



TESTE F ESPECTRAL BAYESIANO PARA CLASSIFICAÇÃO DE MOVIMENTOS  
DA MÃO COM SINAIS EMG

Raffaela de Castro Cunha

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

Orientadores: Carlos Julio Tierra-Criollo

Antonio Mauricio Ferreira

Leite Miranda de Sá

Rio de Janeiro  
Setembro de 2016

TESTE F ESPECTRAL BAYESIANO PARA CLASSIFICAÇÃO DE MOVIMENTOS  
DA MÃO COM SINAIS EMG

Raffaella de Castro Cunha

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

Examinada por:

---

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

---

Prof. Luciano Luporini Menegaldo, D.Sc

---

Prof. Eduardo Vieira Leão Nunes, D.Sc.

---

Prof. Marco Antonio Cavalcanti Garcia, D.Sc.

RIO DE JANEIRO, RJ - BRASIL

SETEMBRO DE 2016

Cunha, Raffaella de Castro

Teste F Espectral Bayesiano para classificação de movimentos da mão com sinais EMG / Raffaella de Castro Cunha – Rio de Janeiro: UFRJ/COPPE, 2016.

X, 74 p.; 29,7 cm.

Orientadores: Carlos Julio Tierra-Criollo

Antônio Mauricio Ferreira Leite Miranda de Sá

Dissertação (mestrado) – UFRJ / COPPE/ Programa de Engenharia Biomédica, 2016.

Referências Bibliográficas: p. 67 - 69.

1. Eletromiografia 2. Teste F Espectral. 3. Classificação do movimento da mão. 4. Acidente Vascular Encefálico. I. Tierra-Criollo, Carlos Julio *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Biomédica. III. Título.

## **DEDICATÓRIA**

*À minha família:  
Francisco, Ivonete e Gabrielle.*

## AGRADECIMENTOS

Ao Professor Carlos Julio por dedicar-se de forma tão atenciosa e paciente a me orientar na realização deste trabalho e pelos valiosos ensinamentos que certamente levarei para minha vida pessoal e profissional.

Ao Professor Antonio Mauricio pela orientação fundamental no desenvolvimento deste trabalho.

À Professora Ana Paula Fontana e toda a sua equipe do Serviço de Fisioterapia do HUCFF (em especial à Gislaine, Inaiacy, Ana Victoria e Fernanda), por disponibilizarem o espaço para a realização das coletas de sinais e pela grande disposição em ajudar, contribuindo muito para este trabalho.

Aos Professores Antonio Fernando Catelli Infantosi (*in memoriam*), Mauricio Cagy e Paulo José Guimarães por toda a experiência passada e por procurarem sempre contribuir de diversas formas na formação de seus alunos.

Ao Alexandre Jacobina, pelo excelente trabalho como secretário do programa e toda a prontidão em ajudar os alunos.

Ao Pablo Cevallos e ao Aluizio D’Affonsêca pela amizade e pela generosidade ao transmitirem seus conhecimentos e se disporem a ajudar sempre que possível.

À Mariana Massote, pela companhia e amizade ao longo de toda esta trajetória na UFRJ.

À Lorena Caruso e à Beatriz Junqueira pelos bate-papos e longas risadas, que certamente fizeram este período muito mais leve e feliz.

Aos colegas do PEB que estiveram comigo durante este período, pela pronta ajuda, parceria e companhia sempre agradável.

Ao Víctor Campos, pela inestimável ajuda e apoio durante todo este período.

Ao Francisco Cunha e à Ivonete Cunha por me apoiarem e me guiarem de forma incondicional ao longo de toda esta caminhada, possibilitando que eu chegasse até aqui.

À Gabrielle Cunha e ao Anderson Diniz por todo o suporte e incentivo em mais uma etapa.

Ao Augusto Alves Jr. pelos valiosos conselhos e pela experiência passada.

A todos os voluntários dos experimentos realizados neste trabalho, por disponibilizarem seus tempos pra que esta pesquisa fosse possível.

Aos órgãos de fomento, CAPES e CNPq, pelo apoio financeiro.

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

## TESTE F ESPECTRAL BAYESIANO PARA CLASSIFICAÇÃO DE MOVIMENTOS DA MÃO COM SINAIS EMG

Raffaella de Castro Cunha

Setembro/2016

Orientadores: Carlos Julio Tierra-Criollo

Antonio Mauricio Ferreira Leite Miranda de Sá.

Programa: Engenharia Biomédica

Sistemas de controle baseados em eletromiografia (EMG) capazes de reconhecer a intenção de movimento do indivíduo e convertê-la no acionamento de um dispositivo externo são utilizados como apoio à reabilitação de indivíduos acometidos por prejuízos motores, como a hemiparesia após Acidente Vascular Encefálico (AVE). Este trabalho desenvolve um novo algoritmo para a classificação de sinais de EMG entre movimentos de flexão e extensão dos dedos da mão, além do relaxamento dos mesmos, com base na razão entre as energias de sinais de dois músculos. A classificação divide-se em duas etapas que se complementam através de uma árvore de decisão: a primeira decide entre movimento, relaxamento e repouso e a segunda entre extensão e flexão. Ambas etapas utilizam o teste F espectral (TFE) para identificar diferenças entre as densidades espectrais de potências dos sinais de EMG, diferindo apenas nas abordagens estatísticas. O classificador foi avaliado com sinais coletados em 25 indivíduos com função motora normal e 7 pacientes com hemiparesia após AVE. Os resultados mostraram uma acurácia média de aproximadamente 90% entre os pares de músculos avaliados no primeiro grupo. Foram realizados estudos de caso que mostram que é possível obter resultados satisfatórios para sujeitos em estágios menos severos de hemiparesia (acurácia  $\geq 70\%$ ), embora ainda inferiores aos daqueles com função motora normal. Algumas adaptações na técnica aplicada devem levar a um melhor desempenho dos classificadores para pacientes.

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

EMG BASED CLASSIFICATION OF HANDS MOVEMENTS USING BAYESIAN  
SPECTRAL F TEST

Raffaella de Castro Cunha

September/2016

Advisors: Carlos Julio Tierra-Criollo

Antonio Mauricio Ferreira Leite Miranda de Sá.

Department: Biomedical Engineering

Control systems based on Electromyography (EMG) capable of recognizing a subject's intention of movement and convert it to set an external device are used to support rehabilitation of individuals with motor impairment, such as post stroke hemiparesis. This work develops an algorithm for classifying EMG signals on hands flexion, extension and relaxing based on the ratio between the energies of two muscles. The classification method is divided into two complementary steps, where the first one decides among movement, relaxing and rest and the second one decides between flexion and extension. Both are based on Spectral F Test (SFT) to identify spectral differences between signals, differing only on the method used for determining the threshold of classifying. The classifier was assessed on signals collected in 25 individuals with normal motor function and 7 post stroke subjects with hemiparesis. The results for the first group show an average accuracy ratio of 90%. Case studies were performed showing that it is possible to obtain satisfactory results for subjects in less severe stages of hemiparesis (accuracy  $\geq 70\%$ ), although it is still lower than the performance of the other group. Some adaptations should be performed to improve the classifier performance.

## SUMÁRIO

1	Introdução.....	1
1.1	Acidente Vascular Encefálico (AVE) e deficiências motoras .....	1
1.2	Tecnologias para assistência e apoio à reabilitação .....	1
1.3	Objetivo .....	2
1.4	Objetivos específicos .....	3
1.5	Estrutura do Trabalho .....	3
2	Revisão da literatura.....	4
2.1	A hemiparesia após AVE.....	4
2.2	Reabilitação e tecnologias assistivas .....	4
2.3	Sinais de Eletromiografia (EMG) .....	5
2.4	Controle de dispositivos por EMG .....	8
2.5	Teoria da detecção .....	13
2.6	Classificadores .....	15
2.6.1	O Teste F espectral (TFE) .....	15
2.6.2	Análise de Discriminantes Lineares (LDA) .....	18
2.6.3	Máquina de Vetores de Suporte (SVM) .....	19
3	Materiais e métodos.....	21
3.1	Sistema de aquisição de sinais .....	21
3.2	Protocolo experimental .....	22
3.3	Processamento de sinais.....	25
3.3.1	Identificação dos instantes de movimento pelo sinal de acelerometria....	26
3.3.2	Extração de características.....	27
3.3.3	Identificação de ativação e desativação muscular por canal com TFE ....	28
3.3.4	Classificação inicial entre extensão e flexão .....	30
3.3.5	Classificação final (Árvore de decisão).....	33
3.3.6	Avaliação do classificador.....	34
3.4	Estimativa de co-contração .....	36
4	Resultados.....	37
4.1	Desempenho teórico do classificador Bayesiano.....	37
4.2	Identificação de ativação e desativação muscular .....	38
4.3	Classificador com TFE bayesiano .....	40
4.4	Classificadores LDA e SVM .....	43



4.5	Desempenho dos classificadores.....	46
4.6	Estimativas de co-contracção .....	50
4.7	Estudo de caso com pacientes (Grupo B) .....	51
4.7.1	Voluntário B01 .....	51
4.7.2	Voluntário B02 .....	57
4.7.3	Comparações entre desempenho e FMA de pacientes .....	61
5	Discussão.....	62
6	Conclusão .....	66
7	Bibliografia.....	67
8	Apêndice A.....	70
9	Apêndice B .....	72
9.1	Voluntário B03.....	72
9.2	Voluntário B04.....	73
9.3	Voluntário B05.....	73
9.4	Voluntário B06.....	74
9.5	Voluntário B07.....	74

## NOMENCLATURA

AVE – Acidente Vascular Encefálico  
AVD – Atividades de Vida Diária  
ECD – Extensor Comum dos Dedos  
ECP - Extensor Curto do Polegar  
EEG – Eletroencefalografia  
EMG – Eletromiografia  
FLP – Flexor Longo do Polegar  
FPD – Flexor Profundo dos Dedos  
FSD – Flexor Superficial dos Dedos  
LDA – Discriminantes Lineares de Fisher  
MUAP – Potencial de ação de unidade motora  
PID – Primeiro Interosseo Dorsal  
PSD – Densidade Espectral de Potências  
SVM – Máquina de Vetores de Suporte  
TFE – Teste F Espectral

# **1 Introdução**

## **1.1 Acidente Vascular Encefálico (AVE) e deficiências motoras**

Diversas patologias neurológicas ou episódios traumáticos podem levar à perda de controle motor dos indivíduos acometidos. Dentre os episódios mais comuns, está o AVE, sendo este o segundo com maior incidência na população mundial. O AVE ocorre pela interrupção de parte da circulação sanguínea no encéfalo, devido ao rompimento ou oclusão de vasos que levam sangue ao mesmo, causando danos ao tecido cerebral (“WHO | Stroke, Cerebrovascular accident” 2014). Em 65% dos casos de sobrevivência a este episódio, o indivíduo apresenta comprometimentos funcionais (Teo e Chew 2014), sendo o mais comum a perda de controle motor ou de força de músculos da face, dos membros superiores ou inferiores no lado do corpo contralateral ao hemisfério cerebral onde ocorreu a lesão, condição chamada de hemiparesia.

Em 73 a 88% dos sobreviventes, a função de membro superior é afetada, entre os quais, 55 a 75% são casos de hemiparesia (de Medeiros et al. 2014). Sendo o membro superior um segmento muito importante para a realização de funções como manipulação, preensão e alcance, a perda de sua função pode afetar de forma significativa a realização das atividades de vida diárias (AVDs) dos indivíduos, tendo como consequência a perda de qualidade de vida (de Medeiros et al. 2014; Brol e Magagnin 2010). Uma das condições que decorre da maioria dos casos de hemiparesia após AVE é a espasticidade, a qual caracteriza-se por um aumento no tônus muscular ao longo do tempo, o que pode dificultar a reabilitação do paciente (Brol e Magagnin 2010).

## **1.2 Tecnologias para assistência e apoio à reabilitação**

Diversas técnicas têm sido aplicadas com o objetivo de reduzir os efeitos das disfunções motoras causadas aos pacientes. Em todos os casos, para que a reabilitação seja eficaz, é necessário que o treinamento seja repetitivo e ao mesmo tempo motivador para o indivíduo (Kwakkel, Kollen, e Krebs 2007). Dada a dificuldade de se conduzir treinamentos que atendam a estes requisitos na clínica, tecnologias de suporte têm sido amplamente empregadas na reabilitação, tais como robôs e exoesqueletos. Tratamentos com o uso de tais tecnologias já foram relatados na literatura, promovendo melhores resultados em relação aos tratamentos convencionais (Kwakkel, Kollen, e Krebs 2007; Dipietro et al. 2005).

Uma forma de se controlar estes dispositivos de forma natural é por meio de sinais de eletromiografia (EMG). Alguns estudos já mostraram a possibilidade de se detectar atividade de EMG voluntária em pacientes hemiparéticos após AVE (Dipietro et al. 2005; Zhang et al. 2013) . Deve-se, porém, considerar que há diversas alterações no que diz respeito ao recrutamento motor e características musculares decorrentes da lesão, influenciando em características do sinal de EMG destes indivíduos (Dipietro et al. 2005; Zhou, Suresh, e Rymer 2007). De forma geral, membros paréticos apresentam maiores níveis de co-contracção (contração simultânea dos músculos agonistas e antagonistas a um dado movimento) que em sujeitos com função motora normal e menores níveis de força muscular. Na literatura, usualmente se estima a co-contracção por meio da razão entre os valores RMS de um músculo antagonista e um músculo agonista a um dado movimento (Chae et al. 2002; Ohn et al. 2013). Este dado pode, além de fornecer informações sobre o estado do paciente, ajudar a distinguir entre movimentos opostos, como a extensão e flexão dos dedos da mão.

Uma contração muscular é caracterizada pelo aumento do número de unidades motoras recrutadas e de suas taxas de disparo, levando a variações de energia em certas bandas de frequência (Merletti e Parker 2004). Assim, a densidade espectral de potências (PSD) do sinal de EMG pode fornecer dados úteis para a detecção de ativações musculares e, utilizando-se múltiplos canais, para o reconhecimento de padrões em diferentes movimentos. Diversos trabalhos realizaram o controle de dispositivo por EMG com base em características em tempo-frequência do EMG, levando a bons resultados (M. Khezri e Jahed 2007; Mahdi Khezri e Jahed 2007). Para realizar a classificação dos movimentos, características com base em PSD para diferentes estados de ativação devem ser comparadas. Neste contexto, o Teste F Espectral (TFE) pode ser utilizado, visto que é um teste estatístico para inferir diferenças entre duas estimativas espectrais (Simpson et al. 2000; Sá et al. 2009).

Propõe-se neste trabalho o desenvolvimento e avaliação de uma técnica para classificação de movimentos de extensão e flexão dos dedos da mão, com base na razão entre as variâncias de sinais de EMG de dois músculos, sendo um agonista e o outro antagonista aos movimentos.

### **1.3 Objetivo**

O objetivo deste trabalho foi desenvolver e avaliar uma técnica de processamento de sinais estatístico, com base no teste F espectral, para classificação de movimentos de

abertura e fechamento da mão baseada em sinais de EMG. Esta técnica deve ser posteriormente aplicada no controle em tempo real de dispositivos externos por pacientes com hemiparesia após AVE e na avaliação dos estágios de recuperação motora e funcional destes pacientes.

#### **1.4 Objetivos específicos**

Os objetivos específicos deste trabalho foram:

- Desenvolver algoritmos para detectar e classificar movimentos de abertura e fechamento da mão com base no TFE da razão entre as variâncias dos sinais provenientes de dois músculos, sendo um agonista e o outro antagonista aos movimentos, com abordagem bayesiana;
- Avaliar o funcionamento do classificador a partir de sinais de EMG coletados em sujeitos com função normal de membro superior e em membros paréticos de pacientes após AVE. Comparar seu desempenho com classificadores LDA (Análise de Discriminantes Lineares) e SVM (Máquina de Vetores de Suporte).
- Realizar uma análise *offline* preliminar das características extraídas dos sinais de EMG de pacientes, averiguando a possibilidade de utilização das mesmas como indicadores do nível de recuperação funcional e motora do paciente.

#### **1.5 Estrutura do Trabalho**

No Capítulo 1 foram apresentados a introdução e objetivos do trabalho. No Capítulo 2, realiza-se uma revisão da literatura, em que se caracteriza a hemiparesia após AVE e tecnologias empregadas na reabilitação, apresenta-se uma revisão sobre sinais de EMG e técnicas de processamento de sinais utilizadas para classificação *offline* de movimentos da mão com base nestes sinais, e, finalmente, explica-se os fundamentos teóricos e técnicas de processamento de sinais que são utilizadas neste trabalho. No Capítulo 3, descreve-se a metodologia utilizada na coleta de sinais de EMG, na extração de características e na classificação destes sinais. A seguir, no capítulo 4, descreve-se os resultados relativos à avaliação das características extraídas pelo algoritmo implementado e do desempenho do classificador. No Capítulo 5, os resultados são discutidos e, por fim, apresenta-se a conclusão, no Capítulo 6.

## **2 Revisão da literatura**

### **2.1 A hemiparesia após AVE**

A hemiparesia é um comprometimento motor que ocorre em apenas um lado do corpo, em consequência de episódios de AVE. Tal comprometimento caracteriza-se pela perda de força e de coordenação motora levando à perda total ou parcial da funcionalidade do membro acometido. Quando a hemiparesia se manifesta no membro superior, provoca sérios prejuízos à qualidade de vida do indivíduo, pois funções básicas, como manipulação, preensão e alcance são bastante dificultadas, prejudicando a realização normal das AVDs (de Medeiros et al. 2014; Brol e Magagnin 2010).

A perda de força e de coordenação nos membros paréticos é explicada principalmente por um recrutamento inadequado das unidades motoras e também por mudanças nas características musculares do membro atingido. Alguns estudos demonstraram que ocorre um aumento na co-contracção (ativação simultânea de músculos agonistas e antagonistas) correlacionada à severidade da hemiparesia, o que leva à perda de sinergia no movimento (Ohn et al. 2013). Em grande parte dos casos, os membros afetados apresentam espasticidade, a qual caracteriza-se por um tônus muscular aumentado de forma anormal (Ohn et al. 2013). Na hemiparesia de membro superior, a espasticidade manifesta-se principalmente nos músculos flexores, de forma que o punho e os dedos ficam permanentemente flexionados, dificultando a execução de movimentos básicos da mão.

### **2.2 Reabilitação e tecnologias assistivas**

Diversos tratamentos podem ser empregados de forma a amenizar os fatores responsáveis por prejudicar a função do membro parético. Estes tratamentos em geral procuram induzir melhoras de forma passiva, como por exemplo pela realização de movimentos passivos no membro visando principalmente à diminuição da espasticidade, ou, de forma ativa, como pelo uso de estimulação elétrica funcional, imaginação motora (Santos-Couto-Paz, Teixeira-Salmela, e Tierra-Criollo 2013) e terapias de indução do movimento, com foco na recuperação da habilidade motora e da força (Ashford et al. 2008).

Alguns estudos mostram que a eficácia em tais tratamentos é maior quando estes cumprem alguns requisitos, tais como: incluírem treinamentos repetitivos, serem orientados a tarefas e serem significativos para o paciente, despertando o interesse e

motivando-o (Kwakkel, Kollen, e Krebs 2007). Especialmente durante um período crítico após o episódio de AVE, se o tratamento for realizado de forma intensiva, há grandes possibilidades de se reduzirem significativamente os danos (Eriksson, Mataric, e Winstein 2005; Santos-Couto-Paz, Teixeira-Salmela, e Tierra-Criollo 2013). Porém, tratamentos convencionais realizados em ambientes clínicos dificilmente conseguem cumprir estes requisitos. Assim, tecnologias de assistência à reabilitação, como robôs, próteses e exoesqueletos, têm sido propostas na literatura e implementadas como produtos comerciais para uso clínico. Alguns estudos já comprovaram a maior eficácia nos tratamentos que incluem tais tecnologias, além de promoverem diversos benefícios adicionais como, por exemplo, a redução da dependência do paciente de um profissional de saúde para execução do treinamento, permitindo que este seja feito mais vezes e com maior frequência, além da motivação proporcionada ao paciente, devido ao *feedback* que em geral pode ser obtido (Kwakkel, Kollen, e Krebs 2007; Dipietro et al. 2005). Tais dispositivos tecnológicos permitem que o usuário exerça algum tipo de interação com os mesmos, seja por meio de botões de comando a serem acionados pelo próprio usuário, ou de sensores que fornecerão informações sobre posição ou intenção de movimento deste. No caso das chamadas Interfaces Cérebro Máquinas (ICMs), por exemplo, sinais cerebrais são captados e, dependendo do padrão encontrado a partir de um processamento, diferentes comandos podem ser enviados ao dispositivo final.

### **2.3 Sinais de Eletromiografia (EMG)**

Uma ativação muscular ocorre a partir do surgimento de um potencial de ação na membrana pós-sináptica de um motoneurônio alfa, o qual desencadeia uma série de reações químicas na junção neuromuscular. Este potencial de ação ocorre quando, em um motoneurônio, o influxo de íons de sódio (Na<sup>+</sup>) atinge um certo limiar, levando à despolarização da membrana pós-sináptica. Em seguida, ocorre uma repolarização. Este ciclo produz um dipolo elétrico que se espalha ao longo da superfície da fibra muscular. A soma dos potenciais de ação de diferentes fibras em uma dada unidade motora formam os chamados potenciais de ação de unidade motora (MUAP – *Motor Unit Action Potential*) e produzem a atividade elétrica muscular (EMG). Para que uma contração muscular ocorra, podendo ou não produzir movimento, vários componentes contráteis devem ser ativados, o que ocorre mediante o recrutamento de um maior número de unidades motoras e um aumento nas frequências de disparo do potencial de ação. Assim, estes potenciais de ação se superpõem, formando os chamados potenciais de ação

compostos musculares (CMAPS - *Compound Muscle Action Potentials*), os quais podem ser captados por eletrodos de forma invasiva (como, por exemplo, por eletrodos agulha) ou de forma não invasiva, por meio de eletrodos de superfície (sEMG) (Konrad 2005). No caso invasivo, apenas os MUAPs de uma ou poucas unidades motoras contribuem para o sinal captado, com menor nível de ruído, de forma que os potenciais de ação são distinguíveis. Isto permite avaliar características das fibras musculares e unidades motoras. Sinais de sEMG, por sua vez, são compostos por potenciais de ação de um conjunto de muitas unidades motoras superpostos. Tal superposição pode gerar diferentes formas de sinais a depender da posição dos eletrodos relativas às unidades motoras e das posições das unidades motoras entre si, além de suas velocidades de condução individuais (Merletti e Parker 2004). Desta forma dificilmente será possível distingui-las. Em contrapartida, o sEMG permite uma análise mais ampla sobre os padrões de recrutamento, sendo útil no estudo de distúrbios de movimentos causados por algumas doenças ou após episódios traumáticos, e até mesmo no controle de próteses e outros dispositivos para reabilitação (Merletti e Parker 2004). Para esta última aplicação, o sEMG mostra-se adequado, pois este se caracteriza pela soma das contribuições de cada músculo dentro de um grupo muscular na região próxima à localização do eletrodo, as quais são função do movimento intencionado.

Como este trabalho tem como foco os sinais de sEMG, o termo EMG se referirá sempre a estes tipos de sinais. O sinal de EMG é um sinal aleatório de média zero, não estacionário (Merletti e Parker 2004). O sinal bruto captado possui amplitudes em geral entre alguns microvolts até 3 mV. O EMG sofre ainda influência das características de condução dos tecidos biológicos existentes entre a fonte do sinal (unidades motoras) e o eletrodo posicionado na superfície da pele, incluindo-se as características da interface eletrodo-pele. Em geral, estas interfaces atuam como um tipo de filtro passa-baixas com frequências de corte e ganho dependentes das dimensões dos tecidos e da interface eletrodo-pele e suas propriedades de condução. O EMG pode ainda variar ou sofrer interferências por parte de diversos processos, detalhados a seguir (Merletti e Parker 2004):

- Instabilidades no contato dos eletrodos com a superfície da pele durante a aquisição de sinais: podem resultar em transições rápidas e aleatórias da linha de base do sinal.



- Variações de posição da inervação muscular relativa ao eletrodo, durante a execução de movimentos: provocam uma modulação em amplitude dos sinais de EMG.
- Artefatos de movimento: em geral possuem baixa frequência e podem ser eliminados por um filtro passa-altas.
- *Crosstalk*: posicionar um eletrodo acima de um dado músculo não garante que o sinal lido provém de unidades motoras apenas deste, já que pode haver contribuições de outros músculos próximos.
- Interferência eletromagnética: é uma das principais fontes de ruído em sinais de EMG, sendo a mais comum a da rede elétrica. Esta possui o espectro centrado em frequências conhecidas (50 ou 60 Hz dependendo da rede elétrica local), de modo que a simples aplicação de um filtro Notch nestas frequências e em seus harmônicos é capaz de atenuá-las.
- Ruído de instrumentação: componentes eletrônicos são utilizados na construção dos sistemas de aquisição, os quais introduzem ruído devido as suas características não ideais. O circuito eletrônico do sistema de aquisição deve ser projetado de forma a minimizar o ruído de instrumentação.
- Interferências de outros sinais eletrofisiológicos: sinais de eletrocardiograma (ECG), por exemplo, podem interferir nos sinais de EMG captados. Requer a aplicação de filtros específicos ou técnicas de redução de ruído (Merletti e Parker 2004).

Alguns tipos de interferência podem provocar uma interpretação incorreta dos sinais adquiridos. Especialmente para o controle de sistemas e/ou dispositivos em tempo real, por exemplo, um pico em amplitude provocado por qualquer um dos fatores acima citados em sinais de EMG pode levar à ocorrência de um falso positivo, ou seja, o sistema detecta um movimento, ou intenção de movimento, quando este na verdade não ocorreu. De forma equivalente, níveis de ruído aleatório muito altos podem dificultar a detecção das contrações musculares, introduzindo muitos falsos negativos.

No estágio de pré-processamento dos sinais adquiridos é aplicado geralmente um filtro passa-bandas entre 20 e 450Hz, banda na qual o EMG está presente (Merletti e Parker 2004). Este filtro é capaz de atenuar alguns dos artefatos acima citados, como o artefato de movimento, mas não todos.

## 2.4 Controle de dispositivos por EMG

O uso de sinais de eletromiografia (EMG) para controle de dispositivos tem sido bastante explorado. As primeiras aplicações descritas na literatura foram desenvolvidas para o controle de próteses para amputados na década de 1960 (Rothchild e Mann 1966). Inicialmente os dispositivos trabalhavam em um simples modo liga-desliga para controlar a abertura e fechamento de próteses de mãos. Mais tarde, no Canadá, surgiu o chamado controlador de três estados (*three-state controller*), o qual permitia controlar três diferentes funções da mão através de um único músculo (Scott e Dorcas 1966). Com a expansão destes estudos e a aplicação prática na clínica, a usabilidade tornou-se um fator fundamental visto que os benefícios propostos por estas próteses só se concretizariam se estes fossem bem aceitos pelos usuários e profissionais de saúde. Para tal, estes dispositivos precisavam ter uma controlabilidade adequada de forma que as pesquisas passaram a voltar-se para a busca de soluções que tornassem o controle dos dispositivos mais intuitivo e cada vez mais próximo do natural. No caso, quanto menos o indivíduo precisar aprender a usar o sistema e quanto mais automático o aprendizado do sistema sobre o seu movimento, mais natural será o controle. Ou seja, no caso ideal, bastaria que o usuário executasse ou tentasse executar um movimento para que o sistema interpretasse esta intenção, acionando a prótese ou dispositivo a ele conectado. Em outras palavras, seria possível um controle mais ‘inconsciente’ (Merletti e Parker 2004; Cipriani et al. 2008). Os métodos que hoje mais se aproximam de promover um controle natural baseiam-se em um controle proporcional – no qual o sinal de controle varia de acordo com determinados parâmetros do EMG - e simultâneo de múltiplos graus de liberdade (Jiang et al. 2012). O sinal de controle proporcional geralmente é estimado a partir do valor médio absoluto do sinal de EMG (Scheme e Englehart 2013).

Ao longo dos últimos anos, diversas outras aplicações controladas por EMG foram propostas, como: robôs de assistência à terapia para reabilitação, teleoperações, realidade virtual, além de algumas aplicações não necessariamente voltadas para a área da saúde como o controle de jogos e para Interação Humano Computador (HCI). A detecção da intenção de movimento tem sido bastante explorada para os casos de controle de prótese e teleoperações (Dipietro et al. 2005). Muitos dos trabalhos foram, inclusive, lançados como produtos comerciais, como o *Otto Bock* e o *I-Limb* (“Sistemas protéticos de mãos mioelétricas — Ottobock” 2016; “i-limb ultra | Touch Bionics” 2016).

Uma vantagem clara, portanto, do uso do EMG para o controle destes dispositivos é a possibilidade de o usuário exercer um controle próximo ao natural (Naik e Kumar

2012). Dipietro e colaboradores (2005) enumeraram alguns benefícios do uso do EMG para controlar um robô de suporte à terapia, dentre os quais, destacam-se:

- Permite saber se o paciente está de fato tentando gerar movimento com o membro em questão durante o treinamento, de forma que o treinamento torna-se mais eficiente;
- Permite que indivíduos com prejuízos severos possam utilizar os robôs, com o único requisito de que os indivíduos sejam capazes de emitir sinais de EMG, ainda que com baixas amplitudes e sem que necessariamente sejam capazes de produzir o movimento;
- Fornece dados úteis para entendimento do processo de recuperação do paciente, além de permitirem avaliar de forma quantitativa e objetiva as habilidades motoras do mesmo.

Como já mencionado na Seção 2.3, diversos fatores podem influenciar na amplitude e frequência dos sinais de EMG adquiridos, de maneira que, além de variações nos sinais durante a coleta individual, há também grandes variações entre indivíduos ou em diferentes coletas. Tais variações ocorrem principalmente por diferenças nas sinergias musculares entre indivíduos, diferenças nas densidades musculares e no posicionamento dos eletrodos entre diferentes coletas (Gibson, Ison, e Artemiadis 2013).

Assim, grande parte dos algoritmos de controle a partir de EMG necessitam previamente de uma seção para que o sistema “aprenda” as características dos sinais do indivíduo, a partir das quais se estimam os parâmetros para a classificação. Estas seções são denominadas, em alguns casos, seções de treinamento e pode ser necessário repeti-las após determinado período de uso. Porém, especialmente por serem voltados para pacientes em um ambiente clínico, os sistemas devem ser projetados de forma que não se exijam longos períodos de treinamento e que tais seções não tenham que ser repetidas em curtos espaços de tempo (Cipriani et al. 2008).

No caso específico da classificação de diferentes movimentos da mão, algumas dificuldades devem ser consideradas, a seguir (Naik e Kumar 2012; Naik et al. 2006) :

- Trata-se de músculos com pequena atividade, de forma que os sinais adquiridos apresentarão baixa razão sinal-ruído (RSR).
- Os músculos responsáveis pelo movimento da mão estão em sua maioria superpostos ou muito próximos uns aos outros, gerando um alto *crosstalk*.

- Qualquer movimento da mão é resultado da combinação da ativação de múltiplos músculos, o que dificulta a classificação de um determinado movimento com base na ativação de um único músculo.

O diagrama da Figura 2.1 ilustra um conjunto de etapas genérico comumente utilizado no controle de sistemas e dispositivos de reabilitação por meio de sinais de EMG.



**Figura 2.1 - Etapas para classificação de movimentos a partir de sinais de EMG.**

Para a classificação em diferentes movimentos, um conjunto de características pode ser extraído dos sinais de EMG. Características no domínio do tempo, da frequência e/ou em tempo-frequência podem ser utilizadas. Dentre as principais características no tempo utilizadas estão: o valor RMS, o valor médio absoluto (MAV) e coeficientes do modelo autorregressivo (AR). Diversos trabalhos mostraram melhores resultados ao utilizar características em tempo-frequência do EMG. Por exemplo, Jahed e colaboradores (2007) empregaram um método para construir o conjunto de características a partir da Transformada de Fourier de Tempo Curto (STFT, do inglês, *Short-Time Fourier Transform*). Para aplicar a transformada, o sinal foi dividido em segmentos suficientemente pequenos de forma que o EMG pudesse ser considerado estacionário dentro de cada segmento. A Transformada Discreta de *Wavelet* também foi citada em outro estudo sendo utilizada para o mesmo fim (M. Khezri e Jahed 2007; Mahdi Khezri e Jahed 2007).

Estudos recentes sobre a classificação de diferentes movimentos da mão procuram ainda de alguma forma decompor os sinais em atividades provenientes de cada músculo ou de diferentes sinergias, partindo do princípio que a atividade em um músculo é resultante de diferentes sinergias com diferentes níveis de contribuição. Naik e colaboradores (2012) utilizaram uma técnica de separação cega (BSS, do inglês, *Blind Source Separation*), mais especificamente a Análise de Componentes Independentes para decompor os sinais em atividade proveniente de cada músculo separadamente. A partir das características resultantes da decomposição, os autores classificaram seis diferentes movimentos da mão a partir do monitoramento de quatro músculos do antebraço. Outros

métodos como o casamento de espectros *wavelet*, a Análise de Componentes Principais (PCA) e a Fatoração Não Negativa de Matrizes (NMF, do inglês, *non-negative matrix factorization*) também são citadas na literatura como técnicas para a decomposição dos sinais de EMG (Atoufi et al. 2014)

A ativação muscular (*onset*) em cada canal de leitura é em geral detectada como um primeiro passo para a classificação do movimento. Tal ativação pode ser determinada por estimativas em amplitude. Dentre os métodos mais utilizados para tais estimativas, estão o cálculo da média móvel (MAV) e do valor médio quadrático (RMS) em janelas de tempo do sinal de EMG (Konrad 2005). Estes métodos são calculados pelas Equações (1) e (2) a seguir, para cada amostra  $n$  do sinal, onde  $N$  é o tamanho de janela considerado:

$$RMS(n) = \sqrt{\frac{\sum_{i=1}^N x_i(n)^2}{N}} \quad (1)$$

$$MAV(n) = \frac{\sum_{i=1}^N x_i(n+i)}{N} \quad (2)$$

Geralmente, determina-se então um limiar com base no sinal de repouso e considera-se que quando o valor RMS do sinal ultrapassa tal limiar, houve uma ativação do músculo em questão. Do contrário, o músculo está desativado. Apesar de ser uma técnica de fácil implementação e baixo custo computacional, este método, denominado ‘*single threshold*’ (limiar simples), é bastante suscetível a erros, especialmente quando há altas razões sinal ruído. Assim, outros métodos foram propostos na literatura resultando em detecções mais acuradas. Dentre estes métodos inclui-se a aplicação de modelos *wavelet*, utilização de outros critérios estatísticos, como o *double threshold* (limiar duplo) e a aplicação do filtro *Teager Kaiser* (TKEO), cuja saída é proporcional ao produto da amplitude e frequência instantâneas do sinal (Li, Zhou, e Aruin 2007; Raez, Hussain, e Mohd-Yasin 2006; Santos 2011).

Porém, para aplicação no controle em tempo real de um dispositivo externo, a detecção somente de ativação e da desativação muscular pode ser insuficiente. Para a classificação de sinais de EMG, diversas técnicas são usadas nos diferentes estudos, dentre os quais destacam-se algoritmos baseados em Redes Neurais Artificiais, lógica Fuzzy, classificadores lineares como os Discriminantes Lineares de Fisher (LDA) e Máquinas de Vetores de Suporte (SVM) (Chowdhury et al. 2013).

Em pacientes com hemiparesia após AVE, o controle por EMG mostra-se uma excelente alternativa, visto que estes em geral não conseguem realizar os movimentos de forma completa, embora apresentem atividade mioelétrica. Dipietro e colaboradores (2005) desenvolveram um sistema acionado por EMG para um robô de assistência à terapia de pacientes com hemiparesia, para realização de movimentos de alcance. Foram monitorados 4 canais de entrada e uma vez que o envelope do sinal de EMG de pelo menos um dos canais ultrapassasse um dado limiar, o robô era acionado. Neste estudo, havia apenas duas classes envolvidas: movimento e repouso (Dipietro et al. 2005).

Ao desenvolver sistemas controlados por EMG para pacientes após AVE, deve-se ter atenção ao fato de que há diversas alterações no que diz respeito ao recrutamento motor e características neuromusculares decorrentes da lesão, as quais influenciam diretamente em suas atividades mioelétricas (Zhang et al. 2013). Devido ao recrutamento inadequado, já mencionado na seção 2.1, alguns estudos mostram a presença de maiores níveis de co-contracção nos sinais de EMG. Isso significa que músculos agonistas e antagonistas a um determinado movimento serão ativados quase que simultaneamente ao tentar executar um movimento (Ohn et al. 2013). Chae e colaboradores (2002) estudaram a correlação entre os parâmetros do sinal de EMG que quantificam o nível de co-contracção e a força de contracção muscular e duas escalas de avaliação funcional capazes de avaliar o nível de recuperação funcional do paciente e o nível de habilidade física do mesmo, por meio, respectivamente, do método Fugl-Meyer (FMA, do inglês, *Fugl Meyer Motor Assessment*) e do teste de Habilidade Motora da mão (AMAT, do inglês, *arm motor ability test*). Os sinais de EMG durante a execução de determinados movimentos de membro superior em pacientes e em normais mostraram uma correlação negativa entre os níveis de co-contracção e os níveis de avaliação dos pacientes e uma correlação positiva entre os mesmos níveis de avaliação e a força de contracção. Em um estudo similar, Ohn e colaboradores (2013) mostraram experimentalmente que o nível de co-contracção possui correlação positiva com a espasticidade, medida pela escala modificada de Ashworth (MAS, do inglês, *Modified Ashworth Scale*) e negativa com a funcionalidade da mão, medida com a escala FMA. Em ambos os estudos o nível de co-contracção foi obtido pela razão entre os valores RMS dos músculos agonista e antagonista no intervalo entre a ativação e a desativação muscular.

Aponta-se também na literatura que nos membros paréticos a frequência mediana é em geral menor e decresce de maneira mais suave que em membros normais. (Toffola et al. 2001). Além disso, devido à espasticidade, alguns músculos podem apresentar uma

atividade involuntária inerente, que pode ser confundida com a atividade voluntária, especialmente porque a primeira tende a se manifestar justamente durante a execução do movimento voluntário. Portanto, esta atividade deve ser modelada como ruído para a classificação de intenção de movimento. Zhang e colaboradores (2013) realizaram um estudo no qual pacientes após AVE realizam diversos movimentos com o membro parético que são classificados por meio de um sistema de controle com base na entropia do EMG. Diferentes seções foram realizadas, com maior ou menor velocidade do movimento de forma a se gerar maior ou menor atividade involuntária. O estudo concluiu que quando a atividade involuntária dos músculos espásticos é maior, a acurácia da classificação foi bastante reduzida em relação as seções em que a atividade involuntária teria sido menor (Zhang et al. 2013).

## 2.5 Teoria da detecção

Um problema básico de detecção ocorre quando se pretende decidir sobre a presença ou não de um sinal de interesse em meio a ruído branco. Como exemplo, pretende-se identificar para cada janela de sinais de EMG de um dado músculo, se houve uma contração muscular ou se foi mantido repouso. Estimando-se os valores RMS do EMG durante a contração e durante um período de repouso, sabe-se que para cada caso a função densidade de probabilidade (PDF) correspondente será diferente. Em um caso simples, pode-se aproximar as distribuições a duas gaussianas, sendo que a média da distribuição correspondente ao período de contração muscular será maior que a média da distribuição correspondente ao período de repouso, como ilustra a Figura 2.2.

Assim, os valores RMS de sinais coletados em períodos de repouso podem ser modelados por um ruído gaussiano de média zero e variância  $\sigma^2$  ( $H_0$ ). Por outro lado, durante uma contração muscular, pode-se modelar tais valores pelo mesmo ruído gaussiano, porém somado a uma constante  $A$  ( $H_1$ ). Estas duas hipóteses são representadas abaixo:

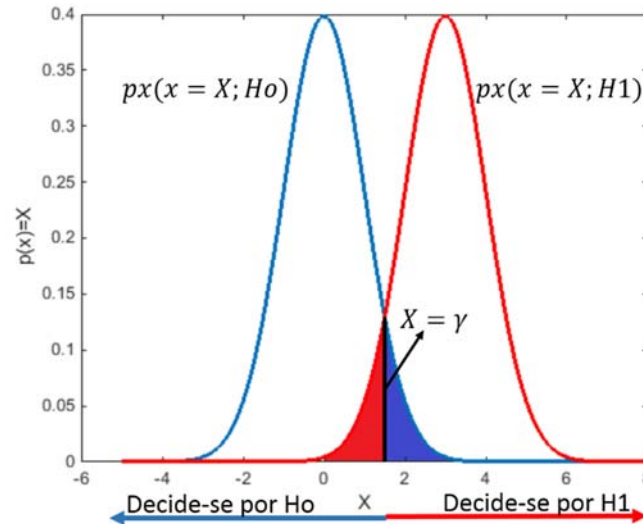
$H_0: X \sim \eta(0, \sigma^2)$ , corresponde ao repouso

$H_1: X \sim A + \eta(0, \sigma^2)$ , corresponde ao movimento

onde  $\sim$  significa “é distribuído segundo” e  $\eta(\mu, \sigma^2)$  é a distribuição normal com média  $\mu$  e variância  $\sigma^2$ .

Para se decidir a qual distribuição pertence um dado segmento do sinal, um teste de hipóteses deve então ser realizado. Para tal, determina-se um limiar  $\gamma$ , o qual separa

as duas regiões de decisão. Para valores de  $x$  menores que o limiar, decide-se por  $H_0$  e para valores maiores que o limiar, decide-se por  $H_1$  (Figura 2.2).



**Figura 2.2 – PDFs correspondentes a  $H_0$  e  $H_1$ .**

Em uma abordagem clássica, utilizando-se o teorema de Neyman-Pearson, fixa-se um valor, geralmente, para a probabilidade de falsos positivos (PFP), com base na PDF de  $H_0$ . Isto é, escolhe-se um nível de significância a partir do qual se determina o limiar. Para o caso ilustrado na Figura 2.2, a Probabilidade de Falsos Positivos é representada pela área preenchida em azul. Assim, procura-se maximizar a probabilidade de detecção (PD), representada como a área sob a curva da PDF de  $H_1$  na região de decisão de  $H_1$ . Isto é feito através do teste de razão de verossimilhança, pela qual decide-se por  $H_1$  se (Kay 1998):

$$\frac{p(x; H_1)}{p(x; H_0)} > \gamma \quad (3)$$

Uma outra forma de se estabelecer o limiar é minimizando-se a Probabilidade de Erro ( $P_e$ ), dada pela equação (4) a seguir (Kay 1998):

$$P_e = P(H_0|H_1)P(H_1) + P(H_1|H_0)P(H_0) \quad (4)$$

onde  $P(H_i|H_j)$  denota a probabilidade de se decidir por  $H_i$  quando  $H_j$  é verdadeiro.

As probabilidades  $P(H_0)$  e  $P(H_1)$  são probabilidades *a priori*, ou seja, probabilidades previamente conhecidas de cada hipótese testada. Este tipo de teste de



hipóteses é chamado de paradigma Bayesiano. Neste caso, para se obter uma Probabilidade de Erro mínima, deve-se decidir por H1 se (Kay 1998):

$$\frac{P(x|H1)}{P(x|H0)} > \frac{P(H0)}{P(H1)} \quad (5)$$

Isto é, o limiar neste caso será dado pela razão entre as probabilidades *a priori* das hipóteses consideradas. Quando as probabilidades *a priori* são consideradas iguais, temos a equação (6), a qual representa o chamado detector de máxima verossimilhança (ML):

$$P(x|H1) > P(x|H0) \quad (6)$$

## 2.6 Classificadores

### 2.6.1 O Teste F espectral (TFE)

Dadas duas variáveis aleatórias  $Z_1$  e  $Z_2$ , com distribuições Qui-quadradas com  $\nu_1$  e  $\nu_2$  graus de liberdade, respectivamente, tem-se que a razão entre estas variáveis divididas pelos seus respectivos graus de liberdade resulta em uma distribuição F, como explicitado a seguir (Kay 1998):

$$\left(\frac{Z_1}{\nu_1}\right) \left(\frac{Z_2}{\nu_2}\right)^{-1} \sim F_{\nu_1, \nu_2} \quad (7)$$

O TFE é um teste estatístico utilizado para detectar diferenças entre duas estimativas espectrais dentro da mesma frequência ou mesma banda de frequências com base na distribuição F. Tomam-se dois segmentos distintos de sinais,  $y[n]$  e  $x[n]$ , cada qual dividido em M janelas. As transformadas de Fourier de cada janela de índice  $i$  (sendo  $1 < i < M$ ) são estimadas e denotadas, respectivamente, por  $Y_i(f_k)$  e  $X_i(f_k)$ . O TFE é realizado com base na razão das energias dos espectros estimados, conforme a equação (8) (Sá et al. 2006; Simpson et al. 2000; Tierra-Criollo 2001) :

$$\phi_{yx}(f_k) = \frac{\sum_{i=1}^M |Y_i(f_k)|^2}{\sum_{i=1}^M |X_i(f_k)|^2} \quad (8)$$

Se  $y[n]$  e  $x[n]$  são assumidos Gaussianos, de média zero e variâncias, respectivamente,  $\sigma_y^2$  e  $\sigma_x^2$ , tanto o numerador quanto o denominador da Equação (8) são distribuições proporcionais a Qui-Quadradas com  $2M$  graus de liberdade. Portanto, a razão será uma distribuição F da seguinte forma (Sá et al. 2009):

$$\frac{\sigma_x^2}{\sigma_y^2} \Phi_{yx}(f) \sim F_{2M, 2M} \quad (9)$$

Assim, denotando-se  $\sigma_y^2 / \sigma_x^2 = a$ , tem-se:

$$\Phi_{yx}(f) \sim a F_{2M, 2M} \quad (10)$$

Isto é,  $\Phi_{yx}(f)$  será uma distribuição F com fator de escalonamento  $a$  e  $2M$  graus de liberdade no numerador e no denominador. Quando as variâncias dos dois sinais são iguais,  $a$  vale 1 e portanto  $\Phi_{yx}$  resulta em uma distribuição F central, com valor esperado e variância dados pelas equações (11) e (12) a seguir (L. Johnson, Kotz, e Balakrishnan 1995):

$$E[F_{v_1, v_2}] = \frac{v_2}{v_2 - 2}, \quad v_2 > 2 \quad (11)$$

$$var[F_{v_1, v_2}] = \frac{2v_2^2(v_1 + v_2 - 2)}{v_1(v_2 - 2)^2(v_2 - 4)}, \quad v_2 > 4 \quad (12)$$

Um teste estatístico bicaudal, utilizando-se a abordagem Neyman Pearson, pode então ser realizado, tendo como hipótese nula ( $H_0$ ) a não existência de diferença entre os espectros, sendo neste caso  $\Phi_{yx}(f) \sim F_{2M, 2M}$ . Estabelecendo-se um nível de significância  $\alpha$ , calculam-se os limiares inferior ( $lim_i$ ) e superior ( $lim_s$ ) da distribuição  $F_{2M, 2M}$ . Assim, quando:

- $lim_i \leq \Phi_{yx} \leq lim_s$ , conclui-se que não houve diferença significativa entre os espectros e  $H_0$  é aceita;
- $\Phi_{yx} > lim_s$ , conclui-se que houve diferença significativa entre os espectros e a energia do espectro do segmento do numerador é superior. Neste caso, rejeita-se  $H_0$  à direita;

- $\Phi_{yx} < \lim_i$ , conclui-se que houve diferença significativa entre os espectros e a energia do espectro do segmento do numerador é inferior. Neste caso, rejeita-se  $H_0$  à esquerda.

Sá e colaboradores (2006) realizaram um estudo para análise quantitativa do fotorrecrutamento utilizando o teste F em sinais de EEG. Neste estudo, o mesmo método de cálculo do teste F acima citado foi utilizado, sendo  $x[k]$  o segmento do sinal imediatamente anterior à estimulação e  $y[k]$  o segmento do sinal durante a estimulação. Utilizando-se o teste F foi possível determinar quando houve ou não resposta cortical ao estímulo aplicado.

Como explicitou-se na Equação (9), se as variâncias dos trechos em questão forem diferentes, a distribuição F sofre um escalonamento com um fator igual a  $a$ . Se  $a$  for maior que 1, a curva sofrerá um escalonamento que aparentará um deslocamento à direita. Por outro lado, se  $a$  for menor que 1, o deslocamento aparente será para a esquerda, como mostra o gráfico das distribuições da Figura 2.3.

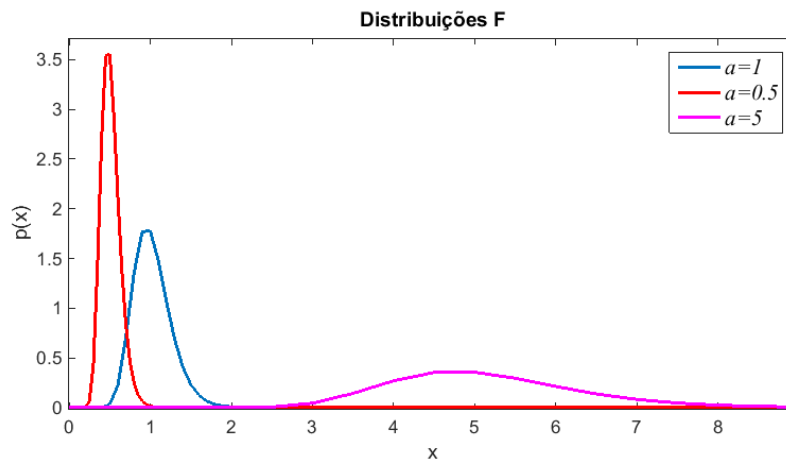


Figura 2.3- Exemplos de distribuições F variando-se os respectivos fatores de escalonamento  $a$ .

Neste caso, a PDF da distribuição F pode ser estimada pela equação (13) (L. Johnson, Kotz, e Balakrishnan 1995):

$$p(\Phi_{y_1, y_2} | H_i) = \frac{\frac{1}{a_i} \left( \frac{\Phi_{y_1, y_2}}{a_i} \right)^{v/2 - 1}}{B\left(\frac{v}{2}, \frac{v}{2}\right) \left( 1 + \frac{\Phi_{y_1, y_2}}{a_i} \right)^v} \quad (13)$$

em que  $a_i$  corresponde o fator de escalonamento  $a$  da distribuição correspondente à hipótese  $H_i$  e  $v = v_1 = v_2$ .

O valor esperado da distribuição F escalonada relaciona-se com o valor esperado da distribuição F não escalonada ( $a=1$ ), como dado pela equação (14):

$$E[aF_{v_1, v_2}] = aE[F_{v_1, v_2}] \quad (14)$$

### 2.6.2 Análise de Discriminantes Lineares (LDA)

O LDA, também conhecido como LDA de Fisher é um classificador linear comumente utilizado para a classificação em tempo real de sinais biológicos, como o eletroencefalograma (EEG) e o EMG.

A partir de um conjunto de amostras de dimensão  $n$ ,  $x_1, x_2, \dots, x_n$ , dividido em dois subconjuntos,  $X_1$  e  $X_2$ , uma combinação linear destas amostras seria dada pelo produto escalar a seguir:

$$y = w^t x \quad (15)$$

Assim, um conjunto correspondente de amostras  $y_1, y_2, \dots, y_n$ , dividido em dois subconjuntos  $Y_1$  e  $Y_2$  seria formado. O vetor  $w$  deve ser então escolhido de forma que se obtenha a melhor separação entre estes subconjuntos (Duda, Hart, e Stork 2012). A técnica Discriminantes Lineares de Fisher determina que a melhor separação pode ser obtida maximizando-se as distâncias entre as médias das classes e minimizando-se a variância cruzada entre as mesmas (Lotte et al. 2007). Para tal, escolhe-se  $w$  de forma que  $J(w)$  representado pela equação (16) seja maximizado:

$$J(w) = \frac{(\tilde{m}_1 - \tilde{m}_2)^2}{\tilde{s}_1^2 + \tilde{s}_2^2} \quad (16)$$

onde  $\tilde{m}_1$  e  $\tilde{m}_2$  são as médias das amostras dos subconjuntos  $Y_1$  e  $Y_2$ , respectivamente, e  $\tilde{s}_1^2$  e  $\tilde{s}_2^2$  são os correspondentes espalhamentos (*scatters*, em inglês), explicitados nas equações (17) e (18) a seguir, sendo  $n_i$  o comprimento do subconjunto de índice  $i$ :

$$\tilde{m}_i = \frac{1}{n_i} \sum_{y \in Y_i} y \quad (17)$$

$$\tilde{s}_i = \sum_{y \in y_i} (y - m_i)^2 \quad (18)$$

A Figura 2.4 ilustra a classificação utilizando a técnica LDA. Amostras de duas classes ( $\omega_1$ , em verde e  $\omega_2$ , em vermelho) são classificadas de acordo com a região a qual pertencem, separadas pela reta rosa.




Figura 2.4 - Dados pertencentes a duas classes ( $\omega_1$  e  $\omega_2$ ) e reta ótima de separação a partir do algoritmo LDA

### 2.6.3 Máquina de Vetores de Suporte (SVM)

Assim como o LDA, o SVM também utiliza hiperplanos para separar as regiões de classificação, diferindo no critério para a escolha do hiperplano. No caso, procura-se o hiperplano com máxima margem, ou seja, maior distância entre as amostras mais próximas (Lotte et al. 2007).

Tomando por base um classificador linear descrito pela equação (19), para amostras  $x_n$ , sendo  $1 < n < N$  e considerando-se que cada amostra recebe um rótulo  $c_n \in \{-1, 1\}$ , que indica a classe à qual pertence, tem-se (Heijden et al. 2004):

$$y = w^t x + b \quad (19)$$

para  $y > 1$ ,  $c_n = 1$  e para  $y \leq -1$ ,  $c_n = -1$ . Assim, pode-se escrever a seguinte inequação:

$$c_n(w^t x + b) \geq 1 \quad (20)$$

Uma vez que  $w$  é o vetor gradiente de  $y$ , o quadrado da margem é inversamente proporcional a  $\|w\|^2 = w^T w$ , o qual deve portanto ser minimizado para a maximização da margem. Para realizar tal minimização pode-se utilizar os multiplicadores de

Lagrange. Assim, na equação (21),  $L$  deve ser maximizado com respeito a  $w$  e  $b$  e minimizado em relação aos multiplicadores de Lagrange,  $\alpha_n$ . Diversos pacotes de software disponíveis podem ser utilizados para tal.

$$L = \frac{1}{2} \|w^2\| + \sum_{n=1}^{N_s} \alpha_n ((c_n(w^t x + b) - 1), \alpha_n \geq 0 \quad (21)$$

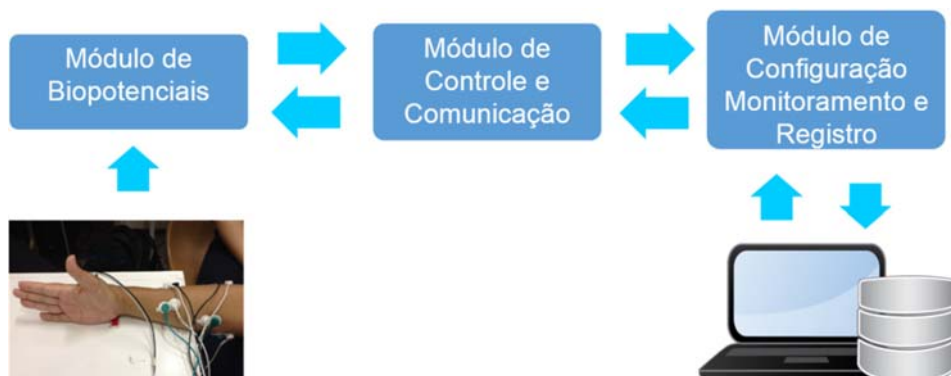
Uma outra particularidade do SVM é a possibilidade de utilização de limites não-lineares através das chamadas funções kernel. Assim, pode-se mapear os dados a um outro espaço de maior dimensão. Um kernel comumente utilizado é o Gaussiano (Duda, Hart, e Stork 2012).

### 3 Materiais e métodos

#### 3.1 Sistema de aquisição de sinais

Adaptou-se, para a aquisição de sinais de EMG, o sistema desenvolvido para adquirir sinais de eletroencefalografia (EEG) e potencial evocado (D’AFFONSÊCA NETTO et al., 2014; CEVALLOS-LARREA et al., 2014). Este sistema é composto por 3 módulos interligados a seguir (Figura 3.1):

- Módulo de Biopotenciais (MB): responsável por captar, condicionar e digitalizar os sinais de entrada, utilizando-se o kit ADS1299EEG-FE da *National Instruments*.
- Módulo de Configuração, Monitoramento e Registro (MCMR): consiste de um software desenvolvido na plataforma *Labview* da *National Instruments* que permite ao usuário monitorar em tempo real os sinais adquiridos, verificar as impedâncias dos canais de entrada, configurar parâmetros de aquisição, além de calibrar as entradas do sistema e registrar os sinais brutos adquiridos em disco. Uma filtragem em tempo real também pode ser realizada para fins de monitoramento.
- Módulo de Controle e Comunicação (MCC): realiza o controle da comunicação entre o MB e o MCMR, utilizando-se o kit STM32F4discovery da *STMicroelectronics*. Assim, os sinais digitalizados no MB são enviados para leitura no MCMR e os sinais de controle configurados pelo usuário, relativos à aquisição, como ganho e frequência de amostragem, são encaminhados, do MCMR ao MB.



**Figura 3.1 - Os diferentes módulos do Sistema de Aquisição. Os dados (sinais) são processados nos diferentes módulos até tornarem-se disponíveis ao usuário, o qual, por sua vez, pode também configurar o seu funcionamento.**

A Figura 3.2 mostra a tela principal do software do MCMR. À esquerda, na seção Configurações de Hardware, é possível acessar as telas para monitoramento de impedância, configuração de parâmetros de aquisição (Registros) e calibração, além de configurações de conexão com o Módulo de controle e comunicação. Logo abaixo, na seção Monitoramento é possível configurar filtros passa-altas, passa-baixas e *Notch*, controlar o início (Start) e parada da aquisição (Stop) e ainda controlar a gravação dos sinais adquiridos (Salvar). À direita, na mesma figura, é possível visualizar os sinais de canais selecionados em tempo real. Na janela em destaque no canto esquerdo inferior da imagem, tem-se uma interface com uma barra deslizante para acompanhamento do movimento por parte do sujeito do experimento. A utilização desta interface será detalhada na próxima seção.

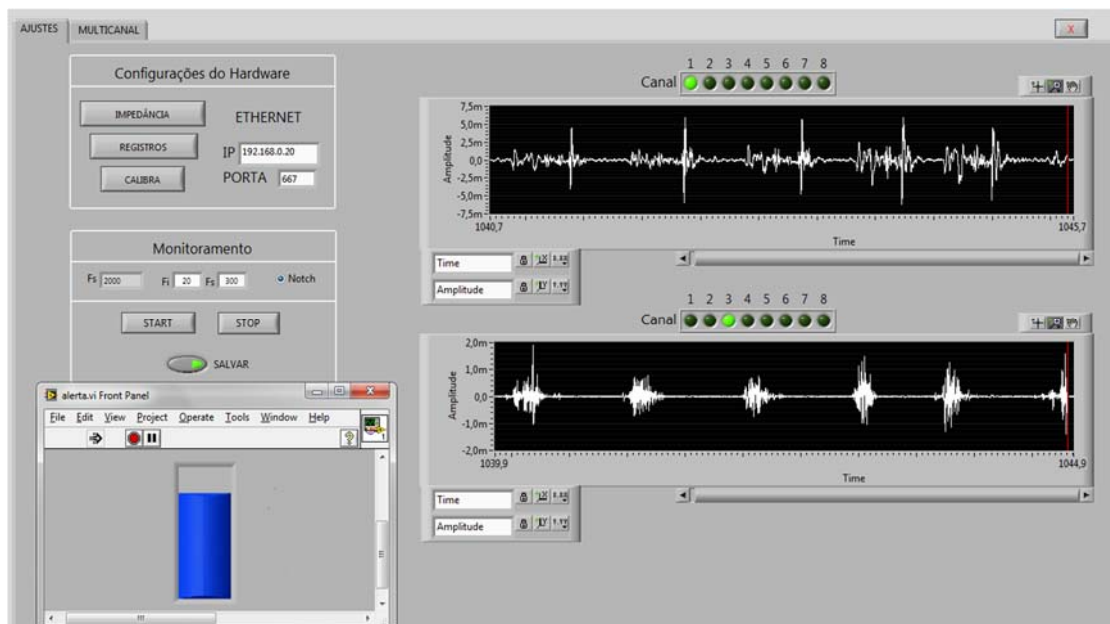



Figura 3.2 - Interface do usuário desenvolvida em Labview durante aquisição de sinais de EMG e acelerometria.

### 3.2 Protocolo experimental

Foram realizadas coletas de sinais de EMG de dois grupos de indivíduos: Grupo A, composto por 27 indivíduos normais e Grupo B, composto por 9 sujeitos com hemiparesia após AVE. No grupo A foram incluídos indivíduos adultos, saudáveis, sem nenhum comprometimento motor ou lesão de membro superior. Para o grupo B foram incluídos pacientes adultos e idosos que sofreram episódios de AVE há no mínimo 1 ano, tendo sido diagnosticados com hemiparesia de membro superior. Todos os indivíduos participantes do Grupo B estavam em tratamento fisioterápico no Hospital Universitário



Clementino Fraga Filho da UFRJ (HUCFF/UFRJ). A pesquisa foi devidamente aprovada pelo Comitê de Ética e Pesquisa (CAAE: 44647715.1.0000.5257), tendo esta um caráter voluntário. O protocolo experimental pode ser encontrado no Apêndice A. Os indivíduos do Grupo A possuem média de idade de  $(34 \pm 13)$  anos e os indivíduos do Grupo B,  $(51 \pm 16)$  anos. Os experimentos do Grupo A foram realizados no Laboratório de Processamento de Imagens e Sinais (LAPIS/PEB/UFRJ) e os do Grupo B no Serviço de Fisioterapia do HUCFF/UFRJ, ambos com ambiente controlado com temperatura de  $(23 \pm 2)^\circ$  Celsius. Cada indivíduo foi acomodado em uma poltrona com apoio lateral para o antebraço em posição neutra com  $90^\circ$  na articulação do cotovelo (Figura 3.3).



**Figura 3.3 – Voluntário sentado com o antebraço em posição neutra realizando o movimento de flexão dos dedos da mão com eletrodos conectados para aquisição dos sinais de EMG.**

Sinais de EMG superficial foram registrados em 6 derivações bipolares, colocando-se eletrodos duplos descartáveis (com 1 cm de diâmetro e distância entre os centros de 2cm) sobre os seguintes músculos: Extensor Comum dos Dedos (ECD), Primeiro Interosseo Dorsal (PID), Extensor Curto do Polegar (ECP), Flexor Superficial dos Dedos (FSD), Flexor Profundo dos Dedos (FPD) e Flexor Longo do Polegar (FLP). O eletrodo terra foi posicionado no epicôndilo lateral ipsilateral. A localização da posição dos eletrodos nos diferentes músculos se determinou por medidas anatômicas, conforme protocolo do Apêndice A, de acordo com (Johnson 1980), além de solicitar ao voluntário que realizasse movimentos específicos para cada músculo, de forma que as posições pudessem ser identificadas através do tato, quando possível. No caso dos voluntários do Grupo A, os sinais foram coletados no membro dominante, segundo informado pelo próprio voluntário. Em voluntários do Grupo B, foram coletados sinais do membro parético, independentemente da dominância. Na mesma semana do experimento cada

paciente foi avaliado com base na escala de Fugl-Meyer (FMA) e os resultados foram registrados. Além dos eletrodos, foi também colocado um acelerômetro (ADXL335 da AnalogDevices) no dedo indicador do indivíduo para posterior identificação do início de cada movimento.

Os indivíduos realizaram 3 seções. Cada seção consistiu em manter o braço relaxado (repouso) por 5 segundos e logo após executar 10 repetições de extensão dos dedos da mão e 10 repetições de flexão. Cada repetição iniciava-se em posição relaxada (Figura 3.4 - intermediária), seguida da extensão (Figura 3.4 – superior) ou flexão (Figura 3.4 – inferior), para finalmente retornar à posição relaxada. Para a velocidade de execução do movimento, o indivíduo teve que acompanhar uma barra deslizante apresentada em um monitor (conforme janela na parte inferior esquerda da Figura 3.2). Assim, orientou-se o voluntário para que realizasse o movimento gradual de abrir ou de fechar a mão (de acordo com a seção correspondente) enquanto a barra deslizante estivesse subindo, e relaxasse, de forma também gradual, quando a barra estivesse em movimento descendente.



**Figura 3.4 – Voluntário com os dedos estendidos (figura superior), relaxados (figura intermediária) e flexionados (figura inferior).**

Na primeira seção o indivíduo aprendeu a tarefa, de forma que os sinais de EMG registrados não foram processados. Os sinais registrados na segunda seção foram processados para se extrair características do EMG durante flexão, extensão, relaxamento e repouso e estimar os parâmetros dos classificadores. Os sinais registrados durante a

terceira seção foram utilizados para simular uma classificação em tempo real e a partir desta avaliar o desempenho do classificador.

Nesta dissertação, os termos extensão, flexão, abertura e fechamento se referirão sempre aos respectivos movimentos dos dedos da mão, bem como o relaxamento e o repouso serão relativos também a este segmento.

### **3.3 Processamento de sinais**

Os sinais de EMG, adquiridos a uma taxa de amostragem de 2 kHz, das seções II e III da coleta de sinais passaram por duas etapas em comum: pré-processamento e extração de características (Figura 3.5).

Na etapa de pré-processamento, os sinais foram filtrados (direta e reversamente - fase zero) offline com filtro Butterworth passa altas de segunda ordem na frequência de 20 Hz, e passa-baixas em 450 Hz. Também foram utilizados filtros Notch para atenuar o ruído da rede elétrica, em 60 Hz e seus harmônicos ímpares até 300 Hz.

Na etapa seguinte foram extraídas características dos sinais de EMG. Para os sinais da seção II, esta etapa dividiu-se em duas partes (Figura 3.5): (i) primeiro, identificou-se os pontos de iniciação do movimento a partir do sinal do acelerômetro (seção 3.3.1); (ii) então, encontrou-se, dentro de um determinado intervalo de tempo a partir destes pontos, as características, com base na densidade espectral de potência (PSD) do sinal de EMG. A partir destas características foram estimados os parâmetros do classificador. Os parâmetros estimados dependem do tipo de classificador utilizado e serão detalhados nas seções correspondentes (seções 3.3.4.1 e 3.3.4.2). Tais parâmetros de classificação foram armazenados em memória para serem utilizados na simulação da classificação em tempo real da seção III.

Na seção III, todo o processamento de sinais foi realizado para janelas de 100ms, simulando a aplicação em “tempo real”. Assim, extraiu-se a característica e classificou-se cada janela como pertencente a uma das classes: repouso, flexão, extensão e relaxamento. Para tal, o procedimento de classificação dividiu-se em três partes (Figura 3.5): (i) classificação inicial entre extensão e flexão (TFE Bayesiano, seção 3.3.4.1, LDA ou SVM, seção 3.3.4.2); em paralelo, (ii) identificação de ativação/desativação muscular nos diferentes músculos com base no TFE (seção 3.3.3); e finalmente, (iii) por meio de uma árvore de decisão (seção 3.3.5), obtenção da classificação final.

Em um sistema de tecnologia assistiva cada classe é associada a um comando que pode ser enviado a um dispositivo externo ou software, executando a ação intencionada

pelo usuário. Esta etapa, porém, foge ao escopo deste projeto tendo sido adicionada ao diagrama da Figura 3.5 apenas para facilitar o entendimento.

O desempenho do classificador foi avaliado estimando-se a sensibilidade, especificidade e acurácia, tomando-se como referência de iniciação e finalização dos movimentos os pontos identificados a partir do sinal do acelerômetro.

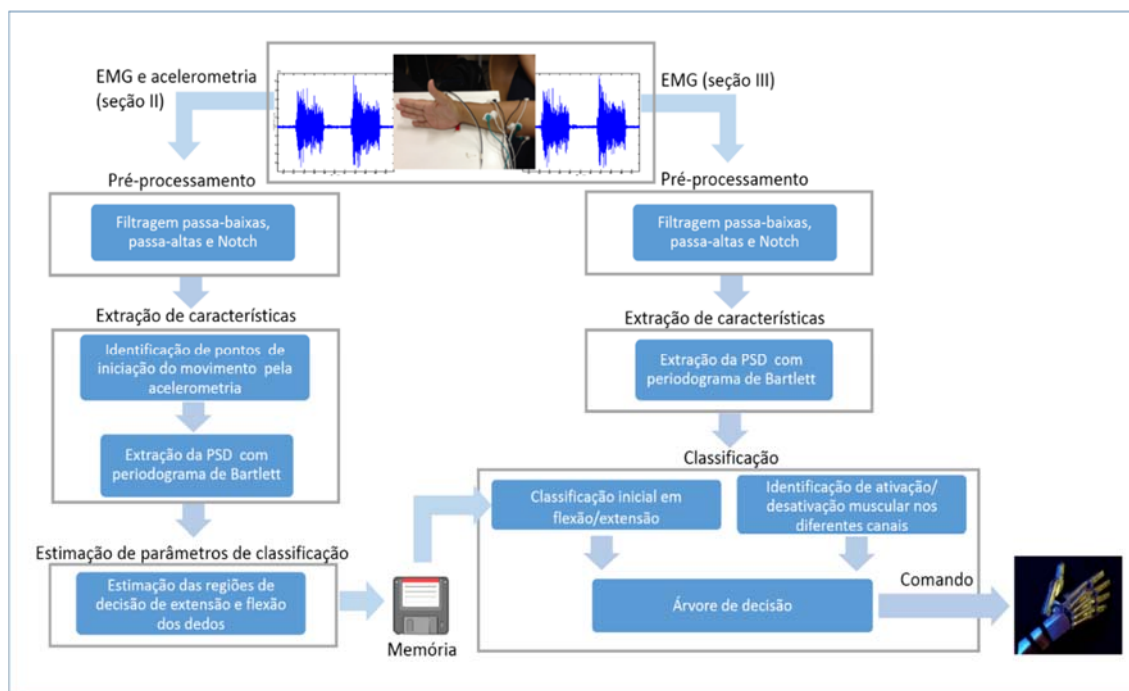


Figura 3.5 - Diagrama do processo de classificação do sinal de EMG

### 3.3.1 Identificação dos instantes de movimento pelo sinal de acelerometria

Uma informação muito importante tanto para a extração de características quanto para posterior avaliação do desempenho do classificador, refere-se aos instantes de tempo em que se iniciaram os movimentos executados. Esta estimativa foi realizada a partir dos sinais do acelerômetro colocado no dedo indicador dos indivíduos. O sinal adquirido corresponde ao eixo longitudinal ao dedo.

O método utilizado baseou-se em uma técnica desenvolvida no trabalho de Branco (2015), acrescentando-se a estimativa do instante de finalização do movimento, que pode ser também interpretado como início de movimento de relaxamento. O sinal do acelerômetro (amostrado a 2kHz) foi inicialmente filtrado com filtro passa-bandas de 1 a 10 Hz. Tomando-se a derivada do sinal filtrado, considera-se como início do movimento o ponto mínimo anterior à primeira inclinação positiva do sinal da derivada (Branco 2015). De forma similar, a finalização do movimento é considerada como o ponto de máximo posterior a uma inclinação negativa do sinal da derivada. A Figura 3.6 mostra

um sinal de acelerometria durante movimentos de extensão e relaxamento e os pontos de iniciação (vermelho) e finalização (verde) do movimento encontrados. Uma validação visual destes pontos foi realizada para assegurar que pequenos tremores, irregularidades no movimento ou até mesmo ruídos presentes no sinal coletado não fossem marcados incorretamente.




Figura 3.6 - Sinal de acelerometria (rosa) e sinal de EMG (azul) com pontos de iniciação (vermelho) e finalização de movimento (verde) de extensão dos dedos da mão.

### 3.3.2 Extração de características

A PSD foi estimada pelo periodograma de Bartlett com segmentos de M janelas de 100ms sem haver sobreposição entre os segmentos. Assim a PSD de um dado segmento de sinal,  $y[n]$ , dividido em M janelas é estimado por meio da Equação (22).

$$PSD_{y[n]}(\Delta f) = \frac{1}{M \cdot nbins} \sum_{k=1}^{nbins} \sum_{i=1}^M |Y_i(f_k)|^2 \quad (22)$$

onde  $Y_i(f_k)$  é a transformada de Fourier discreta da  $i$ -ésima janela de  $y[n]$  e  $nbins$  é o número de componentes em frequência considerado. A transformada de Fourier foi estimada utilizando-se a técnica FDFT (do inglês, *Fast Discrete Fourier Transform*).

Todos os algoritmos de classificação utilizados neste trabalho basearam-se nesta característica.

### 3.3.2.1 Determinação da faixa de frequência das características extraídas para a classificação

A faixa de frequência considerada foi determinada a partir dos sinais de todos os voluntários do Grupo A registrados na seção II do experimento. Estimaram-se os espectros com base em sinais de EMG de dois músculos de referência: o Extensor comum dos dedos (ECD) e o Flexor superficial dos dedos (FSD), durante cada movimento. A seguir, foi realizado um teste estatístico de Wilcoxon (nível de significância de 5%), comparando-se o espectro do sinal durante períodos com a mão em posição relaxada para cada faixa de frequências com os espectros em cada caso a seguir: (i) músculo extensor durante movimentos de extensão; (ii) músculo flexor durante movimentos de flexão; (iii) músculo extensor durante movimentos de flexão; (iv) músculo flexor durante movimentos de extensão. Com isso, procurou-se a faixa de frequências que atendesse ao seguinte critério: possuir a maior parte de suas subfaixas com diferença significativa, segundo o teste de Wilcoxon, quando se tratasse do músculo agonista ao movimento em questão (casos i e iv) e sem diferença significativa quando se tratasse do músculo não agonista (casos ii e iii).

Seguindo esta metodologia, foi selecionada a faixa de frequência de 80 a 100Hz para todos os pares de músculos considerados.

### 3.3.3 Identificação de ativação e desativação muscular por canal com TFE

Na etapa de identificação de ativação/desativação muscular se aplicou o TFE em segmentos subsequentes, ao longo do tempo, no sinal de EMG de cada canal pré-processado, de modo a se detectar diferenças entre as PSDs dos segmentos corrente (L) e imediatamente anterior (L-1). Assim, com base na equação fundamental do TFE (Equação (8)), desenvolveu-se a Equação (23), a seguir:

$$\Phi_{Y_L Y_{L-1}}(\Delta f) = \frac{\sum_{k=1}^{nbins} \sum_{i=1}^M |Y_{Li}(f_k)|^2}{\sum_{k=1}^{nbins} \sum_{i=1}^M |Y_{L-1i}(f_k)|^2} \quad (23)$$

em que  $Y_{Li}(f)$  e  $Y_{L-1i}(f_k)$  são as transformadas de Fourier da  $i$ -ésima janela do sinal de EMG pertencentes, respectivamente, ao segmento corrente,  $y_L[n]$ , e anterior,  $y_{L-1}[n]$ . O valor de  $\Phi_{Y_L Y_{L-1}}$  foi calculado a cada nova janela de 100ms e para a banda de frequência  $\Delta f$  de  $nbins$  componentes. O algoritmo pode ser melhor visualizado pelo esquema exemplo da Figura 3.7, em que se considera  $M=4$  para cada segmento.




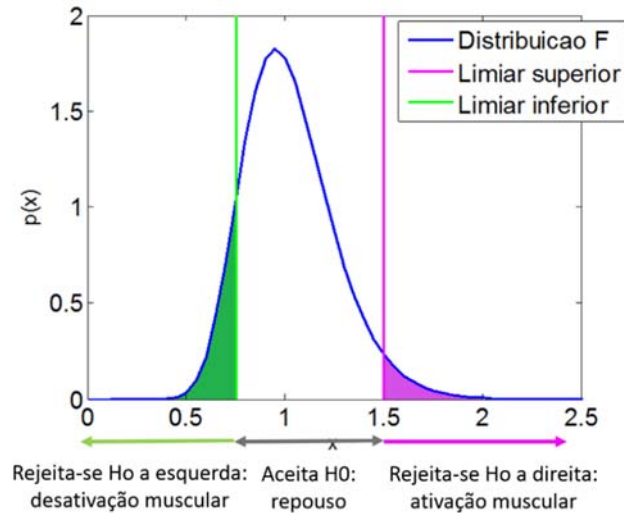
Figura 3.7 - Esquema do processo de cálculo do TFE para cada janela do sinal.

Para que o TFE pudesse ser aplicado neste trabalho, assumiu-se os sinais de EMG como gaussianos. O teste de hipóteses implementado utilizou a abordagem Neyman-Pearson, onde  $H_0$  indica a não existência de diferença entre as PSDs dos segmentos L e L-1. Neste caso,  $\sigma_L^2 = \sigma_{L-1}^2$  ( $a=1$ ) e, portanto, conforme a Equação (9), tem-se:

$$H_0: \Phi_{Y_L Y_{L-1}}(\Delta f) \sim F_{2M*nbins, 2M*nbins} \quad (24)$$

Por simplicidade, neste trabalho o segmento corrente ( $Y_L$ ) será denotado por  $Y_1$  e o segmento anterior ( $Y_{L-1}$ ), por  $Y_2$ , de forma que  $\Phi_{L,L-1}$  será denotado por  $\Phi_{y_1 y_2}$ .

Um teste estatístico bicaudal foi utilizado conforme ilustra a Figura 3.8. Para tanto, o limiar inferior ( $lim_i$ ) e o limiar superior ( $lim_s$ ) foram calculados da distribuição  $F_{2M*nbins, 2M*nbins}$  para uma probabilidade de falsos positivos (nível de significância) de  $\alpha=1\%$ . Assim, valores de  $\Phi_{y_1 y_2}$  superiores a  $lim_s$  indicam um aumento de energia do segmento atual em relação ao segmento anterior do sinal, o qual pode ser interpretado como uma ativação muscular (rejeita-se  $H_0$  à direita). Por outro lado, valores de  $\Phi_{y_1 y_2}$  inferiores a  $lim_i$  indicam uma diminuição na energia do sinal ao longo do tempo, sendo interpretado como uma desativação muscular ou relaxamento (rejeita-se  $H_0$  à esquerda). Por fim, valores de  $\Phi_{y_1 y_2}$  entre os limiares inferior e superior ( $H_0$  é aceito) indicam que não houve mudança na energia do sinal (repouso).



**Figura 3.8- Esquema explicativo do teste estatístico bicaudal realizado.**

Finalmente, a cada nova janela do sinal analisado é associado um valor conforme:

$$D(\phi_{y_1y_2}) = \begin{cases} 1, \phi_{y_1y_2} > \lim_s \\ -1, \phi_{y_1y_2} < \lim_i \\ 0, \lim_i \leq \phi_{y_1y_2} \leq \lim_s \end{cases} \quad (25)$$

Portanto,  $D(\phi_{y_1y_2})$  assume o valor zero quando a  $H_0$  é aceita e os valores 1 e -1 quando  $H_0$  é rejeitado à direita e à esquerda, respectivamente.

### 3.3.4 Classificação inicial entre extensão e flexão

Duas classes foram consideradas, as quais serão abordadas neste texto como classes C1 e C2. A classe C1 indica um indício de flexão e a classe C2, um indício de extensão. Assim, os dados utilizados para treinamento caracterizando a classe C1 foram retirados dos sinais coletados durante movimentos de extensão e os dados para a classe C2, de sinais durante movimentos de flexão, durante a segunda seção do experimento.

As características utilizadas para esta etapa de classificação basearam-se nas mesmas características aplicadas na etapa de identificação de ativação e desativação muscular (PSD). Portanto, a faixa de frequência utilizada foi também de 80 a 100Hz, conforme descrito na seção 3.3.2.1. As técnicas de classificação utilizadas foram o Teste Espectral F bayesiano, LDA e SVM.



### 3.3.4.1 Classificador com TFE bayesiano

Sabe-se que diferentes músculos são recrutados para a execução de cada tipo de movimento com maior ou menor energia dependendo dos seus papéis nas execuções dos mesmos. Com base nisto, levantou-se a hipótese de que as razões entre as energias de sinais de pares de canais, em bandas de frequências específicas, seguem diferentes distribuições dependendo do movimento. Quando o par de músculos em questão são um par de agonista-antagonista a um mesmo movimento, tais razões indicam também o nível de co-contração na articulação em questão, podendo ser um parâmetro útil na avaliação e monitoramento da recuperação funcional de pacientes com membros paréticos.

De forma similar à equação (23), a razão utilizada baseou-se na seguinte equação:

$$\phi_{yx}(\Delta f)_i = \frac{\sum_{k=1}^{nbins} \sum_{i=1}^M |Y_i(f_k)|^2}{\sum_{k=1}^{nbins} \sum_{i=1}^M |X_i(f_k)|^2} \quad (26)$$

na qual  $Y_i(f_k)$  e  $X_i(f_k)$  são as transformadas de Fourier de  $y_i[n]$  e  $x_i[n]$ , os quais são segmentos de sinais de EMG coletados em dois diferentes músculos, durante movimentos de extensão e de flexão dos dedos da mão.

Se considerarmos que os trechos dos sinais de EMG são gaussianos, na equação (26),  $\phi_{yx}(f)$  será dado por uma distribuição F com fator de escalonamento  $a$  (ver equação (9)). Porém, neste caso, dependendo de quais os músculos envolvidos e qual o tipo de movimento, o fator de escalonamento  $a$  poderá assumir diferentes valores. Assim, foi proposto neste trabalho utilizar como base para a classificação as estimativas das razões entre as variâncias dos sinais de certos pares de músculos em bandas de frequência específicas, em janelas de tempo em que se sabe da ocorrência de cada tipo de movimento. Os pares foram escolhidos de forma que estes tivessem diferentes contribuições na flexão ou extensão. Em resumo, diferentes valores de  $a$  relativos às razões entre diferentes pares de músculos podem ser estimados para cada tipo de movimento.

As estimativas de  $a$  para a flexão ( $a_{flex}$ ) e extensão ( $a_{ext}$ ), para cada par de músculos, foram obtidas pelas médias de 3 valores consecutivos de  $\phi_{yx}(\Delta f)$  nos 10 movimentos da seção II (no total média de 30 valores de  $\phi_{yx}(\Delta f)$ ), a partir dos instantes em que se iniciaram os movimentos (identificados através do sinal de acelerometria).

A Figura 3.9 mostra os gráficos das distribuições estimadas para movimentos de extensão (azul) e movimentos de flexão (vermelho) dos dedos. Neste caso foi considerado o par de músculos Extensor Comum dos Dedos e Flexor Superficial dos Dedos.




Figura 3.9 - Exemplo de distribuições estimadas para movimentos de extensão (curva azul) e flexão (curva vermelha) dos dedos.

Uma vez estimadas as distribuições, estas são associadas a duas hipóteses estatísticas a seguir:

$$\begin{aligned} H1: \varnothing_{yx} &\sim a_{flex} F_{v1, v2} \\ H2: \varnothing_{yx} &\sim a_{ext} F_{v1, v2} \quad , (27) \end{aligned}$$

As regiões de classificação foram obtidas com base na razão de verossimilhança que produz a mínima probabilidade de erro (Bayesiana). Assim, decide-se por H2 (extensão) quando (Kay 1998):

$$\frac{p_{x|H2}(x|H2)}{p_{x|H1}(x|H1)} > \frac{P(H1)}{P(H2)} \quad (28)$$

Atribuindo-se 1/2 de probabilidade *a priori* para ocorrência de cada movimento e substituindo-se a PDF da distribuição F com fator de escalonamento dada pela equação (13), para as duas hipóteses apresentadas, temos a equação (29) a seguir (por simplicidade,  $\varnothing = \varnothing_{yx}$ ):

$$\frac{\frac{1}{a_{ext}}\left(\frac{\phi}{a_{ext}}\right)^{\frac{v}{2}-1}}{B\left(\frac{v}{2}, \frac{v}{2}\right)\left(1+\frac{\phi}{a_{ext}}\right)^v} > \frac{\frac{1}{a_{flex}}\left(\frac{\phi}{a_{flex}}\right)^{\frac{v}{2}-1}}{B\left(\frac{v}{2}, \frac{v}{2}\right)\left(1+\frac{\phi}{a_{flex}}\right)^v} > 1 \quad (29)$$

Isolando-se  $\phi_{yx}$  no lado esquerdo da equação, decide-se por H2 se a condição dada por (30) for satisfeita:

$$\phi_{yx} > \frac{a_{flex}k - a_{ext}}{1 - k} = \lim \quad (30)$$

onde  $k = \sqrt[2]{\frac{a_{ext}}{a_{flex}}}$

Assim, com base no valor de  $\phi_{yx}$  em uma dada janela do sinal de EMG, define-se a variável C a seguir:

$$C(\phi_{yx}) = \begin{cases} 1, & \phi_{yx} \leq \lim; \text{ flexão} \\ 2, & \phi_{yx} > \lim; \text{ extensão} \end{cases} \quad (31)$$

O desempenho deste classificador foi avaliado teoricamente por meio da probabilidade de erro para diferentes valores de  $a_{flex}$  e  $a_{ext}$ .

### 3.3.4.2 Classificação com LDA e com SVM


Duas outras técnicas de classificação, LDA e SVM, foram utilizadas neste trabalho para servirem como base de comparação na classificação inicial entre extensão e flexão. As energias dos sinais em bandas de frequências específicas, conforme equação (22), de segmentos do sinal em que ocorreu o movimento – determinados como descrito na seção 3.3.1 - para cada canal considerado, foram utilizadas como características de entrada dos classificadores LDA e SVM. O *Kernel* escolhido para a classificação com SVM foi o Gaussiano.

### 3.3.5 Classificação final (Árvore de decisão)

Ao longo da aquisição de sinais o classificador final teve que distinguir para cada janela, 4 classes de eventos: repouso, extensão, flexão e relaxamento. Janelas de tempo

que tenham sido classificadas como extensão, flexão ou relaxamento são interpretadas como intervalos em que se está executando o referido movimento. Por outro lado, janelas classificadas como repouso indicam que nenhum movimento foi executado no intervalo de tempo em questão, i.e., não houve mudança significativa nas energias dos sinais.

Uma janela de sinal foi classificada como pertencente a classe extensão ou flexão quando  $C(\phi_{yx})$  resultou respectivamente nos valores 1 e 2 e, nesta mesma janela, foi detectada ativação muscular no principal músculo responsável pelo respectivo movimento, ou seja,  $D(\phi_{y1y2})_n = 1$  (Figura 3.10). Uma janela é considerada como pertencente à classe relaxamento quando é detectada desativação muscular no principal músculo responsável pelo último movimento classificado (extensão ou flexão), ou seja,  $D(\phi_{y1y2})_n = -1$ . Quando nenhum dos critérios acima descritos são cumpridos, classifica-se a janela como repouso. Esta lógica está ilustrada na Figura 3.10. A estes critérios foi ainda adicionada a seguinte condição: um movimento só será confirmado se 2 janelas sucessivas cumprirem os critérios anteriormente citados. Este critério adicional visou a diminuir a taxa de falsos positivos do classificador.



**Figura 3.10 - Árvore de decisão para determinação da classificação final de cada janela do sinal de EMG. Não está ilustrado no diagrama a necessidade de as 2 janelas com mesma classificação para confirmar um dado movimento (Relax=Relaxamento).**

### 3.3.6 Avaliação do classificador

Após a simulação do classificador em tempo real a partir dos sinais da seção III do experimento, o seu desempenho foi avaliado utilizando-se três diferentes métricas: especificidade (E) e sensibilidade (S) para cada classe considerada (flexão, extensão e

relaxamento), além da acurácia global (A) (Zhang et al. 2013). O cálculo destas métricas é realizado com base nas equações (32), (33) e (34) a seguir:

$$S = \frac{VP}{VP + FN} \quad (32)$$

$$E = \frac{VN}{VN + FP} \quad (33)$$

$$A = \frac{VP + VN}{VP + FP + VN + FN} \quad (34)$$

VP representa o número de verdadeiros positivos (janelas de uma determinada classe que foram corretamente classificadas como pertencentes a tal classe), VN representa o número de verdadeiros negativos (janelas que não pertencem a determinada classe corretamente classificadas como não pertencentes a tal classe), FP representa o número de falsos positivos (janelas que não pertencem a determinada classe classificadas incorretamente como pertencendo à mesma) e FN é o número de falsos negativos (janelas que pertencem a uma determinada classe mas que não foram classificadas como pertencentes à mesma).

Os sinais de EMG da seção III foram separados em trechos de: (a) movimentos de flexão, (b) movimentos de extensão, os quais consistem da primeira metade dos trechos delimitados pelos pontos de iniciação e finalização do movimento, indicados pelo acelerômetro, quando executado o respectivo movimento; (c) relaxamento, consistindo da primeira metade dos trechos entre os pontos de finalização de um movimento e inicialização do movimento seguinte e (d) repouso, consistindo de todos os trechos restantes do sinal. Assim, janelas classificadas, por exemplo, como relaxamento e que estejam dentro do trecho de relaxamento segundo a separação realizada, foram consideradas verdadeiros positivos. O mesmo é aplicado às classificações de extensão, flexão e repouso. Janelas que estejam fora do respectivo trecho verdadeiro são computadas como falsos positivos para a classe à qual foram associadas.

Cada tipo de classificador foi simulado para 3 diferentes pares de músculos: ECD/FSD; ECP/FLP e ECD/FPD, os quais representam pares de músculos

agonista/antagonista (antagonista/agonista) aos movimentos de extensão e flexão dos dedos da mão. Para fins de comparação, foi acrescentado o par FDI/FPD.

### 3.4 Estimativa de co-contração

Os fatores de escalonamento a correspondentes a cada movimento (denotados por  $a_{ext}$  para extensão e  $a_{flex}$ , para flexão), cuja estimativa foi descrita na seção 3.3.4.1, podem ser boas estimativas para os níveis de co-contração dos músculos, visto que  $a$  é uma estimativa da razão entre a variância do músculo extensor e a variância do músculo flexor. Levando-se em consideração que o músculo extensor selecionado é agonista ao movimento de extensão e antagonista ao de flexão dos dedos e, ao mesmo tempo, o músculo flexor selecionado é agonista ao movimento de flexão e antagonista ao de extensão dos dedos, pode-se estabelecer uma relação entre os valores de  $a_{ext}$  e  $a_{flex}$  e os níveis de co-contração de extensão ( $CC_{ext}$ ) e flexão ( $CC_{flex}$ ), conforme as equações a seguir:

$$a_{ext} = \frac{1}{CC_{ext}} \quad (35)$$

$$a_{flex} = CC_{flex} \quad (36)$$

Porém, estes valores sofrem influência de diferenças de ganho nos diferentes canais de leitura, o que pode prejudicar uma comparação entre diferentes sujeitos, ou para o mesmo sujeito em diferentes coletas. Esta influência pode ser eliminada calculando-se a razão entre os fatores de escalonamento  $a$  ( $Ra$ ) correspondentes a cada tipo de movimento, estimados por sinais de uma mesma coleta. Esta nova razão associa-se aos níveis de co-contração conforme a equação a seguir:

$$Ra = \frac{a_{flex}}{a_{ext}} = CC_{ext}CC_{flex} \quad (37)$$

Assim, os valores de  $Ra$  foram calculados para análise dos níveis de co-contração dos diferentes sujeitos.

## 4 Resultados

Neste capítulo são apresentados resultados referentes às características extraídas dos sinais de EMG e métricas de desempenho geral dos classificadores utilizando os sinais de voluntários do Grupo A. Para os voluntários do Grupo B, as características dos sinais e os desempenhos dos classificadores são apresentados caso a caso. Os sinais de todos os sujeitos foram inicialmente pré-processados, sendo que os sinais de 2 indivíduos do Grupo A foram desconsiderados devido à presença de níveis de ruído acima do sinal de EMG.

A identificação dos pontos de iniciação e finalização do movimento pelo sinal de acelerometria de alguns indivíduos do Grupo B não pôde ser realizada de forma automática devido à menor mobilidade dos pacientes. Nestes casos, a seleção visual foi realizada. Porém, os pontos dos sinais de 2 dos sujeitos ainda assim não puderam ser identificados devido a altos níveis de ruído ou mesmo a pouca atividade muscular aparente nos sinais. Estes sujeitos foram, portanto, desconsiderados neste estudo.

### 4.1 Desempenho teórico do classificador Bayesiano

A Probabilidade de Erro Bayesiana teórica do classificador entre extensão e flexão dos dedos foi obtida conforme a Equação (4) para diferentes combinações de valores de  $a_{ext}$  e  $a_{flex}$ . Como resultado, obteve-se o gráfico da Figura 4.1. Conforme esperado, observa-se que quanto mais próximos tais valores forem uns dos outros, maior a probabilidade de erro, valendo 1 quando  $a_{ext}=a_{flex}$ , ou seja, quando as distribuições se sobrepõem.




Figura 4.1 - Probabilidade de Erro do classificador entre extensão e flexão a partir dos valores de  $a_{ext}$  e  $a_{flex}$ .

## 4.2 Identificação de ativação e desativação muscular

Foi aplicado o algoritmo como descrito na seção 3.3.3, utilizando-se  $M=5$  janelas com  $N=200$  amostras cada e considerando-se o espectro em uma banda de 80 a 100 Hz (resolução espectral de 10Hz – janela de 100ms), o que corresponde a 3 componentes em frequência (nbins). Assim, o número de graus de liberdade das distribuições  $F$  estimadas foi de  $2 \times M \times \text{nbins} = 30$ .

A Figura 4.2 mostra o gráfico com o resultado do método apresentado aplicado ao sinal de EMG do canal referente ao músculo ECD do voluntário1 do grupo A (A01), durante três movimentos que consistem da abertura da mão seguida de relaxamento. Para uma melhor visualização, foram traçados os logaritmos de  $\phi_{y1y2}$  e dos limiares superior e inferior. É possível observar que o valor de  $\log(\phi_{y1y2})$  cresce rapidamente no início de uma contração (quando o movimento está sendo executado), ficando acima do limiar superior, e decresce rapidamente ao fim da contração ficando em valores abaixo do limiar inferior ao completar o movimento (mão relaxada). A Figura 4.3 mostra o mesmo sinal com o resultado do teste  $F$ ,  $D(\phi_{y1y2i})$ , cujos valores são iguais a 1 para valores de  $\phi_{y1y2}$  maiores que o limiar superior; a 0 entre os limiares superior e inferior; e -1 para valores de  $\phi_{y1y2}$  menores que o limiar inferior. Pode-se observar neste gráfico que há um atraso muito pequeno na resposta do identificador de ativação muscular a um aumento de energia no sinal.

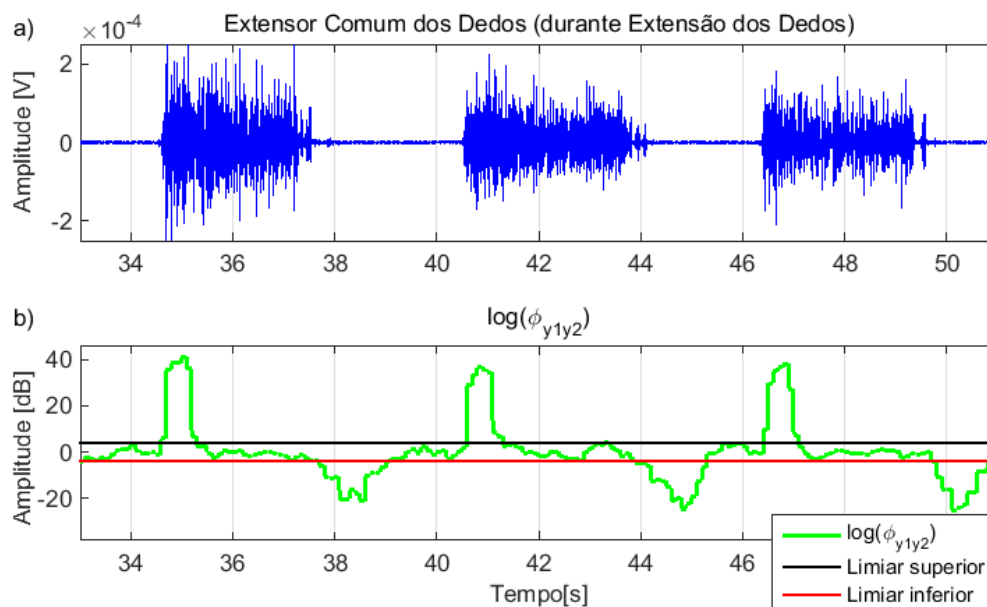
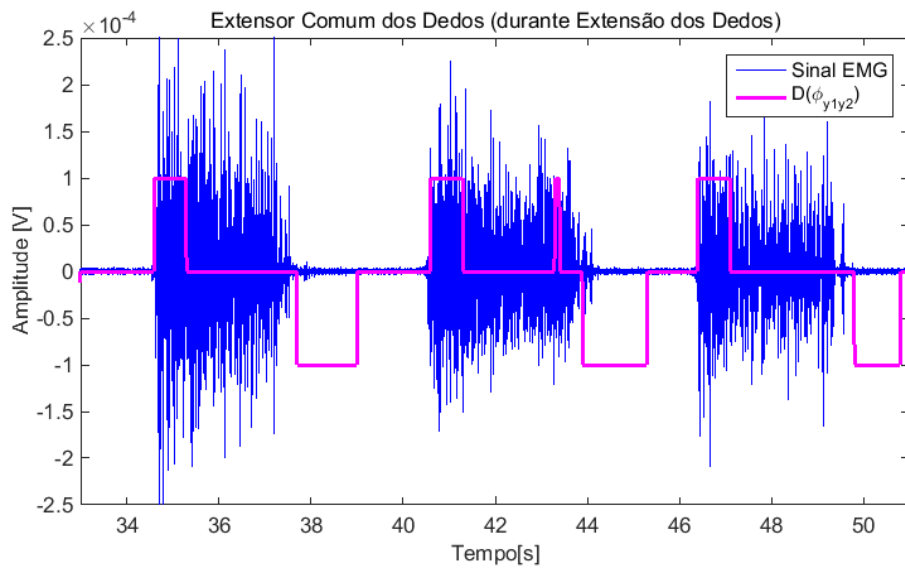


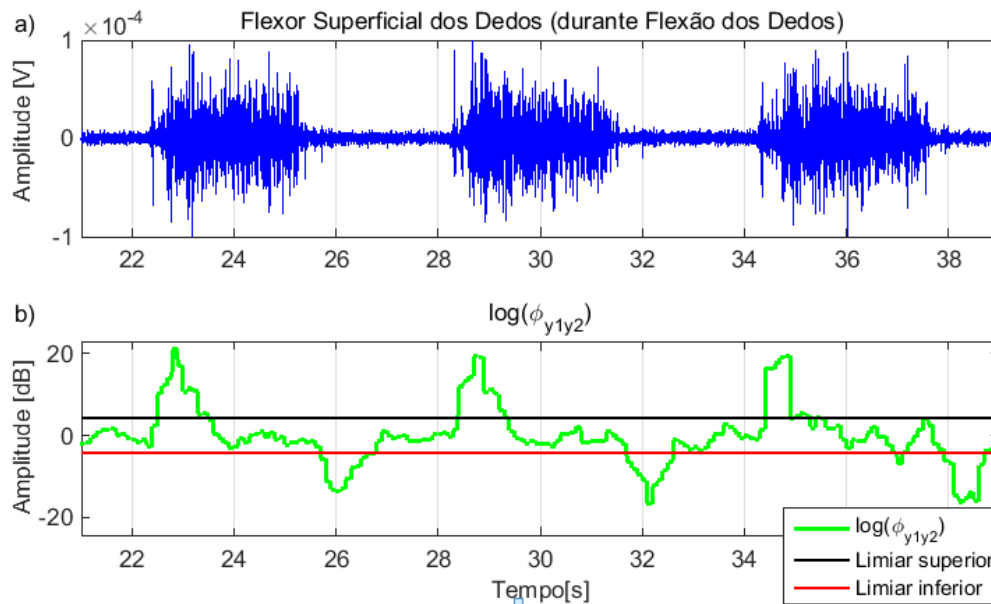
Figura 4.2 - Sinal de EMG (azul) do músculo ECD do voluntário A01 durante movimentos de Extensão (a) e  $\phi_{y1y2}$  estimado para cada janela do sinal, além dos limiares superior e inferior (b).



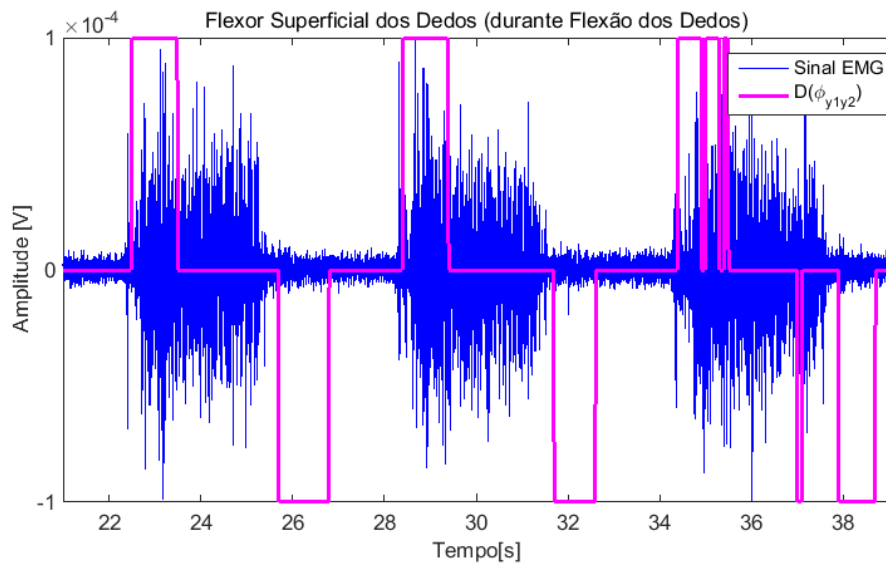


**Figura 4.3 - Sinal de EMG (azul) do músculo ECD, durante movimentos de Extensão e  $D(\phi_{y1y2})$  correspondente. Os valores do  $D(\phi_{y1y2})$  foram multiplicados por potências negativas de 10 apenas para facilitar a visualização.**

As Figuras 4.4 e 4.5 mostram resultados para mesma simulação, neste caso utilizando o sinal do músculo Flexor Superficial dos Dedos durante movimentos de flexão – relaxamento dos dedos do voluntário A01.



**Figura 4.4 - Sinal de EMG (azul) do músculo FSD do voluntário A01 durante movimentos de Flexão (a) e  $\phi_{y1y2}$  estimado para cada janela do sinal, além dos limiares superior e inferior (b).**



**Figura 4.5 - Sinal de EMG (azul) do músculo FSD do voluntário A01 durante movimentos de Flexão e  $D(\phi_{y1y2})$  correspondente. Os valores do  $D(\phi_{y1y2})$  foram multiplicados por potências negativas de 10 apenas para facilitar a visualização.**

Comportamentos similares do teste F foram observados nos músculos estudados em todos os voluntários do Grupo A.

### 4.3 Classificador com TFE bayesiano

A Figura 4.6 apresenta sinais de EMG, durante 3 movimentos de extensão-relaxamento do voluntário A01 dos músculos ECD e FSD e os valores de  $\log(\phi_{yx})$  estimados a partir das razões das energias destes sinais. Pode-se notar que  $\phi_{yx}$  tem uma periodicidade que corresponde à periodicidade do movimento, tendo amplitudes maiores durante o movimento de extensão e amplitudes menores durante o tempo em que a mão fica relaxada. O mesmo fenômeno, porém de forma contrária, pode ser observado na Figura 4.7, em movimentos de flexão-relaxamento, isto é, durante o movimento,  $\phi_{yx}$  assume amplitudes mais baixas que nos períodos em que a mão está relaxada.

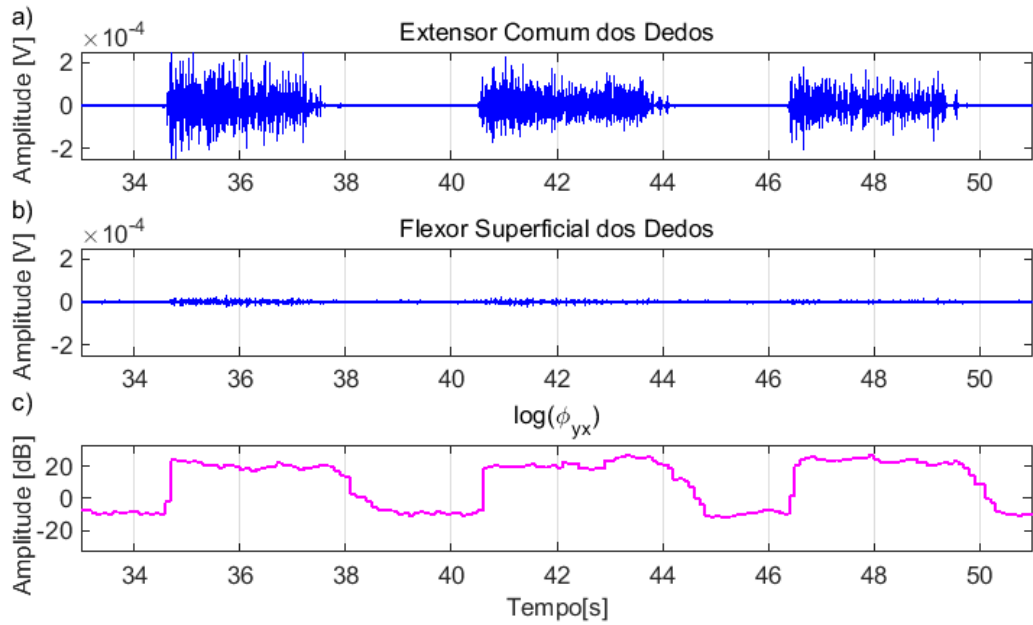


Figura 4.6 - Sinal de EMG nos músculos ECD (a) e FSD (b) do voluntário A01 durante movimentos de extensão dos dedos e  $\phi_{yx}$  correspondente (c).

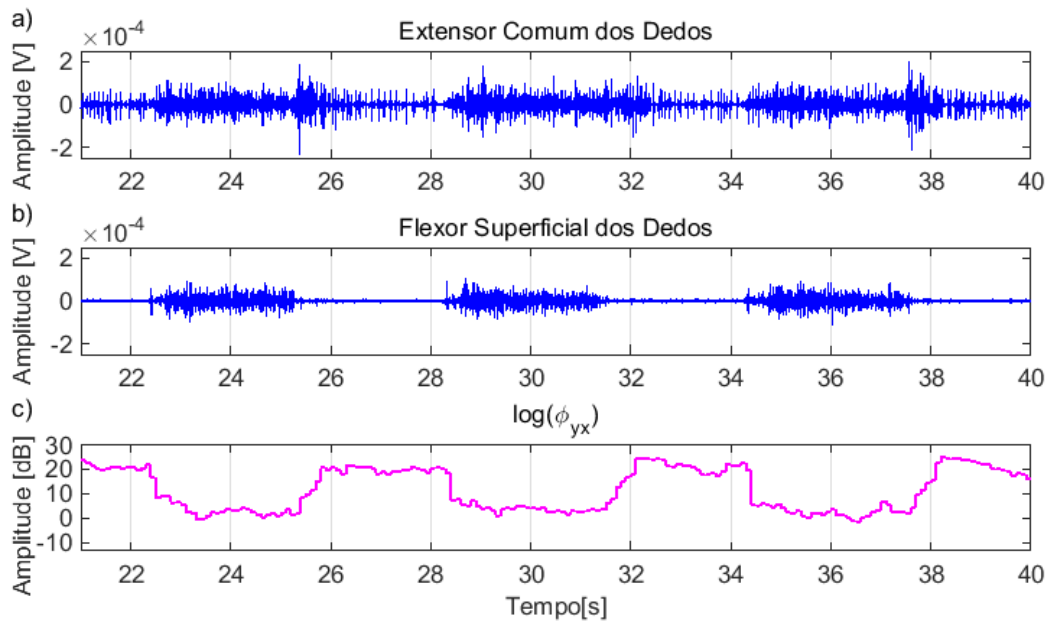




Figura 4.7 - Sinal de EMG nos músculos ECD (a) e FSD (b) do voluntário A01 durante movimentos de flexão dos dedos e  $\phi_{yx}$  correspondente (c).

As distribuições estimadas para o voluntario A01 a partir dos sinais dos músculos ECD e FSD e o limiar de classificação correspondente são mostrados na Figura 4.8. Observa-se que a distribuição correspondente a extensão (H2) fica deslocada à direita.



**Figura 4.8 - Distribuições F estimadas a partir dos canais ECD e FSD de sinais do voluntário A01, para movimentos de extensão e flexão e limiar correspondente.**

A Figura 4.9 mostra a classificação final (após árvore de decisão), segundo a simulação em tempo real realizada com os sinais de EMG da seção III. Nesta simulação utilizou-se o TFE escalonado como classificador entre extensão e flexão, durante movimentos de extensão, com base nos sinais correspondentes aos músculos ECD e FSD. A Figura 4.10 mostra a classificação resultante para movimentos de flexão com base nos mesmos músculos. Os sinais de EMG traçados apenas para referência visual correspondem aos músculos ECD, na Figura 4.9, e FSD, na Figura 4.10.



**Figura 4.9 - Classificação final utilizando o TFE dos sinais considerando músculos ECD e FSD para o voluntário A01 durante trechos de movimentos de extensão – relaxamento.**

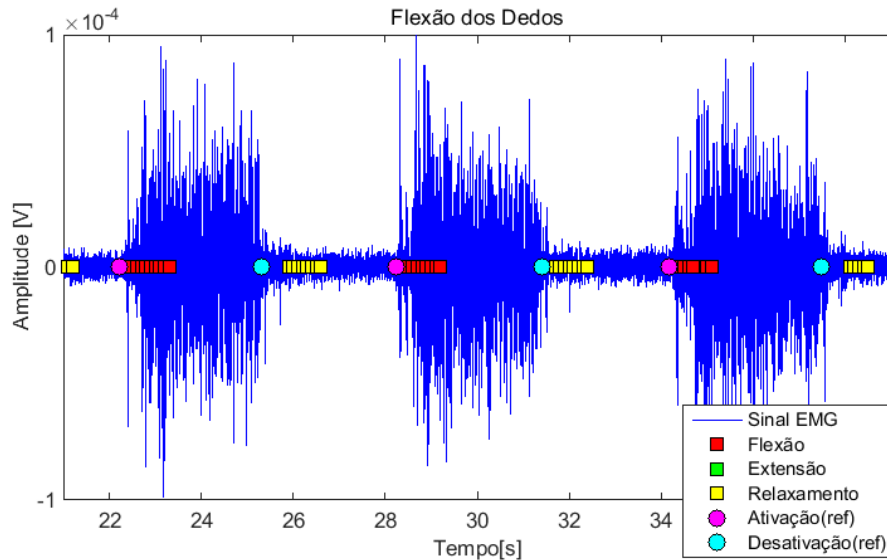


Figura 4.10 - Classificação final com base no TFE dos sinais considerando canais ECD e FSD para o voluntário A01 durante trechos de movimentos de flexão – relaxamento.

#### 4.4 Classificadores LDA e SVM

Os classificadores LDA e o SVM foram aplicados, conforme descrito na seção 3.3.6, nas 4 diferentes configurações de canais. A energia de canal corresponde a uma variável de entrada. A Figura 4.11 mostra as entradas consideradas para um classificador LDA somente com os músculos ECD e FSD. A linha rosa indica a separação entre as regiões de classificação.


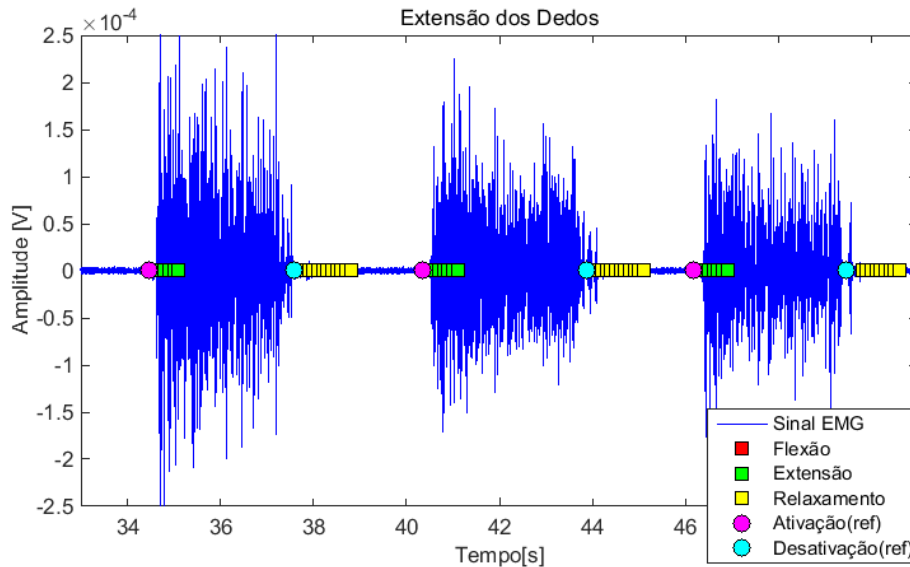



Figura 4.11 - Dados de entrada do classificador com base em LDA com linha em rosa separando as regiões de classificação

As Figuras 4.12 e 4.13 mostram a classificação final com LDA dos sinais da seção III do experimento, para a mesma seção correspondente aos sinais ilustrados pelas Figuras 4.9 e 4.10.



**Figura 4.12 - Classificação final com base em LDA dos sinais considerando canais ECD e FSD para o voluntário A01 durante trechos de movimentos de extensão – relaxamento.**



**Figura 4.13 - Classificação final com base em LDA dos sinais considerando canais ECD e FSD para o voluntário A01 durante trechos de movimentos de flexão – relaxamento.**

A Figura 4.14 mostra o gráfico com as entradas e as regiões de classificação definidas pelo classificador SVM com os sinais do voluntário A01.




Figura 4.14 – Regiões de classificação utilizando SVM

As Figuras 4.15 e 4.16 mostram a classificação final para a mesma seção anteriormente ilustrada nas Figura 4.9 e Figura 4.10.





Figura 4.15 - Classificação final com base em SVM dos sinais considerando canais ECD e FSD para o voluntário A01 durante trechos de movimentos de extensão – relaxamento.




**Figura 4.16 - Classificação final com base em SVM dos sinais considerando canais ECD e FSD para o voluntário A01 durante trechos de movimentos de flexão – relaxamento.**

#### 4.5 Desempenho dos classificadores


Como descrito na seção 3.3.6, diferentes configurações de canais de entrada foram consideradas para os classificadores e seus desempenhos foram avaliados por diferentes métricas. As métricas de desempenho dos classificadores, utilizando os sinais do voluntário A01 são apresentadas a seguir nos gráficos das Figuras 4.17 a 4.20.

Os classificadores obtiveram melhor desempenho para os pares de músculos ECD-FSD (Figura 4.17) e ECP-FLP (Figura 4.19), com valores médios de sensibilidade, especificidade e acurácia acima de 95%. Utilizando os pares de músculos PID-FPD e ECD-FPD, o desempenho foi menor para os três classificadores, principalmente nos valores de sensibilidade, que em vários casos foi menor que 80%. Os gráficos apontam que os diferentes classificadores tiveram desempenhos similares utilizando os sinais do voluntário A01.

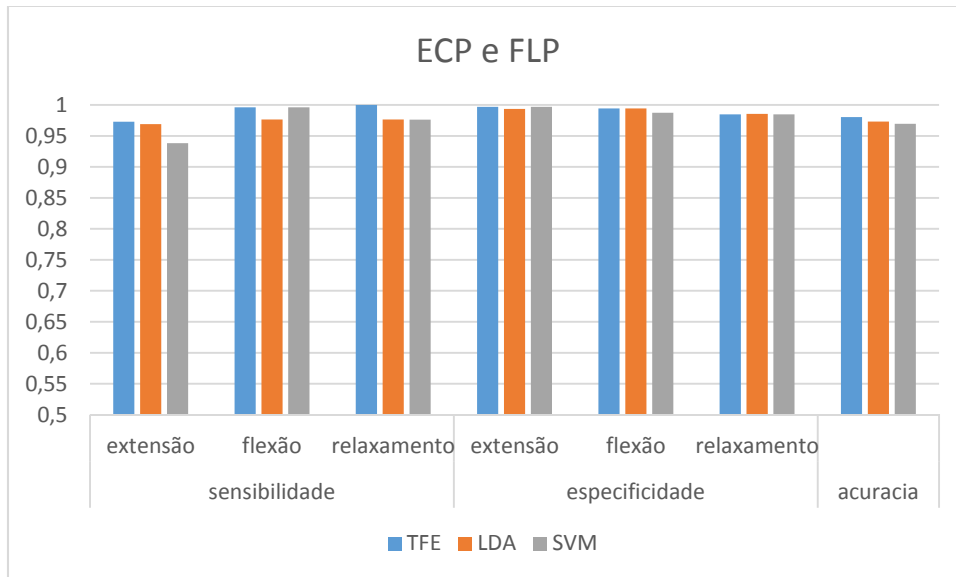




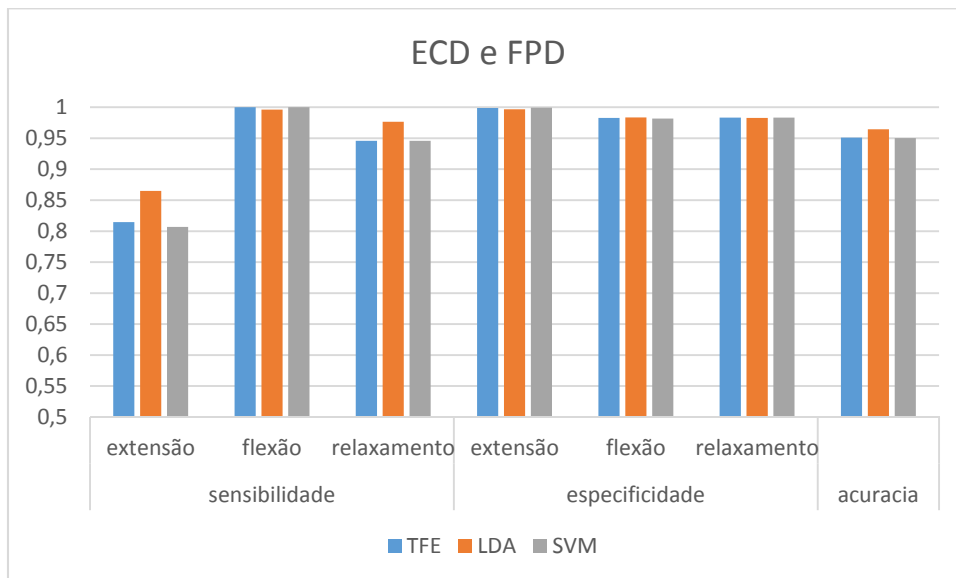
**Figura 4.17 - Métricas de desempenho dos classificadores para canais correspondentes aos músculos ECD e FSD dos sinais do voluntário A01.**



**Figura 4.18 - Métricas de desempenho dos classificadores para canais correspondentes aos músculos PID e FPD dos sinais do voluntário A01.**




**Figura 4.19 - Métricas de desempenho dos classificadores para canais correspondentes aos músculos ECP e FLP dos sinais do voluntário A01.**




**Figura 4.20 - Métricas de desempenho dos classificadores para canais correspondentes aos músculos ECD e FPD dos sinais do voluntário A01.**

As Figuras 4.21 a 4.24 mostram os resultados referentes aos desempenhos dos classificadores finais, a partir das médias das métricas para todos os voluntários do Grupo A. Pode-se novamente notar que os desempenhos dos diferentes classificadores foram similares em todos os pares de músculos utilizados. Para o par de músculos ECD-FSD (Figura 4.21) os classificadores apresentaram melhores desempenhos, com sensibilidades maiores que 85%, especificidades maiores que 95% e acurácias maiores que 90%. Os classificadores obtiveram pior desempenho com os músculos PID-FPD (Figura 4.22), com sensibilidades variando entre 60% e 80%. Nos demais pares de músculos (ECP-FLP


e ECD-FPD, Figura 4.23 e Figura 4.24, respectivamente), os classificadores obtiveram desempenho similar ao par ECD-FSD, porém, com valores de sensibilidade inferiores.




**Figura 4.21 - Média das métricas de desempenho dos classificadores para canais correspondentes aos músculos ECD e FSD.**



**Figura 4.22 - Média das métricas de desempenho dos classificadores para canais correspondentes aos músculos PID e FPD.**



**Figura 4.23 - Média das métricas de desempenho dos classificadores para canais correspondentes aos músculos ECP e FLP.**



**Figura 4.24 - Média das métricas de desempenho dos classificadores para canais correspondentes aos músculos ECD e FPD.**

#### 4.6 Estimativas de co-contração

Os valores das razões entre as variâncias de 3 diferentes pares de músculos (ECD-FSD, ECP-FLP e ECD-FPD) durante movimentos de extensão ( $a_{ext}$ ) e flexão ( $a_{flex}$ ) foram registrados para cada voluntário. O par PID-FPD não foi incluído nesta estimativa pois não representa um par de músculos agonista/antagonista aos movimentos estudados. A Tabela 4-1 apresenta os valores estimados a partir dos sinais do voluntário A01. Foi indicado como zero quando o valor de Ra foi muito pequeno.

**Tabela 4-1 Valor das razões das variâncias dos sinais durante extensão e durante flexão e relação entre os dois valores para o voluntário A01.**

	<b>ECD/FSD</b>	<b>ECP/FLP</b>	<b>ECD/FPD</b>
<b><math>a_{ext}</math></b>	313,29	51,07	275,85
<b><math>a_{flex}</math></b>	2,79	0,13	10,86
<b><math>Ra</math></b>	0,01	0,00	0,04

A Tabela 4-2 apresenta as médias das razões considerando os sinais de todos os voluntários do Grupo A. Pode-se observar que, em ambas, os valores de  $a_{ext}$  são muito maiores que os valores de  $a_{flex}$  e que todos são maiores que 1, o que indica que mesmo durante a flexão a variância do músculo flexor é menor. As razões  $Ra$  indicam valores próximos de zero nas duas tabelas, o que pode expressar baixos níveis de co-contracção.

As distribuições contendo como amostras os valores de  $Ra$  foram ajustadas a distribuições normais com média e desvio padrão apresentados na Tabela 4-2. A hipótese nula ( $H_0$ ), de que há condição de normalidade na co-contracção em cada par de músculos, será aceita quando os valores de  $Ra$  pertencem ao intervalo de confiança de 95% (nível de significância de 5%) das distribuições.

**Tabela 4-2 Valor médio das razões das variâncias dos sinais durante extensão e durante flexão e relação entre os dois valores para o voluntário A01.**

	<b>ECD/FSD</b>		<b>ECP/FLP</b>		<b>ECD/FPD</b>	
	<b>Média</b>	<b><math>\sigma</math></b>	<b>Média</b>	<b><math>\sigma</math></b>	<b>Média</b>	<b><math>\sigma</math></b>
<b><math>a_{ext}</math></b>	143,25	$\pm 167,77$	22,93	$\pm 22,42$	38,63	$\pm 63,17$
<b><math>a_{flex}</math></b>	19,70	$\pm 31,81$	4,81	$\pm 3,74$	6,62	$\pm 10,43$
<b><math>Ra</math></b>	0,20	$\pm 0,30$	0,28	$\pm 0,29$	0,22	$\pm 0,24$

## **4.7 Estudo de caso com pacientes (Grupo B)**

Nesta seção são apresentados os resultados referentes aos sinais dos voluntários B01 e B02. São mostrados os gráficos referentes a cada etapa do algoritmo de classificação, os desempenhos dos classificadores, e, finalmente, apresentados os valores de co-contracção. As métricas de desempenho dos classificadores e os níveis de co-contracção dos demais pacientes são apresentados no Apêndice B.

### **4.7.1 Voluntário B01**

Os gráficos a seguir correspondem a resultados das mesmas simulações apresentadas nas seções 4.2 a 4.5, sendo que, neste caso, os sinais utilizados são do voluntário 01 pertencente ao Grupo B (voluntário B01). Este voluntário teve avaliação 63/66 pelo FMA.

As Figuras 4.25 e 4.26 mostram o comportamento da variável  $\phi_{y1y2}$  no músculo ECD durante movimentos de extensão-relaxamento e no músculo FSD durante movimentos de flexão-relaxamento, respectivamente. Pode-se observar que, para este paciente,  $\log(\phi_{y1y2})$  apresentou comportamento similar ao de voluntários do Grupo A.

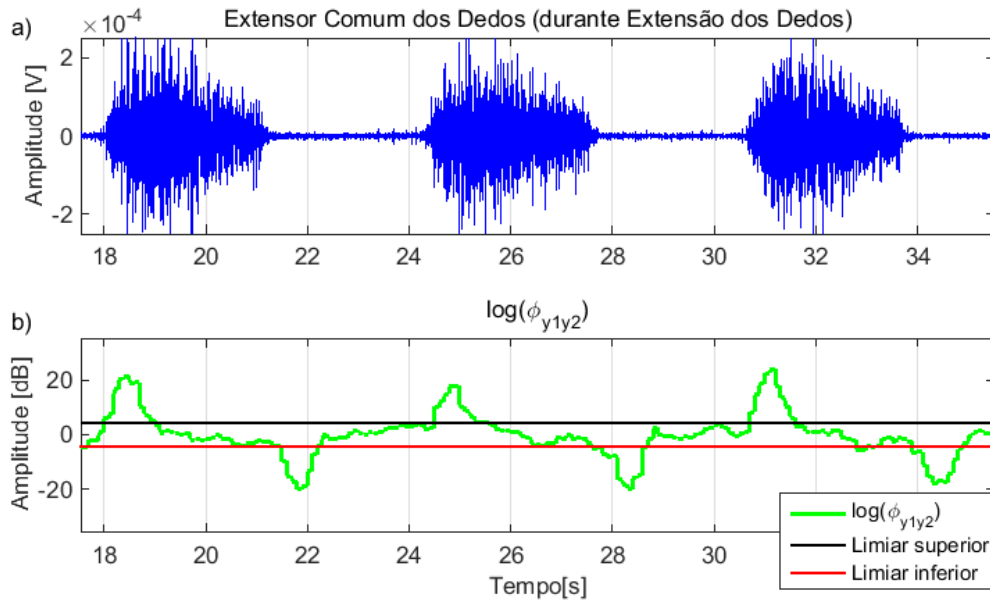


Figura 4.25 - Sinal de EMG (azul) do músculo ECD, durante movimentos de Extensão (a) e  $\log(\phi_{y1y2})$  estimado para cada janela do sinal, além dos limiares superior e inferior (b).




Figura 4.26 - Sinal de EMG (azul) do músculo FSD, durante movimentos de Flexão (a) e  $\phi_{y1y2}$  estimado para cada janela do sinal, além dos limiares superior e inferior (b).

As Figuras 4.27 e 4.28 apresentam sinais de EMG, durante movimentos de extensão-relaxamento e flexão-relaxamento, respectivamente, do voluntário B01, dos músculos ECD e FSD e os valores de  $\log(\phi_{yx})$  estimados a partir das razões das energias dos sinais destes músculos. Observa-se que, diferentemente do comportamento em normais, os valores de  $\log(\phi_{yx})$  não apresentaram um padrão periódico similar aos movimentos.




Figura 4.27 - Sinal de EMG nos músculos ECD (a) e FSD (b) durante movimentos de extensão dos dedos do voluntário B01 e valores de  $\phi_{yx}$  correspondentes (c).





Figura 4.28 - Sinal de EMG nos músculos ECD (a) e FSD (b) durante movimentos de flexão dos dedos do voluntário B01 e valores de  $\phi_{yx}$  correspondentes (c).

As distribuições F estimadas para o voluntário B01 a partir dos sinais dos músculos ECD e FSD e o limiar de classificação correspondente são mostrados na Figura 4.29. Observa-se que as PDFs ficam quase superpostas, o que indica uma alta Probabilidade de Erro, prejudicando o desempenho do classificador.




**Figura 4.29 - Distribuições F escalonadas e estimadas a partir dos sinais da seção II do voluntário B01 e limiar bayesiano correspondente.**


Os gráficos a seguir (Figuras 4.30 a 4.33) mostram as métricas dos classificadores utilizando-se sinais do voluntário B01 dos 4 pares de músculos. Para os sinais do par ECD-FSD (Figura 4.30), os classificadores tiveram acurácias e especificidades maiores que 85%. Porém, os níveis de sensibilidade foram, em geral, menores, principalmente os valores referentes à classe extensão, utilizando-se o classificador com base em LDA. As mesmas observações podem ser feitas para os outros pares de músculos (Figuras 4.31, 4.32 e 4.33), sendo que os níveis de sensibilidade foram pouco maiores para o par ECP-FLP (Figura 4.32) em relação aos outros pares.

Pode-se observar que as métricas dos diferentes classificadores indicam que estes tiveram desempenhos similares, exceto por discrepâncias nos valores de sensibilidade, segundo os quais o TFE foi superior e o LDA, inferior.







**Figura 4.30- Métricas de desempenho do classificador com base em TFE para canais correspondentes aos músculos ECD e FSD dos sinais do voluntario B01.**



**Figura 4.31 - Métricas de desempenho do classificador com base em TFE para canais correspondentes aos músculos PID e FPD dos sinais do voluntario B01.**



**Figura 4.32 - Métricas de desempenho do classificador com base em TFE para canais correspondentes aos músculos ECP e FLP dos sinais do voluntário B01.**



**Figura 4.33 - Métricas de desempenho do classificador com base em TFE para canais correspondentes aos músculos ECD e FPD dos sinais do voluntário B01.**

A Tabela 4-3 mostra as estimativas das razões das variâncias ( $Ra$ ) entre os pares de canais durante a extensão ( $a_{ext}$ ), durante a flexão ( $a_{flex}$ ) e, por fim, a razão entre estes dois valores para o voluntário B01. Pode-se observar que este paciente teve razões maiores que 1 para dois dos pares de músculos considerados (ECD/FSD e ECD/FPD).

Para verificar se o parâmetro de co-contração estimado para cada par de músculos encontra-se dentro do padrão de normais ( $H_0$ ), realizou-se um teste estatístico, considerando 5% de significância. Este teste foi realizado para os dados de todos os voluntários do Grupo B. Para o paciente B01, a hipótese nula foi rejeitada para os 3 pares de músculos, com os valores p mostrados na Tabela 4-3, indicando que os níveis de co-


contração não ficaram dentro da normalidade para este indivíduo em nenhum dos pares de músculos testados. Valores-p indicados como zero representam valores muito baixos, não sendo necessário especificar.

**Tabela 4-3 - Valor médio das razões das variâncias dos sinais durante extensão e durante flexão e relação entre os dois valores para o paciente B01.**


	ECD/FSD	ECP/FLP	ECD/FPD
$a_{ext}$	4,18	0,07	5,27
$a_{flex}$	3,79	0,23	5,30
$Ra$	0,91	3,27	1,01
valor-p	0,02	0	0

#### 4.7.2 Voluntário B02

Os gráficos resultantes das simulações para o voluntário do Grupo B (voluntário B02), o qual obteve 21/66 como avaliação segundo o teste FMA, são apresentados nesta seção. As Figuras 4.34 e 4.35 mostram, respectivamente, o comportamento da variável  $\phi_{y1y2}$  no músculo ECD durante movimentos de extensão-relaxamento e no músculo FSD durante flexão-relaxamento dos dedos. Pode-se observar que durante o trecho do sinal em movimentos de extensão-relaxamento nenhuma ativação muscular voluntária pôde ser identificada no músculo extensor.



**Figura 4.34 - Sinal de EMG (azul) do músculo ECD do voluntário B02, durante movimentos de extensão (a) e  $\phi_{y1y2}$  estimado para cada janela do sinal, além dos limiares superior e inferior segundo o TFE (b).**



**Figura 4.35 - Sinal de EMG (azul) do músculo FSD do voluntário B02, durante movimentos de flexão-relaxamento (a) e  $\phi_{y1y2}$  estimado para cada janela do sinal, além dos limiares superior e inferior segundo o TFE (b).**

As Figuras 4.36 e 4.37 apresentam sinais de EMG, durante movimentos de extensão-relaxamento e flexão-relaxamento, respectivamente, do voluntário B02, dos músculos ECD e FSD, além dos valores de  $\log(\phi_{yx})$  estimados a partir destes sinais. Nota-se que em movimentos de extensão-relaxamento,  $\phi_{yx}$  tem um comportamento periódico similar ao movimento, porém, contrário. Isto é oposto ao que ocorreu em normais, indicando que o músculo flexor está tendo maior ativação durante o movimento de extensão. Já em movimentos de flexão-relaxamento, não foi possível identificar um padrão periódico similar ao movimento.

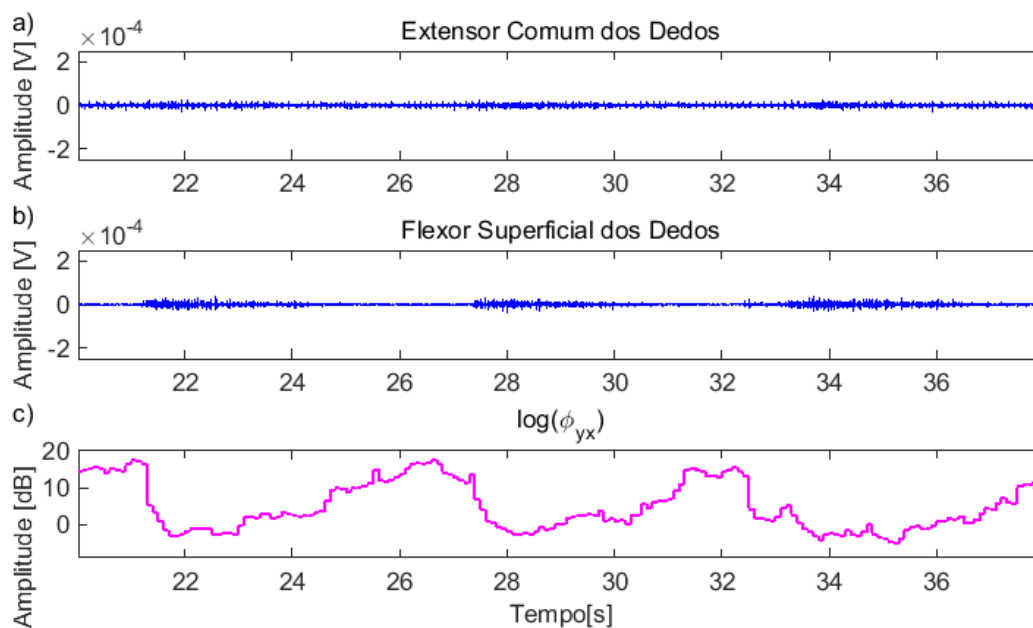


Figura 4.36 - Sinal de EMG nos músculos ECD (a) e FSD (b) durante movimentos de extensão-relaxamento dos dedos do voluntário B02 e  $\phi_{yx}$  calculado pela razão das potências do sinal de EMG destes músculos (c).




Figura 4.37 - Sinal de EMG nos músculos ECD (a) e FSD (b) durante movimentos de flexão-relaxamento dos dedos do voluntário B02 e  $\phi_{yx}$  calculado pela razão das potências do sinal de EMG destes músculos (c).

As distribuições  $F$  estimadas para o voluntario B02 a partir dos sinais dos músculos ECD e FSD e o limiar de classificação correspondente são mostrados na Figura 4.38. Observa-se que diferentemente da maioria dos casos em normais, a PDF relativa à

hipótese H1 (flexão) apresentou um fator de escalonamento superior que ao da PDF relativa à hipótese H2 (extensão).




Figura 4.38 - Distribuições F escalonadas e estimadas a partir dos sinais da seção II do voluntário B02 e limiar bayesiano correspondente.

As métricas dos classificadores para este voluntário são mostradas na Tabela 4-4, a seguir. Pode-se observar que nenhum dos classificadores apresentaram um desempenho satisfatório (acurácia  $\leq 73\%$ ), tendo sensibilidade média abaixo de 50% em vários casos.

Tabela 4-4 Métricas de desempenho dos classificadores simulados com os sinais do voluntário B02. S=Sensibilidade, E=Especificidade, A=Acurácia; Ex=extensão; Fx=Flexão; Rx=Relaxamento.

		TFE			LDA				SVM				
		ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD	ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD	ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD
<b>S</b>	Ex	0,00	1,00	0,18	0,00	0,00	1,00	0,19	0,00	0,00	1,00	0,18	0,00
	Fx	0,59	0,00	0,00	0,58	0,59	0,00	0,51	0,58	0,00	0,00	0,79	0,57
	Rx	0,67	0,79	0,54	0,54	0,67	0,79	0,48	0,44	0,47	0,79	0,55	0,44
<b>E</b>	Ex	1,00	0,93	0,98	1,00	1,00	0,93	0,98	1,00	0,93	0,93	1,00	1,00
	Fx	0,94	1,00	0,99	0,96	0,95	1,00	0,99	0,99	1,00	1,00	0,97	0,99
	Rx	0,98	0,92	0,97	0,98	0,98	0,91	0,97	0,98	0,97	0,92	0,97	0,99
<b>A</b>		0,70	0,73	0,61	0,67	0,70	0,73	0,66	0,64	0,56	0,73	0,72	0,65

Foram estimados os valores dos fatores de escalonamento e calculada razão entre os mesmos ( $Ra$ ). Os resultados mostram valores de  $Ra$  maiores que 1,3, como pode ser observado na Tabela 4-5.

Para o paciente B02, a hipótese nula de função motora normal foi rejeitada para os 3 pares de músculos, com os valores p mostrados na Tabela 4-5, indicando que os


níveis de co-contracção não ficaram dentro da normalidade para este indivíduo em nenhum dos pares de músculos avaliados.

**Tabela 4-5 Valor médio das razões das variâncias dos sinais durante extensão e durante flexão e relação entre os dois valores para o paciente B02.**

	ECD/FSD	ECP/FLP	ECD/FPD
$a_{ext}$	0,12	1,94	0,59
$a_{flex}$	0,47	2,71	1,56
$Ra$	3,84	1,39	2,63
valor-p	0	0	0

### 4.7.3 Comparações entre desempenho e FMA de pacientes

Realizou-se uma análise procurando relacionar os resultados dos desempenhos dos classificadores para os diferentes pacientes, com os seus respectivos níveis de recuperação funcional, dados pela avaliação FMA. Na Figura 4.39 foram traçados os níveis médios das métricas de desempenho dos classificadores, ou seja, sensibilidade (amarelo), especificidade (verde) e acurácia (azul) para os sinais de cada paciente, os quais estão organizados em ordem decrescente segundo as respectivas notas FMA.



**Figura 4.39 - Métricas de desempenho dos classificadores: acurácia(azul), especificidade(verde) e sensibilidade (vermelho), em função das notas FMA de cada paciente.**

Os níveis de especificidade apresentam pequena diferença entre os diferentes pacientes. Observa-se que há uma certa tendência a que os níveis de acurácia e sensibilidade aumentem com o aumento das notas FMA, à exceção do paciente B07, que, apesar de ter baixa nota FMA, os respectivos sinais levaram a um alto desempenho dos classificadores.

## 5 Discussão

Este trabalho propôs um novo algoritmo para classificar movimentos básicos da mão (abertura, fechamento e relaxamento dos dedos da mão) com base nas razões das PSDs de diferentes músculos restritos a uma faixa de frequências específica para futura aplicação em tempo real. Empregando-se a razão entre duas PSDs, como característica para a classificação, foi possível utilizar uma técnica baseada em limiar estatístico, o teste F espectral (TFE).

A classificação propriamente dita dividiu-se em 3 partes, sendo que, na primeira procurou-se identificar intenção de movimento, relaxamento, utilizando-se o teste F espectral, com abordagem Neyman Pearson, com base nas estimativas de energia do trecho atual do sinal, dividido pelo trecho anterior ( $\phi_{y_1y_2}$ ). O TFE, neste caso, foi avaliado com níveis de significância de 1%, 2% e 5%, tendo o primeiro levado a um menor número de falsos positivos com um nível de sensibilidade satisfatório. Portanto, o nível de significância considerado para o teste com Neyman Pearson foi de 1%. Simulações em tempo real foram realizadas para analisar o comportamento desta razão de energias ao longo do tempo e para os diferentes músculos considerados, mostrando que  $\phi_{y_1y_2}$ , e, portanto, a energia do sinal, cresce rapidamente no início do movimento, mantendo-se aproximadamente constante até decrescer ao final do mesmo, durante o relaxamento da mão. Este padrão foi observado em todos os músculos coletados em voluntários do Grupo A, ou seja, com função motora considerada normal de membro superior. Porém, em alguns dos pacientes após AVE (Grupo B), em certos músculos, não foi possível identificar ou identificaram-se poucas ativações e desativações musculares com o método utilizado levando a baixos níveis de sensibilidade no classificador final. Neste trabalho, avaliou-se a acurácia somente do classificador final. Avaliações do desempenho deste método de identificação de ativação e desativação muscular de forma isolada devem ser realizadas, e, uma vez confirmado seu alto desempenho, pode ser utilizado de forma independente em outras aplicações.

Na segunda parte da classificação, utilizou-se a relação entre as energias de dois músculos,  $\phi_{yx}$ , para classificação inicial entre extensão e flexão. O comportamento de  $\phi_{yx}$ , quando avaliado ao longo do sinal durante movimentos repetidos de extensão-relaxamento e flexão-relaxamento, permitiu observar que existe uma alta correspondência entre esta razão e os movimentos realizados, tanto de extensão quanto de flexão dos dedos. Em geral, para a extensão, em normais, estes valores mantêm níveis mais baixos



durante o período em que a mão fica relaxada e níveis mais altos durante o movimento. O contrário ocorre durante movimentos de flexão. Este comportamento é esperado, visto que, em um movimento, os músculos agonistas possuem ativação muscular maior que os antagonistas. Em normais, este padrão não ocorreu apenas para o par PID-FPD.

Este tipo de classificador necessita de um parâmetro inicial para determinação do limiar. Este parâmetro é estimado a partir de sinais registrados em uma seção específica, denominada seção de treinamento. Neste trabalho, o treinamento consistiu de 10 movimentos de flexão e 10 de extensão, resultando nas acurácias finais apresentadas nos gráficos das Figuras 4.20 a 4.24. Não foram, porém, simulados os sinais a partir de números menores ou maiores de movimentos, de forma que o número mínimo de movimentos para alcançar uma dada acurácia não foi teoricamente determinado. Este estudo deverá ser feito em trabalhos futuros.

Adicionalmente, a etapa de classificação inicial entre extensão e flexão foi simulada utilizando-se os classificadores LDA e SVM para comparação. Em geral, as técnicas quando aplicadas não levaram a diferenças significativas no desempenho do classificador final, segundo as métricas utilizadas (sensibilidade, especificidade e acurácia).

Simulações utilizando os classificadores LDA e SVM foram realizadas adicionalmente com dois conjuntos de 4 músculos (ECD- PID-FSD- FPD e ECD- ECP- FLP- FSD) e também com todos os 6 músculos (resultados não apresentados). Porém, as métricas para tais classificadores não indicaram melhora em relação aos classificadores que utilizaram apenas dois músculos diretamente relacionados aos dois movimentos (flexão e extensão). Porém, para classificar um maior número de movimentos será necessário considerar outros músculos relacionados aos movimentos. Assim, no futuro uma técnica com base no TFE bayesiano para mais variáveis deve ser desenvolvida.

Em relação ao desempenho dos classificadores, pôde-se observar através dos valores médios das métricas de sensibilidade, especificidade e acurácia que os classificadores que utilizaram os canais PID e FPD tiveram um menor desempenho. Isto pode ser explicado pelo fato de que este não representa um par de músculos explicitamente antagonistas. Além disso, o PID não é um músculo diretamente relacionado aos movimentos que pretende-se classificar. Ele pode ser ativado de forma similar tanto na extensão quanto na flexão, não sendo portanto informativo para a classificação entre estes dois movimentos.

Apesar dos valores de  $\phi_{yx}$  nos sinais dos voluntários do Grupo B não seguirem um padrão tão bem definido quanto o dos voluntários do Grupo A, os classificadores tiveram desempenhos aceitáveis, tendo a acurácia média ficado acima de 70% em 4 dos 7 pacientes avaliados. Em 3 dos 4 pacientes com bons resultados houve avaliações com notas altas (maiores que 60) com o FMA (o quarto indivíduo foi avaliado com apenas 27/66), o que sugere que quanto mais próximos de um padrão normal, melhor será o desempenho do classificador. Um dos fatores que dificultam a classificação em sinais de EMG de pacientes é que há uma atividade involuntária, a qual representa ruído neste caso. Porém, se esta atividade for alta dentro da banda de frequências considerada para as estimativas das energias, esta poderá ser confundida com atividade voluntária, ou, em outros casos pode mascarar o sinal de EMG resultante de contração muscular voluntária. Este problema deve ser contornado restringindo-se as bandas avaliadas àquelas que concentram maiores níveis de atividade voluntária em cada indivíduo. Além disso, este estudo propôs a aquisição de sinais de 6 músculos, sendo que apenas 2 são usados. Essa redundância, na prática, permite que se utilize o melhor par de canais, isto é, aquele que tiver menor probabilidade de erro, o qual poderá ser calculado com base nas estimativas do parâmetro  $a$  nos diferentes movimentos a partir de uma seção de treinamento. Em resumo, melhores desempenhos dos classificadores quando aplicados a pacientes após-AVE poderiam ser obtidos ao selecionar pares de músculos que forneçam a probabilidade de erro mais baixa e faixas de frequências estimadas individualmente, com base nos sinais da seção II. Caso ainda assim, o desempenho não seja satisfatório, torna-se necessário realizar um estudo aprofundado de cada caso para a determinação de características individualizadas que permitam classificar os diferentes movimentos, visto que há baixa uniformidade do perfil clínico dos diferentes sujeitos após AVE.

Estimativas das razões entre os fatores de escalonamento  $a$ , os quais foram registrados a partir da seção II, podem ser indicadores de nível de co-contracção, e, neste caso, poderiam ser úteis para a avaliação do estágio de recuperação do paciente ao longo do tratamento. Os valores de  $a$  estimados para os indivíduos do Grupo A apresentaram valores quase sempre superiores a 1 tanto na flexão quanto na extensão dos dedos, indicando que os sinais provavelmente não possuem mesma proporção quando adquiridos. Isto pode ser explicado pelo fato de os músculos extensores serem, em geral, mais superficiais, sofrendo, portanto, menor influência do volume condutor. O índice  $R_a$ , calculado a partir dos fatores de escalonamento forneceu uma medida mais confiável para comparação entre diferentes sujeitos ou para o mesmo sujeito entre diferentes coletas de

sinais. Foi possível observar, por exemplo que os valores de  $R_a$  foram predominantemente muito menores que 1 para voluntários do Grupo A, apontando para baixos níveis de co-contracção, e foram maiores que 1 para alguns pares de músculos de voluntários do Grupo B, o qual aponta para altos níveis de co-contracção. A partir dos testes estatísticos realizados tomando como base as distribuições ajustadas por meio dos dados dos voluntários do Grupo A, mostrou-se que os valores de  $R_a$  correspondentes a 10 dos 21 pares de músculos testados não estão dentro da normalidade. Sendo  $R_a$  uma estimativa de co-contracção, isto indica que em boa parte dos casos, em pacientes após AVE, os níveis de co-contracção dos músculos relacionados à extensão e à flexão dos dedos são mais altos que em indivíduos normais. Este resultado concordou com uma das conclusões do trabalho de Chae e colaboradores (2002), em que foi experimentalmente demonstrada diferença significativa entre os níveis de co-contracção entre membros paréticos e não paréticos. Porém, dentro do grupo de indivíduos com membro parético do presente estudo, não foi possível estabelecer uma relação entre os níveis de prejuízo motor dos mesmos (medidos com o FMA) e os níveis de co-contracção estimados para 2 dos 7 pacientes. Um destes pacientes teve nota baixa na avaliação FMA ( $B07 = 27$ ) mas obteve baixos níveis de co-contracção ( $R_a \leq 1$ ). Em contrapartida, outro paciente também com nota baixa segundo o FMA ( $B02$ ), obteve níveis de co-contracção muito altos para os 3 músculos avaliados. Porém, devido à pequena quantidade de dados de pacientes disponíveis no presente estudo, é necessária uma investigação mais aprofundada, incluindo-se maior número de sujeitos de pesquisa com membro parético, além de maiores informações sobre estado do paciente, como, por exemplo, o nível de espasticidade, os quais possibilitariam explicar melhor as diferenças encontradas.

Em trabalhos futuros deve-se incluir o estudo da razão denotada neste trabalho por  $\phi_{yx}$  como estimador da velocidade do movimento. Este parâmetro poderia ser utilizado no controle proporcional, abordagem ainda pouco explorada, embora bastante promissora, para o controle de dispositivos, como próteses, baseados em EMG (Jiang et al. 2012).

## 6 Conclusão

Este trabalho propôs a utilização de uma nova característica para a classificação de sinais de EMG, que é a razão entre as energias de dois trechos de sinais dentro de uma banda de frequência. Tal característica, é ajustada a uma distribuição F, de forma que seja possível estabelecer limiares com embasamento estatístico. Considerando-se todas as etapas, até a classificação final, o método empregado mostrou-se adequado para a classificação de movimentos de abertura e fechamento da mão com base em sinais de EMG de indivíduos com função motora normal de membro superior, tendo como resultado, uma acurácia média de aproximadamente 90%. Já para pacientes com hemiparesia de membro superior após AVE, alguns ajustes devem ser realizados no método, como, por exemplo, a restrição da banda de frequência considerada para a estimação das características, específica de cada indivíduo, afim de se obter maiores desempenhos na classificação dos movimentos. As características que dificultam a classificação em membros paréticos não são, porém, encontradas em outras categorias de indivíduos que utilizam tecnologias assistivas, como os amputados. Portanto, sugere-se que a aplicação desta técnica para o controle por EMG de próteses por estes indivíduos deverá gerar bons resultados.

Os resultados relativos ao parâmetro  $Ra$  sugeriram que este possa ser um indicador de diferenças de recrutamento motor entre membros não paréticos e membros paréticos. Estudos mais focados nesta questão e incluindo-se maior número de sujeitos com membro parético deverão ser realizados afim de avaliar a hipótese de que  $Ra$  possa ainda indicar o estágio funcional muscular de pacientes, o que, se confirmado, será muito útil na avaliação de programas de reabilitação após AVE.

Os resultados deste estudo foram obtidos por meio de simulações a partir de sinais previamente coletados. A aplicação prática do algoritmo controlando um dispositivo ou software deverá ser realizada de forma que se possa avaliar com maior precisão a sua usabilidade.

## 7 Bibliografia

- Ashford, Stephen, Mike Slade, Fabienne Malaprade, e Lynne Turner-Stokes. 2008. “Evaluation of Functional Outcome Measures for the Hemiparetic Upper Limb: A Systematic Review”. *Journal of Rehabilitation Medicine* 40 (10): 787–95. doi:10.2340/16501977-0276.
- Atoufi, Bahareh, Ernest Nlandu Kamavuako, Bernard Hudgins, e Kevin Englehart. 2014. “Toward proportional control of myoelectric prostheses with muscle synergies”. *Journal of Medical and Biological Engineering* 34 (5): 475–81.
- Branco, Raquel. 2015. “A dominância cortical no potencial pré-motor em tarefa voluntária unilateral”. Universidade Federal do Rio de Janeiro. Rio de Janeiro, Brasil.
- Brol, AM, e NMS Magagnin. 2010. “Aplicação da combinação da terapia de restrição e indução do movimento e toxina botulínica tipo A em uma paciente hemiparética crônica pós acidente vascular encefálico: um estudo de caso”. Universidade de Passo Fundo -UFP.
- Chae, John, Guang Yang, Byung Kyu Park, e Ihab Labatia. 2002. “Muscle Weakness and Cocontraction in Upper Limb Hemiparesis: Relationship to Motor Impairment and Physical Disability”. *Neurorehabilitation and Neural Repair* 16 (3): 241–48.
- Chowdhury, Rubana H., Mamun B. I. Reaz, Mohd Alauddin Bin Mohd Ali, Ashrif A. A. Bakar, Kalaivani Chellappan, e Tae G. Chang. 2013. “Surface Electromyography Signal Processing and Classification Techniques”. *Sensors* 13 (9): 12431–66. doi:10.3390/s130912431.
- Cipriani, Christian, Franco Zaccone, Silvestro Micera, e M. Chiara Carrozza. 2008. “On the shared control of an EMG-controlled prosthetic hand: analysis of user–prosthesis interaction”. *IEEE Transactions on Robotics* 24 (1): 170–84.
- de Medeiros, Candice Simões Pimenta, Sabrina Gabrielle Gomes Fernandes, Johnnatas Mikael Lopes, Enio Walker Azevedo Cacho, e Roberta de Oliveira Cacho. 2014. “Efeito da terapia de espelho por meio de atividades funcionais e padrões motores na função do membro superior pós-acidente vascular encefálico”. *Fisioterapia e Pesquisa* 21 (3): 264–70.
- Dipietro, Laura, Mark Ferraro, Jerome Joseph Palazzolo, Hermano Igo Krebs, Bruce T. Volpe, e Neville Hogan. 2005. “Customized Interactive Robotic Treatment for Stroke: EMG-Triggered Therapy”. *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society* 13 (3): 325–34. doi:10.1109/TNSRE.2005.850423.
- Duda, Richard O., Peter E. Hart, e David G. Stork. 2012. *Pattern classification*. John Wiley & Sons.
- Eriksson, Jon, Maja J. Mataric, e C. Winstein. 2005. “Hands-off assistive robotics for post-stroke arm rehabilitation”. In *Proc. IEEE International Conference on Rehabilitation Robotics (ICORR'05)*, 21–24.
- Gibson, Alison E., Mark R. Ison, e Panagiotis Artemiadis. 2013. “User-Independent Hand Motion Classification With Electromyography”, outubro, V002T26A002. doi:10.1115/DSCC2013-3832.
- Heijden, Ferdinand van der, Robert Duin, Dick de Ridder, e David M. J. Tax. 2004. *Classification, Parameter Estimation and State Estimation: An Engineering Approach Using MATLAB*. 1 edition. Chichester, West Sussex, Eng. ; Hoboken, NJ: Wiley.

- “i-limb ultra | Touch Bionics”. 2016. Acessado julho 26.  
<http://www.touchbionics.com/products/active-prostheses/i-limb-ultra>.
- Jiang, Ning, Strahinja Dosen, Klaus-Robert Müller, e Dario Farina. 2012. “Myoelectric control of artificial limbs—Is there a need to change focus”. *IEEE Signal Process. Mag* 29 (5): 152–150.
- Johnson, Ernest W. 1980. “Practical electromyography”.
- Kay, Steve M. 1998. *Fundamentals of Statistical Signal Processing, Volume II: Detection Theory*. 1 edition. Englewood Cliffs, N.J: Prentice Hall.
- Khezri, M., e M. Jahed. 2007. “A Novel Approach to Recognize Hand Movements Via sEMG Patterns”. In *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 4907–10.  
 doi:10.1109/IEMBS.2007.4353440.
- Khezri, Mahdi, e Mehran Jahed. 2007. “Real-time intelligent pattern recognition algorithm for surface EMG signals”. *Biomedical engineering online* 6 (1): 1.
- Konrad, Peter. 2005. “The abc of emg”. *A practical introduction to kinesiological electromyography* 1.
- Kwakkel, Gert, Boudewijn J. Kollen, e Hermano I. Krebs. 2007. “Effects of Robot-Assisted Therapy on Upper Limb Recovery After Stroke: A Systematic Review”. *Neurorehabilitation and Neural Repair*, setembro.  
 doi:10.1177/1545968307305457.
- L. Johnson, Norman, Samuel Kotz, e N. Balakrishnan. 1995. *Continuous Univariate Distributions, Vol. 2*. 2 edition. New York: Wiley-Interscience.
- Li, Xiaoyan, Ping Zhou, e Alexander S. Aruin. 2007. “Teager–Kaiser Energy Operation of Surface EMG Improves Muscle Activity Onset Detection”. *Annals of Biomedical Engineering* 35 (9): 1532–38. doi:10.1007/s10439-007-9320-z.
- Lotte, Fabien, Marco Congedo, Anatole Lécuyer, Fabrice Lamarche, e Bruno Arnaldi. 2007. “A review of classification algorithms for EEG-based brain–computer interfaces”. *Journal of neural engineering* 4.
- Merletti, Roberto, e Philip A. Parker. 2004. *Electromyography: Physiology, Engineering, and Non-Invasive Applications*. John Wiley & Sons.
- Naik, Ganesh R., e Dinesh K. Kumar. 2012. “Identification of Hand and Finger Movements Using Multi Run ICA of Surface Electromyogram”. *Journal of Medical Systems* 36 (2): 841–51. doi:10.1007/s10916-010-9548-2.
- Naik, Ganesh R., Dinesh Kant Kumar, Vijay Pal Singh, e Marimuthu Palaniswami. 2006. “Hand Gestures for HCI Using ICA of EMG”. In *Proceedings of the HCSNet Workshop on Use of Vision in Human-computer Interaction - Volume 56*, 67–72. VisHCI '06. Darlinghurst, Australia, Australia: Australian Computer Society, Inc.
- Ohn, Suk Hooh, Woo-Kyoung Yoo, Deog Young Kim, Seunggho Ahn, Bora Jung, Ikjun Choi, Nam Jae Lee, e Kwang-Ik Jung. 2013. “Measurement of synergy and spasticity during functional movement of the post-stroke hemiplegic upper limb”. *Journal of Electromyography and Kinesiology* 23 (2): 501–7.  
 doi:10.1016/j.jelekin.2012.10.001.
- Raez, M.B.I., M.S. Hussain, e F. Mohd-Yasin. 2006. “Techniques of EMG signal analysis: detection, processing, classification and applications”. *Biological Procedures Online* 8 (março): 11–35. doi:10.1251/bpo115.
- Sá, Antonio Mauricio F. L. Miranda de, Mauricio Cagy, Vladimir V. Lazarev, e Antonio Fernando C. Infantosi. 2006. “Spectral F-Test power evaluation in the EEG during intermittent photic stimulation”. *Arquivos de Neuro-Psiquiatria* 64 (2A): 228–32. doi:10.1590/S0004-282X2006000200011.

- Sá, Antonio Mauricio F. L. Miranda de, Humberto C. Thiengo, Ingrid S. Antunes, e David M. Simpson. 2009. “Assessing Time- and Phase-Locked Changes in the EEG during Sensory Stimulation by Means of Spectral Techniques”. In *World Congress on Medical Physics and Biomedical Engineering, September 7 - 12, 2009, Munich, Germany*, 2136–39. IFMBE Proceedings, 25/4. Springer Berlin Heidelberg.
- Santos, Sibeles. 2011. “Detecção de início de ativação muscular no eletromiograma com operador teager-kaiser”. Dissertação de Mestrado, Rio de Janeiro: Universidade Federal do Rio de Janeiro.
- Santos-Couto-Paz, Clarissa C., Luci F. Teixeira-Salmela, e Carlos J. Tierra-Criollo. 2013. “The Addition of Functional Task-Oriented Mental Practice to Conventional Physical Therapy Improves Motor Skills in Daily Functions after Stroke”. *Brazilian Journal of Physical Therapy* 17 (6): 564–71. doi:10.1590/S1413-35552012005000123.
- Scheme, Erik, e Kevin Englehart. 2013. “Training Strategies for Mitigating the Effect of Proportional Control on Classification in Pattern Recognition Based Myoelectric Control”. *Journal of prosthetics and orthotics : JPO* 25 (2): 76–83. doi:10.1097/JPO.0b013e318289950b.
- Scott, R. N., e D. S. Dorcas. 1966. “A three-state myoelectric control system”. *Med Biol Eng* 4: 367.
- Simpson, David M., Carlos J. Tierra-Criollo, Renato T. Leite, Eduardo J. B. Zayen, e Antonio F. C. Infantosi. 2000. “Objective Response Detection in an Electroencephalogram During Somatosensory Stimulation”. *Annals of Biomedical Engineering* 28 (6): 691–98. doi:10.1114/1.1305530.
- “Sistemas protéticos de mãos mioelétricas — Ottobock”. 2016. Acessado julho 26. <http://www.ottobock.com.br/prosthetics/membros-superiores/visao-geral-das-solucoes/sistemas-mioeletricos/>.
- Teo, Wei-Peng, e Effie Chew. 2014. “Is Motor-Imagery Brain-Computer Interface Feasible in Stroke Rehabilitation?” *PM & R: The Journal of Injury, Function, and Rehabilitation* 6 (8): 723–28. doi:10.1016/j.pmrj.2014.01.006.
- Tierra-Criollo, Carlos Julio. 2001. “Monitorização objetiva da resposta à estimulação somatosensitiva utilizando parâmetros espectrais”. Rio de Janeiro - Brasil: Universidade Federal do Rio de Janeiro.
- “WHO | Stroke, Cerebrovascular accident”. 2014. *WHO*. Acessado novembro 1. [http://www.who.int/topics/cerebrovascular\\_accident/en/](http://www.who.int/topics/cerebrovascular_accident/en/).
- Zhang, Xu, Yun Li, Xiang Chen, Guanglin Li, William Zev Rymer, e Ping Zhou. 2013. “The Effect of Involuntary Motor Activity on Myoelectric Pattern Recognition: A Case Study with Chronic Stroke Patients”. *Journal of neural engineering* 10 (4). doi:10.1088/1741-2560/10/4/046015.
- Zhou, Ping, Nina L. Suresh, e William Z. Rymer. 2007. “Model Based Sensitivity Analysis of EMG–Force Relation with Respect to Motor Unit Properties: Applications to Muscle Paresis in Stroke”. *Annals of Biomedical Engineering* 35 (9): 1521–31. doi:10.1007/s10439-007-9329-3.

## 8 Apêndice A

### Padrão eletromiográfico dos movimentos de abertura e fechamento de mão

Grupo A

Grupo B

Data do Exame: \_\_\_\_/\_\_\_\_/\_\_\_\_

Sujeito: \_\_\_\_\_

Idade: \_\_\_\_\_

Contato: \_\_\_\_\_

Canhoto

Destro

Medicamentos no dia do exame:

\_\_\_\_\_

Experimentadores: \_\_\_\_\_

*Preencher somente caso o voluntário pertença ao Grupo B:*

Data do AVE: \_\_\_\_\_ Dimidio paretico: \_\_\_\_\_

Lateralidade manual antes da lesão: \_\_\_\_\_

**Posição do paciente:** sentado em uma cadeira confortável com o antebraço apoiado em posição pronada com ângulo de aproximadamente 90° na articulação do cotovelo. Deverão ser cumpridas as tarefas enumeradas abaixo com mínimo de 30s de intervalo entre as mesmas.

#### Protocolo:

1. Repouso (1min). Nome do arquivo: \_\_\_\_\_
2. Repouso-extensão. x10. Nome do arquivo: \_\_\_\_\_
3. Repouso-flexão. x10. Nome do arquivo: \_\_\_\_\_
4. Repouso-extensão. x10. Nome do arquivo: \_\_\_\_\_
5. Repouso-flexão. x10. Nome do arquivo: \_\_\_\_\_
6. Repouso-extensão. x10. Nome do arquivo: \_\_\_\_\_
7. Repouso-flexão. x10. Nome do arquivo: \_\_\_\_\_



<b>Canal</b>	<b>Músculo</b>	<b>Posição do eletrodo</b>	<b>MS Direito (cm)</b>	<b>MS esquerdo (cm)</b>
1	Acelerômetro			
2	Extensor Comum dos Dedos	Medida do epicôndilo lateral ao processo estilóide do rádio com eletrodo no terço proximal.		
3	Primeiro Interosseo Dorsal (FDI)	Medida 3 cm abaixo da base metacarpofalangiana.		
4	Extensor Curto do Polegar	Medida do epicôndilo lateral ao processo estilóide do rádio com eletrodo no terço distal.		
5	Flexor Superficial dos Dedos	Medida do processo ósseo do rádio à cabeça da ulna. Marcar linha média e posicionar o eletrodo na região mais medial.		
6	Flexor Profundo dos Dedos	Medida do epicôndilo medial à ulna. Posicionar o eletrodo no terço proximal.		
		Afastar 1cm da ulna para região medial.		
7	Flexor Longo do Polegar	Medida do epicôndilo lateral ao processo estilóide do rádio com eletrodo no terço distal.		
		Medida do processo ósseo do rádio à cabeça da ulna. Marcar linha média e posicionar o eletrodo na região mais lateral.		

## 9 Apêndice B

### Métricas de desempenho do classificador e co-contrações em pacientes (Grupo B)

#### 9.1 Voluntário B03

FMA: 64/66

Tabela 9-1 Métricas de desempenho dos classificadores simulados com os sinais do voluntário B03.

		TFE				LDA				SVM			
		ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD	ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD	ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD
<b>S</b>	Ex	0,32	0,00	0,82	0,14	0,90	0,00	0,92	0,89	0,00	0,00	0,92	0,92
	Fx	0,76	0,69	0,92	0,78	0,77	0,98	0,91	0,77	0,94	0,98	0,73	0,67
	Rx	0,80	0,90	0,89	0,91	0,94	0,93	0,97	0,93	0,80	0,93	0,97	0,97
<b>E</b>	Ex	0,98	0,97	0,97	0,98	0,97	1,00	0,97	0,97	1,00	1,00	0,96	0,96
	Fx	0,97	0,94	0,97	0,96	1,00	0,92	1,00	0,99	0,94	0,92	1,00	1,00
	Rx	0,95	0,91	0,95	0,93	0,94	0,94	0,95	0,93	0,96	0,94	0,96	0,93
<b>A</b>		0,80	0,73	0,88	0,78	0,89	0,79	0,92	0,88	0,77	0,79	0,90	0,88

Tabela 9-2 Valor médio das razões das variâncias dos sinais durante extensão e durante flexão e relação entre os dois valores para o paciente B03.

	ECD/FSD	ECP/FLP	ECD/FPD
$a_{ext}$	0,51	0,80	0,44
$a_{flex}$	4,27	2,80	2,93
$Ra$	8,31	3,49	6,62
valor-p	0 (rejeita H0)	0 (rejeita H0)	0 (rejeita H0)

## 9.2 Voluntário B04

FMA: 59/66

Tabela 9-3 Métricas de desempenho dos classificadores simulados com os sinais do voluntário B04.

		TFE				LDA				SVM			
		ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD	ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD	ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD
<b>S</b>	Ex	0,78	0,44	0,53	0,93	0,69	0,44	0,48	0,94	0,96	0,44	0,51	0,96
	Fx	0,84	0,95	0,12	0,98	0,85	0,86	0,20	0,95	0,48	0,87	0,20	0,72
	Rx	0,69	0,47	0,20	0,35	0,56	0,47	0,38	0,64	0,68	0,47	0,41	0,66
<b>E</b>	Ex	0,98	0,97	1,00	0,97	0,98	0,96	1,00	0,96	0,97	0,96	1,00	0,96
	Fx	0,96	0,96	1,00	0,93	0,96	0,97	0,95	0,97	0,99	0,97	0,97	1,00
	Rx	0,97	0,94	0,98	0,96	0,97	0,94	0,97	0,96	0,96	0,94	0,97	0,96
<b>A</b>		0,84	0,77	0,63	0,80	0,80	0,76	0,66	0,85	0,81	0,76	0,67	0,84

Tabela 9-4 Valor médio das razões das variâncias dos sinais durante extensão e durante flexão e relação entre os dois valores para o paciente B04.

	ECD/FSD	ECP/FLP	ECD/FPD
$a_{ext}$	32,86	0,04	8,71
$a_{flex}$	7,50	1,38	0,73
$Ra$	0,23	38,66	0,08
<b>valor-p</b>	0,92 (aceita H0)	0 (rejeita H0)	0,57 (aceita H0)

## 9.3 Voluntário B05

FMA:62/66

Tabela 9-5 Métricas de desempenho dos classificadores simulados com os sinais do voluntário B05.

		TFE				LDA				SVM			
		ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD	ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD	ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD
<b>S</b>	Ex	0,32	0,38	0,82	0,24	0,65	0,43	0,81	0,41	0,65	0,44	0,60	0,41
	Fx	0,88	0,89	0,80	0,90	0,80	0,88	0,81	0,90	0,88	0,89	0,81	0,90
	Rx	0,60	0,56	0,53	0,63	0,59	0,55	0,53	0,72	0,65	0,52	0,50	0,72
<b>E</b>	Ex	1,00	0,95	0,99	1,00	0,99	0,94	0,99	1,00	0,99	0,95	1,00	1,00
	Fx	0,94	0,95	0,99	0,94	0,99	0,96	0,99	0,97	0,98	0,95	0,98	0,97
	Rx	0,95	0,92	0,99	0,95	0,97	0,91	0,99	0,96	0,96	0,93	0,98	0,96
<b>A</b>		0,75	0,71	0,82	0,74	0,79	0,70	0,82	0,80	0,81	0,70	0,78	0,80

Tabela 9-6 Valor médio das razões das variâncias dos sinais durante extensão e durante flexão e relação entre os dois valores para o paciente B05.

	ECD/FSD	ECP/FLP	ECD/FPD
$a_{ext}$	28,20	4,50	33,74
$a_{flex}$	2,75	1,58	6,17
$Ra$	0,10	0,35	0,18
<b>valor-p</b>	0,74 (aceita H0)	0,79 (aceita H0)	0,88 (aceita H0)

## 9.4 Voluntário B06

FMA: 44/66

Tabela 9-7 Métricas de desempenho dos classificadores simulados com os sinais do voluntário B06.

		TFE			LDA			SVM					
		ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD	ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD	ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD
<b>S</b>	Ex	0,77	0,36	0,49	0,78	0,80	0,41	0,54	0,79	0,80	0,50	0,54	0,71
	Fx	0,72	0,56	0,28	0,41	0,38	0,63	0,31	0,56	0,38	0,63	0,37	0,57
	Rx	0,77	0,57	0,68	0,70	0,74	0,60	0,70	0,69	0,74	0,65	0,70	0,72
<b>E</b>	Ex	0,89	0,96	0,98	0,93	0,87	0,94	0,99	0,90	0,86	0,93	0,98	0,90
	Fx	0,98	0,95	0,95	0,96	1,00	0,95	0,91	0,97	1,00	0,97	0,93	0,97
	Rx	0,85	0,89	0,88	0,86	0,84	0,89	0,88	0,87	0,84	0,89	0,87	0,87
<b>A</b>		0,72	0,64	0,68	0,68	0,67	0,65	0,67	0,69	0,67	0,68	0,68	0,69

Tabela 9-8 Valor médio das razões das variâncias dos sinais durante extensão e durante flexão e relação entre os dois valores para o paciente B06.

	ECD/FSD	ECP/FLP	ECD/FPD
$a_{ext}$	47,68	1,35	28,51
$a_{flex}$	10,19	2,68	14,48
$Ra$	0,21	1,98	0,51
<b>valor-p</b>	0,26 (aceita H0)	0 (rejeita H0)	0,23 (aceita H0)

## 9.5 Voluntário B07

FMA: 27/66

Tabela 9-9 Métricas de desempenho dos classificadores simulados com os sinais do voluntário B07.

		TFE			LDA			SVM					
		ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD	ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD	ECD/ FSD	PID/ FPD	ECP/ FCP	ECD/ FPD
<b>S</b>	Ex	0,11	0,95	0,98	0,51	0,99	0,96	0,98	1,00	0,98	0,94	0,98	1,00
	Fx	0,51	0,93	0,93	0,89	0,59	0,39	0,93	0,55	0,66	0,68	0,93	0,68
	Rx	0,63	0,82	0,44	0,68	0,64	0,73	0,44	0,56	0,59	0,72	0,44	0,64
<b>E</b>	Ex	0,98	0,99	0,99	0,98	0,97	0,96	0,99	0,97	0,98	0,96	0,99	0,97
	Fx	0,96	0,99	1,00	0,98	0,99	0,99	1,00	1,00	0,99	0,99	1,00	0,99
	Rx	0,98	0,97	0,98	0,97	0,98	0,97	0,98	0,98	0,98	0,96	0,98	0,97
<b>A</b>		0,70	0,92	0,84	0,82	0,84	0,82	0,84	0,81	0,83	0,85	0,84	0,84

Tabela 9-10 Valor médio das razões das variâncias dos sinais durante extensão e durante flexão e relação entre os dois valores para o paciente B07.

	ECD/FSD	ECP/FLP	ECD/FPD
$a_{ext}$	21,87	3,06	16,60
$a_{flex}$	12,06	0,48	3,53
$Ra$	0,55	0,16	0,21
<b>valor-p</b>	0,25 (aceita H0)	0,68 (aceita H0)	0,98 (aceita H0)

