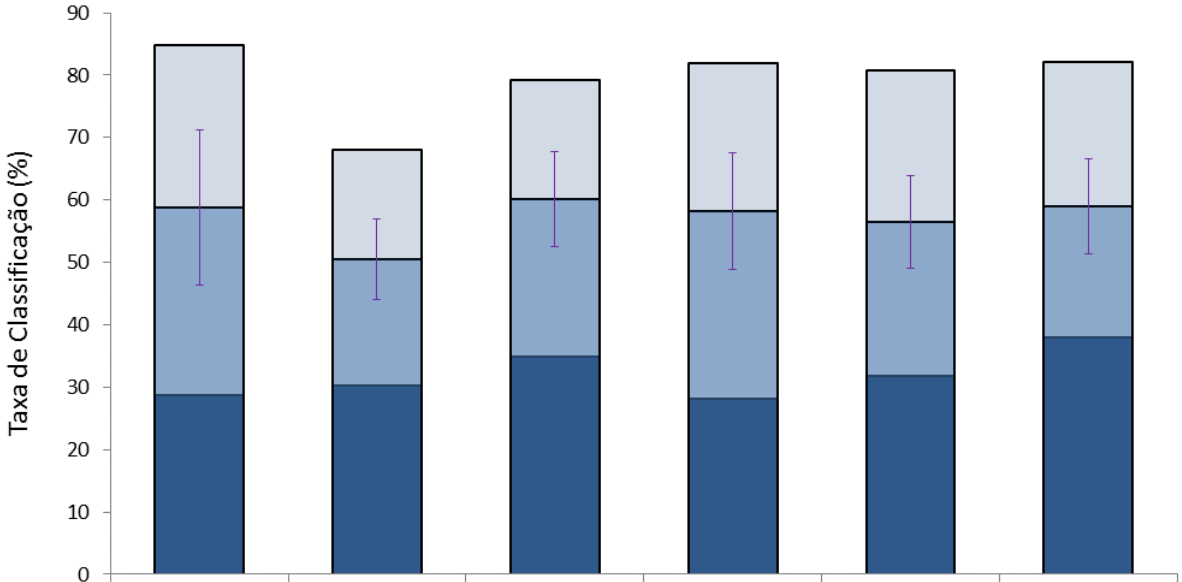

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	28,8	30,3	34,8	28,2	31,8	37,9
Média	58,9	50,5	60,2	58,2	56,4	59,0
Máximo	84,7	68,1	79,2	81,9	80,8	82,1

Figura 76 - Taxas de classificação média entre os três voluntários utilizando LDA para discriminar entre braços.

LDA COM PCA

A Figura 77 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

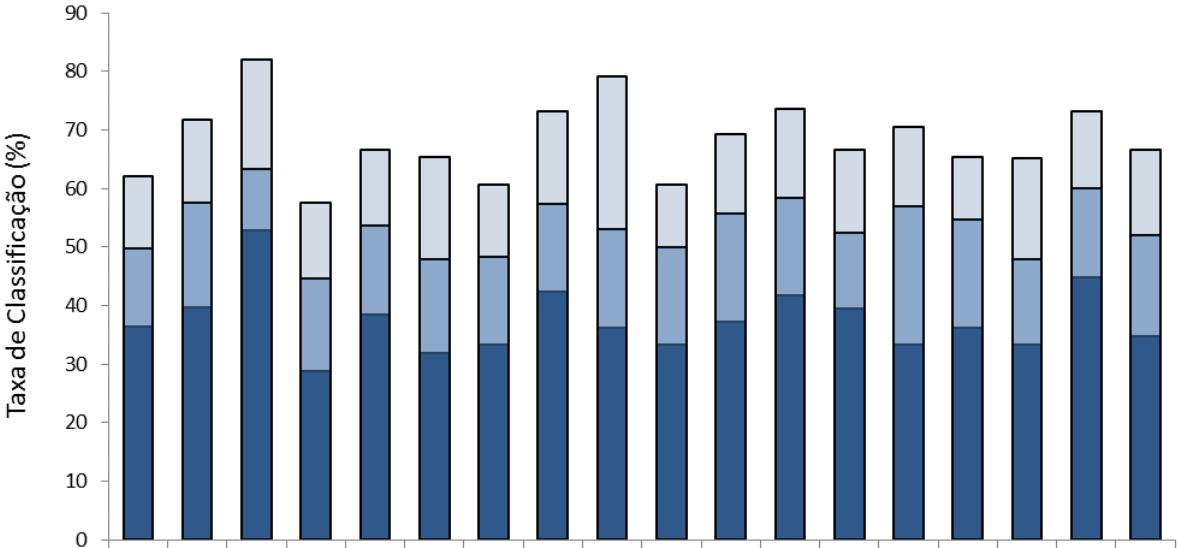

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
	Planejamento			Movimento			Posição Estática			Planejamento			Movimento			Posição Estática		
	Duração 1s									Duração 2s								
Mínima	36,4	39,7	52,8	28,8	38,5	31,9	33,3	42,3	36,1	33,3	37,2	41,7	39,4	33,3	36,1	33,3	44,9	34,7
Média	49,8	57,6	63,4	44,6	53,6	47,9	48,2	57,4	53,1	49,9	55,7	58,3	52,4	56,9	54,8	47,8	59,9	52,0
Máximo	62,1	71,8	81,9	57,6	66,7	65,3	60,6	73,1	79,2	60,6	69,2	73,6	66,7	70,5	65,3	65,2	73,1	66,7

Figura 77 - Taxas de classificação individual média utilizando LDA com PCA para discriminar entre braços.

Analogamente ao apresentado acima, na Figura 78 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 81,9% e 56,9%, respectivamente, sendo que ambas ocorreram para a fase de planejamento e com vetor de dados de 1 s. O pior resultado foi 28,8%, abaixo do mínimo ao acaso, e ocorreu para a execução do movimento e com vetor de dados de 1 s. O indivíduo que obteve a melhor taxa de acerto foi S3 e a pior foi S1.

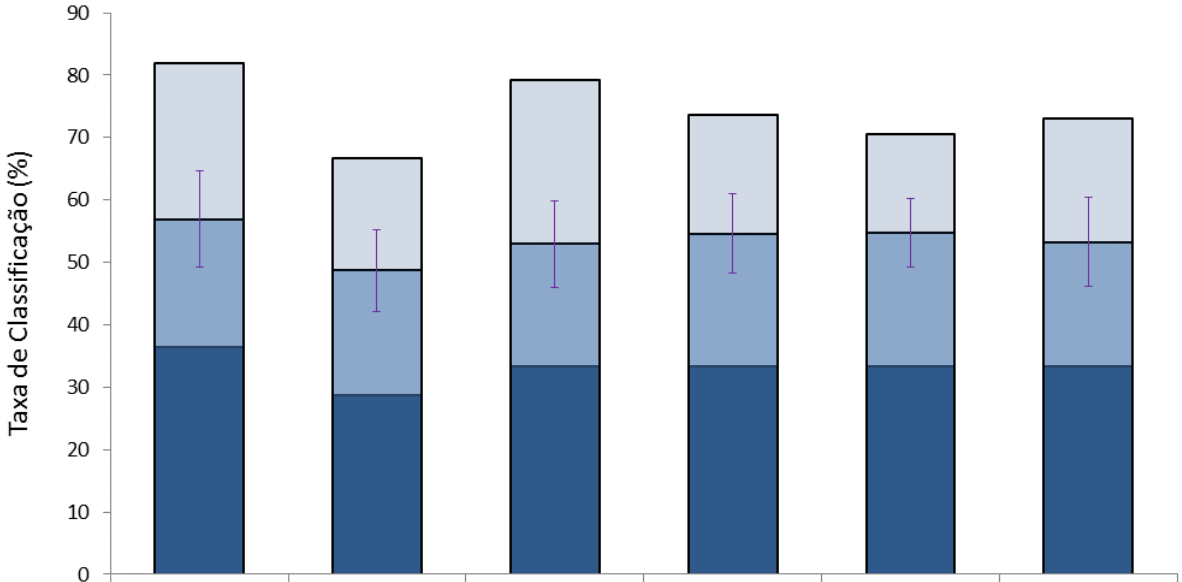

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	36,4	28,8	33,3	33,3	33,3	33,3
Média	56,9	48,7	52,9	54,6	54,7	53,2
Máximo	81,9	66,7	79,2	73,6	70,5	73,1

Figura 78 - Taxas de classificação média entre os três voluntários utilizando LDA com PCA para discriminar entre braços.

SVM

A Figura 79 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

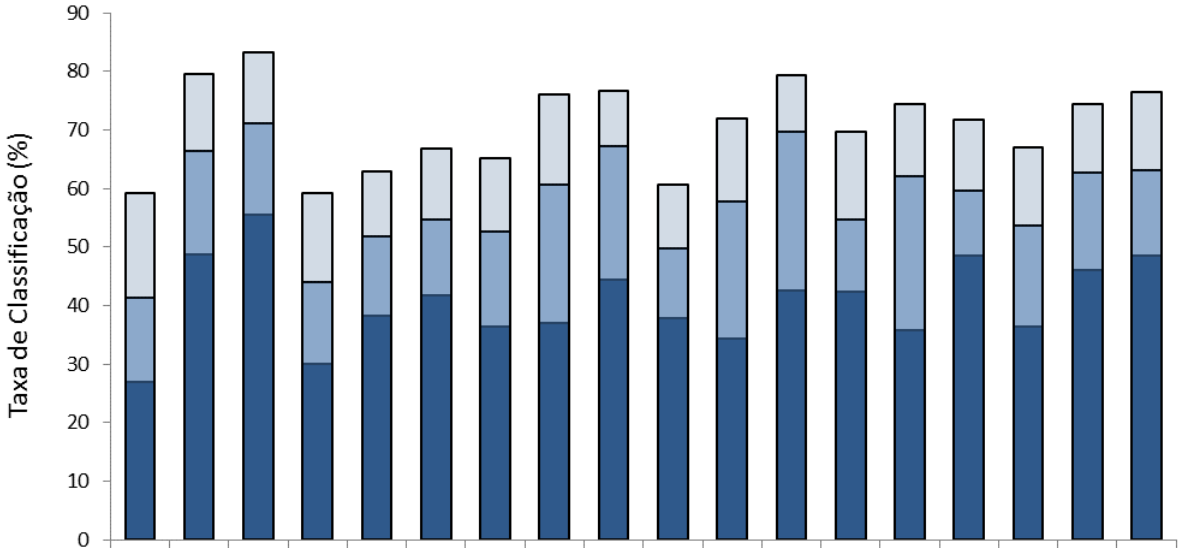

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
Mínima	26,9	48,7	55,5	30,0	38,1	41,6	36,3	36,9	44,4	37,8	34,3	42,5	42,3	35,8	48,5	36,3	46,1	48,6
Média	41,3	66,3	71,2	43,9	51,7	54,5	52,7	60,7	67,2	49,7	57,7	69,5	54,7	62,1	59,6	53,6	62,7	63,0
Máximo	59,3	79,4	83,3	59,1	62,8	66,7	65,1	76,0	76,5	60,6	72,0	79,3	69,6	74,4	71,6	66,9	74,3	76,4

Figura 79 - Taxas de classificação individual média utilizando SVM para discriminar entre braços.

Analogamente ao apresentado acima, na Figura 80 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 83,3% e 60,2%, respectivamente, sendo a primeira para a fase de planejamento e a outra para a posição estática, ambas com vetor de dados de 1 s. O pior resultado foi 26,9%, abaixo do mínimo ao acaso, e ocorreu para a fase de planejamento e com vetor de dados de 1 s. O indivíduo que obteve a melhor taxa de acerto foi S3 e a pior foi S1.

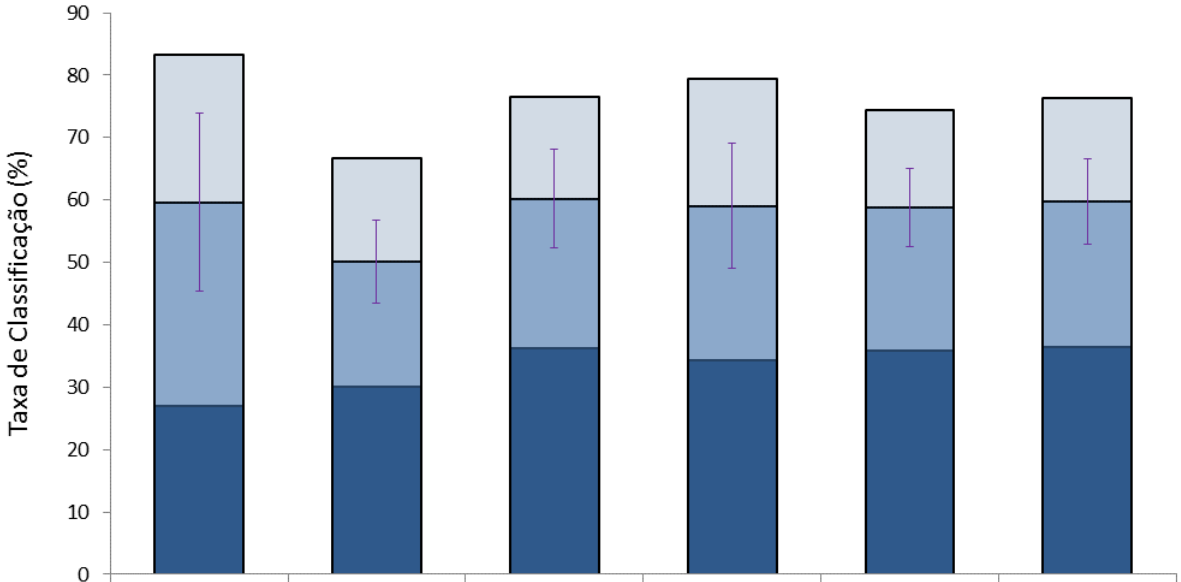

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	26,9338	30,0093	36,3134	34,3583	35,8603	36,3636
Média	59,6169	50,1011	60,2225	59,0167	58,8454	59,7913
Máximo	83,3333	66,7183	76,5734	79,3706	74,4232	76,4093

Figura 80 - Taxas de classificação média entre os três voluntários utilizando SVM para discriminar entre braços.

SVM COM PCA

A Figura 81 apresenta as taxas de classificação médias individuais obtidas pela técnica em questão, destacando em tabela adjunta ao gráfico os níveis mínimos, médios e máximos atingidos em função da aplicação da técnica de Seleção Espacial de Características, para cada fase do movimento e com cada vetor de dados considerados nos experimentos.

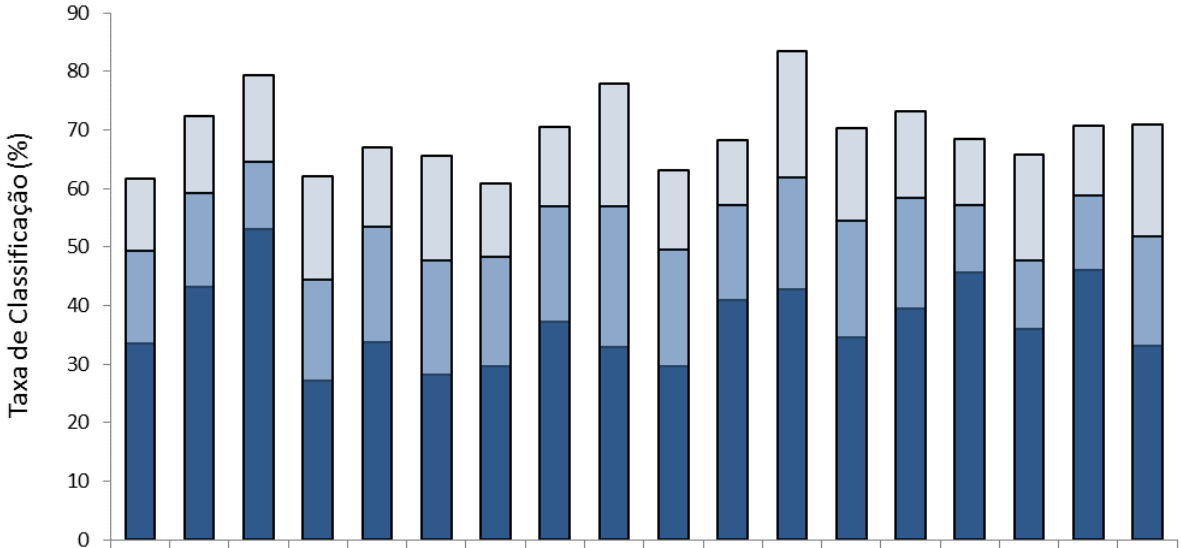

	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
	Planejamento			Movimento			Posição Estática			Planejamento			Movimento			Posição Estática		
	Duração 1s									Duração 2s								
Mínima	33,5	43,1	53,1	27,1	33,8	28,2	29,7	37,3	32,9	29,5	41,0	42,8	34,5	39,4	45,7	35,9	46,0	33,1
Média	49,3	59,2	64,6	44,5	53,4	47,6	48,2	57,0	56,9	49,6	57,2	61,9	54,5	58,5	57,2	47,7	58,7	51,8
Máximo	61,7	72,3	79,4	62,1	67,1	65,6	60,8	70,6	77,9	63,1	68,2	83,4	70,4	73,1	68,4	65,9	70,6	70,8

Figura 81 - Taxas de classificação individual média utilizando SVM com PCA para discriminar entre braços.

Analogamente ao apresentado acima, na Figura 82 observam-se as taxas de classificação médias entre os três indivíduos, bem como a menor e a maior taxa individual, estando representado ao redor do valor médio o desvio padrão em uma linha vertical. As melhores taxas de acerto individual e média foram de 83,4% e 57,5%, respectivamente, sendo que ambas ocorreram para a fase de planejamento, sendo a primeira com vetor de dados de 2 s e a outra com vetor de 1 s. O pior resultado foi 27,1%, abaixo do mínimo ao acaso, e ocorreu para a execução do movimento e com vetor de dados de 1 s. O indivíduo que obteve a melhor taxa de acerto foi S3 e a pior foi S1.

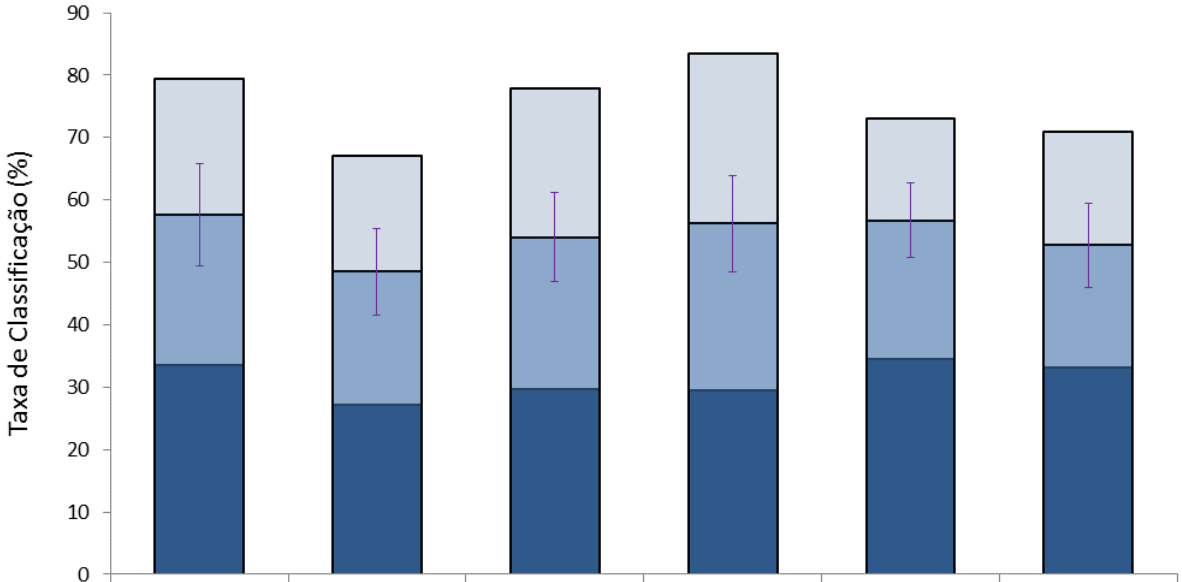

	Planejamento	Movimento	Posição Estática	Planejamento	Movimento	Posição Estática
	Duração 1s			Duração 2s		
Mínimo	33,5	27,1	29,7	29,5	34,5	33,1
Média	57,7	48,5	54,0	56,2	56,7	52,7
Máximo	79,4	67,1	77,9	83,4	73,1	70,8

Figura 82 - Taxas de classificação média entre os três voluntários utilizando SVM com PCA para discriminar entre braços.

APÊNDICE C – Mapeamento das Regiões Cerebrais em Função dos Resultados da Seleção Espacial de Características

As Tabelas Tabela **10** a Tabela **29** mostram os eletrodos que estavam presentes nas melhores taxas de acerto em cada cenário e técnica de classificação consideradas na presente pesquisa, apresentando a fase do movimento, o tamanho do vetor de dados e o voluntário para cada caso, estando destacado em vermelho os eletrodos presentes. Essas tabelas demonstram graficamente a variabilidade entre os voluntários e explicitam para quais voluntários a taxa de acerto ocorrem em mais de uma configuração de eletrodos.

Tabela 10 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA para discriminar entre membros superiores.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1								
Planejamento	1s	S2								
Planejamento	1s	S3								
Planejamento	2s	S1								
Planejamento	2s	S2								
Planejamento	2s	S3								
Planejamento	2s	S3								
Execução	1s	S1								
Execução	1s	S2								
Execução	1s	S3								
Execução	2s	S1								
Execução	2s	S2								
Execução	2s	S3								
Posição Estática	1s	S1								
Posição Estática	1s	S2								
Posição Estática	1s	S3								
Posição Estática	2s	S1								
Posição Estática	2s	S2								
Posição Estática	2s	S3								

Tabela 11 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA com PCA para discriminar entre membros superiores.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1				■	■		■	■
Planejamento	1s	S2	■	■					■	■
Planejamento	1s	S2	■	■			■		■	■
Planejamento	1s	S3			■		■	■		■
Planejamento	2s	S1				■			■	
Planejamento	2s	S1	■							■
Planejamento	2s	S1	■						■	
Planejamento	2s	S1	■	■					■	
Planejamento	2s	S2		■	■		■		■	
Planejamento	2s	S3	■		■			■		
Execução	1s	S1		■				■		■
Execução	1s	S2		■			■			
Execução	1s	S2		■	■		■		■	
Execução	1s	S3	■	■			■			
Execução	2s	S1	■			■				■
Execução	2s	S2		■		■	■	■		
Execução	2s	S2		■	■		■			■
Execução	2s	S3					■			■
Posição Estática	1s	S1								■
Posição Estática	1s	S1							■	■
Posição Estática	1s	S1			■					■
Posição Estática	1s	S2		■					■	
Posição Estática	1s	S3			■	■			■	
Posição Estática	2s	S1		■	■			■		
Posição Estática	2s	S2	■							■
Posição Estática	2s	S3					■			

Tabela 12 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM para discriminar entre membros superiores.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1	■	■						
Planejamento	1s	S2	■		■		■		■	
Planejamento	1s	S2	■	■				■	■	
Planejamento	1s	S3				■				■
Planejamento	2s	S1	■	■		■		■	■	■
Planejamento	2s	S2	■							
Planejamento	2s	S3	■			■	■			■
Execução	1s	S1	■	■	■		■	■	■	■
Execução	1s	S2			■					■
Execução	1s	S3	■		■			■		
Execução	2s	S1	■	■					■	■
Execução	2s	S1	■	■	■	■				
Execução	2s	S2		■		■				
Execução	2s	S3	■		■	■		■		■
Posição Estática	1s	S1	■			■		■	■	
Posição Estática	1s	S2		■			■	■	■	
Posição Estática	1s	S3	■		■	■			■	■
Posição Estática	2s	S1	■			■	■			
Posição Estática	2s	S2		■						
Posição Estática	2s	S3		■		■			■	■

Tabela 13 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM com PCA para discriminar entre membros superiores.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1		■						■
Planejamento	1s	S2		■		■			■	
Planejamento	1s	S3	■		■			■		■
Planejamento	2s	S1						■		■
Planejamento	2s	S2		■	■		■		■	
Planejamento	2s	S3			■		■		■	
Execução	1s	S1		■				■		■
Execução	1s	S2	■		■	■	■	■	■	
Execução	1s	S3	■	■			■			
Execução	2s	S1				■				■
Execução	2s	S2	■	■		■	■			
Execução	2s	S3					■			■
Posição Estática	1s	S1								■
Posição Estática	1s	S1							■	■
Posição Estática	1s	S2		■				■		
Posição Estática	1s	S3	■		■	■				
Posição Estática	2s	S1	■		■			■		
Posição Estática	2s	S2	■	■	■					
Posição Estática	2s	S3	■			■	■	■		

Tabela 14 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA para discriminar entre lados.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1			■	■	■	■	■	
Planejamento	1s	S2					■	■	■	
Planejamento	1s	S2			■		■	■		■
Planejamento	1s	S2	■		■	■	■	■		■
Planejamento	1s	S3		■	■	■		■	■	
Planejamento	1s	S3	■	■	■	■		■	■	■
Planejamento	2s	S1	■	■	■	■	■			■
Planejamento	2s	S1	■	■	■	■	■	■		
Planejamento	2s	S2	■	■				■	■	
Planejamento	2s	S3						■		
Execução	1s	S1			■	■				
Execução	1s	S2			■				■	■
Execução	1s	S3			■	■				
Execução	2s	S1	■		■	■	■	■	■	■
Execução	2s	S2				■		■	■	
Execução	2s	S3	■				■	■		■
Posição Estática	1s	S1		■	■		■			
Posição Estática	1s	S2		■	■		■			■
Posição Estática	1s	S2	■		■		■			■
Posição Estática	1s	S3			■	■		■	■	■
Posição Estática	2s	S1				■	■			■
Posição Estática	2s	S2		■		■	■	■		
Posição Estática	2s	S2	■		■		■	■	■	
Posição Estática	2s	S3				■		■		

Tabela 15 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA com PCA para discriminar entre lados.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1	■			■	■		■	■
Planejamento	1s	S2					■	■		
Planejamento	1s	S3						■	■	
Planejamento	2s	S1					■		■	
Planejamento	2s	S2			■		■	■		
Planejamento	2s	S3						■		
Execução	1s	S1				■				
Execução	1s	S2			■					
Execução	1s	S3				■			■	
Execução	2s	S1					■		■	
Execução	2s	S1	■	■		■				
Execução	2s	S2					■	■		
Execução	2s	S3						■		
Execução	2s	S3	■	■				■	■	
Posição Estática	1s	S1	■			■				
Posição Estática	1s	S2		■	■			■	■	
Posição Estática	1s	S3				■			■	
Posição Estática	2s	S1						■		■
Posição Estática	2s	S2			■		■	■		
Posição Estática	2s	S3						■		

Tabela 16 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM para discriminar entre lados.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1	■		■		■	■	■	
Planejamento	1s	S2					■	■	■	
Planejamento	1s	S3			■	■			■	
Planejamento	2s	S1		■	■		■	■		
Planejamento	2s	S2	■	■	■		■	■		
Planejamento	2s	S3			■	■		■	■	■
Execução	1s	S1		■	■	■				■
Execução	1s	S2			■	■	■			
Execução	1s	S3	■		■	■				
Execução	2s	S1	■			■	■		■	■
Execução	2s	S2				■		■	■	
Execução	2s	S3					■	■		■
Posição Estática	1s	S1	■	■					■	
Posição Estática	1s	S2	■	■	■	■		■	■	
Posição Estática	1s	S3		■	■	■	■	■	■	■
Posição Estática	2s	S1		■			■		■	
Posição Estática	2s	S2	■	■	■		■	■		■
Posição Estática	2s	S3		■		■	■	■		

Tabela 17 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM com PCA para discriminar entre lados.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1	■		■					■
Planejamento	1s	S2					■	■		
Planejamento	1s	S3			■					
Planejamento	2s	S1	■		■					■
Planejamento	2s	S2			■		■	■		
Planejamento	2s	S3	■		■					■
Execução	1s	S1			■	■				
Execução	1s	S2			■					
Execução	1s	S3		■						
Execução	2s	S1	■	■		■				
Execução	2s	S2					■	■		
Execução	2s	S3						■		
Posição Estática	1s	S1	■						■	
Posição Estática	1s	S2		■		■	■	■		
Posição Estática	1s	S3			■					
Posição Estática	2s	S1	■					■		■
Posição Estática	2s	S2			■		■	■		
Posição Estática	2s	S3				■	■			

Tabela 18 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA para discriminar entre mãos.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1				■				
Planejamento	1s	S2					■	■	■	
Planejamento	1s	S3	■		■		■		■	
Planejamento	2s	S1		■		■	■	■	■	■
Planejamento	2s	S2	■	■				■		■
Planejamento	2s	S3	■	■	■		■	■	■	■
Execução	1s	S1						■		
Execução	1s	S1	■	■		■				■
Execução	1s	S2			■	■	■	■		■
Execução	1s	S3			■	■			■	
Execução	1s	S3	■		■	■	■		■	
Execução	2s	S1		■	■		■	■		■
Execução	2s	S2					■	■		
Execução	2s	S3		■		■	■	■	■	■
Posição Estática	1s	S1		■	■	■	■		■	
Posição Estática	1s	S2	■	■						■
Posição Estática	1s	S3	■			■	■	■	■	■
Posição Estática	2s	S1		■						
Posição Estática	2s	S1	■	■				■		
Posição Estática	2s	S2		■			■	■		
Posição Estática	2s	S3	■	■	■					■

Tabela 19 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA com PCA para discriminar entre mãos.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1				■				
Planejamento	1s	S2					■	■		
Planejamento	1s	S3	■			■		■	■	
Planejamento	2s	S1				■				
Planejamento	2s	S2			■		■	■		
Planejamento	2s	S3	■		■					
Execução	1s	S1						■		
Execução	1s	S2	■			■			■	■
Execução	1s	S2	■	■		■	■	■		
Execução	1s	S2	■	■	■	■	■	■	■	■
Execução	1s	S3	■	■	■	■			■	■
Execução	1s	S3	■	■	■	■		■	■	■
Execução	2s	S1	■						■	
Execução	2s	S1	■						■	■
Execução	2s	S2				■	■	■		
Execução	2s	S2			■		■	■		
Execução	2s	S3					■	■		■
Posição Estática	1s	S1	■				■	■		
Posição Estática	1s	S2			■		■	■		
Posição Estática	1s	S3			■					
Posição Estática	2s	S1	■		■					■
Posição Estática	2s	S2			■		■	■		
Posição Estática	2s	S3				■			■	■

Tabela 20 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM para discriminar entre mãos.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1	■			■	■	■	■	
Planejamento	1s	S2					■	■		
Planejamento	1s	S3	■						■	
Planejamento	2s	S1	■	■		■			■	
Planejamento	2s	S2	■	■		■	■	■	■	
Planejamento	2s	S3		■						■
Execução	1s	S1		■	■	■		■		■
Execução	1s	S1	■	■	■	■				■
Execução	1s	S2	■		■	■	■	■		
Execução	1s	S3			■	■				
Execução	2s	S1			■		■			■
Execução	2s	S2					■	■		
Execução	2s	S2					■	■		■
Execução	2s	S3						■		■
Posição Estática	1s	S1	■	■			■			
Posição Estática	1s	S2	■	■						■
Posição Estática	1s	S3			■					
Posição Estática	2s	S1	■	■						
Posição Estática	2s	S2	■		■		■	■	■	
Posição Estática	2s	S2	■	■	■	■		■		
Posição Estática	2s	S3	■	■	■	■				
Posição Estática	2s	S3	■	■	■	■				■

Tabela 21 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM com PCA para discriminar entre mãos.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1				■				
Planejamento	1s	S1		■				■		
Planejamento	1s	S3	■			■	■	■	■	■
Planejamento	2s	S1			■					■
Planejamento	2s	S2			■		■	■		
Planejamento	2s	S3	■					■		■
Planejamento	2s	S3	■				■			
Planejamento	2s	S3	■			■	■		■	■
Planejamento	2s	S3	■		■			■		■
Planejamento	2s	S3	■		■		■		■	■
Execução	1s	S1	■		■			■		
Execução	1s	S2	■	■				■	■	
Execução	1s	S3	■	■		■	■			
Execução	1s	S3	■	■	■				■	■
Execução	1s	S3	■	■	■	■			■	■
Execução	2s	S1	■						■	■
Execução	2s	S2				■	■	■		
Execução	2s	S3								■
Posição Estática	1s	S1	■			■		■		
Posição Estática	1s	S2			■		■	■		
Posição Estática	1s	S3			■					
Posição Estática	2s	S1		■						
Posição Estática	2s	S2			■		■	■		
Posição Estática	2s	S3		■		■		■	■	■

Tabela 22 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA para discriminar entre braços.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1				■				
Planejamento	1s	S1		■		■				
Planejamento	1s	S1	■	■	■		■	■		
Planejamento	1s	S1	■	■	■		■	■		■
Planejamento	1s	S2		■	■	■	■			
Planejamento	1s	S3			■		■			
Planejamento	2s	S1	■	■	■		■			
Planejamento	2s	S2	■		■		■	■		■
Planejamento	2s	S3			■		■			
Execução	1s	S1				■		■		
Execução	1s	S2		■		■				
Execução	1s	S2	■			■	■			
Execução	1s	S2	■		■	■	■			■
Execução	1s	S3	■	■		■		■	■	■
Execução	2s	S1					■	■	■	■
Execução	2s	S2	■		■	■	■		■	
Execução	2s	S3				■		■	■	■
Posição Estática	1s	S1	■	■			■			
Posição Estática	1s	S2	■	■			■			
Posição Estática	1s	S2	■	■		■	■		■	
Posição Estática	1s	S3				■				
Posição Estática	2s	S1	■	■			■	■		
Posição Estática	2s	S2	■	■		■	■	■		
Posição Estática	2s	S3	■		■		■			■

Tabela 23 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA com PCA para discriminar entre braços.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1	■	■	■					
Planejamento	1s	S2	■		■	■			■	
Planejamento	1s	S2	■	■		■				
Planejamento	1s	S3			■					
Planejamento	2s	S1			■		■	■	■	
Planejamento	2s	S2				■	■	■		■
Planejamento	2s	S3								■
Planejamento	2s	S3						■		
Execução	1s	S1				■	■			
Execução	1s	S1	■			■				
Execução	1s	S2	■	■			■		■	
Execução	1s	S3				■			■	■
Execução	1s	S3	■							
Execução	2s	S1	■	■		■				
Execução	2s	S2	■					■		
Execução	2s	S3		■		■				
Posição Estática	1s	S1	■	■	■				■	
Posição Estática	1s	S2	■	■	■	■	■	■	■	■
Posição Estática	1s	S3				■				
Posição Estática	2s	S1								■
Posição Estática	2s	S1					■	■		
Posição Estática	2s	S2		■		■	■	■		
Posição Estática	2s	S3			■					

Tabela 24 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM para discriminar entre braços.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1	■				■			
Planejamento	1s	S2	■		■	■	■			
Planejamento	1s	S3			■			■		
Planejamento	2s	S1	■	■	■					
Planejamento	2s	S2	■				■	■	■	
Planejamento	2s	S3		■	■		■			
Execução	1s	S1		■		■	■			■
Execução	1s	S2		■		■				
Execução	1s	S3	■	■	■					
Execução	2s	S1	■				■	■	■	■
Execução	2s	S2	■		■			■		
Execução	2s	S2	■		■	■	■	■		
Execução	2s	S3				■				
Posição Estática	1s	S1	■	■		■	■	■	■	
Posição Estática	1s	S2		■		■	■	■		■
Posição Estática	1s	S3			■					■
Posição Estática	2s	S1	■		■	■	■	■	■	■
Posição Estática	2s	S2					■	■		
Posição Estática	2s	S3	■		■		■	■	■	■

Tabela 25 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM com PCA para discriminar entre braços.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1	■	■	■					
Planejamento	1s	S2			■		■	■		
Planejamento	1s	S3						■		
Planejamento	1s	S3			■					
Planejamento	2s	S1		■				■	■	
Planejamento	2s	S2	■				■	■		
Planejamento	2s	S3			■			■		
Execução	1s	S1				■	■			
Execução	1s	S2	■	■			■		■	
Execução	1s	S3	■							
Execução	2s	S1	■							■
Execução	2s	S2		■				■		
Execução	2s	S2	■		■			■		
Execução	2s	S3					■		■	
Execução	2s	S3				■				
Posição Estática	1s	S1	■	■	■				■	
Posição Estática	1s	S2	■	■	■	■		■	■	
Posição Estática	1s	S3				■				
Posição Estática	2s	S1		■	■					■
Posição Estática	2s	S2		■			■	■		
Posição Estática	2s	S3			■					

Tabela 26 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA para discriminar entre quatro classes.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1				■	■	■		
Planejamento	1s	S1		■		■				
Planejamento	1s	S2		■	■			■		■
Planejamento	1s	S2		■	■			■	■	■
Planejamento	1s	S3		■		■		■		
Planejamento	2s	S1	■	■	■					
Planejamento	2s	S2		■	■	■		■	■	
Planejamento	2s	S2	■	■			■	■		
Planejamento	2s	S3		■		■		■	■	■
Planejamento	2s	S3	■		■	■		■		■
Execução	1s	S1				■	■		■	
Execução	1s	S2			■		■		■	
Execução	1s	S3			■				■	■
Execução	2s	S1	■	■	■					
Execução	2s	S2	■	■		■	■	■		
Execução	2s	S3			■	■		■		■
Posição Estática	1s	S1	■	■				■	■	■
Posição Estática	1s	S2		■		■				
Posição Estática	1s	S3			■	■			■	■
Posição Estática	2s	S1		■	■					
Posição Estática	2s	S2	■	■			■	■		
Posição Estática	2s	S3				■		■		

Tabela 27 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando LDA com PCA para discriminar entre quatro classes.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1			■	■		■		■
Planejamento	1s	S2	■	■	■					
Planejamento	1s	S2	■	■	■	■				
Planejamento	1s	S3			■		■			
Planejamento	2s	S1								■
Planejamento	2s	S2			■		■			
Planejamento	2s	S2	■		■	■		■	■	
Planejamento	2s	S2	■	■	■		■	■		■
Planejamento	2s	S2	■	■	■	■		■	■	
Planejamento	2s	S3	■		■				■	
Execução	1s	S1	■				■		■	
Execução	1s	S2			■					
Execução	1s	S3			■					
Execução	2s	S1	■	■						■
Execução	2s	S2		■		■				
Execução	2s	S3	■	■				■		■
Posição Estática	1s	S1							■	
Posição Estática	1s	S2	■	■	■			■	■	■
Posição Estática	1s	S3			■	■			■	
Posição Estática	2s	S1	■							■
Posição Estática	2s	S2		■		■	■	■		
Posição Estática	2s	S2		■	■		■	■		
Posição Estática	2s	S3				■		■		■

Tabela 28 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM para discriminar entre quatro classes.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1	■				■			■
Planejamento	1s	S2	■	■			■		■	■
Planejamento	1s	S3						■		
Planejamento	2s	S1	■	■		■			■	■
Planejamento	2s	S2	■				■			
Planejamento	2s	S3						■	■	
Execução	1s	S1						■		
Execução	1s	S2		■			■			
Execução	1s	S3	■							
Execução	2s	S1	■	■		■	■		■	
Execução	2s	S2	■		■					
Execução	2s	S3						■		■
Posição Estática	1s	S1		■					■	■
Posição Estática	1s	S2					■			
Posição Estática	1s	S3			■			■		
Posição Estática	2s	S1	■				■	■	■	■
Posição Estática	2s	S2		■						
Posição Estática	2s	S3	■			■		■		

Tabela 29 - Eletrodos que mais contribuíram na obtenção da melhor taxa de acerto utilizando SVM com PCA para discriminar entre quatro classes.

Fase	Vetor	Voluntário	F3-Fz	F4-Fz	C3-Cz	C4-Cz	P3-Pz	P4-Pz	O1-Oz	O2-Oz
Planejamento	1s	S1	■							
Planejamento	1s	S2	■			■	■		■	
Planejamento	1s	S3			■			■	■	
Planejamento	2s	S1					■			
Planejamento	2s	S2	■		■	■	■			
Planejamento	2s	S3			■		■		■	■
Execução	1s	S1		■	■			■		
Execução	1s	S2		■	■	■		■		
Execução	1s	S3	■		■				■	■
Execução	2s	S1	■	■	■					
Execução	2s	S2		■			■	■		■
Execução	2s	S3						■		■
Posição Estática	1s	S1				■				
Posição Estática	1s	S2	■		■		■	■	■	
Posição Estática	1s	S3		■	■	■		■		■
Posição Estática	2s	S1						■	■	
Posição Estática	2s	S2	■			■	■	■	■	
Posição Estática	2s	S3		■	■	■	■	■		

APÊNDICE D – Códigos MATLAB

O código abaixo realiza as funções de pré-processamento do sinal, mensuração dos tempos de execução e eliminação dos comandos incorretos, salvando uma base de dados com os dados a serem submetidos aos classificadores.

```
clear; clc;
% Frequência máxima do sinal
Fmax=80;
% Diretório de trabalho
directory='C:\Users\rcaine\Documents\Mestrado
FEI\Tese\Experimentos\Coletas\Processados\MATLAB\';
%
%
nch=3;          % Desprezar os três últimos canais, pois não são eletrodos
cmd_thr=0.15;   % Limiar para identificação dos intervalos de tempo no vetor
                % de comandos (uV)
rounds=3;       % Quantidade de rodadas de aquisição
%
%
% Arquivos a serem carregados
input_files = char ( 'padrão_cerebro_mov_Acácio.mat',
'padrão_cerebro_mov_Renato.mat', 'padrão_cerebro_mov_Aguiar.mat' );

for s=1:size(input_files,1)
    input_file=input_files(s,:);
    % Intervalo de dados a ser considerado referente a cada trecho do sinal
    % a ser considerado.
    for moviment_duration = [ 1000 2000 ]
        fprintf('-----------------------------------------------------------
-------------------------------------------------\n');
        %
        % Limpa todas as variáveis desnecessárias à próxima interação do
        % loop de avaliação todas as características
        % e de todas as fases do movimento.
        %
        clear Control_ch Dados EEG_ch Feature Fs Phase_description ans
bands blocktimes ch channels cmd_exec_time cmd_execution cmd_execution_end
cmd_react_time cmd_return cmd_return_start cmd_return_time cmd_start
cmd_timestamp com command_pos_full command_temp commands comtext control
crtl_ch_clip_down crtl_ch_clip_up data dataend datastart delta delta_dir
delta_esq error_list errors file firstsampleoffset freq_moviment
freq_plan_mov freq_plan_rest freq_rest h hh i j l lado loop_end MESSAGE
mov_eval moviment moviment_durations plan_mov plan_rest pos qtde_errors
rangemax rangemin react_times rest return_times samplerate spreadsheet
static Std_Per_moviment Std_Per_plan_mov Std_Per_plan_rest Std_Per_rest
Std_static SUCCESS temp test_round tickrate time titles unittext
unittextmap var voltage xlsfile;

        %
        % Sequencia de comandos codificados da seguinte forma:
        %   0 -> Repouso inicial (ignorado)
        %   1 -> Fechar a mão direita
        %   2 -> Fechar a mão esquerda
        %   3 -> Flexionar o braço direito
```

```
        %   4 -> Flexionar o braço esquerdo
        %
        % A ordem dos comandos solicitados aos voluntários é dada pelo
        % vetor abaixo.
        commands = [ 0  3   2   4   1   2   4   3   1   3   2   1   4   2
3   1   4   3   2   4   1   2   4   3   1   3   2   1   4   2   3   1   4
3   2   4   1   2   4   3   1   3   2   1   4   2   3   1   4   3   2   4
1   2   4   3   1   3   2   1   4]';
        %
        %
        % O primeiro passo é carregar o arquivo a ser trabalhado ...
        % Canais a se considerar, sendo:
        % F -> 1 e 2
        % C -> 3 e 4
        % P -> 5 e 6
        % O -> 7 e 8
        %
        channels_to_consider = [ 1 2 3 4 5 6 7 8 ];
        %
        fprintf('Arquivo EEG: "%s"\n',input_file);
        fprintf('Vetor de dados: com %i ms\n',moviment_duration);
        cd(directory);
        file=strcat(directory,input_file);
        load(file);
        fprintf('Canais considerados:');disp(channels_to_consider);
        %
        % e depois vamos transferir os dados para matrizes a serem
        % posteriormente utilizadas. Antes, é importante iniciar as
        % matrizes com zeros para melhor desempenho do algoritmo.
        %
        EEG_ch=zeros(3,size(titles,1)-nch,max(max(dataend-datastart))+1);
        Control_ch=zeros(3,nch,max(max(dataend-datastart))+1);
        cmd_timestamp=zeros(3,2*size(commands,1));
        %
        % Somente é necessário resgatar a taxa de amostragem das aquisições
        % para os canais de EEG
        %
        Fs=samplerate(1:size(titles,1)-nch,2:rounds+1);
        for test_round=1:3
            for i=1:size(titles,1)
                if ( i<=size(titles,1)-nch )
                    % Matriz para a execução do comando
                    EEG_ch(test_round,i,1:max(max(dataend-datastart))+1)=[
data(datastart(i,1+test_round):dataend(i,1+test_round))
zeros(max(max(dataend-datastart))+1-
size((datastart(i,1+test_round):dataend(i,1+test_round)),2),1)' ];
                else
                    % Matriz para os canais relativos aos sensores (chaves)
                    % e a saída serial do PC (comandos), alocando
                    % esses canais (9,10 e 11), iniciando a partir do
                    % primeiro vetor da nova Matriz (1,2 e 3)
                    % para economizar memória.
                    Control_ch(test_round,i-(size(titles,1)-
nch),1:max(max(dataend-datastart))+1)=[
data(datastart(i,1+test_round):dataend(i,1+test_round))
zeros(max(max(dataend-datastart))+1-
size((datastart(i,1+test_round):dataend(i,1+test_round)),2),1)' ];
                end
```

```
            end
            %
            % É necessário haver uma rotina para eliminar o ripple que
            % ocorre no canal de controle do comando para que a
            % rotina de identificação do momento em que o comando é
            % apresentado ao voluntário funcione corretamente.
            % Para isso, vamos clipar o sinal em 5+cmd_thr e -(5+cmd_thr)
            % Volts.
            %
            crtl_ch_clip_up =
find(Control_ch(test_round,3,:)>=5+cmd_thr/2);
            crtl_ch_clip_down = find(Control_ch(test_round,3,:)<=-
(5+cmd_thr/2));
            for i = 1:size(crtl_ch_clip_up,2)
                Control_ch(test_round,3,crtl_ch_clip_up(i))=5+cmd_thr/2;
            end
            for i = 1:size(crtl_ch_clip_down,2)
                Control_ch(test_round,3,crtl_ch_clip_down(i))=-
(5+cmd_thr/2);
            end
            %
            % Agora vamos fazer uma rotina para determinar o momento em que
            % o comando é apresentado ao voluntário ....
            %
            time=1;
            for i=1:2*size(commands,1)
                if mod(i,2) == 0
                    time=find(Control_ch(test_round,3,time:end)
<=0,1)+time;
                else
                    time=find(Control_ch(test_round,3,time:end)
>=0,1)+time;
                end
                cmd_timestamp(test_round,i)=time;
            end
            %
            % ... e o tempo de reação do voluntário.
            %
            for i=1:size(commands,1)
                if mod(commands(i),2) == 0
                    lado = 2;    % Canal relativo ao movimento do lado
                                 % esquerdo (antigo canal 10)
                else
                    lado = 1;    % Canal relativo ao movimento do lado
                                 % direito (antigo canal 9)
                end
                j=0; delta = 0; delta_dir = 0; delta_esq = 0;
                %
                % Primeiro identificamos o momento da execução do movimento
                %
                while  delta > -0.2 && delta < 0.2
                    delta_dir =
Control_ch(test_round,1,cmd_timestamp(test_round,i*2-1)+j)-
Control_ch(test_round,1,cmd_timestamp(test_round,i*2-1));
                    delta_esq =
Control_ch(test_round,2,cmd_timestamp(test_round,i*2-1)+j)-
Control_ch(test_round,2,cmd_timestamp(test_round,i*2-1));
                    [delta,pos]=min([ delta_dir delta_esq ]);
```

```
                    j=j+1;
                end
                %
                cmd_execution(test_round,i)=cmd_timestamp(test_round,i*2-
1)+j; cmd_start(test_round,i)=cmd_timestamp(test_round,i*2-1);
                %
                % ... e depois o momento de retorno a posição de repouso.
                %
                j=0; loop_end = 0;
                %
                % Agora vamos ver se o voluntário obedeceu corretamente o
                % comando, avaliando a partir do início
                % do comando se os níveis de tensão das chaves são os
                % esperados.
                %
                while  ( loop_end ==0 && j <= 4000-
(cmd_execution(test_round,i)-cmd_start(test_round,i)) )
                    voltage =
Control_ch(test_round,lado,cmd_execution(test_round,i)+j);

cmd_execution_end(test_round,i)=cmd_execution(test_round,i);
                    if ( voltage <= 1 && (commands(i) == 1 || commands(i)
== 2) )

cmd_execution_end(test_round,i)=cmd_execution(test_round,i)+j;
                        loop_end=1;
                    end
                    if ( voltage <= 2 && (commands(i) == 3 || commands(i)
== 4) )

cmd_execution_end(test_round,i)=cmd_execution(test_round,i)+j;
                        loop_end=1;
                    end
                    j=j+1;
                end
                %
                if pos ~= lado  % Min retorna na variável pos a posição em
                                % que ocorreu o menor valor.
                    mov_eval(test_round,i,:)=[ 0 loop_end ];
                                % Se não coincidir com a variável lado,
                                % significa que o
                else            % voluntário não obedeceu o comando (pelo
                                % menos o lado).
                    mov_eval(test_round,i,:)=[ 1 loop_end ];
                                % Fica preenchido o valor 0 na matriz
                                % cmd_ver se o comando
                end             % estiver incorreto e o valor 1 caso
                                % contrário.
                                % A variável loop_end=1 se o movimento está
                                % correto, 0 caso contrário.
                %
                %
                j=0; delta = 0; delta_dir = 0; delta_esq = 0;
                while  ( delta > -0.2 && delta < 0.2 &&
(j+cmd_timestamp(test_round,i*2)) < size(Control_ch,3) )
                    delta_dir =
Control_ch(test_round,1,cmd_timestamp(test_round,i*2)+j)-
Control_ch(test_round,1,cmd_timestamp(test_round,i*2));
```

```
                    delta_esq =
Control_ch(test_round,2,cmd_timestamp(test_round,i*2)+j)-
Control_ch(test_round,2,cmd_timestamp(test_round,i*2));
                    [delta,pos]=min([delta_dir delta_esq]);
                    j=j+1;
                end
                cmd_return(test_round,i)=cmd_timestamp(test_round,i*2)+j-1;
cmd_return_start(test_round,i)=cmd_timestamp(test_round,i*2);
            end
            %
            % Segmenta os dados lidos do arquivo por tipo de movimento. Os
            % dados são também separados por rodada de
            % aquisição.
            for i=1:size(commands,1)
                % Para todos os comandos ... (e canais)
                %
                % Os dados são organizados em uma matriz 3D com o seguinte
                % formato:
                %
                %         [    comando     EEG     canal   ]
                %
                % O intervalo de dados considerado como planejamento
                % inicia-se em sua fase de planejamento em
                % [cmd_execution - moviment_duration/2]
                % e termina durante a execução do movimento em
                % [cmd_execution + moviment_duration/2].
                % Já o intervalo relativo ao movimento inicia-se no
                % instante [cmd_return_start - moviment_duration/2] e
                % termina em [cmd_return_start + moviment_duration/2].
                % O mesmo vale para o planejamento do retorno à posição
                % inicial e para o retorno propriamente dito.
                %
                %
                plan_mov(test_round,i,1:size(titles,1)-
nch,1:moviment_duration)=EEG_ch(test_round,:,cmd_execution(test_round,i)-
0.25*moviment_duration:cmd_execution(test_round,i)+0.75*moviment_duration-
1);
                moviment(test_round,i,1:size(titles,1)-
nch,1:moviment_duration)=EEG_ch(test_round,:,cmd_start(test_round,i):cmd_st
art(test_round,i)+moviment_duration-1);
                static(test_round,i,1:size(titles,1)-
nch,1:moviment_duration)=EEG_ch(test_round,:,cmd_execution_end(test_round,i
)+1:cmd_execution_end(test_round,i)+moviment_duration);
                plan_rest(test_round,i,1:size(titles,1)-
nch,1:moviment_duration)=EEG_ch(test_round,:,cmd_return_start(test_round,i)
-
0.25*moviment_duration:cmd_return_start(test_round,i)+0.75*moviment_duratio
n-1);
                rest(test_round,i,1:size(titles,1)-
nch,1:moviment_duration)=EEG_ch(test_round,:,cmd_return_start(test_round,i)
:cmd_return_start(test_round,i)+moviment_duration-1);

control(test_round,i,1:nch,1:moviment_duration)=Control_ch(test_round,:,cmd
_start(test_round,i):floor(cmd_start(test_round,i)+moviment_duration-1));
            end
            %
            % Por fim, retorna a quantidade de canais da aquisição.
            %
```

```
            channels(test_round)=size(titles,1)-nch;
            %
            % Agora vamos gerar o periodograma e o PSD para cada um dos
            % movimentos.
            % Esses irão compor os vetores de características.
            %
            % Os dados estão organizados em uma matriz 5D com o seguinte
            % formato:
            %
            %   [ rodada do EEG  comando  EEG  canal  Periodograma ]
            %
            %   rodada do EEG => de 1 a 3
            %   comando => de 1 a 60
            %   EEG => dados do EEG
            %   canal => de 1 a 8
            %   Periodograma do EEG => 1000 Hz, com resolução de 0.25Hz.
            %
            for i=1:size(commands,1)
                for j=1:channels
                    [ Std_Per_plan_mov(test_round,i,j,:)
freq_plan_mov(test_round,i,j,:) ] =
periodogram(plan_mov(test_round,i,j,:),[],moviment_duration,1000);
                    [ Std_Per_moviment(test_round,i,j,:)
freq_moviment(test_round,i,j,:)] =
periodogram(moviment(test_round,i,j,:),[],moviment_duration,1000);
                    [ Std_static(test_round,i,j,:)
freq_moviment(test_round,i,j,:)] =
periodogram(static(test_round,i,j,:),[],moviment_duration,1000);
                    [ Std_Per_plan_rest(test_round,i,j,:)
freq_plan_rest(test_round,i,j,:)] =
periodogram(plan_rest(test_round,i,j,:),[],moviment_duration,1000);
                    [ Std_Per_rest(test_round,i,j,:)
freq_rest(test_round,i,j,:)] =
periodogram(rest(test_round,i,j,:),[],moviment_duration,1000);
                end
             end
        end
        %
        % Vamos agora segmentar os dados por movimento para depois rodar
        % classificação. Consideraremos somente o PSD até
        % 40 Hz.
        % Primeiro, é necessário identificar os erros ocorridos para
        % expurgá-los posteriormente.
        %
        qtde_errors=0;temp=commands;
        for i=1:rounds
           errors=find(mov_eval(i,2:end,1).*mov_eval(i,2:end,2)==0)+1;
        % Identifica o comando em que ocorreu erro, sem
        % considerar o primeiro (command=0)
           if size(errors,2)<qtde_errors
               error_list(i,:)=zeros(1,qtde_errors);
           end
           error_list(i,1:size(errors,2))=errors;
           qtde_errors=max(qtde_errors,size(errors,2));
           for j=1:size(find(error_list(i,:)>0),2);
                temp(error_list(i,j))=0;
           end
        end
```

```
        for i=1:4
           command_pos_full(i,:)=find(commands==i);
        end
        %
        % Agora, efetivamente, segmentamos os dados por movimento, já
        % expurgando os erros.
        %
        a=0;b=0;c=0;d=0;command_temp=[];
        for i=1:size(temp,1)
            switch lower(temp(i))
                case 1
                    a=a+1;
                    command_temp(1,a)=i;
                case 2
                    b=b+1;
                    command_temp(2,b)=i;
                case 3
                    c=c+1;
                    command_temp(3,c)=i;
                case 4
                    d=d+1;
                    command_temp(4,d)=i;
            end
            %
            % É necessário garantir que todos os vetores tenham o mesmo
            % tamanho, então expurgamos dados válidos de alguns vetores
            % para que tenham o mesmo tamanho que o menor deles.
            %
            command_pos=command_temp(:,1:min([a b c d]));
        end
        clear a b c d;
        %
        fprintf('Foi identificado os erros abaixo listados, cada linha
correspondendo a uma rodada:\n');disp(error_list);
        fprintf('O universo de amostras tem o seguinte tamanho L x C(erros
já expurgados):');disp(size(command_pos));
        %
        % Obtém os tempos de reação, execução e de retorno à posição de
        % repouso, incluindo zeros nos movimentos em que
        % o voluntário cometeu algum erro.
        %
        cmd_react_time=(cmd_execution-
cmd_start).*(mov_eval(:,:,1).*mov_eval(:,:,2));
        cmd_exec_time=(cmd_execution_end-
cmd_execution).*(mov_eval(:,:,1).*mov_eval(:,:,2));
        cmd_return_time=(cmd_return-
cmd_return_start).*(mov_eval(:,:,1).*mov_eval(:,:,2));
        %
        % Depois, elimina os valores que foram zerados para desconsiderar
        % os movimentos executados incorretamente.
        %
        cmd_react_time=cmd_react_time(cmd_react_time~=0);
        cmd_exec_time=cmd_exec_time(cmd_exec_time~=0);
        cmd_return_time=cmd_return_time(cmd_return_time~=0);
        %
        % ... e determina a média, mínimo, desvio padrão e máximo.
        %
```

```
        react_times = [ mean(cmd_react_time) min(cmd_react_time)
std(cmd_react_time) max(cmd_react_time) ];
        moviment_durations = [ mean(cmd_exec_time) min(cmd_exec_time)
std(cmd_exec_time) max(cmd_exec_time) ];
        return_times = [ mean(cmd_return_time) min(cmd_return_time)
std(cmd_return_time) max(cmd_return_time) ];
        fprintf('Os tempos foram (media/mínimo/desvio
padrão/máximo):\n\n');
        fprintf('Reação:');format short e, disp(react_times);
        fprintf('Movimento:');format short e, disp(moviment_durations);
        fprintf('Retorno ao repouso:');format short e,
disp(return_times);fprintf('\n');
        %
        % Intervalo de dados e caraterística a serem utilizados, conforme
        % abaixo:
        %   a --> Planejamento
        %   b --> Movimento
        %   c --> Posição Estática
        %   d --> Planejamento do retorno a posição de descanso
        %   e --> Retorno a posição de descanso
        %
        %   1 --> PSD
        %   2 --> Potência média do PSD
        %   3 --> Potência média do PSD por faixa de frequência PSDMFi
        %
        for type=[ 'a' 'b' 'c']
            for subtype=[ '1' '2' '3']
                %
                %
                % Precisamos gerar matriz para armazenar os dados a serem
                % submetidos ao
                % classificados que considere somente os comandos
                % executados corretamente, em função da fase do movimento a
                % ser utilizada.
                %
                fprintf('Fase: ');
                switch lower(type)
                case 'a'
                data_interval=Std_Per_plan_mov;
                fprintf('Planejamento do movimento\n');
                Phase_description='Plan_mov';
                case 'b'
                data_interval=Std_Per_moviment;
                fprintf('Movimento.\n');
                Phase_description='Movimento';
                case 'c'
                data_interval=Std_static;
                fprintf('Posição estática.\n');
                Phase_description='Pos_estática';
                case 'd'
                data_interval=Std_Per_plan_rest;
                fprintf('Planejamento do movimento de retorno à posição de
repouso.\n');
                Phase_description='Plan_retorno';
                case 'f'
                data_interval=Std_Per_rest;
                fprintf('Movimento de retorno a posição de repouso.\n');
                Phase_description='Retorno';
```

```
                end
                %
                % Determina espectro de frequências a ser utilizado em
                % função do tipo de característica.
                %
                if (subtype=='3')
                bands = [ [0 4]' [4 8]' [8 12]' [12 14]' [14 18]' [18 25]'
[25 32]' [32 Fmax]' ].*moviment_duration/1000;
                else
                hi_freq = Fmax*moviment_duration/1000;
                % Parecer haver informação útil Acima de 40Hz.
                end
                %
                % Transfere os dados selecionados para um vetor a ser
                % utilizado pelo classificador, em função do tipo de
                % característica desejada.
                %
                h=1;
                for i=1:4
                    for j=1:size(command_pos,2)
                        switch lower(subtype)

                        case {'1'}
                        % PSD Puro
                        Dados(3*size(command_pos,2)*(h-1)+3*j-2,:)= [
(squeeze(data_interval(1,command_pos(i,j),1,1:hi_freq)))'
(squeeze(data_interval(1,command_pos(i,j),2,1:hi_freq)))'
(squeeze(data_interval(1,command_pos(i,j),3,1:hi_freq))')
(squeeze(data_interval(1,command_pos(i,j),4,1:hi_freq))')
(squeeze(data_interval(1,command_pos(i,j),5,1:hi_freq))')
(squeeze(data_interval(1,command_pos(i,j),6,1:hi_freq))')
(squeeze(data_interval(1,command_pos(i,j),7,1:hi_freq))')
(squeeze(data_interval(1,command_pos(i,j),8,1:hi_freq))')];
                        Dados(3*size(command_pos,2)*(h-1)+3*j-1,:)= [
(squeeze(data_interval(2,command_pos(i,j),1,1:hi_freq)))'
(squeeze(data_interval(2,command_pos(i,j),2,1:hi_freq)))'
(squeeze(data_interval(2,command_pos(i,j),3,1:hi_freq))')
(squeeze(data_interval(2,command_pos(i,j),4,1:hi_freq))')
(squeeze(data_interval(2,command_pos(i,j),5,1:hi_freq))')
(squeeze(data_interval(2,command_pos(i,j),6,1:hi_freq))')
(squeeze(data_interval(2,command_pos(i,j),7,1:hi_freq))')
(squeeze(data_interval(2,command_pos(i,j),8,1:hi_freq))')];
                        Dados(3*size(command_pos,2)*(h-1)+3*j,:)= [
(squeeze(data_interval(3,command_pos(i,j),1,1:hi_freq)))'
(squeeze(data_interval(3,command_pos(i,j),2,1:hi_freq)))'
(squeeze(data_interval(3,command_pos(i,j),3,1:hi_freq))')
(squeeze(data_interval(3,command_pos(i,j),4,1:hi_freq))')
(squeeze(data_interval(3,command_pos(i,j),5,1:hi_freq))')
(squeeze(data_interval(3,command_pos(i,j),6,1:hi_freq))')
(squeeze(data_interval(3,command_pos(i,j),7,1:hi_freq))')
(squeeze(data_interval(3,command_pos(i,j),8,1:hi_freq))')];
                        Feature='PSD';

                        case {'2'}
                        % Potencia total do PSD (somatória PDS)
                        Dados(3*size(command_pos,2)*(h-1)+3*j-2,:)= [
sum(squeeze(data_interval(1,command_pos(i,j),1,1:hi_freq)))'
sum(squeeze(data_interval(1,command_pos(i,j),2,1:hi_freq)))'
```

```
sum(squeeze(data_interval(1,command_pos(i,j),3,1:hi_freq)))'
sum(squeeze(data_interval(1,command_pos(i,j),4,1:hi_freq)))'
sum(squeeze(data_interval(1,command_pos(i,j),5,1:hi_freq)))'
sum(squeeze(data_interval(1,command_pos(i,j),6,1:hi_freq)))'
sum(squeeze(data_interval(1,command_pos(i,j),7,1:hi_freq)))'
sum(squeeze(data_interval(1,command_pos(i,j),8,1:hi_freq)))'];
                        Dados(3*size(command_pos,2)*(h-1)+3*j-1,:)= [
sum(squeeze(data_interval(2,command_pos(i,j),1,1:hi_freq)))'
sum(squeeze(data_interval(2,command_pos(i,j),2,1:hi_freq)))'
sum(squeeze(data_interval(2,command_pos(i,j),3,1:hi_freq)))'
sum(squeeze(data_interval(2,command_pos(i,j),4,1:hi_freq)))'
sum(squeeze(data_interval(2,command_pos(i,j),5,1:hi_freq)))'
sum(squeeze(data_interval(2,command_pos(i,j),6,1:hi_freq)))'
sum(squeeze(data_interval(2,command_pos(i,j),7,1:hi_freq)))'
sum(squeeze(data_interval(2,command_pos(i,j),8,1:hi_freq)))'];
                        Dados(3*size(command_pos,2)*(h-1)+3*j,:)= [
sum(squeeze(data_interval(3,command_pos(i,j),1,1:hi_freq)))'
sum(squeeze(data_interval(3,command_pos(i,j),2,1:hi_freq)))'
sum(squeeze(data_interval(3,command_pos(i,j),3,1:hi_freq)))'
sum(squeeze(data_interval(3,command_pos(i,j),4,1:hi_freq)))'
sum(squeeze(data_interval(3,command_pos(i,j),5,1:hi_freq)))'
sum(squeeze(data_interval(3,command_pos(i,j),6,1:hi_freq)))'
sum(squeeze(data_interval(3,command_pos(i,j),7,1:hi_freq)))'
sum(squeeze(data_interval(3,command_pos(i,j),8,1:hi_freq)))'];
                        Feature='PSDm';

                        case {'3'}
                        % Potencia por banda do PSD do EEG
                        hh=1;
                        for ch=channels_to_consider
                            for l=1:size(bands,2)

a(hh,l)=sum(squeeze(data_interval(1,command_pos(i,j),ch,bands(1,l)+1:bands(
2,l))));

b(hh,l)=sum(squeeze(data_interval(2,command_pos(i,j),ch,bands(1,l)+1:bands(
2,l))));

c(hh,l)=sum(squeeze(data_interval(3,command_pos(i,j),ch,bands(1,l)+1:bands(
2,l))));
                            end
                        hh=hh+1;
                        end
                        Dados(3*size(command_pos,2)*(h-1)+3*j-
2,1:size(a,1)*size(a,2))= reshape (a', 1, size(a,1)*size(a,2));
                        Dados(3*size(command_pos,2)*(h-1)+3*j-
1,1:size(b,1)*size(b,2))= reshape (b', 1, size(b,1)*size(b,2));
                        Dados(3*size(command_pos,2)*(h-1)+3*j
,1:size(c,1)*size(c,2))= reshape (c', 1, size(c,1)*size(c,2));
                        Feature='PSDMFi';
                        clear a b c;
                        end
                    end
                h=h+1;
                end
                fprintf('Característica: %s\n',Feature);
                %
                % Agora vamos salvar a matriz de dados referentes a
```

```
                % característica extraída para futuro uso pelos
                % classificadores.
                %
                spreadsheet=strcat(Feature,'-',Phase_description,'-
',strcat(int2str(Fmax),'Hz'),'-',strcat(int2str(moviment_duration),'ms'));
                xlsfile=strcat(directory,'Features\',strrep(strrep
(input_file,'padrão_cerebro_mov_',''),'.mat',''),'.xls');
                file=strcat(directory,'Features\',strrep(strrep
(input_file,'padrão_cerebro_mov_',''),'.mat',''),'-',Feature,'-
',Phase_description,'-',strcat(int2str(Fmax),'Hz'),'-
',strcat(int2str(moviment_duration),'ms'),'.mat');
                warning('off','MATLAB:xlswrite:AddSheet');
                if exist ('Features','dir')

save(file,'Dados','Phase_description','Feature','moviment_duration','Fmax',
'command_pos');
                    if subtype == '1'

[SUCCESS,MESSAGE]=xlswrite(xlsfile,Dados',spreadsheet,'B2');
                    else

[SUCCESS,MESSAGE]=xlswrite(xlsfile,Dados,spreadsheet,'B2');
                    end
                    else
                    mkdir(directory,'\Features');

save(file,'Dados','Phase_description','Feature','moviment_duration','Fmax',
'command_pos');
                    if subtype == '1'
                             % No caso do PSD, a dimensionalidade
                             % da matriz é igual
 [SUCCESS,MESSAGE]=xlswrite(xlsfile,Dados',spreadsheet,'B2');
                            % a 640 colunas por tantas linhas
                            % quanto fui o número
                    else
                            % de comandos válidos. Isso estoura o
                            % número de colunas
 [SUCCESS,MESSAGE]=xlswrite(xlsfile,Dados,spreadsheet,'B2');
                            % do Excel e para contornar a matriz
                            % Dados é salvada invertida.
                    end
                end
            clear Dados;
            end
        end
    end
end
```

O código abaixo automatiza a execução dos algoritmos de classificação a todos os voluntários do experimento, aplicando também a Seleção Espacial de Características para todas as fases do movimento e para os vetores de dados de 1 e 2 s. Foi escrito de forma a permitir que se parametrize o tipo de característica e algoritmo de classificação que se deseja

utilizar, bem como permite especificar a frequência máxima a ser considerada para a faixa gama alta e a configuração dos grupos a ser utilizada na classificação.

```
clear;clc;
% Frequência máxima do sinal
for Fmax=40:10:80;
    %
    % Diretório de trabalho
    %
    directory='C:\Users\rcaine\Documents\Mestrado
FEI\Tese\Experimentos\Coletas\Processados\MATLAB\';
    %
    % Selecione abaixo quais os comandos que se deseja utilizar na
    % classificação (não informar 0) e em quantos grupos se deseja
    % classificar.
    % Se g<=1 ou g > quantidade de movimentos possíveis, então serão
    % considerados a quantidade de grupos igual a quantidade ede comandos
    % informados.
    %
    % Sequencia de comandos codificada da seguinte forma:
    %   0 -> Repouso inicial (ignorado)
    %   1 -> Fechar a mão direita
    %   2 -> Fechar a mão esquerda
    %   3 -> Flexionar o braço direito
    %   4 -> Flexionar o braço esquerdo
    %
    commands_to_consider = [1 2 3 4];
    g=2;
    %
    % Selecione abaixo o tipo de classificador a ser utilizado. Os
    % classificadores disponíveis são LDA, MLDA, linear, quadratico ou SVM.
    %
    classifier='svm';
    %
    % Caso deseja aplicar PCA aos dados antes de submetê-los ao
    % classificador, defina a variável apply_pca com valor 1.
    %
    apply_pca=0;
    %
    % Combinações de Eletrodos a serem utilizadas
    %
    % Eletrodos variando aos pares: [ 256 64 244 253 61 241 52 49 ]
    % Todos os eletrodos: 2:256
    %
    cases = 2:256;
    %
    % Fase do movimento a ser considerada. Utilizar codificação abaixo:
    %
    % Planejamento do movimento ---------> Plan_mov
    % Execução do movimento -------------> Movimento
    % Posição estática ------------------> Pos_estática
    % Planejamento a posição de retorno -> Plan_retorno
    % Execução do movimento de retorno --> Retorno
    %
    Phase_desc = char ( 'Plan_mov', 'Movimento', 'Pos_estática' );
    %
    % Característica a ser utilizada, podendo ser PSD, PSDm, PSDMFi ou
```

```
    % PSDMFi2.
    %
    Feature='PSDMFi2';
    %
    % Atribua o valor 1 para a variável Detail para salvar os resultados
    % detalhados de cada movimento.
    %
    Detail=1;
    %
    % Arquivos de dados utilizados.
    %
    input_files = char ( 'padrão_cerebro_mov_Acácio.mat',
'padrão_cerebro_mov_Renato.mat', 'padrão_cerebro_mov_Aguiar.mat' );
    % Arquivos a serem carregados
    %
    % Cria vetores para Seleção Espacial de Característica
    %
    i=8;h=2;i2=2^i;
    condvects=false(i2,i);
    for m=1:i
        m2=2^m;
        m3=(m2/2)-1;
        i3=i-m+1;
        for h=h:m2:i2
            for k=0:m3
                condvects(h+k,i3)=true;
            end
            h=m2+1;
        end
    end
    %
    % O trecho abaixo será utilizado posteriormente para calcular a PSDMFi
    % Fmax=80;
    bands = [ [0 4]' [4 8]' [8 12]' [12 14]' [14 18]' [18 25]' [25 32]' [32
Fmax]' ];
    if Feature=='PSDMFi2'
        Normaliza = 1;      % A única diferença entre PSDMFi2 e PSDMFi é
                            % que no caso da primeira,
        Feature='PSDMFi';   % os dados são normalizados pela quantidade de
                            % pontos da PSD.
    end
    %
    sfs=1;err_nun=0;
    for sel = cases
        if ( strcmp(classifier, 'linear') && (sel == 64 || sel == 96 || sel
== 112 || sel == 120 || sel == 124))
            fprintf ('Pulando combinação %i',sel-1);
            continue
        end
        channels_to_consider=condvects(sel,:).*[ 1 2 3 4 5 6 7 8 ];

channels_to_consider=channels_to_consider(channels_to_consider(1,:)~=0);
        fprintf('Canais
considerados:');disp(channels_to_consider);fprintf(' (%i)\n\n',sfs);
        %
        % Inicia carregamento dos dados salvos e classificação
        %
        i=1;j=1;k=1;
```

```
        clear Training class;
        for s=1:size(input_files,1)
            % Intervalo de dados a ser considerado referente a cada trecho
            % do sinal a ser considerado.
            for moviment_duration=[ 1000 2000]
                input_file=input_files(s,:);
                voluntario=strrep(strrep
(input_file,'padrão_cerebro_mov_',''),'.mat','');
                for f=1:size(Phase_desc,1)
                    %
                    % Define a fase do movimento
                    %
                    Phase=Phase_desc(f,:);
                    %
                    % Carregar arquivo de dados.
                    %
                    file=strcat(directory,'Features\',voluntario,'-
',Feature,'-',Phase,'-',strcat(int2str(Fmax),'Hz'),'-
',strcat(int2str(moviment_duration),'ms'),'.mat');
                    load (file);
                    %
                    % Determina a quantidade de grupos, caso não tenha sido
                    % especificada, com base na quantidade de comandos a
                    % ser classificada.
                    %
                    if g <=1 || g> size(commands_to_consider,2)
                        g=size(commands_to_consider,2);
                    end
                    if size(commands_to_consider,2) == 2
                        TG=size(Dados,1)/g/2;
                    else
                        TG=size(Dados,1)/g;
                    end
                    %
                    % Aplica Selação Espacial de Característica
                    %
                    for m=1:size(channels_to_consider,2)
                        Dados_selecionados(:,8*(m-
1)+1:8*m)=Dados(:,channels_to_consider(m)*8-7:channels_to_consider(m)*8);
                    end
                    clear Dados; Dados=Dados_selecionados; clear
Dados_selecionados;
                    Dados=Dados*10^6;
                    %
                    % Normaliza os dados se a característica selecionada
                    % tenha foi a PSDMFi2.
                    %
                    if Normaliza == 1;
                        fprintf('Normalizando. ');
                        qtde_pts_psd = repmat( (bands(2,:)-
bands(1,:)).*(moviment_duration/1000), 1, size(Dados,2)/8);
                        Dados=bsxfun(@rdivide,Dados,qtde_pts_psd);
                    end
                    %
                    % Filtra e reordena os dados a serem utilizados com
                    % base nos comandos selecionados, agrupando
                    % sequencialmente
                    % dados da mesma classe, gerando também um vetor
```

```
                    % referente classe a que cada amostra pertence.
                    %
                    clear group;
                    if ( g == 4 && not(strcmp (classifier,'svm')) )
                    % 4 classes
                        group(1:TG) = {'mao direita'};
                        group(TG+1:2*TG) = {'mao esquerda'};
                        group(2*TG+1:3*TG) = {'braço direito'};
                        group(3*TG+1:4*TG) = {'braço esquerdo'};
                        group=group';
                        scenario='4G';
                    else
                        if size (commands_to_consider,2) == 4
                            if commands_to_consider == [1 3 2 4]
                    % lado equerdo versus direito
                                group(1:TG) = {'lado direito'};
                                group(TG+1:2*TG) = {'lado esquerdo'};
                                % Reordena a matriz dados para que esteja
                                % na ordem de comandos desejada
                                Dados=[ Dados(1:TG/2,:)'
Dados(TG+1:3*TG/2,:)' Dados(TG/2+1:TG,:)' Dados(3*TG/2+1:end,:)']';
                                scenario='lado';
                            end
                            if commands_to_consider == [1 2 3 4]
                    % mão versus braço
                                group(1:TG) = {'mão'};
                                group(TG+1:2*TG) = {'braço'};
                                scenario='membro';
                            end
                        else
                            if commands_to_consider == [1 2]
                    % mão esquerda versus mão direita
                                group(1:TG) = {'mão esquerda'};
                                group(TG+1:2*TG) = {'mão direita'};
                                scenario='mao_dir_vs_esq';
                            end
                            if commands_to_consider == [3 4]
                      % braço esquerdo versus braço direito
                                group(1:TG) = {'braço esquerdo'};
                                group(TG+1:2*TG) = {'braço direito'};
                                % Reordena a matriz dados para que esteja
                                % na ordem de comandos desejada
                                Dados=Dados(2*TG+1:end,:);
                                scenario='braco_dir_vs_esq';
                            end
                        end
                    end
                    if apply_pca == 1
                       fprintf('Aplicando PCA. ');
                       [pc,score,latent,tsquare] = princomp(Dados);
                       accountability=cumsum(latent)./sum(latent);
                       if ( strcmp (classifier,'lda') || strcmp
(classifier,'svm') )
                           Dados=Dados*pc(:,1:8);
                       else

Dados=Dados*pc(:,1:find(accountability>0.99,1),1);
                       end
```

```
                    end
                    %
                    % Executa a classificação.
                    %
                    switch lower(classifier)
                     case {'mlda'}
                        fprintf('MLDA com %s e vetor de %i na fase %s para
o voluntário %s.\n\n',Feature,moviment_duration,Phase,voluntario);
                        resultado=MLDA(g,TG,Dados);

                     case {'lda'}
                        fprintf('LDA com %s e vetor de %i na fase %s para o
voluntário %s.\n\n',Feature,moviment_duration,Phase,voluntario);
                        [ res Dados_Trein_Proj_LDA Dados_Test_Proj_LDA
]=LDA_alt(g,TG,Dados);
                        resultado(i,k,j,:,:)=[ squeeze(res(:,1:g))'
[zeros(1,g-1) mean(squeeze(res(:,g+1)))]'];

                     case {'linear'}
                        fprintf('Linear do MATLAB com %s e vetor de %i na
fase %s para o voluntário
%s.\n\n',Feature,moviment_duration,Phase,voluntario);
                        TS=ceil(0.1*TG);Mat_Conf=0;cp = classperf(group);
                        for o=1:size(Dados,1)
                        % roda diversas vezes para minimizar o efeito
                        % aleatório dos membros dos grupos
                            for n = 1:TS
                                indices = crossvalind('Kfold',group,TS);
                                test = (indices == n); train = ~test;
                                [C_LDA,err,P,logp,coeff] =
classify(Dados(test,:),Dados(train,:),group(train)');
                                classperf(cp,C_LDA,test);

[CM,grpOrder]=confusionmat(group(test)',C_LDA);
                                Mat_Conf=Mat_Conf+CM;
                            end
                        end
                        for cl=1:g
                            Mat_Conf(cl,g+1)=Mat_Conf(cl,cl)/TG*100;
                        % porcentagem de acerto de cada grupo
                        end
                        Mat_Conf(g+1,g+1)=(sum(Mat_Conf(1:g,g+1)))/g;
                        % porcentagem de classificação média
                        resultado(i,k,j,:,:)=Mat_Conf/o;

                     case {'quadratico'}
                        fprintf('Quadratica do MATLAB com %s e vetor de %i
na fase %s para o voluntário
%s.\n\n',Feature,moviment_duration,Phase,voluntario);
                        TS=ceil(0.1*TG);Mat_Conf=0;cp = classperf(group);
                        for o=1:size(Dados,1)
                        % roda diversas vezes para minimizar o efeito
                        % aleatório dos membros dos grupos
                            for n = 1:TS
                                indices = crossvalind('Kfold',group,TS);
                                test = (indices == n); train = ~test;
                                [C_LDA,err,P,logp,coeff] =
classify(Dados(test,:),Dados(train,:),group(train)','diagquadratic');
```

```
                                classperf(cp,C_LDA,test);

[CM,grpOrder]=confusionmat(group(test)',C_LDA);
                                Mat_Conf=Mat_Conf+CM;
                            end
                        end
                        for cl=1:g
                            Mat_Conf(cl,g+1)=Mat_Conf(cl,cl)/TG*100;
                        % porcentagem de acerto de cada grupo
                        end
                        Mat_Conf(g+1,g+1)=(sum(Mat_Conf(1:g,g+1)))/g;
                        % porcentagem de classificação média
                        resultado(i,k,j,:,:)=Mat_Conf/o;
                        % média de todas as rodadas

                    case {'svm'}
                        fprintf('SVM com %s e vetor de %i na fase %s para o
voluntário %s.\n\n',Feature,moviment_duration,Phase,voluntario);
                        if g == 2
                            cp = classperf(group); clear svm_groups;

svm_groups(find(ismember(group,group(1:TG))==1))=1;

svm_groups(find(ismember(group,group(1:TG))==0))=2;
                            %indices = crossvalind('Kfold',svm_groups,TG);
                            indices=[1:TG 1:TG]';
                            for n = 1:TG
                                test = (indices == n); train = ~test;

svmStruct=svmtrain(Dados(train,:),svm_groups(train),'kernel_function','line
ar','showplot',false);

C_SVM=svmclassify(svmStruct,Dados(test,:),'showplot',false);
                                classperf(cp,C_SVM,test);
                            end
                            res=[[cp.DiagnosticTable(1,1)
cp.DiagnosticTable(2,2)]./sum(cp.DiagnosticTable,2)']';
                            resultado(i,k,j,:,:)=[ res [ 0 mean(res)]' ];
                        else
                            svm_total_interact=0;scenario='4G';
                            warning('off','MATLAB:colon:nonIntegerIndex');
                            % Menssagem de erro identificada utilizando
                            % [LASTMSG, LASTID] = lastwarn
                            for svm_loop = 1:g-1
                                if svm_loop == 1
                                    clear group;
                                    group(1:TG) = {'mao direita'};
                                    group(TG+1:4*TG) = {'resto'};
                                    group=group';
                                    Dados_SVM=[ Dados(1:TG,:)'
Dados(TG+1:2*TG,:)' Dados(2*TG+1:3*TG,:)' Dados(3*TG+1:end,:)' ]';
                                end
                                if svm_loop == 2
                                    clear group;
                                    group(1:TG) = {'mao esquerda'};
                                    group(TG+1:3*TG) = {'resto'};
                                    group=group';
```

```
                                    Dados_SVM=[ Dados(TG+1:2*TG,:)'
Dados(2*TG+1:3*TG,:)' Dados(3*TG+1:end,:)' ]';
                                end
                                if svm_loop ==3
                                    clear group;
                                    group(1:TG) = {'braço direito'};
                                    group(TG+1:2*TG) = {'braço esquerdo'};
                                    group=group';
                                    Dados_SVM=[ Dados(2*TG+1:3*TG,:)'
Dados(3*TG+1:end,:)' ]';
                                end
                                clear svm_groups;

svm_groups(find(ismember(group,group(1:TG))==1))=1;

svm_groups(find(ismember(group,group(1:TG))==0))=2;
                                DiagnosticTable=zeros(2,2);
                                for o=1:g-svm_loop
                                    clear SVM_groups_to_GO Dados_SVM_to_GO
cp;
                                    SVM_groups_to_GO=[ svm_groups(1:TG)
svm_groups(o*TG+1:(o+1)*TG)];
                                    Dados_SVM_to_GO=[Dados_SVM(1:TG,:)'
Dados_SVM(o*TG+1:(o+1)*TG,:)'];
                                    cp = classperf(SVM_groups_to_GO);
                                    indices=[1:TG]; temp=indices;
                                    for ii=1:size(SVM_groups_to_GO,2)/TG-1
                                       temp=cat (2,temp,indices);
                                    end
                                    indices=temp'; clear temp ii;
                                    for n = 1:TG
                                        test = (indices == n); train =
~test;

svmStruct=svmtrain(Dados_SVM_to_GO(train,:),SVM_groups_to_GO(train),'kernel
_function','rbf','showplot',false);

C_SVM=svmclassify(svmStruct,Dados_SVM_to_GO(test,:),'showplot',false);
                                        classperf(cp,C_SVM,test);
                                    end

DiagnosticTable=cp.DiagnosticTable+DiagnosticTable;
                                end

x(svm_loop)=(DiagnosticTable(1,1)+DiagnosticTable(2,2))/sum(sum(DiagnosticT
able));
                                res(svm_loop,:,:)=DiagnosticTable(1,:);
                                % Salva os resultados da primeira linha da
                                % matriz de confusão para classes 1, 2 e 3
                            end
                            res = [ res(:,:,1) res(:,:,2) ];
                                % Ordena a matriz de confusão com os
                                % acertos na primeira coluna e os erros na
                                % segunda
                            res(4,:,:)=[DiagnosticTable(2,2)
DiagnosticTable(2,1)];
                                % Salva a última linha da matriz de
                                % confusão, invertendo  coluna 2 com 1 para
```

```
                                % seguir o critério acima (classe 4).
                            res=res(:,1)./(res(:,1)+res(:,2));
                                % Transforma os acertos em percentual
                            resultado(i,k,j,:,:)=[ res [0 0 0 mean(res)]'
];
                                % Salva o resultado final e a taxa média
                            clear res;
                        end
                    end
                    k=k+1;
                end
                j=j+1;k=1;
            end
            i=i+1;j=1;
        end
        k=1;
        for i=1:size(resultado,3)
            for j=1:size(resultado,2)
                resultado_final(sfs,(k-1)*size(resultado,2)+1:(k-
1)*size(resultado,2)+size(resultado,2))=resultado(:,j,i,size(resultado,4),s
ize(resultado,5));
                k=k+1;
            end
        end
        %
        % Salva a taxa de acerto de cada movimento caso especificado
        %
        k=1;
        total_cases=size(resultado,1)*size(resultado,2)*size(resultado,3);
        if Detail==1
            for i=1:size(resultado,3) % vetor
                for j=1:size(resultado,2) % fase do movimento
                    for f=1:size(resultado,1) % individuo
                        detalhe(total_cases*(sfs-1)+k,:)=[
squeeze(resultado(f,j,i,:,1))'
resultado(f,j,i,size(resultado,4),size(resultado,5))];
                        k=k+1;
                    end
                end
            end
        end
    sfs=sfs+1;
    end
    if apply_pca == 0

xlsfile=strcat(directory,'Resultados\Spatial_Feature_Selection_',classifier
,'_',Feature,'_',scenario,'_',num2str(Fmax),'_',date,'.xls');
    else

xlsfile=strcat(directory,'Resultados\Spatial_Feature_Selection_',classifier
,'_',Feature,'_',scenario,'_PCA_',num2str(Fmax),'_',date,'.xls');
    end
    warning('off','MATLAB:xlswrite:AddSheet');
    if exist ('Resultados','dir')

[SUCCESS,MESSAGE]=xlswrite(xlsfile,resultado_final,'Resultados','B4');

[SUCCESS,MESSAGE]=xlswrite(xlsfile,condvects(2:end,:),'Combinacoes','B4');
```

```
    else
        mkdir(directory,'\Resultados');

[SUCCESS,MESSAGE]=xlswrite(xlsfile,resultado_final,'Resultados','B4');

[SUCCESS,MESSAGE]=xlswrite(xlsfile,condvects(2:end,:),'Combinacoes','B4');
    end
    %
    % Salva a taxa de acerto de cada movimento caso especificado
    %
    if Detail==1
        [SUCCESS,MESSAGE]=xlswrite(xlsfile,detalhe,'detalhe','B4');
    end
    %
    % Apresenta os resultados
    %
    resultado_final'

end
```

O código abaixo aplica o classificador LDA aos dados e faz a validação do resultado da classificação utilizando a técnica conhecida como *Leave One Out*.

```
function [classific_LDA,Dados_LDA,LDA_Teste]=LDA(g,TG,Dados)

% g - número de grupos a serem reconhecidos ou classificados no seu caso no
% de movimentos, se forem todos seriam 4, mas vc pode trabalhar com parte
% dos dados, por exemplo movimentos do lado direito e diferenciar entre mão
% e braço ou pode trabalhar só com dados da mão ou só do braço e
% diferenciar entre os lados
% TG - tamanho do grupo
% Dados - dados da feature só dos grupos a serem estudados, com os grupos
% organizados em linhas. Por exemplo, as primeiras N linhas são do grupo 1
% a N
% seguintes são do grupo 2 e assim sucessivamente. Isso é necessário em
% função da forma como o matlab calcula a média

clear('Dados_LDA','LDA_Teste','DA','DT','classific_LDA')

% SELEÇÃO DA MATRIZ DE TREINAMENTO E DO ELEMENTO DE
% TESTE utilizando a técnica leave one out
S1=1;
for col=1:(g+1)
    for lin=1:g
        classific_LDA(lin,col)=0;
    end
end
Ntestes=0;  % numero total de testes
while S1 <= TG
    i=1;
    for k=1:1:(TG-1)     % gera matriz de aprendizado DA
        if i==S1
            i=i+1;
        end
        DA(k,:)=Dados(i,:);
        for h=1:1:(g-1)
```

```
            DA((k+(h*(TG-1))),:)=Dados((i+h*TG),:);
        end
        i=i+1;
    end
    for h=1:1:g
        DT(h,:)=Dados(S1+(TG*(h-1)),:); % gera matriz de teste DT
    end

    % ROTINA LDA

    [CPS_LDA]=LDA_NCP(DA,TG-1,g-1);
    Dados_LDA=DA*CPS_LDA; % Projeta a Matriz de Dados na direção das
                          % Componentes dada pelo LDA
    LDA_Teste=DT*CPS_LDA;

    % CÁLCULO DAS DISTANCIAS EUCLIDIANAS E TESTE DOS RESULTADOS
    classific_LDA=CLASSIFY(Dados_LDA,LDA_Teste,g,TG-1,g-1,classific_LDA);

    Ntestes=Ntestes+1;
    S1=S1+1;
end

for cl=1:g
    classific_LDA(cl,g+1)=classific_LDA(cl,cl)/TG*100;
    % porcentagem de acerto de cada grupo
end

classific_LDA(g+1,g+1)=(sum(classific_LDA(1:g,g+1)))/g;
   % porcentagem de classificação média



function [CP_LDA]=LDA_NCP(MATRIX_LDA,TG_LDA,NCP_LDA)

% [CP_LDA]=LDA_NCP(MATRIX_LDA,NCP_LDA,TG_LDA)
% CP_LDA - Matrix de projeção dos dados contendo as  ncp principais
% componentes
% MATRIX_LDA - matrix de dados cujas linhas contém as variáveis e as
% colunas as
% observações
% TG_LDA - Tamanho dos grupos
% NCP_LDA- número de componentes principais para redução de
% dimensionalidade, no máximo número de grupos de separação menos 1
%-------------------------------------------------------------------------


% ROTINA LDA
[MR,NR]=size(MATRIX_LDA); % Indica o tamanho da matriz de Dados - número de
                          % linhas [M] e de colunas [N]
med_total_LDA=mean(MATRIX_LDA); % Calcula as médias dos valores das colunas
                                % da matriz de Dados e retorna num vetor de
                                % 1xN
for i=1:TG_LDA:MR
    Matriz_med_grupo_LDA(i:i+TG_LDA-
1,1:NR)=ones(TG_LDA,1)*mean(MATRIX_LDA(i:i+TG_LDA-1,1:NR));
                                % Calcula a média dos dados pertencentes a
                                % cada grupo e constroi uma matriz
```

```
                                % multiplicando por um vetor coluna de 1's
                                % com o número de linha do tamanho do grupo
end
Matriz_med_total_LDA =ones(MR,1)*med_total_LDA;
                                % Multiplica o vetor M x 1 de 1's pelo
                                % vetor de médias total criando uma matriz
                                % de médias de mesma dimensão da matriz de
                                % médias dos grupos, e da matriz de Dados
inter_classes_LDA=Matriz_med_grupo_LDA-Matriz_med_total_LDA;
                                % Subtrai a matriz das médias dos grupos
                                % pela matriz das médias totais
SB_LDA=inter_classes_LDA'*inter_classes_LDA;
                                % Cria a matriz de covariância inter-
                                % classes
intra_classes_LDA=MATRIX_LDA-Matriz_med_grupo_LDA;
                                % Subtrai a matriz de dados pela matriz das
                                % médias dos grupos
SWF=intra_classes_LDA'*intra_classes_LDA;
                                % cria a matriz de covariâncias intra-
                                % classes (antes era SW_LDA)
[LDA_Avec,LDA_Aval]=eig((SWF\SB_LDA));
                                % calcula os autovetores e autovalores
                                % segundo o critério de Fisher
LDA_Aval=diag(LDA_Aval);
                                % cria uma matriz coluna com os
                                % autovalores, que estão na diagonal
                                % principal de LDA_Aval
[~,LDA_indice]=sort(LDA_Aval,'descend');
                                % Organiza os valores da matriz coluna
                                % LDA_Aval de autovalores em ordem
                                % crescente e retorna numa matriz coluna
                                % LDA_sort , e retorna também uma matriz
                                % coluna LDA_indice com os índices da
                                % posição dos autovalores da matriz
                                % LDA_Aval
LDA_Avec_ord=LDA_Avec(:,LDA_indice);
                                % ordena os autovetores de acordo com os
                                % seus respectivos autovalores nas colunas
                                % a matriz LDA_Avec_ord
 CP_LDA=LDA_Avec_ord(1:NR,(1:NCP_LDA));
                                % Matriz de Projeção com as componentes
                                % principais



function
[CLASSIFIC]=CLASSIFY(MATRIX,MATRIX_TESTE,NUM_GP,TAM_GP,NCP_DADOS,CLASSIFIC_
ANT)
% MATRIX - Matriz de Dados de treinamento
% MATRIX_TESTE - Matriz de Dados de teste
% NUM_GP - Número de grupos
% TAM_GP - Tamanho dos grupos
% NCP_DADOS - Número de componentes consideradas
% CLASSIFIC_ANT - índice de classificação anterior
%-------------------------------------------------------------------------
--------------------------
```

```
z=1;
for d=1:NUM_GP
    centrog(d,1:NCP_DADOS)=mean(MATRIX(z:z+TAM_GP-1,1:NCP_DADOS)); %calcula
os centros
    z=z+TAM_GP;
end
CLASSIFIC=CLASSIFIC_ANT;
for t=1:NUM_GP %cada um dos elementos de teste
    for d=1:NUM_GP % cada um dos grupos
        disti=0;
        for Ni=1:NCP_DADOS % todas as componentes
            disti=disti+((MATRIX_TESTE(t,Ni)-centrog(d,Ni))^2);
        end
        DIST(1,d)=sqrt(disti);  % calcula as distancias euclidianas
    end
    for d=1:NUM_GP
        if min(DIST(1,1:NUM_GP))==DIST(1,d) %Teste dos resultados
            CLASSIFIC(t,d)=CLASSIFIC(t,d)+1;
        end
    end
end
```

APÊNDICE E – Sistema de Automatização do Procedimento de Aquisição de dados

Descrição do sistema

O experimento teve como objetivo a obtenção de dados a respeito dos padrões cerebrais referentes a comandos motores sobre o sistema nervoso central de voluntários, utilizando Eletroencefalograma (EEG).

A aquisição de dados de EEG foi realizada por meio de um instrumento da AD Instruments, o qual é composto por uma touca de eletrodos, um bio-amplificador e um processador de sinais conectado a um computador com um software especializado para armazenamento e pós-tratamento dos sinais adquiridos.

Os voluntários que contribuíram para a aquisição de dados executaram repetidos movimentos, com os braços e com as mãos, para permitir a detecção dos padrões cerebrais referentes aos comandos motores do sistema nervoso central.

Para automatizar o procedimento de aquisição dos dados, foi desenvolvido em Visual C++ um sistema auxiliar que foi executado em um computador distinto daquele ao qual o sistema de aquisição foi conectado. O sistema desenvolvido enviava um sinal por meio da interface USB e/ou RS232 do computador para uma entrada do processador de sinais ao mesmo tempo em que apresentava ao voluntário o movimento a ser executado através de um comando visual no monitor. O objetivo desse sinal foi fornecer uma referência de tempo que permitisse o posterior correlacionamento das informações obtidas durante o processo de aquisição com as instruções passadas ao voluntário.

O sistema inicialmente exibiu ao voluntário as instruções a respeito do experimento que iria participar, obtidas em um arquivo texto previamente salvo em disco. Em seguida, aguardava que se teclasse ENTER para dar início ao experimento, quando passava a apresentar as seguintes instruções: fechar a mão direita, fechar a mão esquerda, flexionar o braço direito e flexionar o braço esquerdo em ordem desconhecida pelo voluntário. As instruções foram previamente armazenadas em um arquivo texto, uma por linha, já na ordem a ser aprestadas ao voluntário.

No instante em que a primeira instrução é apresentada no monitor ao voluntário, um sinal de 5 V era gerado no pino DTR da interface serial RS232 e mantido por um período de tempo constante até que a instrução seja removida da tela. Em quaisquer outras situações, a tensão deste pino é de 0 V. O sistema aguardava então por um período de tempo constante e repetia esse processo para a próxima instrução, até que todas elas tivessem sido apresentadas ao voluntário.

A cor de fundo do sistema foi sempre preta e as mensagens apresentadas de forma centralizada na tela, com fonte de tamanho a permitir sua fácil leitura pelo voluntário. O código foi desenvolvido de forma permitir que seja a porta serial que se deseja utilizar fosse configurável por meio de um arquivo texto.

Os tempos entre os movimentos e as quantidades de repetições do experimento foram obtidos pelo sistema também a partir de um arquivo texto, contendo um parâmetro por linha, respeitando a seguinte ordem:

- ✓ T1: período em que a instrução deve ser apresentada ao voluntário.
- ✓ T2: período de intervalo entre instruções, no qual a tela fica totalmente preta.
- ✓ T3: tempo para início automático da próxima repetição.
- ✓ N: quantidade de repetições.

O requisito de o sistema ler a sequência de movimentos, os intervalos de tempo e a quantidade de repetições a partir de um arquivo texto veio da necessidade de tornar possível a realização de ajustes durante os experimentos, sem a necessidade de revisão no seu código.

A sequência de movimentos, os intervalos de tempo e a quantidade de repetições são componentes fundamentais para a aquisição de dados neste experimento e foram dimensionados experimentalmente para garantir a obtenção de dados que sejam representativos e para garantir conforto aos voluntários e não causar fadiga, pois isso poderia alterar significativamente os padrões das ondas cerebrais e interferir negativamente nos resultados.

O experimento foi parametrizado da seguinte forma:

- ✓ T1 = 5 s, T2 = 4 s, T3 = 1 s, N=1 (previamente definidos).
- ✓ Quantidade total de movimentos = 256 (presentes no arquivo texto, um movimento por linha).

- ✓ Tipos de movimentos = 8 (previamente definidos)

Com essa configuração, obteve-se 45 repetições de cada um dos 4 movimentos, totalizando 180. Sendo a duração de cada movimento igual a 10 s, já com o período de descanso, e o intervalo entre subgrupos de 1 s, o tempo total do experimento foi de 56 minutos.

Informações Técnicas sobre Comunicação Serial

A figura abaixo traz a pinagem da interface serial no padrão RS232 e uma ilustração de um cabo conversor para interface USB.

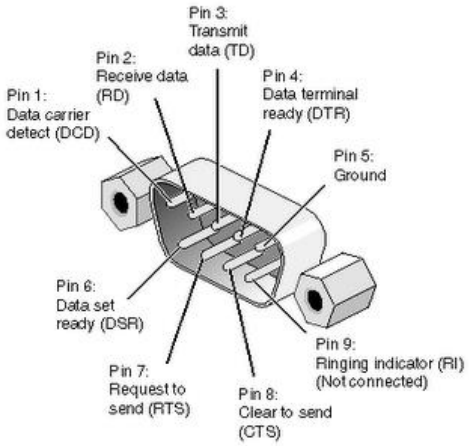

Código Fonte

O código referente ao software de automatização do procedimento de aquisição de dados foi desenvolvido em Visual C++ 2005 sobre WINDOWS XP e encontra-se integralmente listado abaixo.

```
#include "stdio.h"
#include "time.h"
#include "string.h"
#include "windows.h"
#include "math.h"


namespace Aquisição {
	using namespace System;
	using namespace System::ComponentModel;
	using namespace System::Collections;
	using namespace System::Windows::Forms;
	using namespace System::Data;
```

```
	using namespace System::Drawing;
	using namespace System::IO;
	using namespace System::IO::Ports;
	using namespace System::Threading;
	using namespace System::Text::RegularExpressions;

	/// <summary>
	/// Summary for Form1
	///
	/// WARNING: If you change the name of this class, you will need to
change the
	///          'Resource File Name' property for the managed resource
compiler tool
	///          associated with all .resx files this class depends on.
Otherwise,
	///          the designers will not be able to interact properly with
localized
	///          resources associated with this form.
	/// </summary>
	public ref class Form1 : public System::Windows::Forms::Form
	{
	public:
		Form1(void)
		{

			InitializeComponent();

			String^ path = Directory::GetCurrentDirectory();
			System::String^ msgfile1= System::String::Concat( path,
"\\mensagem1.txt");
			String^ msg1; String^ scum;
			StreamReader^ readmsg1 = File::OpenText(msgfile1);
			while ((scum = readmsg1->ReadLine()) != nullptr) {
				msg1= System::String::Concat( msg1, scum);
			}
			this->Bem_Vindo->Text = msg1;

			System::String^ msgfile2= System::String::Concat( path,
"\\mensagem2.txt");
			String^ msg2;
			StreamReader^ readmsg2 = File::OpenText(msgfile2);
			while ((scum = readmsg2->ReadLine()) != nullptr) {
				msg2= System::String::Concat( msg2, scum);
			}
			this->Explicação->Text = msg2;

		}

	protected:
		/// <summary>
		/// Clean up any resources being used.
		/// </summary>
		~Form1()
		{
			if (components)
			{
				delete components;
			}
```

```
            }
      private: System::Windows::Forms::TextBox^  Créditos;
      protected:
      private: System::Windows::Forms::TextBox^  Bem_Vindo;
      private: System::Windows::Forms::Button^  Configurar;
      private: System::Windows::Forms::Button^  Iniciar;
      private: System::Windows::Forms::Button^  Encerrar;
      private: System::Windows::Forms::Button^  Continuar;
      private: System::Windows::Forms::TextBox^  Explicação;
      private: System::Windows::Forms::TextBox^  Movimento;
      private:
      private: System::IO::Ports::SerialPort^  serialPort1;
      private: System::ComponentModel::IContainer^  components;
      private:
            /// <summary>
            /// Required designer variable.
            /// </summary>
      private:
                  // This is the method to run when the timer is raised.
                  static System::Windows::Forms::Timer^ myTimer = gcnew
System::Windows::Forms::Timer;
                  static int alarmCounter = 1;
      private: System::Windows::Forms::Button^  Aborta_Descanço;

                   static bool exitFlag = false;
                  static void TimerEventProcessor( Object^ /*myObject*/,
EventArgs^ /*myEventArgs*/ )
                  {
                  myTimer->Stop();
                  exitFlag = true;
                  }
      private:
            //static bool _continue;
            //static SerialPort^ _serialPort;


#pragma region Windows Form Designer generated code
            /// <summary>
            /// Required method for Designer support - do not modify
            /// the contents of this method with the code editor.
            /// </summary>
            void InitializeComponent(void)
            {
                  this->components = (gcnew
System::ComponentModel::Container());
                  System::ComponentModel::ComponentResourceManager^
resources = (gcnew
System::ComponentModel::ComponentResourceManager(Form1::typeid));
                  this->Créditos = (gcnew
System::Windows::Forms::TextBox());
                  this->Bem_Vindo = (gcnew
System::Windows::Forms::TextBox());
                  this->Encerrar = (gcnew
System::Windows::Forms::Button());
                  this->Configurar = (gcnew
System::Windows::Forms::Button());
                  this->Iniciar = (gcnew System::Windows::Forms::Button());
```

```
                this->Continuar = (gcnew
System::Windows::Forms::Button());
                this->Explicação = (gcnew
System::Windows::Forms::TextBox());
                this->Movimento = (gcnew
System::Windows::Forms::TextBox());
                this->serialPort1 = (gcnew
System::IO::Ports::SerialPort(this->components));
                this->Aborta_Descanço = (gcnew
System::Windows::Forms::Button());
                this->SuspendLayout();
                //
                // Créditos
                //
                this->Créditos->BackColor =
System::Drawing::Color::Black;
                this->Créditos->BorderStyle =
System::Windows::Forms::BorderStyle::None;
                this->Créditos->ForeColor =
System::Drawing::Color::White;
                this->Créditos->Location = System::Drawing::Point(150,
329);
                this->Créditos->Multiline = true;
                this->Créditos->Name = L"Créditos";
                this->Créditos->ReadOnly = true;
                this->Créditos->Size = System::Drawing::Size(479, 40);
                this->Créditos->TabIndex = 9;
                this->Créditos->Text = L"Ricardo Cainé Caracillo -
Metrando FEI 2011\r\n\r\nMaria Claudia Ferrari de Castro - "
                      L"Profa. Orientadora";
                this->Créditos->TextAlign =
System::Windows::Forms::HorizontalAlignment::Center;
                this->Créditos->TextChanged += gcnew
System::EventHandler(this, &Form1::Créditos_TextChanged);
                //
                // Bem_Vindo
                //
                this->Bem_Vindo->BackColor =
System::Drawing::Color::Black;
                this->Bem_Vindo->BorderStyle =
System::Windows::Forms::BorderStyle::None;
                this->Bem_Vindo->Cursor =
System::Windows::Forms::Cursors::Default;
                this->Bem_Vindo->Font = (gcnew
System::Drawing::Font(L"Lucida Console", 21.75F,
System::Drawing::FontStyle::Regular, System::Drawing::GraphicsUnit::Point,
                      static_cast<System::Byte>(0)));
                this->Bem_Vindo->ForeColor =
System::Drawing::Color::White;
                this->Bem_Vindo->ImeMode =
System::Windows::Forms::ImeMode::NoControl;
                this->Bem_Vindo->Location = System::Drawing::Point(150,
142);
                this->Bem_Vindo->Multiline = true;
                this->Bem_Vindo->Name = L"Bem_Vindo";
                this->Bem_Vindo->ReadOnly = true;
                this->Bem_Vindo->Size = System::Drawing::Size(479, 149);
                this->Bem_Vindo->TabIndex = 8;
```

```
                //this->Bem_Vindo->Text = L"Bem-vindo ao experimento
Estudo de Biopotenciais Cerebrais para Identificação de "
                //    L"Movimentos do Braço Humano";
                this->Bem_Vindo->TextAlign =
System::Windows::Forms::HorizontalAlignment::Center;
                //
                // Encerrar
                //
                this->Encerrar->Location = System::Drawing::Point(554,
399);
                this->Encerrar->Name = L"Encerrar";
                this->Encerrar->Size = System::Drawing::Size(75, 23);
                this->Encerrar->TabIndex = 7;
                this->Encerrar->Text = L"Encerrar";
                this->Encerrar->UseVisualStyleBackColor = true;
                this->Encerrar->Click += gcnew System::EventHandler(this,
&Form1::Encerrar_Click);
                //
                // Configurar
                //
                this->Configurar->Location = System::Drawing::Point(345,
399);
                this->Configurar->Name = L"Configurar";
                this->Configurar->Size = System::Drawing::Size(75, 23);
                this->Configurar->TabIndex = 6;
                this->Configurar->Text = L"Configurar";
                this->Configurar->UseVisualStyleBackColor = true;
                //
                // Iniciar
                //
                this->Iniciar->Location = System::Drawing::Point(150,
399);
                this->Iniciar->Name = L"Iniciar";
                this->Iniciar->Size = System::Drawing::Size(75, 23);
                this->Iniciar->TabIndex = 5;
                this->Iniciar->Text = L"Iniciar";
                this->Iniciar->UseVisualStyleBackColor = true;
                this->Iniciar->Click += gcnew System::EventHandler(this,
&Form1::Iniciar_Click);
                //
                // Continuar
                //
                this->Continuar->Location = System::Drawing::Point(150,
398);
                this->Continuar->Name = L"Continuar";
                this->Continuar->Size = System::Drawing::Size(75, 23);
                this->Continuar->TabIndex = 10;
                this->Continuar->Text = L"Continuar";
                this->Continuar->UseVisualStyleBackColor = true;
                this->Continuar->Visible = false;
                this->Continuar->Click += gcnew
System::EventHandler(this, &Form1::Continuar_Click);
                //
                // Explicação
                //
                this->Explicação->BackColor =
System::Drawing::Color::Black;
```

```
                this->Explicação->BorderStyle =
System::Windows::Forms::BorderStyle::None;
                this->Explicação->Font = (gcnew
System::Drawing::Font(L"Lucida Console", 14.25F,
System::Drawing::FontStyle::Regular, System::Drawing::GraphicsUnit::Point,
                      static_cast<System::Byte>(0)));
                this->Explicação->ForeColor =
System::Drawing::Color::White;
                this->Explicação->Location = System::Drawing::Point(150,
122);
                this->Explicação->Multiline = true;
                this->Explicação->Name = L"Explicação";
                this->Explicação->ReadOnly = true;
                this->Explicação->Size = System::Drawing::Size(478, 270);
                this->Explicação->TabIndex = 11;
                //this->Explicação->Text = resources-
>GetString(L"Explicação.Text");
                this->Explicação->TextAlign =
System::Windows::Forms::HorizontalAlignment::Center;
                this->Explicação->Visible = false;
                //
                // Movimento
                //
                this->Movimento->BackColor =
System::Drawing::Color::Black;
                this->Movimento->BorderStyle =
System::Windows::Forms::BorderStyle::None;
                this->Movimento->Font = (gcnew
System::Drawing::Font(L"Lucida Console", 21.75F));
                this->Movimento->ForeColor =
System::Drawing::Color::White;
                this->Movimento->Location = System::Drawing::Point(149,
122);
                this->Movimento->Multiline = true;
                this->Movimento->Name = L"Movimento";
                this->Movimento->ReadOnly = true;
                this->Movimento->Size = System::Drawing::Size(479, 174);
                this->Movimento->TabIndex = 12;
                this->Movimento->Text = L"Movimente o ...";
                this->Movimento->TextAlign =
System::Windows::Forms::HorizontalAlignment::Center;
                this->Movimento->Visible = false;
                this->Movimento->TextChanged += gcnew
System::EventHandler(this, &Form1::Movimento_TextChanged);
                //
                // Aborta_Descanço
                //
                this->Aborta_Descanço->Location =
System::Drawing::Point(345, 399);
                this->Aborta_Descanço->Name = L"Aborta_Descanço";
                this->Aborta_Descanço->Size = System::Drawing::Size(75,
23);
                this->Aborta_Descanço->TabIndex = 13;
                this->Aborta_Descanço->Text = L"Continuar";
                this->Aborta_Descanço->UseVisualStyleBackColor = true;
                this->Aborta_Descanço->Visible = false;
                this->Aborta_Descanço->Click += gcnew
System::EventHandler(this, &Form1::Aborta_Descanso);
```

```
                //
                // Form1
                //
                this->AutoScaleDimensions = System::Drawing::SizeF(6,
13);
                this->AutoScaleMode =
System::Windows::Forms::AutoScaleMode::Font;
                this->BackColor =
System::Drawing::SystemColors::ControlText;
                this->ClientSize = System::Drawing::Size(794, 574);
                this->Controls->Add(this->Aborta_Descanço);
                this->Controls->Add(this->Continuar);
                this->Controls->Add(this->Créditos);
                this->Controls->Add(this->Encerrar);
                this->Controls->Add(this->Configurar);
                this->Controls->Add(this->Iniciar);
                this->Controls->Add(this->Bem_Vindo);
                this->Controls->Add(this->Explicação);
                this->Controls->Add(this->Movimento);
                this->FormBorderStyle =
System::Windows::Forms::FormBorderStyle::FixedSingle;
                this->MaximizeBox = false;
                this->MinimizeBox = false;
                this->Name = L"Form1";
                this->StartPosition =
System::Windows::Forms::FormStartPosition::CenterScreen;
                this->Text = L"Controla Aquisição";
                this->TopMost = true;
                this->ResumeLayout(false);
                this->PerformLayout();

            }
#pragma endregion
private: System::Void Encerrar_Click(System::Object^  sender,
System::EventArgs^  e) {
                 Application::Exit();
             }
private: System::Void Iniciar_Click(System::Object^  sender,
System::EventArgs^  e) {
                 this->Bem_Vindo->Visible=false;
                 this->Créditos->Visible=false;
                 this->Configurar->Visible=false;
                 this->Iniciar->Visible=false;
                 this->Continuar->Visible=true;
                 this->Continuar->Visible=true;
                 this->Explicação->Visible=true;
             }
private: System::Void Continuar_Click(System::Object^  sender,
System::EventArgs^  e) {
                this->Encerrar->Visible=false;
                this->Continuar->Visible=false;
                this->Explicação->Visible=false;
                this->Movimento->Visible=true;
                //
                // Ler os parâmetros de configuração
                //
                String^ path = Directory::GetCurrentDirectory();
```

```
                System::String^ cfgfile= System::String::Concat( path,
"\\configuracao.txt");
                StreamReader^ din = File::OpenText(cfgfile);
            String^ cfg; String^ T1; String^ T2; String^ T3; String^ N;
String^ COM;
                int T1d; int T2d; int T3d; int Nd;
                Regex^ regex1 = gcnew
Regex("(?<variable>[^=]+)=(?<content>.+)");
            while ((cfg = din->ReadLine()) != nullptr) {
                      Match^ m = regex1->Match( cfg );
                      if ( Regex::IsMatch( cfg, "T1=",
                   RegexOptions::IgnoreCase ) ) {
                                  T1=m->Groups["content"]->Value;
                                  T1d=Int32::Parse(T1);
                                  }
                      if ( Regex::IsMatch( cfg, "T2=",
                   RegexOptions::IgnoreCase ) ) {
                                  T2=m->Groups["content"]->Value;
                                  T2d=Int32::Parse(T2);
                                  }
                      if ( Regex::IsMatch( cfg, "T3=",
                   RegexOptions::IgnoreCase )) {
                                  T3=m->Groups["content"]->Value;
                                  T3d=Int32::Parse(T3);
                                  }
                      if ( Regex::IsMatch( cfg, "N=",
                   RegexOptions::IgnoreCase )) {
                                  N=m->Groups["content"]->Value;;
                                  Nd=Int32::Parse(N);
                                  }
                      if ( Regex::IsMatch( cfg, "COM=",
                   RegexOptions::IgnoreCase ))
                                  COM=m->Groups["content"]->Value;
                      }

                // Inicializar a porta Serial
                this->serialPort1->PortName = COM;
                serialPort1->Open();

                // Le os comandos a partir do arquivo texto
                System::String^ cmdfile= System::String::Concat( path,
"\\movimentos.txt");
                StreamReader^ din1 = File::OpenText(cmdfile);
            String^ str1;
                array<String^>^ comandos = gcnew array< String^ >(200);;
            int qtde = 0;
            while ((str1 = din1->ReadLine()) != nullptr) {
                   comandos[qtde] = str1;
                   qtde++;
                }

                // Executa o experimento
                int i; int group=1; int desc = (qtde/Nd);
                myTimer->Tick += gcnew EventHandler( TimerEventProcessor
);
                myTimer->Enabled = true;
                while (i < qtde) {
                      myTimer->Interval = T1d*1000;
```

```
                        myTimer->Start();
                        while ( exitFlag == false ) {
                              Application::DoEvents();
                              this->Movimento->Text = comandos[i];
                              this->serialPort1->DtrEnable = true;
                              }
                        this->serialPort1->DtrEnable = false;
                        exitFlag = false;
                        myTimer->Interval = T2d*1000;
                        myTimer->Start();
                        while ( exitFlag == false ) {
                              Application::DoEvents();
                              this->Movimento->Text = "";
                              }
                        exitFlag = false;
                        if ( i== group*desc-1) {
                              this->Aborta_Descanço->Visible = true;
                              this->Encerrar->Visible=true;
                              group++;
                              myTimer->Interval = T3d*1000;
                              myTimer->Start();
                              while ( exitFlag == false ) {
                                    Application::DoEvents();
                                    this->Movimento->Text = "Intervalo de
descanso";
                                    }
                              exitFlag = false;
                              this->Aborta_Descanço->Visible = false;
                              this->Encerrar->Visible=false;
                        }
                        else this->Aborta_Descanço->Visible = false; this-
>Encerrar->Visible=false;
                        i++;
                  }
                  this->Encerrar->Visible=true;
                  serialPort1->Close();
                  this->Movimento->Text = "Obrigado por participar do
experimento";
            }
private: System::Void Créditos_TextChanged(System::Object^  sender,
System::EventArgs^  e) {
            }
private: System::Void Aborta_Descanso(System::Object^  sender,
System::EventArgs^  e) {
                   myTimer->Stop();
                   exitFlag = true;
            }
private: System::Void Movimento_TextChanged(System::Object^  sender,
System::EventArgs^  e) {
            }
};
}
```