

**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA MECÂNICA**

**AVALIAÇÃO DOS EFEITOS DE COMBINAÇÕES  
FUNÇÃO-CUSTO/ALGORITMO-DE-BUSCA SOBRE O  
ERRO DE CLASSIFICAÇÃO DOS SISTEMAS DE  
CONTROLE MIOELÉTRICO COM SINTONIZAÇÃO IPCA**

**GUILLERMO ALBERTO CAMACHO MUÑOZ**

**ORIENTADOR: CARLOS HUMBERTO LLANOS  
COORIENTADOR: PEDRO DE AZEVEDO BERGER**

**DISSERTAÇÃO DE MESTRADO EM SISTEMAS MECATRÔNICOS**

**PUBLICAÇÃO: ENM.DM- 47A/12**

**BRASÍLIA/DF: MARÇO – 2012**

**UNIVERSIDADE DE BRASÍLIA**  
**FACULDADE DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA MECÂNICA**

**AVALIAÇÃO DOS EFEITOS DE COMBINAÇÕES FUNÇÃO-  
CUSTO/ALGORITMO-DE-BUSCA SOBRE O ERRO DE  
CLASSIFICAÇÃO DOS SISTEMAS DE CONTROLE MIOELÉTRICO  
COM SINTONIZAÇÃO IPCA**

**GUILLERMO ALBERTO CAMACHO MUÑOZ**

**DISSERTAÇÃO SUBMETIDA AO DEPARTAMENTO DE  
ENGENHARIA MECÂNICA DA FACULDADE DE TECNOLOGIA  
DA UNIVERSIDADE DE BRASÍLIA COMO PARTE DOS  
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE  
MESTRE EM SISTEMAS MECATRÔNICOS.**

**APROVADA POR:**

---

**Prof. Carlos Humberto Llanos Quintero, Dr (ENM-UnB)**  
**(Orientador)**

---

**Prof. Pedro de Azevedo Berger, Dr (CIC-UnB)**  
**(Co-Orientador)**

---

**Prof. Adson Ferreira da Rocha, PhD (ENE-UnB)**  
**(Examinador Externo)**

---

**Prof. Cristiano Jacques Miosso Rodrigues Mendes, PhD (FGA-UnB)**  
**(Examinador Externo)**

**BRASÍLIA/DF, 02 DE MARÇO DE 2012**

## FICHA CATALOGRÁFICA

CAMACHO M., GUILLERMO ALBERTO

Avaliação dos efeitos de combinações Função-Custo/Algoritmo-de-Busca sobre o erro de classificação dos Sistemas de Controle Mioelétrico com sintonização iPCA [Distrito Federal] 2012.

xvii, 115p., 210 x 297 mm (ENM/FT/UnB, Mestre, Sistemas Mecatrônicos, 2012).

Dissertação de Mestrado – Universidade de Brasília. Faculdade de Tecnologia.

Departamento de Engenharia Mecânica.

1. Eletromiografia

2. Transformação PCA

3. Sistemas de Controle mioelétrico

4. Algoritmos bio-inspirados

I. ENM/FT/UnB

II. Título (série)

## REFERÊNCIA BIBLIOGRÁFICA

CAMACHO M., G. A. (2012). Avaliação dos efeitos de combinações Função-Custo/Algoritmo-de-Busca sobre o erro de classificação dos Sistemas de Controle Mioelétrico com sintonização iPCA. Dissertação de Mestrado em Sistemas Mecatrônicos, Departamento de Engenharia Mecânica, Publicação ENM.DM-47A/12, Universidade de Brasília, Brasília, DF, 115p.

## CESSÃO DE DIREITOS

AUTOR: Guillermo Alberto Camacho Muñoz.

TÍTULO: Avaliação dos efeitos de combinações Função-Custo/Algoritmo-de-Busca sobre o erro de classificação dos Sistemas de Controle Mioelétrico com sintonização iPCA.

GRAU: Mestre

ANO: 2012

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa dissertação de mestrado pode ser reproduzida sem autorização por escrito do autor.

---

Guillermo Alberto Camacho Muñoz  
SQN 409, Bloco H, Apto 304.  
70857080 Brasília– DF – Brasil.

## AGRADECIMENTOS

Expresso minha gratidão a todas as pessoas que converteram este tempo de mestrado em uma experiência tão integral e engrandecedora:

A Deus meu guia, quem me trouxe até aqui, esteve sempre no meu lado me indicando os caminhos e me protegendo dos perigos.

A minha família, meus pais: José e Rubiela, suas bênçãos, seu amor e carinho me mantiveram em equilíbrio cada um dos dias que levou este processo. Meus irmãos: Rosita, Darío e Fernando, seus conselhos, sua confiança excessiva em mim e seu apoio incondicional alimentaram meu espírito e me permitiram sobrelevar momentos intensos de saudade.

Aos meus amigos: Temporário IV, Diego, Juan Pablo, Camilo, Alejandro, Daniel, Diana, Liliana, Alex, Sarita, ... converteram-se numa família para mim, jamais esperei receber tão grande e incondicional apoio de pessoas que meses atrás eram uns desconhecidos.

A Diana Jimena e Gloria Mesa, responsáveis por grande parte deste logro pessoal e profissional.

Aos meus orientadores Prof. Carlos Humberto Llanos, Prof. Pedro de Azevedo Berger, pelas diretrizes seguras, supervisão, confiança e oportunidade que me concederam para o desenvolvimento desta pesquisa e por todo o apoio prestado durante estes meses.

Aos meus professores, e a todos os membros do grupo LASER-GRACO, que com sua ajuda, sugestões e estímulos tornaram possível este trabalho.

Ao grupo de Automática Industrial da *Universidad del Cauca* quem despertou meu interesse por trabalhar nesta empolgante e desafiante área que é o processamento dos sinais eletromiográficos.

A CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pelo apoio financeiro deste trabalho.

## RESUMO

### AVALIAÇÃO DOS EFEITOS DE COMBINAÇÕES FUNÇÃO-CUSTO/ALGORITMO-DE-BUSCA SOBRE O ERRO DE CLASSIFICAÇÃO DOS SISTEMAS DE CONTROLE MIOELÉTRICO COM SINTONIZAÇÃO IPCA

O sistema de controle mioelétrico classifica os movimentos executados por uma pessoa, realizando o processamento do sinal eletromiográfico (EMG) que acompanha cada movimento. A abordagem mais comum para resolver esses sistemas de classificação é a baseada em reconhecimento de padrões. Recentemente foi proposto o sistema de controle mioelétrico com sintonização do tipo análise individual dos componentes principais (iPCA). Essa proposta consegue superar os desempenhos de classificação reportados na literatura de classificação de movimentos da mão. A proposta mistura três componentes: (a) um sistema de aquisição de dados com alto conteúdo de *crosstalk* muscular, (b) uma etapa de sintonização e (c) um sistema de reconhecimento de padrões. A configuração da etapa de sintonização envolve uma rotina de otimização composta por dois processos: *função custo* e *algoritmo de busca*. Nosso trabalho explora a rotina de otimização tendo como objetivo geral a determinação das relações existentes entre combinações do par função custo/algoritmo de busca e o desempenho de classificação dos sistemas de controle mioelétrico com sintonização iPCA. As combinações consideradas incluem quatro alternativas de algoritmo de busca (seleção sequencial, SFS; seleção sequencial flutuante, SFFS; otimização por enxame de partículas, PSO; e colônias artificiais de abelhas, ABC) e duas alternativas de função custo (erro de classificação, fator de correlação).

A etapa experimental do nosso trabalho foi desenvolvida utilizando uma base de dados de sinais EMG fornecida pelo Instituto de Reabilitação de Chicago. As classes nesta base de dados correspondem a 11 movimentos da mão e 10 usuários sem amputação. A classificação desses dados foi feita utilizando um esquema de sintonização iPCA seguido de um sistema de controle mioelétrico configurado com extração de características baseadas nos coeficientes de um modelo auto-regressivo de ordem seis (AR6), redução de dimensionalidade baseada na análise discriminativa linear sem correlação (ULDA) e classificador de análise discriminativa linear (LDA). Durante o processo de sintonização iPCA foram avaliadas oito alternativas para resolver a rotina de otimização, uma por cada combinação função custo e algoritmo de busca. Os resultados permitiram comparar os tempos de busca e a aptidão das soluções atingidas com cada alternativa. Aliás, foram

comparados os desempenhos de classificação associados com cada solução. Os sinais EMG foram processados utilizando uma arquitetura de simulação codificada especificamente para resolver as necessidades do nosso projeto. O simulador desenvolvido pode ser utilizado em pesquisas futuras relacionadas com a análise dos efeitos de outras etapas do sistema de controle sobre o erro de classificação.

Os resultados de simulação sugerem que: (a) não foi observada evidência estatística suficiente, para indicar a dependência entre os algoritmos de busca e o erro de classificação do sistema de controle ( $p < 0.01$ ). Este comportamento foi concluído para um conjunto específico de parâmetros dos algoritmos de busca, é possível que o uso de outros parâmetros leve a outros comportamentos. (b) Foi observada evidência estatística significativa para sugerir a dependência entre a função custo e o desempenho de classificação do sistema de controle ( $p < 0.02$ ). Resultados complementares permitiram (a) verificar a superioridade de desempenho do sistema de controle mioelétrico com sintonização iPCA sobre o sistema convencional e (b) identificar uma vantagem prática no uso do algoritmo PSO sobre as outras alternativas avaliadas, esta vantagem esteve relacionada com o tempo de busca das soluções ótimas.

## ABSTRACT

### EVALUATION OF THE INFLUENCE OF COST-FUNCTION/SEARCH-ALGORITHM COMBINATIONS ON THE CLASSIFICATION PERFORMANCE OF MYOELECTRIC CONTROL SYSTEMS WITH IPCA TUNING

Myoelectric control system classifies human contractions through signal processing of the myoelectric (MES) potentials generated from the muscle motions. These systems widely employ the pattern-recognition approach. Recently, it was proposed a myoelectric control system with individual principal component analysis tuning (iPCA). This proposal outperforms the reported classifications performances in the literature of hand movement classification by mixing three components: an acquisition system with high muscular *crosstalk* level, a tuning stage, and a pattern recognition system. The configuration of the iPCA tuning stage involves an optimization routine composed by two processes: *cost function* and *search algorithm*. The general objective of our project is to find the relations among cost-function/search-algorithm combinations and classification performance of myoelectric control systems with iPCA. The considered combinations include four search algorithm (sequential forward selection, SFS; sequential floating forward selection, SFFS; particle swarm optimization, PSO; and artificial bee colony, ABC) and two cost functions (classification error and correlation factor).

The experimental stage was executed with a MES data base provided by the Rehabilitation Institute of Chicago. The movements in the data base correspond to 11 motion classes of the hand and 10 users without amputation. The classification of these signals was accomplished using an iPCA tuning stage followed by a conventional myoelectric control system configured with sixth order autoregressive model feature extraction (AR6), uncorrelated linear discriminant analysis dimensionality reduction (ULDA) and linear discriminant analysis classifier (LDA). To solve the optimization routine inside the tuning process, eight combinations of cost-function/search algorithm were used. The results were used to compare the search time and fitness of the optimal solutions computed with each combination. The classification performance associated with each combination was analyzed too. The MES signals were processed with a simulator built specifically to our requirements. This simulator can be used to analyze effects of other processing stages over the classification error.

The simulation results suggest the following: (a) it was not found sufficient statistical evidence, showing the dependence between the search algorithm and the classification error ( $p < 0.01$ ). This behavior was observed under experiments that used a specific set of parameters for the search algorithms. It is possible that other configuration in these parameters lead to different behaviors. (b) It was found statistical evidence indicating the dependence between the cost function and the classification error ( $p < 0.02$ ). Additionally, the results: (a) verify the performance superiority of iPCA tuning systems over conventional ones, and (b) suggest an advantage of the PSO algorithm over the other ones regard to the execution time.

## RESUMEN

### EVALUACIÓN DE EFECTOS DE COMBINACIONES FUNCIÓN-COSTO/ALGORITMOS-DE-BUSCA SOBRE EL ERROR DE CLASIFICACIÓN DE LOS SISTEMAS DE CONTROL MIOELÉCTRICO CON SINTONIZACIÓN IPCA

Un sistema de control mioeléctrico clasifica los movimientos ejecutados por una persona, realizando procesamiento sobre las señales electromiográficas (EMG) que acompañan cada movimiento. El enfoque más común para solucionar la clasificación en este tipo de sistemas utiliza conceptos relacionados con el área de reconocimiento de patrones. Recientemente, fue propuesto un sistema de control mioeléctrico con sintonización basada en análisis individual de los componentes principales (iPCA). Esta propuesta superó los desempeños de clasificación reportados en la literatura de clasificación de movimientos de la mano. La propuesta combina tres componentes: (a) un sistema de adquisición de datos con alto contenido de *crosstalk* muscular, (b) una etapa de sintonización y (c) un sistema de reconocimiento de patrones. La configuración de la etapa de sintonización utiliza una rutina de optimización compuesta por dos procesos: *función costo* y *algoritmo de búsqueda*. Nuestro trabajo explora la rutina de optimización, estableciendo como objetivo general, la determinación de las relaciones existentes entre combinaciones de la pareja función-costo/algoritmo-de-búsqueda y el desempeño de clasificación de los sistemas de control mioeléctrico con sintonización iPCA. Las combinaciones consideradas incluyen cuatro alternativas de algoritmo de búsqueda (selección secuencial, SFS; selección secuencial flotante, SFFS; optimización por enjambre de partículas, PSO; e colonias artificiales de abejas, ABC) y dos alternativas de función costo (erro de classificação, fator de correlação).

La etapa experimental de nuestro trabajo utilizó una base de datos de señales EMG proporcionada por el Instituto de Rehabilitación de Chicago. Las clases en esta base de datos correspondían con 11 movimientos de la mano y 10 usuarios sin amputación. La clasificación de las señales EMG fue realizada utilizando un esquema de sintonización iPCA seguido de un sistema de reconocimiento de patrones configurado con: extracción de características compuestas por los coeficientes de un modelo autoregresivo de orden 6 (AR6), reducción de dimensionalidad basada en análisis discriminativo lineal sin correlación (ULDA) y clasificador basado en análisis discriminativo lineal (LDA). Durante

el proceso de sintonización fueron evaluadas ocho alternativas para resolver la rutina de optimización, una por cada combinación función costo y algoritmo de búsqueda. Los resultados medidos permitieron comparar tiempo de búsqueda y nivel de optimización de las soluciones calculadas con cada alternativa. De igual forma, fueron comparados los desempeños de clasificación asociados con cada solución. Las señales EMG fueron procesadas utilizando una arquitectura de simulación construida para resolver las necesidades específicas de nuestro proyecto. El simulador construido puede ser utilizado en investigaciones futuras relacionadas con el análisis de los efectos de otras etapas del sistema de control sobre el desempeño de clasificación.

Los resultados de simulación sugieren que: (a) no fueron observadas evidencias estadísticas suficientes para concluir dependencias entre los algoritmos de búsqueda y el error de clasificación del sistema de control ( $p < 0.01$ ). Este comportamiento fue concluido para un conjunto específico de parámetros de los algoritmos de búsqueda. Es posible que otras configuraciones en dichos parámetros, lleven a otros comportamientos. (b) Fueron observadas evidencias estadísticas significativas para sugerir que existe dependencia entre la función costo y el error de clasificación del sistema de control ( $p < 0.02$ ). Resultados complementares permitieron (a) comprobar la superioridad del esquema de control con sintonización iPCA sobre el esquema convencional e (b) identificar una ventaja práctica del algoritmo PSO sobre las otras alternativas evaluadas, esta ventaja está relacionada con el tiempo de búsqueda de la solución óptima.

## SUMÁRIO

<b>1 - INTRODUÇÃO .....</b>	<b>1</b>
<b>1.1 - METODOLOGIA.....</b>	<b>1</b>
1.1.1 - Objetivos.....	7
1.1.2 - Organização do Trabalho .....	8
<b>2 - CONCEITOS TEÓRICOS RELACIONADOS COM O CONTROLE ELETROMIOGRÁFICO. ....</b>	<b>9</b>
<b>2.1 - INTRODUÇÃO .....</b>	<b>9</b>
<b>2.2 - GENERALIDADES SOBRE O SINAL ELETROMIOGRÁFICO .....</b>	<b>9</b>
2.2.1 - Fisiologia do sinal Eletromiográfico .....	9
2.2.2 - Medição do sinal Eletromiográfico .....	14
2.2.3 - Pré-processamento do sinal Eletromiográfico .....	16
2.2.4 - Discussão sobre os aspectos básicos de eletromiografia.....	18
<b>2.3 - SISTEMAS DE CONTROLE MIOELÉTRICO BASEADOS EM RECONHECIMENTO DE PADRÕES .....</b>	<b>19</b>
2.3.1 - Formulação do problema de Classificação nos sistemas de controle mioelétrico. ....	20
2.3.2 - Pré-processamento.....	24
2.3.3 - Extração de características .....	24
2.3.4 - Redução de dimensionalidade .....	29
2.3.5 - O Classificador de padrões .....	31
2.3.6 - Etapas de processamento adicionais .....	36
2.3.7 - Comentários sobre os sistemas de controle mioelétrico baseados em reconhecimento de padrões.....	39
<b>2.4 - RESUMO DO CAPÍTULO .....</b>	<b>41</b>
<b>3 - SINTONIZAÇÃO DE DADOS POR IPCA .....</b>	<b>44</b>
<b>3.1 - INTRODUÇÃO .....</b>	<b>44</b>
<b>3.2 - TRANSFORMADA PCA.....</b>	<b>44</b>
3.2.1 - Os componentes Principais.....	44
3.2.2 - Definição da transformação PCA .....	46
3.2.3 - Algoritmo de cálculo das matrizes de transformação PCA.....	48

3.3 - CLASSIFICAÇÃO DE PADRÕES PROJETADOS COM TRANSFORMAÇÃO IPCA .....	49
3.3.1 - Definição da Transformação iPCA .....	50
3.3.2 - Classificação dos padrões projetados com iPCA .....	52
3.4 - REDUÇÃO DE DIMENSIONALIDADE .....	56
3.4.1 - Definição do problema de redução de dimensionalidade .....	56
3.4.2 - Algoritmos de busca .....	58
3.4.3 - Funções custo .....	69
3.5 - RESUMO DO CAPÍTULO .....	72
4 - METODOLOGIA EXPERIMENTAL E RESULTADOS .....	73
4.1 - INTRODUÇÃO .....	73
4.2 - METODOLOGIA EXPERIMENTAL .....	73
4.2.1 - Etapa 1. Experimentos Supervisionados .....	74
4.2.2 - Etapa 2. Cálculo da matriz iPCA reduzida .....	78
4.2.3 - Etapa 3. Configuração de parâmetros do classificador .....	83
4.2.4 - Etapa 4. Avaliação do sistema de classificação .....	84
4.3 - DESCRIÇÃO DO PROJETO DO SIMULADOR DE CONTROLE MIOELÉTRICO COM SINTONIZAÇÃO IPCA .....	89
4.4 - RESUMO DO CAPÍTULO .....	90
5 - DISCUSSÃO DOS RESULTADOS .....	92
5.1 - RESULTADOS GERADOS DURANTE O CÁLCULO DA MATRIZ DE TRANSFORMAÇÃO REDUZIDA .....	92
5.1.1 - Tempos de busca das soluções ótimas .....	92
5.1.2 - Aptidão atingida durante a Otimização .....	96
5.2 - RESULTADOS GERADOS DURANTE A AVALIAÇÃO DO SISTEMA DE CLASSIFICAÇÃO .....	97
5.2.1 - Erros de classificação por usuário .....	97
5.2.2 - Erros médios de classificação .....	97
5.2.3 - Matrizes de confusão .....	98
5.3 - ANÁLISE ESTATÍSTICA DE RESULTADOS .....	98
5.3.1 - Avaliação de condições para utilização de ANOVA .....	98
5.3.2 - Aplicação da ANOVA de dois fatores .....	101

<b>6 - CONCLUSÕES E TRABALHOS FUTUROS.....</b>	<b>103</b>
<b>6.1 - CONCLUSÕES GERAIS .....</b>	<b>103</b>
<b>6.2 - CONTRIBUÇÕES.....</b>	<b>105</b>
<b>6.3 - SUGESTÕES PARA TRABALHOS FUTUROS.....</b>	<b>107</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>109</b>
<b>APÊNDICES .....</b>	<b>117</b>
<b>A - CARACTERÍSTICAS RMS E AR.....</b>	<b>118</b>
<b>A.1 - CARACTERÍSTICAS RMS.....</b>	<b>118</b>
<b>A.2 - PARÂMETROS AR COMO CARACTERÍSTICAS DO SINAL.....</b>	<b>118</b>
<b>B - MATRIZES DE DISPERSÃO NA REDUÇÃO DE DIMENSIONALIDADE</b>	
<b>121</b>	
<b>C - MATRIZ DE COVARIÂNCIA PARA O CASO DE DADOS</b>	
<b>MULTIDIMENSIONAIS .....</b>	<b>123</b>
<b>D - EXEMPLO DA MATRIZ DE COEFICIENTES DE CORRELAÇÃO.....</b>	<b>126</b>

## LISTA DE TABELAS

Tabela 2-1. Parâmetros recomendados pelo SENIAM ( <i>Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles</i> ) para a etapa de pré-processamento do sinal EMG. Fonte: (Hermens, et al., 1999) .....	18
Tabela 2-2. Resumo dos parâmetros de classificação e erros atingidos nos últimos anos. .	43
Tabela 3-1. Etapas de desenvolvimento do sistema de classificação proposto em (Hargrove, et al., 2009). .....	54
Tabela 3-2. Parâmetros do algoritmo PSO .....	65
Tabela 3-3. Parâmetros do algoritmo ABC .....	69
Tabela 4-1. Alternativas de tratamento de sinal na redução de dimensionalidade dos padrões projetados com iPCA .....	73
Tabela 4-2. Identificadores das classes de movimento utilizadas durante a coleta de sinais EMG. ....	75
Tabela 4-3. Divisão dos ensaios na base de dados .....	78
Tabela 4-4. Parâmetros experimentais do algoritmo PSO.....	81
Tabela 4-5. Parâmetros experimentais do algoritmo ABC.....	81
Tabela 4-6. Tempo médios de iteração durante o processo de otimização com as oito alternativas de tratamento de sinal.....	82
Tabela 4-7. Erros de classificação atingidos com o nível 1 do fator <i>A</i> (função custo <i>erro de classificação</i> ) e os níveis 1 até 4 do fator <i>B</i> .....	85
Tabela 4-8. Erros de classificação atingidos com o nível 2 do fator <i>A</i> (função custo <i>fator de correlação</i> ) e os níveis 1 até 4 do fator <i>B</i> .....	85
Tabela 4-9. Matriz de confusão para os algoritmos sequenciais e a função custo erro de classificação. As células sem sombra (coluna esquerda) contêm as porcentagens com o algoritmo SFS. As células em gris (coluna direita) contêm as porcentagens do algoritmo SFFS. Os resultados na diagonal principal são as porcentagens de classificações corretas.....	87
Tabela 4-10. Matriz de confusão para os algoritmos bio-inspirados e a função custo erro de classificação. As células sem sombra (coluna esquerda) contêm as porcentagens com o algoritmo PSO. As células em gris (coluna direita) contêm as porcentagens do algoritmo ABC. Os resultados na diagonal principal são as porcentagens de classificações corretas.....	87

Tabela 4-11. Matriz de confusão para os algoritmos sequenciais e a função custo fator de correlação. As células sem sombra (coluna esquerda) contêm as porcentagens com o algoritmo SFS. As células em gris (coluna direita) contêm as porcentagens do algoritmo SFFS. Os resultados na diagonal principal são as porcentagens de classificações corretas.....	88
Tabela 4-12. Matriz de confusão para os algoritmos bio-inspirados e a função custo fator de correlação. As células sem sombra (coluna esquerda) contêm as porcentagens com o algoritmo PSO. As células em gris (coluna direita) contêm as porcentagens do algoritmo ABC. Os resultados na diagonal principal são as porcentagens de classificações corretas.....	88
Tabela 4-13. Resumo das características do PC utilizado para as simulações.....	90
Tabela 5-1. Tabela ANOVA dos erros de classificação.....	101

## LISTA DE FIGURAS

Figura 1-1 Arquitetura de processamento convencional dos sistemas de controle mioelétrico baseados em reconhecimento de padrões. ....	2
Figura 1-2. Arquitetura de controle mioelétrico com o processo de sintonização por iPCA	3
Figura 1-3. Etapas de avaliação e configuração de parâmetros durante o desenvolvimento do sistema de controle mioelétrico com sintonização iPCA. ....	4
Figura 1-4. Processo de cálculo do vetor $O$ durante a etapa de configuração de parâmetros. ....	5
Figura 1-5. Resumo das alternativas de tratamento de sinal utilizadas durante a solução do problema de otimização. ....	8
Figura 2-1. Sistema Nervoso Central e Unidade Motora. Modificado de (Merletti, et al., 2004).....	10
Figura 2-2. Sinapses na Unidade Motora. Fonte (De Luca, 2008).....	11
Figura 2-3. Combinação aditiva da atividade elétrica gerada por cada unidade motora. Modificado de: (De Luca, 2008) .....	12
Figura 2-4. Sinal EMG medido no primeiro músculo <i>dorsal interósseo</i> durante contração voluntária. Fonte: (De Luca, 2006).....	13
Figura 2-5. Diagrama de blocos do processo de classificação para um sistema de controle EMG multicanal.....	22
Figura 2-6. Janelamento adjacente. Fonte (Englehart, et al., 2003) .....	25
Figura 2-7. Janelamento com superposição. Fonte (Englehart, et al., 2003) .....	25
Figura 2-8. Comparação do desempenho atingido com seis conjuntos de características utilizando o classificador LDA. Modificado de (Hargrove, et al., 2007).....	28
Figura 2-9. Comparação do desempenho atingido entre cinco classificadores diferentes. Fonte (Hargrove, et al., 2007). Problema de classificação de 6 classes de movimento, 4 canais de aquisição e 12 sujeitos sem amputação .....	31
Figura 2-10. Exemplo de duas regiões formadas pelo classificador Bayesiano no caso de duas classes equiprováveis. Fonte: (Theodoridis, et al., 2006) .....	34
Figura 2-11. Comparação de resultados de classificação com processamento MV ( <i>majority vote</i> ). Fonte (Chan, 2007) .....	37
Figura 2-12. Transformação iPCA .....	38

Figura 2-13. Esquema de Transformação iPCA complementado com Redução de dimensionalidade .....	39
Figura 3-1. Exemplo dos eixos de projeção na transformação iPCA de um sinal $x$ de duas dimensões. A elipse indica os contornos das densidades de probabilidade de $x_1(m)$ e $x_2(m)$ . Fonte: (Hyvärinen, et al., 2001) .....	45
Figura 3-2. Esquema de transformação iPCA no sistema de classificação de $C$ classes ....	50
Figura 3-3. Comparação entre as transformações PCA e iPCA em um problema de classificação. Fonte: (Das, et al., 2008) .....	51
Figura 3-4. Arquitetura de classificação com transformação iPCA reduzida. ....	55
Figura 3-5. Redução de dimensionalidade por seleção de características .....	57
Figura 3-6. Diagrama de blocos do processo de classificação para um sistema de controle mioelétrico multicanal convencional .....	70
Figura 4-1 Metodologia de quatro etapas para obtenção do erro de classificação médio no sistema de controle mioelétrico com sintonização iPCA. ....	74
Figura 4-2. Estrutura do experimento de coleta de dados EMG .....	75
Figura 4-3. Distribuição dos eletrodos durante a aquisição do sinal EMG. A distribuição em anel garante os níveis de <i>crosstalk</i> necessários para a experimentação com a sintonização iPCA. Fonte: (Hargrove, et al., 2009) .....	75
Figura 4-4. Classes de movimento: a) abrir mão, b) supinação, c) pronação, d) flexão do pulso, e) extensão do pulso, f) repouso, g) agarre de ferramenta, h) agarre pinza, i) agarre cilíndrico, j) agarre fino, k) agarre de chave. Fonte: (Kaufmann, et al., 2010) (Kuiken, et al., 2009) .....	76
Figura 4-5. Sequência de classes de movimentos dentro do ensaio. O movimento no período de tempo entre classes (IC) corresponde com a classe de repouso ( <i>no movement</i> ). Fonte própria .....	77
Figura 4-6. Sequência de execução dos movimentos durante a aquisição do sinal EMG. Os sinais ilustrados correspondem com o canal 1, durante os ensaios 6, 7 e 8, para o usuário 1 .....	77
Figura 4-7. Diagrama de blocos para o cálculo do vetor de dimensões reduzidas $O$ .....	79
Figura 4-8. Combinações de função-custo/ algoritmo-de-busca consideradas durante a etapa 2. ....	80
Figura 4-9. Esquema de processamento para o cálculo da função custo erro de classificação .....	81

Figura 4-10. Comparação entre o número de iterações dos algoritmos de busca na minimização das funções custo <i>erro de classificação</i> e <i>fator de correlação</i> . .....	82
Figura 4-11. Comparação do valor mínimo da função custo atingido por cada algoritmo de busca no processo de otimização. ....	82
Figura 4-12. Valor médio e desvio padrão do erro de classificação atingido com cada alternativa de tratamento de sinal avaliada. A linha tracejada indica o erro de classificação do sistema de controle sem sintonização iPCA. ....	86
Figura 4-13. Estrutura do toolbox de controle mioelétrico com sintonização iPCA projetado. ....	89
Figura 5-1. Tempos de busca da solução ótima para cada combinação função-custo/algoritmo-de-busca. ....	95
Figura 5-2. Comparação da aptidão gerada com as combinações de função-custo/algoritmo-de-busca avaliadas. ....	96
Figura 5-3. Erros médios de classificação atingidos com combinações de fatores $A$ e $B$ . ....	100
Figura 5-4. Figura de probabilidade normal. a) Resíduos do erro de classificação $e_{1j}$ . b) Resíduos do erro de classificação $e_{2j}$ . ....	101
Figura 6-1. Relação entre os sinais $x_1, x_2$ . ....	126
Figura 6-2. Matrizes de coeficientes de correlação para os três casos considerados no exemplo. ....	127

# 1 - INTRODUÇÃO

Os sinais eletromiográficos (EMG) são potenciais de ação eletrofisiológicos originados no sistema nervoso e associados com as contrações musculares no corpo humano. Fazendo medição e processamento desse tipo de sinais é possível determinar intenções de movimento numa pessoa. Esta característica preditiva do sinal EMG permite seu uso no desenvolvimento de interfaces homem máquina (HMI) numa ampla faixa de aplicações. Uma das aplicações mais desafiantes é o desenvolvimento de próteses multifuncionais. Estes são dispositivos que retornam a uma pessoa com limitações de movimento (por causa de traumatismo, paralisias ou amputação) parte da habilidade para realizar tarefas cotidianas. O desenvolvimento desse tipo de sistema envolve a síntese de diversas etapas de processamento digital de sinal e de algoritmos de classificação. O presente projeto de pesquisa está relacionado com o desenvolvimento desse tipo de sistema, particularmente, com o sistema de controle mioelétrico de próteses de mão. Nesse sentido, este trabalho visa determinar os efeitos das combinações *função custo / algoritmo de busca* sobre o desempenho de classificação dos sistemas de controle eletromiográfico com sintonização iPCA. A hipótese de pesquisa considera que a utilização de algoritmos não sequenciais assim como funções custo não-supervisionadas pode incrementar os desempenhos de classificação reportados na literatura.

## 1.1 - METODOLOGIA

Os sistemas de controle mioelétrico são conjuntos de elementos (*hardware/software*) que classificam os movimentos executados por uma pessoa, fazendo processamento sobre os sinais EMG associados com as contrações realizadas durante estes movimentos. O indicador de desempenho preferido para avaliar este tipo de sistemas é o *erro de classificação* definido como a relação entre o número de movimentos identificados incorretamente e o número total de movimentos classificados pelos sistema. Existem diversas abordagens para resolver esse tipo de tarefa, como exposto em (Oskoei Asghari, et al., 2007), (Dorcas, et al., 1966), (Merletti, et al., 2004), (Nielsen, et al., 2011). Dentre elas, o controle mioelétrico baseado em *reconhecimento de padrões* é a abordagem que tem atingido os maiores sucessos considerando os

seguintes pontos: (a) número de classes de movimento  $C$  e (b) erro de classificação (Englehart, 1998), (Merletti, et al., 2004), (Jiang, et al., 2009).

A arquitetura de processamento baseada em reconhecimento de padrões é ilustrada na Figura 1-1. Nessa arquitetura o sinal eletromiográfico (representado pelo vetor de padrões  $x$ ) é submetido a processos de extração de características, redução de dimensionalidade e classificação para obter a classe de movimento associada (representada pelo vetor de etiquetas de classes  $\hat{y}$ ).

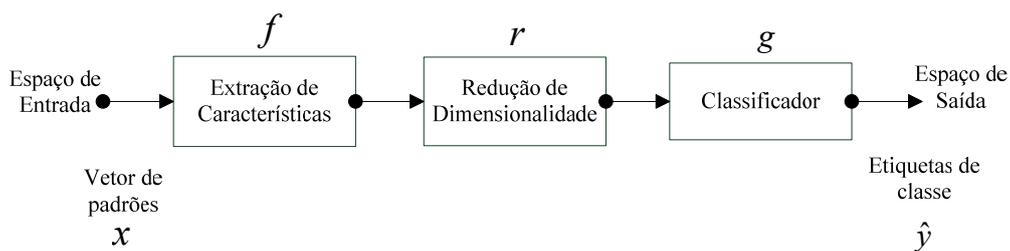


Figura 1-1 Arquitetura de processamento convencional dos sistemas de controle mioelétrico baseados em reconhecimento de padrões.

Com a arquitetura convencional ilustrada na Figura 1-1 foi possível atingir erros de classificação de 7.4% em um problema com sete classes de movimento e oito canais EMG (Chan, 2007); ou seja, de cada 100 classificações feitas pelo sistema aproximadamente sete estiveram erradas. Sem dúvida, esse é um erro baixo, mas a tendência desses sistemas é incrementar o número de classes de movimento disponíveis, essa tendência aumenta a complexidade junto com o erro de classificação do sistema. Por essa razão ainda existem esforços para reduzir os erros de classificação na medida em que é incrementado o número de classes disponíveis. Como resultado desses esforços recentemente foi sugerido que a informação de *crosstalk* muscular do sinal EMG contém informação discriminativa de classe que pode ser utilizada para melhorar o desempenho do sistema de classificação (Huang, et al., 2005). Essa proposta foi pesquisada em Hargrove et al., 2009, e resultou em reduções significativas no erro de classificação reportado na literatura de controle eletromiográfico. Nesse caso, para o problema de 7 classes de movimento e 6 canais de aquisição EMG, foram atingidos erros de classificação de 1.9%. A arquitetura usada em (Hargrove, et al., 2009) é ilustrada na Figura 1-2.

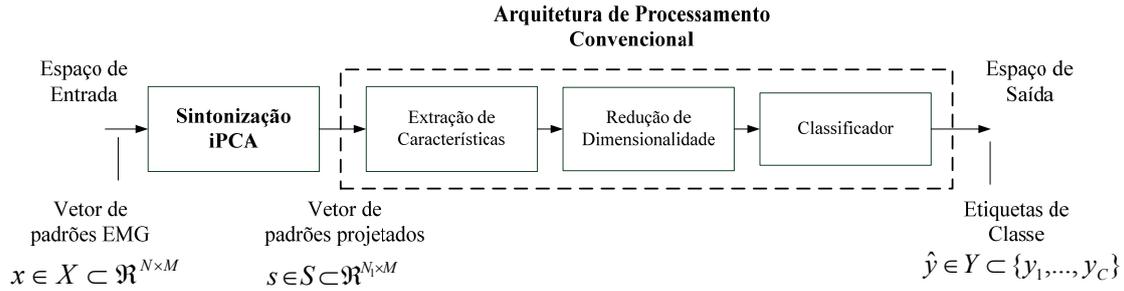


Figura 1-2. Arquitetura de controle mioelétrico com o processo de sintonização por iPCA

A proposta feita em (Hargrove, et al., 2009) mistura um sistema de aquisição com altos níveis de *crossstalk* junto com uma etapa de processamento que utiliza a transformação individual dos componentes principais (iPCA, *individual Principal Component Analysis*) sobre os padrões de entrada, no intuito de fazer uma sintonização dos dados antes do processo de classificação. Assim, o propósito dessa transformação é gerar um novo espaço de sinal onde a informação discriminativa relacionada com a classe de movimento seja amplificada e outros tipos de informação sejam atenuados. A principal desvantagem da transformação iPCA é o incremento na dimensionalidade dos padrões de EMG. Por exemplo, considerando a classificação de um sistema com  $C$  classes de movimento, a transformação define  $C$  matrizes de projeção e, conseqüentemente, a projeção de um padrão de entrada de dimensão  $N$  resulta em um padrão de dimensões  $CN$ .

Para eliminar problemas derivados do incremento na dimensionalidade dos dados, em (Hargrove, et al., 2009) é proposta a execução de uma ou *transformação iPCA reduzida*. Com a transformação iPCA reduzida é possível projetar os sinais de entrada e gerar unicamente  $N_I$  dimensões com maior informação discriminativa de classe (com  $N_I < CN$ ). O cálculo da matriz de transformação iPCA parcial envolve um problema de otimização: Escolha do subconjunto  $O$  de comprimento  $N_I$  a partir do conjunto de comprimento  $CN$ , garantindo maximização da informação discriminativa de classe no subconjunto escolhido.

Considerando os requisitos de tempo de execução do sistema de controle mioelétrico [150-250]ms (Farrell, et al., 2007) e complexidade computacional do processo de otimização, conclui-se que a busca ótima não pode ser executada durante a classificação dos padrões EMG. Conseqüentemente, os autores em (Hargrove, et al., 2009) propõem o desenvolvimento do sistema de controle mioelétrico em duas etapas como indicado na

Figura 1-3: (a) Etapa de configuração de parâmetros e (b) Etapa de avaliação do sistema.

Na etapa de configuração de parâmetros são calculados os parâmetros do classificador e o parâmetro da sintonização iPCA, ou seja, a matriz de transformação iPCA reduzida. Os padrões utilizados são: dados de treinamento ( $x_{tr}$ ) e dados de validação ( $x_v$ ). É importante aclarar que esta etapa não tem que satisfazer requisitos estritos no tempo de execução.

Uma vez calculados os parâmetros passamos à etapa de avaliação. Nessa etapa, faz-se a classificação em tempo real dos padrões EMG de teste ( $x_t$ ). As saídas geradas nessa etapa são as utilizadas para determinar o desempenho de classificação do sistema de controle mioelétrico.

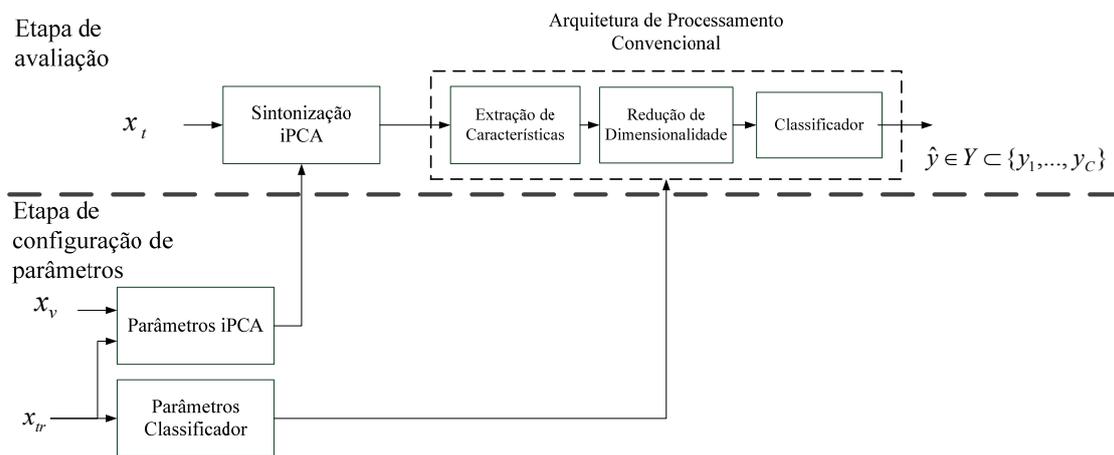


Figura 1-3. Etapas de avaliação e configuração de parâmetros durante o desenvolvimento do sistema de controle mioelétrico com sintonização iPCA.

O foco de nossa pesquisa está localizado no bloco *Parâmetros iPCA*, executado durante a etapa de configuração. Como foi dito, para resolver esse bloco é necessário calcular o vetor com a sequência dos  $N_I$  canais com maior informação discriminativa de classe. Essa solução é calculada com o esquema de blocos da Figura 1-4. Nesse esquema, os padrões EMG de comprimento  $N$  (que chamaremos padrões de validação) são projetados com as matrizes de transformação iPCA, na saída obtém-se o padrão  $s$  de comprimento  $CN$ . Esse novo conjunto de padrões é submetido ao processo de escolha dos  $N_I$  canais com maior informação discriminativa. O processo de escolha é um processo iterativo onde o algoritmo de busca seleciona um subconjunto  $O'$  do conjunto

$CN$ , posteriormente a aptidão desse subconjunto é avaliada com a função custo e finalmente se avaliam os critérios de parada da busca. O processo termina quando as condições de parada são satisfeitas (por exemplo, máximo número de iterações, comprimento  $N_I$  do vetor  $O'$  ou máximo nível de aptidão atingido), nesse instante é apresentado na saída o vetor  $O$  com o subconjunto  $N_I$ .

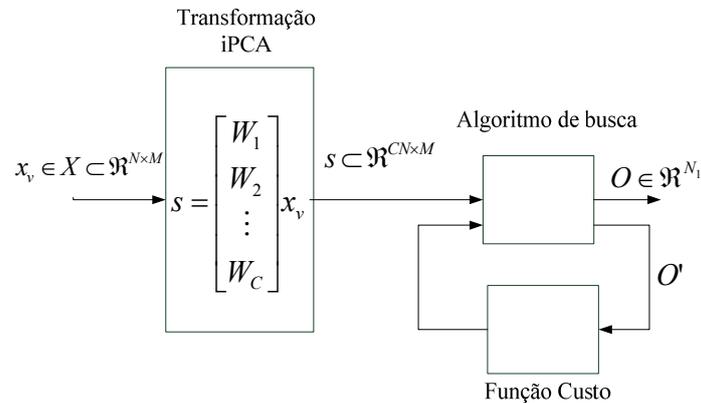


Figura 1-4. Processo de cálculo do vetor  $O$  durante a etapa de configuração de parâmetros.

O esquema utilizado em (Hargrove, et al., 2009) combina o algoritmo de busca de seleção sequencial (SFS) e a função custo *erro de classificação* para resolver o diagrama de blocos da Figura 1-4. Algumas vantagens dessa combinação são:

- (a) A função custo erro de classificação é o mesmo indicador de desempenho de classificação do sistema, conseqüentemente, é o indicador ideal para comparar a quantidade de informação discriminativa entre instâncias do vetor  $O$ . Quanto menor é o erro de classificação, maior será a quantidade de informação discriminativa.
- (b) O algoritmo SFS garante que não há canais repetidos no vetor  $O$ , essa propriedade reduz o nível de correlação entre canais escolhidos. Levando em conta que existe uma proporção direta entre o erro de classificação e o nível de correlação entre canais EMG, assume-se que a propriedade de repetitividade nula de canais do SFS beneficia a localização do valor mínimo na função custo erro de classificação.

Entretanto, também existem algumas desvantagens associadas com a combinação mencionada, por exemplo:

(a) O algoritmo SFS apresenta o problema chamado de *nesting effect*, o qual impede rejeitar um canal uma vez tenha sido escolhido (Theodoridis, et al., 2006).

(b) Assume-se que a função custo erro de classificação é uma função multimodal com mínimos locais distribuídos aleatoriamente no espaço de busca. A localização do mínimo global nesse tipo de função precisa de estratégias de busca envolvendo componentes aleatórios. Esses componentes estimulam o descobrimento de novas soluções inteiramente desconhecidas que ocasionalmente podem levar a melhores aptidões (Karaboga, et al., 2007). O algoritmo SFS carece desse tipo de componentes (Theodoridis, et al., 2006).

(c) A função custo erro de classificação representa uma aprendizagem supervisionada<sup>1</sup> e de alta complexidade computacional<sup>2</sup>. Essas características têm dois efeitos no processo de busca: (i) Restringem a execução da busca ótima para conjuntos de padrões onde se conhece com antecipação a classe de movimento associada. (ii) Incrementam os requisitos computacionais e consequentemente os tempos de busca da solução.

Até o momento se desconhecem os efeitos das desvantagens expostas aqui, referentes ao erro de classificação. Consequentemente, é interessante pesquisar a respeito, tendo em conta os seguintes pontos:

1) Os algoritmos de busca sequenciais chamados de *flutuantes* (SFFS) conseguem reduzir as implicações do *nesting effect* e conservam a maioria das vantagens do algoritmo SFS (Somol, et al., 1999).

2) Os algoritmos chamados de *bio-inspirados* incluem componentes aleatórias na busca de máximos ou mínimos de uma função custo, tendo em vista que é permitido a obtenção de bons resultados na solução de problemas de otimização (Eberhart, et al., 1995 ), (Karaboga, et al., 2007). Nesse sentido, os algoritmos de

---

<sup>1</sup> A característica de função supervisionada significa que a função precisa entre seus argumentos tanto os padrões EMG como a classe de movimento a que pertencem esses padrões.

<sup>2</sup> A alta complexidade computacional associada com o erro de classificação é inferida pelo fato de que um dos argumentos da função erro de classificação é a classe predita, consequentemente, para calcular essa função é necessário resolver o sistema de controle mioelétrico completo.

otimização por enxame de partículas (PSO) e colônias artificiais de abelhas (ABC) são alternativas interessantes para o problema definido.

3) O desempenho de classificação dos sistemas de controle eletromiográfico é inversamente proporcional com o nível de redundância nos padrões EMG, conseqüentemente, é possível usar uma medida do nível de correlação no padrão EMG como função custo na solução do problema de otimização. Essa função apresenta algumas características interessantes, tais como: (a) é uma função que representa um aprendizado não supervisionado, (b) é uma função de complexidade relativamente baixa.

### 1.1.1 - Objetivos

O objetivo geral desta pesquisa é determinar os efeitos das combinações *função-custo / algoritmo-de-busca* no erro de classificação do sistema de controle mioelétrico com sintonização iPCA quando algoritmos de busca bio-inspirados e sequenciais, assim como, funções custo supervisionadas e não supervisionado são utilizadas para resolver o problema de otimização. A hipótese de pesquisa considera que a utilização das combinações citadas pode incrementar os desempenhos de classificação reportados na literatura.

Esse objetivo é dividido em três objetivos específicos:

1. Estudo dos fundamentos teóricos relacionados com: (a) classificação do sinal eletromiográfico, (b) transformação iPCA, (c) algoritmos de busca e (d) funções custo reportadas na área do controle eletromiográfico.
2. Obtenção de uma plataforma de simulação que permita avaliar o desempenho de classificação do sistema de controle de próteses de mão baseado em reconhecimento de padrões.
3. Análise comparativa entre os desempenhos de classificação gerados com as estratégias de redução de dimensionalidade escolhidas.

Adicionalmente, no intuito de definir os limites da pesquisa, serão consideradas as alternativas de redução de dimensionalidade formadas pelas combinações de algoritmos de busca: SFS, SFFS, PSO, ABC; com funções custo: (a) *erro de classificação* e (b) *fator de correlação*. Essas alternativas são resumidas na Figura 1-5 que indica as oito combinações que serão avaliadas durante a solução do problema de otimização. É importante ressaltar que até o momento só se tem reportado na literatura a avaliação da

alternativa B1-A1 (SFS - erro de classificação) para o problema de controle mioelétrico com sintonização iPCA (Hargrove, et al., 2009).

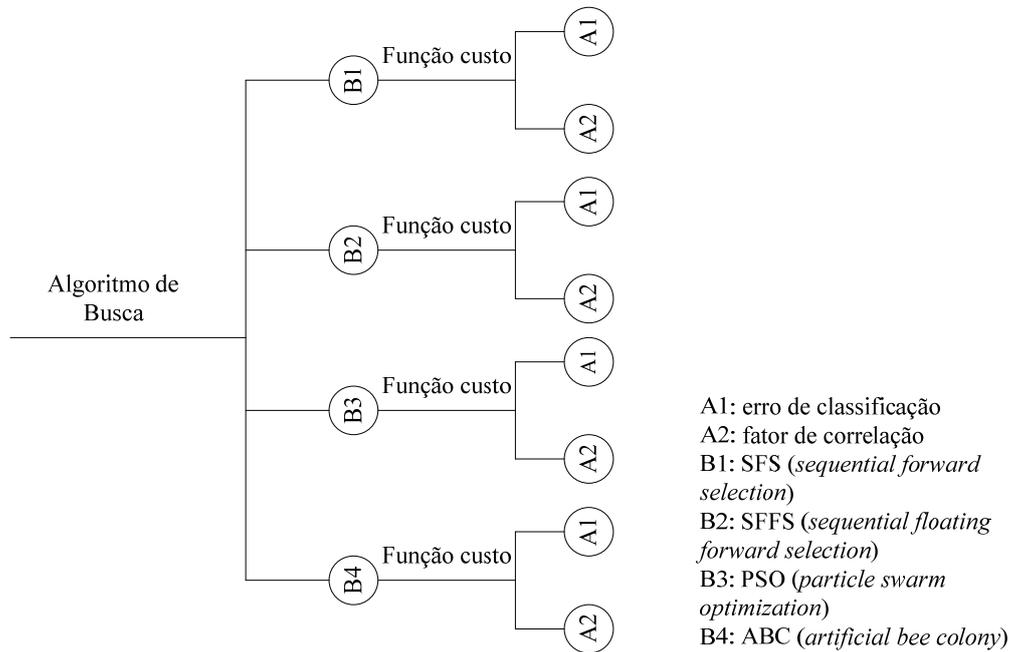


Figura 1-5. Resumo das alternativas de tratamento de sinal utilizadas durante a solução do problema de otimização.

### 1.1.2 - Organização do Trabalho

O capítulo 1 apresenta o problema de dimensionalidade derivado da transformação iPCA, junto com o enfoque de seleção de canais adotado neste projeto e os objetivos da pesquisa. O capítulo 2 apresenta os conceitos teóricos relacionados com o controle mioelétrico. A apresentação é dividida em duas partes: (1) Introdução básica à eletromiografia e (2) Etapas de processamento do sistema de controle mioelétrico. No capítulo 3 são definidos os métodos envolvidos na etapa de *sintonização por iPCA*: a apresentação é focada em três tópicos: Transformação iPCA, algoritmos de busca e funções custo. O capítulo 4 apresenta a metodologia experimental junto com os resultados obtidos. No Capítulo 5 se faz a análise comparativa dos resultados de desempenho atingidos. O Capítulo 6 contém as conclusões e sugestões para trabalhos futuros relacionados com esta pesquisa.

## **2 - CONCEITOS TEÓRICOS RELACIONADOS COM O CONTROLE ELETROMIOGRÁFICO.**

### **2.1 - INTRODUÇÃO**

Neste capítulo são apresentados os conceitos básicos relacionados com *sistemas de controle mioelétrico de próteses de mão*. A apresentação é dividida em duas seções: Na primeira seção se faz uma introdução à eletromiografia focada nos aspectos relevantes, considerando a sua aplicação em sistemas de controle mioelétrico. Na segunda seção são apresentadas as etapas envolvidas no processo de classificação dos sinais eletromiográficos.

### **2.2 - GENERALIDADES SOBRE O SINAL ELETROMIOGRÁFICO**

Qualquer tipo de contração das fibras musculares do corpo está acompanhada de uma atividade elétrica. A eletromiografia é um método de medição e registro dessa atividade elétrica através de eletrodos. O sinal resultante é chamado de sinal eletromiográfico ou de eletromiograma (EMG), o qual é um sinal elétrico composto pelas contribuições das fibras musculares que estão a certa distância do eletrodo. A análise desse tipo de sinal é importante em diversas áreas de aplicação que vão desde o diagnóstico de doenças neuromusculares até o desenvolvimento de mecanismos de controle neuromuscular. Neste seção é apresentada uma introdução básica à eletromiografia focada nos aspectos relevantes, considerando a sua aplicação em *sistemas de controle mioelétrico de próteses de mão*.

#### **2.2.1 - Fisiologia do sinal Eletromiográfico**

A seguir são apresentados alguns conceitos relacionados com a fisiologia e anatomia humana. Esses conceitos incluem: (a) o sistema nervoso, (b) tipos de músculos, (c) anatomia dos músculos e (d) contração muscular.

### 2.2.1.1 - O sistema nervoso e a Unidade Motora (MU).

O sistema nervoso central é composto pelo cérebro e a espinha dorsal. A espinha dorsal liga o sistema de músculos esqueléticos<sup>3</sup> com o cérebro, como ilustrado na Figura 2-1. Um músculo esquelético é formado por um grupo de *Unidades Motoras* (MU). A unidade motora é a menor unidade funcional do sistema neuromuscular. Ela consiste de um neurônio motor *tipo alfa* e um conjunto de fibras musculares inervadas pelo neurônio, onde a inervação é feita através dos axônios do neurônio motor tipo alfa. Existem de 100 a 1700 unidades motoras por músculo aproximadamente (Merletti, et al., 2004). A quantidade de fibras musculares por unidade motora não é fixa. Similarmente, a quantidade de unidades motoras por músculo não é fixa, por exemplo, unidades motoras dos músculos dos olhos podem ter de 5 a 7 fibras musculares. No caso dos músculos da mão o número pode chegar a 100 (Welling, 2000) e no caso de músculos do braço pode-se encontrar mais de 500 fibras musculares por unidade motora (Merletti, et al., 2004).

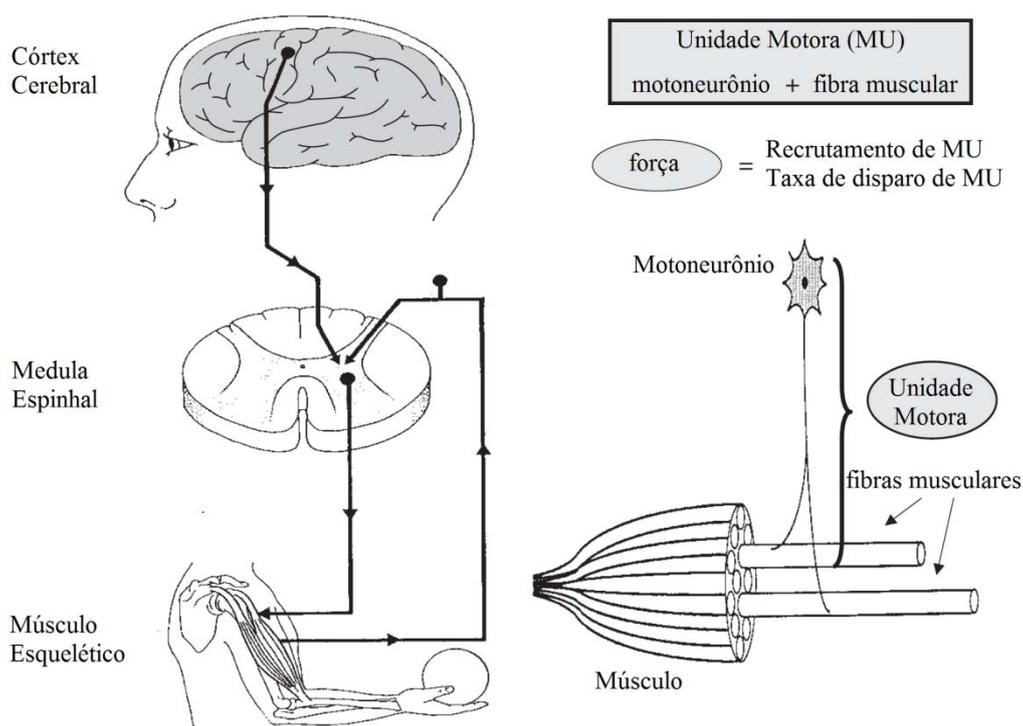


Figura 2-1. Sistema Nervoso Central e Unidade Motora. Modificado de (Merletti, et al., 2004)

<sup>3</sup> Nos humanos, os músculos podem ser classificados em três grupos: cardíacos, lisos e esqueléticos. O grupo dos músculos esqueléticos está ligado ao esqueleto e exerce forças no mesmo.

### 2.2.1.2 - Contração das fibras musculares e geração do sinal EMG.

A contração voluntária de músculos é originada a partir de potenciais de ação elétricos que viajam desde os nervos até os músculos. A sequência de eventos da contração muscular pode se iniciar com um disparo de potencial de ação em um neurônio motor *alfa superior*, com corpo localizado no *córtex cerebral*. Logo, o potencial de ação alcança o neurônio motor tipo *alfa inferior* na espinha dorsal. Desde este ponto, o potencial é enviado através dos axônios para a junção neuromuscular com as fibras musculares, onde essa ligação é denominada de *sinapse* neuromuscular, conforme ilustrado na Figura 2-2.

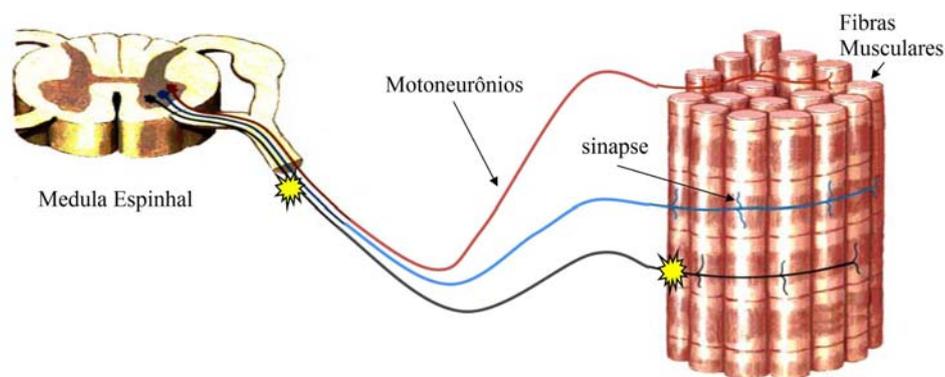


Figura 2-2. Sinapses na Unidade Motora. Fonte (De Luca, 2008)

Cada disparo do neurônio motor chega até a sinapse neuromuscular e nesse momento libera-se um neurotransmissor, chamado *Acetilcolina*. Esse neurotransmissor estimula os receptores na membrana celular da fibra muscular e como consequência a membrana da fibra muscular é despolarizada (Koch, 2007). A despolarização é propagada em direções opostas ao longo de cada fibra muscular. Esse fenômeno gera dois potenciais de ação viajando a uma velocidade conhecida como *velocidade de condução da fibra muscular* (CV, *Conduction Velocity*). Os potenciais de ação das fibras musculares pertencentes à mesma unidade motora são assíncronos no espaço e no tempo. Isto é devido a vários aspectos, entre eles: (a) diferença de comprimento das terminações dos axônios, (b) distribuição espacial das fibras musculares, (c) variações de CV entre fibras, etc. (Merletti, et al., 1992). O potencial de ação gerado em cada fibra muscular é chamado de (MFAP *Muscle Fiber Action Potential*). A soma das MFAPs pertencentes à mesma unidade motora é chamada de *potencial de ação da unidade motora* (MUAP, *Motor Unit Action Potential*) e a sequência destes MUAPs é chamada de trem de MUAPs (Merletti, et al., 1992).

Na Figura 2-3 são ilustrados os potenciais: MFAP, MUAP e MUAPT. Cada MUAP tem uma corrente associada no condutor volumétrico que o circunda. Essa corrente é associada à soma dos campos elétricos não-lineares gerados pelas fibras musculares individuais da unidade motora. Dois eletrodos podem ser usados para detectar a diferença de potencial entre dois pontos, dentro ou nos limites do volume condutor. O potencial detectado por esse par de eletrodos é o sinal eletromiográfico (EMG), esse potencial é produzido pela soma das contribuições de diferentes trens de MUAP e sinais de ruído, como se indica na Figura 2-3. Geralmente, essa adição é modelada como uma soma ponderada com pesos diferentes para cada MUAP. A ponderação de cada componente é determinada pela distância entre fonte e eletrodos, assim como pelas características da pele, entre outros (De Luca, 2006).

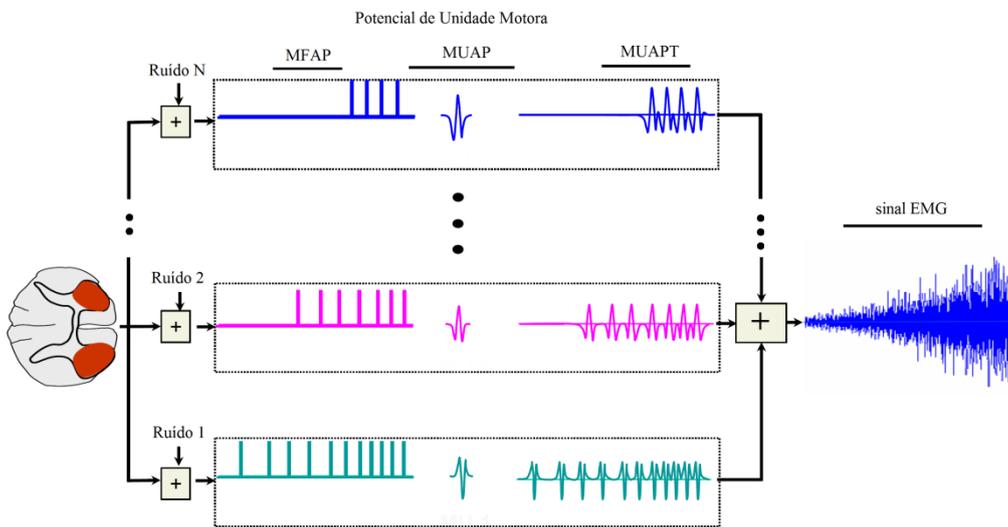


Figura 2-3. Combinação aditiva da atividade elétrica gerada por cada unidade motora. Modificado de: (De Luca, 2008)

### 2.2.1.3 - O Sinal Eletromiográfico.

Como mostrado na Figura 2-3, uma única unidade motora é disparada repetidamente e gera o trem de MUAPs (MUAPT). O sinal de EMG medido pelos eletrodos, geralmente consiste de contribuições de vários MUAPs além de fontes de ruído. Na Figura 2-4 ilustra-se um sinal EMG medido no primeiro músculo *dorsal interósseo* da mão durante contração voluntária. O sinal inicia com baixa amplitude e nessa etapa uma ampliação da figura permite identificar os MUAPs associados à contração. Na medida em que a força da contração é incrementada, uma maior quantidade de fibras musculares é recrutada e a taxa de disparo das MUAPs cresce. Conseqüentemente, a amplitude do sinal aumenta.

Quando o sinal de EMG é gerado em uma contração voluntária, e medido utilizando um par de eletrodos, o mesmo apresenta as seguintes características (Merletti, et al., 2001) (Merletti, et al., 2004):

- Seu valor instantâneo é aparentemente aleatório com distribuição aproximadamente gaussiana na faixa de 0 a 10 *mV*.
- A amplitude pode ser medida utilizando o valor da raiz média quadrática (RMS), que coincide com o desvio padrão da distribuição.
- Seus harmônicos (que formam o espectro e são obtidos por meio da análise de Fourier) estão na faixa de frequências [10-400]Hz.
- Se dois pares de eletrodos, A e B, são localizados na direção das fibras musculares, é possível identificar um retardo entre sinais similares  $x_A$ ,  $x_B$ . A velocidade de propagação pode ser estimada a partir desse retardo. Esse valor vai ser uma estimativa da velocidade de condução das fibras musculares (CV) e só é confiável se os dois sinais ( $x_A$ ,  $x_B$ ) são suficientemente parecidos (coeficiente de correlação > 0.7 ou 0.8).

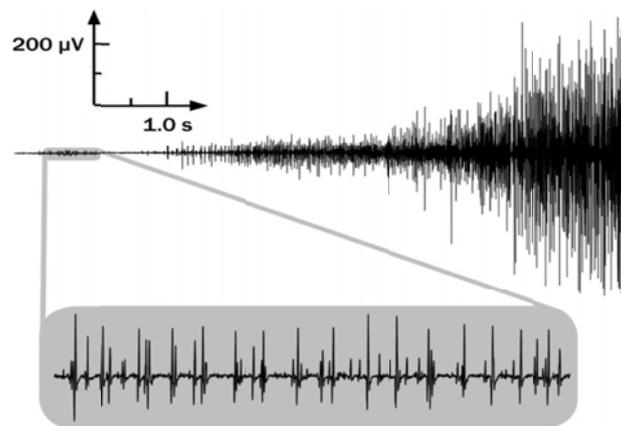


Figura 2-4. Sinal EMG medido no primeiro músculo *dorsal interósseo* durante contração voluntária. Fonte: (De Luca, 2006)

Existem alguns fatores pelos quais o sinal de EMG é considerado um processo estocástico não estacionário, entre os mais importantes podemos citar: (1) A alta variabilidade entre sujeitos e no mesmo sujeito (Merletti, et al., 2004), (2) a natureza irregular das descargas das MUs e (3) a quantidade de potenciais de ação de unidades motoras. Porém, as referências (Karlsson, et al., Feb. 2000), (Merletti, et al., 1992)

indicam que o sinal eletromiográfico pode ser considerado um processo estocástico estacionário no sentido amplo<sup>4</sup>, sob condições de contração de baixa intensidade (MVC *Maximal Voluntary Contraction* [20-30]%) e curtos intervalos de tempo de contração [20-40]seg. Quando a intensidade da contração é incrementada, a hipótese de estacionariedade no sentido amplo é válida para intervalos de tempo de contração menores ([500-1500]ms com MVC [50-80]%). Portanto, o sinal eletromiográfico pode ser considerado um processo estocástico estacionário em aplicações com tempo de resposta menor de 500ms.

## 2.2.2 - Medição do sinal Eletromiográfico

Existem vários tipos de eletrodos para registrar o sinal eletromiográfico, sendo que estes podem ser classificados em duas categorias: (a) eletrodos de medição de superfície e (b) eletrodos de medição intramuscular. A seguir são apresentadas algumas informações gerais desses grupos, informações mais detalhadas podem ser consultadas em (Merletti, et al., 2004), (Merletti, et al., 2009).

### 2.2.2.1 - Eletrodos de Superfície

A eletromiografia de superfície (SEMG) é um método de coleta de sinais seguro, não invasivo e simples. Nesse caso, eletrodos metálicos são localizados na superfície da pele com o propósito de registrar a atividade elétrica dos músculos ativados durante o movimento. Em algumas aplicações de eletromiografia, nas quais é importante evitar a dor durante a execução de movimentos, é preferível utilizar esse tipo de medição. Essas aplicações encontram-se, principalmente, no campo do *biofeedback*, do controle de próteses, da ergonomia, da medicina esportiva e da terapia ocupacional e análise de movimento (Merletti, et al., 2004). As maiores críticas desse tipo de medição são as seguintes (Hargrove, et al., 2007) (De Luca, 2006):

---

<sup>4</sup>Segundo (Athanasios, 1991) um processo  $x(t)$  é chamado estacionário no sentido amplo (WSS *WideSenseStationary*) se sua média é constante:

$$E[x(t)] = \eta$$

e sua auto-correlação só depende do intervalo de tempo  $\tau$  entre as variáveis consideradas.  $\tau = t_1 - t_2$

$$R(\tau) = E[x(t+\tau)x^*(t)]$$

- A contribuição dos músculos que ficam longe da superfície é limitada devido aos efeitos da filtragem derivados da eletromiografia de superfície. Os efeitos de filtragem mais comuns são: o gerado pelos tecidos gordurosos do corpo humano e o efeito de filtragem passa baixa provocado na interface eletrodo-pele (Merletti, et al., 2009).
- A grande quantidade de *crossstalk* entre músculos. O *crossstalk* muscular é o sinal detectado num músculo, mas gerado por outro músculo perto do primeiro (Merletti, et al., 2004). Esse efeito é exclusivo da eletromiografia de superfície, sendo que alguns fatores que influem no nível de *crossstalk* são: (a) a distribuição geométrica dos músculos, (b) a propagação dispersiva do sinal no volume condutor, a qual é mais intensa pelo efeito do tecido de gordura subcutânea (Lowery, et al., 2002) e (c) a distância entre canais de aquisição (Mogk, et al., 2003).

#### 2.2.2.2 - Eletrodos de medição Intramuscular

A principal vantagem na medição intramuscular é a redução no efeito de filtragem originado pelo tecido, devido à inexistência da gordura ou pele entre a fonte de sinal e o eletrodo. Como consequência desse método de medição, obtém-se um sinal de EMG de maior qualidade e, praticamente, sem conteúdo de *crossstalk* (Hargrove, et al., 2007). Existem várias alternativas de eletrodos, entre elas: (a) eletrodos de agulhas, (b) eletrodos de fios finos, (c) sensores mioelétricos implantáveis (IMES) e (d) eletrodos de eletrônica epidérmica.

Os eletrodos de agulhas de menor tamanho podem chegar a registrar potenciais de ação de fibras musculares independentes. Aqueles com maior superfície ativa podem registrar o potencial de ação de unidades motoras (MUAPs) (Koch, 2007). Quando são utilizados eletrodos de agulha durante contrações dinâmicas, a distância entre a ponta do eletrodo e a fibra muscular muda durante a contração dos músculos. Nesses casos, é mais conveniente utilizar eletrodos de fios finos. Estes são inseridos no músculo com ajuda de agulhas, depois a agulha é removida e os fios ficam dentro do músculo. Uma vantagem dessa alternativa com relação aos eletrodos de agulha é que estes últimos geram menor dor ao paciente durante a execução dos movimentos.

### 2.2.2.3 - Eletrodos para o controle eletromiográfico de próteses.

Na pesquisa publicada em (Hargrove, et al., 2007) é feita uma comparação entre eletrodos de superfície e eletrodos intramusculares. O critério de comparação é a precisão atingida no sistema de controle eletromiográfico. A comparação é feita para sistemas baseados em reconhecimento de padrões. Os autores concluem que os desempenhos de classificação obtidos a partir das alternativas de eletromiografia de superfície e eletromiografia intramuscular são de alto nível, sendo que não existe uma diferença significativa. Essa conclusão justifica o uso da eletromiografia de superfície nos sistemas de controle eletromiográfico.

Com relação à configuração do eletrodo de superfície, o modo *diferencial simples* (SD) é o preferido para as aplicações de controle eletromiográfico. Nesse modo é registrada a diferença entre potenciais detectados por dois eletrodos localizados em uma distância fixa (IED, do inglês *Interelectrode Distance*) ao longo da direção da fibra muscular (Merletti, et al., 2009). Para se obter um canal bipolar de informação com configuração SD é necessário no mínimo um *duotrodo* (estrutura com dois eletrodos fixos e separados) e um eletrodo de referência.

A estratégia de medição preferida é a chamada de *canais múltiplos bipolares* (Kuruganti, et al., 1995) (Englehart, et al., 2001). Essa configuração utiliza *duotrodos* múltiplos com distâncias pequenas entre eles, com objetivo de capturar a atividade elétrica de diferentes grupos de músculos em determinada região (Merletti, et al., 2004).

Os sinais de EMG mencionados neste documento de dissertação são sinais de EMG de superfície, obtidos com *duotrodos* adesivos fabricados pela 3M (Ag-AgCl). Maiores detalhes sobre esses sinais são apresentados no Capítulo 4.

### **2.2.3 - Pré-processamento do sinal Eletromiográfico**

Nesta seção apresenta-se um resumo das etapas de pré-processamento do sinal de EMG, maiores detalhes podem ser encontrados em (Merletti, et al., 2009), (De Luca, 2003), (Henrique Veneziano, 2006). A descrição é feita considerando um sistema de aquisição de um único canal. Para o caso multicanal o processamento é o mesmo em cada canal.

O sinal elétrico gerado pelos músculos é de baixa amplitude (da ordem dos milivolts) portanto, é necessário fazer uma amplificação do sinal. Essa amplificação deve garantir um sinal de saída na ordem dos volts, compatível com a faixa de entrada do conversor analógico digital (A/D) e com baixo conteúdo de ruído. Para o caso particular de medições em modo SD, em que um canal está composto pela informação gerada em um par de eletrodos, utiliza-se um esquema de amplificador diferencial. O esquema SD adquire o sinal dos eletrodos e calcula o sinal diferencial mediante subtração dos sinais em cada eletrodo. A vantagem desse esquema é a eliminação do ruído comum aos dois eletrodos, o que permite recuperar o sinal de EMG mais próximo do original.

A etapa seguinte é a filtragem analógica. Por meio dela tenta-se eliminar ruídos e selecionar os componentes de frequência mais importantes do sinal de EMG. Os componentes de ruído são localizados em duas bandas de frequência (Merletti, et al., 2001): (a) abaixo dos 10Hz, onde as componentes nesta faixa são geradas por movimento dos eletrodos e potenciais galvânicos da pele (Merletti, et al., 2009), e (b) acima da frequência de 500Hz. O ruído nesta faixa é gerado por sinais provenientes de equipamentos externos, ou como interferência dos componentes de processamento do sinal (Merletti, et al., 2009). A filtragem nesta última faixa também é necessária para eliminar os efeitos de *aliasing* dos componentes de frequência durante o processo de digitalização do sinal.

A próxima etapa do processo é a conversão A/D. Considerando o fato de que a frequência máxima do sinal EMG é de 500Hz, o critério de Nyquist estabelece que o sistema de digitalização apresente uma taxa de amostragem mínima de 1000Hz. O número de bits do conversor A/D deve ser suficiente para capturar as variações significativas na amplitude do sinal de EMG, mas não pode ser tão alto para evitar que componentes de ruído sejam digitalizadas. A Tabela 2-1 apresenta os parâmetros recomendados pelo grupo de trabalho SENIAM (Hermens, et al., 1999) para as etapas de pré-processamento do sinal EMG.

Os dados digitalizados precisam ser armazenados para análise posterior ou intercâmbio com outros pesquisadores. Seria útil que a comunidade científica utilizasse formatos padronizados para aquisição dos sinais de EMG. Entretanto, embora existam algumas propostas (McGill, 2006) (LACERDA, et al., 2010), ainda não há um padrão com aceitação geral.

Tabela 2-1. Parâmetros recomendados pelo SENIAM (*Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles*) para a etapa de pré-processamento do sinal EMG. Fonte: (Hermens, et al., 1999)

<b>Parâmetro</b>	<b>Valor Recomendado</b>
Filtro passa-alta:	
<i>Para análise espectral</i>	<10Hz
<i>Para análise de movimento somente</i>	10-20Hz
Filtro passa-baixa	
<i>Para aplicações gerais</i>	~500Hz (amostragem > 1000Hz)
<i>Para aplicações especiais</i>	~1000Hz (amostragem [2000-4000]Hz)
Nível de ruído de entrada (tensão)	<1 $\mu V_{RMS}$ (banda [10-500]Hz)
Nível de ruído de entrada (corrente)	<10 $pA_{RMS}$ (banda [10-500]Hz)
Impedância de entrada	>100 <i>Mohms</i> (eletrodos convencionais)
Ganho	O suficiente para compatibilizar o sinal como o número de bits do conversor A/D
Número de bits do conversor A/D	12 ou 16

#### 2.2.4 - Discussão sobre os aspectos básicos de eletromiografia

Nesta seção foram apresentados os conceitos básicos relacionados com a eletromiografia, os quais foram importantes para o desenvolvimento deste trabalho. A discussão dos mesmos foi focada nos tópicos relevantes no estudo dos *sistemas de controle mioelétrico de próteses de mão*.

A apresentação foi dividida em três partes. Na primeira parte (fisiologia do sinal eletromiográfico) foram descritos o sistema nervoso, as unidades motoras e as interações existentes durante a contração das fibras musculares para a geração do sinal de EMG. Também foram indicadas algumas características estatísticas e elétricas do sinal de EMG: (a) modelo probabilístico, (b) faixa de amplitude e (c) largura de banda. Como conclusões importantes desta seção destacam-se:

- O sinal eletromiográfico pode ser considerado um processo estocástico estacionário no sentido amplo em aplicações de controle mioelétrico. Isto acontece como consequência de que o tempo de resposta definido para esse tipo de aplicações é menor do que o limite onde se perde a hipótese de estacionariedade (500-1500ms).

- A alta variabilidade do sinal de EMG entre diferentes sujeitos justifica o processamento independente do sistema de classificação; ou seja, é necessário configurar, assim como avaliar o sistema de classificação para cada usuário.
- Os componentes de frequência do sinal EMG encontram-se na banda [10 - 400]Hz

A segunda parte da discussão (sistemas de medição e pré-processamento) definiu aspectos relacionados com a medição do sinal de EMG. Inicialmente, foram apresentados os dois tipos de eletrodos mais comuns em aplicações de controle mioelétrico. Posteriormente, foram tratados aspectos acerca da configuração do eletrodo durante a medição e a estratégia de medição de sinais. Finalmente, foi resumido o esquema de pré-processamento feito sobre cada canal EMG adquirido, onde esta informação permitiu estabelecer o seguinte:

- Os eletrodos de superfície são tão apropriados quanto os eletrodos intramusculares, no contexto do controle eletromiográfico baseado em reconhecimento de padrões. No entanto, existe uma vantagem de comodidade e conforto que favorece o uso dos eletrodos de superfície.
- O esquema de medição diferencial simples (*SD single diferencial*) é o preferido para a aplicação de controle mioelétrico.
- A estratégia de aquisição multicanal tem apresentado desempenhos de classificação superiores que as estratégias de único canal. Essa superioridade é justificada pela maior quantidade de informação registrada no caso multicanal.

### **2.3 - SISTEMAS DE CONTROLE MIOELÉTRICO BASEADOS EM RECONHECIMENTO DE PADRÕES**

Nesta seção são apresentadas as etapas envolvidas no processo de classificação dos sinais eletromiográficos no contexto de um *sistema de controle mioelétrico de próteses de mão*. Esse sistema é dividido em três etapas: (a) extração de características, (b) redução de dimensionalidade e (c) classificação de padrões. Para cada uma dessas etapas é descrito o propósito, as abordagens mais comuns assim como os seus efeitos sobre o erro de classificação. Finalmente, são apresentadas etapas de processamento complementares que procuram melhorar o desempenho de classificação destes sistemas.

### 2.3.1 - Formulação do problema de Classificação nos sistemas de controle mioelétrico.

Os sistemas de controle mioelétrico baseados em reconhecimento de padrões são um caso particular de sistemas de classificação onde os padrões são características dos sinais de EMG e as classes representam o tipo de movimento realizado ou desejado. Esses sistemas assumem que para uma localização de eletrodos fixa, o conjunto de características do sinal de EMG será *repetível* para um estado particular de ativação determinado dos músculos e *distingüível* entre um estado de ativação e outro (Graupe, et al., 1982). A seguir é definida a terminologia utilizada na área de controle mioelétrico (Hargrove, et al., 2009):

- Sítio de Controle (*Control Site*): área na superfície da pele, acima do músculo do qual o sinal de EMG vai ser adquirido.
- Canal (*channel*): medição bipolar feita com dois eletrodos localizados no sítio de controle.
- Característica (*feature*): descritor do sinal de EMG ao longo de uma janela de tempo definida.
- Grau de Liberdade (DOF): é uma rotação ao redor de uma articulação ou um eixo de coordenadas.
- Classe de movimento (*Class Motion*): qualquer ação que a prótese é capaz de realizar em uma direção e com um ou mais graus de liberdade. Por exemplo, flexão e extensão do pulso são classes de movimento que envolvem um grau de liberdade (rotação ao redor da articulação do pulso). Uma classe de movimento também inclui movimentos pré-programados que envolvem mais de um grau de liberdade como no caso de manipulação de objetos.

Nos sistemas de controle mioelétrico com múltiplos canais de aquisição, cada padrão é representado como um vetor  $x \in X \subset \mathcal{R}^{N \times M}$  onde  $M$  é o número de observações e  $N$  o número de canais. Nesta seção vamos considerar que  $x$  é uma janela de medições representando um único padrão; portanto, podemos interpretar  $M$  como o número de observações na janela.

Cada padrão  $x$  deve pertencer a uma das  $C$  classes de movimento denotadas como  $y_c$ . Podemos dizer então que  $X \subset \mathcal{R}^{N \times M}$  é o espaço de entrada e  $Y \subset \{y_1, \dots, y_C\}$  é o espaço de saída. O espaço de saída é simplesmente um conjunto de  $C$  etiquetas de classes,

representando cada classe de movimento que o sistema pode classificar. Portanto  $X \times Y$  é o conjunto de todos os pares de sinais de entrada e classes de saída correspondentes. Desta forma, a classificação do sinal de EMG pode ser interpretada como uma função  $d : X \rightarrow Y$ , que atribui uma etiqueta de classe para cada padrão de entrada  $x$  (Englehart, 1998). É importante levar em conta que o mapeamento direto do vetor de medições  $x$  para o espaço de saída apresenta as seguintes dificuldades (Englehart, 1998) (Romo, 2008):

- O tempo de resposta finito do sistema. O espaço do sinal  $x$  é de alta dimensão (geralmente  $M=256$  amostras,  $2 < N < 16$ ) e o tempo de processamento desses dados é superior ao permitido pelo sistema.
- A presença de ruído e redundância no sinal  $x$  reduz a precisão do processo de classificação.

Por isso, prefere-se extrair do espaço original  $\mathfrak{R}^{M \times N}$  um conjunto de características capazes de descrever a informação discriminativa do vetor  $x$  num espaço dimensional reduzido, ou seja, utilizando-se um vetor de características  $v \in V \subset \mathfrak{R}^{1 \times LN}$  com  $L < M$ . Onde  $L$  é um conjunto de características extraído por canal. O processo de extração de características pode ser definido como o mapeamento  $f : X \rightarrow V$ . No caso em que a dimensão  $\mathfrak{R}^{1 \times LN}$  continue sendo grande, é possível adicionar uma etapa de *redução de dimensionalidade* que a partir do vetor  $v$  busca escolher o subconjunto de amostras  $z \in Z \subset \mathfrak{R}^{1 \times KN}$  com maior quantidade de informação discriminativa, garantindo que  $K < L$ . Esse processo pode ser interpretado como uma função  $r : V \rightarrow Z$ . Neste ponto, o classificador pode ser representado como o mapeamento  $g : Z \rightarrow Y$ . Considerando as transformações indicadas, o processo de classificação completo pode ser interpretado como a função  $d = f \circ r \circ g$

Na Figura 2-5 é apresentado um diagrama de blocos que resume os processos de mapeamento do sistema de classificação. Nessa Figura a etapa de extração de características é definida como o primeiro processamento sobre o sinal EMG, que gera o conjunto original de características:  $v \in V \subset \mathfrak{R}^{1 \times LN}$ . O conjunto gerado é submetido ao processo de redução de dimensionalidade até obtermos o conjunto reduzido de características:  $z \in Z \subset \mathfrak{R}^{1 \times KN}$ . O propósito na redução de dimensionalidade é rejeitar os dados considerados como ruído, reduzir a complexidade do classificador e incrementar sua capacidade de generalização. Finalmente, o sistema classificador mapeia o conjunto

reduzido de características para o espaço de saída  $\hat{y}$ . O espaço de saída pode ser interpretado como o conjunto de classes de movimento previstas pelo sistema.

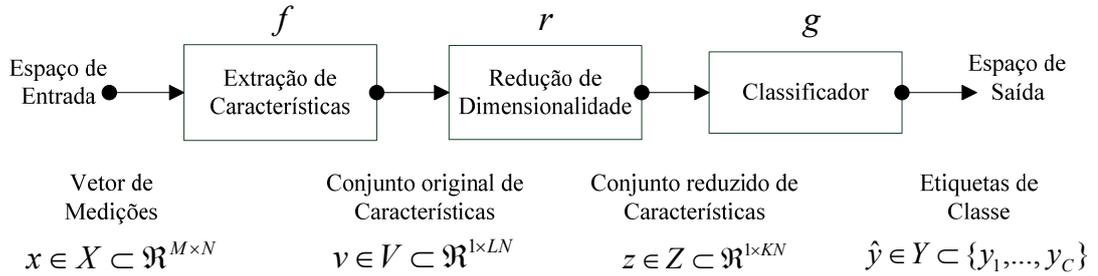


Figura 2-5. Diagrama de blocos do processo de classificação para um sistema de controle EMG multicanal

O desenvolvimento dos sistemas de classificação é feito em três etapas: (1) *experimentos supervisionados*, (2) *configuração de parâmetros* do classificador e (3) *avaliação do sistema*. Na primeira etapa um conjunto de classes de movimento  $y$  que chamaremos de *classe alvo* é estabelecido pelo experimentador; posteriormente, o usuário do sistema é estimulado a executar este conjunto de classes. Enquanto os movimentos são executados, um sistema de aquisição de sinais registra as amplitudes dos potenciais eletromiográficos gerados. No final desta etapa obtém-se um conjunto de dados ou *bases de dados*  $\mathfrak{S}$  composta por sinais eletromiográficos  $x$  e classes de movimento associadas  $y$ .

Na segunda etapa são calculados os parâmetros configuráveis do classificador. Para tanto, é utilizado um subconjunto  $\mathfrak{S}_{tr}$  de  $M_1$  dados de treinamento extraído da base de dados  $\mathfrak{S}$  de pares padrão-classe. Os  $M_2$  elementos de  $\mathfrak{S}$  não utilizados na segunda etapa de desenvolvimento são destinados à avaliação de desempenho, e compõem o subconjunto  $\mathfrak{S}_t$  de padrões de teste. Assim,

$$\mathfrak{S} = \mathfrak{S}_{tr} \cup \mathfrak{S}_t \quad (2-1)$$

em que,

$$\mathfrak{S}_{tr} = \{(x^{(1)}, y^{(1)}), \dots, (x^{(M_1)}, y^{(M_1)})\}$$

$$\mathfrak{S}_t = \{(x^{(1)}, y^{(1)}), \dots, (x^{(M_2)}, y^{(M_2)})\}$$

sendo que o índice sobrescrito <sup>(i)</sup> representa o  $i$ -ésimo par padrão-classe.

Na terceira etapa é avaliado o sistema de classificação. Para este fim é utilizado um subconjunto  $\mathfrak{S}_t$  da base de dados adquirida na etapa 1, sendo este chamado de *dados de teste* e consiste de  $M_2$  pares de padrões e etiquetas de classe  $(x_t^{(i)}, y_t^{(i)})$  com  $i \in \{1, 2, \dots, M_2\}$ . O processo de avaliação é feito em dois ciclos: (a) fornecimento dos sinais EMG de teste para o sistema classificador e registro do conjunto de classes preditas  $\hat{y}_t^i$  e (b) comparação entre as classes preditas  $\hat{y}_t^i$  e as classes alvo  $y_t^i$ . O indicador mais comum para realizar esta comparação é o *erro de classificação*. Este erro é avaliado de maneira independente para cada usuário do sistema, e é dado por<sup>5</sup>:

$$erro = \frac{1}{M_2} \sum_{i=1}^{M_2} e_i, \quad (2-2)$$

em que

$$e_i = \begin{cases} 0 & \text{se } y_t^i = \hat{y}_t^i \\ 1 & \text{Caso contrário} \end{cases}$$

A equação (2-2) apresenta a relação entre o número de classes mal preditas e o total de classes preditas pelo sistema de controle. Além de utilizar o erro de classificação para avaliar o sistema, também são utilizados outros indicadores:

- 1) A complexidade computacional.
- 2) Tempo de resposta do sistema. Esse tempo foi estudado em (Farrell, et al., 2007) concluindo que o retardo ideal para o controlador de próteses teria que estar na faixa [100-175] ms. Pode ser observado que, considerando esse tempo de resposta, é válido assumir o sinal EMG como um processo estocástico estacionário no sentido amplo (vide seção 2.2.3).
- 3) Recentemente tem-se reportado a *usabilidade* como indicador para quantificar a funcionalidade do sistema de controle de próteses (Lock, et al., 2005), (Hargrove, et al., 2010).

A seguir, apresentamos as etapas de processamento consideradas na Figura 2-5.

---

<sup>5</sup> Esta é uma definição ideal do erro de classificação válida para janelas de classificação compostas por uma única amostra.

### 2.3.2 - Pré-processamento

Antes de definir o espaço de entrada  $x$ , a partir dos sinais eletromiográficos, é necessário fazer um processamento prévio sobre as amostras adquiridas pelos eletrodos. Esse processamento inclui etapas de amplificação, filtragem e digitalização do sinal de EMG.

### 2.3.3 - Extração de características

Nesta seção é apresentado o processo de extração de características, que é dividido em duas etapas: (a) *janelamento*, (b) *cálculo das características*.

#### 2.3.3.1 - Janelamento

Devido à natureza aleatória do sinal eletromiográfico seu valor instantâneo não é apropriado para propósitos de controle. Conseqüentemente, é necessário definir janelas de dados a partir das quais as características são extraídas. Essas janelas têm que ser suficientemente pequenas para evitar retardos excessivos no processamento, mas, suficientemente grandes para que possam conter informação que gere uma decisão confiável do classificador.

Existem duas alternativas de janelamento: (1) *adjacente* e (2) com *superposição*. No primeiro caso, as janelas são segmentos de comprimento pré-definido que vão se deslocando adjacente como se ilustra na Figura 2-6 (vide W1, W2, W3). Uma vez adquirida a janela, o sistema de processamento faz a extração de características e classificação; a classe predita  $\hat{y}$  é gerada depois de um tempo de processamento indicado como  $\tau$  na Figura 2-6. Geralmente o tempo de processamento é pequeno, com relação ao comprimento da janela, e o processador fica ocioso durante a maior porção de tempo da janela.

No janelamento adjacente, tenta-se eliminar o tempo de ócio do processador e gerar maior densidade de classes preditas por unidade de tempo. Para isso, cada nova janela é formada a partir do deslizamento temporal ao longo da janela atual como se ilustra na Figura 2-7 (vide R1, R2, R3). O deslizamento tem que ser menor do que o comprimento da janela e maior do que o tempo de processamento  $\tau$ . Desta forma, garante-se que o sistema calcule a nova classe  $\hat{y}$  antes que a janela seguinte seja adquirida.

Segundo o reportado em (Huang, et al., 2005), o desempenho do classificador é superior quando é utilizado janelamento com superposição. A principal consequência desse janelamento é o incremento na quantidade de lotes de dados para processamento. Esse

incremento garante maior quantidade de informação relevante para o treinamento do classificador. A desvantagem associada é o incremento na complexidade computacional e nos tempos de processamento, como consequência do maior volume de dados.

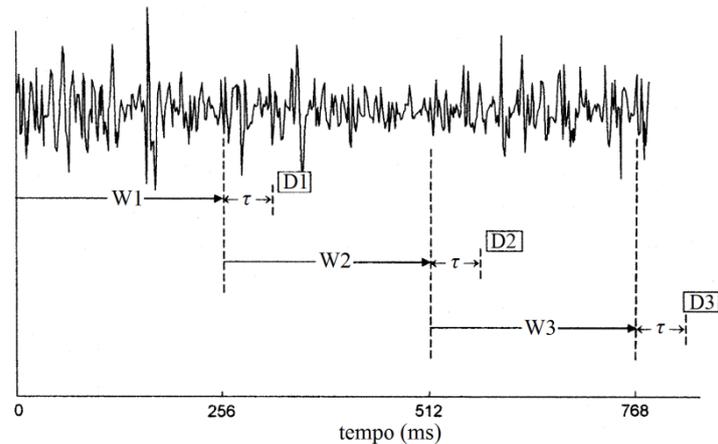


Figura 2-6. Janelamento adjacente. Fonte (Englehart, et al., 2003)

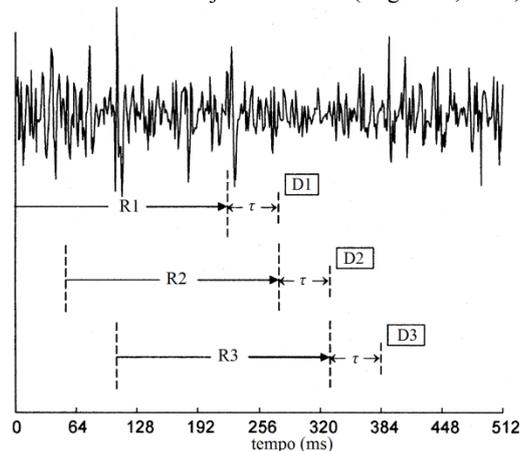


Figura 2-7. Janelamento com superposição. Fonte (Englehart, et al., 2003)

O comprimento das janelas tem um efeito direto no erro de classificação. Janelas de maior comprimento acumulam mais informação discriminativa para o sistema de classificação, conseqüentemente se assume menores erros de classificação. Porém, as janelas grandes provocam retardos excessivos do sistema que prejudicam o controle da prótese pelo usuário. Esse tipo de correlação é pesquisada em (Smith, 2011), onde concluem que o comprimento de janela ótimo deve estar na faixa [150-250]ms.

### 2.3.3.2 - Cálculo das Características.

Uma vez adquirida a janela de dados, a etapa seguinte é o cálculo das características. Estas podem ser definidas como descritores do sinal de EMG ao longo da janela de dados. O propósito nesta etapa é calcular as características mais relevantes no intuito de

preservar a separabilidade entre as classes do sistema e rejeitar aquelas que são irrelevantes do ponto de vista da classificação (por exemplo, características de ruído). Geralmente, esse processo é dependente da aplicação específica e do sistema classificador utilizado, ou seja (Englehart, 1998):

- As melhores características num projeto de compressão de sinais podem não ser as melhores em um projeto de classificação.
- As características ótimas para um classificador podem não ser ótimas para outro classificador.

Na atualidade, tem-se pesquisado uma ampla gama de alternativas da dupla característica/classificador, para o problema de *controle mioelétrico*. A seguir se faz um resumo das publicações mais recentes que relacionam o erro de classificação e o conjunto de características utilizado para descrever o sinal EMG.

Com o propósito de extrair maior quantidade de informação discriminativa do sinal de EMG, tem-se proposto conjuntos de características compostas. Por exemplo, Hudgins et al. (Hudgins, et al., 1993) avaliaram vetores de características compostos por cinco atributos temporais (TD, *Time Domain*): valor absoluto do valor médio (MAV, *Mean Absolute Value*), inclinação do MAV (MAVS *Mean Absolute Value Slope*), passagem por zero do sinal de EMG (ZC, *Zero Crossings*), trocas de sinal (SSC, *Slope Sign Changes*) e comprimento de onda (WL, *Wave Length*). Como resultado, obtiveram um erro médio de classificação de 9.25% em um problema de 4 classes de movimento, 2 canais de aquisição e quinze sujeitos (9 sem amputação e 6 com amputação).

Cinco anos mais tarde, Englehart et al. (Englehart, 1998) analisaram o desempenho de classificação utilizando a etapa transiente do sinal de EMG. A análise feita é do tipo comparativo e foram consideradas características em três domínios: (a) tempo, (b) tempo-frequência e (c) tempo-escala. As características temporais foram as mesmas reportadas em (Hudgins, et al., 1993). Como características tempo-frequência utilizaram os coeficientes obtidos a partir da transformada de Fourier de tempo curto (STFT) do sinal de EMG. As características tempo-escala foram obtidas a partir das transformações *wavelet* discreta (DWT) e por pacotes (WPT). Os testes foram feitos para um problema de 4 classes de movimento, 2 canais de aquisição e 16 sujeitos sem amputação. Os resultados permitiram concluir reduções progressivas no erro de classificação na sequência de características: TD, STFT, DWT, WPT. Essa publicação demonstra a

superioridade das características tempo-escala na classificação do sinal eletromiográfico de etapa transiente. Neste caso, o menor erro reportado foi de 6.25%.

Em 2001, Englehart et al. (Englehart, et al., 2001) compararam a quantidade de informação discriminativa nas etapas transiente e estacionária do sinal EMG. A partir da comparação, os autores concluíram que a etapa estacionária apresenta maior quantidade de informação discriminativa. Para classificar o sinal de EMG de estado estacionário, Englehart et al. utilizaram as características do domínio tempo, tempo-frequência e tempo-escala definidas em (Hudgins, et al., 1993), junto com características formadas a partir de indicadores de correlação e correlação cruzada dos sinais de EMG. Os menores erros médios de classificação foram obtidos com as características DWT e WPT, erros de 7.8% e 6.8% respectivamente, em um problema de 6 classes de movimento, 4 canais de aquisição e 11 sujeitos sem amputação.

No ano de 2003, Englehart e Hudgins (Englehart, et al., 2003) indicaram que o esquema de classificação chamado de *contínuo* (classificação da etapa estacionária do sinal de EMG) junto com aquisição multicanal e características temporais<sup>6</sup> é uma combinação que atinge índices de classificação superiores, sendo que não existe vantagem de utilizar transformações tempo-escala para a análise do sinal de EMG de estado estacionário. Adicionalmente, os autores reportam que foram feitos testes no classificador contínuo comparando o erro de classificação das características WPT, DWT, TD e STFT. Os melhores desempenhos foram atingidos com as características TD. Para o problema de 4 classes de movimento, 4 canais de aquisição e 12 sujeitos sem amputação o menor erro médio atingido foi de aproximadamente 5% utilizando comprimentos de janela de 256ms.

Em 2005, Huang et al. (Huang, et al., 2005) continuaram experimentando com o esquema de classificação contínuo. Nesta pesquisa são utilizados como características: o valor médio quadrático (RMS) do sinal e os primeiros seis coeficientes do modelo autoregressivo do sinal (AR6, *6th order Autoregressive Coeficients*). O desempenho de classificação atingido é comparado com sistemas baseados em características TD, AR6+RMS e AR+RMS+TD. Os menores erros médios de classificação foram atingidos

---

<sup>6</sup> As características utilizadas foram TD: ZC *Zero Crossing*, WL *Wave Length*, SSC *Slope Signal Changes*, MA *Mean Absolute*.

com a combinação de características: AR6+RMS e AR6+RMS+TD sendo 3.7% e 3.09%, respectivamente; em um problema de 6 classes de movimento, 4 canais de aquisição e doze usuários sem amputação.

A superioridade de classificação com características AR+RMS foi confirmada por Hargrove et al., em 2007 (Hargrove, et al., 2007), e Oskoei et al., em 2008 (Oskoei, et al., 2008). Este último obteve um erro de classificação aproximado de 3% num problema de 5 classes de movimento, 4 canais de aquisição e 11 sujeitos sem amputação. Nessa pesquisa, os autores também indicaram que, utilizando o conjunto de características (MAV + WL + ZC + SSC), é possível atingir o mesmo erro de classificação que com RMS +AR6, mas, com um sistema de menor complexidade computacional.

Na Figura 2-8, Hargrove et al. (Hargrove, et al., 2007) apresentam uma comparação de 6 alternativas de características avaliadas entre os anos 1993 e 2007 na literatura de *controle mioelétrico*.

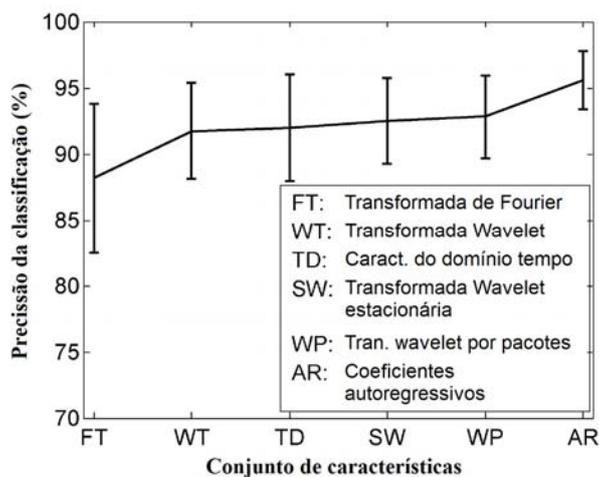


Figura 2-8. Comparação do desempenho atingido com seis conjuntos de características utilizando o classificador LDA. Modificado de (Hargrove, et al., 2007)

O problema de classificação avaliado na Figura 2-8 foi de 6 classes de movimento, 4 canais de aquisição e 12 sujeitos sem amputação. O índice de comparação utilizado é a precisão de classificação definida como o complemento do erro de classificação (vide equação (2-2)). A comparação indica a superioridade do conjunto de características AR com desempenhos de classificação maiores aos 95%. Especificamente, foram calculados os parâmetros de um modelo AR6. As linhas verticais na figura indicam a

variância entre usuários do sistema. O artigo reporta que esse comportamento é conservado entre diversos classificadores utilizados durante a experimentação (a lista de classificadores é apresentada na Figura 2-9).

Levando em conta que o conjunto de características AR e RMS, sobre a etapa estacionária do sinal eletromiográfico, tem atingido os mais altos desempenhos de classificação no sistema de controle mioelétrico, no Apêndice A - se faz uma descrição detalhada das características AR e RMS.

### **2.3.4 - Redução de dimensionalidade**

Existem diversas razões que justificam a redução da dimensão do vetor de características do sinal EMG. Uma delas é a complexidade computacional do sistema de classificação. Outra é a capacidade de generalização do classificador. Essa capacidade é proporcional à relação  $T/Q$ , onde  $T$  é o número de padrões de treinamento e  $Q$  o número de parâmetros configuráveis do classificador (Theodoridis, et al., 2006).

Vetores de características de grandes dimensões são traduzidos em classificadores com maior quantidade de parâmetros configuráveis,  $Q$ . Conseqüentemente, é necessário garantir que a dimensão do vetor de características seja suficientemente baixa para conservar o nível de generalização do classificador. Por outro lado, a dimensão do vetor de características tem que ser suficientemente grande para conservar a quantidade de informação discriminativa dos padrões de classificação. Existem duas abordagens para resolver o problema da redução de dimensionalidade: (a) *seleção de características* e (b) *projeção de características*.

Os métodos baseados em seleção de características tentam reduzir a dimensão mediante escolha de um subconjunto  $z$  a partir do conjunto de características originais  $v$ . Essa escolha é baseada na comparação de uma função custo, definida em termos das características originais. A vantagem da seleção de características é que se consegue preservar a identidade original das características, o que é útil na avaliação da eficiência de classificação das características individuais (Englehart, 1998). A principal desvantagem é a rejeição de algumas características originais e conseqüentemente a eliminação da informação discriminativa que pode ser relevante para a classificação. Isso é um problema em dados onde a informação discriminativa está espalhada no conjunto original de características  $v$ . Os algoritmos propostos para resolver o problema de seleção de características têm que definir: *algoritmo de busca e função custo*. A

função custo é basicamente uma função que permite estabelecer quando um subconjunto de amostras do vetor  $z$  tem maior quantidade de informação discriminativa do que outro subconjunto. O método de busca define a estratégia a partir da qual serão escolhidos os subconjuntos de amostras do vetor  $z$  antes de serem avaliados com o critério de juízo (Theodoridis, et al., 2006). Para escolha do critério de juízo existem duas alternativas comuns: (a) índices baseados em medidas de separabilidade das classes e (b) índices baseados no desempenho de classificação. Para escolha do método de busca existem duas abordagens: (a) buscas ótimas ou exaustivas, (b) buscas subótimas (Theodoridis, et al., 2006), (Englehart, 1998). Esse tópico será abordado com maior detalhe no capítulo seguinte.

Por outro lado, os métodos de projeção de características procuram reduzir a dimensão garantindo a menor perda de informação. O processo pode ser resumido em três etapas:

- 1) Inicialmente, realiza-se uma combinação (ou projeção) do conjunto original de características  $v$ .
- 2) Posteriormente, realiza-se um reordenamento de características no domínio projetado procurando otimizar uma *função custo*.
- 3) Finalmente, as  $KN < LN$  primeiras características são escolhidas para formar o novo conjunto reduzido  $z$ .

A vantagem desse método é a geração do conjunto de dimensões reduzidas sem a rejeição total das características originais.

Alguns algoritmos reportados na literatura de controle mioelétrico para redução de dimensionalidade por projeção de características são (Englehart, 1998), (Chan, 2007):

- a) Análise dos componentes principais (PCA)
- b) Análise discriminativa linear (LDA)
- c) Análise discriminativa linear sem correlação (ULDA)

Em (Chan, 2007), apresenta-se uma análise comparativa desses algoritmos. A comparação é feita no contexto do controle mioelétrico e utilizando como métrica de comparação o desempenho de classificação. Os resultados obtidos indicam a superioridade do algoritmo ULDA.

Tanto as técnicas por seleção de características quanto as técnicas por projeção de características fazem uso da função custo. Quando esta função toma entre seus

argumentos informação de pertinência às classes de movimento, então, a redução de dimensionalidade é considerada *supervisionada*. Quando ao contrário, a função custo não inclui informação de pertinência às classes, o processo é considerado *não supervisionado*

#### 2.3.4.1 - ULDA (Uncorrelated Linear Discriminant Analysis).

A técnica LDA é uma ferramenta de análise de sinal utilizada tanto para classificação como para redução de dimensionalidade. Para definir LDA como técnica de redução de dimensionalidade, considera-se um conjunto de dados de altas dimensões agrupado por classes. LDA permite fazer uma transformação linear ótima desse conjunto para um domínio de menor dimensão onde a distância entre padrões da mesma classe é minimizada e a distância entre classes diferentes é maximizada. Essas distâncias podem ser calculadas com base nas matrizes de dispersão (*scatter matrices*) definidas no Apêndice B - .

A técnica ULDA é uma variante do algoritmo LDA onde se garante que as características reduzidas têm correlação mútua nula. A principal diferença com LDA é que o algoritmo ULDA converge para casos de singularidade nas matrizes de dispersão (Hargrove, et al., 2010). A definição matemática do algoritmo LDA é apresentada em (Theodoridis, et al., 2006), (Duda, et al., 2000) e uma forma eficiente para o cálculo do algoritmo ULDA é apresentada em (Ye, et al., 2004), (Ye, et al., 2006).

#### 2.3.5 - O Classificador de padrões

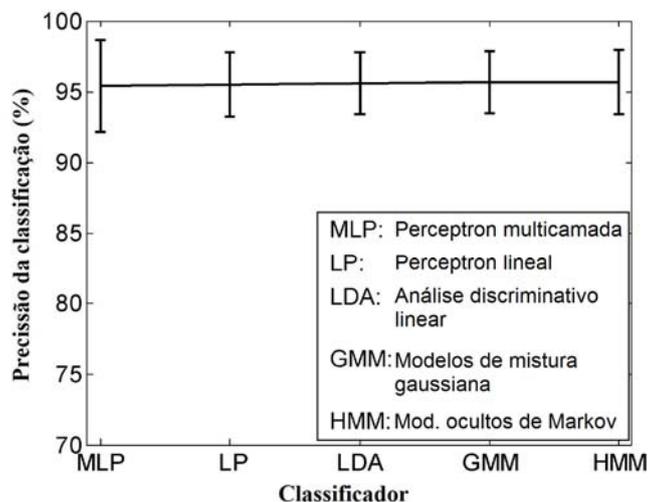


Figura 2-9. Comparação do desempenho atingido entre cinco classificadores diferentes. Fonte (Hargrove, et al., 2007). Problema de classificação de 6 classes de movimento, 4 canais de aquisição e 12 sujeitos sem amputação

O propósito do classificador é dividir o espaço de entrada em regiões, de forma que cada uma corresponda a uma classe de movimento. Na atualidade se tem reportado diversas alternativas para desenvolver essa etapa, sendo que algumas das propostas avaliadas na área do *controle mioelétrico* são (Hargrove, et al., 2009) (Micera, et al., 2010): (a) máquinas de vetores de suporte (SVM), (b) classificadores bayesianos, (c) redes neurais artificiais de perceptrons em multicamadas (MLP), (d) modelos de misturas de gaussianas (MMG), (e) modelo ocultos de *markov* (HMM), (f) lógica nebulosa, (g) algoritmos genéticos, entre outras. Segundo a comparação feita em (Hargrove, et al., 2007) o desempenho de classificação atingido por esses classificadores é semelhante (vide Figura 2-9), mas o classificador baseado em LDA apresenta vantagens práticas pela simplicidade de desenvolvimento assim como pela facilidade de treinamento (vide Figura 2-9) (Englehart, et al., 2003).

O foco deste projeto está na representação e no pré-processamento do sinal de EMG e não na avaliação de classificadores, portanto, esta seção está limitada à apresentação das propriedades principais do classificador que na atualidade tem sido catalogado como superior no problema de controle mioelétrico, ou seja, o classificador LDA (o qual será usado neste trabalho para a avaliação dos resultados).

#### 2.3.5.1 - Classificador LDA (*Linear Discriminant Analysis*).

Este é um classificador pertencente ao grupo de classificadores estatísticos. Os classificadores estatísticos estão baseados na análise estatística do sinal de entrada. As características são agrupadas numa classe particular mediante a execução de um modelo probabilístico. Esse modelo estima funções de densidade de probabilidade do conjunto de características no espaço dimensional  $KN$  (vide Figura 2-5) e divide esse espaço em regiões correspondentes a cada classe. As alternativas mais destacadas nessa abordagem são: (a) classificadores bayesianos, (b) classificadores de distância e (c) árvores de classificação (Englehart, 1998). O classificador LDA é um caso particular do *classificador bayesiano*.

O problema central da classificação pode ser apresentado como: a definição de funções de decisão (ou *funções discriminativas*) a partir de um conjunto finito de padrões pertencentes a diferentes classes. Essas funções segmentam o espaço de entrada em regiões, cada uma agrupando os padrões de uma classe. Nesta etapa  $z \in Z \subset \mathcal{R}^{1 \times KN}$  é o

espaço de entrada e  $\hat{y} \in Y \subset \{y_1, \dots, y_C\}$  é o espaço de saída, onde  $z$  e  $\hat{y}$  são o padrão de entrada (em forma de vetor de características) e a etiqueta de classe, respectivamente.

Nos classificadores estatísticos o conjunto de dados  $z$  e  $y$  pode ser considerado como um conjunto de observações das *variáveis aleatórias*  $Z$  e  $Y$  respectivamente. Desta forma, é possível conhecer as probabilidades *a posteriori* do espaço de entrada, dada por  $P(y_k | z)$  para  $k = 1, \dots, C$ . As probabilidades *a posteriori* indicam a probabilidade de que um padrão desconhecido (e representado pelo vetor de características  $z$ ) pertença à classe de movimento  $y_k$ . Essa informação permite que o classificador escolha a classe mais provável, ou seja, aquela que corresponda com a probabilidade mais alta dentre o conjunto  $P(y_k | z)$ . A regra de classificação é dada por

$$\hat{y} = \arg \max_{y_k \in Y} P(y_k | z) \quad (2-3)$$

Em geral, as probabilidades *a posteriori*  $P(y_k | z)$  são desconhecidas, mas podem ser calculadas a partir das probabilidades *a priori*  $P(y_k)$ , as PDF (PDF, *Probability Density Functions*) condicionais  $p(z|y_k)$  e o teorema de *Bayes*, que estabelece (Theodoridis, et al., 2006) que

$$P(y_k | z) = \frac{P(y_k)p(z | y_k)}{p(z)} \quad (2-4)$$

onde,

$P(y_k)$  é a probabilidade *a priori* da classe  $k$ . Geralmente calculada com o conjunto de dados de treinamento;

$p(z|y_k)$  é a PDF condicional de  $z$  considerando a classe  $y_k$ ;

$p(z) = \sum_{k=1}^C P(y_k)p(z | y_k)$  é a PDF do espaço de entrada;

Deve ser observado que  $p(z)$  permanece constante para todas as classes  $k$ ; portanto, pode ser ignorada para propósitos de comparação. Dessa forma, a regra de classificação em (2-3) muda para a equação (2-5).

$$\hat{y} = \arg \max_{y_k \in Y} p(z | y_k)P(y_k) \quad (2-5)$$

A regra de decisão na equação (2-5) tem a propriedade de minimizar o erro de classificação, feito que justifica a superioridade do classificador estatístico de *Bayes* (Englehart, 1998).

O cálculo da PDF condicional  $p(z|y_k)$  a partir dos dados de treinamento é a parte difícil do processo de classificação. Esse processo dificulta-se ainda mais quando o tamanho do espaço de entrada  $K \times N$  é grande. O chamado *curse of dimensionality* impõe a restrição de que a quantidade de amostras de treinamento  $T$  seja muito maior do que  $K \times N$  para garantir uma estimativa confiável de  $p(z|y_k)$ .

Existe a possibilidade de realizar algumas suposições para simplificar o cálculo de  $p(z|y_k)$ . Para apresentar essa possibilidade consideremos o seguinte exemplo:

- Classificador com duas classes ( $C=2$ ) equiprováveis ( $P(y_1)=P(y_2)$ ).
- PDFs condicionais  $p(z|y_1), p(z|y_2)$  com distribuição normal.
- Vetor de características unidimensional ( $K \times N=1$ ).

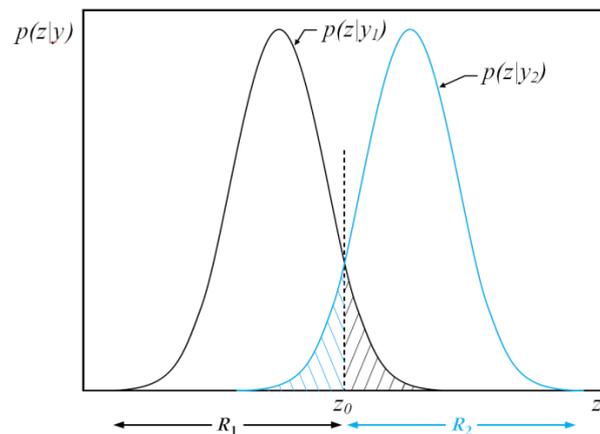


Figura 2-10. Exemplo de duas regiões formadas pelo classificador Bayesiano no caso de duas classes equiprováveis.  
Fonte: (Theodoridis, et al., 2006)

A Figura 2-10 apresenta os gráficos das PDF condicionais  $p(z|y_1), p(z|y_2)$ . Pode ser observado que existe uma linha descontínua no ponto  $z_0$  equidistante das duas PDF. Essa linha é a *curva de decisão* que divide o espaço de características em duas regiões:  $R_1$  e  $R_2$ . A regra de classificação pode ser interpretada em termos das regiões  $R_1$  e  $R_2$  como: (1) para todo  $z$  em  $R_1$  o classificador escolhe a classe  $\hat{y} = y_1$ ; (2) para todo  $z$  em  $R_2$  o classificador escolhe a classe  $\hat{y} = y_2$ .

Para o caso de problemas de classificação com vetores de características de dimensão maior do que 1 ( $K \times N > 1$ ), a linha converte-se em uma superfície de decisão que divide o espaço de características em 2 regiões, sendo que essa superfície pode tomar diversas formas de acordo com as suposições feitas para as PDF  $p(z|y_k)$ . Consideremos o seguinte exemplo:

- Classificador com duas classes ( $C=2$ ) equiprováveis ( $P(y_1)=P(y_2)$ ).
- Vetor de características bidimensional ( $K \times N=2$ )
- Distribuições normais para as PDF  $p(z|y_k)$  como as apresentadas na equação (2-6).

$$p(z | y_k) = \frac{1}{(2\pi)^{N/2} |\Sigma_k|^{1/2}} \exp\left(-\frac{1}{2}(z - \mu_k)^T \Sigma_k^{-1}(z - \mu_k)\right) \text{ para } k=1, \dots, C \quad (2-6)$$

Na equação (2-6), cada PDF está especificada por um vetor de média  $\mu_k$ , pela classe  $y_k$  e pela matriz de covariância  $\Sigma_k$ , que são definidos como:

- $\mu_k = E_k[z]$ ; valor esperado dos padrões pertencentes à classe  $y_k$ .
- $\Sigma_k = E[(x - \mu_k)(x - \mu_k)^T]$ ; matriz de covariância da classe  $k$
- $|\Sigma_k|$  determinante da matriz de covariância.

Por causa dos termos exponenciais na PDF definida na equação (2-6) é preferível trabalhar com funções que envolvem logaritmos. Dessa forma, define-se a função de decisão  $g_k(z)$  para a regra de classificação da equação (2-5).

$$g_k(z) = \ln(p(z | y_k)P(y_k)) \quad (2-7)$$

Assumindo matrizes de covariância na forma apresentada na equação (2-8), a equação (2-7) pode ser expandida para uma equação de segunda ordem. Consequentemente, as funções de decisão vão ser *quádricas* (elipsoides, parábolas, hyperparábolas, etc.) (Theodoridis, et al., 2006). Em tal caso, diz-se que o classificador *Bayesiano* é um classificador quadrático, no sentido em que as superfícies de decisão tomam formas quadráticas. Para o caso de  $K \times N > 2$ , as superfícies são *hiperquadráticas*.

$$\Sigma_k = \begin{bmatrix} \sigma_k^2 & 0 \\ 0 & \sigma_k^2 \end{bmatrix} \quad (2-8)$$

Assumindo que a matriz de covariância na equação (2-8) é a mesma para todas as classes, ou seja,  $\Sigma_k = \Sigma$ , então  $g_k(z)$  pode ser aproximada como uma função linear [19]. Consequentemente, as superfícies de decisão são hiperplanos. Em estatística, esse caso particular do classificador de *Bayes* é conhecido como LDA (*Linear Discriminant Analysis*) pela forma das funções de decisão.

Em (Tou, et al., 1977) os autores apresentam como essas funções de decisão lineares ou quadráticas, derivadas do classificador de Bayes, são ótimas teoricamente para distribuições diferentes da normal, ou gaussiana. Algumas características do classificador LDA são (Englehart, 1998): (1) seu treinamento é relativamente rápido com conjuntos de dados de comprimentos razoáveis, (2) não precisa de ajustes na arquitetura o no algoritmo de treinamento.

### 2.3.6 - Etapas de processamento adicionais

Procurando reduzir o erro de classificação, tem-se reportado algumas etapas de processamento adicionais às consideradas na Figura 2-5. Nessa seção apresentamos três propostas que têm demonstrado melhoras significativas no desempenho de classificação.

#### 2.3.6.1 - Pós-processamento com *majority vote*

Esta etapa foi proposta em (Englehart, et al., 2001) com o intuito de suavizar as variações na saída do classificador (Englehart, et al., 2001), (Englehart, et al., 2003), (Huang, et al., 2005), (Hargrove, et al., 2007). Pode ser observado que o esquema de classificação de janelamento com superposição gera um *stream* de decisões com maior frequência do que o janelamento adjacente. De fato, esse *stream* tem uma frequência maior do que a requerida pelo sistema de prótese (Chan, et al., 2003), (Chan, et al., 2005). Essa característica pode ser aproveitada em um processamento posterior que permita reduzir o erro de classificação. Uma alternativa de processamento é a chamada *maioria de votos* (MV). Nesse processo, o *stream* de decisões, gerado durante o tempo de resposta limite, é segmentado como se ilustra na Figura 2-11. Posteriormente, é escolhida a classe de movimento com maior quantidade de ocorrências no segmento. Finalmente, essa classe é apresentada na saída do sistema de classificação (Englehart, et al., 2001). Geralmente, o processo é feito unicamente durante a etapa de avaliação do sistema (Huang, et al., 2005), sendo que na etapa de treinamento não se faz esse processamento.

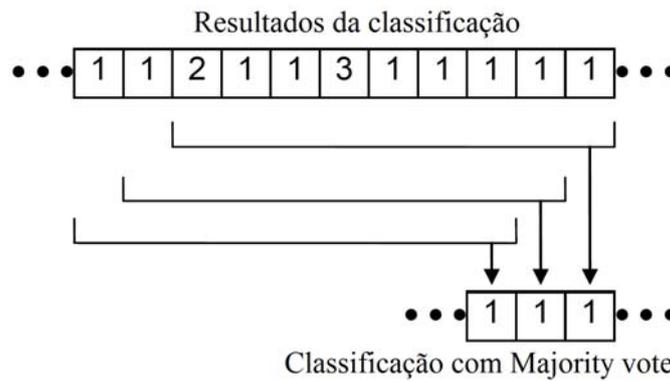


Figura 2-11. Comparação de resultados de classificação com processamento MV (*majority vote*). Fonte (Chan, 2007)

### 2.3.6.2 - Eliminação da informação entre classes de movimentos

Em (Englehart, et al., 2001) é constatado que a maioria dos erros de classificação ocorre durante os períodos de transição de classes de movimento e justificam esse comportamento porque nesses instantes, o sinal eletromiográfico representa classes indeterminadas entre contrações. Conseqüentemente, alguns autores (Chan, 2007), (Chan, et al., 2003), (Huang, et al., 2005) consideram que durante o cálculo do erro do sistema, é conveniente remover a informação das janelas de análise ao redor do instante de classificação. Outra justificativa para a eliminação destes dados é a baixa probabilidade de que a prótese responda aos erros gerados na zona de transição de classes, isso acontece devido à inercia intrínseca do dispositivo mecânico (Huang, et al., 2005).

### 2.3.6.3 – Sintonização com Transformação iPCA

Entre os anos 2005 e 2009 não foram apresentados avanços significativos na redução do erro de classificação dos sistemas de *controle mioelétrico*. No ano 2009 foi proposta a hipótese de que o *crosstalk muscular* do sinal EMG contém informação relevante capaz de melhorar o desempenho na classificação. Essa proposta foi pesquisada em (Hargrove, et al., 2009), obtendo-se baixas porcentagens de erro de classificação: no problema de 11 classes de movimento, 10 canais de aquisição e 10 sujeitos sem amputação, o menor erro médio atingido foi de aproximadamente 5%, sendo este o menor reportado até a data para esse tipo de configuração.

A proposta mistura um sistema de aquisição que garante alto conteúdo de *crosstalk muscular* nos canais de aquisição e uma transformação chamada de iPCA (*individual PCA*). Essa transformação é uma variação da PCA (*Principal Component Analysis*)

proposta para melhorar o desempenho de classificação em aplicações de reconhecimento de faces (Liu, et al., 2002).

A transformação é feita para produzir um novo espaço de entrada do sinal eletromiográfico. Nesse espaço, busca-se incrementar a informação relacionada com as classes de movimento e reduzir a informação que está relacionada com outros fatores (idade, sexo, repetição. etc). Esse processo, chamado de *sintonização* (Hargrove, et al., 2009), é localizado antes da extração de características (vide Figura 1-2). A principal desvantagem dessa projeção é o incremento na quantidade de dimensões do sinal eletromiográfico (ou quantidade de canais). Por exemplo, considerando um sistema de classificação de  $C$  classes, a transformada iPCA define  $C$  matrizes de transformação. Conseqüentemente, a transformação de um vetor de entrada  $x$  de comprimento  $M \times N$  vai gerar  $C$  vetores  $s$  de comprimento  $M \times N$  cada, como se indica na Figura 2-12. Ou seja, a transformação iPCA gera um incremento de dados num fator  $C$ .

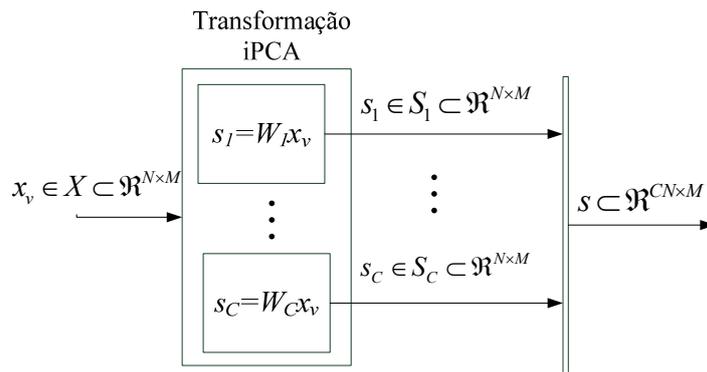


Figura 2-12. Transformação iPCA

Sem dúvida o efeito de incremento de canais converte-se num problema para o sistema de classificação, basicamente pelo incremento na complexidade computacional e a perda de generalização do classificador (vide seção 2.3.5 -). Para viabilizar a avaliação da hipótese proposta em (Hargrove, et al., 2009), o processo de transformação iPCA foi complementado com uma etapa de *redução de dimensionalidade*. A solução é ilustrada na Figura 2-13. Nesse esquema o vetor  $x$  de comprimento  $M \times N$  é transformado com as matrizes iPCA no vetor  $s$  de comprimento  $M \times CN$ . Posteriormente, o vetor  $s$  é fornecido à etapa de redução de dimensionalidade, onde se escolhe o subconjunto de amostras com maior quantidade de informação para a classificação. A escolha é apresentada na saída como o vetor  $O$ , de comprimento  $N_1$  com  $N_1 < CN$ . Desta forma

são reduzidos os problemas relacionados com o incremento na dimensionalidade dos dados na arquitetura de classificação com sintonização iPCA.



Figura 2-13. Esquema de Transformação iPCA complementado com Redução de dimensionalidade

### 2.3.7 - Comentários sobre os sistemas de controle mioelétrico baseados em reconhecimento de padrões

Nesta seção foram apresentados os sistemas de controle mioelétrico baseados em reconhecimento de padrões. Inicialmente, foi formulado o problema de classificação e a terminologia utilizada na área de *controle mioelétrico*. Posteriormente, foram descritas as etapas: (1) extração de características, (2) redução de dimensionalidade e (3) classificação de padrões. Finalmente, foram apresentadas três das etapas complementares que têm sido propostas para reduzir o erro de classificação: (1) *majority vote*, (2) eliminação de informação entre classes e (3) transformação iPCA.

Na seção 2.3.3 - apresentou-se a revisão bibliográfica das propostas mais relevantes e recentes, com relação à extração de características. A Tabela 2-2 apresenta um resumo das propostas consideradas, indicando, além do erro de classificação, algumas características dos experimentos reportados (quantidade de sujeitos, canais, movimentos, etc). Essa informação permitiu concluir:

- O desempenho dos sistemas de *controle mioelétrico* é medido com relação a três variáveis: o *erro de classificação*, a complexidade computacional e o tempo de resposta do sistema. Entre elas, o erro de classificação é o indicador mais reportado na literatura.
- Existe superioridade das características AR, RMS na descrição do sinal EMG para propósitos de classificação. A superioridade é justificada em dois aspectos: (a) o erro de classificação, (b) a complexidade computacional.
- Existe uma proporção direta entre o erro de classificação e a quantidade de classes de movimento do sistema de *controle mioelétrico*.

- Existe uma proporção inversa entre o erro de classificação e o volume de informação discriminativa disponível. Esse volume depende, entre outros fatores, da quantidade de canais de aquisição, a redundância nos canais de aquisição, o comprimento de janelas e o tipo de sinal de EMG analisado (transiente ou estacionário).
- O sinal de EMG estacionário contém o maior volume de informação discriminativa para o problema de classificação definido nos sistemas de controle mioelétrico.
- Até o ano de 2005, o erro mínimo de classificação atingido era de 3% (Huang, et al., 2005) (Oskoei, et al., 2008), num problema que analisou a etapa estacionária do sinal de EMG, com seis classes de movimento e quatro canais de informação. A análise foi feita com sujeitos sem amputação

Na seção 2.3.4 - foi descrito o problema de capacidade de generalização do classificador. Posteriormente, foram referenciadas algumas das soluções mais comuns na literatura de controle mioelétrico. Essas soluções foram classificadas nos grupos: (1) seleção de características e (2) projeção de características. No final da seção foram apresentados detalhes respeito da técnica ULDA (*Uncorrelated LDA*).

A seção 2.3.5 - foi dividida em duas partes: (a) a introdução aos classificadores de controle mioelétrico e (b) a descrição teórica do classificador LDA. Na parte introdutória foram reportados os classificadores mais comuns utilizados no problema controle mioelétrico. Esse relatório permitiu estabelecer dois aspectos importantes: (1) a existência de um grupo amplo de classificadores. (2) a semelhança no desempenho de classificação atingido por esse grupo de classificadores. A partir desse comportamento é possível concluir que:

- O critério de escolha da abordagem de desenvolvimento do classificador está determinado pelas vantagens práticas (facilidade de treinamento do classificador, complexidade computacional, etc.) e não pelo *desempenho de classificação*.

Tomando em conta esse comportamento o classificador baseado em LDA (*Linear Discriminant Analysis*) tem sido escolhido por diversos autores como a alternativa mais apropriada para o *controle mioelétrico* (Englehart, 1998), (Hargrove, et al., 2009), (Chan, 2007).

Na segunda parte da seção 2.3.5 -, mediante exemplos, foram apresentadas as suposições que permitem definir o classificador LDA a partir do classificador de *Bayes*. Esses detalhes permitem concluir que:

- O funcionamento do classificador é altamente dependente da precisão das estatísticas dos dados: médias, covariâncias, PDFs, etc.
- O sucesso do classificador LDA depende, em certa medida, da validade na suposição de padrões com distribuições normais.
- O desenvolvimento e a interpretação do classificador LDA são relativamente simples.

O suposto de classes equiprováveis utilizado na seção 2.3.5 - é assumido no intuito de facilitar a representação gráfica e definição das funções de decisão e não representa uma restrição dos dados processados nessa pesquisa.

Na seção 2.3.6 - foram descritas três etapas de processamento complementares: (a) pós-processamento com *majority vote*, (b) eliminação da informação ao redor dos instantes de troca de movimento e (c) sintonização de dados com transformação iPCA. Essas etapas têm sido propostas objetivando reduzir o erro de classificação dos sistemas de controle mioelétrico. Entre essas propostas a sintonização de dados por iPCA foi a de maior sucesso. O feito de sintonizar os dados antes da classificação permitiu reduzir significativamente o erro de classificação. Os aspectos relacionados com a sintonização de dados por iPCA serão definidos com maior detalhe no capítulo seguinte.

## **2.4 - RESUMO DO CAPÍTULO**

Este capítulo apresentou conceitos teóricos básicos relacionados com os sistemas de controle mioelétrico. A apresentação foi dividida em duas seções: (1) Generalidades sobre os sinais EMG e (2) Sistemas de controle mioelétricos. As principais conclusões da primeira seção são resumidas a seguir:

- A alta variabilidade do sinal EMG entre diferentes usuários justifica a abordagem de projeção independente do sistema de classificação: configuração e avaliação do sistema de controle mioelétrico para cada usuário.
- O sinal de EMG utilizado em aplicações de controle mioelétrico de próteses de mão pode ser considerado um processo estocástico estacionário em sentido amplo.

- A estratégia de medição de sinal EMG multicanal envolve maior quantidade de informação discriminativa, feito que seja reflexado no atingimento de desempenhos de classificação superiores do que os apresentados com sistemas de controle baseados em dois ou três canais.

A segunda seção permitiu concluir:

- O erro de classificação é o indicador de desempenho recomendado para avaliar o desempenho de classificação do sistema de controle mioelétrico em nosso projeto.
- A extração de características AR6 e/ou RMS é uma alternativa com sucesso na representação de sinais de EMG em aplicações de classificação.
- Existe uma proporção direta entre o erro de classificação e a quantidade de classes de movimento do sistema de *controle mioelétrico*.
- Existe uma proporção inversa entre o erro de classificação e o volume de informação discriminativa disponível nos padrões do sinal EMG.
- O sinal de EMG estacionário contém o maior volume de informação discriminativa para o problema de classificação definido nos sistemas de controle mioelétrico.
- O classificador LDA apresenta superioridade prática sobre outros classificadores avaliados nos sistemas de controle mioelétrico.
- O sucesso do classificador LDA é altamente dependente da precisão das estatísticas dos dados: médias, covariâncias, PDFs, etc.
- Existe informação discriminativa de classes no *crosstalk* muscular do sinal EMG. Esta pode ser aproveitada para fins de classificação utilizando a sintonização de padrões iPCA.
- A proposta de sintonização dos padrões através de iPCA tem sido a de maior sucesso no intuito de reduzir os erros de classificação reportados na literatura recente.

Tabela 2-2. Resumo dos parâmetros de classificação e erros atingidos nos últimos anos.

Classificador	Canais	Classes	Características	Sujeitos	Erro médio	Processamento Adicional	Referencia	Ano
MLP	2	4	MAV, MAVS, ZC, SSC, WL. Transiente	9	9.25%		Hudgins et al. (Hudgins, et al., 1993)	1993
LDA, MLP	5	4	WPT. Transiente	16	6.25%		Englehart et al. (Englehart, 1998)	1998
PCA, LDA	4	6	WPT. Estacionário	11	6.8%		Englehart et al. (Englehart, et al., 2001)	2001
LDA	4	4	TD. Estacionário	12	5%	<i>Majority Vote</i>	Englehart e Hudgins (Englehart, et al., 2003)	2003
GMM	4	6	AR6+RMS+TD. Estacionário	12	3.1%	<i>Majority Vote</i> Eliminação informação entre classes	Huang et al. (Huang, et al., 2005)	2005
LDA	8	7	AR4+RMS. Estacionário	30	7.4%	<i>Majority Vote</i> Eliminação informação entre classes	Chan A. D. C. (Chan, 2007)	2007
SVM	4	5	RMS +AR6. Estacionário	11	3%	<i>Majority Vote</i> Eliminação informação entre classes	Oskoei et al. (Oskoei, et al., 2008)	2008
LDA	10	11	AR6 Estacionário	10	6.5%		Hargrove et al. (Hargrove, et al., 2009)	2009
LDA	10	11	AR6 Estacionário	10	5%	Transformação iPCA	Hargrove et al. (Hargrove, et al., 2009)	2009

## 3 - SINTONIZAÇÃO DE DADOS POR IPCA

### 3.1 - INTRODUÇÃO

Neste capítulo é definida uma perspectiva global do *processo de classificação com sintonização por iPCA*. Posteriormente, são apresentadas as variantes desse processo que serão avaliadas no projeto de pesquisa. O capítulo inicia com a apresentação da transformação PCA convencional e posteriormente, é apresentada a proposta de PCA individual (iPCA) indicando suas vantagens e desvantagens nos sistemas de classificação. Seguidamente é discutido o processo de redução de dimensionalidade envolvido. A discussão é focada nos algoritmos de busca e funções custo que serão avaliadas neste projeto de pesquisa.

### 3.2 - TRANSFORMADA PCA

A transformada de análise dos componentes principais (PCA) também conhecida como transformação *Karhunen-Loevè* ou transformação *Hotelling* é uma transformação ortogonal linear que descorrelaciona dados multivariáveis fazendo projeções para um novo sistema de coordenadas onde a máxima variância dos dados é localizada na primeira coordenada e a mínima variância tende a ficar na última coordenada (Hyvärinen, et al., 2001). Nesta seção é apresentado o conceito de componentes principais, seguido da definição da transformação PCA.

#### 3.2.1 - Os componentes Principais.

Para introduzir o conceito de *componentes principais* serão consideradas  $M$  observações de um vetor aleatório  $x$  de dimensão  $N$  e correlação mútua diferente de zero. O vetor  $x$  pode ser representado em função de vetores linha  $x_i(m)$  para  $i=1, \dots, N$  como se indica na equação (3-1).

$$x = \begin{bmatrix} x_1(m) \\ x_2(m) \\ \vdots \\ x_N(m) \end{bmatrix}; m = 1, \dots, M \quad (3-1)$$

O primeiro passo da transformação PCA é centrar o vetor  $x$  mediante subtração de seu valor médio. Para simplificar nossa análise, consideramos que o vetor na equação (3-1) já foi centrado, ou seja,  $E[x_i(m)] = 0$ .

O seguinte passo é aplicar uma transformação linear em  $x$  e obter o vetor  $s$  de dimensão  $N'$ , com  $N' \leq N$ . A projeção deve garantir que os elementos em  $s$  tenham correlação mútua zero, objetivando eliminar a redundância nos dados. Para satisfazer esta condição é necessário encontrar um sistema de coordenadas ortogonais capaz de descorrelacionar o vetor  $x$  nas novas coordenadas de  $s$ . O efeito de correlação mútua nula implica compressão de energia em cada eixo do sistema projetado, conseqüentemente, o primeiro eixo da projeção (primeiro componente principal) vai corresponder com a máxima variância, o segundo eixo (segundo componente principal) corresponderá à máxima variância na direção ortogonal do primeiro eixo e assim por diante (Hyvärinen, et al., 2001). Por exemplo, consideremos o caso de um vetor  $x$  de duas dimensões ( $N=2$ ). Assumindo que  $x_1(m)$  e  $x_2(m)$  têm densidades de probabilidade Gaussianas constantes no espaço bidimensional como mostrado na Figura 3-1, então, os componentes principais são as projeções de  $x$  nos dois eixos principais  $e_1$ ,  $e_2$ .

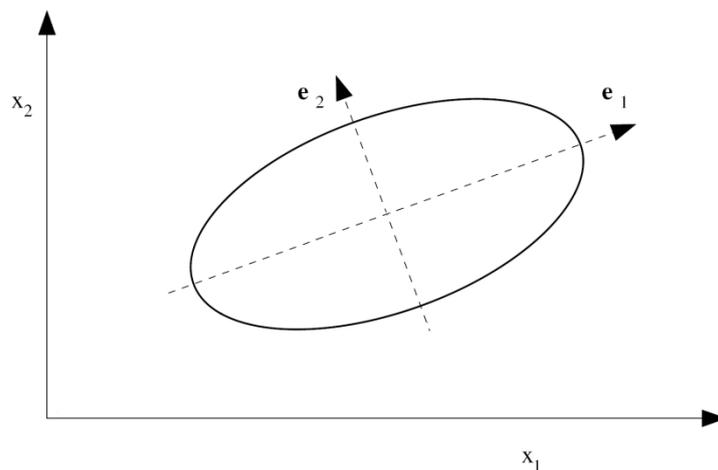


Figura 3-1. Exemplo dos eixos de projeção na transformação iPCA de um sinal  $x$  de duas dimensões. A elipse indica os contornos das densidades de probabilidade de  $x_1(m)$  e  $x_2(m)$ . Fonte: (Hyvärinen, et al., 2001)

Pode ser observado que para o caso de um sinal de  $N$  dimensões teremos  $N$  eixos de projeção. Lembrando que a condição de correlação mútua nula implica que as variâncias em cada eixo sejam altamente diferentes intui-se a existência de componentes de amplitudes pequenas nos últimos eixos da projeção. Geralmente, esses componentes são rejeitados e somente os  $N'$  primeiros componentes de maior amplitude conformam o vetor  $s$  (Hyvärinen, et al., 2001).

### 3.2.2 - Definição da transformação PCA

Considere os componentes reais do vetor de entrada  $x$  na equação (3-1). Assuma-se a existência de uma matriz unitária  $W$  a partir da qual é definida a projeção do vetor  $x$  para um novo vetor  $s$  como se indica na equação (3-2)

$$s = W x \quad (3-2)$$

onde,

$W^T = [w_1(n), w_2(n), \dots, w_N(n)]$ ; com  $w_i(n)$  vetor coluna de comprimento  $N$ .

$$s = \begin{bmatrix} s_1(m) \\ s_2(m) \\ \vdots \\ s_N(m) \end{bmatrix}; m = 1, \dots, M$$

A condição de correlação mútua nula no vetor  $s$  definido na equação (3-2) pode ser representada em termos do valor esperado como se indica na equação (3-3).

$$E[s_i(m)s_j(m)] = 0; i \neq j; m = 1, \dots, M \quad (3-3)$$

Lembrando a consideração de média zero nos dados  $x$ , a matriz de covariância  $C_s$  do vetor projetado  $s$  pode ser calculada como se indica na equação (3-4):

$$C_s = E[ss^T] = E[Wxx^TW^T] = WC_xW^T \quad (3-4)$$

Com  $C_x$  matriz de covariância do vetor  $x$

Considerando a condição de correlação mútua nula na equação (3-3) junto com a definição de matriz de covariância na equação (3-4), conclui-se que a matriz de covariância  $C_s$  dos dados projetados é uma matriz diagonal.

Pode ser observado que  $C_x$  é uma matriz simétrica e, portanto, seus autovetores são mutuamente ortogonais (Theodoridis, et al., 2006). Deve-se lembrar que para qualquer matriz simétrica  $C_x$  com distintos autovalores existe uma matriz ortogonal  $A$  que permite diagonalizar  $C_x$  com a sequência de produtos indicada na equação (3-5). A condição que deve satisfazer  $A$  consiste em que seus vetores coluna correspondam com os autovetores de  $C_x$ .

$$A^T C_x A = \Lambda \quad (3-5)$$

onde,

$A = [e_1(n), \dots, e_N(n)]$ ;  $e_i$  ( $i=1..N$ ) são os autovetores coluna da matriz  $C_x$ ;

$\Lambda$  é uma matriz diagonal, tendo como elementos na sua diagonal principal os autovalores  $\lambda_i$ ,  $i=1,2,\dots,N$  de  $C_x$ . Considerando que  $A$  é uma matriz definida positiva, seus autovalores também serão positivos.

A partir das equações (3-4), (3-5) podemos definir a relação  $A=W^T$  e, portanto, conclui-se que a matriz de transformação  $W$  da equação (3-2) pode ser expressa em termos dos autovetores coluna  $e_i$  da matriz de covariância  $C_x$  como se indica na equação (3-6).

$$W^T = [e_1(n), \dots, e_N(n)] \quad (3-6)$$

Em síntese, a matriz de transformação definida na equação (3-6) garante o propósito original de gerar uma projeção  $s$  descorrelacionada com a operação definida na equação (3-2). A transformada resultante é conhecida como transformada *PCA* (*Principal Component Analysis*), uma ferramenta de importância fundamental em aplicações de processamento de sinais e reconhecimento de padrões (Theodoridis, et al., 2006).

Uma propriedade importante desta transformação é o mínimo erro de aproximação. Levando em conta as características da matriz  $W$  é possível definir uma reconstrução do sinal  $x$  a partir das projeções  $s_i(m)$  e os vetores base  $e_i(m)$  como se apresenta na equação (3-7).

$$x = \sum_{i=1}^N s_i(m) e_i(n) \quad (3-7)$$

onde,

$$s_i(m) = e_i^T(n) x$$

Considere-se a definição de uma nova projeção de dimensões reduzidas onde somente os primeiros  $N'$  vetores base são levados em conta para a reconstrução.

$$\hat{x} = \sum_{i=1}^{N'} s_i(m) e_i(n) \quad (3-8)$$

Para avaliar a fidelidade com que o novo vetor  $\hat{x}$  aproxima o vetor original  $x$ , é possível utilizar o erro médio quadrático como se indica em (3-9).

$$E\left[\|x - \hat{x}\|^2\right] = E\left[\left\|\sum_{i=N'+1}^N s_i(m)e_i(n)\right\|^2\right] \quad (3-9)$$

Em (Theodoridis, et al., 2006) é provado que a escolha dos  $N'$  autovetores  $e_i$  associados com os autovalores de maior amplitude na reconstrução da equação (3-8) permite minimizar o erro médio quadrático definido na equação (3-9).

### 3.2.3 - Algoritmo de cálculo das matrizes de transformação PCA

Considere o vetor de padrões  $x \subseteq \mathfrak{R}^{N \times M}$  definido na equação (3-1). Em um sistema de controle mioelétrico a dimensão  $N$  do vetor está dada pela quantidade de canais de aquisição. Por outro lado, a quantidade de observações  $M$  é definida pela quantidade de amostras (*samples*) feita em cada canal. Tendo em conta estas considerações os passos do algoritmo PCA são os seguintes:

---

Algoritmo 3-1. Cálculo das matrizes de transformação iPCA

---

1. Extrair o valor médio ao longo de cada dimensão de  $x$ :

$$\bar{x} = x - E[x] \quad (3-10)$$

2. Calcular a matriz de covariância do vetor de dados  $\bar{x}$  ao longo das colunas. Considerando as dimensões de  $\bar{x}$ , as matrizes de covariância terão um comprimento de  $N \times N$  (vide Apêndice C -).

$$C_x = E[\bar{x} \bar{x}^T] \quad (3-11)$$

3. Calcular os *autovalores*  $\lambda$  e *autovetores*  $e_i(n)$  de comprimento unitário da matriz de covariância  $C_x$ .

$$[\lambda, e] = eig(C_x) \quad (3-12)$$

onde,  $\lambda$  é o conjunto de autovalores de  $C_x$ ;  $\lambda = [\lambda(1), \lambda(2), \dots, \lambda(N)]$ ,  $e$  é o conjunto de autovetores coluna de  $C_x$ ;  $e = [e_1(n), e_2(n), \dots, e_N(n)]$ ;  $e_i(n) \subseteq \mathfrak{R}^N$

4. Ordenar os autovetores  $e_i$  na sequência ascendente respeito da amplitude do autovalor associado  $\lambda(i)$ . Os primeiros  $N'$  autovetores são escolhidos para conformar a matriz de transformação  $W$ .
-

Na transformação PCA convencional utilizada nos sistemas de reconhecimento de padrões, o conjunto de dados de treinamento  $\mathfrak{S}_T$  é utilizado para calcular a matriz de transformação  $W$ . Posteriormente,  $W$  é utilizada para projetar os padrões EMG (Hargrove, et al., 2009).

### **3.3 - CLASSIFICAÇÃO DE PADRÕES PROJETADOS COM TRANSFORMAÇÃO IPCA**

Em aplicações de classificação de padrões as projeções feitas durante o processamento compartilham um objetivo comum: *destacar a informação discriminativa de classe no sinal*. Como foi apresentado na seção anterior, a transformação PCA convencional atinge a propriedade de mínimo erro de aproximação, feito que justifica sua aplicação em problemas de compressão de sinal. Entretanto, a transformação não inclui informação das classes do problema de classificação, resultando sub-ótima para propósitos de classificação (Das, et al., 2007). Procurando resolver esta desvantagem, em (Das, et al., 2007), (Liu, et al., 2002) é proposta uma modificação sobre a transformação PCA convencional chamada de iPCA (*individual PCA*) ou cPCA (*classwise PCA*). Com esta modificação consegue-se aproveitar as vantagens de compressão de energia de PCA assim como incluir a informação de classes para melhorar o desempenho de classificação. A transformação PCA convencional gera um novo espaço que mistura diferentes tipos de variações do sinal. Particularmente, na aplicação de *controle mioelétrico* as variações misturadas podem ser classificadas em dois grupos:

- Variações por causa das diferentes classes de movimento.
- Variações por causa de diferenças entre ensaios no mesmo sujeito: mudanças na localização dos eletrodos, habilidade do usuário e variações circadianas (ao longo do dia) devidas a estados de ânimo, hábitos, alimentação, etc.

O propósito da iPCA é a geração de projeções que conservem e intensifiquem as variações provocadas pela classe de movimento, enquanto, ofuscam as variações geradas por outras causas. Desta forma espera-se garantir índices de sucesso superiores na classificação.

### 3.3.1 - Definição da Transformação iPCA

Considere os dados de treinamento  $\mathfrak{X}_t$  e seu vetor de padrões  $x \in X \subset \mathfrak{R}^{N \times M}$ ; sendo  $M$  o número de observações e  $N$  o número de canais. Para cada padrão definido no instante  $m$  é conhecida a classe de movimento  $y(m)$ . Nessas condições, é possível agrupar o conjunto de padrões  $x$  em  $C$  categorias, onde  $C$  é o número de classes do problema de classificação. O critério de agrupamento é a pertinência de cada padrão à classe. Desta forma, o conjunto de dados  $x$  será representado como se indica na equação (3-13).

$$x = \{x_1, x_2, \dots, x_C\} \quad (3-13)$$

Onde,

$x_i$  é o subconjunto de padrões de treinamento pertencentes à classe  $i$ .  $C$  é o máximo número de classes do problema de classificação.

Uma vez segmentado o conjunto de padrões, para cada vetor  $x_i$  ( $i=1, \dots, C$ ) serão calculadas as matrizes de transformação seguindo o procedimento apresentado nas equações (3-10) até (3-12). Como resultado obtém-se o grupo de matrizes de transformação iPCA:  $W_i$  ( $i=1, \dots, C$ ) cada uma de comprimento  $N \times N$ .

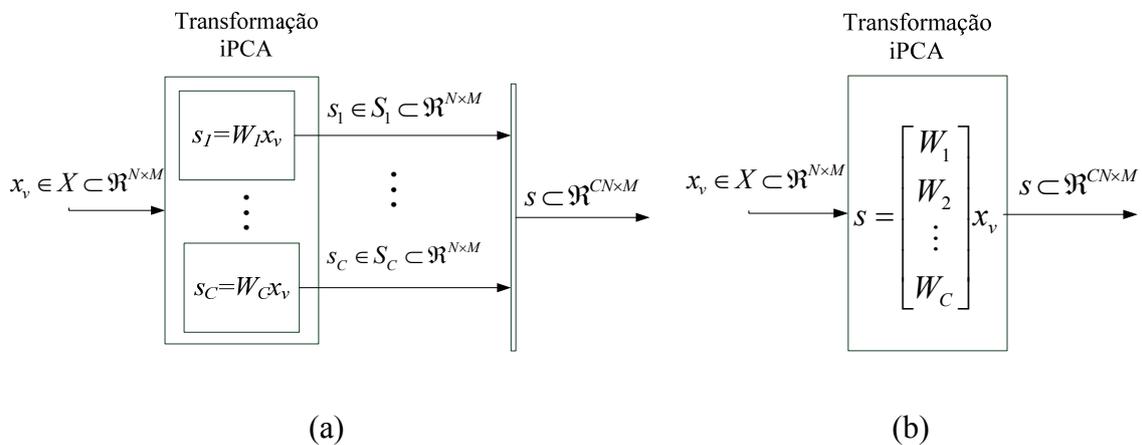


Figura 3-2. Esquema de transformação iPCA no sistema de classificação de  $C$  classes

Finalmente, os padrões do conjunto de dados de teste  $\mathfrak{X}_t$  são transformados com as matrizes  $W_i$  como se indica na Figura 3-2(a). Esta operação provoca a projeção dos padrões de entrada para  $C$  subespaços  $S_i$  onde se espera que a informação discriminativa de classe dos padrões seja intensificada. Pode ser observado que o processo de

transformação também pode ser interpretado como a projeção dos padrões de teste com uma única matriz  $W_{PCA}$  de comprimento  $CN \times N$  como se indica na Figura 3-2(b).

A Figura 3-3 apresenta um exemplo em que a transformação iPCA é superior à PCA em um problema de classificação. Neste exemplo, assumem-se formas Gaussianas na distribuição condicional de classe dos padrões. O problema de classificação tem duas classes  $y_1, y_2$  e padrões de duas dimensões ( $N=2$ ). Conseqüentemente, a transformação iPCA vai gerar 2 subespaços  $\{S_1, S_2\}$  onde serão projetados os padrões bidimensionais.

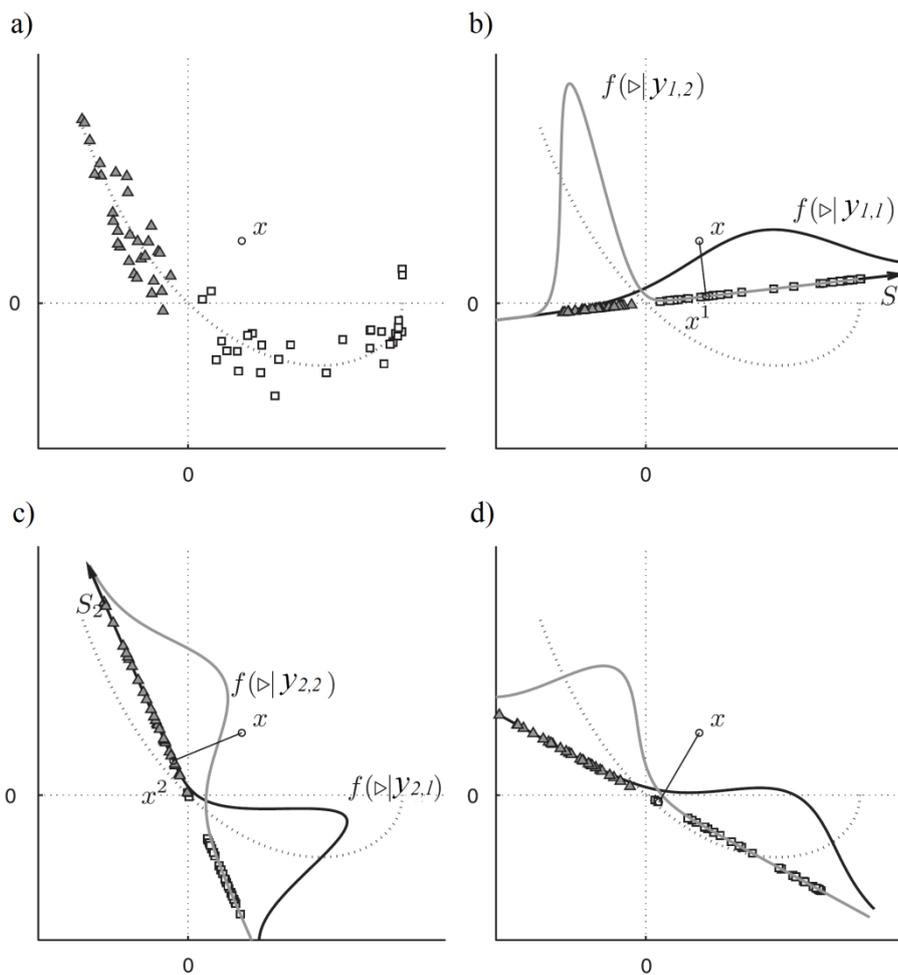


Figura 3-3. Comparação entre as transformações PCA e iPCA em um problema de classificação. Fonte: (Das, et al., 2008)

A Figura 3-3 (a) apresenta os padrões de treinamento e o único padrão de avaliação  $x$ . Os padrões de treinamento que pertencem à classe  $y_1$  são apresentados com triângulos cinza, enquanto que os pertencentes a classe  $y_2$  são apresentados com quadrados. O padrão de avaliação  $x$  e apresentado com um círculo. Na Figura 3-3 (b) é apresentada a projeção dos padrões (de treinamento e avaliação) para o subespaço  $S_1$ . Pode ser

observado que os padrões de treinamento conservam a forma gaussiana nas distribuições condicionais de classe. Da mesma maneira pode ser percebido como a projeção do padrão de avaliação  $x$  localiza o novo ponto  $x_1$  entre os padrões de treinamento da classe  $y_2$ . Na Figura 3-3 (c) é apresentada a projeção dos padrões para o subespaço  $S_2$ . Neste caso, o padrão de avaliação projetado  $x_2$  é localizado entre os padrões de treinamento da classe  $y_1$ . Finalmente, a Figura 3-3 (d) apresenta a projeção de padrões para o espaço gerado com a transformação PCA convencional. Neste caso, o padrão de avaliação fica na interseção das distribuições condicionais dos padrões de treinamento.

Considerando-se as projeções descritas é possível ver que na transformação PCA o padrão de avaliação localiza-se em uma zona onde os erros de classificação tem probabilidade diferente de zero<sup>7</sup>. De outro lado, as projeções feitas com iPCA conseguem localizar o padrão de avaliação fora da zona de erro de classificação (ou fora da interseção entre as densidades de probabilidade condicionais). Consequentemente, existe maior probabilidade de sucesso na classificação utilizando a transformação iPCA. Entretanto, os resultados da transformação iPCA ainda tem que ser processados para decidir a classe do padrão  $x$ . A seguir, são apresentadas as alternativas propostas para resolver essa tarefa.

### 3.3.2 - Classificação dos padrões projetados com iPCA

A primeira proposta para classificação dos padrões projetados com iPCA foi apresentada em (Das, et al., 2007). Esta proposta será chamada de *classificação independente de subespaços*. Nela se faz uma comparação entre as probabilidades das classes escolhidas em cada subespaço. A sequência de decisão para o caso de duas classes é a seguinte:

- Calcular a probabilidade de que o padrão  $x_1$  pertença às classes  $y_{1,i}$  ( $i=1,2$ ). Essas classes são as projeções das classes  $y_1, y_2$  para o espaço  $S_1$ .
- Escolher  $l$ , a classe de maior probabilidade entre  $y_{1,i}$ .
- Calcular a probabilidade de que o padrão  $x_2$  pertença às classes  $y_{2,i}$  ( $i=1,2$ ). Essas classes correspondem com as projeções das classes  $y_1, y_2$  para o espaço  $S_2$ .

---

<sup>7</sup> Neste sentido o erro é definido como o caso em que um padrão  $x$  seja classificado em  $y_2$  mas pertença a  $y_1$  ou vice-versa (Theodoridis & Konstantinos, 2006).

- Escolher  $k$  a classe de maior probabilidade entre  $y_{2,i}$ .
- Finalmente, escolher a classe mais provável entre  $l$  e  $k$  para determinar a classe a que pertence o padrão  $x$ .

A classificação independente de subespaços tem uma desvantagem prática: a complexidade computacional cresce de maneira linear (Das, et al., 2007) com a quantidade de classes do problema de classificação. Pode ser observado que em um problema de  $C$  classes de movimento, vai ser necessário resolver pelo menos  $C$  classificadores. Esta condição resulta em alto custo computacional para o caso de problemas de reconhecimento de padrões com mais de 5 classes, como no *controle mioelétrico* ( $5 \leq C \leq 11$ ).

Em (Hargrove, et al., 2009) é proposta uma alternativa de classificação que chamaremos de *classificação conjunta de subespaços*. Esta consiste em processar o conjunto completo  $s$  (vide Figura 3-2(b)) com um único classificador. A proposta é justificada considerando que os padrões projetados nos  $C$  subdomínios conseguem intensificar a informação discriminativa por variações de classe e reduzir a informação discriminativa originada por outro tipo de variações (Liu, et al., 2002). Inicialmente, parece que a alternativa resolve o problema da complexidade computacional, entretanto, somente translada o problema para o espaço de entrada do sistema de classificação. Pode ser observado que esta alternativa provoca incremento na dimensão dos padrões em um fator  $C$  (vide Figura 3-2), feito que envolve maiores esforços computacionais nos processos posteriores (por exemplo, na *extração de características*). Adicionalmente, lembrando que a capacidade de generalização de um classificador é tão alta como seja a relação  $T/Q$ , onde  $T$  é o número de dados de treinamento e  $Q$  é o número de parâmetros do classificador (Theodoridis, et al., 2006) é possível inferir outro efeito de incrementar a dimensão dos padrões: o incremento é traduzido em um crescimento de parâmetros do classificador, feito que reduz tanto a relação  $T/Q$  quanto a capacidade de generalidade do classificador.

Procurando resolver esta situação os autores de (Hargrove, et al., 2009) propõem um método de desenvolvimento do sistema de classificação baseado em uma projeção reduzida. O método proposto precisa considerar um conjunto adicional de dados chamado de *validação*  $\mathfrak{S}_v$ . A equação (3-14) apresenta a nova divisão da base de dados dos padrões EMG considerando os dados de validação.

$$\mathfrak{S} = \{\mathfrak{S}_t, \mathfrak{S}_v, \mathfrak{S}_r\} \quad (3-14)$$

$$\mathfrak{S}_r = \{(x^{(1)}, y^{(1)}), \dots, (x^{(M_1)}, y^{(M_1)})\}$$

$$\mathfrak{S}_t = \{(x^{(1)}, y^{(1)}), \dots, (x^{(M_2)}, y^{(M_2)})\}$$

$$\mathfrak{S}_v = \{(x^{(1)}, y^{(1)}), \dots, (x^{(M_3)}, y^{(M_3)})\}$$

onde,

$\mathfrak{S}$  é a base de dados de padrão-classe;

$\mathfrak{S}_r$  é o conjunto de dados de treinamento;

$\mathfrak{S}_t$  é o conjunto de dados de teste;

$\mathfrak{S}_v$  é o conjunto de dados de validação;

o índice sobrescrito <sup>(i)</sup> representa o i-ésimo par padrão-classe.

A principal diferença com o método de desenvolvimento descrito no capítulo 2 (vide seção 2.3.1 -) é a adição de uma etapa que chamaremos de *cálculo da matriz iPCA reduzida*. Desta forma o método de desenvolvimento fica com a sequência de etapas indicada na Tabela 3-1:

Tabela 3-1. Etapas de desenvolvimento do sistema de classificação proposto em (Hargrove, et al., 2009).

<b>Etapa</b>	<b>Nome</b>	<b>Padrões EMG utilizados</b>
1	Experimentos supervisionados	--
2	Cálculo da matriz iPCA reduzida	Treinamento, Validação
3	Configuração de parâmetros do classificador	Treinamento
4	Avaliação do sistema	Teste

A etapa 2 é feita em duas fases: (a) cálculo de um vetor de dimensões reduzidas  $O$  que contém os  $N_I$  canais (ou dimensões) com maior informação discriminativa de classe (com  $N_I < CN$ ) e (b) construção da matriz iPCA reduzida a partir do vetor calculado na fase (a).

Para calcular o vetor de dimensões reduzidas  $O$  é utilizado o esquema de *redução de dimensionalidade* da Figura 2-13. Neste esquema, os padrões de validação (de  $N$  canais, cada de comprimento  $M_3$ ) são projetados com as matrizes de transformação iPCA para gerar o sinal  $s$  de dimensão  $CN$  (cada de comprimento  $M_3$ ); sendo que as matrizes iPCA são calculadas com dados de treinamento. Posteriormente,  $s$  é fornecido ao bloco de redução de dimensionalidade, onde são feitas avaliações iterativas de uma *função custo*

que utiliza como argumento um vetor de canais  $O'$ . No momento em que se satisfaz um critério de parada (por exemplo, mínimo valor da função custo ou máximo número de iterações) o bloco entrega o vetor  $O$  de comprimento  $N_l < CN$ . Este vetor contém a sequência de canais com maior informação discriminativa do sistema. É importante aclarar que este processo não precisa satisfazer requerimentos estritos de tempo de execução pelo fato de que não é executado durante a etapa de avaliação do sistema.

Seguidamente e para complementar a etapa 2 é calculada a matriz de transformação iPCA reduzida. Esta é uma matriz de dimensão  $N \times N_l$  que projeta padrões de EMG gerando unicamente os canais que compõem o vetor  $O$  calculado na fase prévia.

Durante as etapas 3 e 4 é utilizada a transformação iPCA reduzida (vide Figura 3-4), ou seja, só é executada a porção da transformação iPCA correspondente com o cálculo dos canais que compõem o vetor de dimensões reduzidas  $O$ . Com isto os autores conseguem reduzir o esforço computacional e os problemas de generalidade do classificador dito. Além disso, consegue-se uma representação dos padrões EMG com intensificação da informação discriminativa de classe.

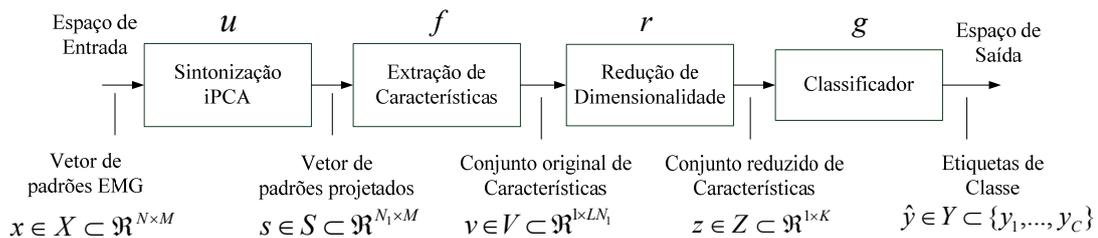


Figura 3-4. Arquitetura de classificação com transformação iPCA reduzida.

Os requisitos de quantidade de classes e tempos de resposta da aplicação próprios do *controle mioelétrico* fazem com que a proposta de classificação independente de subespaços feita em (Das, et al., 2007) não seja apropriada. Portanto, entre as alternativas de classificação ditas só a classificação conjunta de subespaços apresentada em (Hargrove, et al., 2009) é fatível para a aplicação de controle mioelétrico. Na seguinte seção são apresentados detalhes desta técnica.

### 3.4 - REDUÇÃO DE DIMENSIONALIDADE

Nesta seção é definido o problema de redução de dimensionalidade dos dados projetados com iPCA. Seguidamente, é feita uma descrição dos componentes do processo de redução dimensionalidade focada nas alternativas consideradas neste trabalho.

#### 3.4.1 - Definição do problema de redução de dimensionalidade

Como foi descrito no Capítulo 2 (vide seção 2.3.4 -) existem duas alternativas na redução de dimensionalidade: *seleção de características* e *projeção de características*. Para determinar a alternativa mais apropriada no processo de redução de dimensionalidade das projeções feitas com iPCA (vide Figura 2-13), são consideradas as propriedades do vetor de dados  $s$ . Esse vetor é o resultado da transformação iPCA, uma transformação com propriedades de compressão de energia. Consequentemente, espera-se que a informação em  $s$  não esteja dispersa ao longo de todo o espaço de sinal  $S$ . Esse comportamento justifica a preferência da abordagem por seleção de características na redução de dimensionalidade (Englehart, 1998).

A seleção de características dos espaços projetados com iPCA pode ser interpretada como um problema de otimização onde o propósito é encontrar um subconjunto  $O$  de  $N_I$  elementos a partir de um conjunto de  $CN$  canais garantindo informação discriminativa máxima no subconjunto escolhido. Este pode ser classificado como um problema de otimização discreta, pela restrição implícita de elementos inteiros no subconjunto  $O$ ; o identificador de um canal é um número inteiro. Os componentes deste problema de otimização são:

- *Variáveis de decisão*: são as incógnitas que definem a solução do modelo. Estão representadas por cada elemento do vetor  $O$ :  $O(k)$  para  $k=1, \dots, N_I$ . Cada elemento do vetor  $O$  pode tomar valores na faixa  $[1 - CN]$ . A escolha de  $N_I$  é externa ao algoritmo e geralmente é definida pelas condições particulares do problema de otimização como será indicado no capítulo 4.
- *Espaço de busca*: é o conjunto de pontos que representam as soluções factíveis e infactíveis ao problema de otimização. Está representado pelo espaço  $\mathfrak{R}^{N_I}$ .
- *Função custo*: é a função matemática que deve ser otimizada. O valor da função custo avaliada em uma possível solução indica a quantidade de informação discriminativa dessa solução. Este valor é conhecido como valor de *aptidão*.

- *Restrições*: são condições que limitam o espaço de busca. No problema pesquisado existe uma única restrição. Neste caso, o sistema deve evitar soluções compostas com canais repetidos. Esta restrição é definida pela relação de proporção inversa que existe entre o desempenho de classificação e a quantidade de redundância nos canais de aquisição do sinal de EMG (vide Capítulo 2).
- *Exploração (exploration)*: processo de visitar pontos inteiramente novos no espaço de busca.
- *Exploração (exploitation)*: processo de explorar o espaço de busca utilizando informações de pontos anteriormente visitados a fim de encontrar pontos com melhor aptidão.

A seleção de características é um processo iterativo onde são executadas duas etapas interdependentes: (a) *algoritmo de busca*, (b) *função custo*; como se indica na Figura 3-5. Nesta figura o vetor  $O'$  é um vetor composto por um subconjunto dos  $CN$  canais candidatos. Os componentes deste vetor mudam em cada iteração do processo, seguindo uma estratégia definida pelo algoritmo de busca. A função custo permite avaliar quantitativamente quão bom é o subconjunto de canais  $O'$  respeito da maximização da informação discriminativa dos canais. Uma vez sejam satisfeitos os *critérios de parada* da busca, o esquema da Figura 3-5 entrega na sua saída o vetor  $O$  com a sequência dos  $N_I$  canais escolhidos.

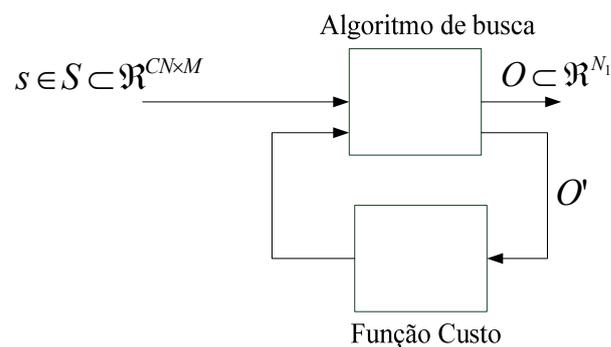


Figura 3-5. Redução de dimensionalidade por seleção de características.

### 3.4.2 - Algoritmos de busca

Os algoritmos de busca podem ser divididos em dois grupos: exaustivos (ou ótimos) e sub-ótimos. Nos algoritmos exaustivos avalia-se a função custo para as  $\psi$  combinações

possíveis de canais; com  $\psi = \binom{CN}{N_1}$ .

Posteriormente, se escolhe a combinação com valor ótimo da função custo. A principal desvantagem desta abordagem é o esforço computacional requerido, ainda para pequenos valores de  $CN$ ,  $N_1$ . Por exemplo, para  $CN=20$ ,  $N_1=5$ , o número de combinações é de 15504. Por esta razão o método não é apropriado para aplicações práticas (Theodoridis, et al., 2006). Por outro lado, existe o grupo de algoritmos sub-ótimos que consegue garantir resultados aceitáveis com menores esforços computacionais. Esse grupo pode ser dividido em duas categorias: (1) *sequenciais* e (2) *bio-inspirados*.

Dentro da categoria de algoritmos sequenciais encontram-se três subgrupos: (a) *clássicos*, (b) *flutuantes* e (c) *flutuantes-adaptativos*. No grupo de algoritmos clássicos destacam-se o SFS (*sequential forward selection*) e o SBS (*sequential backward selection*). Esses algoritmos são bastante intuitivos e de baixo custo computacional, porem, apresentam o efeito *nesting effect* que impede rejeitar um candidato uma vez há sido escolhido em uma interação prévia ou vice-versa (aceitar um candidato uma vez há sido rejeitado) (Theodoridis, et al., 2006). Procurando eliminar o *nesting effect*, no ano 1994 foram propostos os algoritmos flutuantes (Pudil, et al., 1994). Nessa alternativa é possível aceitar candidatos que em iterações prévias foram rejeitados assim como rejeitar candidatos que foram aceitos em iterações prévias. Desta forma, os algoritmos flutuantes conseguem eliminar as implicações do *nesting effect*.

Existem dois esquemas para desenvolver os algoritmos flutuantes: SFFS (*sequential floating forward selection*), SFBS (*sequential floating backward selection*). A principal crítica nesses esquemas é a utilização de adições ou rejeições de um único candidato por iteração. Procurando um ganho de eficiência nesse aspecto, em 1999 foi proposto o subgrupo de algoritmos flutuantes adaptativos (Somol, et al., 1999). A diferença fundamental entre o grupo flutuante e o flutuante-adaptativo está na quantidade de candidatos que podem ser aceitos ou rejeitados em cada iteração do algoritmo. O algoritmo adaptativo pode determinar esse número dinamicamente. Como

consequência, tem o potencial de encontrar uma solução mais próxima da solução ótima, mas, com um maior esforço computacional. Em (Campos, et al., 2000) são realizados testes comparando os grupos flutuante e flutuante-adaptativo em termos de desempenho, em um problema de discriminação de faces. Conclui-se que o desempenho dessas categorias é similar, mas o tempo de resposta é muito maior no caso da categoria adaptativa. Consequentemente, nesta pesquisa somente será considerada a alternativa sequencial flutuante (SFFS).

A segunda categoria de algoritmos sub-ótimos é a categoria de algoritmos bio-inspirados ou baseados em *inteligência de enxames*. Inteligência de enxames (ou *swarm intelligence*) é a denominação de uma subárea da inteligência computacional que abrange um conjunto de metodologias e técnicas inspiradas na inteligência coletiva observada em algumas espécies animais como: os insetos sociais (formigas, cupins, abelhas, vespas, etc.), bandos de pássaros, cardumes, etc. De um modo geral, a inteligência de enxames reúne uma gama de algoritmos que encontram suas principais aplicações em problemas de otimização e de planejamento. Tais algoritmos simulam a dinâmica de populações de pequenos indivíduos que se comunicam, desenvolvendo uma inteligência coletiva que os permite solucionar problemas com sofisticado grau de complexidade, de forma extremamente eficiente. Nesta pesquisa serão consideradas duas alternativas de algoritmos de busca baseados em inteligência de enxames: otimização por enxame de partículas (PSO), colônias artificiais de abelhas (ABC).

A seguir é feita uma descrição dos algoritmos de busca considerados neste projeto.

#### 3.4.2.1 – Seleção sequencial (SFS)

Este é um dos primeiros algoritmos desenvolvidos para resolver o problema de seleção de características. O procedimento de busca consiste dos seguintes passos: (1) calcule a aptidão de cada um dos  $CN$  canais, logo, escolha o canal com maior aptidão. (2) arrume todos os vetores de duas dimensões possíveis que incluam o canal escolhido no passo 1, (3) calcule a aptidão para cada vetor, logo, (4) escolha a combinação de maior aptidão, (5) repita o mesmo processo até que consiga o vetor de comprimento  $N_I$ .

O principal problema do algoritmo SFS é a impossibilidade de rejeitar canais escolhidos em iterações prévias. Este problema é conhecido como o *nesting effect*.

### 3.4.2.2 – Seleção sequencial flutuante (SFFS).

SFFS é um algoritmo de busca sub-ótimo proposto por Pudil et al. no ano de 1994 (Pudil, et al., 1994) e utilizado em problemas de seleção de características. Para aplicar este algoritmo no problema de redução de dimensionalidade definido, são considerados os dados de entrada  $s \in S \subset \mathfrak{R}^{CN \times M}$  (na Figura 3-5) como um conjunto de  $CN$  canais candidatos. O algoritmo SFFS começa a iterar com um subconjunto inicial  $O'$  de dois canais. Para cada iteração faz dois processos básicos: (1) procura o canal candidato que otimiza a função custo e o inclui no conjunto  $O'$ . (2) verifica se a função custo pode ser otimizada rejeitando um canal do conjunto  $O'$ .

Consequentemente, a busca com SFFS é executada dinamicamente acrescentando e decrementando o número de canais em  $O'$  até atingir o subconjunto de comprimento  $N_I$ . A seguir é apresentado o algoritmo SFFS.

Considerando um conjunto de canais de dimensão  $CN$ , a ideia é procurar o melhor subconjunto de dimensão  $k$  para  $k=1, 2, \dots, N_I < CN$ , de tal forma que uma função custo seja otimizada. Define-se  $O_k = \{o_1, o_2, \dots, o_k\}$  como o conjunto com a melhor combinação de  $k$  canais. Adicionalmente é definido  $P_{CN-k}$  como o conjunto de canais restante de  $CN-k$  elementos. Finalmente, é definido que todos os melhores subconjuntos de dimensões menores que  $N_I$  têm que ser registrados:  $O_2, O_3, \dots, O_{N_I-1}$  de 2, 3, ...,  $N_I-1$  canais, respectivamente.

Os passos do algoritmo considerando a maximização da função custo  $f(.)$  são indicados no Algoritmo 3-2 (Theodoridis, et al., 2006), (Pudil, et al., 1994).

O algoritmo é iniciado com o conjunto  $O_{k_{init}}$ . Geralmente, este conjunto é obtido rodando o algoritmo SFS (Theodoridis, et al., 2006) em busca dos  $k_{init}$  melhores canais. As iterações de SFFS terminam quando os  $N_I$  elementos têm sido escolhidos. Ainda quando o algoritmo SFFS não garante encontrar a melhor solução, seus resultados são superiores respeito das alternativas sequenciais, à custa de maior complexidade. Este algoritmo garante que o vetor de saída  $O_{N_I}$  não tenha canais repetidos entre seus componentes. Esta característica é uma vantagem na solução do problema de redução de dimensionalidade dos dados projetados com iPCA.

*Passo I. Inclusão.*

$o_{k+1} = \arg \max_{p \in P_{CN-k}} f(\{O_k, p\})$ ; ou seja, escolher o elemento de  $P_{CN-k}$  que combinado com o conjunto  $O_k$ , resulte no maior valor da função custo  $f$ . Posteriormente, definir o conjunto  $O_{k+1}$ :

$$O_{k+1} = \{O_k, o_{k+1}\}$$

*Passo II. Prova.*

1.  $o_r = \arg \max_{p \in O_{k+1}} f(O_{k+1} - \{p\})$ ; ou seja, encontrar o elemento de  $O_{k+1}$  que gera o menor efeito sobre a função custo  $f$  quando é removido de  $O_{k+1}$ .
2. Se  $r=k+1$ , então, faça  $k=k+1$  e volte ao passo I.
3. Se  $r \neq k+1$  AND  $f(O_{k+1} - \{o_r\}) < f(O_k)$ , então, volte ao passo I; ou seja, se a rejeição de  $o_r$  não melhora o custo do melhor grupo de  $k$  elementos escolhido previamente, não se faz mais busca para trás (*backward search*).
4. Se  $k=k_{init}$ , então, faça  $O_k = O_{k+1} - \{o_r\}$  and  $f(O_k) = f(O_{k+1} - \{o_r\})$ , volte ao passo I.

*Passo II. Remoção.*

1.  $O'_k = O_{k+1} - \{o_r\}$ ; ou seja, remova  $o_r$ .
  2.  $o_s = \arg \max_{p \in O'_k} f(O'_k - \{p\})$ , ou seja, encontre o elemento menos significativo no novo conjunto  $O'_k$ .
  3. Se  $f(O'_k - \{o_s\}) < f(O_{k-1})$ , então, faça  $O_k = O'_k$  e volte ao passo I; não se faz mais busca para trás (*backward search*).
  4. Faz  $O'_{k-1} = O'_k - \{o_s\}$  e  $k=k-1$ .
  5. Se  $k=k_{init}$ , então, faz  $O_k = O'_k$  and  $f(O_k) = f(O'_k)$  e volte ao passo I.
  6. Voltar ao passo III.1
-

### 3.4.2.3 – Otimização por enxame de partículas (PSO).

PSO é uma técnica de otimização estocástica desenvolvida por Eberhart e Kenedy em 1995 (Eberhart, et al., 1995 ) e inspirada no comportamento social de enxames de pássaros e cardumes de peixes. Nesse algoritmo, as soluções potenciais, chamadas de indivíduos ou *partículas*, podem ser consideradas simples agentes ‘voando’ ao longo do espaço de busca do problema. A localização ou *posição* de uma partícula no espaço multidimensional é considerada uma solução do problema de otimização; esta é representada por um vetor de valores reais  $N_I$ -dimensional. Cada indivíduo fornece as coordenadas de posição atual para uma função custo, que retorna a aptidão da solução. Posteriormente, o indivíduo se movimenta para uma nova posição e repete o mesmo processo. PSO compartilha algumas similitudes com *algoritmos genéticos*: o algoritmo PSO é iniciado com uma *população* aleatória de soluções e posteriormente atualiza suas soluções por gerações. Os fatores que compõem o PSO são (Robinson, et al., 2004):

- *O enxame*: é uma coleção de partículas. O número de partículas  $S$  é dependente do problema de otimização e geralmente encontra-se na faixa de 10 até 50.
- *Partícula*.: é um único indivíduo do enxame. Tem uma velocidade aleatória  $v_i$  que permite sua movimentação ao longo do espaço de busca. Tem memória com capacidade para lembrar: (a) a posição em que encontrou seu melhor valor de aptidão (memória individual), (b) a posição em que o enxame encontrou o melhor valor de aptidão (memória coletiva).
- *Posição*: indica a coordenada que uma partícula específica ocupa no espaço  $N_I$ -dimensional do problema.
- *Topologia*: cada partícula tem uma topologia que provoca o efeito de enlace com outra partícula no enxame. Existem duas topologias básicas: (a) sociometria *gbest* (b) sociometria *lbest*. Na topologia *gbest* cada partícula tem conhecimento acerca da melhor solução descoberta pelo enxame completo. Em contraste, na topologia *lbest* cada partícula lembra a localização onde encontrou sua melhor solução.
- *Aptidão*: valor que representa quão boa é uma solução. Geralmente, é o resultado de avaliação da função custo.

Durante as iterações do algoritmo cada partícula ajusta sua trajetória no espaço objetivando se movimentar na direção a sua melhor posição e a melhor posição global de acordo com as seguintes equações:

$$v_{ij}(t+1) = w * v_{ij}(t) + c_1 * r_1 * (pbest_{ij} - x_{ij}(t)) + c_2 * r_2 * (gbest_{ij} - x_{ij}(t)) \quad (3-15)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad (3-16)$$

onde,

$i$  é o índice da partícula;  $i \in 1, \dots, S$  ;

$j$  é o índice de dimensão com  $j \in 1, \dots, N_1$  ;

$N_1$  é o número total de dimensões ou parâmetros de otimização;

$x_i$  é a posição atual da partícula  $i$ ;

$v_i$  é a velocidade atual da partícula  $i$ ;

$w$  é um fator de escala que decresce linearmente durante a execução do algoritmo.

$r_1$  e  $r_2$  são dois números aleatórios com distribuição uniforme na faixa  $[0,1]$ . Por outro lado,  $c_1$  e  $c_2$  são parâmetros cognitivos e parâmetros sociais respectivamente.  $pbest_i$  é a melhor posição local, ou seja, a posição da partícula  $i$  onde a função custo atingiu o máximo valor até o instante  $t$ ;  $gbest$  é a melhor posição global, ou seja, a posição entre todas as partículas do enxame onde a função custo atingiu o máximo valor até o instante  $t$ . As velocidades  $v_{ij}$  estão limitadas na faixa  $[v_{min}, v_{max}]$  evitando que as partículas abandonem o espaço de busca.

Considerando o problema de minimização da função custo  $f(\cdot)$ , a equação (3-17) pode ser utilizada para atualizar a melhor posição de cada partícula em cada iteração do algoritmo.

$$pbest_i(t+1) = \begin{cases} pbest_i(t) & \text{if } f(pbest_i(t)) < f(x_i(t)) \\ x_i(t) & \text{if } f(pbest_i(t)) \geq f(x_i(t)) \end{cases} \quad (3-17)$$

Finalmente, a melhor partícula global do enxame é atualizada utilizando a seguinte equação:

$$gbest(t+1) = \arg \min_{pbest_i} f(pbest_i(t+1)) \quad (3-18)$$

O algoritmo descrito é utilizado para problemas de otimização contínuos, entretanto, como foi definido na seção 3.4.1 -, o problema de redução de dimensionalidade dos dados projetados com iPCA é um caso de otimização discreto.

Em (Khushaba, et al., 2007) e (Jin, et al., 2008) apresenta-se uma modificação do PSO que busca aproximar a posição calculada por cada partícula pelo inteiro mais próximo. Esta modificação, chamada de *PSO discreto*, pode ser utilizada para resolver o problema de otimização de escolha de canais. Com base nesta modificação obtém-se:

$$v_{ij}(t+1) = w * r(v_{ij}(t)) + c_1 * r_1 * r(pbest_{ij} - x_{ij}(t)) + c_2 * r_2 * r(gbest_{ij} - x_{ij}(t)) \quad (3-19)$$

$$x_{ij}(t+1) = x_{ij}(t) + r(v_{ij}(t+1)) \quad (3-20)$$

onde  $r(.)$  é a função de arredondamento ao inteiro mais próximo.

Diversos aportes e modificações têm sido propostos para o algoritmo PSO. Um dos mais interessantes é a inclusão da segunda melhor posição na equação de atualização da velocidade (Forbes, et al., 2001). O propósito desta modificação é promover a diversidade e convergência lenta do algoritmo restringindo o movimento de cada partícula respeito da soma ponderada das distâncias com a primeira e segunda melhor posição encontradas pelo enxame. A equação de atualização de velocidade utilizada nesta variação do PSO é indicada na equação (3-21).

$$v_{ij}(t+1) = w * r(v_{ij}(t)) + c_1 * r_1 * r(pbest_{ij} - x_{ij}(t)) + \dots \quad (3-21)$$

$$\dots + c_2 * r_2 * r(gfbest_{ij} - x_{ij}(t)) + c_3 * r_3 * r(gsbest_{ij} - x_{ij}(t))$$

Em que  $gfbest$  é a primeira melhor solução encontrada pelo enxame,  $gsbest$  é a segunda melhor solução encontrada pelo enxame,  $r_3$  é um número aleatório com distribuição uniforme na faixa [0,1].

Os parâmetros do algoritmo são resumidos na Tabela 3-2 e os passos básicos são ilustrados no Algoritmo 3-3. Neste algoritmo os critérios de parada geralmente são dois: Máximo número de iterações  $C_{max}$  ou valor ótimo da função custo  $f(.)$

Tabela 3-2. Parâmetros do algoritmo PSO

<b>Parâmetros</b>	<b>Símbolo</b>	<b>Observação</b>
Parâmetro cognitivo	$c_1$	Um valor alto indica partículas com alta autoconfiança na sua experiência.
Parâmetros sociais	$c_2, c_3$	Um valor alto proporciona às partículas maior confiança no enxame
Peso de inércia	$w$	Controla a capacidade de exploração das partículas. Valores grandes resultam em uma busca global. Valores pequenos permitem às partículas explorar localmente a vizinhança de uma possível solução.
Tamanho do enxame	$S$	Indica o número de partículas na busca
Limites de velocidade	$[v_{min}, v_{max}]$	
Limites de posição	$[x_{min}, x_{max}]$	
Máximo número de iterações	$C_{max}$	Critério de parada do algoritmo

Algoritmo 3-3. Busca do valor mínimo com PSO

---

### 1. Inicialização

- a. Inicializar o enxame. A posição e velocidade das partículas são calculados aleatoriamente com três restrições: (1) limites de posição, (2) coordenadas compostas por valores inteiros e (3) Coordenadas sem pontos repetidos.

### 2. REPETE

- a. Calcular o valor de aptidão para a posição de cada partícula no enxame.
- b. Atualizar a melhor partícula do enxame utilizando a equação (3-17).
- c. Atualizar a melhor posição individual de cada partícula utilizando a equação (3-18)
- d. Atualizar a posição das partículas utilizando equações (3-19), (3-20).
- e. Conferir limites de posição e velocidade das partículas.

### 3. ATÉ (Critérios de parada satisfeitos)

---

#### 3.4.2.4 – Colônias artificiais de abelhas (ABC)

O algoritmo ABC é uma técnica de otimização baseada em inteligência de populações, proposta por Karaboga (Karaboga, 2005) e inspirada no comportamento social das colônias de abelhas durante a coleta de alimento. Nesse algoritmo cada solução ao problema de otimização é chamada de *fonte de alimento* e é representada por um vetor de valores reais  $N_I$ -dimensional. A avaliação da solução corresponde com a quantidade de *néctar* da fonte de alimento associada.

Existem três tipos de abelhas na colônia artificial (Karaboga, et al., 2007):

- *Operária (employed)*: abelha indo para a fonte de alimento que visitou previamente.
- *Seguidora (onlooker)*: abelha esperando (na área de dança) fazer a escolha de fonte de alimento na área de dança da colmeia.
- *Escoteira (scout)*: abelha realizando uma busca de alimento aleatória.

A primeira metade da colônia consiste de abelhas operárias e a segunda metade de seguidoras. Para cada fonte de alimento existe unicamente uma abelha operária. Consequentemente, o número de abelhas operárias é igual ao número de fontes de alimento. A categoria escoteira é um estado transitório das abelhas operárias. A abelha operária cuja fonte de alimento tem sido exaurida (pela mesma campeira ou pelas seguidoras) converte-se numa escoteira.

O algoritmo pode ser dividido em duas etapas: (1) etapa de inicialização e (2) etapa iterativa. Na primeira etapa as abelhas operárias escolhem fontes de alimento aleatoriamente e determinam a quantidade de néctar. Posteriormente, essas abelhas retornam à colmeia e compartilham a informação de néctar com as abelhas seguidoras. Na segunda etapa são desenvolvidas três fases iterativamente: (a) enviar as abelhas operárias a medir o néctar numa fonte de alimento candidata, (b) posteriormente, cada abelha seguidora escolhe com certa probabilidade uma fonte de alimento a explorar (*exploitation*), (c) determinar que operárias tornam-se escoteiras e enviá-las em procura de novas fontes de alimento.

A seguir é feita uma descrição mais detalhada destas etapas.

- **Etapa de Inicialização**

Nesta etapa o algoritmo ABC gera uma população inicial de  $S$  soluções distribuídas aleatoriamente no espaço de solução  $\mathfrak{R}^{N_1}$ ;  $S$  indica o tamanho da população. Cada solução  $x_i$  ( $i=1,2,\dots,S$ ) é um vetor de dimensão  $N_1$ , com  $N_1$  número de parâmetros de otimização. As abelhas campeiras determinam a quantidade de néctar nas soluções iniciais. Posteriormente, retornam à colmeia e compartilham a informação de néctar com as abelhas seguidoras.

- **Etapa Iterativa**

Depois da inicialização, a população de soluções é submetida a ciclos repetitivos  $C=1,2,\dots,C_{max}$ , de processos de busca. Os processos realizados são: *fase das operárias*, *fase das seguidoras* e *fase das escoteiras*. Cada abelha tem capacidade de memória para lembrar a localização de uma fonte de alimento. Durante a etapa iterativa as abelhas modificam o conteúdo desta memória de forma probabilística objetivando encontrar as fontes de alimento com melhor aptidão.

- **Fase das operárias:** nesta etapa, cada operária retorna para a fonte de alimento  $x_i$  em sua memória, posteriormente calcula uma nova fonte de alimento  $v_i$  na vizinhança. No modelo utilizado (Karaboga, et al., 2007) a escolha da nova fonte de alimento é baseada num processo de comparação de posições com componentes aleatórios, conforme a expressão,

$$v_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) \quad (3-22)$$

Se a quantidade de néctar da fonte  $v_i$  é maior do que a associada com  $x_i$ , então, a abelha memoriza a nova posição e esquece a antiga. De outra forma, a abelha conserva a posição da fonte de alimento  $x_i$ .

Uma vez terminada a fase das operárias, é calculada uma probabilidade  $p_i$  associada com o nível de néctar em cada fonte de alimento  $x_i$ . O cálculo desta probabilidade é feito utilizando a equação (3-23).

- **Fase das seguidoras:** nesta etapa as abelhas seguidoras avaliam a informação de néctar fornecida por todas as operárias e escolhem uma fonte de alimento  $x_i$  para explorar; a escolha é baseada na probabilidade

$p_i$  de cada fonte de alimento. Como no caso das campeiras, as abelhas seguidoras calculam uma nova fonte de alimento  $v_i$  na vizinhança da fonte  $x_i$  escolhida. O cálculo da coordenada  $v_i$  é feito com a equação (3-22). Posteriormente, é avaliada a quantidade de néctar em  $v_i$ . Se esta é maior do que a contéuda na fonte  $x_i$ , então, a abelha memoriza a nova posição e esquece a antiga.

- **Fase das escoteiras:** cada vez que a exploração de uma coordenada  $x_i$  não consegue melhorar o nível de néctar na memória das abelhas, então, um contador atualiza o número de ciclos de aprimoramento da coordenada  $x_i$ . Se o valor deste contador excede o número de ciclos limite de aprimoramento  $C_{lim}$ , então, a fonte de alimento  $x_i$  é abandonada pelas abelhas. Quando uma fonte de alimento é abandonada, uma nova fonte de alimento é determinada aleatoriamente por uma abelha escoteira. O algoritmo ABC modela este comportamento calculando uma posição aleatória que substitui a posição abandonada.

Uma abelha seguidora escolhe uma fonte de alimento baseada no valor da probabilidade associada com a fonte,  $p_i$ , calculada conforme

$$p_i = \frac{fit_i}{\sum_{n=1}^S fit_n}, \quad (3-23)$$

onde  $fit_i$  é o valor da função custo para a solução  $i$  avaliada pela abelha operária. Esse valor é proporcional à quantidade de néctar da fonte de alimento na posição  $i$  e  $S$  é o número de fontes de alimento. Esta é a forma em que a informação das operárias é compartilhada com as seguidoras.

No intuito de produzir uma posição de alimento na vizinhança da posição  $x_i$ , o algoritmo utiliza a equação (3-22), onde  $k$  e  $j$  são índices escolhidos aleatoriamente. O índice  $k$  tem que ser diferente do índice  $i$ .  $\phi_{ij}$  é um número aleatório na faixa  $[1, -1]$  que controla a geração de fontes de alimento na vizinhança de  $x_{ij}$ . A equação (3-22) indica que, enquanto a diferença entre os parâmetros  $x_{ij}$ ,  $x_{kj}$  reduz-se, a perturbação na posição  $x_{ij}$  também se reduz. Conseqüentemente, enquanto a busca alcança a solução ótima, o tamanho do passo é reduzido adaptativamente. Se  $v_{ij}$  calculada excede o limite predeterminado, o parâmetro é forçado para um valor aceitável.

Os parâmetros do algoritmo ABC são resumidos na Tabela 3-3 e , os passos básicos do algoritmo são ilustrados no Algoritmo 3-4.

Tabela 3-3. Parâmetros do algoritmo ABC

Parâmetros	Símbolo	Observação
Número de fontes de alimento	$S$	Define o número de abelhas campeiras e seguidoras
Valores limite	$[v_{min}, v_{max}]$	
Número máximo de ciclos	$C_{max}$	
Ciclos limite no aprimoramento de uma solução	$C_{lim}$	

Algoritmo 3-4. Busca do valor mínimo com o algoritmo ABC.

- 
1. Inicialização
  2. REPETE
    - a. Fase das operárias.
    - b. Calcular probabilidades  $p_i$  para cada fonte de alimento.
    - c. Fase das seguidoras.
    - d. Fase das escoteiras.
  3. ATÉ (critérios de parada satisfeitos)
- 

### 3.4.3 - Funções custo

As funções custo utilizadas para avaliar a quantidade de informação discriminativa do subconjunto de canais  $O'$  podem ser divididas em duas categorias: (a) *supervisionadas*, (b) *não supervisionadas*. Na primeira categoria a função custo utiliza entre seus argumentos o padrão EMG e a classe  $y$  dos padrões EMG. Consequentemente, a escolha do vetor  $O'$  é baseada no desempenho do sistema de classificação. Na segunda categoria a função custo utiliza unicamente os padrões EMG; esta categoria tem a vantagem de menores requerimentos computacionais. Neste projeto serão avaliadas duas funções custo: (a) o *erro de classificação* como alternativa supervisionada e (b) o *fator de correlação* como alternativa não supervisionada.

#### 3.4.3.1 - Erro de classificação

O erro de classificação é o indicador ideal para determinar padrão EMG com maior informação discriminativa. Este pode ser calculado com a expressão definida na

equação (3-24). Note que um dos argumentos do erro de classificação é a classe predita  $\hat{y}$ , isto significa que para calcular essa função é necessário resolver o processo de classificação na Figura 3-6. Conseqüentemente, a complexidade computacional envolvida é significativa (vide Capítulo 2).

$$erro = 100\% \times \frac{\#decisõesErradas}{\#totalDecisões} \quad (3-24)$$

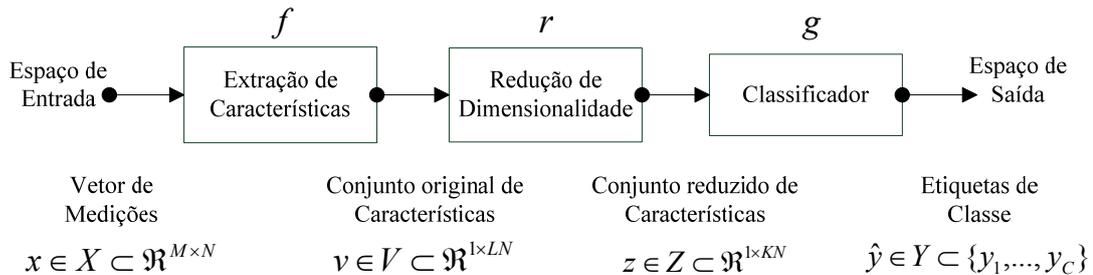


Figura 3-6. Diagrama de blocos do processo de classificação para um sistema de controle mioelétrico multicanal convencional

Pode ser observado que o esquema na Figura 3-6 precisa de padrões de treinamento e teste na configuração dos parâmetros do classificador. Na avaliação considerada neste projeto os mesmos padrões de validação serão utilizados como padrões de treinamento e teste durante o cálculo da função custo erro de classificação; ou seja, cada grupo de canais candidatos ( $O'$ ) é utilizado independentemente para treinar e subsequentemente testar o desempenho de classificação. Esta metodologia foi utilizada na pesquisa apresentada em (Hargrove, et al., 2009) para um processo de condições similares.

### 3.4.3.2 - Fator de correlação

O fator de correlação é um índice que permite quantificar o nível de correlação entre as  $N$  dimensões de um vetor  $x$ . Atualmente, têm sido propostos vários índices para quantificar essa variável, sendo que o de maior aceitação é o fator de correlação cruzada (Mogk, et al., 2003). A equação para calcular este fator num vetor  $x$  de duas dimensões é a seguinte:

$$C_x(x_1, x_2) = E[(x_1 - \mu_1)(x_2 - \mu_2)] \quad (3-25)$$

onde  $E[.]$  é a função de valor esperado e  $\mu_i = E[x_i]$ . Para o caso de sinais de  $N$  dimensões utiliza-se a matriz de coeficientes de correlação na equação (3-26). Esta

matriz contém elementos com valores na faixa [1, -1] para cada par de dimensões do vetor  $x$ .

$$R_x(i, j) = \frac{C_x(i, j)}{\sqrt{C_x(i, i)C_x(j, j)}} \quad (3-26)$$

para  $i=1, \dots, N; j=1, \dots, N$ ;

Quando a correlação é nula a amplitude do coeficiente  $R_x(i, j)$  é zero. Quando a correlação indica proporcionalidade direta o coeficiente é positivo e quando a correlação indica proporcionalidade inversa o coeficiente é negativo. Para visualizar estas três condições, considere o exemplo no Apêndice D - .

A matriz  $R_x$  é simétrica e tem diagonal principal unitária, conseqüentemente, para quantificar o nível de correlação que representa é suficiente considerar os elementos acima ou embaixo da diagonal principal. A equação (3-27) considera os elementos embaixo da diagonal principal e aplica uma somatória sobre o valor absoluto desses para calcular o fator de correlação. A inclusão do valor absoluto é necessária para evitar eliminação de coeficientes na somatória. Pode ser observado que o fator só pode tomar valores positivos e seu valor mínimo é zero.

$$f_c = \text{sum}(\text{trinf}(|R_x|)) \quad (3-27)$$

onde,  $\text{trinf}(\cdot)$  é uma função que calcula a sequencia dos elementos embaixo da diagonal principal da matriz que recebe como argumento. Uma versão normalizada do coeficiente de correlação é apresentada na equação (3-28). Nesta versão a amplitude do coeficiente  $F_c$  é restrita na faixa [0-100].

$$F_c = 100 * \frac{f_c}{\frac{N^2 - N}{2}} \quad (3-28)$$

com  $N$  dimensão do vetor  $x$ .

É importante esclarecer que o propósito da rotina de otimização é minimizar a função custo fator de correlação  $F_c$ . Isto garante baixa redundância nos padrões EMG e incrementa a informação discriminativa de classe.

### 3.5 - RESUMO DO CAPÍTULO

Neste capítulo foi apresentada uma perspectiva global do processo de classificação dos sinais EMG com sintonização iPCA. A apresentação foi dividida em três partes: (1) inicialmente foram discutidos fundamentos básicos da transformação PCA, destacando a definição de *componentes principais* e as vantagens de compressão de energia da transformação, (2) seguidamente foi apresentada a proposta iPCA que procura aproveitar vantagens de compressão de energia em problemas de classificação de padrões, (3) finalmente, foi discutida a etapa de redução de dimensionalidade necessária na abordagem de classificação iPCA dos sinais eletromiográficos.

Na seção 3.2 - foram definidos os componentes principais, o processo de cálculo da matriz de transformação  $W$  que garante correlação mútua nula no espaço projetado e as propriedades de compressão de energia da transformação PCA. Esta informação permitiu concluir que PCA é uma transformação ótima para aplicações de compressão de informação, mas subótima para aplicações de classificação. Isto basicamente porque desconsidera a informação de classes de movimento dos padrões que transforma.

Na seção 3.3 - foi apresentada a transformação iPCA, uma variação de PCA para aplicação em sistemas de classificação. Junto com a definição de iPCA foram apresentadas duas estratégias de classificação dos padrões projetados com iPCA: (a) classificação independente de subespaços, (b) classificação conjunta de subespaços. Dentre estas alternativas foi escolhida a mais apropriada para o problema de controle mioelétrico: classificação conjunta de subespaços. A factibilidade desta alternativa envolve a aplicação de uma etapa de redução de dimensionalidade. Os aspectos relacionados com esta etapa foram discutidos na seção 3.4 -.

Na seção 3.4 - foi apresentado o problema de redução de dimensionalidade dos padrões projetados com iPCA. Depois de analisar as características das projeções feitas com iPCA foi concluído que a abordagem mais apropriada para a redução de dimensionalidade é a *seleção de características*. Esta técnica foi interpretada como um problema de otimização onde foram definidos os componentes básicos: algoritmo de busca e a função custo. A apresentação destes componentes foi focada nas alternativas que buscam ser avaliadas dentro do projeto de pesquisa: Algoritmos de busca: SFS, SFFS, PSO e ABC; Funções custo: erro de classificação, fator de correlação. No seguinte capítulo será apresentada a metodologia experimental utilizada nesta avaliação.

## 4 - METODOLOGIA EXPERIMENTAL E RESULTADOS

### 4.1 - INTRODUÇÃO

Este capítulo apresenta a metodologia experimental utilizada para determinar o desempenho de classificação de cada combinação de *função custo* e de *algoritmo de busca* no sistema controle mioelétrico com sintonização iPCA. Adicionalmente, junto com a metodologia, são apresentados os resultados gerados em cada etapa.

### 4.2 - METODOLOGIA EXPERIMENTAL

O propósito desta pesquisa é determinar os efeitos das combinações *função custo*/ *algoritmo de busca* sobre o erro de classificação dos sistemas de controle mioelétrico com sintonização iPCA. Consequentemente, a abordagem experimental utilizada definiu dois fatores<sup>8</sup>: (A) *algoritmo de busca* e (B) *função custo*. O primeiro fator com quatro níveis<sup>9</sup>: (1) SFS, (2) SFFS, (3) PSO e (4) ABC. O segundo fator com dois níveis: (1) desempenho de classificação e (2) fator de correlação. As oito alternativas resultantes da combinação desses fatores são resumidas na Tabela 4-1. Nessa tabela,  $\bar{e}_{ij}$  representa o erro médio de classificação gerado com a matriz de transformação iPCA reduzida  $W_R^{ij}$ , onde  $i$  indica a função custo,  $j$  indica o algoritmo de busca para  $i=1,2; j=1,2,3,4$ .

Tabela 4-1. Alternativas de tratamento de sinal na redução de dimensionalidade dos padrões projetados com iPCA

		Algoritmo de busca (j)			
		SFS (1)	SFFS (2)	PSO (3)	ABC (4)
Função custo (i)	desempenho de classificação (1)	$\bar{e}_{11}$	$\bar{e}_{12}$	$\bar{e}_{13}$	$\bar{e}_{14}$
	fator de correlação (2)	$\bar{e}_{21}$	$\bar{e}_{22}$	$\bar{e}_{23}$	$\bar{e}_{24}$

O cálculo do erro de classificação  $\bar{e}_{ij}$  implica que para cada alternativa serão executadas as etapas 1 até 4 apresentadas na seção 3.3.2 - (vide Tabela 3-1). A Figura 4-1 resume essas etapas. A seguir são apresentados os detalhes no desenvolvimento de cada fase ilustrada na Figura 4-1.

<sup>8</sup> Neste sentido, um fator é a característica que diferencia os tratamentos de sinal avaliados durante a otimização.

<sup>9</sup> Os níveis são os diferentes valores que pode tomar um fator.

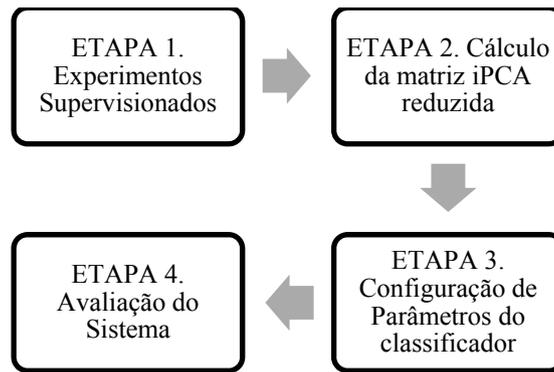


Figura 4-1 Metodologia de quatro etapas para obtenção do erro de classificação médio no sistema de controle mioelétrico com sintonização iPCA.

#### 4.2.1 - Etapa 1. Experimentos Supervisionados

Nesta etapa um conjunto de classes de movimento  $y$  que chamaremos de *classe alvo* é estabelecido pelo experimentador. Posteriormente, o usuário do sistema é estimulado a executar os movimentos numa sequência predefinida. Enquanto os movimentos são executados, um sistema de aquisição de sinais registra as amplitudes dos potenciais eletromiográficos gerados (sinal  $x$ ). O resultado é um conjunto de dados ou *base de dados*  $\mathfrak{S}$  composto por sinais eletromiográficos  $x$  e classes de movimento associadas  $y$ .

$$\mathfrak{S} = \{(x^{(1)}, y^{(1)}), \dots, (x^{(M)}, y^{(M)})\} \quad (4-1)$$

onde,  $\mathfrak{S}$  é a base de dados de padrão-classe. O índice sobrescrito <sup>(i)</sup> representa o  $i$ -ésimo par padrão-classe.

A base de dados EMG utilizada nesta pesquisa foi coletada em experimentos desenvolvidos na Universidade New Brunswick, no Canadá, sendo que a autorização para o uso desses dados foi fornecida pelo Dr. Levi Hargrove (Hargrove, et al., 2009). É importante ressaltar que a etapa de experimento supervisionada só foi executada uma vez por ser este um tratamento anterior ao cálculo da matriz iPCA reduzida, ou seja, anterior ao ponto onde são avaliadas as alternativas de função custo e de algoritmo de busca.

Os sinais eletromiográficos que compõem a base de dados utilizada neste trabalho estão associados com 11 classes de movimento e 10 sujeitos sem amputação. Os eletrodos utilizados foram de tipo superficial, especificamente *duotrodos* adesivos de Ag-AgCl, fabricados pela 3M. Esses eletrodos foram localizados na seção proximal do antebraço em forma de anel como se indica na Figura 4-3. Doze pontos equidistantes foram

marcados sobre a superfície da pele, os eletrodos foram localizados em dez dessas marcas excluindo as marcas laterais e médias.

Os dados experimentais foram coletados por sessões como se indica na Figura 4-2. Nessa estrutura cada sessão está composta por 8 ensaios. Cada ensaio consiste de duas repetições e cada repetição consiste da execução das 11 classes de movimento resumidas na Tabela 4-2. Esses movimentos são ilustrados na Figura 4-4.

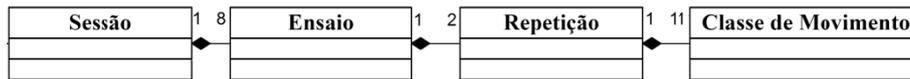


Figura 4-2. Estrutura do experimento de coleta de dados EMG

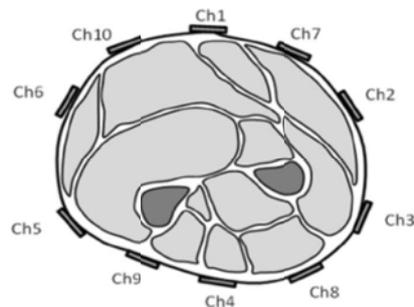


Figura 4-3. Distribuição dos eletrodos durante a aquisição do sinal EMG. A distribuição em anel garante os níveis de *crosstalk* necessários para a experimentação com a sintonização iPCA. Fonte: (Hargrove, et al., 2009).

Tabela 4-2. Identificadores das classes de movimento utilizadas durante a coleta de sinais EMG.

ID	Classe de movimento	ID	Classe de movimento
1	Pronação do antebraço ( <i>Forearm Pronation</i> )	7	Agarre de pinça ( <i>Chuck Grip</i> )
2	Supinação do antebraço ( <i>Forearm Supination</i> )	8	Agarre cilíndrico ( <i>Power Grip</i> )
3	Flexão do pulso ( <i>Wrist Flexion</i> )	9	Agarre fino ( <i>Fine Pinch Grip</i> )
4	Extensão do pulso ( <i>Wrist Extension</i> )	10	Agarre de ferramenta ( <i>Tool Grip</i> )
5	Mão aberta ( <i>Hand Open</i> )	11	Repouso ( <i>No movement</i> )
6	Agarre de chave ( <i>Key Grip</i> )		

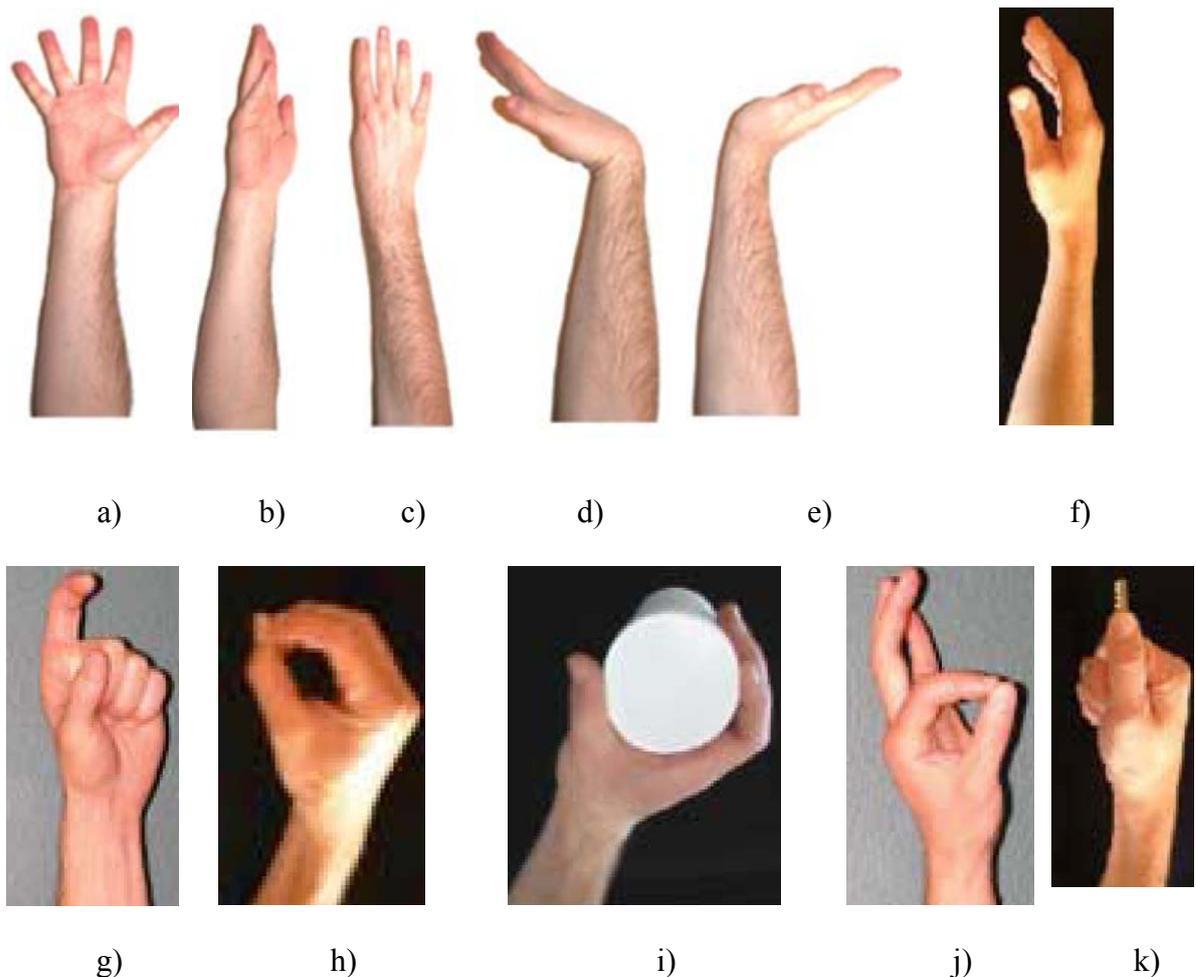


Figura 4-4. Classes de movimento: a) abrir mão, b) supinação, c) pronação, d) flexão do pulso, e) extensão do pulso, f) repouso, g) agarre de ferramenta, h) agarre pinça, i) agarre cilíndrico, j) agarre fino, k) agarre de chave. Fonte: (Kaufmann, et al., 2010) (Kuiken, et al., 2009)

O cotovelo do usuário descansou num reposab braços durante a execução dos movimentos. Os usuários não foram contidos durante a coleta de dados e receberam instruções para executar contrações repetíveis e de força constante. A intensidade da contração foi estabelecida pelo usuário, mas eles foram persuadidos para estabelecer uma intensidade constante durante todo o experimento. Foi reservado um tempo de 10 minutos no qual os usuários podiam interagir com o sistema. Neste tempo o experimentador instruiu ao sujeito para completar cada uma das contrações. Aliás, o sinal de EMG foi examinado pelo experimentador para garantir uma boa adesão entre eletrodos e pele para todos os movimentos. Os ganhos do sistema de aquisição também foram monitorados para evitar zonas de saturação.

Durante cada ensaio o usuário executou a contração desde o repouso, manteve a contração por 4 s e retornou à posição repouso durante um tempo chamado de IC (*intermotion class delay*). Os ensaios 1, 2, 3 e 4 utilizaram ICs de 3, 2, 1 e 0 s,

respectivamente. Os ensaios 5 até 8 utilizaram um IC de 2 s. Cada usuário utilizou um curto período de descanso entre ensaios, no intuito de prevenir fadiga. Esse período foi de pelo menos dois minutos. O experimento, incluindo localização de eletrodos demorou menos de 2 horas.

As repetições de classe foram consecutivas na ordem crescente, ou seja, dentro do ensaio foi executada a sequência de movimentos: 1, 1, 2, 2...,11, 11 como se indica na Figura 4-5.

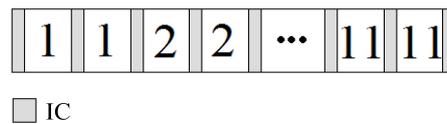


Figura 4-5. Sequência de classes de movimentos dentro do ensaio. O movimento no período de tempo entre classes (IC) corresponde com a classe de repouso (*no movement*). Fonte própria.

O sinal diferencial fornecido por cada *duotrodo* foi filtrado para garantir componentes de frequência na faixa [0-500]Hz e potenciais de tensão na faixa [-5, 5]V. Posteriormente, o sinal foi digitalizado com frequência de amostragem de 1kHz e resolução de 16 bits.

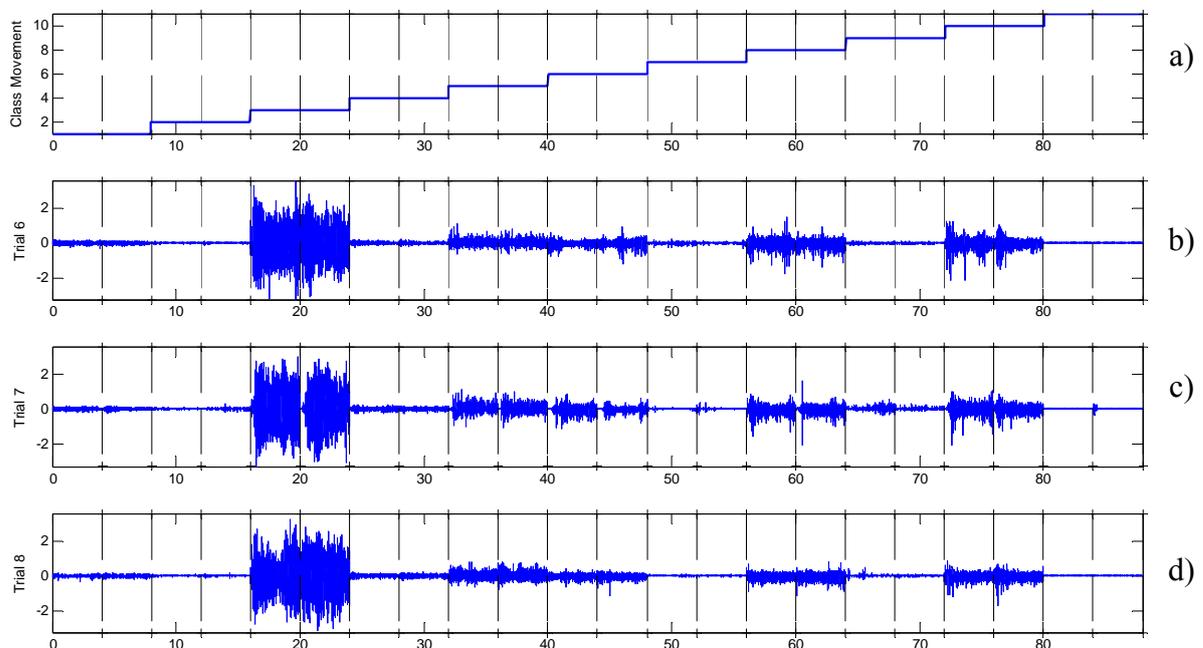


Figura 4-6. Sequência de execução dos movimentos durante a aquisição do sinal EMG. Os sinais ilustrados correspondem com o canal 1, durante os ensaios 6, 7 e 8, para o usuário 1.

Como exemplo ilustrativo, a Figura 4-6 apresenta alguns dos sinais de EMG na base de dados citada. Os dados exibidos correspondem a amostras adquiridas durante experimentação com um dos usuários. Na Figura 4-6 (a) é apresentada a sequência de movimentos executados durante o ensaio, as linhas verticais nesta figura estendem-se até as figuras b, c, d e indicam o instante de início e fim de uma classe de movimento. Nessa figura foram excluídos os intervalos IC. Nas Figuras (b) até (d) apresenta-se a amplitude do sinal EMG durante os ensaios 6, 7 e 8, respectivamente. Por facilidade só é ilustrado o sinal de EMG correspondente a um dos 10 canais de aquisição. A figura mostra como as tendências do sinal EMG em diferentes ensaios permitem identificar um fator repetitivo na amplitude do sinal EMG com relação a cada classe de movimento.

A base de dados  $\mathfrak{S}$  foi dividida em três grupos: 50% dos ensaios foi reservado para criar o conjunto de dados de treinamento  $\mathfrak{S}_t$ , 25% foi utilizado para dados de validação  $\mathfrak{S}_v$  e o último 25% para dados de teste  $\mathfrak{S}_i$ . A divisão dos grupos foi aleatória e é resumida na Tabela 4-3. Em todos os conjuntos de dados foram excluídas as amostras adquiridas durante o intervalo IC (*Intermotion Class Delay*) (Hargrove, et al., 2009).

Tabela 4-3. Divisão dos ensaios na base de dados

<b>Base de dados</b>	<b>Ensaio</b>
Treinamento	1, 3, 7, 8
Validação	5, 6
Teste	4, 2

#### 4.2.2 - Etapa 2. Cálculo da matriz iPCA reduzida

Esta etapa foi desenvolvida em duas fases: (a) busca do vetor de dimensões reduzidas  $O$  e (b) construção da matriz de transformação iPCA reduzida.

##### 4.2.2.1 - Fase a. Busca do vetor de dimensões reduzidas $O$

Nesta fase foram utilizados os dados de treinamento  $\mathfrak{S}_t$  e validação  $\mathfrak{S}_v$ . Inicialmente, o conjunto  $\mathfrak{S}_t$  foi utilizado para calcular as matrizes de transformação iPCA, conforme foi apresentado no Capítulo 3. Posteriormente, os dados de validação foram projetados com as matrizes iPCA e as projeções resultantes foram utilizadas para realizar a busca do vetor de dimensões reduzidas  $O$ . A seguir é feita uma descrição mais detalhada do processo.

O vetor de padrões EMG na base de dados  $\mathfrak{S}_t$  pode ser considerado uma variável aleatória com média zero, como se indica na equação (3-1), sendo  $M$  número de amostras em tempo discreto do conjunto  $\mathfrak{S}_t$  ( $M=176000$ ). As  $M$  amostras do vetor  $x$  foram divididas em  $C$  grupos (onde  $C$  representa o número de classes de movimento,  $C=11$ ), utilizando como critério de separação a pertinência de classe de cada amostra. Conseqüentemente, foram construídos  $C$  vetores  $x$  cada de comprimento  $M_c=16000$ . Para cada um destes vetores foi calculada uma matriz de transformação  $W_c$  ( $c=1, \dots, C$ ) utilizando o procedimento descrito no Capítulo 3 (vide seção 3.2.3 -). Posteriormente, os padrões de validação  $x_v$  foram projetados com essas matrizes como se indica na Figura 4-7. Na saída desta projeção obtém-se o vetor  $s$  de dimensão  $CN$  (onde  $N$  representa o número de canais de aquisição  $N=10$ ,  $CN=110$ ). No intuito de reduzir a dimensionalidade desse vetor de  $CN$  para  $N_l$  ( $N_l=30$ )<sup>10</sup>, foi utilizado o esquema de seleção de características composto pelo algoritmo de busca e a função custo (vide Figura 4-7 e seção 3.4 -). A saída desse processo é o vetor  $O$  de comprimento  $N_l$ , com a seqüência de canais escolhidos. Levando em conta que a fase (a) tem que ser executada para cada combinação de *função custo/algoritmo de busca* na Figura 4-8, no final desta fase obteve-se o conjunto de vetores  $O_{ij}$ , cada de comprimento  $N_l$ ; onde  $i$  indica a função custo utilizada e  $j$  o algoritmo de busca.

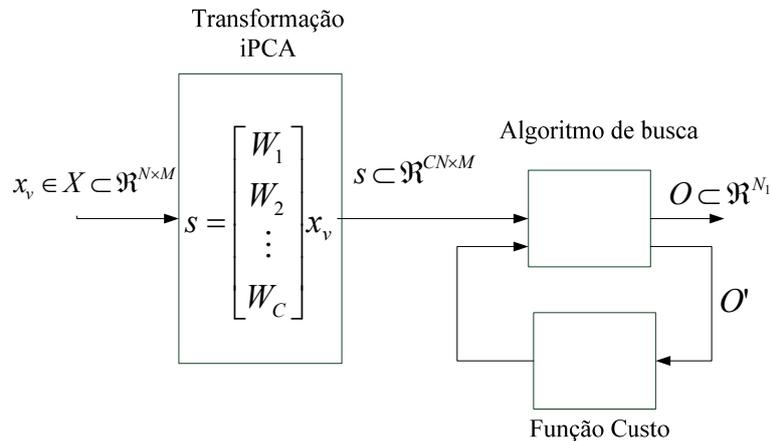


Figura 4-7. Diagrama de blocos para o cálculo do vetor de dimensões reduzidas  $O$ .

<sup>10</sup> O valor 30 para  $N_l$  foi escolhido porque segundo (Hargrove, et al., 2009) com esse valor é possível obter bons resultados de desempenho de classificação.

Os algoritmos de busca considerados foram os seguintes: SFS, SFFS, PSO, ABC. Para o algoritmo SFS foi definido um único critério de parada: comprimento do vetor  $O$  igual com  $N_I$ . O algoritmo SFFS utilizou dois critérios de parada: (1) o definido para o SFS e (2) o máximo número de iterações ( $C_{max}=120$ ). Os algoritmos PSO e ABC precisaram de outro tipo de parâmetros que são resumidos na Tabela 4-4 e na Tabela 4-5, respectivamente. Esses parâmetros foram escolhidos levando-se em conta a complexidade computacional das funções custo consideradas.

A função custo *erro de classificação* foi calculada utilizando o esquema de classificação da Figura 3-6. Como foi apresentado no Capítulo 2, existem diversas opções de configuração para esse esquema de controle. A configuração utilizada como estrutura básica nesta pesquisa envolveu os seguintes aspectos: (a) estrutura de janelamento com superposição, considerando comprimentos de janela de 150ms e incrementos de janela de 25ms, (b) extração de características AR6, (c) redução de dimensionalidade baseada no algoritmo ULDA e (d) classificação de padrões baseada no classificador LDA (vide Figura 4-9). Essa estrutura precisa de dados de treinamento e teste, nesta pesquisa os mesmos dados de validação foram utilizados para treinar e posteriormente avaliar o sistema. Essa metodologia foi utilizada por (Hargrove, et al., 2009) em um problema de condições similares.

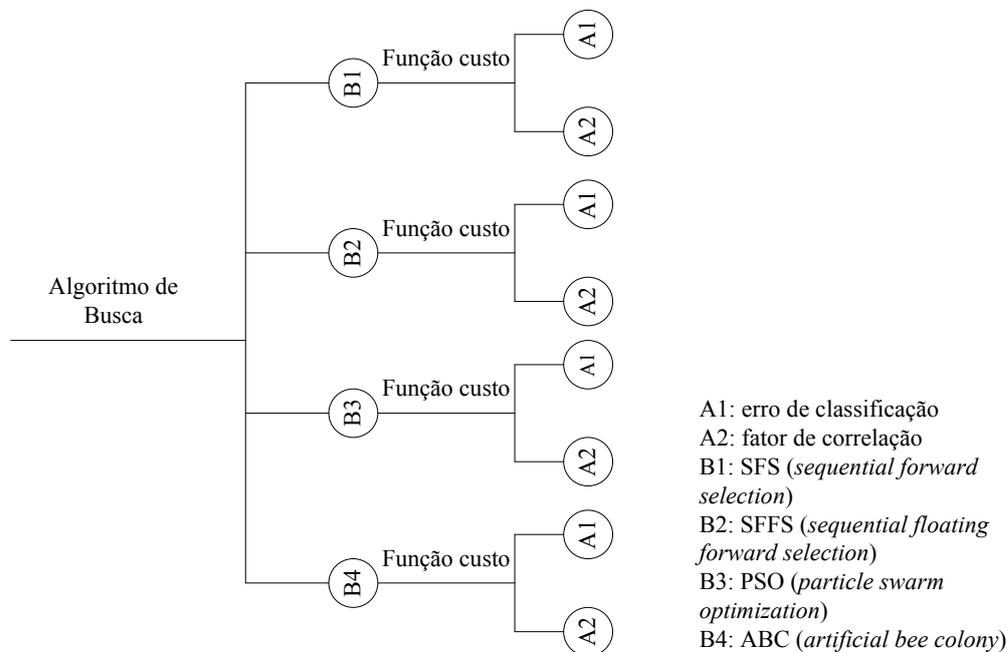


Figura 4-8. Combinações de função-custo/algoritmo-de-busca consideradas durante a etapa 2.

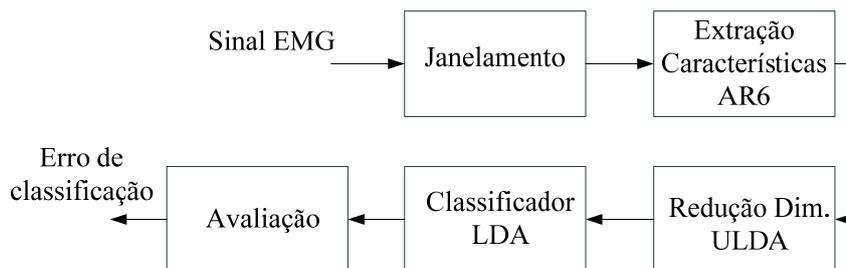


Figura 4-9. Esquema de processamento para o cálculo da função custo erro de classificação

Tabela 4-4. Parâmetros experimentais do algoritmo PSO

Parâmetros	Símbolo	Valor
Parâmetro cognitivo	$c_1$	2
Parâmetro social	$c_2$	2
Parâmetro social	$c_3$	1
Peso de inércia	$w$	[0.8 0.1]
Tamanho do enxame	$S$	10
Limites de velocidade	$[v_{min}, v_{max}]$	[-109 109]
Limites de posição	$[x_{min}, x_{max}]$	[1 110]
Máximo número de iterações	$C_{max}$	120

Tabela 4-5. Parâmetros experimentais do algoritmo ABC

Parâmetros	Símbolo	Valor
Número de fontes de alimento	$S$	10
Valores limite	$[v_{min}, v_{max}]$	[1 110]
Número máximo de ciclos	$C_{max}$	120
Ciclos limite no aprimoramento de uma solução	$C_{lim}$	6

#### 4.2.2.2 - Resultados da fase (a).

A Figura 4-10 apresenta a comparação entre o número de iterações utilizado por cada algoritmo de busca durante o processo de otimização. A amplitude das barras indica o valor médio das iterações necessárias para encontrar uma solução, considerando os 10 usuários disponíveis. Esses valores são representados com barras pretas e brancas para os casos de função custo erro de classificação e fator de correlação respectivamente. O tempo que dura a execução de uma única iteração durante o processo de otimização é resumido na Tabela 4-6. Esses tempos foram medidos tomando como referência um PC com as características resumidas na tabela Tabela 4-13.

A Figura 4-11 apresenta a comparação entre a aptidão das soluções ótimas calculadas com cada combinação *função custo/algoritmo de busca*. Nessa figura o eixo vertical

corresponde à função erro de classificação para o caso das barras pretas e à função fator de correlação para o caso das barras brancas. A amplitude das barras indica o valor médio das aptidões calculado a partir dos dados gerados com os 10 usuários considerados.

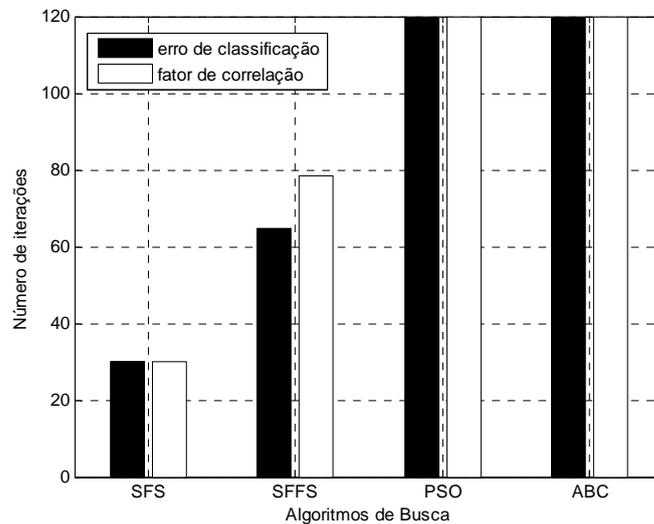


Figura 4-10. Comparação entre o número de iterações dos algoritmos de busca na minimização das funções custo erro de classificação e fator de correlação.

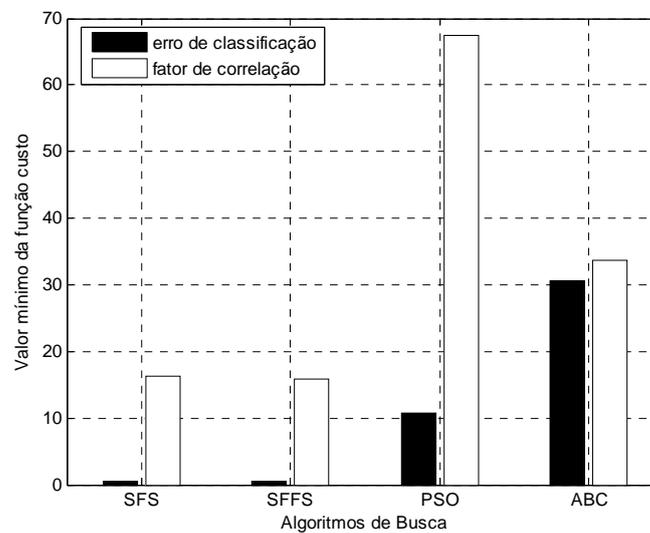


Figura 4-11. Comparação do valor mínimo da função custo atingido por cada algoritmo de busca no processo de otimização.

Tabela 4-6. Tempo médios de iteração durante o processo de otimização com as oito alternativas de tratamento de sinal.

Erro de classificação				Fator de Correlação			
SFS	SFFS	PSO	ABC	SFS	SFFS	PSO	ABC
1282s	1705s	155s	475s	5.62s	7.61s	0.79s	1.12s

#### 4.2.2.3 - Fase b. Construção da matriz de transformação iPCA reduzida

O parâmetro da sintonização iPCA é a matriz de transformação reduzida  $W_R$ . A transformação feita com essa matriz garante que só sejam calculados os canais escolhidos no vetor de dimensões reduzidas  $O$ , eliminando assim problemas de complexidade computacional e generalidade do classificador associados com a dimensionalidade dos dados.

Seja  $W_{iPCA}$  a matriz de transformação iPCA completa definida na equação (4-2). Ou seja, uma matriz de dimensão  $CN \times M$  formada pela concatenação de linhas das matrizes  $W_1$  até  $W_C$  (vide Figura 4-7).

$$W_{iPCA} = \begin{bmatrix} W_1 \\ \vdots \\ W_C \end{bmatrix} \quad (4-2)$$

Seja  $O$  o vetor com o subconjunto dos  $N_I$  canais de maior informação discriminativa:

$$O = [o_1, o_2, \dots, o_{N_I}] \quad (4-3)$$

Então, a matriz de transformação iPCA reduzida  $W_R$  vai ser uma submatriz de  $W_{iPCA}$  onde só as linhas indicadas no vetor  $O$  serão consideradas. A representação de  $W_R$  com a notação de sub-matrizes utilizada em Matlab é apresentada na equação (4-4).

$$W_R = W_{iPCA}(O, :) \quad (4-4)$$

$$s = W_R x \quad (4-5)$$

A transformação iPCA reduzida é apresentada na equação (4-5), onde  $W_R$  é uma matriz de  $10 \times 30$  e  $s$  o conjunto de padrões de dimensão reduzida.

Levando-se em conta que na saída da fase (a) foram gerados oito vetores  $O$ , na saída da fase (b) também serão geradas oito matrizes de transformação iPCA reduzidas, uma para cada alternativa função-custo  $i$  algoritmo-de-busca  $j$  avaliada:  $W_R^{ij}$  para  $(i=1,2 ; j=1,2,3,4)$ .

#### 4.2.3 - Etapa 3. Configuração de parâmetros do classificador

Nesta etapa são calculados os parâmetros do classificador. Para isso, são utilizados os dados de treinamento  $\mathfrak{S}_r$  e o procedimento apresentado em (Theodoridis, et al., 2006);

levando-se em conta que a etapa de classificação não é o foco desta pesquisa, não serão descritos detalhes desse procedimento.

#### 4.2.4 - Etapa 4. Avaliação do sistema de classificação

O processo de avaliação é feito em duas etapas:

- a) Fornecimento dos sinais EMG de teste para o sistema de controle mioelétrico com sintonização iPCA e registro do conjunto de classes preditas  $\hat{y}$ .
- b) Comparação entre as classes preditas  $\hat{y}$  e as classes alvo  $y$ . O indicador utilizado na comparação é o *erro de classificação*. Esse erro é avaliado de maneira independente para cada usuário  $k$  do sistema. O cálculo é feito como se indica na equação (4-6).

$$e_{ij}(k) = \frac{1}{P} \sum_{p=1}^P e_{ij}^{(p)}(k) \quad (4-6)$$

em que

$$e_{ij}^{(p)}(k) = \begin{cases} 0 & \text{se } y_i^{(p)} = \hat{y}_{ij}^{(p)}(k) \\ 1 & \text{Caso contrário} \end{cases}$$

sendo  $p$  o índice das janelas;  $P$  o número de janelas dentro dos ensaios considerados;  $y_i^{(p)}$  a classe alvo da janela  $p$ ;  $\hat{y}_{ij}^{(p)}(k)$  a classe predita na janela  $p$  com a matriz  $W_R^{ij}$  e o usuário  $k$ ; para  $k=1, \dots, K$  ( $K=10$ )

##### 4.2.4.1 - Resultados da Etapa 4

Os resultados de erros de classificação  $e_{ij}(k)$  são resumidos na Tabela 4-7 e Tabela 4-8. A Tabela 4-7 contém os erros de classificação atingidos com o nível 1 do fator  $A$  ( $i=1$ ) e os quatro níveis do fator  $B$  ( $j=1, \dots, 4$ ). Por outro lado a Tabela 4-8 contém os erros de classificação obtidos com o nível 2 do fator  $A$  ( $i=2$ ) e os quatro níveis do fator  $B$ . Nessas tabelas também são indicados o valor médio e o desvio padrão dos erros de classificação em cada nível do fator  $B$ . Essa informação é resumida na Figura 4-12, onde as barras verticais representam a magnitude do erro médio de classificação. As barras pretas indicam o erro de classificação para a arquitetura de sintonização associada com as matrizes  $(W_R^{1j})$ , ou seja, as matrizes calculadas com a função custo erro de classificação. As barras brancas indicam o erro de classificação para a

arquitetura de sintonização associada com as matrizes ( $W_R^{2j}$ ), ou seja, as matrizes calculadas com a função custo fator de correlação. As linhas sobre as barras representam um desvio padrão do erro de classificação entre usuários. Finalmente, a linha vermelha tracejada é a magnitude do erro de classificação atingido com o sistema de controle mioelétrico convencional (vide Figura 1-1), ou seja, o esquema sem sintonização iPCA.

Tabela 4-7. Erros de classificação atingidos com o nível 1 do fator *A* (função custo *erro de classificação*) e os níveis 1 até 4 do fator *B*.

Usuário <i>k</i>	Algoritmo de busca			
	SFS <i>e<sub>11</sub></i>	SFFS <i>e<sub>12</sub></i>	PSO <i>e<sub>13</sub></i>	ABC <i>e<sub>14</sub></i>
1	1.7341	4.8274	2.3590	2.6246
2	4.5462	5.3898	4.7180	5.5304
3	3.5776	4.2650	3.5307	2.9995
4	10.2953	11.3420	10.9358	9.4829
5	0.8124	1.3435	1.5466	2.3903
6	1.7029	2.7808	1.5466	1.9528
7	3.8275	4.7649	3.3120	3.4526
8	3.8588	3.7963	4.7805	4.9836
9	5.9209	5.4367	4.8742	5.4679
10	3.7963	4.6399	4.4056	4.2806
Médias amostrais	<b>4.0072</b>	<b>4.8586</b>	<b>4.2009</b>	<b>4.3165</b>
Desvio padrão	2.6762	2.6005	2.6911	2.2256

Tabela 4-8. Erros de classificação atingidos com o nível 2 do fator *A* (função custo *fator de correlação*) e os níveis 1 até 4 do fator *B*.

Usuário <i>k</i>	Algoritmo de busca			
	SFS <i>e<sub>21</sub></i>	SFFS <i>e<sub>22</sub></i>	PSO <i>e<sub>23</sub></i>	ABC <i>e<sub>24</sub></i>
1	5.7179	5.6710	4.9680	5.7647
2	5.8585	6.0147	5.7647	6.4677
3	5.6397	4.2806	4.5462	4.4524
4	12.7793	14.5602	14.7321	14.1540
5	2.0153	1.4060	2.2653	2.1872
6	2.7652	2.7027	2.9214	2.9839
7	3.8744	3.8588	3.7807	4.2337
8	7.5926	5.7491	5.1398	6.1240
9	10.9358	11.3264	9.9359	8.4674
10	6.4990	6.3584	5.5148	5.5304
Médias amostrais	<b>6.3678</b>	<b>6.1928</b>	<b>5.9569</b>	<b>6.0366</b>
Desvio padrão	3.3804	3.9594	3.7161	3.3702

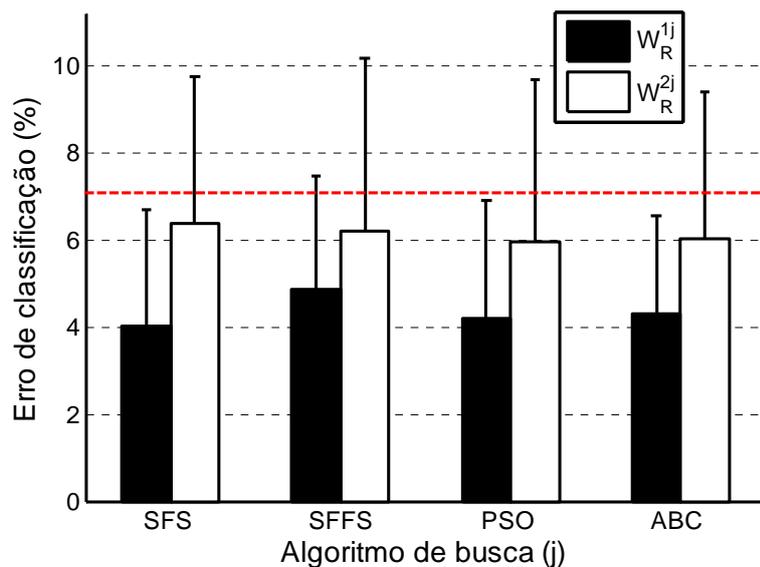


Figura 4-12. Valor médio e desvio padrão do erro de classificação atingido com cada alternativa de tratamento de sinal avaliada. A linha tracejada indica o erro de classificação do sistema de controle sem sintonização iPCA

As tabelas Tabela 4-9 até Tabela 4-12 apresentam matrizes de confusão do sistema de classificação. As entradas dessas tabelas são os identificadores das classes de movimento (vide Tabela 4-2). As matrizes correspondentes com a função custo erro de classificação são indicadas na Tabela 4-9 e na Tabela 4-10. A Tabela 4-9 apresenta os dados correspondentes aos algoritmos sequenciais e a Tabela 4-10 apresenta dados obtidos com algoritmos bio-inspirados. Similarmente, as matrizes correspondentes à função custo fator de correlação são indicadas na Tabela 4-11 e na Tabela 4-12.

A matriz de confusão indica para uma classe de movimento  $y$  as classificações feitas pelo sistema. Por exemplo, consideremos a linha quatro da Tabela 4-9 (vide marcador vermelho), a informação nessa linha indica que para os padrões EMG pertencentes à classe  $y=4$  (pronação) o sistema baseado em algoritmo SFS (coluna esquerda) e função custo erro de classificação, decidiu em 0.2% das vezes  $\hat{y} = 2$  (supinação), em 98.6% das vezes  $\hat{y} = 4$  (pronação), em 0.6% das vezes  $\hat{y} = 9$  (*fine pinch*) e em 0.5% das vezes  $\hat{y} = 11$  (repouso). As células vazias nessas tabelas correspondem a porcentagens de 0% e todos os dados foram arredondados para ilustrar só um dígito após o ponto decimal. As porcentagens apresentadas são valores médios calculados com a informação dos 10 usuários considerados na pesquisa.

Tabela 4-9. Matriz de confusão para os algoritmos sequenciais e a função custo erro de classificação. As células sem sombra (coluna esquerda) contêm as porcentagens com o algoritmo SFS. As células em gris (coluna direita) contêm as porcentagens do algoritmo SFFS. Os resultados na diagonal principal são as porcentagens de classificações corretas.

	1		2		3		4		5		6		7		8		9		10		11	
<b>1</b>	<b>97.3</b>	96.4		0.2	0.3	0.2		0.4	0.2	1	0.1		0.2	0.2	0.2	0.1	1	0.8		0.1	0.7	0.6
<b>2</b>	0.2	0.3	<b>98.2</b>	97.7					0.2				0.5	1.2			0.2	0.1		0.1	0.6	0.5
<b>3</b>	0.5	0.7	0.3	0.1	97.9	97.9	0.1	0.4	0.2	0.4	0.1	0.1					0.1		0.1	0.2	0.7	0.3
<b>4</b>		0.2	0.2	0.7			<b>98.6</b>	97.4		0.8							0.6	0.4		0.1	0.5	0.4
<b>5</b>	3.7	5.7	0.2				0.2	0.6	91.5	<b>91.8</b>	0.1		0.1				1.2	1.3	0.2	0.3	2.9	0.2
<b>6</b>											<b>94.7</b>	91.1	1	1	3.2	5.4	0.6	0.8	0.4	0.9	0.1	0.8
<b>7</b>	0.7	0.3									0.7	0.8	<b>92.4</b>	91	0.3	0.2	3.7	5.8			2.2	1.9
<b>8</b>		0.1									3.5	5.4	0.2	0.4	<b>95.6</b>	93.3	0.1	0.5	0.5	0.3		
<b>9</b>	0.3	0.2						0.2	0.5	0.5	4.1	3.4		0.7	94.8	<b>94.9</b>			0.1	0.1		
<b>10</b>								0.6	0.3	0.4	0.4	0.2	0.2	0.2	0.2	0.1	0.1	<b>98.6</b>	98.5			0.2
<b>11</b>	0.1		1.6	1.2			0.1	0.1	0.1	0.3			0.1	0.2			0.8	0.3	0.1	0.5	97.1	<b>97.3</b>

Tabela 4-10. Matriz de confusão para os algoritmos bio-inspirados e a função custo erro de classificação. As células sem sombra (coluna esquerda) contêm as porcentagens com o algoritmo PSO. As células em gris (coluna direita) contêm as porcentagens do algoritmo ABC. Os resultados na diagonal principal são as porcentagens de classificações corretas.

	1		2		3		4		5		6		7		8		9		10		11	
<b>1</b>	97	97	0.1	0.2	0.1	0.1		0.1	0.4	0.2	0.5	0.4	0.2	0.1	0.1	0.1	1	1			0.7	0.8
<b>2</b>	0.1	0.1	98.2	98.2				0.1	0.1	0.1	0.1		0.7	0.8			0.1	0.1			0.6	0.5
<b>3</b>	0.7	0.9	0.2	0.3	97.3	<b>97.4</b>	0.3	0.1	0.6	0.3	0.1	0.1	0.1	0.1	0.1			0.2	0.1	0.1	0.4	0.5
<b>4</b>	0.1	0.5	0.1	0.1			<b>98.8</b>	98.3		0.1			0.1		0.1		0.4	0.3			0.6	0.4
<b>5</b>	3.6	4	0.2	0.1			0.1	1	92	92		0.1	0.1				1.6	0.4	0.1	0.1	2.3	2.3
<b>6</b>											<b>94.6</b>	94.1	1.2	0.9	3	3.8	0.5	0.8	0.5	0.3	0.1	0.1
<b>7</b>	0.5	0.7									1.1	0.9	92.3	<b>93.4</b>	0.2	0.3	2.8	2.5			3.2	2.2
<b>8</b>											4.6	4.6	0.1	0.3	<b>94.9</b>	94.5	0.1	0.2	0.2	0.3		
<b>9</b>	0.3	0.2						0.1	1	0.6	3.6	4.3	0.8	0.8	<b>94.2</b>	94						0.1
<b>10</b>								0.8	1	0.2	0.4	0.2	0.4	0.2	0.4		0.1	<b>98.4</b>	97.6			
<b>11</b>	0.1	0.1	1.2	1.5			0.2	0.1	0.1	0.1			0.4	0.4			1.1	1.2	0.3	0.1	96.6	96.6

Tabela 4-11. Matriz de confusão para os algoritmos sequenciais e a função custo fator de correlação. As células sem sombra (coluna esquerda) contêm as porcentagens com o algoritmo SFS. As células em gris (coluna direita) contêm as porcentagens do algoritmo SFFS. Os resultados na diagonal principal são as porcentagens de classificações corretas.

	<b>1</b>		<b>2</b>		<b>3</b>		<b>4</b>		<b>5</b>		<b>6</b>		<b>7</b>		<b>8</b>		<b>9</b>		<b>10</b>		<b>11</b>	
<b>1</b>	92.9	<b>94.6</b>	0.8	0.7	0.9	0.7	0.3	0.2	3	2	0.3	0.2	0.5	0.1	0.1	0.1	0.8	0.7			0.6	0.6
<b>2</b>	0.2	0.2	98.2	98.2			0.1	0.2	0.3	0.2		0.1	0.6	0.8			0.2	0.1		0.1	0.4	0.3
<b>3</b>	1.7	1.4	0.3	0.1	95.5	<b>96.1</b>	0.7	0.7	0.9	0.9	0.1	0.1					0.1	0.1	0.1	0.1	0.6	0.4
<b>4</b>	0.5	0.5	1.2	1.2	0.2	0.3	<b>96.4</b>	96	0.8	0.7		0.1	0.1				0.4	0.5	0.1	0.1	0.3	0.5
<b>5</b>	3.2	3.3	0.2	0.2			0.5	0.2	<b>92.4</b>	91.4	0.1	0.1			0.1		1.7	2.7	0.6	0.6	1.2	1.5
<b>6</b>	0.1								0.1	0.2	88.3	<b>89.3</b>	1.8	1.6	6.3	5.6	1.3	1.2	1.1	1	0.9	1
<b>7</b>	0.6	0.2							0.1	0.1	1.7	1.7	87.4	<b>88</b>	0.3	0.4	6.7	6.2			3.1	3.3
<b>8</b>	0.2	0.1								0.1	5.9	5.5	0.6	0.6	92	<b>92.5</b>	0.6	0.5	0.7	0.6		
<b>9</b>	0.5	0.4							0.4	0.3	0.9	1	4.4	4.6	0.6	0.7	<b>93</b>	92.8			0.1	0.2
<b>10</b>									0.4	0.3	0.7	0.7	0.5	0.3	0.5	0.4	0.6	0.8	97.2	<b>97.3</b>	0.1	0.1
<b>11</b>			1.5	1.5			0.2	0.1	0.5	0.6	0.1	0.1	0.3	0.3			1.1	1.3	0.1	0.1	<b>96.2</b>	96

Tabela 4-12. Matriz de confusão para os algoritmos bio-inspirados e a função custo fator de correlação. As células sem sombra (coluna esquerda) contêm as porcentagens com o algoritmo PSO. As células em gris (coluna direita) contêm as porcentagens do algoritmo ABC. Os resultados na diagonal principal são as porcentagens de classificações corretas.

	<b>1</b>		<b>2</b>		<b>3</b>		<b>4</b>		<b>5</b>		<b>6</b>		<b>7</b>		<b>8</b>		<b>9</b>		<b>10</b>		<b>11</b>	
<b>1</b>	<b>95.7</b>	95.6	0.4	0.4	0.7	0.3	0.2	0.5	1.2	1.3		0.3		0.2	0.1	0.1	1	0.6			0.7	0.7
<b>2</b>	0.3	0.1	96.8	<b>97.9</b>			0.4	0.2		0.2		0.1	1.5	0.9			0.5	0.1		0.1	0.4	0.3
<b>3</b>	0.8	0.8	0.1	0.2	96.6	<b>96.9</b>	0.8	0.8	0.7	0.5	0.1	0.1					0.2	0.1	0.1	0.2	0.5	0.3
<b>4</b>	0.5	0.3	0.6	0.6	0.1	0.1	96.6	<b>97.1</b>	1	0.8	0.1				0.1		0.5	0.5	0.2	0.2	0.4	0.3
<b>5</b>	3.6	3.5	0.3	0.3			0.4	0.6	<b>93.1</b>	91.4	0.1				0.1		1.3	2.6	0.6	0.5	0.6	1
<b>6</b>	0.1								0.1	0.1	87.1	<b>88.3</b>	1.3	2.3	7	6.5	1.9	0.8	1	1.4	1.4	0.5
<b>7</b>	0.9	1.2							0.1		1.3	1.2	86.1	<b>88.1</b>	0.4	0.3	8.4	6.3	0.1		2.8	2.9
<b>8</b>	0.1	0.1							0.1		6.3	6.3	0.5	0.5	91.2	<b>92</b>	0.9	0.5	0.9	0.7		
<b>9</b>	0.6	0.2							0.6	0.2	1.5	1.1	4.5	3.5	1	0.9	91.5	<b>94.1</b>	0.1		0.3	
<b>10</b>							0.1	0.1	0.4	0.2	1	1	0.7	0.5	0.5	0.5	1.2	0.6	96	<b>97.1</b>	0.1	0.1
<b>11</b>	0.1		1.5	1.6			0.3	0.2	0.3	0.5	0.1	0.3	0.3	0.5			1.4	0.6	0.5	0.2	95.4	<b>96</b>

### 4.3 - DESCRIÇÃO DO PROJETO DO SIMULADOR DE CONTROLE MIOELÉTRICO COM SINTONIZAÇÃO IPCA

O desenvolvimento da metodologia experimental descrita na seção 4.2 - foi feito utilizando uma plataforma de simulação construída neste trabalho de mestrado para satisfazer os requisitos específicos de nossa aplicação. A construção desse simulador demandou um tempo considerável devido à grande quantidade de etapas de processamento envolvidas, assim como a sincronização entre os diversos componentes do sistema. O software de desenvolvimento utilizado para construir o simulador foi MATLAB (The Mathworks Inc, (R2010b)) sendo escolhido pela flexibilidade, possibilidade de desenvolver códigos de forma modular e relativamente rápida (sem se preocupar pelo desempenho computacional da ferramenta desenvolvida). Como indicado na Figura 4-13, o *toolbox* desenvolvido para o simulador é dividido em quatro partes básicas.

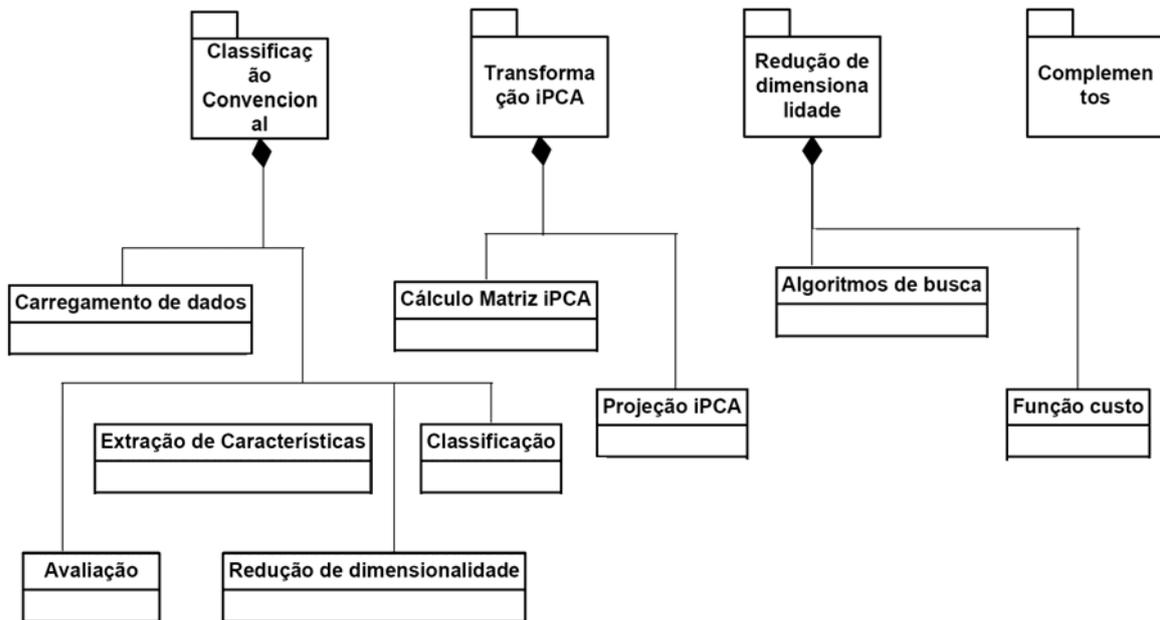


Figura 4-13. Estrutura do toolbox de controle mioelétrico com sintonização iPCA projetado.

- Classificação convencional: contém o conjunto de funções necessárias para realizar o processo de classificação convencional descrito no capítulo 2. 80% desse código é baseado no *toolbox* apresentado em (Chan, 2007).
- Transformação iPCA: contém as funções necessárias para cálculo de matrizes de transformação PCA, iPCA e projeção de dados com transformação iPCA como foi descrito no capítulo 3.

- Redução de dimensionalidade: contém as funções necessárias para desenvolver os processos de busca das soluções ótimas com algoritmos: SFS, SFFS, PSO e ABC, assim como avaliação das funções custo: erro de classificação e fator de correlação como foram definidas no capítulo 3.
- Complementos: contém as funções necessárias para tarefas complementares como: cálculo do desempenho do classificador, matrizes de confusão, reporte de eventos, etc.

No intuito de validar o funcionamento do simulador desenvolvido, foram feitos experimentos para replicar os erros de classificação publicados nas referências: (Chan, 2007) e (Hargrove, et al., 2009). Os resultados obtidos indicaram o correto funcionamento do simulador. A documentação destas provas pode ser consultada em (Camacho, 2011).

A maior parte das simulações foi executada em PCs com as características indicadas na Tabela 4-13.

Tabela 4-13. Resumo das características do PC utilizado para as simulações.

Sistema Operacional	Ubuntu - 64 bits
Capacidade de memória RAM	8Gb
Processador	2.8GHz
Núcleos	4

#### 4.4 - RESUMO DO CAPÍTULO

Neste capítulo foi apresentada a metodologia experimental utilizada para a coleta dos erros de classificação do sistema de controle mioelétrico com sintonização iPCA. Essa informação foi dividida em quatro etapas: (1) experimentos supervisionados, (2) cálculo da matriz iPCA reduzida, (3) configuração de parâmetros do classificador e (4) avaliação do sistema de classificação. Em cada etapa foram apresentados os processos realizados e os resultados obtidos.

Na etapa 1, descreveu-se a quantidade de sujeitos, os tipos de movimento, a quantidade de canais e os ensaios executados durante a coleta. A informação apresentada permitiu conferir que a base de dados utilizada contém características necessárias para a experimentação com o sistema de classificação iPCA. Nesse ponto, é importante mencionar que, nas pesquisas relacionadas com controle mioelétrico, os sujeitos nos quais é medido o sinal de EMG são pessoas sem amputação.

Na etapa 2, foi descrito o processo de cálculo da matriz de transformação iPCA reduzida. O processo foi dividido em duas fases: (a) busca do vetor de dimensões reduzidas e (b) construção da matriz de transformação iPCA reduzida. Na fase (a) foi descrita a transformação iPCA e o processo de redução de dimensionalidade executado sobre os dados. Foram especificados os parâmetros de configuração utilizados nos algoritmos de busca utilizados. Foram apresentadas tabelas e figuras comparativas de resultados entre os oito tratamentos avaliados durante o processo de otimização. A comparação foi feita com relação ao número de iterações dos algoritmos, tempo de iteração e o nível mínimo das funções custo. A fase (b) apresentou o processo de cálculo da matriz de transformação reduzida  $W_R$ .

Na etapa 3, foram indicadas as referências onde pode ser consultado o processo de configuração de parâmetros do classificador LDA.

Na etapa 4, foi apresentado o procedimento para cálculo do erro de classificação. Os erros de classificação obtidos foram resumidos na Tabela 4-7 e na Tabela 4-8. Além desses resultados, na Figura 4-12, foram apresentados os erros médios de classificação entre usuários. Essa figura permitiu identificar certa semelhança entre os desempenhos atingidos nos diferentes níveis do fator B. Como resultado complementar, foram apresentadas as matrizes de confusão do sistema de classificação. Essas matrizes permitiram identificar as classes de movimento com maiores e menores porcentagens de sucesso na classificação.

No final do capítulo foi feita a descrição do simulador utilizado para desenvolver a metodologia experimental do projeto. O capítulo seguinte apresenta a análise dos resultados apresentados neste capítulo.

## 5 - DISCUSSÃO DOS RESULTADOS

Neste Capítulo é apresentada a discussão dos resultados obtidos na pesquisa. Os mesmos podem ser divididos em dois grupos (correspondentes aos passos 2 e 4 da metodologia experimental): (1) resultados gerados durante o cálculo da matriz de transformação reduzida; (2) resultados gerados durante a avaliação do sistema de classificação. Na primeira seção do capítulo são apresentados os resultados correspondentes ao primeiro grupo. Na segunda seção, a discussão é focada nos erros de classificação. Essa discussão é complementada com uma análise estatística dos resultados.

### 5.1 - RESULTADOS GERADOS DURANTE O CÁLCULO DA MATRIZ DE TRANSFORMAÇÃO REDUZIDA

A discussão nesta seção é sobre os resultados gerados durante a fase (a) da etapa dois: busca do vetor de dimensões reduzidas  $O$  (vide seção 4.2.2 -). Essa discussão é dividida em duas partes: (a) tempos de busca das soluções ótimas e (b) aptidão atingida durante a otimização.

#### 5.1.1 - Tempos de busca das soluções ótimas.

Para obter os tempos de busca das soluções ótimas analisaremos o número de iterações (vide Figura 4-10) e o tempo médio de execução da iteração em cada combinação *função custo/ algoritmo de busca* (vide Tabela 4-6).

##### 5.1.1.1 - Algoritmo SFS

As tendências apresentadas na Figura 4-10 indicam que o algoritmo SFS utilizou a menor quantidade de iterações durante a busca da solução ótima, sendo que consegue convergir em exatamente 30 iterações independentemente da função custo considerada. O número de iterações foi de 30 para cada usuário, esse comportamento era o esperado já que por definição o algoritmo SFS só realiza  $N_l$  iterações, onde  $N_l$  corresponde ao comprimento do vetor de dimensões reduzidas (vide seção 3.4.2.1).

Por outro lado, o algoritmo SFS apresentou tempos de iteração variáveis, ou seja, a primeira iteração foi executada em um tempo diferente do que a segunda e a terceira, e assim por diante. Esse comportamento foi observado em todos os usuários e foi causado por duas razões: (a) a quantidade variável de avaliações da função custo em cada iteração e (b) o número variável de argumentos com que se avalia a função custo em cada iteração. Esse número de argumentos cresce na medida em que as iterações vão avançando. Uma consequência importante desse comportamento é o incremento do tempo de execução das

iterações na medida em que vão aumentando as iterações, ou seja, as últimas iterações são as que consomem mais tempo de processamento. O valor médio do tempo de execução das iterações foi de 1282 s para o erro de classificação e 5.62 s para o fator de correlação (vide Tabela 4-6). Esses foram os segundos maiores tempos entre as alternativas consideradas.

Em síntese, a vantagem de poucas iterações exibida na busca com o algoritmo SFS é ofuscada pelo alto tempo de execução da iteração, resultando em uma alternativa pouco eficiente do ponto de vista do tempo de cálculo da solução.

#### 5.1.1.2 - Algoritmo SFFS

O número de iterações no algoritmo SFFS foi variável entre usuários e apresentou alta dependência com relação à função custo avaliada (vide Figura 4-10). Considerando a dimensão do problema de otimização e o suposto de funções custo multimodais com mínimos distribuídos aleatoriamente, esperava-se que esse número de iterações estivesse perto do máximo definido  $C_{max}$  ( $C_{max}=120$ , vide seção 4.2.2 -). Entretanto, a quantidade de iterações sempre esteve longe de 120. Esse comportamento sugere que a distribuição aleatória dos mínimos nas funções custo consideradas tem baixa variância, fato que facilita a busca com algoritmos sequenciais.

O tempo de iteração do algoritmo SFFS foi variável em cada iteração, sendo que o valor médio desse tempo foi de 1705 s para o erro de classificação e 5.62 s para o fator de correlação (vide Tabela 4-6). Essa variabilidade é provocada pela avaliação da função custo com diferente número de argumentos em cada iteração.

O comportamento próprio do algoritmo SFFS de incrementar e decrementar dinamicamente o número de canais escolhidos adiciona maior variabilidade ao tempo de iteração e provoca o maior número de iterações com relação ao algoritmo SFS (vide Figura 4-10). Esse comportamento, junto com o fato de que SFFS avalia mais de uma vez a função custo em cada iteração, justificam que o SFFS apresente o tempo máximo médio de iteração entre as alternativas avaliadas (vide Tabela 4-6).

Finalmente, a Figura 4-10 indica que a otimização da função custo *fator de correlação* precisou de maior número de iterações do que a função custo *erro de classificação*, sugerindo que a busca do valor mínimo no fator de correlação envolve maior quantidade de avaliações da função custo.

### 5.1.1.3 - Algoritmo PSO

Este algoritmo sempre teve que executar o máximo número de iterações  $C_{max}$  para terminar o processo de busca (vide Figura 4-10). Essa tendência está diretamente relacionada com dois parâmetros utilizados durante a execução da busca: (a) parâmetros cognitivos e sociais e (b) o tamanho do enxame. Esses parâmetros também são determinantes para a velocidade de convergência do algoritmo e a aptidão da solução encontrada. Infelizmente, o tempo demandado para realizar as simulações com esse algoritmo foi muito elevado e só foi possível experimentar com a combinação de parâmetros indicada na Tabela 4-4.

O algoritmo PSO apresentou tempos iguais em todas as iterações: 155 s com a função erro de classificação e 0.79 s com a função fator de correlação (vide Tabela 4-6). Os tempos iguais são consequência de dois comportamentos: (a) a função custo sempre foi avaliada para  $N_I$  argumentos e (b) em cada iteração sempre foi feita uma única avaliação da função custo. Esse último comportamento foi a razão pela qual o algoritmo PSO apresentou o menor tempo de iteração médio entre as alternativas consideradas (vide Tabela 4-6).

### 5.1.1.4 - Algoritmo ABC

No algoritmo ABC sempre foi necessário executar as 120 iterações para terminar o processo de busca (vide Figura 4-10). Essa tendência está relacionada com três parâmetros: (a) o número máximo de iterações, (b) o número de fontes de alimento e (c) o número de etapas limite no aprimoramento de uma solução. Esses parâmetros também influenciam o tempo de iteração e a aptidão da solução calculada. Como aconteceu com PSO, o elevado tempo de simulação desta alternativa de tratamento só permitiu avaliar a configuração de parâmetros na Tabela 4-5.

O tempo médio de iteração foi de 475 s e 1.12 s para as funções custo erro de classificação e fator de correlação respectivamente. Da mesma forma que o PSO, o algoritmo ABC apresentou tempos de execução iguais em cada iteração. Esse comportamento foi consequência de: (a) a função custo sempre foi avaliada para  $N_I$  argumentos e (b) em cada iteração sempre foram feitas duas avaliações da função custo. Esse último comportamento justifica porque o tempo médio de iteração na alternativa ABC foi maior do que o apresentado em PSO (vide Tabela 4-6).

A Figura 5-1 apresenta a comparação entre o tempo necessário para o cálculo da solução ótima, esses tempos foram calculados como: número médio de iterações (vide Figura 4-10)  $\times$  tempo médio de execução da iteração (vide Tabela 4-6). A Figura 5-1 (a) faz a

comparação considerando a função custo erro de classificação e a Figura 5-1 (b) considerando o fator de correlação. No intuito de facilitar a identificação dos algoritmos de maior e menor consumo de recursos computacionais os tempos calculados foram dispostos em sequência decendente. As tendências nessa figura permitem concluir que: (a) as buscas da solução ótima sobre a função erro de classificação precisaram de maiores tempos do que as buscas sobre a função fator de correlação. Este comportamento é justificado pelo alto consumo de recursos computacionais associado com a função erro de classificação; (b) independentemente da função custo considerada, os algoritmos de maior e menor complexidade computacional foram o SFFS e o PSO, respectivamente. A diferença entre tempos de busca desses algoritmos é significativa indicando que o SFFS consome aproximadamente quatro vezes mais recursos do que o PSO. Esses resultados sugerem que existe uma vantagem prática do algoritmo PSO sobre os algoritmos sequenciais. Essa vantagem é consequência das poucas avaliações da função custo em cada iteração do PSO.

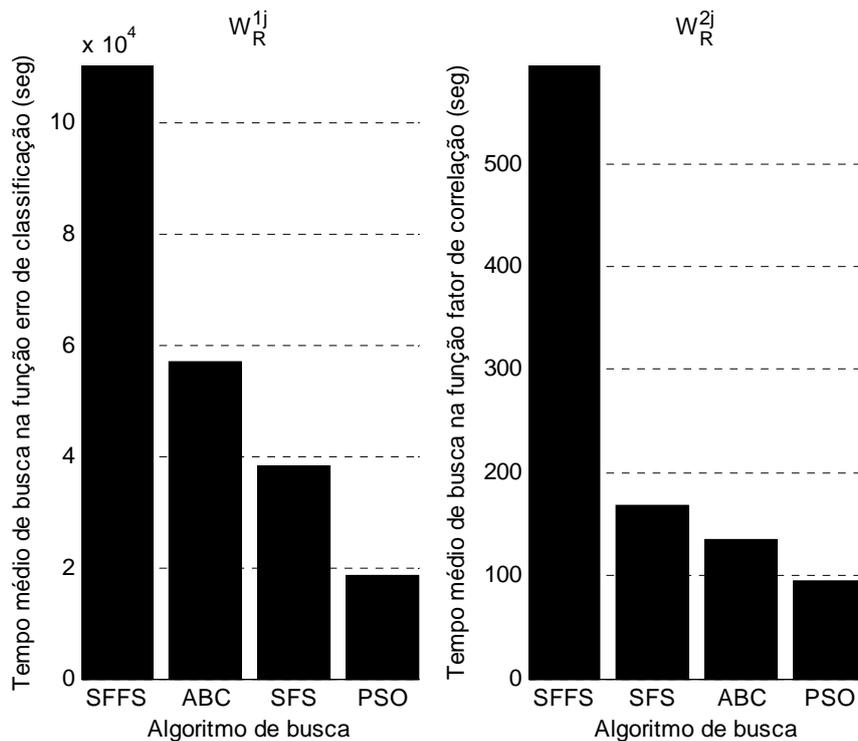


Figura 5-1. Tempos de busca da solução ótima para cada combinação função-custo/algoritmo-de-busca.

### 5.1.2 - Aptidão atingida durante a Otimização

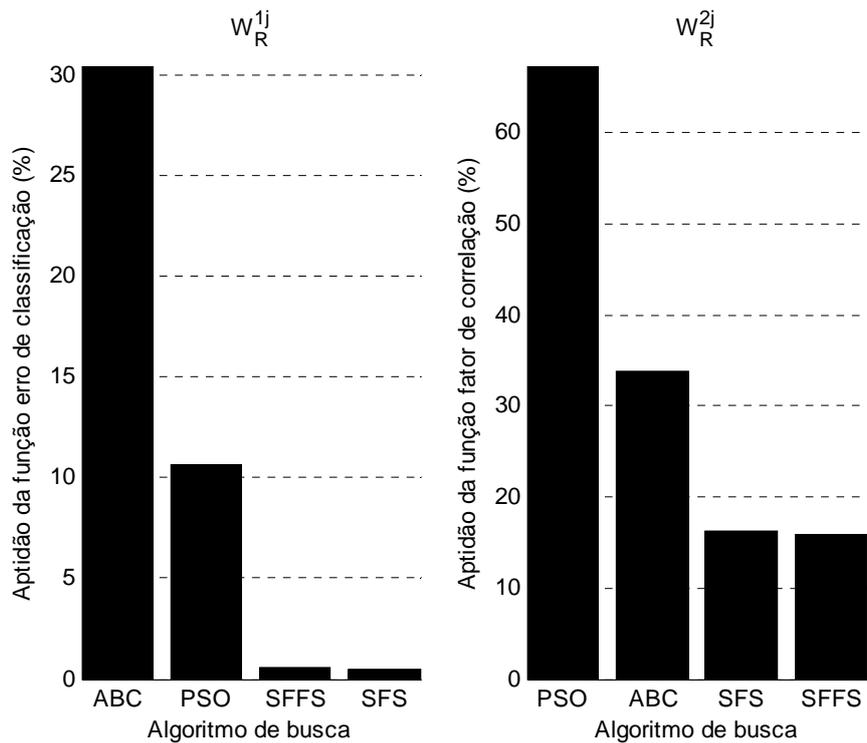


Figura 5-2. Comparação da aptidão gerada com as combinações de função-custo/algorithm-de-busca avaliadas.

A Figura 5-2 apresenta a aptidão das soluções calculadas com as oito alternativas de tratamento de sinal avaliadas. Os resultados de minimização da função custo erro de classificação na Figura 5-2 (a), indicam um incremento na aptidão da solução encontrada na sequência: ABC, PSO, SFFS, SFS. No caso da função custo fator de correlação (vide Figura 5-2 (b)) a sequência de incremento na aptidão foi: PSO, ABC, SFS, SFFS.

Com relação a essas tendências, é importante destacar o seguinte:

- 1) Os algoritmos sequenciais obtiveram soluções de maior aptidão do que os bio-inspirados, entretanto, esse comportamento não pode ser generalizado. Seria interessante realizar pesquisas adicionais considerando outros parâmetros de configuração tanto em PSO como em ABC.
- 2) Considerando a semelhança entre os níveis de otimização atingidos com SFS e SFFS, conclui-se que os efeitos do *nesting effect*, próprios do SFS, não são significativos para as duas funções custo consideradas.

## 5.2 - RESULTADOS GERADOS DURANTE A AVALIAÇÃO DO SISTEMA DE CLASSIFICAÇÃO.

Os resultados obtidos nesta etapa podem ser divididos em três grupos: (a) erros de classificação por usuário, (b) valores médios dos erros de classificação e (c) matrizes de confusão.

### 5.2.1 - Erros de classificação por usuário.

Nas oito alternativas de tratamento de sinal avaliadas, o usuário com maior número de erros de classificação foi o número 4. O usuário de maior número de acertos na classificação foi o número 6. Os erros de classificação gerados por esses usuários encontram-se dentro da faixa de variação de dois desvios padrão ao redor da média amostral (vide Tabela 4-7 e Tabela 4-8), conseqüentemente, os dados desses usuários não podem ser considerados *outliers*<sup>11</sup>. Infelizmente, não se tem (na base de dados) informação específica de usuário que permita explicar esses comportamentos.

### 5.2.2 - Erros médios de classificação.

A Figura 4-12 apresenta a comparação entre os erros médios de classificação associados com cada matriz de transformação reduzida  $W_R^{ij}$ . Os resultados indicam que:

a) Os níveis de erro atingidos ficam na faixa entre 4 e 6.5%, por tanto, concordam com resultados publicados em (Hargrove, et al., 2009). Aliás, o erro de classificação da arquitetura sem sintonização iPCA (vide linha vermelha na Figura 4-12) sempre foi superior do que os erros associados com as arquiteturas de sintonização iPCA. Este comportamento permite verificar a superioridade de desempenho de classificação da arquitetura com sintonização iPCA.

b) Existem níveis similares no erro de classificação associados com as matrizes ( $W_R^{i\bullet}$ ), ou seja, as matrizes calculadas com a função custo  $i$  e cada um dos algoritmos de busca. Este comportamento não era o esperado. Devido à superioridade das aptidões associadas aos algoritmos sequenciais (vide Figura 5-2), esperávamos maiores diferenças entre erros de classificação. Por exemplo, que os erros de classificação associados com matrizes de transformação calculadas com algoritmos sequenciais ( $W_R^{ij}$  com  $j=1,2$ ) foram menores do

---

<sup>11</sup> Uma observação que está numericamente distante do resto dos dados, geralmente gerada por erros na medição.

que os erros associados com matrizes de transformação calculadas com algoritmos bio-inspirados ( $W_R^{ij}$  com  $j=3,4$ ). Esses resultados sugerem que a localização do valor mínimo sobre as funções custo consideradas não é condição suficiente para garantir os menores erros de classificação durante o processamento dos sinais EMG de prova.

c) Existem diferenças entre os erros de classificação associados com matrizes ( $W_R^{\bullet j}$ ), ou seja, matrizes de transformação calculadas com o algoritmo de busca  $j$  e cada uma das funções custo. Este comportamento era esperado e é justificado por duas razões:

- i. A superioridade da função erro de classificação sobre a função fator de correlação respeito da capacidade de determinar o nível de informação discriminativa nos padrões EMG.
- ii. A superioridade das aptidões associadas com as buscas sobre a função erro de classificação (vide Figura 5-2).

### **5.2.3 - Matrizes de confusão.**

As matrizes de confusão geradas com a função custo erro de classificação (vide Tabela 4-9 e Tabela 4-10) permitem ver que na maioria das classes de movimento o algoritmo SFS atingiu a maior porcentagem de acertos na classificação. No caso da função custo fator de correlação (vide Tabela 4-11 e Tabela 4-12) o algoritmo SFFS foi o que atingiu as maiores porcentagens de acerto.

Para complementar a análise dos erros de classificação obtidos, na seção seguinte é apresentada a análise estatística desses resultados.

## **5.3 - ANÁLISE ESTATÍSTICA DE RESULTADOS.**

Nessa seção apresenta-se a análise estatística dos resultados obtidos. Inicialmente se avaliam as condições para a utilização de ANOVA como ferramenta de análise. Posteriormente, são avaliadas as hipóteses de interesse.

### **5.3.1 - Avaliação de condições para utilização de ANOVA**

Vamos considerar os erros de classificação na Tabela 4-7 e Tabela 4-8 como valores observados de variáveis aleatórias. Sejam:

- $E_{ijk}$ : uma variável aleatória que representa o erro de classificação da observação  $k$  quando o fator  $A$  é mantido no nível  $i$  e o fator  $B$  no nível  $j$ .
- $e_{ijk}$ : o valor observado de  $E_{ijk}$ .
- $K$ : o número de observações.

A análise ANOVA escolhida utiliza o modelo aditivo definido na equação (5-1) (Devore, 2006).

$$E_{ijk} = \mu + \alpha_i + \beta_j + \gamma_{ij} + \varepsilon_{ijk} \quad (5-1)$$

em que  $\mu$  é a resposta média Real,  $\alpha_i$  é o efeito do fator  $A$  no nível  $i$  sobre o erro de classificação,  $\beta_j$  é o efeito do fator  $B$  no nível  $j$  sobre o erro de classificação,  $\gamma_{ij}$  é o parâmetro de interação e  $\varepsilon_{ij}$  é a quantidade aleatória pela qual os valores observados diferem dos valores esperados.

Para avaliar a factibilidade desse modelo, é necessário satisfazer três condições (Devore, 2006):

1. Verificar que o erro médio de cada amostra ( $\mu_{ij}$ ) seja igual à soma de um efeito do fator  $A$  no nível  $i$  ( $\alpha_i$ ) e um efeito do fator  $B$  no nível  $j$  ( $\beta_j$ ).
2. Verificar distribuição normal das variáveis aleatórias  $\varepsilon_{ij}$
3. Verificar variância  $\sigma^2$  única nas variáveis aleatórias  $\varepsilon_{ij}$

Na Figura 5-3 são apresentados os valores médios dos erros de classificação observados  $\bar{e}_{ij}$ . As tendências ilustradas nesta figura permitem concluir que a configuração é razoavelmente representativa do que se espera da aditividade, ou seja: a diferença entre erros médios nos dois níveis de um dos fatores é a mesma para todos os níveis do outro fator (Devore, 2006). Com isto é verificada a primeira condição.

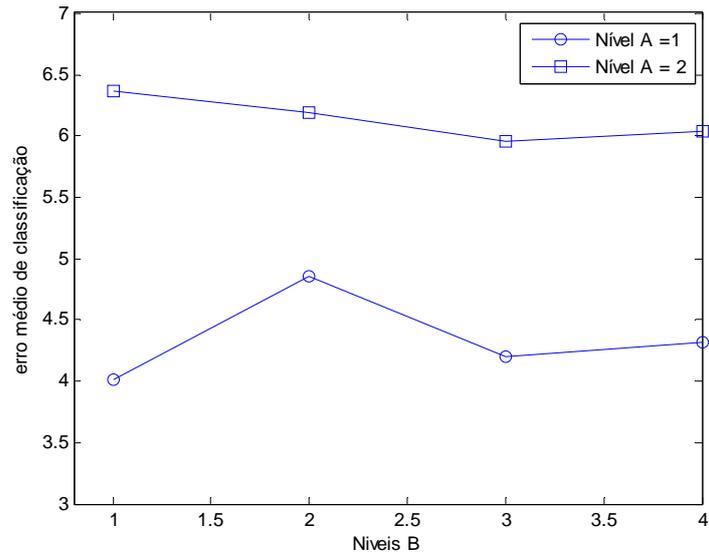


Figura 5-3. Erros médios de classificação atingidos com combinações de fatores *A* e *B*

Segundo (Bivkel, et al., 2001) a análise dos resíduos é a ferramenta mais utilizada no momento de avaliar a suposta normalidade na variável  $\varepsilon_{ij}$ . Os gráficos de probabilidade normal para os resíduos dos erros de classificação  $e_{1j}$  e  $e_{2j}$  são apresentados na Figura 5-4 (a) e Figura 5-4 (b), respectivamente. As tendências de linha reta nessas figuras indicam normalidade nos dados e inexistência de *outliers*. Com esse comportamento, verifica-se a segunda condição.

Segundo (Devore, 2006), uma regra prática para verificar variância única nas variáveis aleatórias  $\varepsilon_{ij}$  é a comparação dos desvios padrão  $s_{ij}$ : Se  $s_{max} < 2s_{min}$ , então é válida a suposição de variância única. Para os resultados da Tabela 4-7 e Tabela 4-8 temos que  $3.9594 < 2(2.2256)$ , por tanto, a terceira condição é verificada.

Em conclusão, é factível o uso do ANOVA de dois fatores com modelo aditivo para a análise estatística dos erros de classificação obtidos.

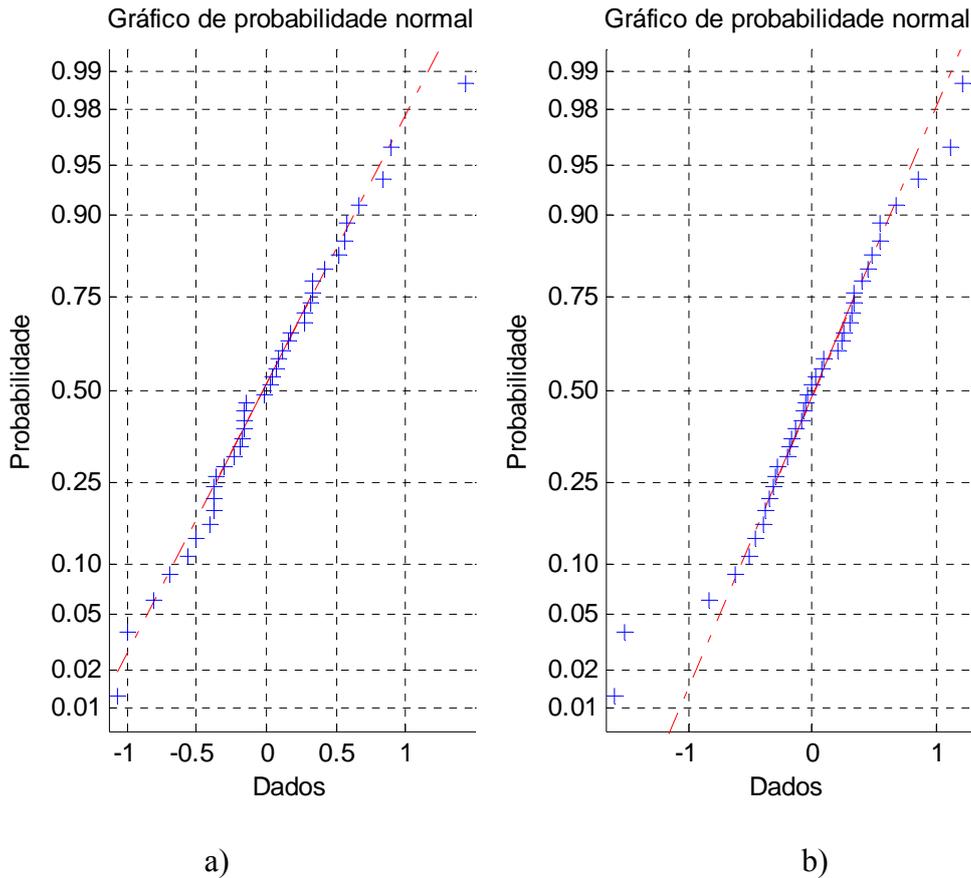


Figura 5-4. Figura de probabilidade normal. a) Resíduos do erro de classificação  $e_{ij}$ . b) Resíduos do erro de classificação  $e_{2j}$ .

### 5.3.2 - Aplicação da ANOVA de dois fatores

Existem três conjuntos de hipóteses a serem considerados:

- 1  $H_{0AB}: \gamma_{ij} = 0$  para todos os  $i, j$  versus  $H_{aAB}$ : pelo menos um  $\gamma_{ij} \neq 0$
- 2  $H_{0A}: \alpha_1 = \alpha_2 = 0$  versus  $H_{aA}$ : pelo menos um  $\alpha_i \neq 0$
- 3  $H_{0B}: \beta_1 = \beta_2 = \beta_3 = \beta_4 = 0$  versus  $H_{aB}$ : pelo menos um  $\beta_j \neq 0$

Tabela 5-1. Tabela ANOVA dos erros de classificação.

Fonte de Variação	gl	Soma dos Quadrados	Quadrado Médio	$f$
A. Função Custo	1	64.275	64.274	6.56
B. Algoritmo de Busca	3	2.287	0.7623	0.08
AB. Interação	3	2.697	0.8989	0.09
Erro	72	705.521	9.7989	
Total	79	774.779		

A Tabela 5-1 resume os resultados dos cálculos da ANOVA. Visto que  $F_{0.01,3,72} = 4.0659$  e  $f_{AB}=0.09$  não é  $\geq 4.0659$ ,  $H_{0AB}$  não pode ser rejeitada no nível de significância 0.01, de modo que concluímos que os efeitos de interação entre fatores não são significativos.

Agora, passamos a investigar a presença ou ausência dos efeitos principais. Visto que  $F_{0.01,1,72} = 7.0005$  e  $f_A=6.56$  não é  $\geq 7.0005$ ,  $H_{0A}$  não pode ser rejeitada no nível de significância 0.01. Entretanto, modificando o nível de significância para 0.02 temos que  $F_{0.02,1,72} = 5.0162$  e  $f_A=6.56$  é  $\geq 5.0162$ , portanto,  $H_{0A}$  é rejeitada confirmando a conclusão de que as diferentes variedades de função custo na redução de dimensionalidade influenciam o erro de classificação.

De modo semelhante  $F_{0.01,3,72} = 4.0659$ , então,  $f_B=0.08$  é  $\leq 4.0659$ , portanto,  $H_{0B}$  é rejeitada no nível de significância 0.01, concluindo que o erro de classificação é independente do algoritmo de busca utilizado.

Em síntese, temos que:

1. Considerando um nível de significância de 0.01, os efeitos da interação entre fatores  $A$  e  $B$  não são significativos com relação ao erro de classificação atingido.
2. Considerando um nível de significância de 0.02, os diferentes níveis do fator  $A$  na redução de dimensionalidade influenciam o erro de classificação.
3. Considerando um nível de significância de 0.01 parece que o erro de classificação é independente dos níveis do fator  $B$ .
4. Isto nos mostra que, na prática, o algoritmo de busca não tem efeitos significativos sobre o erro de classificação, entretanto, a função custo influencia significativamente o erro de classificação.

## 6 - CONCLUSÕES E TRABALHOS FUTUROS

### 6.1 - CONCLUSÕES GERAIS

O objetivo geral desta pesquisa foi determinar os efeitos que tem sobre o erro de classificação o uso de diversas alternativas na combinação *função custo/ algoritmo de busca* nos sistemas de controle mioelétrico com sintonização iPCA. As alternativas consideradas incluem quatro candidatos no algoritmo de busca (SFS, SFFS, ABC e PSO) e dois candidatos na função custo (erro de classificação, fator de correlação). Para atingir esse objetivo a pesquisa foi dividida em duas fases:

- (a) Definição de aspectos teóricos relacionados com o controle mioelétrico e a sintonização de dados por transformação iPCA.
- (b) Avaliação experimental das alternativas de tratamento de sinal consideradas na pesquisa e análise comparativa de resultados.

O desenvolvimento da fase (a) envolveu uma revisão da literatura relacionada com generalidades sobre o sinal eletromiográfico, extração de características, redução de dimensionalidade, classificação de padrões, transformações PCA, iPCA, problemas de otimização discreta, algoritmos de busca e funções custo. Essa revisão permitiu estabelecer o seguinte:

- O sinal eletromiográfico pode ser considerado um processo estocástico estacionário no sentido amplo em aplicações de controle mioelétrico. Isso acontece como consequência de que o tempo de resposta (100-175ms) definido para esse tipo de aplicações é menor do que o limite onde se perde a hipótese de estacionariedade (500-1500ms).
- Os eletrodos de superfície são tão apropriados quanto os eletrodos intramusculares, no contexto do controle mioelétrico baseado em reconhecimento de padrões. Entretanto, existe uma vantagem de comodidade e conforto que favorece o uso dos eletrodos de superfície.
- O erro de classificação é o indicador de desempenho mais reportado na literatura de controle mioelétrico. Esse indicador tem uma relação de proporcionalidade direta com a quantidade de classes de movimento no problema de classificação e uma proporcionalidade inversa com o volume de informação discriminativa disponível nos padrões EMG. Esse volume depende, entre outros fatores, da quantidade de

canais de aquisição, a redundância nos canais de aquisição, o comprimento de janelas e a etapa de sinal de EMG analisado (transiente ou estacionário).

- Atualmente, a configuração preferida para resolver o esquema de controle mioelétrico convencional envolve: (a) estrutura de janelamento com superposição, extração de características AR6, (b) redução de dimensionalidade baseada no algoritmo ULDA e (c) classificação de padrões baseada no classificador LDA.
- PCA é uma transformação ótima para aplicações de compressão de informação, mas subótima para aplicações de classificação. Isso porque desconsidera a informação de classes de movimento dos padrões que transforma.
- A transformada iPCA consegue aproveitar as vantagens de compressão de energia de PCA assim como incluir a informação de classes para melhorar o desempenho de classificação em aplicações de sistemas de reconhecimento de padrões. Entretanto, envolve um problema de incremento de dimensionalidade dos padrões projetados.
- O problema de incremento de dimensionalidade dos padrões em iPCA pode ser resolvido mediante aplicação de uma transformação iPCA reduzida. Essa abordagem envolve a solução de um problema de otimização discreto.

O desenvolvimento da fase (b) envolveu processos de: (1) aquisição dos sinais eletromiográficos para projetar e avaliar o sistema, (2) construção do simulador de controle mioelétrico, (3) execução de experimentos que permitiram determinar o desempenho de classificação com as alternativas de tratamento de sinal consideradas e (4) análise comparativa dos resultados.

O banco de sinais eletromiográficos foi fornecido pelo Dr. Levi Hargrove (Hargrove, et al., 2009), o que beneficiou o projeto em dois aspectos: (i) tempo (ii) confiabilidade do banco de dados EMG.

A construção da plataforma de simulação de controle mioelétrico foi o processo que necessitou de mais tempo por causa da grande quantidade de etapas de processamento necessárias e por causa da complexidade dos algoritmos envolvidos. A construção desse simulador foi feita utilizando o software de cálculo numérico Matlab e o conceito de *toolbox* definido nessa ferramenta. Uma porção das funções utilizadas no nosso simulador, foram baseadas na biblioteca de reconhecimento de padrões fornecida pelo Dr. A. D. Chan (Chan, 2007).

A execução de experimentos foi um processo que requereu mais tempo do que o planejado. Isto por causa da complexidade computacional no cálculo da função custo erro de classificação durante as rotinas de otimização. Por essa razão, foi necessário solicitar o serviço de empréstimo das plataformas computacionais do Laboratório Nacional de Computação Científica (LNCC) para cumprir os tempos previstos na coleta dos resultados.

## 6.2 - CONTRIBUÇÕES

A principal contribuição deste trabalho de pesquisa foi a determinação dos efeitos das combinações *função-custo/ algoritmo de busca*, sobre o erro de classificação nos sistemas de controle mioelétrico com sintonização iPCA. A seguir são resumidos estes efeitos:

- Durante o processo de otimização as alternativas de tratamento de sinal com algoritmos de busca sequenciais obtiveram soluções de maior aptidão do que aquelas com algoritmos bio-inspirados. Essas diferenças não foram observadas durante o cálculo do erro de classificação dos padrões de teste. Uma análise de variância (ANOVA) de dois fatores foi executada sobre os resultados obtidos e foi observado um comportamento independente entre o erro de classificação e o algoritmo de busca utilizado ( $p < 0.01$ ) durante a otimização. Sugere-se que a obtenção do valor mínimo na solução do problema de otimização não é condição suficiente para garantir erros de classificação baixos durante o processamento dos padrões de teste.
- Durante o processo de otimização as alternativas de tratamento de sinal que usaram a função custo erro de classificação obtiveram soluções de maior aptidão do que aquelas com função custo fator de correlação. Essa relação foi conservada durante o cálculo do erro de classificação dos padrões de teste, ou seja: os sistemas de controle mioelétrico com matrizes de transformação iPCA reduzida, calculadas a partir da função custo erro de classificação, geraram desempenhos de classificação superiores. A análise ANOVA de dois fatores permitiu concluir que essa superioridade é significativa ( $p < 0.02$ ).
- Considerando o consumo de recursos computacionais existe uma vantagem prática do algoritmo PSO sobre os algoritmos sequencias durante a solução do problema de otimização. Essa vantagem é consequência das poucas avaliações da função custo em cada iteração do PSO: uma avaliação por iteração.

- Os efeitos do *nesting effect* próprios do algoritmo de busca SFS não são significativos nem para a solução do problema de otimização, nem sobre o erro de classificação dos padrões EMG de teste.
- O desempenho de classificação atingido a partir das matrizes de transformação iPCA reduzidas calculadas com função custo fator de correlação foi inferior àquele atingido com matrizes iPCA reduzidas calculadas a partir da função custo erro de classificação. Entretanto, esse desempenho foi superior ao gerado com o sistema de controle mioelétrico convencional.
- O cálculo do fator de correlação precisa de menos recursos computacionais do que o cálculo do erro de classificação. Esse comportamento é consequência da baixa complexidade computacional e da propriedade de função custo não supervisionada do fator de correlação. Entretanto, essa característica não beneficia de forma direta o erro de classificação dos padrões EMG de teste.

Outras contribuições importantes desta pesquisa são:

- Desenvolvimento do *simulador de controle mioelétrico* apto para experimentação com arquiteturas de sintonização iPCA. Esse simulador é uma ferramenta confiável para a execução de experimentos na área de controle mioelétrico. Nele podem ser modificadas as etapas de processamento de maneira independente com o intuito de continuar explorando os efeitos de cada bloco de processamento sobre o erro de classificação do sistema. Essa flexibilidade existe tanto para os processos envolvidos na sintonização iPCA quanto para os processos relacionados com a extração de características, classificação, redução de dimensionalidade e avaliação. Dessa forma, a ferramenta desenvolvida converte-se num recurso de pesquisa valioso para novos projetos na área de controle mioelétrico.
- Avaliação de alternativas de algoritmos de busca bio-inspirados no problema de otimização dentro do esquema de controle mioelétrico com sintonização iPCA.
- Análise detalhada dos fundamentos teóricos relacionados com o controle mioelétrico e a sintonização iPCA.
- Verificação da superioridade de desempenho de classificação do esquema de controle mioelétrico com sintonização iPCA, sobre o esquema de controle mioelétrico convencional.
- Desenvolvimento de um artigo científico que resume as principais conclusões desta pesquisa.

### 6.3 - SUGESTÕES PARA TRABALHOS FUTUROS

No intuito de obter uma definição mais completa das relações entre parâmetros utilizados na rotina de otimização e no erro de classificação gerado durante a avaliação, são sugeridos os seguintes trabalhos futuros:

- Determinar como outros fatores influenciam o desempenho de classificação, por exemplo: o comprimento  $N_l$  do vetor de dimensões reduzidas, o número de componentes principais  $N'$  considerado durante a transformação iPCA (vide seção 3.2.1 -).
- Determinar se as tendências que apresentaram os resultados neste projeto conservam-se quando são utilizadas outras condições de experimentação, em especial nos parâmetros: número de canais de aquisição, número de classes de movimento, pessoal com amputação.
- Estabelecer se a superioridade dos algoritmos sequenciais sobre os bio-inspirados que indicaram nossos resultados durante o processo de otimização, pode ser generalizada. Para isso, é necessário concentrar esforços na sintonização dos parâmetros dos algoritmos bio-inspirados e determinar: (a) se é possível melhorar a aptidão das respostas geradas com esses algoritmos e (b) se a melhora na aptidão tem efeitos sobre o erro de classificação gerado durante avaliação do sistema.

Procurando reduzir a complexidade computacional do processo de otimização sugerem-se os seguintes trabalhos:

- Modificar os algoritmos bio-inspirados para que incluam os comportamentos conhecidos das funções custo durante a busca, por exemplo: sabemos que soluções do vetor  $O'$  com canais repetidos geram altos níveis de correlação e altos erros de classificação, conseqüentemente, é apropriado incluir no algoritmo de busca uma rotina que no lugar de avaliar a função custo sobre esse tipo de soluções puna a combinação de canais repetidos com uma baixa aptidão. Isto vai reduzir o número de avaliações da função custo e o tempo de geração da solução ótima.
- Avaliar alternativas de parâmetros dos algoritmos de busca em procura de combinações que permitam deter o processo de cálculo da solução ótima com critérios diferentes ao número máximo de iterações. Isso vai reduzir o número de iterações e o tempo de geração da solução ótima.

Na seção 3.3.2 - foi apresentada a classificação independente de subespaços. Essa proposta foi rejeitada para o caso do controle mioelétrico pela complexidade computacional envolvida em problemas com alto número de classes de movimento. Entretanto, ainda se desconhece se existe uma vantagem em utilizar esse esquema na classificação de sinais eletromiográficos. Nesse sentido, é interessante: (1) determinar se existe alguma vantagem derivada do esquema de classificação independente de subespaços e (b) estabelecer qual é o limite de classes de movimento que podem ser classificadas com essa técnica, considerando plataformas de processamento de alta capacidade de processamento como FPGAs ou GPUs.

Os tempos registrados durante o processo de otimização com a função custo erro de classificação indicam que a busca da solução é realizada em tempos não triviais (vide Tabela 4-6): considerando o algoritmo de menores tempos de iteração (PSO) o cálculo da matriz iPCA reduzida para um único usuário pode superar as 5 horas<sup>12</sup> (155s \* 120 iterações). Adicionalmente, sabemos que o sinal eletromiográfico é um sinal que apresenta alta variabilidade ainda no mesmo sujeito (Araujo, et al., 2000). Portanto, surge a pergunta: é possível que os sinais EMG em um usuário tenham mudado o suficiente desde o momento em que foi coletada a base de dados para configuração do sistema até o momento em que o sistema de controle mioelétrico esteja configurado? A resposta a essa pergunta vai permitir estabelecer o benefício prático do esquema de controle mioelétrico com sintonização iPCA.

É interessante formalizar o *toolbox* de controle mioelétrico desenvolvido nesta pesquisa com o intuito de obter uma ferramenta de simulação útil para apoiar processos de ensino na área de controle mioelétrico e processamento digital de sinais eletromiográficos.

---

<sup>12</sup> Este tempo considerando a capacidade de computo do PC utilizado nossa pesquisa (vide Tabela 4-13)

## REFERÊNCIAS BIBLIOGRÁFICAS

**Araujo R.C., Duarte M. e A.C. Amadio** On the inter- and intra-subject variability of the electromyographic signal in isometric contractions [Periódico] // Electromyogr Clin Neurophysiol. - 2000. - 4 : Vol. 40. - pp. 225-229.

**Athanasios Papoulis** Probability, Random Variables, and Stochastic Processes [Livro]. - New York : McGraw-Hill, Inc, 1991. - Terceira.

**Bivkel J. Piter e Doksum Kjell** A Mathematical Statistics Basic Ideas and Selected Topics [Livro]. - New Jersey : Joane Wendelken, 2001. - segunda.

**Camacho Guillermo** Relatório de avanços no projeto de Mestrado - 03 [Relatório] / Departamento de Engenharia Mecânica ; Universidade de Brasília. - Faculdade de Tecnologia : [s.n.], 2011.

**Campos Teófilo Emídio, Feris Rogério Schimidt e Marcondes Cesar Junior Roberto** Improved Face x Non-Face Discrimination Using Fourier Descriptors Through Feature Selection [Conferência] // Brazilian Symposium on Computer Graphics and Image Processing (SIBGRAPI 2000). - Gramado, Brazil : [s.n.], 2000. - pp. 1-8.

**Chan A. D. C. e Englehart K. B.** Continuous Classification of Myoelectric Signals for Powered Prostheses using Gaussian Mixture Models [Periódico] // Proceedings of the 25 Annual International Conference of the IEEE EMBS. - Setembro de 2003. - pp. 2841-2844.

**Chan A.D. C. e Englehart Kevin** Continuous Myoelectric Control for Powered Prostheses Using Hidden Markov Models [Periódico] // IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING. - Janeiro de 2005. - Vol. 52. - pp. 121-124.

**Chan A.D.C.** Myoelectric Control Development Toolbox [Periódico] // Apresentado na trigésima conferência Can. Med. Biol. Eng. Soc. Toronto. - 2007. - Vol. M0100. - p. 4.

**Das Koel e Nenadic Zoran** An efficient discriminant based solution for small sample size problem [Periódico] // Pattern Recognition. - Agosto de 2008. - Vol. 42. - pp. 857-866.

**Das Koel, Osechinskiy Sergey e Nenadic Zoran** A classwise PCA-based Recognition of Neural Data for Brain Computer Interfaces [Conferência] // Proceedings of the 29th

Annual International Conference of the IEEE EMBS. - Lyon, France : [s.n.], 2007. - pp. 6519-6522.

**De Luca C. J.** Encyclopedia of Medical Devices and Instrumentation. Electromyography [Livro] / ed. Webster John G.. - Boston : John Wiley Publisher, 2006.

**De Luca Carlo** Imaging the Behavior of Motor Units by Decomposition of the EMG Signal [Online] // Delsys. - 2008. - 18 de Junho de 2011. - [http://www.delsys.com/Attachments\\_pdf/Practicum%20on%20sEMG%20v1.5%20-%20Section%201%20Basic%20Concepts.pdf](http://www.delsys.com/Attachments_pdf/Practicum%20on%20sEMG%20v1.5%20-%20Section%201%20Basic%20Concepts.pdf).

**De Luca Gianluca** Fundamental Concepts in EMG Signal Acquisition [Relatório] / Delsys Inc. - 2003.

**Devore Jay L** Probabilidade e Estatística para Engenharia e Ciências [Livro]. - [s.l.] : Thomson, 2006. - Tradução da Sexta Edição .

**Dorcas D. S. e Scott R. N.** "A three state myoelectric control [Periódico] // Med. Biol. Eng. - 1966. - Vol. 4. - pp. 367-372.

**Duda R., Hart P. e Stork D.** Pattern Classification [Livro]. - New York : Wiley-Interscience, 2000. - 2.

**Eberhart R. e Kennedy J.** A new optimizer using particle swarm theory [Periódico] // Proceedings of the Sixth International Symposium on Micro Machine and Human Science, 1995. MHS '95.. - Outubro de 1995 . - pp. 39 - 43 .

**Englehart Kevin e Hudgins Bernard** A Robust, Real-Time Control Scheme for Multifunction Myoelectric Control [Periódico] // IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING. - julho de 2003. - 7 : Vol. 50. - pp. 848-854.

**Englehart Kevin** Signal Representation for Classification of the Transient Myoelectric Signal [Livro] / ed. Elétrica Dissertação de Doutorado em Engenharia. - New Brunswick : University of New Brunswick, 1998.

**Englehart Kevin, Hudgins Bernard e Parker Philip A.** A Wavelet-Based Continuous Classification Scheme for Multifunction Myoelectric Control [Periódico] // IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING. - março de 2001. - 3 : Vol. 48. - pp. 302-311.

**Farrell T.R. e Weir R.F.** The Optimal Controller Delay for Myoelectric Prostheses [Periódico] // IEEE Transactions on Neural Systems and Rehabilitation Engineering. - Março de 2007. - 1 : Vol. 15. - pp. 111-118.

**Forbes Ryan e Mohammad Teli Nayeem** Particle Swarm Optimization on Multi-Funnel Functions [Relatório]. - Colorado : Universidade Estadual de Colorado , 2001.

**Graupe D, Salahi J e Kohn K** Multifunction Prosthesis and Orthosis Control via computer identification of temporal pattern differences in single site myoelectric signals [Periódico] // J. Biomed Eng. - 1982. - Vol. 4. - pp. 17-22.

**Hargrove L.J., Scheme E.J. e Englehart K.B.** Multiple Binary Classifications via Linear Discriminant Analysis for Improved Controllability of a Powered Prosthesis [Periódico] // IEEE Transactions on Neural Systems and Rehabilitation Engineering. - Fevereiro de 2010. - 1 : Vol. 18. - pp. 49 - 57 .

**Hargrove Levi J. [et al.]** Principal Components Analysis Preprocessing for Improved Classification Accuracies in Pattern-Recognition-Based Myoelectric Control [Periódico] // IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING. - Maio de 2009. - 5 : Vol. 56. - pp. 1407-1414.

**Hargrove Levi J., Englehart Kevin e Hudgins Bernard** A Comparison of Surface and Intramuscular Myoelectric signal classification [Periódico] // IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING. - Maio de 2007. - 5 : Vol. 54. - pp. 847-853.

**Henrique Veneziano Wilson** Estudo do comportamento do sinal eletromiográfico de superfície em atividades subaquáticas [Livro] / ed. Brasília Universidade de. - Brasília : Tesis de Doutorado em Engenharia Elétrica, 2006.

**Hermens Hermie J. [et al.]** European Recommendations for Surface ElectroMyoGraphy for Noninvasive Assessment of Muscles - Seniam [Livro]. - [s.l.] : RRD publisher, 1999.

**Huang Yonghong [et al.]** A Gaussian Mixture Model Based Classification Scheme for Myoelectric Control of Powered Upper Limb Prostheses [Periódico] // IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING. - Noviembre de 2005. - 11 : Vol. 52. - pp. 1801-1811.

**Hudgins Bernard, Parker Philip e Scott Robert N.** A New Strategy for Multifunction Myoelectric Control [Periódico]// IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING. - Janeiro de 1993. - Vol. 40. - pp. 82-94.

**Hyvärinen A., Karhunen J. e Oja E.** Independent Component Analysis [Livro]. - [s.l.] : John Wiley & Sons, Inc, 2001.

**Jiang Ning, Englehart K.B. e Parker P.A.** Extracting Simultaneous and Proportional Neural Control Information for Multiple-DOF Prostheses From the Surface Electromyographic Signal [Periódico]// IEEE Transactions on Biomedical Engineering. - Abril de 2009. - pp. 1070 - 1080 .

**Jin Jing, Wang Xingyu e Zhang Jianhua** Optimal Selection of EEG Electrodes via DPSO Algorithm [Periódico]// Proceedings of the 7th World Congress on Intelligent Control and Automation. - Junho de 2008. - pp. 5095-5099.

**Karaboga D.** An idea based on honey bee swarm for numerical optimization [Relatório] : Reporte Técnico TR06 / Erciyes University, Engineering Faculty, Computer Engineering Department. - 2005.

**Karaboga Dervis e Basturk Bahriye** A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm [Periódico]// Journal of Global Optimization. - Abril de 2007. - pp. 459-471.

**Karlsson S., Yu J. e Akay M.** Time-frequency analysis of myoelectric signals during dynamic contractions: a comparative study [Periódico]// IEEE Transactions on Biomedical Engineering. - Feb. 2000. - pp. 228 - 238.

**Kaufmann Paul, Englehart Kevin e Platzner Marco** Fluctuating EMG Signals: Investigating Long-term effects of Pattern Matching Algorithms [Periódico]// Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). - 2010. - pp. 6357 - 6360.

**Khushaba R.N., Al-Ani A. e Al-Jumaily A.** Swarm Intelligence based Dimensionality Reduction for Myoelectric Control [Periódico]// 3rd International Conference on Intelligent Sensors, Sensor Networks and Information, 2007.. - Dezembro de 2007. - pp. 577 - 582 .

**Koch Volker M.** A Factor Graph Approach to Model-Based Signal Separation [Livro] / ed. Loeliger Hans-Andrea. - Schweiz : [s.n.], 2007.

**Kuiken Todd [et al.]** Targeted Muscle Reinnervation for Real-Time Myoelectric Control of Multifunction Artificial Arms [Periódico] // The Journal of the American Medical Association. - 2009. - 6 : Vol. 301. - pp. 619–628.

**Kuruganti U., Hudgins B. e Scott R.N.** Two-channel enhancement of a multifunction control system [Periódico] // IEEE Transactions on Biomedical Engineering. - 1995. - 1 : Vol. 42. - pp. 109 - 111.

**LACERDA JOÃO M. T. [et al.]** MULT-I/O - UM MIDDLEWARE MULTI ENTRADA E SAÍDA PARA ACESSO A DISPOSITIVOS: UM ESTUDO DE CASO APLICADO A DISPOSITIVOS BIOMÉDICOS [Conferência] // XVIII Congresso Brasileiro de Automática. - Bonito-MS : [s.n.], 2010. - pp. 4202-4208.

**Liu Xiaoming . Chen, Tsuhan e Kumar Vijaya B.V.K.** Face authentication for multiple subjects using eigenflow [Periódico] // Pattern Recognition. - 2002. - Vol. 36. - pp. 313-328.

**Lock B.A., Englehart K e Hudgins B** Real-time myoelectric control in a virtual environment to relate usability vs. accuracy [Periódico] // Proc. MyoElectric Controls Symp.. - 2005. - pp. 122-127.

**Lowery M.M. [et al.]** A multiple-layer finite-element model of the surface EMG signal [Periódico] // IEEE Transactions on Biomedical Engineering. - Maio de 2002. - 5 : Vol. 49. - pp. 446 - 454.

**McGill Kevin** [Online] // EMGLAB. - Julho de 2006. - <http://www.emglab.net/>.

**Merletti R., A. Rainoldi e Farina D.** Surface Electromyography for Noninvasive Characterization of Muscle [Periódico] // Exerc. Sport Sci. Rev.. - 2001. - 1 : Vol. 29. - pp. 20-25.

**Merletti R., Knaflitz M. e DeLuca C. J.** Electrically evoked myoelectric signals. [Periódico] // Crit Rev Biomed Eng. . - 1992. - pp. 293-340.

**Merletti Roberto [et al.]** Technology and instrumentation for detection and conditioning of the surface electromyographic signal: State of the art [Periódico] // Clinical Biomechanics. - Agosto de 2009. - Vol. 24. - pp. 122-134.

**Merletti Roberto e Parker Philip A.** Electromyography: Physiology, Engineering and Noninvasive Applications [Livro] / ed. Kartalopoulos Stamatios V.. - [s.l.] : IEEE Press Editorial Board, 2004.

**Micera Silvestro e Carpaneto Jacopo, Raspopovic, Stanisa** Control of Hand Prostheses Using Peripheral Information [Periódico] // IEEE Reviews in Biomedical Engineering. - Outubro de 2010. - Vol. 3. - pp. 48-68.

**Micera Silvestro, Sabatini Angelo M. e Dario Paolo** On automatic identification of upper-limb movements using small sized training sets of EMG signals [Periódico] // Medical Engineering & Physics. - 2001. - Vol. 22. - pp. 527-533.

**Mogk Jeremy P.M. e Keir Peter J.** Crosstalk in surface electromyography of the proximal forearm during gripping tasks [Periódico] // Journal of Electromyography and Kinesiology. - April de 2003. - Vol. 13. - pp. 63-71.

**Nielsen J.L.G. [et al.]** Simultaneous and Proportional Force Estimation for Multifunction Myoelectric Prostheses Using Mirrored Bilateral Training [Periódico] // IEEE Transactions on Biomedical Engineering. - Março de 2011. - 3 : Vol. 58. - pp. 681 - 688 .

**Oskoei Asghari Mohammadreza e Huosheng Hu** Myoelectric control systems—A survey [Periódico] // Biomedical Signal Processing and Control. - Outubro de 2007. - 4 : Vol. 2. - pp. 275-294 .

**Oskoei M.A. e Hu Huosheng** Support Vector Machine-Based Classification Scheme for Myoelectric Control Applied to Upper Limb [Periódico] // IEEE Transactions on Biomedical Engineering. . - Agosto de 2008. - 8 : Vol. 55. - pp. 1956 - 1965.

**Pudil P., Novovičová J. e Kittler J.** Floating search methods in feature selection [Periódico] // Pattern Recognition Letters. - New York : [s.n.], Novembro de 1994. - 11 : Vol. 15. - pp. 1119-1125.

**Rainoldi A. [et al.]** Repeatability of maximal voluntary force and of surface EMG variables during voluntary contraction of quadriceps muscles in healthy subjects [Periódico] // J Electromyogr Kinesiol. - 2001. - pp. 425-438.

**Robinson J. e Rahmat-Samii Y.** Particle swarm optimization in electromagnetics [Periódico] // IEEE Transactions on Antennas and Propagation. - Fevereiro de 2004. - pp. 397 - 407 .

**Romo Harold** Aplicación de Wavelets en el análisis y la extracción de características para la clasificación de señales EMGS [Livro]. - Popayán : Universidad del Cauca, 2008. - Dissertação de Maestría em Engenharia.

**Smith L.H. Hargrove, L.J. Lock, B.A. Kuiken, T.A.** Determining the Optimal Window Length for Pattern Recognition-Based Myoelectric Control: Balancing the Competing Effects of Classification Error and Controller Delay [Periódico] // IEEE Transactions on Neural Systems and Rehabilitation Engineering. - Abril de 2011. - 2 : Vol. 19. - pp. 186 - 192.

**Somol P. [et al.]** Floating search methods in feature selection [Periódico] // Pattern Recognition Letters. - 1999. - Vol. 20. - pp. 1157-1163.

**The Mathworks Inc** MATLAB 7.11. - Natick, MA : [s.n.], (R2010b).

**Theodoridis Sergios e Konstantinos Koutrumbas** Pattern Recognition [Livro]. - [s.l.] : Elsevier, 2006. - Terceira.

**Tou Julius T. e Gonzales R. C.** Pattern Recognition Principles [Livro]. - [s.l.] : Addison-Wesley, 1977.

**Welling P. T.** Zerlegung von Langzeit-Elektromyogrammen zur Prävention von arbeitsbedingten Muskelschäden [Livro]. - Schweiz : ETH Zurich, 2000. - Tesis Doctoral.

**Ye Jieping [et al.]** Feature Reduction via Generalized Uncorrelated Linear Discriminant Analysis [Periódico] // IEEE TRANSACTIONS ON KNOWLEDGE AND DATA ENGINEERING. - Outubro de 2006. - 10 : Vol. 18. - pp. 1312-1322.

**Ye Jieping [et al.]** Using uncorrelated discriminant analysis for tissue classification with gene expression data [Periódico] // IEEE/ACM TRANSACTIONS ON

COMPUTATIONAL BIOLOGY AND BIOINFORMATICS. - Outubro de 2004. - 1 : Vol.  
4. - pp. 181-190.

## **APÊNDICES**

## A - CARACTERÍSTICAS RMS E AR

### A.1 - CARACTERÍSTICAS RMS.

Esta característica é preferida em aplicações onde o sinal pode tomar valores negativos e positivos, sendo este o caso do sinal eletromiográfico. Matematicamente o valor RMS é calculado a partir da raiz quadrada do valor médio das amostras como se indica na equação (6-1).

$$x_{i,rms} = \sqrt{\frac{1}{M} \sum_{i=1}^M x_i^2} \quad (6-1)$$

Onde

$x_{i,rms}$  é o sinal EMG do canal  $i$

$M$  é a quantidade de amostras na janela

### A.2 - PARÂMETROS AR COMO CARACTERÍSTICAS DO SINAL.

Está é uma das características mais comuns na literatura de controle eletromiográfico. Sua popularidade é justificada pelo bom compromisso que apresenta entre a capacidade discriminativa e custo computacional (Micera, et al., 2001). A seguir é apresentado o processo de cálculo desta característica considerando um único canal. Para  $N$  canais o processo pode ser repetido independentemente para cada canal.

Os modelos AR fazem parte de uma família de *preditores lineares* baseados em modelos paramétricos. A notação  $AR_p$  indica: modelo AR de ordem  $p$ . O modelo AR de ordem  $p$  é indicado na equação (6-2) (Micera, et al., 2010).

$$x(n) = \sum_{j=1}^p a_j x(n-j) + e(n) \quad (6-2)$$

com  $x(n)$  é o sinal eletromiográfico no instante  $n$ ,  $a_j$  é o conjunto de coeficientes do modelo autoregressivo para ( $j=1, \dots, p$ ) e  $e(n)$  o erro de predição.

O vetor de parâmetros  $a_j$  é o componente utilizado como característica em aplicações de controle eletromiográfico. Uma forma de olhar a equação (6-2) é interpretando os coeficientes  $a_j$  como parâmetros de predição do sinal  $x$ . Ou seja, o conjunto  $a_j$  é um conjunto de parâmetros que pondera as amostras prévias  $[x(n-1), \dots, x(n-p)]$  objetivando prever o valor atual do sinal  $x(n)$ . Considerando um único canal teremos o valor predito como se indica na equação (6-3):

$$\hat{x}(n) = \sum_{j=1}^p a_j x(n-j) \equiv a_p^T x_p(n-1) \quad (6-3)$$

Com

$$a_p^T = [a(1), a(2), \dots, a(p)]; \text{ vetor de parâmetros.}$$

$$x_p(n-1) = [x(n-1), \dots, x(n-p)]$$

O vetor de parâmetros pode ser estimado minimizando o erro médio quadrático do preditor. Este erro é definido na equação (6-4):

$$E[e^2(n)] = E[(x(n) - \hat{x}(n))] = E[(x(n) - a_p^T x_p(n-1))^2] \quad (6-4)$$

Em (Theodoridis, et al., 2006), apresenta-se o processo de otimização da expressão (6-4), concluindo que o vetor de parâmetros desconhecidos  $a_p$  pode ser calculado solucionando a expressão em (6-5). São precisamente esses parâmetros os utilizados como características discriminativas para classificação do sinal eletromiográfico.

$$E[x_p(n-1)x_p^T(n-1)]a_p = E[x(n)x_p(n-1)] \quad (6-5)$$

Considerando a sequência de autocorrelação definida em (6-6), a expressão em (6-5) pode ser escrita como se apresenta na equação (6-7).

$$r(k) = E[x(n)x(n-k)] \quad (6-6)$$

$$\begin{bmatrix} r(0) & r(-1) & \cdots & r(-p+1) \\ r(1) & r(0) & \cdots & r(-p+2) \\ \vdots & \vdots & \vdots & \vdots \\ r(p-2) & r(p-3) & \cdots & r(-1) \\ r(p-1) & r(p-2) & \cdots & r(0) \end{bmatrix} \begin{bmatrix} a(1) \\ a(2) \\ \vdots \\ a(p-1) \\ a(p) \end{bmatrix} = \begin{bmatrix} r(1) \\ r(2) \\ \vdots \\ r(p-1) \\ r(p) \end{bmatrix} \quad (6-7)$$

Ou na forma resumida como aparece em (6-8).

$$Ra_p = r_p \quad (6-8)$$

Onde  $r_p = [r(1), \dots, r(p)]^T$

A matriz de autocorrelação  $R$  tem propriedades simétricas que podem ser aproveitadas para desenvolver algoritmos com esforços computacionais eficientes na solução da equação (6-8). Um destes algoritmos é o algoritmo de *Levinson-Durbin* que consegue solucionar o sistema de equações em  $O(p^2)$  multiplicações e somas, superando os esquemas clássicos que precisavam de  $O(p^3)$  multiplicações e somas (Theodoridis, et al., 2006).

## B - MATRIZES DE DISPERSÃO NA REDUÇÃO DE DIMENSIONALIDADE

Considere um problema de reconhecimento de padrões de  $C$  classes. A partir do conjunto de amostras de treinamento  $x$  podemos calcular:

$m_i = E[x_i]$ ; Valor esperado das amostras da classe  $i$ . Comprimento  $[I \times LN]$

$S_i = E[(x - m_i)(x - m_i)^T]$ ; Matriz de covariância da classe  $i$ . Comprimento  $[LN \times LN]$

$P_i = \frac{x_i}{length(x)}$ ; Probabilidade a priori da classe  $i$ . Comprimento  $[I \times LN]$

$m = E[m_i]$ ; Média total. Comprimento  $[1 \times 1]$

Tomando em conta estas definições, as matrizes de dispersão são:

$S_w = \sum_{i=1}^C P_i S_i$ ; *within-class scatter matrix*. Comprimento  $[I \times LN]$

$S_b = \sum_{i=1}^C P_i (m_i - m)(m_i - m)^T$ ; *between-class scatter matrix*. Comprimento  $[I \times LN]$

$S_t = S_b + S_w$ ; *total scatter matrix*. Comprimento  $[I \times LN]$

Um indicador da distância entre padrões pertencentes à mesma classe é:

$$trace(S_w)$$

Um indicador da distância entre classes é:

$$trace(S_b)$$

A matriz de transformação  $G$  utilizada em LDA procura minimizar a distância entre padrões da mesma classe e maximizar a distância entre classes diferentes, o problema de otimização é proposto assim:

$$G = \underset{G}{\operatorname{argmax}} \operatorname{trace}[(S_w^L)^{-1} S_b^L]$$

Onde

$S_w^L$  é a matriz *within-class scatter matrix* do domínio transformado com  $G$ .

$S_b^L$  é a matriz *between-class scatter matrix* do domínio transformado com  $G$ .

## C - MATRIZ DE COVARIÂNCIA PARA O CASO DE DADOS MULTIDIMENSIONAIS

Considere um conjunto de dados multidimensional representado na equação (6-9). Assuma que os dados tem média zero.

$$x = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1M} \\ x_{21} & x_{22} & \cdots & x_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \cdots & x_{NM} \end{bmatrix} \quad (6-9)$$

Onde  $M$  é o número de observações (ou amostras) e  $N$  o número de canais.

Resulta prático representar o conjunto de dados na equação (6-9) em função de vetores colunas como se indica na equação (6-10)

$$x = [x_1(n) \quad x_2(n) \quad \cdots \quad x_M(n)] \quad (6-10)$$

Onde

$$x_i(n) = [x_{1i} \quad x_{2i} \quad \cdots \quad x_{Ni}]^T$$

Segundo (Theodoridis, et al., 2006) a matriz de covariância para este conjunto de dados pode ser calculada com a expressão na equação (6-11)

$$C_x = \frac{1}{M} \sum_{i=1}^M x_i(n)x_i^T(n) \quad (6-11)$$

Agora vamos tentar expandir esta expressão:

$$C_x = \frac{1}{M} (x_1 x_1^T + x_2 x_2^T + \dots + x_M x_M^T)$$

$$C_x = \frac{1}{M} \left( \begin{bmatrix} x_{11} \\ x_{21} \\ \vdots \\ x_{N1} \end{bmatrix} [x_{11} \quad x_{21} \quad \cdots \quad x_{N1}] + \begin{bmatrix} x_{12} \\ x_{22} \\ \vdots \\ x_{N2} \end{bmatrix} [x_{12} \quad x_{22} \quad \cdots \quad x_{N2}] + \cdots + \begin{bmatrix} x_{1M} \\ x_{2M} \\ \vdots \\ x_{NM} \end{bmatrix} [x_{1M} \quad x_{2M} \quad \cdots \quad x_{NM}] \right)$$

$$\begin{aligned}
C_x &= \frac{1}{M} \left( \begin{bmatrix} x_{11}x_{11} & x_{11}x_{21} & \cdots & x_{11}x_{N1} \\ x_{21}x_{11} & x_{21}x_{21} & \cdots & x_{21}x_{N1} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1}x_{11} & x_{N1}x_{21} & \cdots & x_{N1}x_{N1} \end{bmatrix} + \begin{bmatrix} x_{12}x_{12} & x_{12}x_{22} & \cdots & x_{12}x_{N2} \\ x_{22}x_{12} & x_{22}x_{22} & \cdots & x_{22}x_{N2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N2}x_{12} & x_{N2}x_{22} & \cdots & x_{N2}x_{N2} \end{bmatrix} + \cdots + \begin{bmatrix} x_{1M}x_{1M} & x_{1M}x_{2M} & \cdots & x_{1M}x_{NM} \\ x_{2M}x_{1M} & x_{2M}x_{2M} & \cdots & x_{2M}x_{NM} \\ \vdots & \vdots & \ddots & \vdots \\ x_{NM}x_{1M} & x_{NM}x_{2M} & \cdots & x_{NM}x_{NM} \end{bmatrix} \right) \\
C_x &= \frac{1}{M} \left( \begin{bmatrix} x_{11}x_{11} + x_{12}x_{12} + \cdots + x_{1M}x_{1M} & x_{11}x_{21} + x_{12}x_{22} + \cdots + x_{1M}x_{2M} & \cdots & x_{11}x_{N1} + x_{12}x_{N2} + \cdots + x_{1M}x_{NM} \\ x_{21}x_{11} + x_{22}x_{12} + \cdots + x_{2M}x_{1M} & x_{21}x_{21} + x_{22}x_{22} + \cdots + x_{2M}x_{2M} & \cdots & x_{21}x_{N1} + x_{22}x_{N2} + \cdots + x_{2M}x_{NM} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1}x_{11} + x_{N2}x_{12} + \cdots + x_{NM}x_{1M} & x_{N1}x_{21} + x_{N2}x_{22} + \cdots + x_{NM}x_{2M} & \cdots & x_{N1}x_{N1} + x_{N2}x_{N2} + \cdots + x_{NM}x_{NM} \end{bmatrix} \right) \\
C_x &= \frac{1}{M} \left( \begin{bmatrix} \sum_{i=1}^M x_{1i}x_{1i} & \sum_{i=1}^M x_{1i}x_{2i} & \cdots & \sum_{i=1}^M x_{1i}x_{Ni} \\ \sum_{i=1}^M x_{2i}x_{1i} & \sum_{i=1}^M x_{2i}x_{2i} & \cdots & \sum_{i=1}^M x_{2i}x_{Ni} \\ \vdots & \vdots & \ddots & \vdots \\ \sum_{i=1}^M x_{Ni}x_{1i} & \sum_{i=1}^M x_{Ni}x_{2i} & \cdots & \sum_{i=1}^M x_{Ni}x_{Ni} \end{bmatrix} \right) \tag{6-12}
\end{aligned}$$

Nesta última forma da matriz de covariância (equação (6-12)) é possível distinguir algumas características:

- A matriz de covariância é simétrica e de comprimento  $N \times N$ .
- O primeiro elemento  $\sum_{i=1}^M x_{1i}x_{1i}$  é o somatório do quadrado das observações pertencentes ao canal 1.

- O segundo elemento da primeira coluna  $\sum_{i=1}^M x_{2i}x_{1i}$  é o somatório do produto entre observações dos canais 1, 2 adquiridas no mesmo instante de tempo
- O  $N$ -ésimo elemento da primeira coluna  $\sum_{i=1}^M x_{Ni}x_{1i}$  é o somatório do produto entre amostras dos canais 1,  $N$  adquiridas no mesmo instante de tempo

## D - EXEMPLO DA MATRIZ DE COEFICIENTES DE CORRELAÇÃO.

Calcule a matriz de coeficientes de correlação entre dois sinais  $x_1$ ,  $x_2$  considerando os casos a seguir:

- $x_1$ ,  $x_2$  são sinais com tendências de proporção direta como as ilustradas na Figura 6-1a). Com incrementos em  $x_1$  também temos incrementos em  $x_2$ .
- $x_1$ ,  $x_2$  não apresentam nenhum tipo de proporção mútua (vide Figura 6-1b)).
- $x_1$ ,  $x_2$  são sinais com tendências de proporção inversa como as ilustradas na Figura 6-1c). Com crescimentos de  $x_1$  temos decréscimos de  $x_2$ .

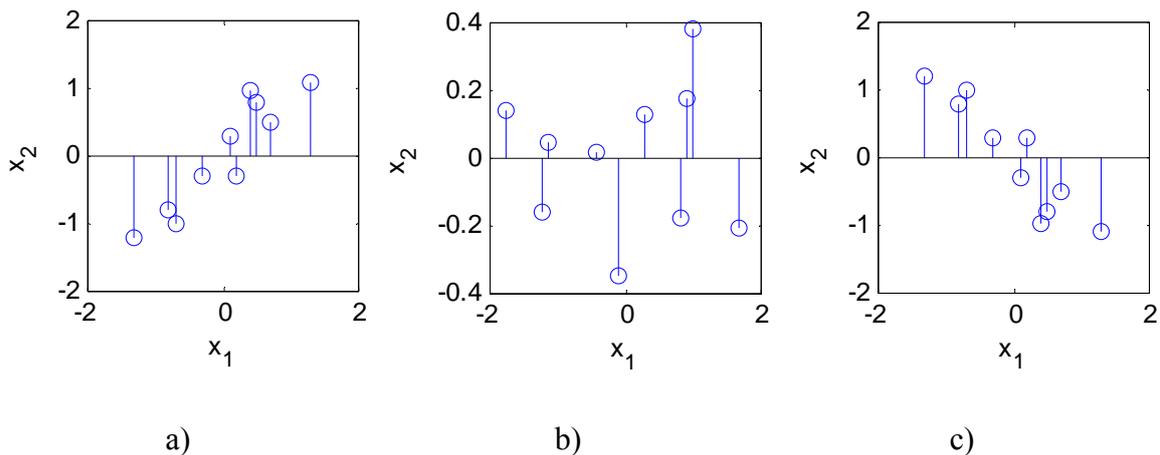


Figura 6-1. Relação entre os sinais  $x_1$ ,  $x_2$ .

A Figura 6-2 ilustra a matriz de coeficientes de correlação para os três casos considerados. Em cada caso desta Figura, as barras indicam a correlação entre um par de sinais: A barra na coordenada (1,2) indica a correlação entre o par de sinais ( $x_1$ ,  $x_2$ ). Para o caso (a), que considera proporção direta (vide Figura 6-2a)) vemos que a barra tem um valor positivo de elevada amplitude. Isto é consequência da tendência de crescimento proporcional tão definida entre os sinais (vide Figura 6-1a)). Para o caso (b), que considera proporção nula, a barra tem uma amplitude zero (vide Figura 6-2b)), indicando que não existem tendências de crescimento entre os dois sinais. Para o caso (c), que considera proporção inversa, a barra tem um valor negativo (vide Figura 6-2c)) indicando que quando um sinal cresce, o outro sinal decresce.

A barra na coordenada (1,1) indica o coeficiente de correlação entre o par de sinais ( $x_1, x_1$ ). Neste caso a amplitude atingida sempre vai ser 1 devido a que se trata da correlação entre o mesmo sinal. Este caso repete-se para a coordenada (2,2) que avalia a correlação entre o par de sinais ( $x_2, x_2$ ).

Finalmente, a coordenada (2,1) apresenta o coeficiente de correlação entre os sinais ( $x_2, x_1$ ). Este coeficiente vai ser igual ao calculado na coordenada (1,2).

A partir das observações neste exemplo podemos concluir algumas características da matriz de coeficientes de correlação:

- É uma matriz simétrica
- Sua diagonal principal é unitária
- É uma matriz quadrada de comprimento  $N \times N$ . Onde  $N$  é a dimensão dos dados de entrada (no exemplo  $N=2$ )

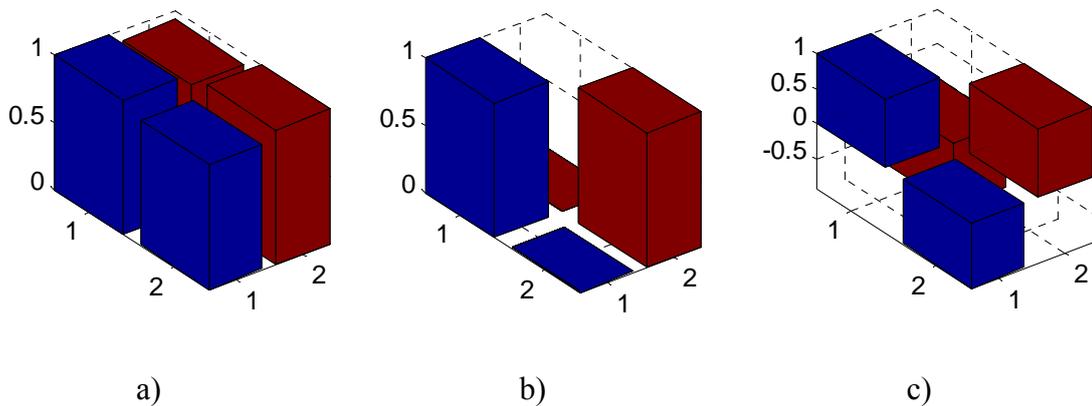


Figura 6-2. Matrizes de coeficientes de correlação para os três casos considerados no exemplo.