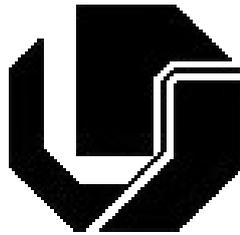


UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA



Decomposição de sinais eletromiográficos de
superfície utilizando Modelos Ocultos de Markov

Ângela Abreu Rosa de Sá

Novembro

2010

Decomposição de sinais eletromiográficos utilizando Modelos Ocultos de Markov

Ângela Abreu Rosa de Sá[‡]

Texto da tese apresentada à Universidade Federal de Uberlândia como parte dos requisitos para obtenção do título de Doutor em Ciências.

Prof. Alcimar Barbosa Soares, PhD.

Orientador

Prof. Adriano O. Andrade, PhD.

Co-orientador

Prof. Dr. Alexandre Cardoso

Coordenador do curso de Pós-Graduação

[‡]A bolsa de estudo para esta pesquisa foi concedida pela CAPES, Brasil.

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**Decomposição de sinais eletromiográficos de
superfície utilizando Modelos Ocultos de Markov**

Ângela Abreu Rosa de Sá

Texto da tese apresentada à Universidade Federal de Uberlândia, perante a banca de examinadores abaixo, como parte dos requisitos necessários para a obtenção do título de Doutor em Ciências.

Banca Examinadora:

Prof. Alcimar Barbosa Soares, PhD - Orientador (UFU)

Prof. Adriano de Oliveira Andrade, PhD - Co-orientador (UFU)

Prof. Dr. Keiji Yamanaka (UFU)

Prof. Dr. Adson Ferreira Rocha (UNB)

Prof. Dr. Marcus Fraga Vieira (UFG)

*“Sem metas, os sonhos não têm alicerces.
Sem prioridades, os sonhos não se tornam reais.”
(Autor desconhecido)*

*“If I have seen further,
it is by standing on the
shoulders of giants.”
(Isaac Newton)*

*Aos meus pais, Jacira e Alamen,
À minha irmã, Angélica ,
Aos meus irmãos, Alamen e Leonardo,
pelo incentivo, amor e apoio incondicionais.*

Agradecimentos

A Deus, por estar sempre presente em minha vida e me iluminar durante esta longa jornada.

À minha mãe, Jacira ... o que eu posso falar para você, mamãe? Sem você, nada seria possível! Obrigada por você existir!

Ao meu pai, Alamen, por todo o incentivo e apoio.

Aos meus amados irmãos, Angélica, Alamen e Leonardo, por tudo de bom que vocês são para mim! Obrigada por todo o apoio e torcida: vocês são muito preciosos para mim!

Aos meus sobrinhos Leonardo, Mateus e Laura; por sempre me alegrar e me deixar mais feliz ao ver um sorriso no rosto de vocês!

Ao meu querido Afonso Castro, por estar sempre ao meu lado e me apoiar em todos os momentos!

Ao meu orientador Alcimar Soares, pela amizade, companheirismo e pela força (e esforços!) durante todos esses anos. Eu nunca vou conseguir agradecer o quanto eu devo a você! Obrigada por tudo!

Ao meu orientador Adriano Andrade, pela amizade, por sempre acreditar no meu trabalho e sempre me mostrar um caminho para eu crescer mais. Meu eterno agradecimento a você!

Ao meu orientador Slawomir Nasuto, pela amizade, trabalho em conjunto e pela oportunidade de estágio na Inglaterra. *Thank you very much indeed for everything!*

Aos meus amigos do laboratório da University of Reading: Richard, Martin, Leg, Phil and Paul - you were really angels in my life! Those were the best times ever ... words can't express what you mean to me! Thank you all guys!

Aos meus amigos de Reading - Graham, Anoop e Emma: I'll be always indebted with you! Thank you so much!

À querida Cinara Fagundes, pela amizade, apoio, alegria e dedicação no trabalho nesta pós-graduação. Muito obrigada!

Às minhas amigas Laíse Oliveira e Tatiane Vieira, pelo companheirismo, amizade e todos os momentos de descontração!

Aos amigos do Laboratório de Engenharia Biomédica (Biolab) - é sempre uma grande alegria estar com vocês!

Ao meu amigo Nei Souza, pela grande amizade e torcida durante todos esses anos. Obrigada!

Às minhas amigas Suzi Miziara e Cyntia Medeiros: a energia positiva de vocês fez toda a diferença. Muito obrigada!

Aos amigos Wesley Pacheco e Aylton Alves, do Laboratório de Máquinas Elétricas e Eletromagnetismo: muito obrigada pela amizade e pela torcida!

A todos os professores e funcionários da Faculdade de Engenharia Elétrica, sempre dispostos a ajudar!

A todos os amigos da pós-graduação, pela amizade e alegria que vocês me propor-

cionaram ao longo destes 4 anos.

A todos que contribuíram de alguma forma, direta ou indiretamente, para a realização deste trabalho.

A todos que torceram por mim!

A CAPES pelo suporte financeiro a esta pesquisa, no Brasil e na Inglaterra.

Resumo

Sa, A. A. R. & Soares, A. B. & Andrade, A. O. Decomposição de sinais eletromiográficos de superfície utilizando Modelos Ocultos de Markov, FEELT-UFU, Uberlândia, 2010, 184p.

A captação de sinais fisiológicos provenientes do Sistema Motor, que pode ser realizada pela eletromiografia, tem sido cada vez mais utilizada na prática clínica para auxiliar o terapeuta no diagnóstico de distúrbios motores. Desta forma, o processo de decomposição de sinais eletromiográficos (EMG), que inclui a identificação e classificação dos potenciais de ação de Unidade Motora (MUAP) de um sinal EMG de superfície é de extrema importância para a prática clínica, para auxiliar os profissionais na detecção de patologias do Sistema Motor.

O processo de decomposição de um sinal EMG é uma tarefa complexa, pois as características de um sinal EMG dependem do tipo de eletrodo utilizado (intramuscular ou de superfície), do seu posicionamento em relação ao músculo, o nível de contração e o estado clínico do Sistema Neuromuscular do paciente. A maior parte dos sistemas de decomposição de sinais EMG são específicos para o sinal proveniente de eletrodos invasivos, devido às facilidades e vantagens em processar este tipo de sinal. Assim, poucos esforços foram concentrados no que tange à decomposição de sinais EMG de superfície.

Neste contexto, este trabalho apresenta um sistema de decomposição de sinais EMG de superfície utilizando Modelos Ocultos de Markov, com o apoio das técnicas Evolução Diferencial e Agrupamento Espectral, no intuito de auxiliar a prática clínica e as terapias de Biofeedback.

O sistema desenvolvido apresentou resultados coerentes no que tange a: a) Identi-

ficação da quantidade de Unidades Motoras ativas no sinal EMG; b) Apresentação dos padrões morfológicos de MUAPs presentes no sinal EMG; c) Identificação da seqüência de disparos das Unidades Motoras no sinal EMG analisado.

As técnicas utilizadas neste trabalho ainda não tinham sido fruto de pesquisa na área de decomposição de sinais EMG, e se destacam como excelentes técnicas para processamento de sinal EMG de superfície. A arquitetura do modelo proposto constitui um avanço nas pesquisas de decomposição de eletromiografia de superfície.

Palavras-chave: decomposição de sinal eletromiográfico, eletromiografia, Unidades Motoras, potenciais de ação de Unidade Motoras.

Abstract

Sa, A. A. R. & Soares, A. B. & Andrade, A. O. Decomposition of surface electromyographic signals using Hidden Markov Models, Uberlândia, 2010, 184p.

The detection of physiological signals from the Motor System (electromyographic signals), studied by electromyography, is being utilized in the practice clinic to guide the therapist in a more precise and accurate diagnosis of motor disorders. In this context, the process of decomposition of electromyographic signals (EMG) that includes the identification and classification of Motor Unit Action Potential (MUAP) of EMG signals, is very important to help the therapist in the evaluation of motor disorders

The EMG decomposition is a complex task due to the features of the EMG features depend on the electrode type (needle or surface), its placement related to the muscle, the contraction level and the health of the Neuromuscular System. To date the majority of research on EMG decomposition utilizes EMG signals acquired by needle electrodes, due to their advantages in processing this type of signal. However, relatively little research has been conducted using surface based EMG signals.

As such this thesis aims to contribute to the clinical practice and Biofeedback therapies by presenting a system permitting the decomposition of surface EMG signal via the use of Hidden Markov Models. This process is supported by the use of Differential Evolution and Spectral Clustering techniques.

The developed system presented coherent results in: a) Identification of the number of Motor Units actives in the EMG signal; b) Presentation of the morphological patterns of MUAPs in the EMG signal; c) Identification of the firing sequence of the Motor Units.

The Techniques utilized in this work have not yet been applied in the field of EMG

decomposition and, in the end of this work, it was proved that they are excellent techniques for the surface EMG decomposition. The model proposed in this work is an advance in the research of decomposition of surface EMG signals.

Keywords: decomposition of electromyographic signal, electromyography, Motor Units, Motor Units Action Potentials.

Lista de Acrônimos

AG: Algoritmo Genético.

ED: Evolução Diferencial.

EMG: Eletromiografia.

MOM: Modelo Oculto de Markov.

MU: Motor Unit (Unidade Motora).

MUAP: Motor Unit Action Potential (Potencial de ação de Unidade Motora).

MUAPT: Motor Unit Action Potential Train (Trem de potenciais de ação de Unidade Motora).

PDF: Probability Density Function (função de densidade de probabilidade).

SN: Sistema Neuromuscular.

SNC: Sistema Nervoso Central.

Conteúdo

1	Introdução	1
1.1	Motivação	3
1.2	Definição do problema	5
1.3	Objetivo	8
1.4	Contribuições da tese	8
1.5	Estrutura do trabalho	9
2	O Sinal Eletromiográfico	12
2.1	Introdução	12
2.2	Origem do sinal EMG	13
2.2.1	O músculo esquelético	13
2.2.2	As fibras musculares	16
2.2.3	A Unidade Motora	17
2.2.3.1	Recrutamento de Unidades Motoras	18
2.2.4	Composição do sinal eletromiográfico	19
2.3	Detecção do sinal EMG	20
2.3.1	Amplificação do sinal EMG	24
2.3.2	Aquisição do sinal EMG	24
2.3.3	Pré-processamento do sinal EMG	25
2.4	Decomposição de sinais EMG	25
2.4.1	Seleção de MUAPs	26
2.4.2	Agrupamento de MUAPs	27
2.4.3	Software EMG Decomposition-BR	28
2.5	Conclusão	28

3	Modelos Ocultos de Markov	30
3.1	Introdução	30
3.2	Cadeias de Markov	31
3.3	Modelos Ocultos de Markov	33
3.3.1	Operações realizadas com os parâmetros do Modelo Oculto de Markov	35
3.3.1.1	Busca por uma solução	35
3.3.1.2	Seqüência ótima de estados	37
3.3.1.3	Estimação de parâmetros	39
3.4	Modelo Oculto de Markov Contínuo	41
3.5	Topologias de Modelos Ocultos de Markov	43
3.6	Aplicações dos Modelos Ocultos de Markov	45
3.7	Conclusão	45
4	Evolução Diferencial	47
4.1	Introdução	47
4.2	Algoritmos genéticos	48
4.2.1	Elementos integrantes de um Algoritmo Genético	49
4.2.2	Parâmetros da evolução do AG	53
4.3	Evolução Diferencial	54
4.3.1	Mutação	55
4.3.2	Cruzamento	56
4.3.3	Seleção	57
4.4	Conclusão	57
5	Agrupamento Espectral	59
5.1	Introdução	59
5.2	Agrupamento	59
5.2.1	Representação dos dados: extração de características	60
5.2.2	Medidas de similaridade	60
5.2.3	Medidas de avaliação da qualidade do agrupamento	62
5.2.3.1	Medidas Externas	62
5.2.3.2	Medidas Internas	62
5.2.4	Técnicas de Agrupamento	63

5.3	Agrupamento Espectral	63
5.3.1	Análise Espectral de Grafos	69
5.3.2	Estimando a quantidade de grupos	70
5.3.3	Algoritmos para Agrupamento Espectral	72
5.4	Conclusão	73
6	Projeto e implementação de um sistema de decomposição de sinais EMG de superfície	74
6.1	Introdução	74
6.2	Estrutura do sistema de decomposição de sinais EMG de superfície	75
6.2.1	Sistema EMG-Decomposition-BR®	76
6.2.2	Agrupamento de MUAPs	77
6.3	Implementações realizadas	88
6.3.1	Simulações e resultados obtidos com o MOM	89
6.3.2	Evolução Diferencial: estudos e simulações	99
6.3.2.1	Avaliação do desempenho do algoritmo Evolução Diferencial	99
6.3.2.2	Proposta do algoritmo Evolução Diferencial com Seleção Probabilística (EDSP)	104
6.3.2.3	Otimização dos parâmetros do Modelo Oculto de Markov utilizando o algoritmo EDSP	110
6.3.3	Avaliação da qualidade de grupos de MUAPs	115
6.4	Conclusão	121
7	Validação do sistema desenvolvido e resultados	122
7.1	Introdução	122
7.1.1	Sinais EMG sintéticos	122
7.1.2	Sinais EMG reais	124
7.2	Resultados	126
7.2.1	Sinais EMG sintéticos	126
7.2.2	Sinais EMG reais	140
7.3	Discussão	142
7.4	Conclusão	144

8	Considerações finais e trabalhos futuros	146
8.1	Conclusões gerais	146
8.2	Limitações do sistema	149
8.3	Trabalhos futuros	149
	Referências bibliográficas	149
A	Publicações	167
B	Protocolo de coleta dos sinais EMG	169
B.1	Detecção do sinal EMG	169
B.2	Posicionamento dos eletrodos no músculo	170
B.3	Protocolo Experimental	171
B.4	Aquisição de dados	171
C	Estimativa da seqüência de disparos das Unidades Motoras	174

Lista de Figuras

1.1	Estruturas neurais necessárias à produção dos movimentos normais (modificado de [1]).	1
1.2	A decomposição do sinal EMG é o processo utilizado para identificar os potenciais de ação das unidades motoras (MUAPs) em um sinal EMG (modificado de [2]).	3
1.3	Exemplo de um sinal EMG que representa um distúrbio miopático: MUAPs de baixas amplitudes e de curta duração [3].	4
1.4	Exemplo de um sinal EMG que representa um distúrbio neuropático: MUAPs de altas amplitudes e de longa duração [3].	4
2.1	Ilustração esquemática das diferentes estruturas e sub-estruturas de um músculo [4].	14
2.2	Organização estrutural dos filamentos de actina e miosina (modificado de [5]).	15
2.3	Estados relaxado e contraído de uma miofibrila, mostrando o deslizamento dos filamentos de actina (em preto) para o interior dos espaços existentes entre os filamentos de miosina (em vermelho) [6].	15
2.4	Composição estrutural dos músculos [5].	16
2.5	Representação de uma Unidade Motora [5].	17
2.6	Detalhe esquemático da junção neuromuscular mostrando uma terminação do neurônio motor e a membrana da célula muscular [4].	18
2.7	(Superior) : Desenho esquemático de um potencial de ação de uma fibra muscular isolada. (Inferior) : Propagação do potencial de ação ao longo da fibra muscular [4].	19
2.8	Recrutamento progressivo de Unidades Motoras (modificado de [5]).	19
2.9	Exemplo de eletrodos invasivos [7].	21
2.10	Exemplo de eletrodos ativos para a detecção de sinal EMG de superfície [7].	22

2.11	Exemplo de eletrodos passivos para a detecção de sinal EMG de superfície [7].	22
2.12	Exemplo do posicionamento correto de eletrodos EMG de superfície: paralela- mente às fibras (modificado de [8]).	23
2.13	Estágios necessários para o processo de decomposição do sinal EMG (modificado de [5]).	26
3.1	Exemplo de uma Cadeia de Markov com 3 estados, onde $p(q_t = a q_{t-1} = b)$ representa a probabilidade de transição do estado b (no tempo t-1) para o estado a (no tempo t) [9].	32
3.2	Exemplo de um Modelo Oculto de Markov com três estados (x_i), quatro símbolos (y_k), probabilidade de transição entre os estados (a_{ij}) e probabilidade de emissão de símbolos (b_{ij}). A seqüência de estados (x_i) representa o processo oculto do Modelo de Markov, que gera a seqüência de observações (y_k) [10].	34
3.3	Exemplo de um Modelo Oculto de Markov com a topologia ergódico, com 3 estados (A, B e C). Neste MOM, existe probabilidade de transição entre todos os estados [11].	43
3.4	Exemplo de um MOM esquerdo-direito, com 3 estados [11].	44
3.5	Exemplo de um MOM com misturas Gaussianas na saída [9].	45
4.1	Estágios básicos da implementação de um Algoritmo Genético.	49
4.2	Exemplo de cruzamento simples em Algoritmos Genéticos (modificado de [12]).	51
4.3	Exemplo de cruzamento múltiplo em Algoritmos Genéticos (modificado de [12]).	52
4.4	Exemplo de cruzamento uniforme em Algoritmos Genéticos (modificado de [12]).	52
4.5	Exemplo de mutação em Algoritmos Genéticos (modificado de [12]).	53
4.6	Evolução Diferencial: exemplo de um processo de cruzamento para $D = 4$ (mo- dificado de [13]).	56
6.1	Diagrama de blocos da estrutura do sistema híbrido de decomposição de sinais EMG.	76
6.2	Diagrama de blocos das etapas de pré-processamento do sinal EMG realizadas pelo sistema EMG Decomposition BR®.	76
6.3	Etapas do processo de agrupamento de MUAPs realizadas pelo sistema de de- composição de sinais EMG de superfície utilizando Modelo Oculto de Markov.	78
6.4	Padrões de formas de onda utilizados na validação de modelos dinâmicos [14].	79

6.5	Exemplo de um sinal dinâmico [14].	80
6.6	Exemplo de um sinal dinâmico segmentado (linhas vermelhas) em T segmentos (Modificado de [14]).	81
6.7	Exemplo de um MUAP segmentado (linhas vermelhas) e com o_t representando o vetor de características de cada segmento.	83
6.8	Exemplo de um MUAP representado pela topologia esquerda-direita de um Modelo Oculto de Markov com T estados, sendo que cada estado S representa um segmento t.	85
6.9	Algoritmo utilizado para gerar a Matriz de Dissimilaridade entre os MUAPs, utilizando os modelos λ 's gerados e as observações O extraídas dos MUAPs. . .	86
6.10	Exemplo de classificação dos MUAPs existentes no sinal EMG, em sua respectiva Unidade Motora geradora, após a execução do sistema proposto para decomposição de sinais EMG de superfície.	88
6.11	Definição das regiões de pontos que serão avaliados pelo MOM, de acordo com a distância mínima (d_{min}^b) e máxima (d_{max}^b)	91
6.12	Mapa de pontos em R^2 utilizados para representar os parâmetros A e B do MOM, que foram utilizados para avaliar a variação da verossimilhança do modelo. Estes pontos são separados em regiões de acordo com a sua Distância Euclidiana em relação ao ponto central (x=500, y=500), escolhido empiricamente.	92
6.13	Resultado da simulação 1 com o MOM. (a): O erro médio entre as matrizes A_{otimo} e $A_{Estimativa}$ de acordo com a distância entre as matrizes A_{otimo} e $A_{Vizinho}$. As linhas verticais (em azul) representam a variância de cada erro médio. (b): A média da verossimilhança de acordo com a distância entre as matrizes A_{otimo} e $A_{Estimativa}$. As linhas verticais (em azul) representam a variância de cada verossimilhança.	95
6.14	Resultado da simulação 1 com o MOM -(a): O erro médio entre as matrizes B_{otimo} e $B_{Estimativa}$ de acordo com a distância entre as matrizes B_{otimo} e $B_{Estimativa}$. As linhas verticais (em azul) representam a variância de cada erro médio. (b) A média da verossimilhança de acordo com a distância entre as matrizes B_{otimo} e $B_{Estimativa}$. As linhas verticais (em azul) representam a variância de cada verossimilhança.	96

6.15	Resultado da simulação 3 com o MOM - (a) : O erro médio entre as matrizes A_{otimo} e $A_{Estimativa}$ de acordo com a distância entre as matrizes A_{otimo} e $A_{Vizinho}$; (b) : O erro médio entre as matrizes B_{otimo} e $B_{Estimativa}$ de acordo com a distância entre as matrizes B_{otimo} e $B_{Vizinho}$. As linhas verticais (em azul) representam a variância de cada erro médio. As linhas verticais (em azul) representam a variância de cada erro médio.	97
6.16	A média da verossimilhança de acordo com a distância entre as matrizes A_{otimo} e $A_{Vizinho}$, e B_{otimo} e $B_{Estimativa}$. As linhas verticais (em azul) representam a variância de cada verossimilhança.	98
6.17	Gráfico 3D de uma função de Rastringing.	100
6.18	Resultado da minimização da função Rastringing utilizando o algoritmo ED (a) Distribuição inicial da população antes da execução do algoritmo ED. (b) Distribuição final da população, após executar o algoritmo ED. As setas indicam a solução ótima (mínimo global), a distribuição inicial e final da população. . .	102
6.19	Estimativa da quantidade média de membros da população que, após 1000 simulações, alcançaram as vizinhanças próximas ao mínimo global, utilizando o algoritmo ED para minimização da função de Rastringing.	103
6.20	Resultado da maximização da função Rastring utilizando o algoritmo ED (a) Distribuição inicial da população. (b) Distribuição final da população, após executar o algoritmo ED. As setas indicam os máximos globais (soluções ótimas), a distribuição inicial e final da população.	103
6.21	Estimativa da quantidade média de membros da população que, após 1000 simulações, alcançaram as vizinhanças próximas ao máximo global, utilizando o algoritmo ED para maximização da função de Rastringing.	104
6.22	Minimização: estágio de seleção probabilística do algoritmo EDSP.	105
6.23	Maximização: estágio de seleção probabilística do algoritmo EDSP.	106
6.24	Resultado da minimização da função de Rastringing utilizando o algoritmo EDSP: (a) Distribuição inicial da população. (b) Distribuição final da população, após a execução do algoritmo EDSP. As setas indicam o mínimo global (solução ótima), a distribuição inicial e final da população.	107

6.25	Estimativa da quantidade média de membros da população que, após 1000 simulações, alcançaram as vizinhanças próximas ao mínimo global, utilizando o algoritmo EDSP para minimização da função de Rastringing.	107
6.26	Comparação entre os resultados dos algoritmos ED e EDSP na minimização da função de Rastring: quantidade média de membros da população que atingiram a vizinhança mais próxima à solução ótima (99% de proximidade), em cada iteração.	108
6.27	- Resultado do algoritmo EDSP para a maximização da função de Rastring: (a) Distribuição inicial da população. (b) Distribuição final da população, após executar o algoritmo EDSP. As setas indicam a solução ótima (máximo global), a distribuição inicial e final da população.	108
6.28	Estimativa da quantidade média de membros da população que, após 1000 simulações, alcançaram as vizinhanças próximas ao mínimo global, utilizando o algoritmo EDSP para a maximização da função de Rastring.	109
6.29	Comparação entre os resultados dos algoritmos ED e EDSP na maximização da função de Rastring: quantidade média de membros da população que atingiram a vizinhança mais próxima à solução ótima (99% de proximidade), em cada iteração.	109
6.30	Média da verossimilhança de um MOM para um conjunto de dados utilizando seis estratégias distintas para estimar os parâmetros A e B . No caso do algoritmo EDSP, as matrizes A e B foram selecionadas considerando o melhor membro da população. As barras horizontais representam os limites superior e inferior do intervalo de confiança da média.	113
6.31	Média da verossimilhança de um MOM com 5 estados e 4 símbolos para um conjunto de dados utilizando seis estratégias distintas para estimar os parâmetros A e B . Para algoritmo EDSP, as matrizes A e B foram selecionadas considerando o melhor membro da população. As barras horizontais são os limites superior e inferior do intervalo de confiança da média.	114
6.32	Representação das regiões (sombreado) de maior similaridade entre MUAPs gerados por uma mesma Unidade Motora [15].	116

6.33	Agrupamento de um conjunto de 76 MUAPs utilizando o algoritmo EDSP. Distribuição inicial da população: apresenta os 76 MUAPs antes do início da otimização (a linha vermelha representa a média de todos os MUAPs; Distribuição final da população: apresenta a convergência de todos os MUAPs para um único padrão, após a execução do EDSP.	118
6.34	Quatro diferentes padrões de MUAPs que serão utilizados para a validação de grupos de MUAPs utilizando o algoritmo Evolução Diferencial.	119
6.35	Agrupamento de um conjunto de quatro padrões de MUAPs utilizando o algoritmo EDSP. Distribuição inicial da população: apresenta os 163 MUAPs antes do início da otimização (as linhas coloridas representam a média de cada um dos cinco padrões de MUAPs; Distribuição final da população: apresenta a convergência de todos os membros da população para um dos quatro padrões existentes.	119
7.1	Exemplo de utilização do Simulador de Sinais EMG sintéticos, desenvolvido por [5].	124
7.2	a) Posicionamento do músculo Interósseo Dorsal I; b) Posicionamento dos eletrodos de superfície, invasivo e de referência - modificado de [5].	125
7.3	Representação do array de eletrodos utilizado na coleta dos sinais EMG de [5]. .	125
7.4	Sinal EMG sintético com 3 Unidade Motoras ativas. Neste sinal EMG existem 3 padrões de MUAP distintos, e cada um deles representa o padrão morfológico gerado por uma Unidade Motora ativa.	127
7.5	Teste 1: MUAPs detectados no sinal EMG, delimitados pelas linhas tracejadas e contínuas verticais.	127
7.6	Grupos de MUAPs detectados na etapa de agrupamento do projeto proposto: (a) Grupo de MUAPs com padrão morfológico do tipo 1; (b) Grupo MUAPs com padrão morfológico do tipo 2; (c) Grupo de MUAPs com padrão morfológico do tipo 3.	128
7.7	Avaliação da qualidade do grupo 1 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.	129
7.8	Avaliação da qualidade do grupo 2 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.	130
7.9	Avaliação da qualidade do grupo 3 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.	130

7.10	Resultado do sistema proposto: seqüência de disparos das Unidades Motoras. . .	131
7.11	Sinal EMG sintético com 5 Unidade Motoras ativas.	133
7.12	Teste 2: MUAPs detectados no sinal EMG sintético, delimitados pelas linhas tracejadas e contínuas verticais.	134
7.13	Grupos de MUAPs detectados na etapa de agrupamento do projeto proposto: (a) Grupo de MUAPs com padrão morforológico do tipo 1; (b) Grupo de MUAPs com padrão morforológico do tipo 2; (c) Grupo de MUAPs com padrão morforológico do tipo 3; (d) Grupo de MUAPs com padrão morforológico do tipo 4; (e) Grupo de MUAPs com padrão morforológico do tipo 5.	135
7.14	Avaliação da qualidade do grupo 1 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.	136
7.15	Avaliação da qualidade do grupo 2 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.	136
7.16	Avaliação da qualidade do grupo 3 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.	137
7.17	Avaliação da qualidade do grupo 4 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.	137
7.18	Avaliação da qualidade do grupo 5 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.	138
7.19	Resultado do sistema proposto: seqüência de disparos das Unidades Motoras. . .	138
B.1	Representação do array de eletrodos utilizado na coleta dos sinais EMG de [5]. .	170
B.2	A marca preta indica a localização do músculo Interósseo Dorsal I [5].	170
B.3	Exemplo mostrando o posicionamento dos eletrodos de agulha e de superfície no músculo Interósseo Dorsal I [5].	171
B.4	Exemplo de abdução do dedo indicador para ativar o músculo Interósseo Dorsal I [5].	172
B.5	Interface gráfica do software de Biofeedback. Durante os experimentos, o objetivo do voluntário era controlar o movimento do peixe laranja, de acordo com a força utilizada no movimento de abdução do dedo indicador [5].	173

B.6	Principais componentes da unidade de aquisição de dados: A) Plataforma de força; B) Laptop com placa de aquisição; C) Software de Biofeedback; D) Osciloscópio digital; E) Amplificador EMG; F) Amplificador da plataforma de força [5].	173
C.1	Etapa pós-agrupamento de MUAPs: MOM para estimar a seqüência de disparo das Unidades Motoras.	174
C.2	Exemplo de classificação dos MUAPs existentes no sinal EMG, após a execução do estágio de Agrupamento.	175
C.3	Exemplo de topologica ergódica, representando a transição de disparo entre as Unidade Motoras (estados do Modelo Oculto de Markov). As observações O representam a geração de um determinado padrão de MUAP pela Unidade Motora.	177
C.4	Sinal EMG sintético com 3 Unidade Motoras ativas.	178
C.5	MUAPs detectados no sinal EMG, delimitados pelas linhas tracejadas verticais.	178
C.6	Determinação da seqüência de disparos das Unidades Motoras.	179
C.7	Avaliação da qualidade do grupo 1 de MUAPs utilizando o algoritmo EDSP. . .	179
C.8	Avaliação da qualidade do grupo 2 de MUAPs utilizando o algoritmo EDSP. . .	180
C.9	Avaliação da qualidade do grupo 3 de MUAPs utilizando o algoritmo EDSP. . .	180
C.10	Predição da seqüência de disparo das Unidades Motoras.	181
C.11	Distribuição da freqüência dos disparo das Unidades Motoras: sinal EMG sintético analisado e estimativa da sequencia de disparos das Unidades Motoras geradas pelo MOM.	181
C.12	Distribuição da freqüência de disparo das Unidades motoras:sinal EMG e média de 1000 seqüências geradas pelo Modelo Oculto de Markov discreto.	182
C.13	Média da distribuição da freqüência de disparo das Unidades motoras de 1000 seqüências geradas pelo Modelo Oculto de Markov Discreto. As linhas verticais indicam o erro calculado em relação ao desvio padrão da média.	183
C.14	Média da distribuição da freqüência de disparo das Unidades motoras de 1000 seqüências geradas pelo Modelo Oculto de Markov discreto. As linhas horizontais delimitam o intervalo de confiança de cada média.	184
C.15	Probabilidade disparo das Unidades Motoras.	185

Lista de Tabelas

5.1	Formulação matemática utilizada para a otimização das medidas de avaliação de particionamento de grafos.	69
6.1	Convergência dos MUAPs após a execução do EDSP.	120
7.1	Resumo do resultado do sistema proposto após a aplicação de sinais EMG reais.	141

Capítulo 1

Introdução

Falar, andar, dirigir, escrever, são exemplos de algumas ações executadas pelo sistema neuromotor do corpo humano. O movimento é orquestrado pela ação coordenada das regiões periférica, medular, tronco encefálico/cerebelar e cerebral [1]. O controle normal do movimento exige a ativação das seguintes estruturas neurais: áreas de planejamento motor, circuitos de controle, vias descendentes, conexões da região medular e motoneurônios inferiores (Figura 1.1).

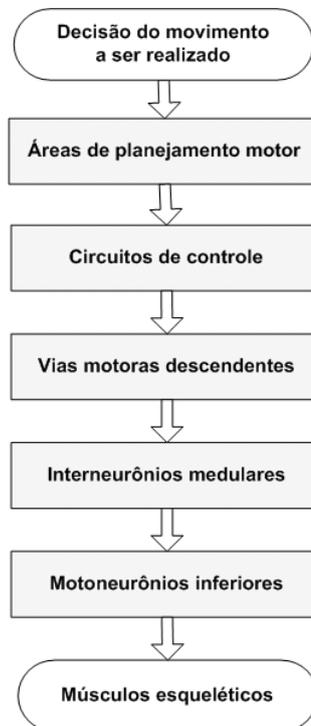


Figura 1.1: Estruturas neurais necessárias à produção dos movimentos normais (modificado de [1]).

Para controlar um simples ato motor, o Sistema Nervoso inicia as suas atividades no lobo frontal, nas áreas de planejamento motor. Em seguida, são ativados os circuitos de controle, os quais são formados pelo cerebelo e pelos núcleos da base. Estes têm a função de regular a atividade das vias motoras descendentes, as quais, por sua vez, levam sinais para os interneurônios medulares e para os motoneurônios inferiores. Os motoneurônios inferiores transmitem sinais diretamente para os músculos esqueléticos, produzindo a contração das fibras musculares apropriadas para o movimento desejado.

Os distúrbios do sistema neuromotor incluem anormalidades nos seguintes aspectos do corpo humano [1] [16] [17]:

- **Força muscular**

Exemplos: paresia, paralisia e hemiplegia;

- **Massa muscular**

Exemplos: atrofia de desuso e atrofia neurogênica;

- **Contração muscular:**

Exemplos: espasmos musculares, fasciculações e fibrilações;

- **Tônus muscular**

Exemplos: hipotonia e hipertonia;

- **Reflexos**

Exemplos: perda de reflexo ou reflexos anormais;

- **Eficiência, velocidade dos movimentos e controle postural**

Exemplos: tremor e sequenciamento anormal da ativação muscular.

Esses distúrbios do sistema neuromotor podem ser observados ou terem o diagnóstico auxiliado por meio da análise do sinal eletromiográfico (EMG). O sinal EMG é a manifestação de ativação neuromuscular associada à uma contração muscular.

A cada ano, mais pessoas têm sofrido distúrbios motores, o que dificulta que elas executem normalmente as suas atividades diárias [18]. Nesse contexto, um estudo sobre ferramentas e métodos que possam extrair características relativas à dinâmica de funcionamento da fibra muscular é de extrema relevância para a detecção e/ou tratamento de anormalidades do sistema neuromotor, pois, dessa forma, estas ferramentas auxiliariam o diagnóstico de distúrbios motores.

1.1 Motivação

A detecção e a análise dos sinais fisiológicos provenientes do sistema neuromotor têm estado presente em diversos estudos, desde a ciência básica aos diagnósticos clínicos [19] [20]. A eletromiografia é um método analítico para o estudo da fisiologia, biomecânica e conceitos básicos do sistema neuromotor do corpo humano [21]. Entender o sinal eletromiográfico (EMG) implica no entendimento do funcionamento dos músculos e da forma como são gerados os sinais bioelétricos [20] [22].

O sinal EMG é proveniente do somatório dos diversos potenciais de ação de unidades motoras (Motor Unit Action Potential - MUAP) que percorrem as fibras musculares, levando à contração do músculo [1] (Figura 1.2). Desta forma, a decomposição do sinal eletromiográfico tem como resultado o conjunto dos diversos MUAPs que o compõem [23] [24].

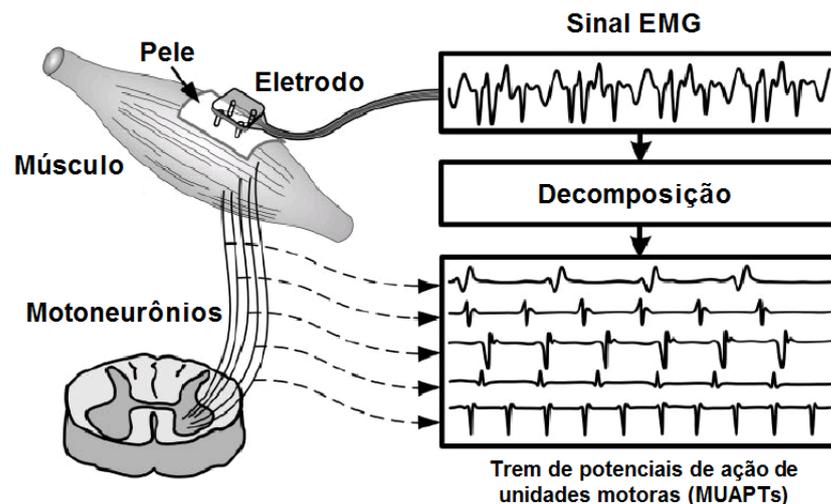


Figura 1.2: A decomposição do sinal EMG é o processo utilizado para identificar os potenciais de ação das unidades motoras (MUAPs) em um sinal EMG (modificado de [2]).

O estudo da eletromiografia tem sido cada vez mais utilizado na prática clínica, permitindo aos neurofisiologistas avaliar o estado do músculo através das informações provenientes das unidades básicas que compõem o sinal eletromiográfico, isto é, através dos potenciais de ação das unidades motoras (MUAPs) [25] [26].

As informações relacionadas aos MUAPs, tais como morfologia, duração, taxa de ocorrência e tempo de disparo, são muito utilizadas para o diagnóstico de distúrbios neuromusculares [5] [27]. E ainda, a morfologia dos MUAPs contém informações a respeito

da anatomia e da saúde das fibras musculares [2].

A análise dos MUAPs auxilia o profissional a avaliar se existe algum distúrbio motor e qual é a sua origem: a) lesão no axônio do neurônio motor (neuropatia); b) lesão da fibra muscular ou atrofia (miopatia) [28] [29] [30] [16]. Os MUAPs de um sinal EMG que representa um distúrbio miopático geralmente apresentam curta duração e baixa amplitude (Figura 1.3). Já os MUAPs que apresentam altas amplitudes e duração maior, caracterizam distúrbios neuropáticos (Figura 1.4).

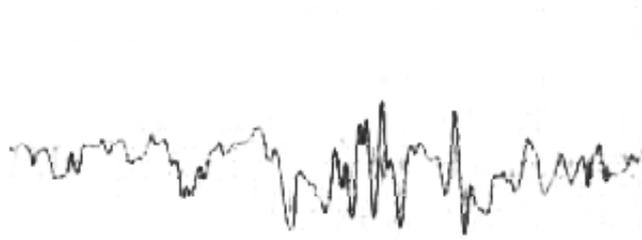


Figura 1.3: Exemplo de um sinal EMG que representa um distúrbio miopático: MUAPs de baixas amplitudes e de curta duração [3].

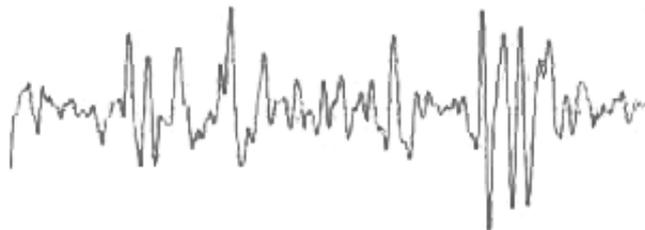


Figura 1.4: Exemplo de um sinal EMG que representa um distúrbio neuropático: MUAPs de altas amplitudes e de longa duração [3].

Em diversos casos, também é interessante utilizar as informações relativas ao tempo de disparo dos MUAPs para entender como o Sistema Nervoso Central (SNC) controla a geração da força muscular e para avaliar a profundidade de uma lesão no motoneurônio, tal como a paralisia cerebral, doença de Parkinson, Acidente Vascular Cerebral e outros [31].

Não obstante, entender o comportamento normal ou anormal do controle das Unidades Motoras é fundamental na decisão da necessidade de uma intervenção cirúrgica, farmacológica ou baseada em exercícios. E ainda, outra importante aplicação da decomposição

de sinais EMG é na área de envelhecimento e ergonomia, onde é interessante entender quando o controle motor é alterado como consequência do envelhecimento, exercícios, fadiga ou produção de força excessiva e prolongada [32].

1.2 Definição do problema

Conforme detalhado na seção anterior, a partir do sinal EMG é possível extrair informações provenientes dos potenciais de ação das Unidades Motoras (MUAPs). Para que seja possível a extração de tais informações, é necessário decompor o sinal eletromiográfico nos diversos potenciais de ação de unidades motoras que o compõem.

Para realizar a decomposição de sinais eletromiográficos, diversos procedimentos e técnicas computacionais têm sido desenvolvidos [33] [34] [35] [25] [21] [5] [20]. Tais técnicas classificam os MUAPs gerados por uma determinada fonte (Unidade Motora) em um único grupo; e esta classificação auxilia o profissional na avaliação da morfologia dos MUAPs e da frequência de disparo das Unidades Motoras. [5] [21].

Entretanto, o processo de decomposição de um sinal EMG é uma tarefa complexa. As características de um sinal EMG dependem do tipo de eletrodo utilizado (intramuscular ou de superfície), do seu posicionamento em relação ao músculo, o nível de contração e o estado clínico do Sistema Neuromuscular do paciente [31].

O sinal EMG coletado por meio de eletrodos de agulha (intramuscular) possui a grande vantagem de refletir somente a atividade do músculo analisado, isto é, somente a atividade do músculo em que o eletrodo de agulha foi inserido, sem sofrer a interferência dos sinais dos músculos que estão próximos (fenômeno *cross-talk*). E também, a remoção dos possíveis artefatos mecânicos presentes no sinal coletado por eletrodos intramusculares podem ser facilmente filtrados, visto que os artefatos e o sinal EMG coletado possuem frequências distintas [36].

Devido aos benefícios do sinal coletado por meio de eletrodos intramusculares, a maior parte das pesquisas e desenvolvimento de sistemas para decomposição de sinais EMG é aplicável somente para a eletromiografia de agulha [32]. Entretanto, esse tipo de coleta do sinal eletromiográfico possui alguns inconvenientes/limitações [2]:

- O eletrodo de agulha deve ser inserido dentro do músculo, e isto requer uma minuciosa preparação clínica, envolvendo a esterilização do sensor e do ambiente onde

a coleta do sinal EMG será realizada;

- Existe o risco, mesmo que mínimo, de transmissão de doenças e infecções;
- Este procedimento pode não ser suportado por crianças e por indivíduos com aversão a agulhas ou com grande sensibilidade à dor;
- Uma vez que o eletrodo de agulha foi inserido no músculo, o paciente deve permanecer parado (estático). Um pequeno movimento de 0.1 mm pode causar uma mudança no formato da MUAP, o que dificultaria o processo de identificação dos MUAPs provenientes do processo de contração muscular;
- O procedimento de inserção do eletrodo de agulha pode ser dificultado nos casos de avaliação de regiões muito sensíveis, tais como lábios, língua, músculos faciais, entre outros.

E ainda, é importante ressaltar que este cenário muitas vezes é inconveniente para o paciente, e até mesmo impraticável em exames clínicos devido ao desconforto e à dor sofrida pelo paciente. Em terapias de biofeedback eletromiográfico com a finalidade de reabilitação muscular, a utilização da eletromiografia de agulha é praticamente inviável, considerando que o paciente está em fase de reabilitação muscular, necessitando realizar movimentos para esta finalidade e a dor provocada pelos eletrodos de agulha dificultaria e/ou inviabilizaria os movimentos do paciente e, conseqüentemente, anularia as chances de sucesso da terapia de Biofeedback.

Neste contexto, algumas pesquisas já foram iniciadas para estudar a decomposição de sinais EMG coletados por meio de eletrodos de superfície, visando contornar os inconvenientes descritos anteriormente. Entretanto, apesar dos interessantes resultados já alcançados, as pesquisas são recentes e ainda estão no estágio inicial de desenvolvimento [2]. Dessa forma, é real a necessidade de investigação de técnicas para decomposição de sinais EMG coletados por meio de eletrodos de superfície, e assim contribuir com a proposta de um novo caminho para as pesquisas na área da eletromiografia de superfície.

Como forma de buscar e investigar possíveis técnicas para a decomposição de sinais EMG coletados por meio de eletrodos de superfície é necessário averiguar as técnicas que já foram aplicadas no processamento dos demais sinais biológicos coletados por meio de eletrodos de superfície, como por exemplo o sinal eletroencefalográfico. Durante os últimos

anos, alguns pesquisadores concentraram esforços em pesquisas de processamento de sinais eletroencefalográficos, coletados através de eletrodos de superfície, utilizando modelos gráfico-probabilísticos [37] [38] [39]. Estes autores alcançaram resultados satisfatórios no que tange à classificação e estimação dos disparos dos *spikes* do sinal eletroencefalográfico. Os modelos gráfico-probabilísticos têm como característica principal a utilização de sólidos princípios probabilísticos, ao invés de conjunto de regras pré-definidas. Dessa forma, com base em probabilidades, é possível gerar, através do modelo gráfico, conjuntos de seqüências que representam as características do sinal que está modelado [40] [41] [42] [43].

Tomando como inspiração os modelos gráficos-probabilísticos utilizados nas pesquisas em sinais eletroencefalográficos de superfície das últimas décadas e, ainda, considerando os profícuos resultados apresentados pelos autores daquelas pesquisas, os modelos gráfico-probabilísticos podem ser uma técnica interessante para processar sinais eletromiográficos de superfície. A utilização de modelos gráficos-probabilísticos pode ser um novo caminho para implementar um sistema de decomposição de sinais EMG de superfície, capaz de classificar os MUAPs e calcular a probabilidade de disparo das Unidades Motoras em um determinado momento. De posse de uma ferramenta que utilize modelos probabilísticos para classificação de MUAPs, será possível, também, realizar a estimativa da dinâmica do disparo das Unidades Motoras que compõe o sinal EMG. Uma técnica com este recurso é muito importante como auxílio na avaliação do mecanismo de funcionamento do Sistema Neuromuscular e muito necessário para as terapias de Biofeedback com foco na reabilitação muscular.

Desta forma, o que se propõe neste trabalho é a utilização de um modelo gráfico-probabilístico no processo de decomposição de um sinal EMG de superfície. Para atingir esta meta, três técnicas foram utilizadas:

- **Modelo gráfico-probabilístico:**

Para realizar a classificação de MUAPs será utilizado o modelo gráfico-probabilístico Modelo Oculto de Markov;

- **Agrupamento Espectral:**

A técnica Agrupamento Espectral, em conjunto com o Modelo Oculto de Markov, será a responsável pela determinação da quantidade de Unidades Motoras ativas no sinal EMG e a realização do agrupamento não-supervisionado de MUAPs;

- **Evolução Diferencial:**

A técnica Evolução Diferencial será a responsável pela otimização dos parâmetros do Modelo Oculto de Markov e pela avaliação da qualidade dos grupos de MUAPs detectados pelo Agrupamento Espectral.

1.3 Objetivo

Para contribuir com os avanços das pesquisas e apresentar uma nova direção que visa aprimorar as técnicas para a decomposição do sinal eletromiográfico de superfície, o presente trabalho pretende avaliar a seguinte hipótese:

É possível desenvolver uma técnica de decomposição de sinal eletromiográfico de superfície utilizando um modelo gráfico-probabilístico?

Para avaliar a hipótese acima, este trabalho deverá atingir os seguintes objetivos específicos:

- Determinar a quantidade de Unidades Motoras presentes no sinal EMG de superfície;
- Classificar cada potencial de ação de unidade motora (MUAP) que compõe um sinal EMG em sua respectiva Unidade Motora geradora;
- Apresentar o padrão morfológico do MUAP gerado por cada Unidade Motora ativa no sinal EMG de superfície.

1.4 Contribuições da tese

No âmbito das pesquisas na área de Engenharia biomédica, mais especificamente na área de decomposição de sinais eletromiográficos de superfície, é importante destacar que a utilização de modelos gráficos-probabilísticos, implementados com a técnica Modelo Oculto de Markov, na área de processamento de sinais EMG de superfície, com o objetivo de avaliar o funcionamento do Sistema Neuromuscular, ainda não foi alvo de pesquisas anteriores. Neste contexto, esta tese apresenta as seguintes contribuições para a comunidade científica:

1. Projeto e desenvolvimento de um método, utilizando Modelo Oculto de Markov, para compor o processo de decomposição de sinais eletromiográficos de superfície;
2. Projeto e desenvolvimento de uma ferramenta para a avaliação do funcionamento do Sistema Neuromuscular, utilizando Modelos Ocultos de Markov.

Além disso, esta tese também apresenta as seguintes contribuições científicas:

1. Investigação sobre a aplicação da técnica Modelo Oculto de Markov no processo de decomposição de sinais eletromiográficos;
2. Investigação sobre a aplicação do algoritmo Agrupamento Espectral para determinar a quantidade de Unidades Motoras ativas em um sinal EMG e realizar o agrupamento de MUAPs;
3. Investigação sobre a aplicação da técnica Modelo Oculto de Markov no processo de agrupamento de MUAPs;
4. Investigação sobre a utilização da técnica Modelo Oculto de Markov no processo de estimativa da seqüência dos disparos das Unidades Motoras;
5. Investigação sobre a utilização da técnica Modelo Oculto de Markov para determinar a probabilidade de disparo de uma Unidade Motora em um determinado tempo;
6. Investigação sobre a aplicação da técnica Evolução Diferencial para a avaliação da coesão de grupos de MUAPs;
7. Investigação sobre a utilização da técnica Evolução Diferencial para a otimização dos parâmetros do Modelo Oculto de Markov.

1.5 Estrutura do trabalho

Além deste capítulo introdutório, que apresenta a motivação e o objetivo desta pesquisa, as estratégias utilizadas para atingir as metas propostas serão detalhadas nos demais capítulos deste trabalho. Estruturalmente, o texto está dividido da seguinte forma:

- **Capítulo 2**

Apresenta uma breve revisão sobre eletromiografia e decomposição de sinal eletromiográfico, bem como algumas técnicas desenvolvidas para a decomposição de sinais eletromiográficos;

- **Capítulo 3**

Será apresentado o conceito de Modelos Ocultos de Markov e o seu funcionamento;

- **Capítulo 4**

Neste capítulo será apresentada a técnica Evolução Diferencial e a sua base teórica;

- **Capítulo 5**

Neste capítulo será apresentada a técnica Agrupamento Espectral e os seus fundamentos teóricos;

- **Capítulo 6**

Este capítulo apresenta a proposta de um modelo de decomposição de sinais EMG de superfície utilizando Modelos Ocultos de Markov e os detalhes das implementações que foram necessárias para o desenvolvimento deste projeto;

- **Capítulo 7**

Serão apresentados os resultados dos testes realizados para o processo de validação do sistema proposto;

- **Capítulo 8**

Este capítulo apresenta as considerações finais dos estudos realizados. E ainda, serão propostos trabalhos/estudos futuros que podem ser realizados a partir desta pesquisa.

- **Anexo A (Publicações)**

Neste anexo serão listados todos os artigos resultantes deste trabalho que foram, até o presente momento, aceitos, publicados ou submetidos em congressos e periódicos (nacionais e internacionais).

- **Anexo B (Protocolo de aquisição de sinais EMG)**

Será apresentado o protocolo utilizado para a captação dos sinais EMG de superfície,

que compõem o Banco de Dados que será utilizado nesta pesquisa para a validação do sistema proposto.

- **Anexo C (Estimativa da Seqüência de Disparos das Unidades Motoras)**

Finalmente, será apresentada uma proposta de trabalho futuro que pode ser realizado a partir do presente trabalho. Será detalhada a arquitetura de um sistema, baseado em Modelo Oculto de Markov para estimar a seqüência de disparo das Unidades Motoras e calcular a probabilidade de disparo de cada uma delas em um determinado instante de tempo.

Capítulo 2

O Sinal Eletromiográfico

2.1 Introdução

O desenvolvimento da eletromiografia teve o seu primeiro marco por volta do ano de 1600, quando Francesco Redi documentou que um músculo era a fonte de energia do peixe elétrico. Em meados de 1670, Galvani descobriu uma evidência que relacionava a contração muscular e a eletricidade. Em 1810, Wallaston [44] verificou que durante a contração muscular, a energia do músculo gerava um som em uma frequência audível. Já em 1920, os sinais EMG foram apresentados pela primeira vez em um osciloscópio [45].

Em 1973, Basmajian [22] [46] desenvolveu novos sensores para a detecção do sinal EMG e divulgou estudos sobre a aplicação do sinal EMG em ferramentas para terapias de Biofeedback. Em 1985, De Luca [8] publicou um estudo sobre a aquisição e o condicionamento de sinais EMG. Em 1998, Cram et al. [47] [45] apresentaram um atlas que apresenta o posicionamento de eletrodos de superfície em diversos músculos.

A aplicação da eletromiografia na prática clínica começou a ser difundido através da divulgação das pesquisas de [48] [49] [50] [51] [52] [53]. Neste campo de atuação, os estudos de Merletti et al. [54] mostraram a potencial utilização de informações úteis a respeito da anatomia e fisiologia do músculo, bem como da estratégia de controle do Sistema Nervoso Central. Após alguns estudos, os pesquisadores [48] [26] [55] verificaram que a eletromiografia de superfície (Surface EMG - SEMG), para a utilização na prática clínica, é substancialmente inferior às medições da eletromiografia de agulha (Needle EMG - NEMG) para a avaliação de pacientes com distúrbios neuromusculares, pois a SEMG possui uma resolução espacial limitada, é mais suscetível a artefatos mecânicos e possui

mais tendência a apresentar o fenômeno denominado *cross-talk* entre os músculos adjacentes do que a NEMG.

E ainda, a importância da função muscular durante o controle da marcha é objeto de estudo na área de biomecânica [56] [57] [58], problemas de reabilitação motora e no controle de membros artificiais [59] [60] [61].

O trabalho de pesquisadores pioneiros na área, tais como Basmajian e De Luca, mostraram diversas aplicações dos sinais eletromiográficos e, assim, influenciaram positivamente a comunidade científica. Desde então, diversos pesquisadores têm trabalhado nesta área e contribuído para a evolução dos estudos em eletromiografia.

2.2 Origem do sinal EMG

A análise da atividade dos músculos durante o processo de contração muscular, conhecida como eletromiografia, permite o estudo do funcionamento do Sistema Neuromuscular (SN). O sinal eletromiográfico (EMG) é a medição da atividade muscular, sendo a soma dos potenciais de ação gerados pelas Unidades Motoras [62] [63].

O músculo é um tecido especializado para realizar a contração, produzindo forças mecânicas que tornam possíveis as diversas atividades, tais como a locomoção, manipulação de objetos, propulsão de alimentos através do tubo digestivo etc. Histologicamente, os músculos são classificados em três tipos de tecido muscular: esquelético, liso e cardíaco [6]. Neste trabalho, será abordado somente o músculo esquelético devido ao fato dele ser o responsável pelo processo de geração do sinal eletromiográfico, que é o foco desta pesquisa.

2.2.1 O músculo esquelético

Os músculos esqueléticos são os responsáveis pelos movimentos voluntários [6], os quais são realizados através da contração muscular, que é o resultado da ativação de um determinado número de fibras musculares [64]. Este processo de ativação é acionado através do disparo dos neurônios que recrutam as fibras musculares.

O músculo esquelético é composto por unidades estruturais de tamanho decrescente (Figura 2.1). As células musculares são chamadas de fibras musculares. Sendo assim, o músculo é composto por diversas fibras musculares, que são envolvidas por uma fina

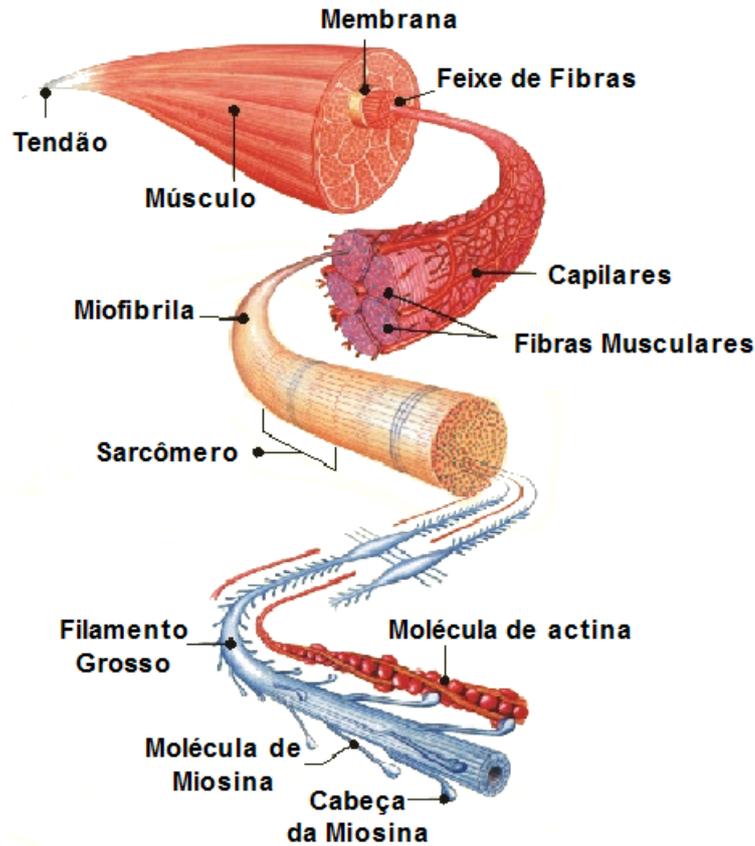


Figura 2.1: Ilustração esquemática das diferentes estruturas e sub-estruturas de um músculo [4].

membrana formada, principalmente, por fibras reticulares, as quais mantêm as fibras individuais juntas dentro do músculo. As fibras do músculo são constituídas de miofibrilas paralelas entre si. O elemento repetido nesse padrão é chamado sarcômero, que é a unidade contrátil básica de um músculo. Os sarcômeros são limitados pelas linhas Z (*Z*wischscheibe ou discos intermediários) e contêm filamentos finos (actina) e grossos (miosina). Estes filamentos são constituídos basicamente de moléculas de proteínas e encontram-se paralelos uns aos outros [4] [5] (Figura 2.2). A actina e a miosina consistem 80% dessas proteínas e são responsáveis pelo encurtamento do músculo.

Os espaços compreendidos entre as linhas Z na Figura 2.2 é chamado de sarcômero. Nos maiores músculos do corpo humano, o seu comprimento chega a ser, no máximo, 2.5 μm . A Figura 2.2 também mostra as bandas que compõem o sarcômero. Na banda I (faixa isotrópica) não existe sobreposição entre os filamentos de actina e miosina, mas na banda A (anisotrópica) estes filamentos são sobrepostos. A banda H contém apenas

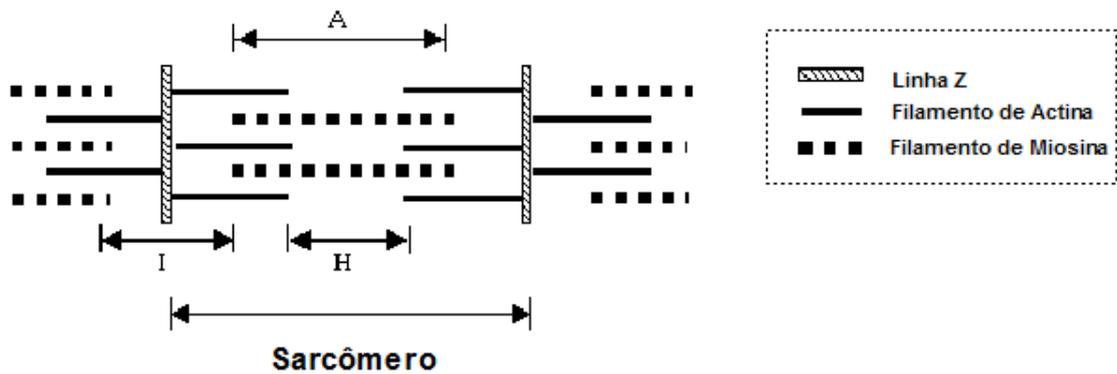


Figura 2.2: Organização estrutural dos filamentos de actina e miosina (modificado de [5]).

filamentos de miosina [5].

Estreitos filamentos de actina, que estão presos na linha Z, deslizam sobre os filamentos de miosina para realizar a contração muscular (Figura 2.3) [5].

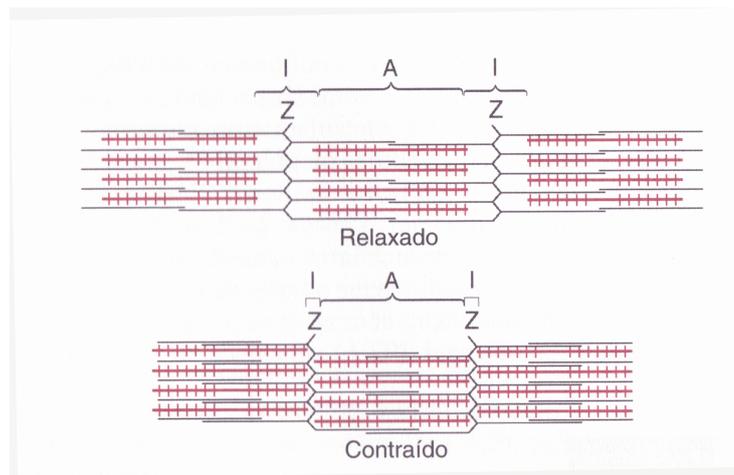


Figura 2.3: Estados relaxado e contraído de uma miofibrila, mostrando o deslizamento dos filamentos de actina (em preto) para o interior dos espaços existentes entre os filamentos de miosina (em vermelho) [6].

Durante os movimentos naturais realizados pelos grupos musculares podem ocorrer três tipos de contração [6] [65]:

- **Isométrica ou estática**

Este tipo de contração não provoca movimento ou deslocamento articular; neste caso o músculo exerce uma força estática. Tem como características baixo consumo

calórico, média duração e a energia utilizada durante esta contração é dissipada na forma de calor. Em virtude disso, apresenta rápido ganho de força;

- **Isotônica ou dinâmica**

Tem como característica o alto consumo calórico e a rápida duração. Divide-se em dois tipos: **Concêntrica** - neste tipo de contração o músculo realiza um movimento com aproximação de suas inserções (encurtamento) e **Excêntrica** - ao realizar o movimento, o músculo alonga-se, ou seja, as inserções se afastam;

E ainda, existe a contração Isocinética, que é um tipo de contração que utiliza um equipamento especial. É diferente da isotônica, pois combina as características da contração isométrica e do treinamento com pesos, a fim de proporcionar uma sobrecarga muscular com uma velocidade constante.

2.2.2 As fibras musculares

Os filamentos de actina e miosina formam, em conjunto, as células musculares chamadas de miofibrilas. Uma fibra muscular é composta por um conjunto de miofibrilas (Figura 2.4).

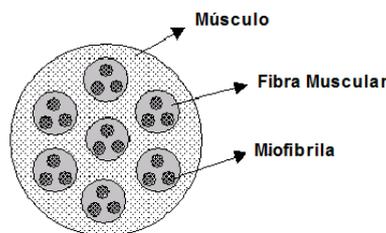


Figura 2.4: Composição estrutural dos músculos [5].

As fibras musculares podem variar consideravelmente de tamanho e de comprimento entre os diversos músculos do corpo humano e, também, podem variar de acordo com o sexo, tipo físico e a idade da pessoa [59] .

As fibras musculares esqueléticas são usualmente classificadas de acordo com suas diferenças estruturais e funcionais em [6]:

- **Fibras de contração lenta**

Também chamadas de fibras de tipo I ou vermelhas, são organizadas para fornecer

resistência à fadiga. Elas permitem força de contração prolongada por muitos minutos ou horas;

- **Fibras de contração rápida**

Também chamadas de fibras de tipo II ou brancas, são organizadas para potência e velocidade para contrações rápidas que necessitam de potência elevada, podendo suportar trabalhos de segundos até um minuto.

2.2.3 A Unidade Motora

O músculo esquelético é organizado em Unidades Motoras, sendo que a Unidade Motora é a menor parte funcional do músculo. Uma Unidade Motora é definida como um conjunto de fibras musculares inervadas pelo mesmo neurônio motor [1] (Figura 2.5).

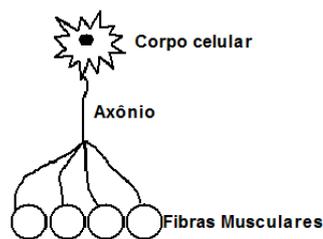


Figura 2.5: Representação de uma Unidade Motora [5].

A quantidade de fibras musculares em uma Unidade Motoras em um músculo humano pode variar de 50 (por exemplo, em um pequeno músculo da mão) até 1000 ou mais, em músculos maiores [20]. Uma pequena Unidade Motora de um pequeno músculo que necessite de um controle extremamente fino pode consistir de poucas fibras musculares. Em contrapartida, uma Unidade Motora de um grande músculo esquelético humano pode conter mais de 2000 fibras musculares [4]. E ainda, considerando que a força de contração, entre outros parâmetros, depende do número de fibras ativadas, uma grande Unidade Motora (que possua um grande número de fibras musculares) pode exercer mais força do que uma pequena Unidade Motora [59].

Os axônios do neurônio motor se ramificam em terminações conforme se aproximam do músculo. Cada terminação termina perto de uma única fibra muscular, na junção neuromuscular, formando uma sinapse entre o nervo e o músculo (Figura 2.6). Quando o axônio do motoneurônio alfa libera o seu neurotransmissor, acetilcolina, esse transmissor

se fixa a receptores na membrana muscular, produzindo despolarização local da membrana da célula muscular. À medida que essa despolarização progride ao longo da membrana da célula muscular, uma série de reações provocam a contração muscular [1].

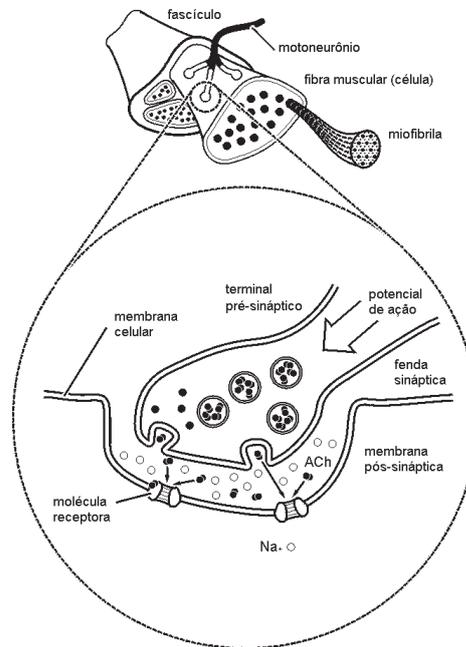


Figura 2.6: Detalhe esquemático da junção neuromuscular mostrando uma terminação do neurônio motor e a membrana da célula muscular [4].

Quando o neurônio motor é estimulado, um potencial de ação percorre o seu axônio chegando a todas as fibras da Unidade Motora, as quais deverão se contrair (Figura 2.7). As características dos potenciais de ação das Unidades Motoras (Motor Unit Action Potentials - MUAPs) são: duração, amplitude, número de fases, área e formato. Estes dados são importantes para comparar um sinal EMG de uma pessoa saudável, doente ou para avaliar a funcionalidade dos músculos [66].

2.2.3.1 Recrutamento de Unidades Motoras

Nas contrações voluntárias, a força é modulada por uma combinação de recrutamento de Unidades Motoras e alterações na frequência de ativação das Unidades Motoras [20]. As Unidades Motoras que são recrutadas, bem como a frequência em que elas são ativadas, dependem, principalmente, da quantidade de força e da velocidade da contração.

Tem sido observado que as Unidades Motoras variam em tamanho e em características contráteis e estas diferenças refletem diretamente em seu padrão durante uma atividade

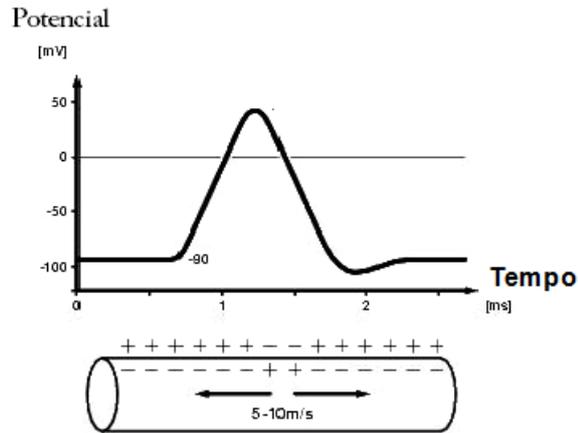


Figura 2.7: (Superior): Desenho esquemático de um potencial de ação de uma fibra muscular isolada. (Inferior): Propagação do potencial de ação ao longo da fibra muscular [4].

normal. De acordo com o aumento da força, mais Unidades Motoras são recrutadas (Figura 2.8) [20].

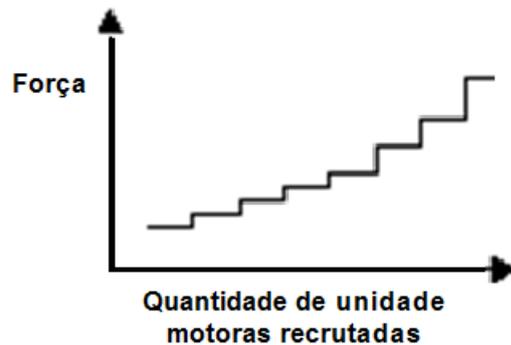


Figura 2.8: Recrutamento progressivo de Unidades Motoras (modificado de [5]).

2.2.4 Composição do sinal eletromiográfico

O conjunto de MUAPs gerados por uma Unidade Motora é chamado de trem de potencial de ação de Unidade Motora (MUAPT) (equação 2.1) [21].

$$MUAPT_j(t) = \sum_{k=1}^j MUAP_{jk}(t - \delta_{jk}) \quad (2.1)$$

Onde :

- $MUAPT_j(t)$ é o MUAPT da j -ésima unidade motora;

- $MUAP_{jk}(t)$ é o MUAP gerado durante a k -ésima ativação da j -ésima Unidade Motora;
- M_j é o número de vezes que a Unidade Motora j foi ativada;
- δ_{jk} é k -ésima ativação da j -ésima Unidade Motora.

Devido às variações biológicas na forma dos MUAPs, cada $MUAPT_j(t)$ será único. De acordo com o aumento da ativação da quantidade de Unidades Motoras, o número de MUAPs em cada MUAPT irá aumentar [21].

Desta forma, a composição de um sinal eletromiográfico (EMG) é o somatório de todos os MUAPs de todas as Unidades Motoras recrutadas, conforme apresentado em (2.2).

$$EMG(t) = \sum_{j=1}^{N_m} MUAPT_j(t) + n(t) \quad (2.2)$$

Onde:

- $MUAPT_j(t)$ é o j -ésimo MUAPT;
- N_m é o número de Unidades Motoras ativadas;
- $n(t)$ é o ruído inerente ao processo de captação dos MUAPs.

Teoricamente, de acordo com (2.2), o sinal EMG é composto pela contribuição de todas as fibras ativas no músculo. Entretanto, as formas dos MUAPs dentro dos MUAPT, que contribuem para o sinal detectado e o número de Unidades Motoras que podem ser consideradas para contribuir em um MUAPT, dependem da configuração dos eletrodos de detecção do sinal e de sua localização em relação as fibras musculares [21] [26] [34].

2.3 Detecção do sinal EMG

A detecção do sinal EMG é realizada através de eletrodos. Existem dois tipos de eletrodos: 1) Eletrodos invasivos ou intramusculares; 2) Eletrodos de superfície. Para músculos grandes e superficiais, geralmente são utilizados eletrodos de superfície. Mas, para músculos pequenos e superficiais ou situados entre ou abaixo de outros músculos, podem ser utilizados os eletrodos invasivos. Entretanto, a escolha de um determinado tipo eletrodo dependerá do músculo e do tipo de estudo que será realizado. A seguir, serão apresentadas as características destes dois tipos de eletrodos [20]:

- **Eletrodos invasivos**

Os eletrodos invasivos podem ser utilizados para a análise de músculos mais profundos. Estes tipos de eletrodos permitem alcançar áreas definidas no músculo e aumentam a probabilidade de detectar o sinal individual de cada Unidade Motora, pois ele utiliza uma agulha ou fio para alcançar o músculo (Figura 2.9). Entretanto, os movimentos da agulha durante o exame podem causar desconforto no paciente, dor causada no momento da inserção do eletrodo, câimbras e dificuldade de repetição do movimento.

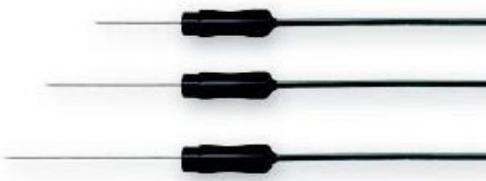


Figura 2.9: Exemplo de eletrodos invasivos [7].

- **Eletrodos de superfície**

Os eletrodos de superfície são não-invasivos e mais fáceis de manusear, pois eles são posicionados na superfície da pele para detectar o sinal EMG. Entretanto, estes eletrodos são mais suscetíveis ao fenômeno de *cross-talk* (detecção de sinais provenientes de outros músculos), o que dificulta a extração de informações do sinal do músculo. Estes eletrodos podem ser ativos ou passivos:

- *Ativos*

Os eletrodos ativos possuem amplificadores diferenciais próximos às superfícies de detecção dos eletrodos. A vantagem deste tipo de configuração é que o movimento do cabo do eletrodo não irá gerar ruídos significativos.

- *Passivos*

Estes eletrodos geralmente são compostos de Ag/AgCl (Figura 2.11). O sinal EMG detectado através de eletrodos passivos são mais suscetíveis aos ruídos externos. Algumas soluções são utilizadas para reduzir estes ruídos, tais como

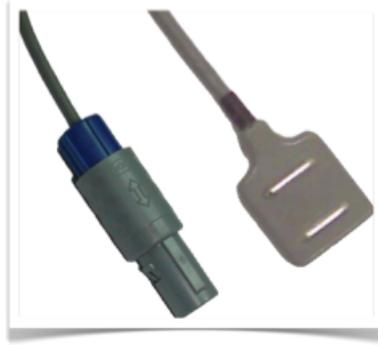


Figura 2.10: Exemplo de eletrodos ativos para a detecção de sinal EMG de superfície [7].

manter os cabos afixados durante o experimento e utilizar gel condutor para reduzir a impedância da interface eletrodo/pele. Geralmente, é necessário remover a camada superficial da pele abrasivamente e realizar a raspagem do pêlo (tricotomia) na área onde o eletrodo será posicionado.



Figura 2.11: Exemplo de eletrodos passivos para a detecção de sinal EMG de superfície [7].

O mau posicionamento dos eletrodos na área de detecção implica na obtenção errônea dos sinais, de forma que o sinal detectado pode não representar com fidelidade a realidade, podendo provocar, dessa forma, avaliações incorretas. A amplitude e o espectro de frequência do sinal EMG são afetados pela localização dos eletrodos em relação à zona de inervação, a junção miotendinosa e a extremidade lateral do músculo. O melhor local para o posicionamento dos eletrodos é na região entre a zona de inervação e a junção miotendinosa, pois nesta região será detectado o sinal EMG com maior amplitude. E ainda, alguns cuidados devem ser tomados no posicionamento dos eletrodos, são eles [7]:

- o fenômeno *cross-talk*, o qual ocorre devido à proximidade entre os músculos, pode ser minimizado com a seleção do tipo de eletrodo e do tipo de amplificação (monopolar, diferencial simples ou diferencial duplo);
- os eletrodos devem ser posicionados paralelamente às fibras, o que maximiza a sensibilidade a seletividade (Figura 2.12);



Figura 2.12: Exemplo do posicionamento correto de eletrodos EMG de superfície: paralelamente às fibras (modificado de [8]).

Um outro ponto de grande importância é a presença de ruído que pode ser gerado de várias outras fontes, causando a deteriorização das características do sinal EMG. Estes ruídos podem ter várias origens:

- **Ruídos inerentes dos componentes do equipamento de detecção:**

Todos os equipamentos eletrônicos geram ruídos elétricos. Estes ruídos estão na faixa de frequência de 0 Hz a milhares de hertz. É importante ressaltar que esses ruídos não podem ser eliminados, mas podem ser reduzidos através das utilização de componentes de boa qualidade e técnicas corretas de construção de *layouts* e equipamentos;

- **Ruídos de ambiente:**

São ruídos provenientes de fontes de radiação eletromagnética, tais como rádio e transmissão de TV, luzes fluorescentes etc;

- **Artefatos de movimento:**

Este tipo de ruído inclui dois tipos básicos de interferências: o movimento relativo

entre a pele e o eletrodo de detecção e o movimento dos cabos que conectam os eletrodos aos amplificadores. Estes ruídos contêm frequências na faixa de 0 a 20 Hz.

2.3.1 Amplificação do sinal EMG

O sinal gerado pelos músculos possui uma amplitude muito pequena, da ordem de dezenas a centenas de microvolts. Dessa forma, é necessário amplificar o sinal para que ele seja digitalizado de maneira adequada. Neste processo, alguns quesitos devem ser considerados [8]:

- **Impedância de entrada:**

A impedância de entrada de um amplificador é a impedância visualizada pelo eletrodo. Quanto menor for a impedância de entrada, maior será a quantidade de corrente que deve ser fornecida pela fonte do sinal. Entretanto, a impedância de entrada de um amplificador EMG deve ser substancialmente alta, da ordem de giga ohms;

- **Largura da banda de amplificação:**

A largura da banda de amplificação de um circuito é definida como sendo uma faixa de frequências que podem ser passadas ou amplificadas com perda de menos 3 dB. Considerando que a energia dos sinais EMG está concentrada entre 0 e 500 Hz, a largura de banda do amplificador deve incluir estas frequências.

- **Filtragem:**

Usualmente, um filtro passa-banda (20-500 Hz) é utilizado para filtrar os sinais EMG de superfície.

2.3.2 Aquisição do sinal EMG

Para realizar a aquisição de um sinal qualquer, é necessário, primeiro, considerar qual será a frequência de amostragem do mesmo. A amostragem é definida como sendo a leitura de um valor do sinal em um instante específico. E ainda, para que a frequência de amostragem seja correta, ela deve seguir o Teorema de Nyquist: “para a correta reconstrução de um sinal, dever-se usar uma frequência de amostragem de, no mínimo, o dobro de sua frequência máxima do sinal”. Desta forma, para realizar a correta aquisição do sinal EMG de superfície, a frequência mínima de amostragem deve ser de 1000 Hz [22].

2.3.3 Pré-processamento do sinal EMG

Após a aquisição do sinal EMG é necessário realizar o pré-processamento. A presença de ruídos no sinal EMG detectado sugere a utilização de um filtro para a redução/suavização dos mesmos. Diferentes filtros digitais podem ser utilizados para esta finalidade. Na literatura, LeFever e De Luca [67] [68] utilizaram um filtro do tipo passa-alta para atenuar as baixas frequências do sinal [21], as quais podem estar relacionados com ruídos provenientes do hardware utilizado para a aquisição dos dados ou provenientes de interferências de outras MUAPs que estão distantes do eletrodo de detecção do sinal EMG.

Outra técnica utilizada são os filtros diferenciais, que são filtros do tipo passa-baixa. Entretanto, esta ferramenta possui a desvantagem de gerar picos artificiais no sinal e, assim, modificar o formato dos MUAPs. Tal característica indesejável motivou a utilização de outros filtros, como por exemplo, Wavelets, filtro Laplaciano [69] [70] [34] [71] e *Empirical Mode Decomposition* [5].

2.4 Decomposição de sinais EMG

Para que as informações sobre o controle do Sistema Motor e do Sistema Neuromuscular (SN) sejam extraídas é necessário que os sinais eletromiográficos sejam decompostos em suas unidades básicas: os potenciais de ação das Unidades Motoras (MUAPs) [72]. Esse processo é denominado *Decomposição do Sinal Eletromiográfico*, e tal processo envolve diversas etapas de condicionamento e processamento de sinais [73]. Os resultados da decomposição de sinais EMG possuem aplicações práticas na área de neurologia, fisioterapia, odontologia, engenharia de reabilitação, biofeedback e no desenvolvimento de pesquisas de base visando um melhor entendimento sobre o comportamento de mecanismos básicos do SN [5] [74].

A decomposição do sinal EMG é um processo complexo, que requer muito processamento do sinal e etapas de reconhecimento de padrões. Uma forma que já foi muito utilizada para visualizar os MUAPs é utilizar o osciloscópio e escutar as suas características por meio de auto-falantes. Entretanto, tal prática, além de consumir muito tempo para ser realizada, requer muita experiência e habilidade por parte do profissional para conseguir extrair informações relevantes por meio desta análise visual e auditiva [5].

Para automatizar tal processo e obter uma análise padronizada dos sinais EMG, nas

últimas décadas muitos sistemas computacionais foram desenvolvidos para esta finalidade [5] [33]. Um sistema típico de extração de MUAPs de sinais EMG requer os seguintes estágios: 1) Detecção do sinal EMG; 2) Pré-processamento do sinal EMG; 3) Seleção de MUAPs; 4) Agrupamento de MUAPs (Figura 2.13).

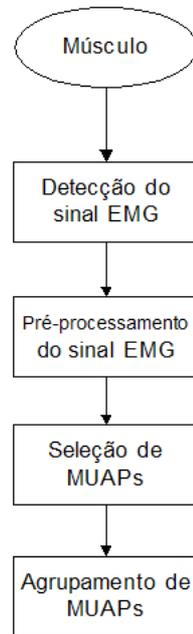


Figura 2.13: Estágios necessários para o processo de decomposição do sinal EMG (modificado de [5]).

Os estágios de Detecção e Pré-processamento do sinal EMG já foram discutidos nas seções anteriores. A seguir, serão detalhados os estágios de Seleção de MUAPs e Agrupamento de MUAPs.

2.4.1 Seleção de MUAPs

Após a realização da detecção e do pré-processamento do sinal EMG, um estágio importante da decomposição do sinal EMG é detectar todos os MUAPs gerados pelas Unidades Motoras ativas durante a aquisição do sinal. Neste estágio é necessário detectar os segmentos ativos ou inativos, isto é, os segmentos que possuem atividade eletromiográfica ou não. O principal objetivo deste estágio é identificar MUAPs únicos ou uma combinação deles. A separação dos segmentos ativos e inativos pode ser realizada de forma visual e manual, isto é, o pesquisador pode classificar as regiões de um sinal eletromiográfico em ativo ou inativo. Entretanto, esta técnica consome muito tempo e requer muita concentração, sem

a qual pode ser realizada uma análise errônea do sinal [5].

Uma das técnicas computacionais mais simples para a separação de MUAPs que pertencem a um mesmo grupo em um sinal eletromiográfico, é a utilização de limiares. A idéia central desta técnica é utilizar um limiar para a detecção de MUAPs que têm picos similares, o qual é representado pelo pico mais alto de um MUAP. A principal vantagem desta técnica é que ela é fácil de ser aplicada, pois requer o mínimo de hardware e software [75]. Entretanto, esta técnica possui algumas desvantagens, tais como a escolha do limiar depende muito da taxa de ruído; e ainda, apenas uma única característica (o pico mais alto da MUAP) é utilizada para a classificação do dado. Desta forma, duas diferentes MUAPs podem ser agrupadas em um único grupo pelo simples fato delas terem amplitudes similares [5].

Diversas abordagens podem ser utilizadas para melhorar este processo. Por exemplo, já foi empregado o valor da raiz média quadrática de um sinal EMG e um limiar pré-definido de acordo com o máximo pico do sinal [21]. Zennaro *et al.* [76] utilizaram um limiar que era manualmente ajustado pelo usuário. Na técnica apresentada por [5], o início e o final do segmento são detectados quando as amostras do sinal ficam $0.5 \mu\text{V}$ abaixo do limiar configurado.

2.4.2 Agrupamento de MUAPs

Após a detecção das regiões de atividade é possível agrupá-las em grupos e, para tanto, é necessário efetuar a extração de características morfológicas dessas regiões para poder agrupá-las. Os pesquisadores têm utilizado as seguintes características dos MUAPs para classificá-las: duração, amplitude, área, quantidade de fases, quantidade de picos positivos e negativos, coeficientes obtidos a partir da Transformada de Fourier, *Principal Component Analysis* (PCA), *Independent Component Analysis* (ICA) [34] [71] e *Generative Topographic Mapping* [5].

Conforme já relatado no Capítulo 1, uma ferramenta que disponibilize os resultados da decomposição do sinal EMG é de extrema importância para a prática clínica, seja na avaliação/diagnóstico de distúrbios motores ou nas terapias de Biofeedback. Entretanto, a maioria dos métodos já desenvolvidos são focados em sinais EMG coletados através de eletrodos intramusculares devido à facilidade e benefícios do processamento deste sinal. Entretanto, este tipo de coleta pode acarretar diversos inconvenientes - conforme já dis-

cutido anteriormente. Dessa forma, existe a necessidade de mais investigações de técnicas que possam ser aplicadas na decomposição de sinal EMG de superfície.

Para contribuir com os estudos na área de decomposição de sinais EMG de superfície, este trabalho tem como objetivo realizar o estudo, o projeto e a implementação dos métodos necessários para obter resultados que supram as necessidades desta área. Os estágios iniciais necessários para a decomposição do sinal EMG (pré-processamento e detecção das MUAPs), os quais já foram muito bem explorados na literatura [75] [76] [5], reproduzidos do sistema EMG Decomposition-BR [5].

2.4.3 Software EMG Decomposition-BR

No Laboratório de Engenharia Biomédica (BioLab) da Faculdade de Engenharia Elétrica, da Universidade Federal de Uberlândia já foram realizados estudos e desenvolvimento de técnicas para a decomposição de sinais EMG [5] [77] [15] [78] [79] [80].

Como resultado destes estudos, foi desenvolvido o software EMG Decomposition®-BR. Neste software, o usuário fornece um sinal EMG e, como resultado, são apresentados os MUAPs que compõem o sinal EMG fornecido. A decomposição do sinal EMG é realizada utilizando conceitos clássicos e modernos de processamento digital de sinais, tais como a técnica *Empirical Mode Decomposition*, na etapa de pré-processamento do sinal EMG; janelamento automático, na etapa de detecção de MUAPs; e a técnica *Generative Topographic Mapping*, na etapa de agrupamento e visualização de MUAPs [78] [79] [80].

Utilizando o *know-how* já desenvolvido neste laboratório de pesquisa, este trabalho irá utilizar as ferramentas já implementadas, testadas e validadas para aprimorar as técnicas de decomposição de sinal EMG de superfície. A partir da etapa de detecção dos MUAPs do sinal EMG, desenvolvida no software EMG Decomposition®-BR, irá começar o objetivo deste trabalho: identificar a quantidade de Unidades Motoras ativas no sinal EMG e realizar o agrupamento dos MUAPs, classificando-os em sua Unidade Motora geradora, utilizando Modelos Ocultos de Markov.

2.5 Conclusão

Este capítulo apresentou uma breve introdução sobre a anatomia e fisiologia do músculo. E ainda, apresentou o processo de contração muscular, bem como o processo de geração

dos potenciais de ação das Unidades Motoras e a conseqüente formação do sinal EMG. Foram apresentadas, também, as etapas necessárias em um sistema de decomposição de sinais EMG e as técnicas que já foram desenvolvidas para este propósito. Estes conceitos básicos serão úteis para o leitor entender os próximos capítulos e o desenvolvimento deste trabalho.

Foi apresentado o software EMG Decomposition®-BR, desenvolvido no Laboratório de Engenharia Biomédica da Universidade Federal de Uberlândia. Os estágios de pré-processamento do sinal EMG e detecção de MUAPs que foram desenvolvidos neste software, que são os passos iniciais de um processo de decomposição de sinais EMG, serão utilizados neste trabalho.

No próximo capítulo será apresentada uma revisão sobre Modelos Ocultos de Markov, que é a técnica principal estudada e proposta neste trabalho para a realização da decomposição do sinal EMG de superfície.

Capítulo 3

Modelos Ocultos de Markov

3.1 Introdução

Um Processo Estocástico pode ser definido como uma coleção de variáveis randômicas $(X(t))$ indexadas por um parâmetro t , pertencentes a um conjunto T , onde $X(t)$ representa uma característica mensurável de interesse no tempo t [81]. Processos estocásticos são interessantes para descrever o procedimento de um sistema operando sobre algum período de tempo e, desta forma, a variável randômica $X(t)$ representa o estado do sistema no parâmetro t [43].

Existem diversos tipos de Processos Estocásticos, e um tipo muito conhecido e utilizado é o Processo de Markov. Um Processo de Markov é um Processo Estocástico no qual as distribuições de probabilidade para o seu desenvolvimento futuro dependem somente do estado presente [82].

Os processos Markovianos são modelados formalmente pelos Modelos de Markov, os quais são sistemas de transições de estados, onde os estados são representados em termos de vetores probabilísticos, que podem variar no espaço temporal (discreto ou contínuo), e as transições entre estados são probabilísticas e dependem apenas do estado atual [82] [40], conforme descrito na equação (3.1). Este tipo de Processo Estocástico é chamado de *memoryless process* (processo sem memória), pois o passado é “esquecido” (desprezado) [40].

$$P\{X(t_{k+1}) \leq x_{k+1} | X(t_k) = x_k, X(t_{k-1}) = x_{k-1}, \dots, X(t_1) = x_1, X(t_0) = x_0\} = P\{X(t_{k+1}) \leq x_{k+1} | X(t_k) = x_k\} \quad (3.1)$$

para $t_0 \leq t_1 \leq \dots \leq t_k \leq t_{k+1}$ e toda seqüência $k_0, k_1, \dots, k_{t-1}, k_t, k_{t+1}$.

A expressão descrita em (3.1) representa:

- A probabilidade condicional de qualquer evento futuro, dado qualquer evento passado e o estado presente $(X(t_k)) = x_k$,
- É independente do evento passado;
- É dependente somente do estado presente.

As probabilidades condicionais $P(X(t_{k+1})) \leq P(x_{k+1}|X(t_k))$ são denominadas probabilidades de transição e representam a probabilidade do estado $X(t_{k+1})$ ser x_{k+1} no instante t_{k+1} , dados os estados $X(t_k)$ e x_k , no instante t_k .

Se o espaço de estados é discreto (enumerável), então o Modelo de Markov é denominado de Cadeias de Markov [82]. As propriedades desses modelos são estudadas em termos das probabilidades das matrizes de transição de estados, as quais são utilizadas em sua definição.

3.2 Cadeias de Markov

Uma Cadeia de Markov é um processo em que a probabilidade de estar em um certo estado em um determinado tempo futuro, pode depender do estado atual do sistema, mas não dos estados em tempos passados. Desta forma, o estado futuro de um sistema é independente do passado, mas poderá depender do estado presente [82].

Em uma Cadeia de Markov, o símbolo p_{ij} é chamado de probabilidade de transição entre estados, pois é utilizado para representar a probabilidade de que, dado que o sistema esteja no estado i em um determinado momento, venha a estar no estado j no intervalo de tempo seguinte [43](Figura 3.1).

Em uma Cadeia de Markov com N estados, a matriz $P_{NxN} = [p_{ij}]$ denomina-se matriz de transição da Cadeia de Markov. A equação 3.2 representa uma matriz de transição P de uma Cadeia de Markov com 4 estados [82].

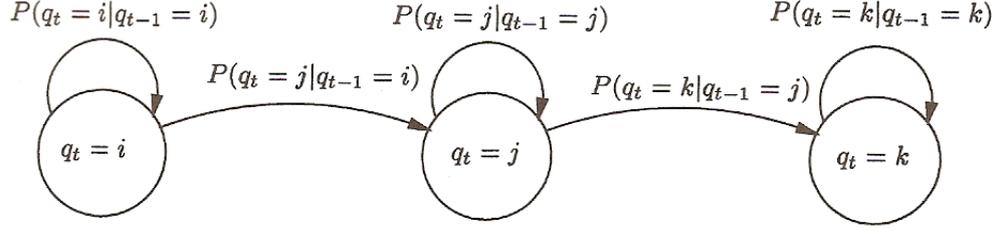


Figura 3.1: Exemplo de uma Cadeia de Markov com 3 estados, onde $p(q_t = a|q_{t-1} = b)$ representa a probabilidade de transição do estado b (no tempo t-1) para o estado a (no tempo t) [9].

$$P = \begin{pmatrix} p_{11} & p_{12} & p_{13} & p_{14} \\ p_{21} & p_{22} & p_{23} & p_{24} \\ p_{31} & p_{32} & p_{33} & p_{34} \\ p_{41} & p_{42} & p_{43} & p_{44} \end{pmatrix} \quad (3.2)$$

A probabilidade de transição do estado i para o estado j, em n períodos de tempo denota-se por $p_{ij}^{(n)}$. A matriz $P^{(n)} = [p_{ij}^{(n)}]$ obtida, denomina-se matriz de transição de n fases da Cadeia de Markov. Para determinar uma fórmula para $P^{(n)}$ em termos da matriz de transição P, basta elevar a matriz P à potência n [40].

$$P^{(n)} = P^n \quad (3.3)$$

Dado que o estado inicial (tempo 0) de um sistema seja i, a probabilidade de que o sistema esteja no estado j, no tempo n é $p_{ij}^{(n)}$. Suponhamos, entretanto, que o estado inicial não seja conhecido e que somente as várias probabilidades do sistema estar em um particular estado no tempo 0 é que sejam conhecidas. Neste caso, para determinar a probabilidade do sistema estar em um determinado estado j no tempo n, é necessário considerar um vetor de distribuição inicial da Cadeia de Markov [82], o qual é representado pelo vetor $\Pi^{(n)}$.

Assim, para cada tempo n, onde $n \geq 0$, seja $\Pi_j^{(n)}$ a probabilidade de que uma Cadeia de Markov esteja no estado j, no tempo n. Desta forma, para uma cadeia de Markov com N estados, será considerado um vetor de distribuição inicial $\Pi^{(n)}$, de tamanho N, como mostra a equação apresentada em (3.4):

$$\Pi^{(n)} = [\Pi_1^{(n)}, \Pi_2^{(n)}, \dots, \Pi_N^{(n)}] \quad (3.4)$$

Em particular, $\Pi_j^{(0)}$ representa a probabilidade de que a Cadeia de Markov esteja inicialmente (no tempo 0) no estado j [40]. Assim, a distribuição da Cadeia de Markov, a qualquer tempo n , é:

$$\Pi^{(n)} = \Pi^{(0)} \cdot P^n \quad (3.5)$$

3.3 Modelos Ocultos de Markov

Um Modelo Oculto de Markov (MOM) é uma variante das Cadeias de Markov, na qual, além da função de distribuição de probabilidades associadas aos estados, existe uma função de distribuição de probabilidades para as observações que podem ser realizadas em cada estado.

O MOM é um método estatístico que utiliza medidas probabilísticas para modelar dados seqüenciais que são representados por uma seqüência de observações [83]. Rabiner [40] define um MOM como “*um processo estocástico duplamente imerso em processos não observáveis, isto é, ocultos, mas que apenas podem ser observados através de um outro conjunto de processos estocásticos que produzem uma seqüência de observações*” [84].

O Modelo de Markov é chamado de *Oculto* porque existem processos estocásticos subentendidos, isto é, seqüência de estados, que não são observados mas que afetam a seqüência de eventos observáveis [10]. O MOM consiste de um processo duplamente estocástico composto por um processo oculto (não observável), mas que se manifesta através de um outro processo estocástico que produz a seqüência de símbolos observados [10] [85].

Esquemáticamente, o MOM pode ser representado através das probabilidades de emissão dos símbolos observáveis em um determinado estado e das probabilidades de transição entre os estados do modelo (Figura 3.2).

Para a configuração do MOM, os seguintes parâmetros são necessários [43]:

- N = quantidade de estados;
- $S = [S_1 S_2 \dots S_N]$ - conjunto de estados;
- M = quantidade de símbolos observáveis;
- $V = [v_1 v_2 \dots v_M]$ - conjunto de símbolos que podem ser números escalares ou vetores;

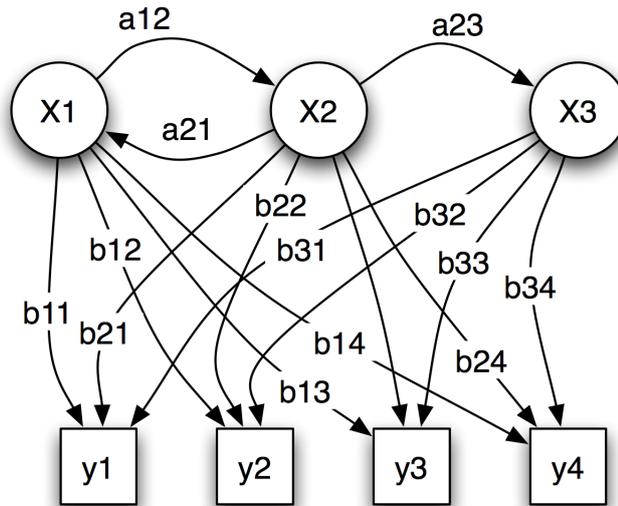


Figura 3.2: Exemplo de um Modelo Oculto de Markov com três estados (x_i), quatro símbolos (y_k), probabilidade de transição entre os estados (a_{ij}) e probabilidade de emissão de símbolos (b_{ij}). A seqüência de estados (x_i) representa o processo oculto do Modelo de Markov, que gera a seqüência de observações (y_k) [10].

- T = comprimento da seqüência de observações;
- $O = [O_1 O_2 \dots O_T]$ - conjunto de observações do modelo;
- Π = vetor de probabilidades inicial para cada um dos N estados S ;
- $A = P(S_t | S_{t-1})$ (probabilidade de transição do estado S_{t-1} para o estado S_t);
- $B = P(k | S_t)$ probabilidade de observar o símbolo k no estado S_t .

Os parâmetros do MOM podem ser representados por:

$$\lambda = (\Pi, A, B) \quad (3.6)$$

Desta forma, a partir do MOM λ é possível gerar uma seqüência de observações. E ainda, a partir de λ é possível calcular a verossimilhança de uma série de observações, que é probabilidade do modelo λ gerar a seqüência O_t [85]. A verossimilhança é calculada através do produto das probabilidades individuais de transição de um estado para o próximo, produzindo as observações O_t naqueles estados. Assim, a verossimilhança define

o quão ideal um modelo λ é para gerar uma determinada seqüência de observações O_t . Quanto maior for o valor da verossimilhança, maior será a probabilidade de um modelo gerar uma determinada seqüência.

3.3.1 Operações realizadas com os parâmetros do Modelo Oculto de Markov

Através da definição dos parâmetros A , B e π de um MOM λ , é possível executar algumas operações básicas:

- Busca exaustiva por uma solução;
- Seqüência ótima de estados;
- Estimação dos parâmetros do MOM.

3.3.1.1 Busca por uma solução

Uma das operações mais utilizadas em um Modelo Oculto de Markov é gerar as possíveis seqüências de observações e estados ocultos que podem ser extraídos a partir desse modelo. A forma mais direta para calcular a probabilidade de uma seqüência de observação $O_{1:T}$, dado um modelo $\lambda = (A, B, \pi)$, é enumerar todas as possíveis seqüências de comprimento T .

Considerando que existem N possíveis transições de um estado para o outro, teremos um total de N^T seqüências. E ainda, considerando uma seqüência de estados $S_{1:t}$, onde S_1 é o estado inicial, e assumindo a independência estatística das observações, a probabilidade desta seqüência de estados é definida por:

$$P(O|S, \lambda) = \prod_{t=1}^T P(o_t|S_t, \lambda) \quad (3.7)$$

$$P(O|S, \lambda) = b_{S_1}(o_1) \times b_{S_2}(o_2) \times \dots \times b_{S_t}(o_t) \quad (3.8)$$

A probabilidade da seqüência de estados S pode ser definida conforme as equações (3.9) e (3.10).

$$P(S|\lambda) = \pi_{S_1} \times a_{S_1 S_2} \times a_{S_2 S_3} \times \dots \times a_{S_{T-1} S_T} \quad (3.9)$$

$$P(O|S, \lambda) = P(O|S, \lambda)P(S|\lambda) \quad (3.10)$$

Desta forma, considerando que a probabilidade da seqüência O é obtida através da soma das probabilidades de todas as possíveis seqüências S, temos:

$$P(O|\lambda) = \sum_{\text{todos os } S} P(O|S, \lambda)P(S|\lambda) \quad (3.11)$$

Esta forma de calcular a $P(O|\lambda)$ possui um custo computacional muito alto, visto que ela considera todas as probabilidades possíveis entre todos os estados e observações do MOM. Sendo assim, um outro algoritmo o algoritmo *Forward* é utilizado para otimizar este processo.

Algoritmo Forward

Neste método, é possível utilizar a não-variação do tempo das probabilidades para reduzir a complexidade computacional no cálculo das probabilidades. Considere a variável forward $\alpha_t(i)$:

$$\alpha_t(i) = P(o_1 o_2 \dots o_t, q_t = i | \lambda) \quad (3.12)$$

Onde:

- $\alpha_t(i)$ é a probabilidade parcial da seqüência de observações $O_{1:t}$;
- Estado i no tempo t ;

De forma geral, as probabilidades parciais representam a probabilidade de obter um determinado estado q em um tempo t . Desta forma, é possível reduzir a complexidade da equação 3.10. Sendo assim, $\alpha_t(i)$ pode ser calculado de acordo com a seqüência abaixo:

1. Inicialização

$$\alpha_t(i) = \pi_1 b_i(o_1) \quad (3.13)$$

Onde: $1 \leq i \leq N$

2. Indução

$$a_{t+1}(j) = \left[\sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(o_{t+1}) \quad (3.14)$$

Onde:

- $1 \leq t \leq T - 1$
- $1 \leq j \leq N$

3. Término

$$P(O_{1:T}|\lambda) = \sum_{i=1}^N \alpha_T(i) \quad (3.15)$$

A idéia básica deste algoritmo é explorar a recursão nos cálculos e evitar os exaustivos cálculos em todos os caminhos do MOM. Assim, a probabilidade de uma seqüência de observações é obtida através do cálculo das probabilidade parciais, variando o tempo $t=1,2,\dots,T$, e adicionando todos os α s para cada t .

3.3.1.2 Seqüência ótima de estados

Identificar a seqüência ótima de estados significa encontrar a melhor seqüência de estados S gerado pelo MOM, isto é, significa maximizar $P(S, O|\lambda)$ de modo que a verossimilhança da seqüência gerada pelo MOM seja a maior deste modelo. Para este propósito, o algoritmo *Viterbi* é utilizado.

No algoritmo *Viterbi*, a probabilidade parcial $\delta_t(i)$ é a probabilidade de alcançar um determinado estado, de acordo com as observações e estados (3.16):

$$\delta_t(i)_{q_1, q_2, \dots, q_{t-1}} = \max\{P(q_1 q_2 \dots q_{t-1}, q_t = i, o_1 o_2 \dots o_t | \lambda)\} \quad (3.16)$$

Considerando que δ é a probabilidade máxima de todas as seqüências que terminam no estado i no tempo t , e que o melhor caminho parcial é a seqüência que atinge a máxima probabilidade, por indução temos:

$$\delta_{t+1}(j) = (\max_i\{\delta_t(i) a_{ij}\}) \times b_j(a_{t+1}) \quad (3.17)$$

Para obter a seqüência de estados é necessário manter a busca do argumento que foi maximizado para cada t e j (3.17). Isto pode ser implementado utilizando um array $\psi_t(j)$. Os passos do algoritmo Viterbi são:

1. Inicialização

$$\delta_1(i) = \pi_i b_i(o_1) \quad (3.18)$$

$$\psi_1(i) = 0 \quad (3.19)$$

Onde: $1 \leq i \leq N$

2. Recursão

$$\delta_t(j) = (\max_{1 \leq i \leq N} \{\delta_{t-1}(i) a_{ij}\}) \times b_j(o_t) \quad (3.20)$$

$$\psi_t(j) = \operatorname{argmax}_{1 \leq i \leq N} \{\delta_{t-1}(i) a_{ij}\} \quad (3.21)$$

Onde:

- $2 \leq t \leq T$;
- $1 \leq j \leq N$

3. Término

$$P^* = \max_{1 \leq i \leq N} \{\delta_T(i)\} \quad (3.22)$$

$$q_T^* = \operatorname{argmax}_{1 \leq i \leq N} \{\delta_T(i)\} \quad (3.23)$$

4. Busca pelo caminho (seqüência de estados)

$$q_t^* = \psi_{t+1}(q_{t+1}^*) \quad (3.24)$$

Onde: $t = T-1, T-2, \dots, 1$

Exceto na passo 4 (busca pelo caminho), o algoritmo Viterbi é similar à implementação do algoritmo Forward. A diferença fundamental entre eles é na maximização dos estados anteriores (3.20), que é utilizada no lugar da soma (3.14).

3.3.1.3 Estimação de parâmetros

Existem diversos contextos em que os parâmetros do MOM não podem ser diretamente e corretamente estimados. E ainda, não é conhecida uma forma para determinar analiticamente o conjunto de parâmetros do MOM de forma que maximize a probabilidade de uma seqüência de observações. Para resolver este problema, alguns procedimentos são utilizados para que, dado um modelo λ , a verossimilhança $P(O|\lambda)$ seja maximizada. Uma das técnicas utilizadas para esta finalidade é o método *Baum-Welch*, também conhecido como método *expectation-maximization*.

No algoritmo *Baum-Welch* é necessário definir a variável *backward* $\beta_t(i)$, que define a probabilidade da seqüência parcial de observações, de $t+1$ até T, dado o estado i no tempo t e o modelo λ (3.25).

$$\beta_t = P(o_{t+1}, o_{t+2} \dots o_T | q_t = i, \lambda) \quad (3.25)$$

Desta forma, $\beta_t(i)$ pode ser calculado da seguinte forma:

- **Inicialização**

$$\beta_T(i) = 1 \quad (3.26)$$

Onde: $1 \leq i \leq N$

- **Indução**

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(o_{t+1}) \beta_{t+1}(j) \quad (3.27)$$

E ainda, temos que considerar a probabilidade de estar no estado i no tempo t , e no estado j no tempo $t+1$, dados O e o modelo λ (3.28).

$$\xi_t(i, j) = P(q_t = i, q_{t+1} = j | O, \lambda) \quad (3.28)$$

Utilizando a definição das variáveis *forward* e *backward*, $\xi_t(i, j)$ pode ser escrito da seguinte forma (3.29):

$$\xi_t(i, j) = \frac{\alpha_t(i)a_{ij}b_j(o_{t+1})\beta_{t+1}(j)}{\sum_{i=1}^N \sum_{j=1}^N \alpha_t(i)a_{ij}b_j(o_{t+1})\beta_{t+1}(j)} \quad (3.29)$$

Agora, dado $\xi_t(i, j)$, é possível definir $\gamma_t(i)$: probabilidade de estar no estado i no tempo t , dado a seqüência completa de observações e o modelo λ .

$$\gamma_t(i) = \sum_{j=1}^N \xi_t(i, j) \quad (3.30)$$

Com o somatório de $\gamma_t(i)$ e $\xi_t(i, j)$, teremos (3.31) e (3.32):

$$\sum_{t=1}^{T-1} \gamma_t(i) = QTI. \quad (3.31)$$

Onde: QTI = quantidade esperada de transições do estado i , na seqüência O ;

$$\sum_{t=1}^{T-1} \xi_t(i, j) = QTIJ. \quad (3.32)$$

Onde: QTIJ = quantidade esperada de transições do estado i para o estado j , na seqüência O ;

Realizadas todas as definições necessárias, é utilizado o algoritmo *Forward-Backward* para reestimar os parâmetros. Se temos o modelo $\lambda = (A, B, \pi)$, temos que calcular o modelo reestimado $\lambda^* = (A^*, B^*, \pi^*)$ utilizando as seguintes fórmulas de reestimação de parâmetros:

$$\pi^* = \gamma_t(i) \quad (3.33)$$

$$a_{ij}^* = \frac{\sum_{t=1}^{T-1} \xi_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)} \quad (3.34)$$

$$b_j(k) = \frac{\sum_{t=1}^T \gamma_t(i)}{\sum_{t=1}^T \gamma_t(j)} \quad (3.35)$$

O resultado final do procedimento de reestimação é a máxima verossimilhança estimada do MOM. É importante notar que o algoritmo *Forward-Backward* apenas conduz ao máximo local. E é necessário considerar que a verossimilhança é uma função geralmente complexa e que pode ter vários máximos locais. Dessa forma, dependendo da aplicação,

pode ser necessária a utilização de um outro algoritmo de otimização de parâmetros, como estratégia para tentar fazer com o que o algoritmo de otimização escape dos máximos locais e se aproxime do máximo global.

3.4 Modelo Oculto de Markov Contínuo

Quando as observações do Modelo Oculto de Markov são representadas por símbolos discretos, selecionados de um alfabeto finito, uma função de densidade de probabilidade discreta (matriz B) é utilizada para representar a probabilidade de observação dos símbolos. Entretanto, quando as observações forem números reais, outras formas para lidar com essa situação devem ser consideradas. Uma alternativa é utilizar vetores de quantização (*codebooks*) para converter estas observações em uma seqüência de símbolos discretos. Porém, uma discretização não realizada de maneira adequada poderá acarretar danos à modelagem do MOM e, assim, o MOM não irá fornecer respostas adequadas ao sistema que foi modelado.

Sendo assim, é mais interessante modelar uma representação direta destas observações representadas por números reais. Para tanto, a forma mais comum de função de densidade de probabilidade (*pdf* - probability density function) para este propósito, baseia-se na utilização de misturas finitas (3.36), conforme proposto por [11].

$$b_j(\langle o \rangle) = \sum_{k=1}^M c_{jk} N(\langle o \rangle, \mu_{jk}, U_{jk}) \quad (3.36)$$

Onde:

- o é o vetor de observações;
- c_{jk} é a mistura de coeficientes para a k-ésima mistura no estado j;
- N é uma função de densidade côncava ou elipticamente simétrica.

A função de densidade N mais utilizada é a Gaussiana. A equação 3.37 apresenta a definição de um caso uni-dimensional.

$$N(x, a, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-a)^2}{2\sigma^2}} \quad (3.37)$$

Onde:

- \mathbf{x} é um valor real;
- \mathbf{a} é a média;
- σ^2 é a variância.

Quando $\mathbf{a} = 0$ e $\sigma^2 = 1$, temos uma distribuição normal padrão, isto é, Distribuição Gaussiana padrão. Nos casos multidimensionais, a função de Distribuição Gaussiana Multivariável é definida conforme a equação 3.38.

$$N(\mathbf{X}, \mathbf{A}, \Sigma^2) = \frac{1}{\prod \sqrt{2\pi\sigma_i^2}} e^{-\sum_{i=1}^n \frac{(x_i - a_i)^2}{2\sigma_i^2}} \quad (3.38)$$

Onde:

- $\mathbf{X} = (x_1, x_2, \dots, x_n)$;
- $\mathbf{A} = (a_1, a_2, \dots, a_n)$;
- $\Sigma^2 = (\sigma_1^2, \sigma_2^2, \dots, \sigma_n^2)$;

Considerando que o coeficiente c_{jk} da mistura Gaussiana satisfaz a restrição estocástica de que o somatório das probabilidades de observação de cada elemento de um determinado conjunto de dados é 1, temos:

$$\sum_{k=1}^M c_{jk} = 1 \quad (3.39)$$

Onde: $c_{jk} \geq 0$, para $1 \leq j \leq N$ e $1 \leq k \leq M$.

Nesse novo contexto de observações não-discretas, as mesmas operações básicas para o MOM λ , descritas na seção anterior, podem ser aplicadas, sendo necessários apenas alguns ajustes. Para detalhar as fórmulas para reestimar a *pdf*, primeiro é necessário definir $\gamma_t(j, k)$ - probabilidade de estar no estado j , no tempo t e com a componente de mistura k -ésima para o vetor de observações $\langle o \rangle_t$, no tempo t (3.40).

$$\gamma_t(j, k) = \left[\frac{\alpha_t(j)\beta_t(j)}{\sum_{j=1}^N \alpha_t(j)\beta_t(j)} \right] \left[\frac{c_{jk}N(\langle o \rangle_t, \mu_{jk}, U_{jk})}{\sum_{j=1}^N c_{jm}N(\langle o \rangle_t, \mu_{jm}, U_{jm})} \right] \quad (3.40)$$

Dessa forma, as fórmulas para reestimação dos coeficientes da função de densidade são definidas conforme as equações (3.41), (3.42) e (3.43).

$$c_{jk}^* = \frac{\sum_{t=1}^T \gamma_t(j, k)}{\sum_{t=1}^T \sum_{k=1}^M \gamma_t(j, k)} \quad (3.41)$$

$$\mu_{jk}^* = \frac{\sum_{t=1}^T \gamma_t(j, k) \langle o \rangle_t}{\sum_{t=1}^T \gamma_t(j, k)} \quad (3.42)$$

$$U_{jk}^* = \frac{\sum_{t=1}^T \gamma_t(j, k) \langle o \rangle_t - \mu_{jk} (\langle o \rangle_t - \mu_{jk})^t}{\sum_{t=1}^T \gamma_t(j, k)} \quad (3.43)$$

Assim, todas as operações com o MOM descritas na seção anterior, também são aplicáveis ao Modelo Oculto de Markov com observações de valores contínuos. Entretanto, é necessário ressaltar que a matriz B, que denota a probabilidade de observação dos símbolos, será representada pela função de densidade de probabilidade.

3.5 Topologias de Modelos Ocultos de Markov

Existem diversas topologias para os Modelos Ocultos de Markov [9] [84]. Algumas das topologias mais utilizadas na literatura são:

- **Ergódico**

A topologia do tipo ergódico, ou completamente conectado, considera que qualquer estado pode ser alcançado por qualquer outro estado, em apenas um passo (transição) (Figura 3.3).

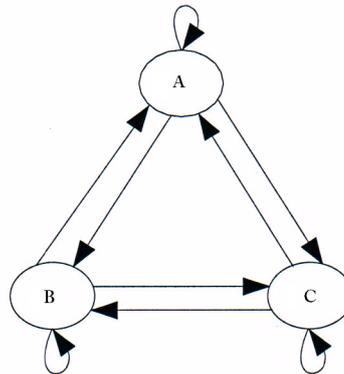


Figura 3.3: Exemplo de um Modelo Oculto de Markov com a topologia ergódico, com 3 estados (A, B e C). Neste MOM, existe probabilidade de transição entre todos os estados [11].

Para este MOM, a matriz de transição A será representada conforme apresentado em 3.44.

$$A = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix} \quad (3.44)$$

Onde: $a_{ij} > 0$, para $1 \leq i$ e $j \leq 3$.

- **Esquerdo-Direito**

No MOM Esquerdo-Direito, quando o tempo incrementa, o estado pode incrementar ou não, avançando sempre da esquerda para a direita. Este modelo é ideal para representar sinais cujas propriedades se alteram ao longo do tempo (Figura 3.4).

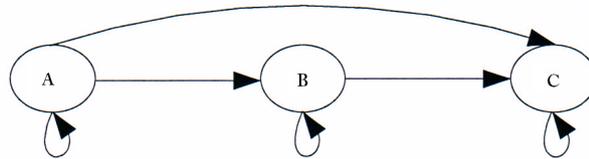


Figura 3.4: Exemplo de um MOM esquerdo-direito, com 3 estados [11].

Para este modelo, a matriz de transição de estados será representada por:

$$A = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ 0 & a_{22} & a_{23} \\ 0 & 0 & a_{33} \end{pmatrix} \quad (3.45)$$

- **MOM com saída de misturas Gaussianas**

Em muitas aplicações, é comum representar $P(Y_t|Q_t = i)$ utilizando uma mistura M de Gaussianas para cada estado Q (Figura 3.5).

Nesta topologia, a Distribuição da probabilidade de observar Y_t está descrito em (3.46) e (3.47).

$$P(Y_t = y_t|Q_t = i, M_t = m) = \eta(y_t; \mu_{i,m}, \sum_i, m) \quad (3.46)$$

$$P(M_t = m|Q_t = i) = C(i, m) \quad (3.47)$$

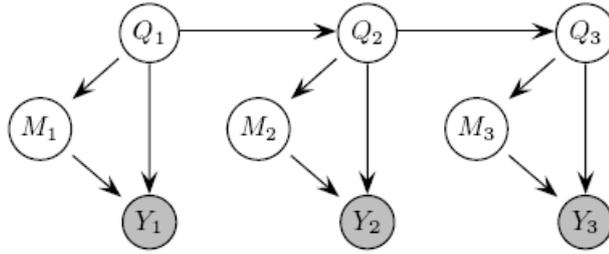


Figura 3.5: Exemplo de um MOM com misturas Gaussianas na saída [9].

É importante ressaltar que a escolha do tipo de topologia dependerá, exclusivamente, do contexto em que o Modelo Oculto de Markov será aplicado.

3.6 Aplicações dos Modelos Ocultos de Markov

Nos últimos anos, diversos pesquisadores divulgaram pesquisas utilizando Modelos Ocultos de Markov. De uma forma geral, os MOMs têm sido utilizados para o reconhecimento da fala ([86] [87] [88] [89] [90] [91] [88] [92]), reconhecimento de texto ([93] [94] [95] [96] [96] [97] [98] [99] [100]), processamento de imagens ([81] [101] [102] [103] [104]), sistemas especialistas ([105] [106]), análise de movimento ([107] [108]), algoritmos de agrupamento ([109] [110] [111] [112] [113] [41]), entre outros.

Na área de Engenharia Biomédica, algumas pesquisas com MOM já foram realizadas para o processamento de sinais biológicos ([114] [115] [39] [116] [117] [84] [118]). Entretanto, para realizar a decomposição de sinais EMG, ainda não há registro na literatura de pesquisas que investigaram o MOM para esta finalidade.

3.7 Conclusão

Neste capítulo foi apresentada a definição de Processos Estocásticos e Cadeias de Markov. Foi apresentado, também, a teoria e a descrição e as operações básicas realizadas com os parâmetros do Modelo Oculto de Markov. E ainda, foram descritas algumas das topologias que podem ser implementadas para o Modelo Oculto de Markov, bem como as potenciais áreas de aplicação deste modelo.

Nesta pesquisa, será utilizada a topologia esquerda-direita para o MOM, com 5 estados e observações multi-dimensionais, conforme será justificado no Capítulo 6.

No próximo capítulo será apresentada a teoria do Agrupamento Espectral, que será utilizado, em conjunto com o Modelo Oculto de Markov, para realizar o agrupamento dos potenciais de ação das Unidades Motoras.

Capítulo 4

Evolução Diferencial

4.1 Introdução

A Computação Evolucionária é uma área da Computação Natural que engloba um conjunto de métodos computacionais, tendo como base os mecanismos evolutivos encontrados na natureza, tais como auto-organização e comportamento adaptativo [119] [120].

Tais mecanismos estão diretamente relacionados com a teoria da evolução de Charles Darwin, que afirma que a vida na Terra é o resultado de um processo de seleção, em que somente os mais aptos e adaptados possuirão chances de sobreviver e, conseqüentemente, de reproduzir-se [121]. Desta forma, a Computação Evolucionária emprega conceitos de cruzamento (recombinação gênica), mutação e seleção natural originados da genética. O cruzamento é responsável pela passagem das características dos pais para os filhos. Já a mutação é responsável pelo surgimento da diversidade nos indivíduos da população, com o surgimento de novas características que, se forem benéficas, tornam os indivíduos mais aptos e adaptados, facilitando, assim, a geração de descendentes com tais características; caso contrário, essas características tendem a ser eliminadas. Esse processo, que é a base da Teoria da Evolução Natural de Darwin, é denominado de Seleção Natural [122].

Seguindo a teoria da Seleção Natural de Darwin, o processo evolucionário pode gerar as melhores soluções possíveis [123]. No caso dos problemas de otimização, estes algoritmos buscam atender, através da maximização ou minimização de uma ou mais funções objetivo, as metas estabelecidas para a operação do sistema. Assim, os valores das chamadas variáveis de decisão do problema correspondentes ao valor ótimo (maximização ou minimização das funções objetivos) são identificados [124].

4.2 Algoritmos genéticos

Algoritmos Genéticos (AG), que também compõem a Computação Evolucionária, são métodos de busca e otimização que têm sua inspiração nos conceitos da teoria de Seleção Natural das espécies proposta por Darwin [12] [125]. Dessa forma, os sistemas desenvolvidos a partir destes princípios são utilizados para procurar soluções de problemas complexos ou com espaço de soluções muito grande (espaço de busca), o que os tornam problemas de difícil modelagem e solução, quando são aplicados métodos de otimização convencionais [126]. Estes algoritmos são inspirados nos processos genéticos de organismos biológicos para procurar soluções ótimas.

Para procurar a solução ótima, procede-se da seguinte maneira: codifica-se cada possível solução de um problema em uma estrutura chamada de “cromossomo”, que é composta por uma cadeia de bits ou bytes. Estes cromossomos representam indivíduos, que são evoluídos ao longo de várias gerações, de forma similar aos seres vivos, de acordo com os princípios de seleção natural e sobrevivência dos mais aptos. Os algoritmos genéticos são capazes de “promover a evolução” de soluções de problemas do mundo real [127]. Os indivíduos são então submetidos a um processo evolucionário que envolve *avaliação, seleção, cruzamento e mutação*. Após vários ciclos de evolução a população deverá conter indivíduos mais aptos a alcançar a solução desejada. O procedimento básico de um algoritmo genético está apresentado na Figura 4.1 [128].

A cada indivíduo atribui-se uma aptidão, que indica o quanto a solução representada por este indivíduo é boa em relação às outras soluções da população. Desta maneira, o termo *População* refere-se ao conjunto de todas as soluções com as quais o sistema trabalha [12]. Aos indivíduos mais adaptados é dada uma probabilidade maior de se reproduzirem mediante cruzamentos com outros indivíduos da população, produzindo descendentes com características de ambas as partes. A mutação também tem um papel importante, pois introduz na população novos indivíduos gerados de maneira aleatória [129].

O processo de evolução começa com a criação aleatória dos indivíduos que formarão a população inicial. A partir de um processo de seleção baseado na aptidão de cada indivíduo, são escolhidos indivíduos para a fase de reprodução que cria novas soluções utilizando-se, para isto, um conjunto de operadores genéticos. Deste modo, a aptidão do indivíduo determina o seu grau de sobrevivência e, assim, a possibilidade de que o cromossomo possa fazer parte das gerações seguintes [127]. Para determinar o final da

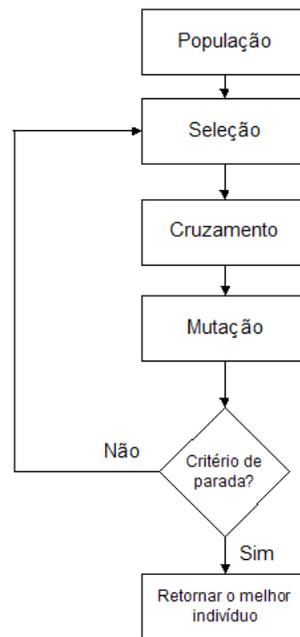


Figura 4.1: Estágios básicos da implementação de um Algoritmo Genético.

evolução pode-se fixar a quantidade de gerações, ou condicionar o algoritmo à obtenção de uma solução satisfatória [12].

4.2.1 Elementos integrantes de um Algoritmo Genético

Dentro do AG existem algumas definições básicas que devem ser consideradas [125] [130]:

- **Espaço de busca:**

É a região que compreende as soluções possíveis ou viáveis para o problema a ser resolvido;

- **Indivíduo:**

É um membro da população. Nos AGs, um indivíduo é formado pelo cromossomo e sua aptidão. Cada indivíduo representa um candidato à solução do problema;

- **População:**

É um conjunto de indivíduos, os quais são possíveis soluções do problema a ser resolvido;

- **Cromossomo:**

É o elemento portador do material genético. Nos AGs, o cromossomo representa uma cadeia de bits associada a uma solução possível para o problema. É importante ressaltar que cada cromossomo corresponde a um ponto no espaço de soluções do problema de otimização;

- **Gene:**

É o elemento que compõe os cromossomos, a sua unidade básica. Cada cromossomo tem uma determinada quantidade de genes, os quais descrevem a variável do problema que deverá ser solucionado;

- **Aptidão:**

Representa a informação numérica do desempenho de cada indivíduo, estando associado à uma função objetivo e às restrições do problema. Através da avaliação da aptidão de cada indivíduo é possível selecionar os melhores indivíduos de cada população para a aplicação das operações genéticas e, assim, realizar a evolução da população para a solução ótima;

- **Geração:**

É cada passo do processo evolutivo. Cada geração é considerada um ciclo de criação e transformação de uma população. As gerações são representadas pelas iterações que o AG executa;

- **Operadores genéticos:**

O princípio básico dos operadores genéticos em AG é transformar a população, através de sucessivas gerações, realizando assim, a busca pela melhor solução até que seja alcançado um resultado satisfatório. Os operadores genéticos são necessários para que a população se diversifique, mas que mantenha as boas características de adaptação adquiridas nas gerações anteriores. Os operadores mais utilizados nos algoritmos genéticos são os de *Seleção, cruzamento e mutação* [131]:

- **Seleção**

Refere-se ao processo de selecionar um determinado cromossomo para a população seguinte, de acordo com sua aptidão. Este operador desempenha o papel da seleção natural na evolução, permitindo a sobrevivência e reprodução dos organismos mais adaptados ao meio. Assim, os cromossomos mais ap-

tos têm maior probabilidade de contribuir para a formação de um ou mais indivíduos da população seguinte [126];

– **Cruzamento**

É um operador baseado na troca de partes dos cromossomos (pais), formando duas novas soluções (filhos). Através do cruzamento são criados novos indivíduos misturando características de dois indivíduos “pais” [127]. O resultado desta operação é um indivíduo que, potencialmente, combine as melhores características dos indivíduos utilizados como base. Existem, basicamente, três tipos de operações de cruzamentos: o simples, o múltiplo e o uniforme.

* *Cruzamento simples*

Neste tipo de cruzamento, um ponto dos dois cromossomos envolvidos na operação é escolhido e ambos os cromossomos são cortados neste ponto. A primeira parte do Pai A é concatenada à segunda parte do Pai B, formando um dos filhos. O mesmo ocorre com as outras partes: a primeira parte do Pai B é ligada à segunda parte do Pai A, formando um segundo filho (Figura 4.2) [126] [127].

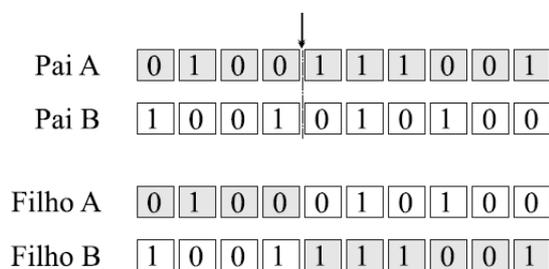


Figura 4.2: Exemplo de cruzamento simples em Algoritmos Genéticos (modificado de [12]).

* *Cruzamento múltiplo*

Dois ou mais pontos de cruzamento são escolhidos aleatoriamente. Neste caso, os segmentos dos genes, definidos pelos pontos de corte, são alternadamente trocados entre os pais na formação dos filhos. A Figura 4.3 ilustra este processo para dois pontos de corte.

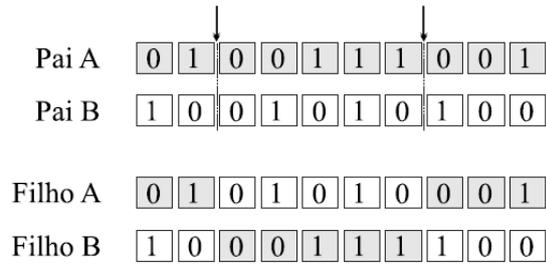


Figura 4.3: Exemplo de cruzamento múltiplo em Algoritmos Genéticos (modificado de [12]).

* *Cruzamento uniforme*

É um tipo de cruzamento múltiplo, mas ao invés de sortear o ponto de corte, é sorteado uma máscara do tamanho do cromossomo que indica qual cromossomo Pai fornecerá cada gene ao primeiro filho. O segundo filho é gerado pelo complemento da máscara (Figura 4.4).

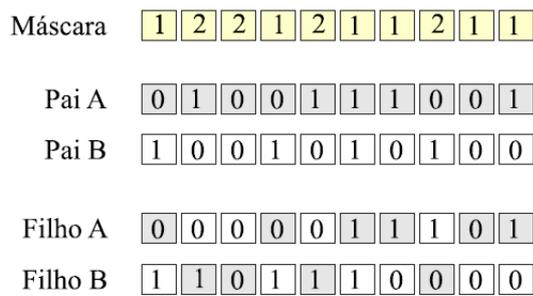


Figura 4.4: Exemplo de cruzamento uniforme em Algoritmos Genéticos (modificado de [12]).

– **Mutação**

A mutação é uma operação que modifica, aleatoriamente, alguma(s) característica(s) do indivíduo. Esta operação é importante pois permite criar novas características que não existiam ou apareciam em pequena quantidade na população em análise, introduzindo diversidade genética na população. Desta forma, a mutação aumenta a probabilidade de alcançar uma solução do espaço de busca. Para tanto, utiliza-se uma taxa de mutação de forma que, para cada gene do cromosso, é sorteada a ocorrência ou não da mutação. No caso de ocorrência, o bit será trocado por outro valor válido pertencente ao alfabeto de representação do cromossomo [126] [127](Figura 4.5).

A mutação proporciona uma busca aleatória no AG, oferecendo oportunidade para que mais pontos do espaço de busca sejam avaliados [126].

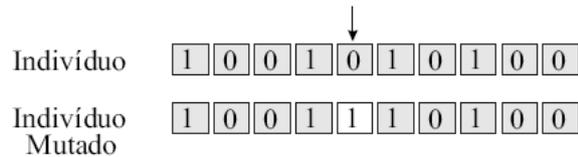


Figura 4.5: Exemplo de mutação em Algoritmos Genéticos (modificado de [12]).

4.2.2 Parâmetros da evolução do AG

Os parâmetros que mais influenciam o desempenho do Algoritmo Genético são [126] [127]:

- **Tamanho da população:**

Este parâmetro afeta o desempenho global e a eficiência dos Algoritmos Genéticos. Uma população muito pequena oferece uma pequena cobertura do espaço de busca, causando uma queda no desempenho. Uma população suficientemente grande fornece uma melhor cobertura do domínio do problema e previne a convergência prematura para soluções locais. Entretanto, com uma grande população tornam-se necessários mais recursos computacionais ou um tempo maior de processamento do problema. Sendo assim, é recomendável optar por um ponto de equilíbrio no que diz respeito ao tamanho escolhido para a população;

- **Taxa de cruzamento:**

É a probabilidade de um indivíduo ser recombinado com outro. Quanto maior for esta taxa, mais rapidamente novas estruturas serão introduzidas na população. Entretanto, isto pode gerar um efeito indesejável, pois a maior parte da população será substituída, causando assim perda de variedade genética, podendo ocorrer perda de estruturas de alta aptidão e convergência a uma população com indivíduos extremamente parecidos, indivíduos estes de solução boa ou não. Mas, com um valor baixo para a taxa de cruzamento, o algoritmo pode ficar muito lento para atingir uma boa solução;

- **Tipo de cruzamento:**

O tipo de cruzamento a ser utilizado determina a forma como será realizada a troca de genes entre os cromossomos selecionados para o cruzamento;

- **Taxa de mutação:**

É a probabilidade do conteúdo de cada gene do cromossomo ser alterado. A taxa de mutação diminui a probabilidade da população ficar estagnada em um valor e aumenta a probabilidade de alcançar qualquer ponto do espaço de busca. Porém, deve-se evitar uma taxa de mutação muito alta, uma vez que esta pode tornar a busca essencialmente aleatória, prejudicando, assim, a convergência para uma solução ótima;

- **Número de gerações:**

Representa o número total de ciclos de evolução de um Algoritmo Genético, sendo este um dos critérios de parada do algoritmo genético;

- **Diversidade populacional:**

A diversidade populacional está relacionada com a variabilidade genética dos indivíduos da população: quanto maior a diversidade, maior será o espalhamento das possíveis soluções no espaço de busca;

- **Pressão seletiva:**

A pressão seletiva é o grau que os melhores indivíduos são favorecidos. Ela determina a velocidade e a “direção” que o AG vai seguir no espaço de busca. Sem este fator, o AG iria se comportar como um algoritmo de busca aleatório, sem “direção”. A pressão seletiva depende da medida de aptidão e do método de seleção adotado e, ainda, ela modula o grau de privilégio de um indivíduo para sobreviver e reproduzir em detrimento dos demais. Quando a aptidão de alguns indivíduos da população difere muito em relação a outros, é dito que a pressão seletiva é grande. Caso contrário, isto é, se as aptidões dos indivíduos são próximas, diz que a pressão seletiva é pequena.

4.3 Evolução Diferencial

O algoritmo Evolução Diferencial (ED) pertence à classe de Algoritmos Evolucionários e foi descrito por Storn e Price [132] [133]. Este algoritmo é baseado na evolução dos indivíduos de uma população, que engloba soluções potenciais para os problemas de otimização utilizando operadores genéticos que são escolhidos para conduzir a evolução para as melhores soluções [134].

O ED é um algoritmo de otimização que cria uma nova solução de candidatos pela combinação de diversos indivíduos da mesma população. Um candidato substitui o anterior apenas se o resultado daquele for melhor [134] [135]. O ED utiliza os mesmos operadores genéticos do AG: mutação, cruzamento e seleção. O conjunto de regras dos operadores genéticos é utilizado para garantir que exista a possibilidade de se obter soluções melhores e cobrir, suficientemente, o espaço das possíveis soluções para maximizar a probabilidade de encontrar um resultado global ótimo.

Durante a inicialização do algoritmo, a população de NP indivíduos, cada um deles com dimensão D (número de variáveis de decisão que serão utilizadas no problema de otimização), é gerada aleatoriamente dentro do espaço de busca.

A população do ED consiste de vetores $\mathbf{X}_{i,G}$ de tamanho NP, onde $i = 1, 2, \dots, NP$ para cada geração G. Em cada uma das gerações, são aplicados nesta população os três operadores genéticos explicados na seção anterior: mutação, cruzamento e seleção.

4.3.1 Mutação

No estágio de *mutação*, o ED introduz um novo operador aritmético que depende da diferença de dois indivíduos selecionados aleatoriamente (Equação 4.1).

$$v_{i,G+1} = x_{r1,G} + F * (x_{r2,G} - x_{r3,G}) \quad (4.1)$$

Onde os índices $r1, r2$ e $r3 \in [1, NP]$. É importante observar que os índices devem ser diferentes uns dos outros e, também, devem ser diferentes do i atual. Desta forma, a população do ED deve ser constituída sempre por, no mínimo, quatro indivíduos.

Nesta etapa, é calculada uma diferença entre 2 vetores aleatórios (x) selecionados da população. Esta diferença é multiplicada por um de peso fixo, $F \in [0, 2]$ que controla a amplificação da diferença entre $x_{r2,G} - x_{r3,G}$. Esta diferença é adicionada a um terceiro vetor randomicamente selecionado da população, gerando um vetor mutante \mathbf{v} [132] [133] [134].

É importante observar que, quanto menor for a diferença entre os vetores representados pelos índices $r2$ e $r3$, menor será a alteração no vetor diferença e, conseqüentemente, menor será a perturbação na população. Isto significa que, se a população estiver alcançando o ótimo global, o algoritmo se auto-ajustará para alcançar a solução desejada.

4.3.2 Cruzamento

Após a *mutação*, o *cruzamento* é realizado entre os vetores (\mathbf{X}) e o vetor mutante (\mathbf{V}) (Figura 4.6), resultando no vetor \mathbf{U} .

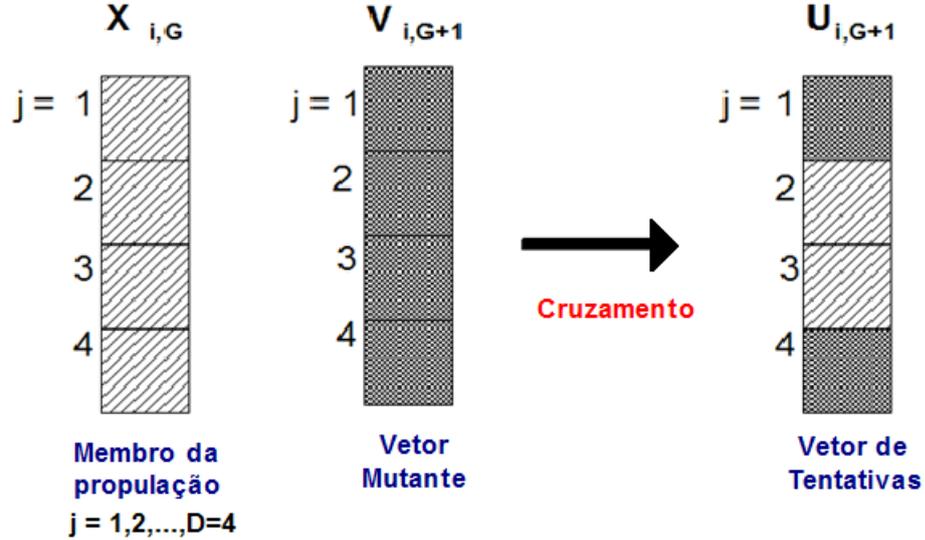


Figura 4.6: Evolução Diferencial: exemplo de um processo de cruzamento para $D = 4$ (modificado de [13]).

O vetor \mathbf{U} é formado de acordo com o esquema proposto por 4.3 (Equação 4.2).

$$u_{i,G+1} = (u_{1,G+1}, u_{2,G+1}, \dots, u_{D,G+1}) \quad (4.2)$$

A probabilidade de cruzamento é determinada pela constante de cruzamento (CR), e o seu objetivo é trazer diversidade para a população original [136].

$$U_{ji,G+1} = \begin{cases} V_{ji,G+1} & \text{se } (r(j) \leq CR \text{ ou } j = rn(i)) \\ X_{ji,G} & \text{se } (r(j) > CR \text{ ou } j \neq rn(i)) \end{cases} \quad (4.3)$$

Onde:

- $r(j)$ é a j ésima avaliação de um gerador de números aleatórios uniforme com resultados compreendidos dentro do intervalo $[0, 1]$;
- $rn(i) \in (1, 2, \dots, D)$, é um índice escolhido aleatoriamente, que garante que $U_{i,G+1}$ tenha, no mínimo, um parâmetro de $V_{i,G+1}$ [132];

- CR é a taxa de cruzamento $\in [0, 1]$. Esta taxa representa a porcentagem de genes de cada indivíduo que irá realizar o cruzamento. Quando $CR = 0$, significa que não haverá cruzamento.

No algoritmo da ED, existem algumas configurações que podem ser utilizadas para os estágios de mutação e cruzamento [132]:

- Especificação do vetor que irá sofrer a mutação. Este vetor pode ser aleatoriamente escolhido ou ser o melhor membro da população, isto é, aquele que está mais próximo da solução ótima;
- Especificação da quantidade de vetores que serão utilizados na operação de mutação e cruzamento;

4.3.3 Seleção

Na última etapa, chamada *seleção*, os vetores \mathbf{U} , resultantes do *cruzamento*, irão substituir o seu predecessor se eles estiverem mais perto da solução ótima, isto é, se eles tiverem uma aptidão maior do que o vetor $x_{ji,G}$, eles irão substituir estes vetores na geração $G + 1$.

De acordo com a literatura científica, a Evolução Diferencial mostrou ser efetiva em diversos problemas clássicos de otimização, e mostrou ser mais eficiente do que técnicas de Algoritmos Genéticos [135] [136]. Entretanto, a sua capacidade de encontrar o global ótimo depende muito da escolha das variáveis de controle F e CR [13]. Diversos estudos já realizados, [134] [13] [136] detectaram um comportamento indesejado do algoritmo ED, na situação em que 100% da população fica presa em uma base de atração de algum máximo local, não atingindo o ótimo global. Para diminuir a probabilidade deste tipo de comportamento, no Capítulo 6 será apresentada uma proposta de um algoritmo de Evolução Diferencial com Seleção Probabilística (EDSP).

4.4 Conclusão

Neste capítulo apresentou-se os conceitos de Computação Evolucionária com destaque para o algoritmo de Evolução Diferencial, que será utilizado nesta pesquisa. Conforme foi

citado, o ED apresenta um comportamento indesejado quando toda a população fica presa em uma base de atração (máximo ou mínimo local). Uma modificação no algoritmo ED foi proposta com a finalidade de melhorar o resultado da otimização, considerando os casos de otimização multimodal em que existem diversos locais máximos e mínimos. Assim, foi realizada uma modificação no estágio de seleção dos membros da população, resultando no algoritmo Evolução Diferencial com Seleção Probabilística (EDSP) - que será detalhado no Capítulo 6. No próximo Capítulo, será apresentada a técnica Agrupamento Espectral, que foi utilizada nesta pesquisa na etapa de agrupamento dos potenciais de ação de unidades motoras (MUAPs).

Capítulo 5

Agrupamento Espectral

5.1 Introdução

O processo de organização de dados em grupos significativos, denominado agrupamento, é um dos mais importantes e fundamentais métodos de aprendizado [137]. De forma geral, os objetivos de um agrupamento são:

- Dispor os dados em grupos, de forma que cada grupo seja homogêneo em relação a certas características, isto é, os objetos analisados, em cada grupo, devem ser similares uns aos outros;
- Cada grupo resultante de um procedimento de agrupamento deve ser diferente dos outros grupos, em relação às suas características, isto é, os objetos de um grupo devem ser diferentes dos objetos de outros grupos.

É importante ressaltar que a definição de similaridade ou homogeneidade depende, unicamente, do problema que está sendo analisado.

As próximas sessões irão apresentar os detalhes relevantes sobre agrupamentos, que são necessários para o entendimento desta pesquisa. Uma revisão completa sobre agrupamento pode ser encontrada em [138] [139].

5.2 Agrupamento

De acordo com Jain [140]:

“Um grupo é um conjunto no espaço, de forma que a distância entre dois pontos de um mesmo grupo é menor que a distância entre qualquer ponto desse grupo e qualquer ponto fora desse grupo.”

De modo geral, o agrupamento de dados envolve os seguintes passos [138]:

1. Representação dos dados: extração de características;
2. Definição de medidas de similaridade apropriadas para os dados;
3. Aplicação de uma técnica de agrupamento;
4. Abstração dos dados, isto é, rotulação dos dados apresentados;
5. Medição da qualidade do agrupamento produzido.

5.2.1 Representação dos dados: extração de características

No processo de agrupamento, a representação do dados e a extração de características irão depender do problema que está sendo analisado. Assim, não existe um guia para a escolha dos padrões e características apropriadas para uma situação específica [141].

Para a extração de características de um conjunto de dados, existem diversas técnicas descritas na literatura, como por exemplo, PCA (*Principal Component Analysis*) [137], *Nonlinear Principal Component Analysis* [142] e Escala Multidimensional [143]. Entretanto, é necessária uma análise detalhada do tipo dos dados que é objeto do estudo para definir qual técnica deverá ser aplicada para a extração das características relevantes para o agrupamento.

5.2.2 Medidas de similaridade

Os algoritmos de agrupamento identificam a similaridade entre os objetos de um conjunto e, seguindo algum critério, determinam em que grupo cada um destes objetos deve ser alocado. Essa semelhança é computada através da medição da distância ou similaridade entre os objetos.

Para cada objeto que será agrupado, geralmente é associado um vetor com n dimensões pertencente ao espaço n , onde cada dimensão representa uma das características que

descrevem este objeto. Deste modo, as medidas de similaridade dos objetos são calculadas em função destes vetores de características.

Existem na literatura referências ao uso de diversas medidas de similaridade ou distância usadas no agrupamento de dados, como por exemplo, Distância Euclidiana, Cosseno do ângulo ϑ [144], Métrica de Minkowski [143], Distância de Manhattan, Distância de Mahalanobis, Correlação de Pearson [144] e Divergência de Bregman [143]. Entretanto, as duas medidas mais utilizadas para o cálculo da similaridade entre os objetos que serão agrupados são a Distância Euclidiana e o Cosseno do ângulo ϑ .

Desta forma, utilizando medidas de similaridade, é possível definir o conceito de *Matriz de Similaridade ou Distâncias*, que são matrizes que contém os índices de proximidade entre os pares de objetos representados por seus atributos. Essas matrizes geralmente são simétricas e seus elementos se referem ao coeficiente de similaridade entre os objetos ou o grau de dissimilaridade (distância) entre eles [145]. Sendo assim, temos:

- **Matriz de Similaridades S**

$$S_{ij} = \begin{cases} \psi(x_i, x_j) & \text{se } i \neq j \\ 1 & \text{se } i = j \end{cases} \quad (5.1)$$

Onde:

- $\psi(x_i, x_j)$ é o grau de similaridade entre x_i e x_j ;
- $\psi = \frac{1}{1+\xi}$, sendo ξ uma função de distância.

- **Matriz de Distâncias**

$$D_{ij} = \begin{cases} \xi(x_i, x_j) & \text{se } i \neq j \\ 0 & \text{se } i = j \end{cases} \quad (5.2)$$

Onde: $\xi = 1 - \psi$;

Assim, a representação dos objetos através dessas matrizes está diretamente relacionada à similaridade ψ ou à distância D_{ij} entre esses objetos.

5.2.3 Medidas de avaliação da qualidade do agrupamento

As técnicas de agrupamento, geralmente, não possuem nenhuma informação sobre os possíveis grupos que compõem os dados em análise. Isto torna mais complexa a tarefa de avaliar o comportamento do algoritmo de agrupamento e a qualidade dos seus resultados. A avaliação dos resultados deve considerar tanto a qualidade do agrupamento quanto a qualidade de cada um dos grupos formados. Este tipo de análise é necessária, pois é possível obter um bom resultado global e ao mesmo tempo um ou mais grupos que não apresentem um adequado particionamento dos dados. E ainda, é possível obter um agrupamento em que alguns grupos tenham um particionamento adequado dos dados e, ao mesmo tempo, a medida de qualidade global não seja elevada.

De forma geral, as medidas de avaliação podem ser classificadas em dois grupos: Medidas externas (supervisionadas) e medidas internas (não supervisionadas) [144].

5.2.3.1 Medidas Externas

Para a utilização das Medidas Externas é necessário o conhecimento de um conjunto de dados, previamente classificados, para que se possa medir a qualidade dos resultados, comparando-os com os associados às classes existentes.

Existem na literatura várias Medidas Externas utilizadas para a avaliação de qualidade de um agrupamento. Algumas delas são: Entropia, pureza, Coeficiente Jaccard, acurácia Média, Estatística Rand, Índice Fowlkes e Mallows [146]. Essas medidas são usadas para medir a similaridade entre diferentes conjuntos de dados. Neste caso, significa medir o quão similares são as classes de um conjunto de dados pré-classificados com os grupos formados após o agrupamento do mesmo conjunto. Assim, se os grupos forem similares às classes pré-definidas, isto significa que o algoritmo de agrupamento atingiu um bom resultado.

5.2.3.2 Medidas Internas

As medidas internas, geralmente, procuram estabelecer uma relação entre a distribuição dos objetos dentro de cada grupo (representando a coesão do grupo), e a distribuição dos objetos ao longo de todos os grupos (mostrando a separação entre os grupos). Um bom agrupamento é aquele que apresenta uma alta coesão entre os objetos de um mesmo grupo (os objetos de um grupo são altamente similares) e tem uma alta separação (os grupos

formados são distintos).

Várias medidas baseiam-se neste conceito, tais como coeficiente de Silhueta (SC) e os índices Dunn e Davies-Bouldin [146] [138]. Entretanto, é importante ressaltar que a técnica utilizada para medir a qualidade interna de um grupo dependerá das características dos dados da aplicação que está sendo analisada.

5.2.4 Técnicas de Agrupamento

Os algoritmos de agrupamento podem ser classificados de acordo com a abordagem utilizada para a geração dos grupos e a forma como são apresentados os resultados [140].

Em [138] é apresentada uma organização dos algoritmos de agrupamento em duas categorias principais: algoritmos hierárquicos e algoritmos de particionamento. Entretanto, nos últimos anos, tem sido pesquisado um outro tipo de agrupamento: Agrupamento Espectral. Esta técnica será utilizada nesta pesquisa e está detalhada na sessão a seguir.

5.3 Agrupamento Espectral

O desafio de encontrar os melhores grupos em um conjunto de dados tem sido o foco de diversas pesquisas na área de reconhecimento de padrões. Nesse sentido, a técnica Agrupamento Espectral (do inglês, *Spectral Clustering*) tem se consagrado, nos últimos anos, como um dos melhores métodos de agrupamento [147] [148]. A razão para isto pode ser atribuída à sua generalidade, eficiência e à rica fundamentação teórica [149].

O Agrupamento Espectral pode ser aplicado em qualquer tipo de dados que possuem alguma medida de similaridade e pode ser calculado para milhões de pontos [150]. E ainda, o Agrupamento Espectral possui a vantagem adicional de determinar, automaticamente, o número de grupos de um conjunto de dados, baseado nos autovetores da matriz de similaridade [151].

O termo espectral refere-se ao fato de que o problema a ser resolvido toma a forma de um problema de autovalor. A escolha dos autovetores é o ponto que diferencia a maioria dos algoritmos do Agrupamento Espectral. Alguns algoritmos escolhem um autovetor que divide um conjunto em dois grupos, e assim procedem sucessivamente até encontrar o número desejado de grupos. Outros algoritmos escolhem o número de autovetores que corresponde ao número desejado de grupos e aplica o agrupamento diretamente sobre a

matriz formada por estes vetores [152] [153].

Dado um conjunto de pontos, a matriz de similaridade pode ser definida como sendo uma matriz S_{ij} , a qual representa a medida de similaridade entre os pontos. O Agrupamento Espectral utiliza o espectro da matriz de similaridade dos dados para realizar a redução da dimensão e agrupar os dados em dimensões menores.

A idéia principal do Agrupamento Espectral é converter um problema de agrupamento em um problema de partição de grafos, ou seja, os dados são representados na forma de grafos, através da Matriz de Adjacências. Considere n como sendo a quantidade de dados que serão agrupados. Considere, também, $\mathbf{W} = [w_{i,j}]_{n \times n}$ sendo a matriz peso, onde cada $w_{i,j}$ é a similaridade entre dois dados. Desta forma, o problema de agrupamento pode ser formulado como um problema de corte (Equação 5.3):

$$q^* = \underset{q \in \{-1, 1\}^n}{\text{argmin}} \sum_{i,j=1}^n w_{i,j} (q_i - q_j)^2 = q^T \mathbf{L} \mathbf{q} \quad (5.3)$$

Onde:

- $q = (q_1, q_2, \dots, q_n)$ é um vetor para membros binários e cada q_i pode ser -1 ou 1;
- \mathbf{L} é matriz Laplaciana, definida por: $\mathbf{L} = \mathbf{D} - \mathbf{W}$, onde $\mathbf{D} = [d_{i,i}]_{n \times n}$ é a Matriz Diagonal e cada elemento $d_{i,i} = \sum_{j=1}^n w_{i,j}$.

Grafos são estruturas abstratas compostas por um par de conjuntos representando seus vértices e suas arestas. Um vértice pode ser definido como sendo a unidade fundamental, e é a partir deles que os grafos são formados. Uma aresta é um segmento que conecta dois vértices em um grafo. Um grafo pode ser expresso por $G = (\nu, \varepsilon)$, sendo $\nu = v_1, v_2, \dots, v_v$ seu conjunto de vértices, com cardinalidade $|\nu| = V$, que representa sua ordem, e $\varepsilon = e_1, e_2, \dots, e_E$ seu conjunto de arestas, com cardinalidade $|\varepsilon| = E$, que define o seu tamanho.

Existem diferentes maneiras de se representar matematicamente um grafo \mathbf{G} , porém a mais comum é a representação matricial através de sua Matriz de Adjacências. A Matriz de Adjacências é uma matriz quadrada da ordem do grafo, onde os elementos que não pertencem à diagonal principal representam a quantidade de arestas do vertice v_i ao vértice v_j [154].

A tarefa de agrupamento no contexto da teoria dos grafos é conhecida por particionamento de grafos [155] e tem por objetivo particionar o grafo em grupos disjuntos de vértices, de acordo com suas similaridades. Para tanto, é considerada a estrutura de suas

arestas, de modo que existam muitas arestas dentro de cada grupo e relativamente poucas arestas entre os grupos, ou ainda, que a soma dos pesos das arestas dentro dos grupos sejam maiores do que a soma dos pesos das arestas presentes entre os grupos.

Para resolver o problema de particionamento de grafos pode-se utilizar duas abordagens distintas: bi-particionamento ou multi-particionamento. A abordagem de bi-particionamento consiste em particionar o conjunto de vértices ν do grafo $G = (\nu, \varepsilon)$ em dois grupos disjuntos, P_1 e P_2 , satisfazendo $\nu = P_1 \cup P_2$ e $P_1 \cap P_2 = 0$. Por outro lado, a abordagem de multi-particionamento tem por objetivo tomar o conjunto de vértices ν do grafo $G = (\nu, \varepsilon)$ e dividí-lo em g grupos disjuntos P_1, P_2, \dots, P_g tal que $|P_i| = p$, $i = 1, 2, \dots, g$ e $V = p * g$, satisfazendo $\nu = P_1 \cup P_2 \cup \dots \cup P_g$ e $0 = P_1 \cap P_2 \cap \dots \cap P_g$. Quando o objetivo é dividir o grafo em g grupos disjuntos, pode-se utilizar tanto o bi-particionamento quanto o multi-particionamento, sendo que no primeiro caso o bi-particionamento é aplicado recursivamente.

Medidas de Avaliação:

Existem diversas medidas de avaliação para avaliar a qualidade do particionamento de um grafo em grupos disjuntos de vértices. Essas medidas podem ser usadas na identificação dos grupos, na escolha de um melhor esquema de particionamento ou na comparação entre diferentes abordagens de particionamento.

As medidas mais utilizadas são baseadas em critérios de conectividade do grafo, mais especificamente em critérios de corte. São elas [155]:

1. Corte mínimo

Uma das funções mais populares utilizadas para otimizar o particionamento de grafos é o Corte Mínimo [156], que tem como objetivo encontrar grupos de vértices cuja quantidade de arestas que conectam os grupos entre si seja mínima (Equação 5.4):

$$\zeta_{cmin}(P_1, \dots, P_g) = \sum_{i=1}^g \phi(P_i, \bar{P}_i) \quad (5.4)$$

Um problema com a abordagem do corte mínimo é que esta não considera o tamanho de cada grupo, o que pode conduzir a grupos de tamanhos não-balanceados, isto

é, grupos que possuem quantidades de membros muito diferentes uns dos outros. Uma maneira de driblar esta inconveniência é impor algumas restrições como, por exemplo, requerer que os grupos sejam razoavelmente grandes. Para isso, foram propostas outras soluções: corte médio, corte normalizado e corte mínimo-máximo [157] [158] [159], apresentadas a seguir.

2. Corte médio

O Corte Médio [160] tenta impor a restrição do tamanho dos grupos utilizando o tamanho do grupo $|P_i|$ como fator de balanceamento:

$$\zeta_{cMedio}(P_1, \dots, P_g) = \sum_{i=1}^g \frac{\phi(P_i, \bar{P}_i)}{|P_i|} \quad (5.5)$$

O objetivo do Corte Medio é gerar grupos de vértices cuja quantidade de arestas intergrupos é normalizada pelo tamanho do grupo $|P_i|$. Entretanto, um método mais robusto de particionamento de grafos deveria levar em consideração as conexões intra-grupos e, também, as conexões intergrupos. Esta característica é levada em consideração na formulação das duas medidas que serão apresentadas seguir.

3. Corte normalizado

O Corte Normalizado [159] utiliza o número de arestas $\phi(P_i, \nu)$ como fator de normalização para impor restrição ao volume dos grupos:

$$\zeta_{cNorm}(P_1, \dots, P_g) = \sum_{i=1}^g \frac{\phi(P_i, \bar{P}_i)}{\phi(P_i, \nu)} \quad (5.6)$$

Neste caso, a restrição utilizada por ζ_{cNorm} utiliza o número de arestas $\phi(P_i, \nu)$ para balancear os grupos. Ou seja, enquanto aquele tem como ponto de referência os vértices dos grupos, este utiliza as arestas como referencial. Para levar em consideração as conexões intergrupos, o numerador da medida deve ser minimizado, enquanto seu denominador deve ser maximizado para atender as conexões intragrupos. O fator de normalização representa os graus dos vértices internos ao grupo.

4. Corte mínimo-máximo

O Corte Mínimo-Máximo [157] tenta minimizar as similaridades inter-grupos e maximizar as similaridades intra-grupos ao mesmo tempo:

$$\zeta_{cMinMax}(P_1, \dots, P_g) = \sum_{i=1}^g \frac{\phi(P_i, \bar{P}_i)}{\phi(P_i, P_i)} \quad (5.7)$$

A restrição utilizada por $\zeta_{cMinMax}$ utiliza o número de arestas $\phi(P_i, \bar{P}_i)$ para balancear os grupos. Para levar em consideração as conexões intergrupos, o numerador da medida deve ser minimizado, enquanto seu denominador deve ser maximizado para atender as conexões intragrupos.

De acordo com [157], se os grupos são bem separados, as equações 5.5, 5.6 e 5.7 conseguem capturar as características dos grupos e dão resultados similares e precisos. Porém, quando os grupos são marginalmente separados, apenas o Corte Normalizado e o Corte Mínimo-Máximo conseguem bons resultados. E no caso onde há significativa sobreposição entre os grupos, o Corte Mínimo-Máximo tem por característica apresentar grupos mais balanceados e compactos.

O problema de minimizar essas funções de avaliação foi provado ser NP-difícil, devido à sua natureza combinatória [159] [155]. Desta forma, a solução desse problema por meio das abordagens espectrais é uma alternativa viável, pois o problema de particionamento é convertido em um problema de autovalor, e a solução aproximada é dada através da utilização de ferramentas de álgebra linear [161].

Como a minimização dessas funções é um problema da classe NP-difícil, a estratégia utilizada para minimizá-las será transformar o problema original de otimização discreta em um outro problema aproximado, o de otimização contínua. Para isso, considere $y_i = [y_{i1}, y_{i2}, \dots, y_{in}]$ como sendo o vetor indicador de um grupo P_i , onde cada um dos seus elementos y_{ij} assume um valor binário indicando se o j -ésimo elemento do conjunto de dados pertence ou não a P_i (Equação 5.8):

$$y_{ij} = \begin{cases} 1 & \text{se } (j \in P_i) \\ -1 & \text{se } (j \notin P_i) \end{cases} \quad (5.8)$$

Assim, a tarefa de encontrar os grupos que minimizam as medidas de avaliação é reformulada como um problema de otimização que tenta encontrar os g vetores indicadores

$[y_1, y_2, \dots, y_g]$ com elementos binários que minimizam aquelas medidas. Para solucionar este problema, pode ser utilizado o teorema do Quociente de Rayleigh, considerando que diminua a restrição que permite apenas valores binários nos elementos dos vetores indicadores y_i , de modo que passem a permitir valores reais.

Segundo o teorema de Rayleigh [155], dada uma matriz real e simétrica $A = A^T$, o Quociente de Rayleigh de \mathbf{A} é representado pela equação 5.9.

$$\psi_A(u) = \frac{u^T A u}{u^T u} \quad (5.9)$$

A equação 5.9 é minimizada pelo autovetor u_1 correspondente ao menor autovalor α_1 , e seu valor mínimo é dado por λ_1 (Equação 5.10).

$$\forall u_i, \lambda_1 \leq \psi(u_i) \leq \lambda_n \quad (5.10)$$

Onde:

- $\psi_A(u_1) = \lambda_1$;
- $\psi_A(u_n) = \lambda_n$
- Os autovalores de A são colocados em ordem crescente: $\lambda_1 \leq \lambda_2 \dots \leq \lambda_n$
- u_i são os autovetores correspondentes.

Dessa forma, de acordo com [161], através do vetor indicador y_i , é possível derivar as seguintes igualdades em relação à função ϕ :

$$|P_i| = y_i^T y_i \quad (5.11)$$

$$\phi(P_i, P_j) = y_i^T A y_j \quad (5.12)$$

$$\phi(P_i, \nu) = y_i^T K y_i \quad (5.13)$$

$$\phi(P_i, \bar{P}_j) = y_i^T (K - A) y_i = y_i^T L y_i \quad (5.14)$$

$$\phi(P_i, P_i) = y_i^T A y_i \quad (5.15)$$

$$\phi(\nu, \nu) = q^T A q \quad (5.16)$$

Os métodos espectrais geralmente apresentam bons resultados porque a solução ótima do problema relaxado, associado ao problema de agrupamento original, é calculada globalmente. A Tabela ?? resume a formulação espectral dos critérios de particionamento apresentados, de acordo com o Teorema de Rayleigh.

Tabela 5.1: Formulação matemática utilizada para a otimização das medidas de avaliação de particionamento de grafos.

Medida de Avaliação	de	Critério a ser minimizado	Forma Matricial	Problema de Autovalor
Corte mínimo		$\zeta_{cmin}(P_1, \dots, P_g) = \sum_{i=1}^g \phi(P_i, \bar{P}_i)$	$\sum_i y_i^T L y_i$	$L y_i = \lambda_i y_i$
Corte médio		$\zeta_{cMedio}(P_1, \dots, P_g) = \sum_{i=1}^g \frac{\phi(P_i, \bar{P}_i)}{ P_i }$	$\sum_i \frac{y_i^T L y_i}{y_i^T y_i}$	$L y_i = \lambda_i y_i$
Corte Normalizado		$\zeta_{cNorm}(P_1, \dots, P_g) = \sum_{i=1}^g \frac{\phi(P_i, \bar{P}_i)}{\phi(P_i, \nu)}$	$\sum_i \frac{y_i^T L y_i}{y_i^T K y_i}$	$L y_i = \lambda_i K y_i$
Corte Mínimo-Máximo		$\zeta_{cNorm}(P_1, \dots, P_g) = \sum_{i=1}^g \frac{\phi(P_i, \bar{P}_i)}{\phi(P_i, P_i)}$	$\sum_i \frac{y_i^T L y_i}{y_i^T A y_i}$	$L y_i = \lambda_i K y_i$

5.3.1 Análise Espectral de Grafos

De acordo com a Teoria Espectral dos Grafos, o espectro de um grafo \mathbf{G} é a lista de autovalores de sua Matriz de Adjacências. A importância da análise espectral dos grafos se deve ao fato de que muitas propriedades importantes de um grafo podem ser expressas por meio dos seus autovalores, que é o seu espectro [156] [145] [162]

O espectro de uma matriz \mathbf{M} é composto pelos seus autovalores. Seja λ um autovalor de \mathbf{M} e \mathbf{u} o seu correspondente autovetor (Equação 5.17):

$$\mathbf{M}\mathbf{u} = \lambda\mathbf{u} \Leftrightarrow \mathbf{u}^T \mathbf{M}\mathbf{u} = \lambda \quad (5.17)$$

No caso de serem considerados todos os autovalores e correspondentes autovetores da matriz \mathbf{M} , a equação 5.17 pode ser escrita da seguinte forma:

$$\mathbf{M}\mathbf{U} = \Lambda\mathbf{U} \Leftrightarrow \mathbf{U}^T \mathbf{M}\mathbf{U} = \Lambda \quad (5.18)$$

Onde:

- \mathbf{U} é a matriz de autovetores u_i ;
- Λ é a matriz diagonal com os respectivos autovalores λ_i .

Assim, a partir da análise espectral de um grafo, é possível estimar, também, a quantidade de grupos distintos que estão presentes nele, conforme será descrito na próxima seção.

5.3.2 Estimando a quantidade de grupos

A quantidade de grupos que deverão ser extraídos através do algoritmo de agrupamento, geralmente, é configurada manualmente [163] [164] e não existem muitas pesquisas que investigam uma forma de configurá-lo automaticamente.

Entretanto, os pesquisadores *Perona et al.* [165] desenvolveram uma técnica de Agrupamento Espectral capaz de descobrir, automaticamente, a quantidade de grupos existentes em um conjunto de dados, através da análise dos autovetores.

Considerando que a matriz de afinidade L seja definida por:

$$L = D^{-\frac{1}{2}}AD^{-\frac{1}{2}} \quad (5.19)$$

Onde: D é a matriz diagonal $D_{ii} = \sum_{j=1}^n A_{ij}$.

Considerando, também, que L é um bloco diagonal com blocos $L^{(c)}$, $c = 1, \dots, C$, e os autovalores dos blocos são diferentes, cada autovetor assumirá valores diferentes de zero:

$$\hat{X} = \begin{pmatrix} x^{(1)} & \vec{0} & \vec{0} \\ \vec{0} & \dots & \vec{0} \\ \vec{0} & \vec{0} & x^{(c)} \end{pmatrix} \quad (5.20)$$

Onde: $x^{(c)}$ é um autovetor da sub-matriz $L^{(c)}$ correspondente ao grupo c .

Para cada possível grupo C , é realizada a rotação que melhor alinha as colunas de \hat{X} com as coordenadas canônicas do sistema. Sendo $Z \in R^{n \times C}$ a matriz obtida após rotacionar a matriz de autovetores \hat{X} , isto é, $Z = X R$, e $M_i = \max Z_{ij}$. Agora, é necessário

recuperar a rotação R para cada linha em Z que tenha no máximo uma entrada diferente de zero. Desta forma, temos a seguinte função custo:

$$J = \sum_{i=1}^j \sum_{j=1}^c \frac{Z_{ij}^2}{M_i^2} \quad (5.21)$$

Minimizando a função custo em todas as possíveis rotações, obtém-se o melhor alinhamento com as coordenadas canônicas do sistema. A quantidade de grupos é aquela gerada pelo custo mínimo. Caso vários grupos tiverem praticamente o mesmo custo mínimo, o maior custo será selecionado.

O algoritmo proposto por *Perona et Al.* [165] para estimar a quantidade de grupos em um conjunto de dados, baseado em Agrupamento Espectral, contempla os seguintes passos:

- **Entrada: Conjunto de dados $S = S_1, \dots, S_n$ que serão agrupados.**

1. Calcular a escala local σ_i para cada ponto $s_i \in S$, onde: $\sigma_i = d(s_i, s_k)$;
2. Construir a matriz de similaridade A, onde: $A_{ij} = \exp\left(\frac{-s^2(s_i, s_j)}{\sigma_i \sigma_j}\right)$;
3. Definir a matriz diagonal D, onde: $D_{ij} = \sum_{j=1}^n A_{ij}$;
4. Construir a matriz normalizada L, onde $L = D^{-0.5} A D^{-0.5}$;
5. Encontrar x_1, \dots, x_c , sendo C o maior autovetor de L e formar a matriz $X = [x_1, \dots, x_c]$, onde C é o maior grupo possível;
6. Recuperar a rotação R a qual melhor alinha as colunas de X com as coordenadas canônicas do sistema;
7. Calcular o custo do alinhamento para cada grupo, até C, de acordo com a equação: $J = \sum_{i=1}^n \sum_{j=1}^c \frac{Z_{ij}^2}{M_i^2}$;
8. Configurar o número final de grupos para C, sendo C o grupo que possui o menor custo de alinhamento.

- **Saída: quantidade de grupos existentes no conjunto de dados S.**

Para o estágio de agrupamento dos potenciais de ação de unidade motora (MUAP), o algoritmo proposto por *Perona et Al.* [165] será utilizado para definir quantos padrões morfológicos distintos de MUAPs existem no sinal EMG e, em seguida, será utilizado um algoritmo de Agrupamento Espectral para classificar cada MUAP em um determinado grupo, de acordo com o seu padrão morfológico.

5.3.3 Algoritmos para Agrupamento Espectral

Os algoritmos de Agrupamento Espectral são técnicas que lidam com o problema de agrupamento utilizando um processo de duas fases. Na primeira, o problema é relaxado em uma versão que aborda um problema clássico de autovalor. Na segunda fase, a solução do problema de autovalor (versão relaxada) é convertida em uma solução discreta.

O que torna os métodos de Agrupamento Espectral mais interessantes é o fato de que seu ótimo global em um domínio contínuo relaxado é obtido através de auto-decomposição, ou seja, através da solução de um problema de autovalor. Desta forma, os autovetores são tratados como coordenadas geométricas do conjunto de dados.

De maneira geral, qualquer algoritmo de Agrupamento Espectral é composto por três etapas:

1. **Pré-processamento:**

É responsável por construir a Matriz de Similaridades entre os dados e gerar o grafo de similaridades referente a ela;

2. **Representação Espectral:**

Na etapa de representação espectral, a Matriz Laplaciana associada ao grafo de similaridades é gerada, e seus autovalores e autovetores são calculados. Em seguida, os elementos do conjunto de dados são mapeados em uma representação de menor dimensionalidade, baseada em um ou mais autovetores.

3. **Agrupamento:**

Na etapa de Agrupamento é realizada a divisão dos elementos em grupos distintos (dois ou mais), atribuindo a cada um dos elementos um rótulo que identifique a que grupo ele pertence.

Na literatura, existem diversas variações para algoritmos de Agrupamento Espectral. Muitos autores utilizam a normalização da Matriz Laplaciana e outros não. Existem vários argumentos que defendem a utilização da versão normalizada da Matriz Laplaciana ao invés de sua versão não normalizada [152]. Um desses argumentos é que aquela implementa tanto a minimização inter-grupos quanto a maximização intra-grupos [145]. Um dos algoritmos de Agrupamento Espectral mais utilizados é o proposto por *Ng et al* [152], que contempla os seguintes procedimentos:

- **Entradas:**

- **Matriz de Similaridade;**
 - **Quantidade k de grupos que deverão ser formados;**
1. Definir matriz de Adjacências W;
 2. Definir a matriz diagonal D, onde o elemento (i,i) é a soma da linha i-ésima de W;
 3. Construir a matriz normalizada $L = D^{-0.5}WD^{-0.5}$
 4. Encontrar os primeiros autovetores u_1, u_2, \dots, u_k da matriz L;
 5. Construir a matriz U, que contém os vetores u_1, u_2, \dots, u_k como colunas;
 6. Construir a matriz T a partir da normalização de cada linha da matriz U:
$$t_{ij} = \frac{u_{ij}}{(\sum u_{ik}^2)^{\frac{1}{2}}};$$
 7. Para $i = 1, \dots, n$, considere Y_i como sendo o vetor correspondente à i-ésima linha de T;
 8. Executar o algoritmo k-means [140] nas linhas da matriz Y, agrupando os pontos (Y_i) $i=1, \dots, n$, em grupos C_1, \dots, C_k .

- **Saída:** grupos C_1, \dots, C_k

O algoritmo de Agrupamento Espectral Normalizado, proposto por Ng *et al* é que foi utilizado neste trabalho. As etapas em que ele foi utilizado, serão detalhadas no próximo capítulo.

5.4 Conclusão

Neste capítulo foram apresentados os conceitos fundamentais das técnicas de agrupamento, que são necessários para o leitor compreender o trabalho desenvolvido. E também, foram detalhadas as características do algoritmo Agrupamento Espectral, que será utilizado nesta pesquisa para realizar o agrupamento dos potenciais de ação de unidades motoras (MUAPs). No próximo capítulo será apresentada a arquitetura do sistema proposto nesta tese e, também, serão detalhados todos os passos que foram desenvolvidos para o projeto.

Capítulo 6

Projeto e implementação de um sistema de decomposição de sinais EMG de superfície

6.1 Introdução

Conforme visto no Capítulo 1, já foram desenvolvidos vários sistemas para a decomposição do sinal EMG coletado através de eletrodos invasivos. Entretanto, poucos esforços foram concentrados em pesquisas de decomposição do sinal EMG de superfície. A investigação e desenvolvimento de métodos para a decomposição de sinais EMG de superfície é essencial, visto que a coleta do sinal EMG utilizando eletrodos invasivos pode acarretar diversos inconvenientes para o paciente, inviabilizar terapias de Biofeedback para reforço muscular e pode ser muito dependente da habilidade do médico para a inserção da agulha no músculo.

Na área de processamento de sinais biológicos, a literatura científica apresenta diversos registros sobre a utilização de modelos gráficos-probabilísticos na área da neurociência, mais especificamente, na área de processamento do sinal EEG de superfície. Os pesquisadores [115] [37] [114] já obtiveram profícuos resultados com o processamento do sinal EEG utilizando, por exemplo, Modelos Ocultos de Markov.

Baseando-se no sucesso da utilização de modelos gráficos-probabilísticos para o processamento do sinal EEG, surgiu a inspiração de utilizar tais modelos para processar e decompor o sinal EMG de superfície.

Este capítulo apresenta a seqüência de métodos e técnicas que foram implementados para o desenvolvimento do modelo de decomposição de sinais eletromiográficos de superfície utilizando Modelo Oculto de Markov. O detalhamento completo do sistema é apresentado nas próximas seções.

6.2 Estrutura do sistema de decomposição de sinais EMG de superfície

Para desenvolver o sistema proposto, inicialmente foi necessário arquitetar uma estrutura para que o sistema fosse capaz de realizar o processamento (eliminação do ruído e detecção de MUAPs) e realizar a decomposição do sinal do sinal EMG de superfície.

Para a etapa de pré-processamento do sinal EMG, que engloba a aplicação de filtro para eliminação de possíveis ruídos e a detecção de MUAPs, foi utilizado o sistema EMG Decomposition System BR. Assim, o referido sistema já disponibiliza os MUAPs presentes no sinal EMG. Em seguida, de posse do conjunto de MUAPs detectados, utilizou-se o Modelo Oculto de Markov para agrupar os MUAPs de acordo com a similaridade morfológica entre eles. Assim, considerando que uma Unidade Motora gera um padrão único de padrão morfológico de MUAP, é possível determinar quantas Unidade Motoras estão ativas no sinal EMG e, também, apresentar o padrão morfológico do MUAP gerado por elas.

O projeto desenvolvido é parte integrante de um sistema híbrido para decomposição de sinais EMG: 1) EMG Decomposition BR® - responsável por realializar o pré-processamento dos sinais EMG; 2) Sistema de Decomposição de sinais EMG de superfície utilizando Modelo Oculto de Markov - que é o sistema desenvolvido neste trabalho. A Figura 6.1 apresenta o diagrama com a estrutura do sistema de decomposição de sinais EMG de superfície que foi desenvolvido, contendo todo o processo e a seqüência de técnicas que foram utilizadas na decomposição do sinal eletromiográfico, bem como as respostas que são apresentadas pelo sistema.

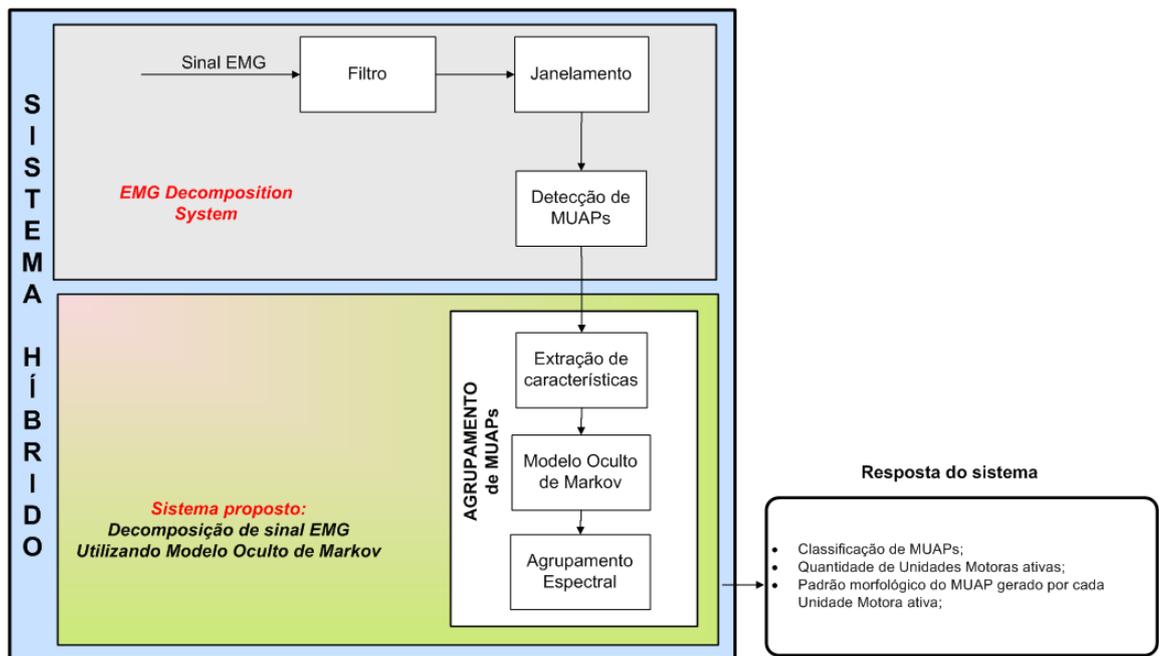


Figura 6.1: Diagrama de blocos da estrutura do sistema híbrido de decomposição de sinais EMG.

6.2.1 Sistema EMG-Decomposition-BR®

Conforme mencionado na seção anterior, este trabalho utiliza algumas das etapas de pré-processamento do sinal EMG do sistema de decomposição EMG Decomposition-BR®, desenvolvido no Laboratório de Engenharia Biomédica, da Universidade Federal de Uberlândia, que já foi apresentado no Capítulo 2 (Figura 6.2).

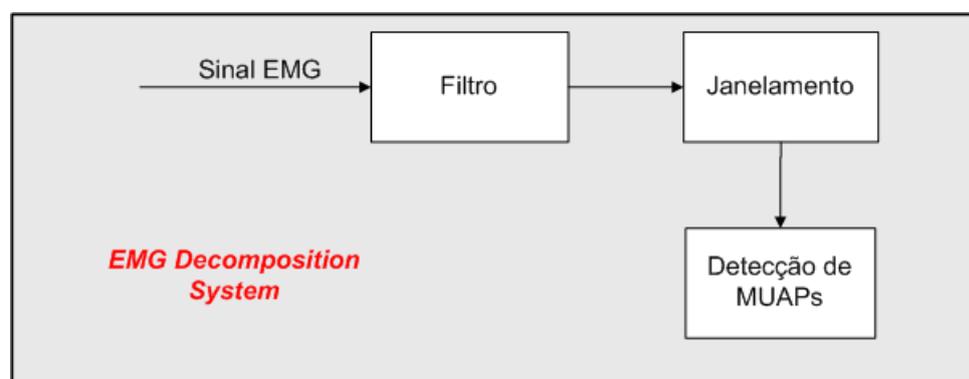


Figura 6.2: Diagrama de blocos das etapas de pré-processamento do sinal EMG realizadas pelo sistema EMG Decomposition BR®.

Para realizar as etapas de pré-processamento do sinal EMG, o EMG Decomposition-BR® executa as seguintes ações [5] [79] [80]:

1. Filtragem:

O sistema EMG Decomposition-BR® oferece duas opções de filtros: 1) *Butterworth*; 2) *Empirical Mode Decomposition*. Estes filtros tem como responsabilidade eliminar/suavizar os possíveis ruídos existentes no sinal EMG;

2. Janelamento retangular:

Após a filtragem do sinal EMG, o sistema EMG Decomposition-BR® fornece a opção de janelar de forma retangular o sinal que será processado, isto é, o usuário deverá selecionar o início e o final da atividade eletromiográfica que será processada no estágio seguinte. A escolha dessa região do sinal EMG é interessante e importante para o usuário, pois ele pode selecionar apenas a região do sinal EMG em que ele está interessado em fazer a decomposição;

3. Detecção de MUAPs:

Após o usuário selecionar a região do sinal EMG que deve ser processada pelo sistema, o EMG Decomposition-BR® realiza a detecção do início e fim de cada MUAP presente no sinal EMG.

Após a detecção dos MUAPs no sinal EMG, realizado pelo EMG Decomposition-Br, o sistema fornece o resultado através de um conjunto de vetores de 100 pontos (cada vetor representa um MUAP) para o próximo estágio do sistema híbrido de decomposição de sinais EMG: a etapa de agrupamento de MUAPs. Esta etapa foi desenvolvida pelo projeto proposto neste trabalho e será explicada a seguir.

6.2.2 Agrupamento de MUAPs

Após o estágio de detecção de MUAPs, o próximo estágio desenvolvido pelo sistema proposto é o agrupamento de MUAPs (Figura 6.3).

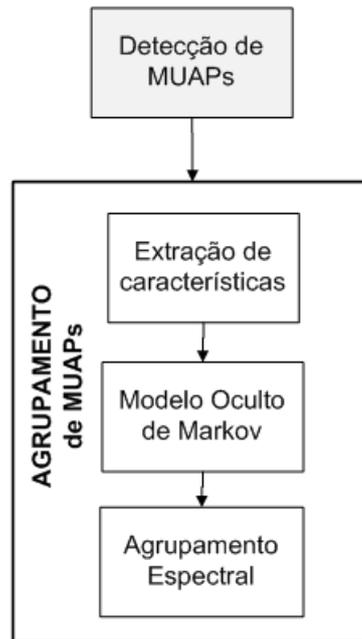


Figura 6.3: Etapas do processo de agrupamento de MUAPs realizadas pelo sistema de decomposição de sinais EMG de superfície utilizando Modelo Oculto de Markov.

Este estágio tem como funções:

- Agrupar os MUAPs que apresentam características similares em sua morfologia;
- Identificar a quantidade de Unidades Motoras ativas no sinal eletromiográfico que está sendo analisado;
- Apresentar a morfologia padrão do MUAP que é gerado por cada Unidade Motora ativa;

Para tanto, o processo de agrupamento de MUAPs é realizado através da execução da seguinte seqüência:

A - Extração de características dos MUAPs

Nesta etapa, são selecionadas as características dos MUAPs detectados no sinal EMG. O processo de extração de características dos MUAPs foi inspirado no trabalho desenvolvido pelos pesquisadores *Kanar et al.* [14] [166].

A pesquisa desenvolvida por *Kanar et al.* é sobre a validação de padrões dinâmicos, baseado em um padrão pré-definido. A validação de padrões dinâmicos consiste na validação estrutural e na validação comportamental. A validação estrutural significa estabelecer que o relacionamento utilizado no modelo é adequado para a representação de relacionamentos no mundo real. Já a avaliação comportamental consiste demonstrar que o comportamento do modelo é equivalente ao observado no mundo real.

O problema principal no desenvolvimento de uma ferramenta para reconhecimento de padrões dinâmicos é a escolha dos padrões básicos que irão ser incluídos na ferramenta. *Kanar et al.* optaram por escolher os principais padrões que são utilizados na literatura científica: constante, crescente, decrescente, crescente-decrescente, decrescente-crescente ou oscilatório (Figura 6.4).

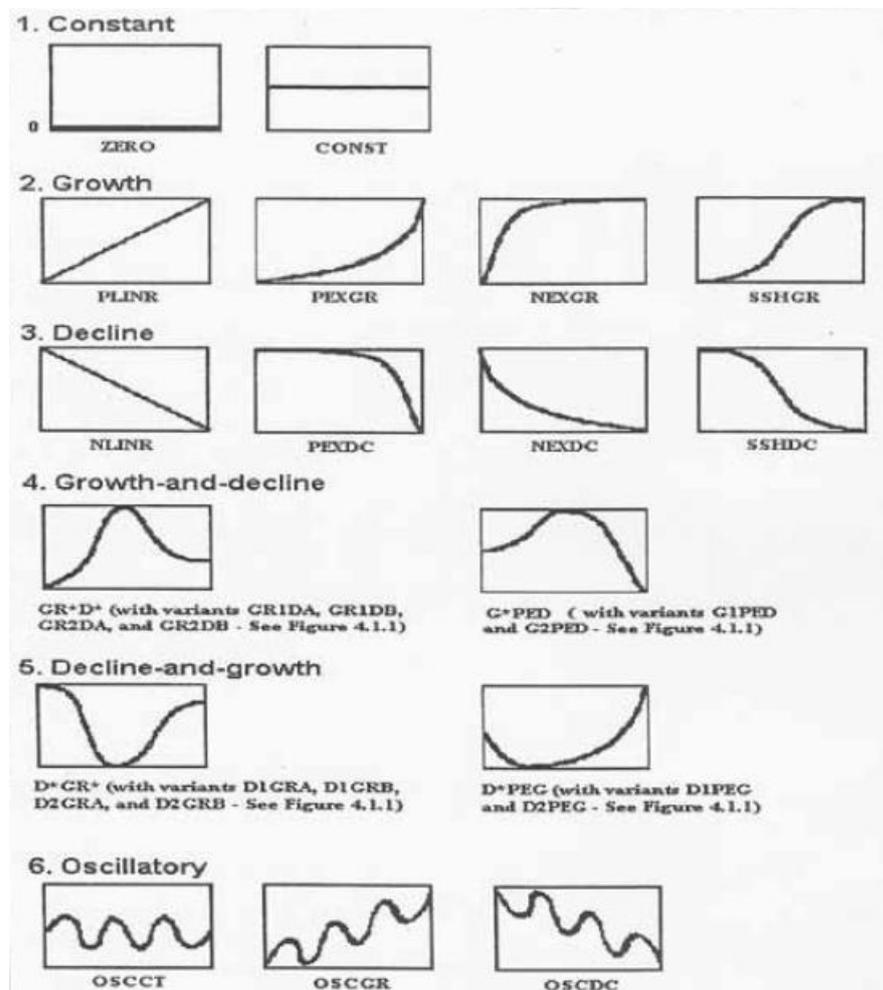


Figura 6.4: Padrões de formas de onda utilizados na validação de modelos dinâmicos [14].

Automatizar o teste comportamental de padrões dinâmicos é um grande problema

de reconhecimento de padrões. Na literatura já foram apresentados inúmeros algoritmos para classificações de padrões, mas devido à natureza dinâmica deste teste específico, as ferramentas já desenvolvidas eram inadequadas.

Neste contexto, *Kanar et al.* [14] [166] desenvolveram um algoritmo baseado em Modelo Oculto de Markov para reconhecimento de padrões. A principal diferença entre os algoritmos clássicos para reconhecimento de padrões e Modelos Ocultos de Markov é o processo de extração de características. No caso dos Modelos Ocultos de Markov, um dado uni-dimensional pode ser dividido em uma seqüência de segmentos e, desta seqüência ser extraído um vetor de características. Já nos algoritmos clássicos, um único conjunto de características é extraído para um determinado dado. Assim, os dados analisados pelos pesquisadores eram uni-dimensionais, o que tornava viável a aplicação do Modelo Oculto de Markov.

No problema de reconhecimento de comportamento dinâmico estudado pelos pesquisadores, um sinal dinâmico foi representado por uma seqüência $y(k)$, $k = 1, 2, \dots, K$, onde K é a quantidade de pontos, conforme apresenta a Figura 6.5.

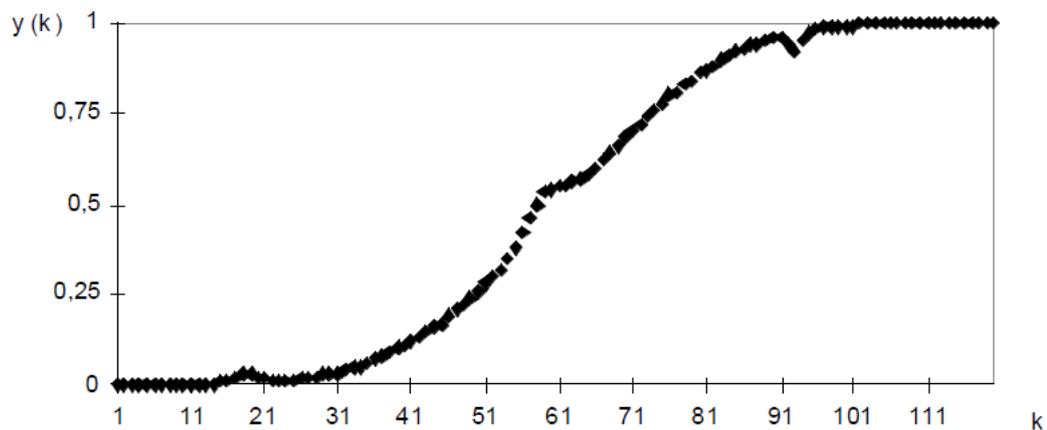


Figura 6.5: Exemplo de um sinal dinâmico [14].

O procedimento de extração de características é iniciado com a divisão da seqüência $y(k)$ em T segmentos de comprimento L (Figura 6.6). Cada segmento é representado por $y_t(l)$, $t = 1, 2, \dots, T$.

$$y_t(l) = y[(t - 1)L + 1] \quad (6.1)$$

Onde $l = 1, 2, \dots, L$

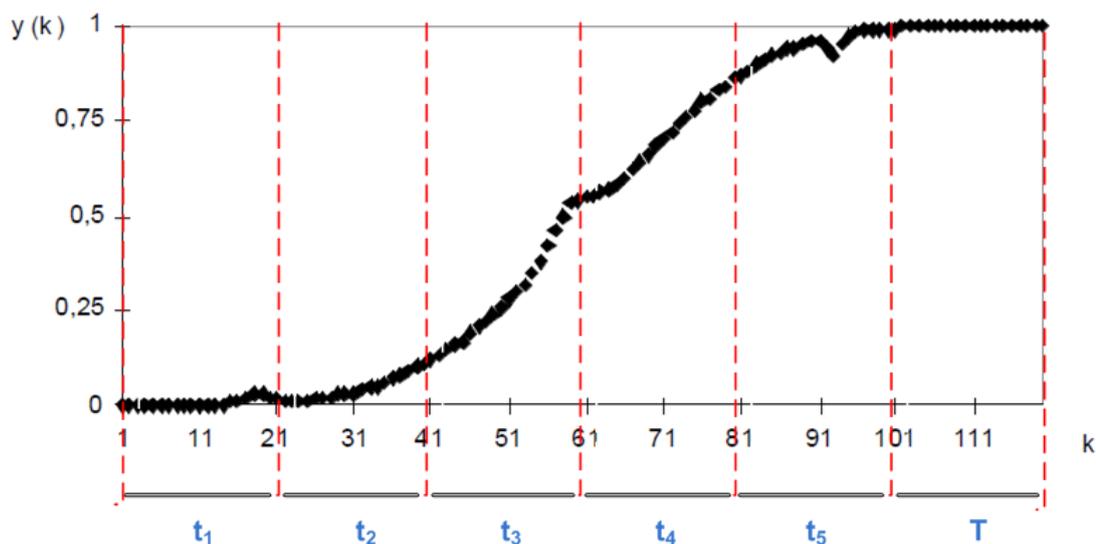


Figura 6.6: Exemplo de um sinal dinâmico segmentado (linhas vermelhas) em T segmentos (Modificado de [14]).

É importante ressaltar que a escolha dos valores de T e L dependem do modelo de sistema reconhecedor que está sendo implementado, isto é, depende do problema que está sendo modelado.

O próximo passo é a extração de características de cada segmento. Os padrões dinâmicos, de forma geral, são caracterizados por sucessivos segmentos crescentes ou decrescentes. Dessa forma, é considerável que as informações da angulação e da curvatura de cada segmento sejam componentes do vetor de características. Essas características podem ser obtidas através de aproximações polinomiais em cada segmento. A angulação do polinômio de primeira ordem fornece informações sobre o comportamento, isto é, crescente, decrescente ou constante. Já o polinômio de segunda ordem pode ser utilizado para obter a derivada segunda, a qual irá fornecer a informação sobre a curvatura do segmento. E a terceira informação que vai compor o vetor de características é a média do segmento.

Assim, o vetor de características de cada segmento será composto por:

- **Angulação:** ϕ_{t1}

O polinômio de primeira ordem aproximado para a seqüência de pontos em um segmento, pode ser expresso conforme a equação 6.2:

$$f_t(x) = \phi_{t1}x + \phi_{t0} \quad (6.2)$$

Onde:

- $t = 1, 2, \dots, T$;
- x é uma variável contínua.

- **Curvatura:** $c_t(k_t)$

O polinômio de segunda ordem é definido de acordo com a equação 6.3:

$$g_t(x) = \gamma_{t2}x^2 + \gamma_{t1}x + \gamma_{t0} \quad (6.3)$$

A equação 6.3 pode ser utilizada para calcular a derivada segunda:

$$c_t(x) = \frac{d^2g_t/d^2x}{(1 + (dg_t/dx)^2)^{3/2}} \quad (6.4)$$

Para esta característica, a curvatura é calculada no ponto do meio do segmento (k_t).

Assim, a segunda característica será $c_t(k_t)$.

- **Média:** μ_t

A média dos pontos do segmento também fornece uma informação importante a respeito do nível do sinal:

$$\mu_t = \frac{\sum r_t(l)}{L} \quad (6.5)$$

Dessa forma, para cada segmento t , onde $t=1, 2, \dots, T$, teremos um vetor de características o_t , de acordo com 6.6.

$$o_t = \begin{pmatrix} \phi_{t1} \\ c_t(k_t) \\ \mu_t \end{pmatrix} \quad (6.6)$$

Então, de acordo com *Kanar et al.*, um sinal dinâmico pode ser segmentado em L segmentos e cada segmento pode ser representado por um vetor de características O :

$$O = \{o_1, o_2, o_3, \dots, o_T\} \quad (6.7)$$

Extração de características de MUAPs utilizando o método de Kanar et al., 1999.

Considerando que a morfologia de um MUAP é similar ao de um sinal dinâmico, isto é, pode ser representada por uma seqüência de segmentos crescentes, decrescentes ou constantes, é possível aplicar o conjunto de características proposto por *Kanar et al.* [14] [166], no processo de extração de características de MUAPs.

Assim, de acordo com o procedimento de extração de características apresentado no trabalho de *Kanar et al.* [14] [166], exposto anteriormente, um potencial de ação de unidade motora pode ser dividida em L segmentos e para cada segmento, é possível extrair um conjunto de características o_t , como exemplificado na Figura 6.7.

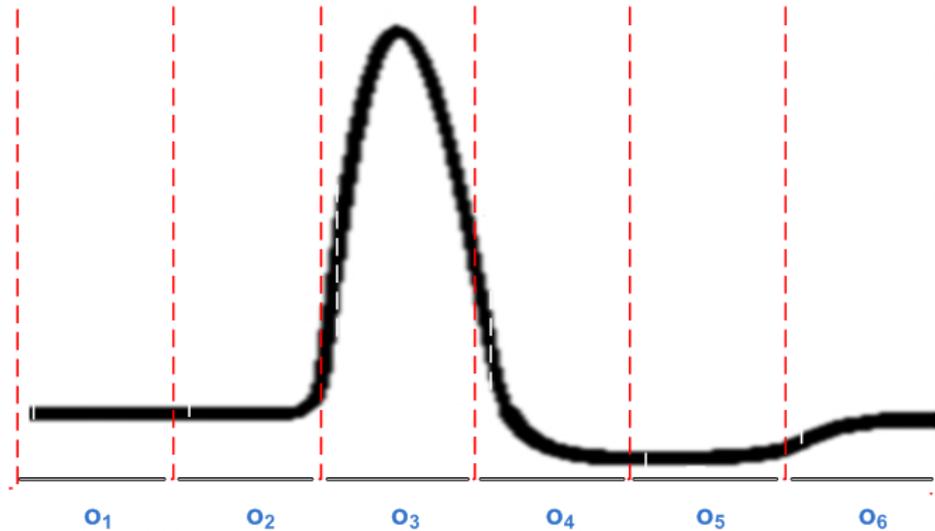


Figura 6.7: Exemplo de um MUAP segmentado (linhas vermelhas) e com o_t representando o vetor de características de cada segmento.

Realizado o estágio de extração de características dos MUAPs, o próximo passo é gerar o Modelo Oculto de Markov, conforme é apresentado a seguir.

B - Modelo Oculto de Markov

Após a etapa de extração das características, o próximo passo é gerar um Modelo Oculto de Markov que represente um MUAP detectada no sinal EMG. O objetivo de criar um modelo para cada MUAP é explicado pela necessidade de construir uma Matriz de Similaridade entre os padrões de MUAPs que possibilite a aplicação do algoritmo Agrupamento Espectral.

De acordo com *Kanar et al.* [14] [167], cada conjunto de características, extraído de um determinado dado, pode ser considerado com sendo a observação que é observada em um estado. Dessa forma, se considerarmos cada segmento, delimitado na seção anterior, como sendo um estado, então teremos um total de T estados (S_i). E ainda, a transição desses estados sempre será da esquerda para a direita, considerando a dinâmica da evolução do sinal no tempo. Sendo assim, o MUAP pode ser representado por um Modelo Oculto de Markov de T estados, com a topologia esquerda-direita.

Desta forma, para cada MUAP detectado no sinal EMG, será extraído um conjunto de características O_t , $t = 1, 2 \dots T$, onde T é a quantidade de segmentos do MUAP. Após realizada esta etapa, será criado um Modelo Oculto de Markov, topologia esquerda-direita, com T estados. Assim, cada MUAP será representado por um modelo λ (Figura 6.8).

Para esta topologia de Modelo Oculto de Markov, a matriz de transição de estados (A), será representada por:

$$A = \begin{pmatrix} 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ 0 & 0 & \dots & 1 & 0 \\ 0 & 0 & 0 & \dots & 1 \end{pmatrix} \quad (6.8)$$

Como os valores do conjunto de observações de cada segmento são números reais, é necessário utilizar o Modelo Oculto de Markov contínuo. Desta forma, a probabilidade de observar uma determinada observação em um determinado estado j será definida por $N(\mu_j, V_j)$, onde V_j é a matriz de covariância e μ_j é o vetor média.

Para cada MUAP i presente no sinal EMG, será gerado um Modelo Oculto de Markov λ_i , utilizando o conjunto de características O_i . Desta forma, a máxima verossimilhança produzida pelo modelo λ_i será aquela gerada pelo conjunto de observações O_i . É importante ressaltar o fato de que observações com valores próximos irão, necessariamente,

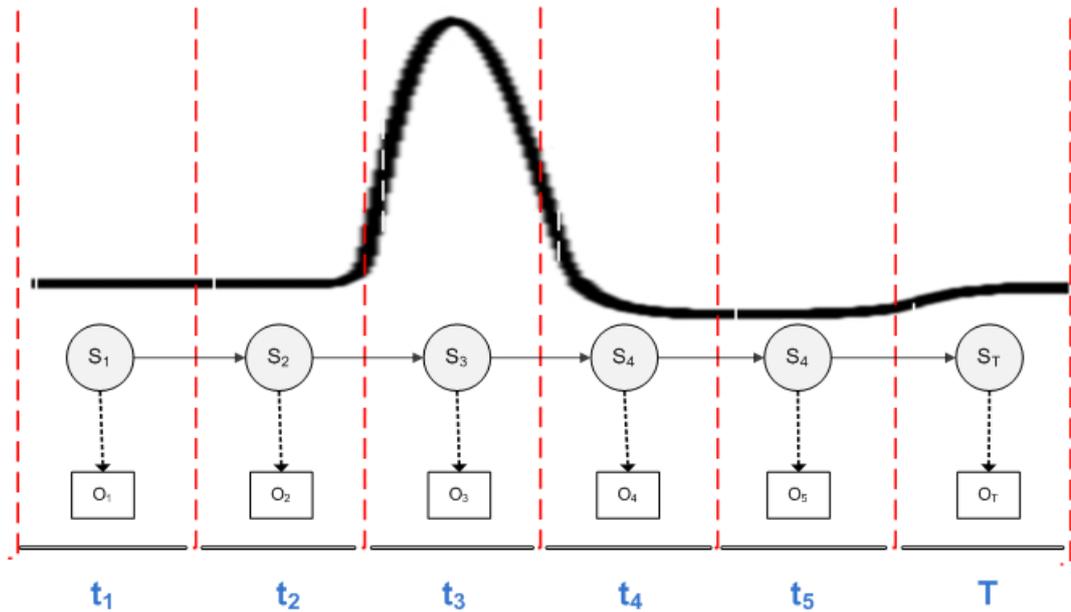


Figura 6.8: Exemplo de um MUAP representado pela topologia esquerda-direita de um Modelo Oculto de Markov com T estados, sendo que cada estado S representa um segmento t .

gerar verossimilhanças de valores próximos. E este caso irá acontecer quando tivermos MUAPs de morfologia parecidas, ou seja, MUAPs morforlogicamente parecidas irão gerar conjuntos de observações de valores próximos. Conseqüentemente, as verossimilhanças terão valores próximos. E ainda, considerando que, geralmente:

- uma Unidade Motora produz um padrão morfológico único de MUAP;
- unidades Motoras distintas geram padrões morfológicos distintos de MUAPs,

Então é possível concluir que se gerarmos uma Matriz de Distância/Dissimilaridade entre todas os MUAPs i , utilizando as verossimilhanças geradas pela $p(O_i|\lambda_i)$, será possível descobrir quais são os MUAPs que possuem morfologias similares, isto é, quais são os MUAPs que foram geradas pela mesma Unidade Motora. Desta forma, descobriremos quantos padrões morfológicos distintos existem no sinal EMG e, conseqüentemente, podemos inferir a quantidade de Unidade Motoras ativas no sinal EMG analisado.

Assim, de posse dos modelos λ_i e do conjunto de observações O_i , é possível construir uma Matriz de Dissimilaridade necessária para executar o algoritmo de Agrupamento Espectral.

C - Agrupamento Espectral

Após a construção do Modelo Oculto de Markov para cada um dos MUAPs presentes no sinal EMG e de posse dos modelos λ_i e do conjunto de observações O_i , a geração da Matriz de Dissimilaridade é realizada de acordo com o algoritmo apresentado na Figura 6.9. Neste algoritmo, célula (i,j) da matriz *Matriz de Distancia* corresponde à $p(O_i|\lambda_j)$, isto é, corresponde à verossimilhança da seqüência de observações O_i ser gerada pelo modelo λ_j .

```
// N é a quantidade de MUAPs detectadas no sinal EMG
double MatrizDistancia = matriz(N,N);

Para i = 1 até N
|   Para j = 1 até N
|   |   MatrizDistancia = p(O_i|\lambda_j)
|   |
|   fim para
fim para
```

Figura 6.9: Algoritmo utilizado para gerar a Matriz de Dissimilaridade entre os MUAPs, utilizando os modelos λ 's gerados e as observações O extraídas dos MUAPs.

Ao executar o algoritmo da Figura 6.9, a Matriz de Distancia (MD) será gerada conforme 6.9.

$$MD = \begin{pmatrix} P(O_1|\lambda_1) & P(O_1|\lambda_2) & P(O_1|\lambda_3) & \dots & P(O_1|\lambda_N) \\ P(O_2|\lambda_1) & P(O_2|\lambda_2) & P(O_2|\lambda_3) & \dots & P(O_2|\lambda_N) \\ P(O_3|\lambda_1) & P(O_3|\lambda_2) & P(O_3|\lambda_3) & \dots & P(O_3|\lambda_N) \\ \dots & \dots & \dots & \dots & \dots \\ P(O_N|\lambda_1) & P(O_N|\lambda_2) & P(O_N|\lambda_3) & \dots & P(O_N|\lambda_N) \end{pmatrix} \quad (6.9)$$

De posse da Matriz de Distâncias, é executado o Algoritmo de Agrupamento Espectral. Como resultado, teremos:

- **A quantidade de grupos existentes:**

O algoritmo Agrupamento Espectral irá fornecer a quantidade de grupos existentes entre as N verossimilhanças fornecidas na Matriz de Distâncias. Como consequência, irá fornecer, também:

- A quantidade de padrões morfológicos de MUAPs;
- A quantidade de Unidades Motoras ativas no sinal EMG analisado;
- **A classificação de cada conjunto de observações em um determinado grupo:**

Após estimar a quantidade de grupos, o algoritmo Agrupamento Espectral classifica cada uma das verossimilhanças, através das informações fornecidas pela Matriz de Distância, em um dos grupos estimados. Assim, considerando que cada grupo representa, neste trabalho, uma Unidade Motora ativa, teremos como resultado:

- Quantos MUAPs foram gerados por cada Unidade Motora;
- Quais são os MUAPs gerados por cada Unidade Motora;
- Qual é o padrão morfológico do MUAP gerado por cada Unidade Motora.

Conforme já foi apresentado anteriormente, um dos resultados fornecidos pela etapa de Agrupamento é a classificação de cada MUAP em um grupo. E, nesta pesquisa, um grupo representa uma Unidade Motora. Sendo assim, temos como resultado do estágio de Agrupamento a informação sobre qual Unidade Motora gerou determinada MUAP. Dessa forma, é possível retornar à série temporal do sinal EMG e classificar cada MUAP (Figura 6.10).

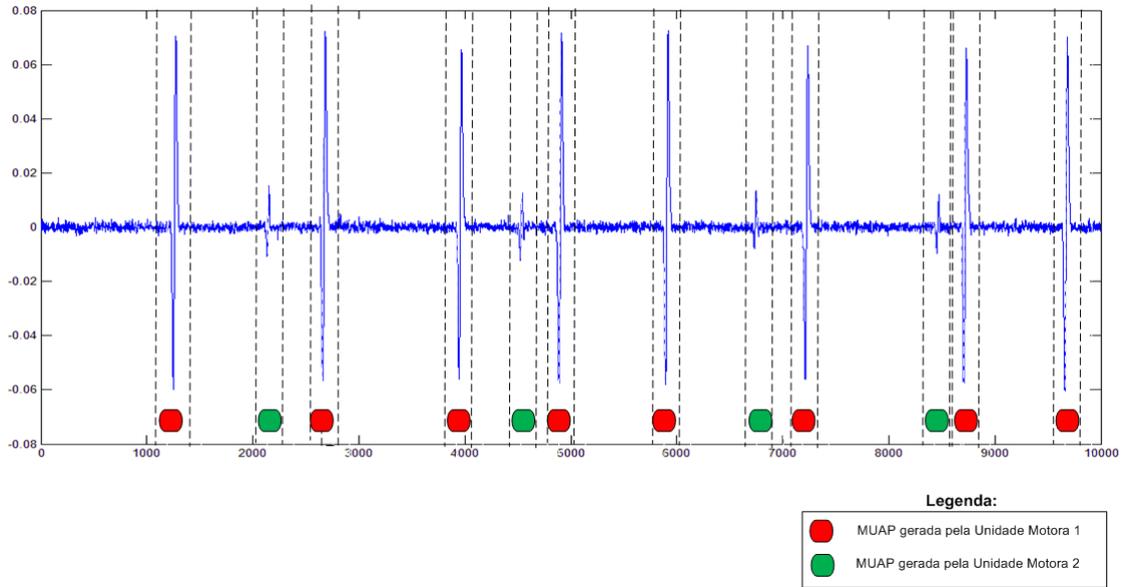


Figura 6.10: Exemplo de classificação dos MUAPs existentes no sinal EMG, em sua respectiva Unidade Motora geradora, após a execução do sistema proposto para decomposição de sinais EMG de superfície.

Assim, o sistema proposto pode apresentar, também, a seqüência de disparo das Unidades Motoras ativas no sinal EMG de superfície que está sendo analisado.

6.3 Implementações realizadas

Para a implementação do sistema proposto, diversas investigações, simulações e estudos foram realizados, são eles:

- Investigação sobre a inicialização dos parâmetros do Modelo Oculto de Markov;
- Investigação do comportamento do algoritmo Evolução Diferencial em problemas de otimização multimodal;
- Avaliação da inicialização dos parâmetros do Modelo Oculto de Markov utilizando Evolução Diferencial;
- Agrupamento de MUAPs utilizando Evolução Diferencial.

Nas próximas seções, serão detalhados cada um dos estudos realizados para a implementação do projeto.

6.3.1 Simulações e resultados obtidos com o MOM

O Modelo Oculto de Markov é uma teoria que pode ser aplicada em diversos problemas/situações do mundo real. Para tanto, é necessário abstrair os conceitos deste modelo, fazer a analogia com o problema do mundo real que está sendo o objeto de estudo e configurar os parâmetros do MOM - e isto não é uma tarefa simples.

Existem diversas técnicas para otimizar os parâmetros do Modelo Oculto de Markov. Desde que os MOMs têm sido aplicados na prática, um problema freqüente que os pesquisadores encontram é como selecionar ou estimar os valores iniciais dos parâmetros do modelo λ [43]. Já se sabe que inicializações impróprias do modelo levam a estimações inadequadas dos parâmetros do MOM e/ou na convergência para um ótimo local, que é significativamente pior do que o ótimo global [97]. E ainda, já é sabido que a melhor inicialização deve ser aquela que apresenta a maior verossimilhança para o MOM [168] [169].

Algumas estratégias têm sido desenvolvidas para iniciar os parâmetros do MOM, tais como aplicações de algoritmos de agrupamento ([97] [90] [81] [170], [171] [172] [108]), Modelos de Mistura de Gaussianas ([104] [173] [112] [174] [175] [176]) e a utilização de valores randômicos ([40] [43] [177] [97] [41] [128]). Entretanto, ainda não há um consenso sobre qual técnica é a melhor, pois para cada contexto podem ser necessárias algumas alterações no algoritmo ou, até mesmo, o desenvolvimento de um algoritmo específico. Ainda é um desafio inicializar os parâmetros do MOM, e uma inicialização adequada é essencial, pois se os parâmetros do MOM forem estimados de forma imprecisa, o modelo não conseguirá atingir o seu melhor resultado (ótimo global) [97].

Se não existe uma técnica específica para a inicialização do modelo, é interessante, e necessário, fazer um estudo para avaliar se uma inicialização do modelo é apropriada. O objetivo desta avaliação é investigar a forma como os parâmetros iniciais do MOM se comportam em um contexto prático. Desta forma, alguns questionamentos sobre este assunto devem ser considerados: como é possível saber se uma inicialização está correta? Como saber quais devem ser os melhores parâmetros que devem ser utilizadas na otimização e no teste do MOM?

Nas próximas seções são apresentados, através de simulações, os efeitos de uma inicialização inadequada dos parâmetros do MOM, e também serão discutidos importantes tópicos relacionados à estimação e seleção destes parâmetros.

Simulações realizadas

Para avaliar o comportamento do MOM de acordo com a alteração dos valores dos parâmetros ótimos A (matriz de transição de estados) e B (matriz de probabilidade de observação de símbolos), a estratégia utilizada foi simular diversos valores para A e B de forma que eles fossem se distanciando, linearmente, dos parâmetros ótimos A e B. Assim, seria possível avaliar a alteração da verossimilhança de acordo com a alteração dos parâmetros ótimos, que são os geradores do MOM.

Para realizar esta simulação, três estágios foram necessários: 1) Definição dos parâmetros do MOM; 2) Geração de dados sintéticos do MOM; 3) Otimização dos parâmetros do MOM.

- **Definição dos parâmetros do MOM**

Para gerar os parâmetros do MOM e avaliá-los de acordo com a distância em relação aos seus valores ótimos do MOM, foi considerada a Distância Euclidiana. Para tanto, foi considerado um ponto central, escolhido empiricamente, o qual representa os valores ótimos das matrizes A e B. A partir deste ponto central, foram selecionados 1000 pontos pertencentes à vizinhança deste ponto central, para ser possível realizar a análise do comportamento do MOM de acordo com a variação linear da distância dos parâmetros A e B em relação aos seus valores ótimos. Estes 1000 pontos são separados em regiões (indicadas por cores diferentes) e cada região é composta por pontos que possuem uma Distância Euclidiana no intervalo $[d_{min}^b, d_{max}^b]$ em relação ao ponto central, onde b é uma das regiões disponíveis (Figura 6.12), e d_{min}^b e d_{max}^b são as distâncias mínimas e máximas que definem a região (Figura 6.11).

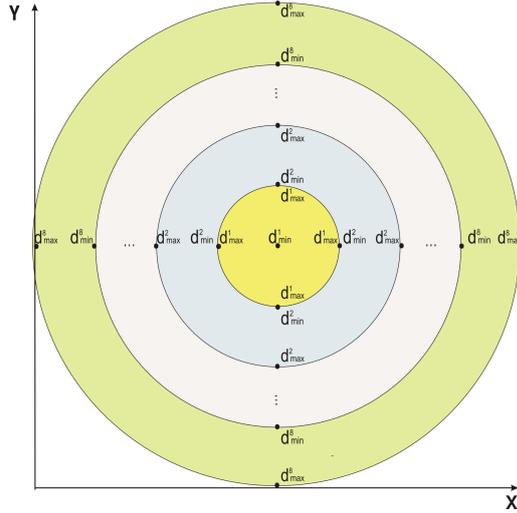


Figura 6.11: Definição das regiões de pontos que serão avaliados pelo MOM, de acordo com a distância mínima (d_{min}^b) e máxima (d_{max}^b)

A Figura 6.12 ilustra um conjunto de possíveis parâmetros posicionados ao redor de um ponto, definido na coordenada central (500,500), que foi escolhida empiricamente para representar os valores ótimos das matrizes A e B do MOM.

Dessa forma, é possível investigar a variação da verossimilhança e do erro mínimo quadrático entre os parâmetros estimados e os ótimos, de acordo a variação da Distância Euclidiana (d_{max}^b/d_{min}^b)/2 em uma região.

As representações em R^2 nas Figuras 6.12 e 6.11 são apenas para efeito de visualização. Na prática, as matrizes A e B possuem dimensão maior do que dois. Por exemplo, a matriz A com 3 estados necessitaria de um vetor em R^9 para representá-la. Observe que, apesar dos parâmetros A e B de um MOM serem vetores multidimensionais, eles podem ser visualizados como vetores unidimensionais. Esta observação é importante porque é sempre possível obter uma projeção linear de um espaço dimensional mais baixo para um outro espaço com dimensão maior, garantindo a mesma Distância Euclidiana nos dois espaços [178]. Esta transformação permitirá a geração das matrizes A e B, as quais vão possuir a mesma Distância Euclidiana dos pontos apresentados na Figura 6.12 em relação ao ponto central, que representa os parâmetros ótimos do MOM.

A projeção linear é definida conforme (6.10):

$$P(R^n) = Ort * P(R^2) \quad (6.10)$$

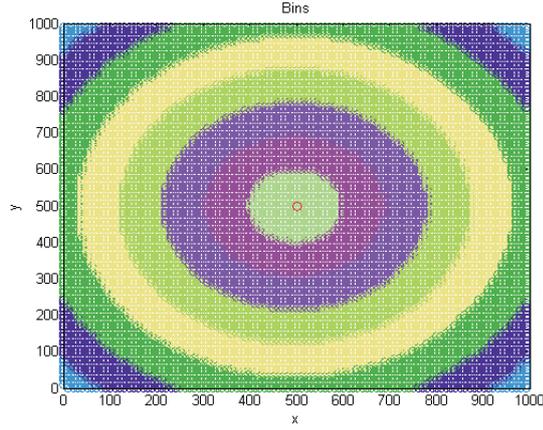


Figura 6.12: Mapa de pontos em R^2 utilizados para representar os parâmetros A e B do MOM, que foram utilizados para avaliar a variação da verossimilhança do modelo. Estes pontos são separados em regiões de acordo com a sua Distância Euclidiana em relação ao ponto central ($x=500, y=500$), escolhido empiricamente.

Onde:

- $P(R^n)$ é um vetor em R^n e $P(R^n) = [w_1, w_2, \dots, w_n]$;
- $P(R^2)$ é um vetor $[x,y]$, em R^2 ;
- Ort é uma matriz ortogonal.

Observe que a Distância Euclidiana em (R^2) , em relação ao ponto central (500,500), dos pontos estimados pela equação 6.10 será preservado no espaço (R^n) , onde $n > 2$. A equação (6.11) representa uma matriz A, utilizando um vetor multidimensional $(P(R^n))$. O mesmo raciocínio é utilizado para compor a matriz B.

$$A = \begin{pmatrix} w_1 & w_2 & w_N \\ w_{N+1} & w_{N+2} & \dots \\ \dots & \dots & w_n \end{pmatrix} \quad (6.11)$$

Para a simulação realizada com o MOM, o vetor Π de probabilidades iniciais foi definido conforme (6.12), onde N é o número de estados.

$$\Pi = \left(\frac{1}{N} \quad \frac{1}{N} \quad \frac{1}{N} \right) \quad (6.12)$$

- **Geração de dados sintéticos a partir do MOM**

Para realizar a simulação do comportamento do MOM, inicialmente, foram geradas observações sintéticas (Processo Markoviano Oculto). Para gerar as observações (**O**) do MOM, foi utilizada a *HMM Toolbox do Matlab*® (6.13):

$$[\mathbf{O}, \mathbf{estados}] = \text{hmmgenerate}(T, A_{otimo}, B_{otimo}) \quad (6.13)$$

Onde:

- **O** é o vetor de observações gerado pela toolbox;
- **estados** é o vetor que contém o estado de cada observação;
- T é o número total de observações;
- A_{otimo} é a matriz ótima de probabilidade de transição entre os estados;
- B_{otimo} é a matriz ótima de probabilidade observação.

Neste estudo, uma projeção linear foi utilizada para definir os parâmetros iniciais, $Estimativa_A$ e $Estimativa_B$, do MOM. A idéia foi estimar estes parâmetros através da variação da distância a seus valores ótimos (A_{otimo} , B_{otimo}), os quais foram utilizados na geração dos dados. De acordo com a Figura 6.12, os valores ótimos são representados pelo ponto central (500,500) e as demais estimativas desses parâmetros são representados pelos pontos vizinhos à este ponto central.

- **Otimização dos parâmetros do MOM**

Para ser possível avaliar o comportamento do MOM de acordo com a inicialização dos parâmetros, diferentes condições iniciais, representadas por $A_{Vizinho}$ e $B_{Vizinho}$, foram utilizadas. Para otimizar estes parâmetros do MOM, a função do Matlab *hmmtrain* foi utilizada (6.14):

$$[A_{Estimativa}, B_{Estimativa}] = \text{hmmtrain}(\mathbf{O}, A_{Vizinho}, B_{Vizinho}) \quad (6.14)$$

Onde:

- \mathbf{O} é o vetor de observações obtido pela função *hmmgenerate*;
- $A_{Vizinho}$ é o valor inicial para a matriz A_{otimo} ;
- $B_{Vizinho}$ é o valor inicial para a matriz B_{otimo} ;
- $A_{Estimativa}$ e $B_{Estimativa}$ são as matrizes otimizadas resultantes da função *hmm-train*, que otimiza os parâmetros utilizando o algoritmo Baum-Welch.

Observe que as matrizes $A_{Vizinho}$ e $B_{Vizinho}$ são variações das matrizes A_{otimo} e B_{otimo} que consideram Distâncias Euclidianas distintas em relação a estas matrizes, que são os pontos ótimo utilizados para a geração do processo Markoviano.

O objetivo deste estudo é avaliar a sensibilidade do algoritmo de otimização Baum-Welch, de acordo com a escolha dos parâmetros iniciais ($A_{Vizinho}$ e $B_{Vizinho}$). Dessa forma, as simulações consideraram três condições distintas:

1. Inicializar $A_{Vizinho}$ como uma função de A_{otimo} e manter $B_{Vizinho}$ igual a B_{otimo} ;
2. Inicializar $B_{Vizinho}$ como uma função de B_{otimo} e manter $A_{Vizinho}$ igual a A_{otimo} ;
3. Inicializar $A_{Vizinho}$ e $B_{Vizinho}$ como uma função de A_{otimo} e B_{otimo} , respectivamente.

Após a otimização dos parâmetros do MOM, duas novas matrizes são estimadas: $A_{Estimativa}$ e $B_{Estimativa}$. Idealmente, estas matrizes deveriam ser o mais próximas possíveis de A_{otimo} e B_{otimo} , entretanto, devido a limitações do algoritmo de otimização, o que pode ser obtido na prática é apenas uma estimativa, o qual é dependente dos parâmetros de inicialização. Mas, é possível calcular o Erro Médio Quadrático entre os parâmetros ótimos e estimados do MOM.

E ainda, é possível investigar o comportamento das probabilidades de um modelo de acordo com um conjunto de dados, isto é, é possível investigar a verossimilhança de um conjunto de dados no MOM.

Assim, o erro médio quadrático entre as matrizes otimizadas e as matrizes ótimas do MOM e a verossimilhança, foram utilizados para investigar a sensibilidade do MOM de acordo com a inicialização dos parâmetros.

Para cada simulação, foram testados N estados, variando de 1 a 10. Para cada estado, o número de símbolos (M) variou de 1 a 10. A escolha dos valores de N e M foram realizadas empiricamente.

Resultados

- Simulação 1:

Para a primeira simulação, que considera $A_{Vizinho}$ como uma função de A_{otimo} e $B_{Vizinho}$ igual a B_{otimo} , foi obtido o resultado apresentado na Figura 6.13.

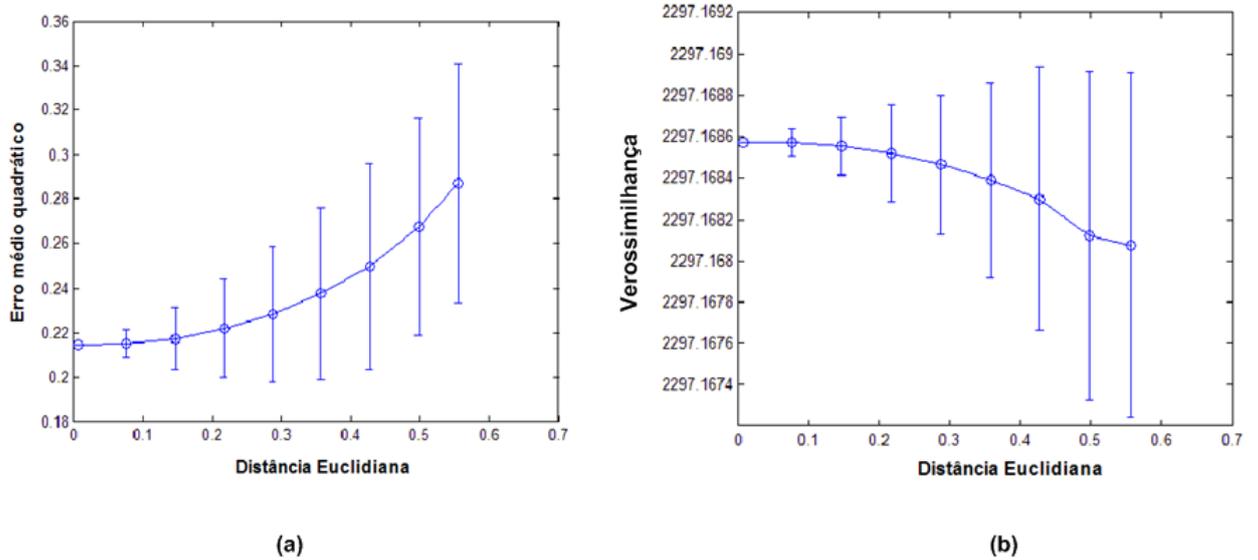


Figura 6.13: Resultado da simulação 1 com o MOM. **(a):** O erro médio entre as matrizes A_{otimo} e $A_{Estimativa}$ de acordo com a distância entre as matrizes A_{otimo} e $A_{Vizinho}$. As linhas verticais (em azul) representam a variância de cada erro médio. **(b):** A média da verossimilhança de acordo com a distância entre as matrizes A_{otimo} e $A_{Estimativa}$. As linhas verticais (em azul) representam a variância de cada verossimilhança.

Cada marca no gráfico da Figura 6.13 representa o erro médio (calculado como a média do Erro Quadrado Médio) juntamente com sua variância (indicado pelas barras verticais). A partir deste resultado, é possível concluir que a média da Distância Euclidiana indicada pelas regiões no eixo x, aumenta de acordo com o aumento do erro médio quadrado (eixo y).

Nesta simulação, é possível notar que a distância entre $A_{Vizinho}$ e A_{otimo} (eixo x) aumenta enquanto a verossimilhança (eixo y), diminui.

- **Simulação 2:**

Para a segunda simulação, que considera $B_{Vizinho}$ como sendo uma função de B_{otimo} e $A_{Vizinho}$ igual a A_{otimo} , foi obtido o resultado apresentado na Figura 6.14.

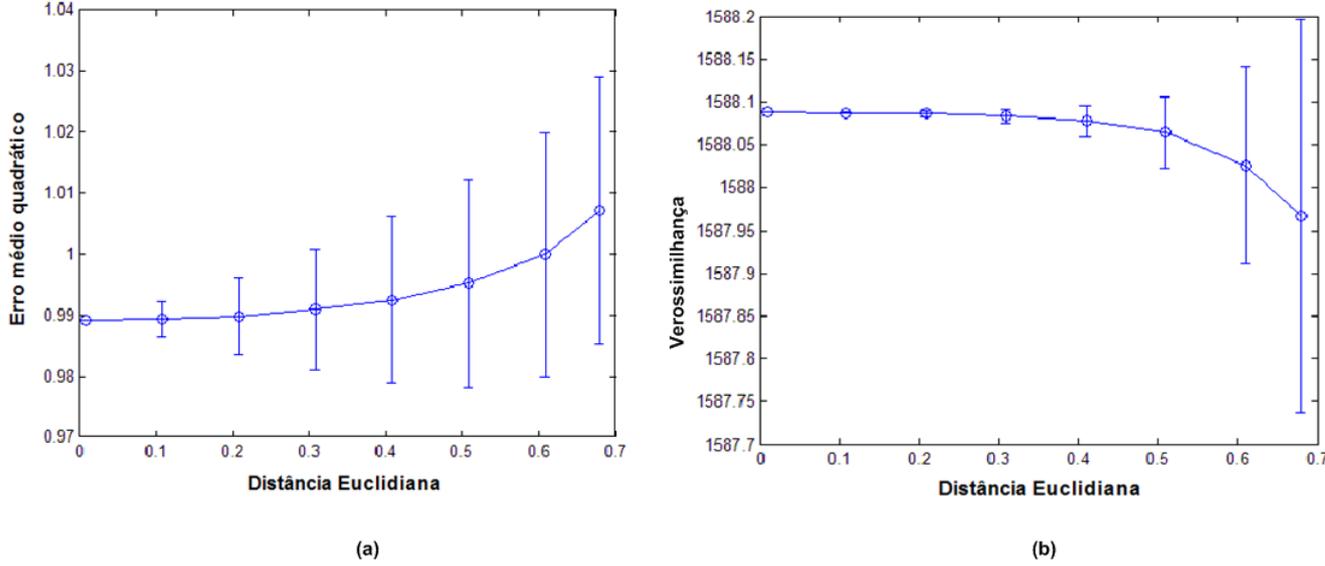


Figura 6.14: Resultado da simulação 1 com o MOM -**(a)**: O erro médio entre as matrizes B_{otimo} e $B_{Estimativa}$ de acordo com a distância entre as matrizes B_{otimo} e $B_{Estimativa}$. As linhas verticais (em azul) representam a variância de cada erro médio. **(b)** A média da verossimilhança de acordo com a distância entre as matrizes B_{otimo} e $B_{Estimativa}$. As linhas verticais (em azul) representam a variância de cada verossimilhança.

A partir deste resultado, também observou-se que a média da Distância Euclidiana entre as matrizes $B_{Estimativa}$ e B_{otimo} (eixo X) aumenta de acordo com o aumento do erro médio quadrático (eixo y). E ainda, nesta simulação foi possível observar que a distância entre $B_{Estimativa}$ e B_{otimo} (eixo x) aumenta enquanto a verossimilhança (eixo y), diminui.

- **Simulação 3:**

Na terceira simulação, que considera $A_{Vizinho}$ como uma função de A_{otimo} e $B_{Vizinho}$ como uma função de B_{otimo} , foram obtidos os resultados apresentados na Figura 6.15.

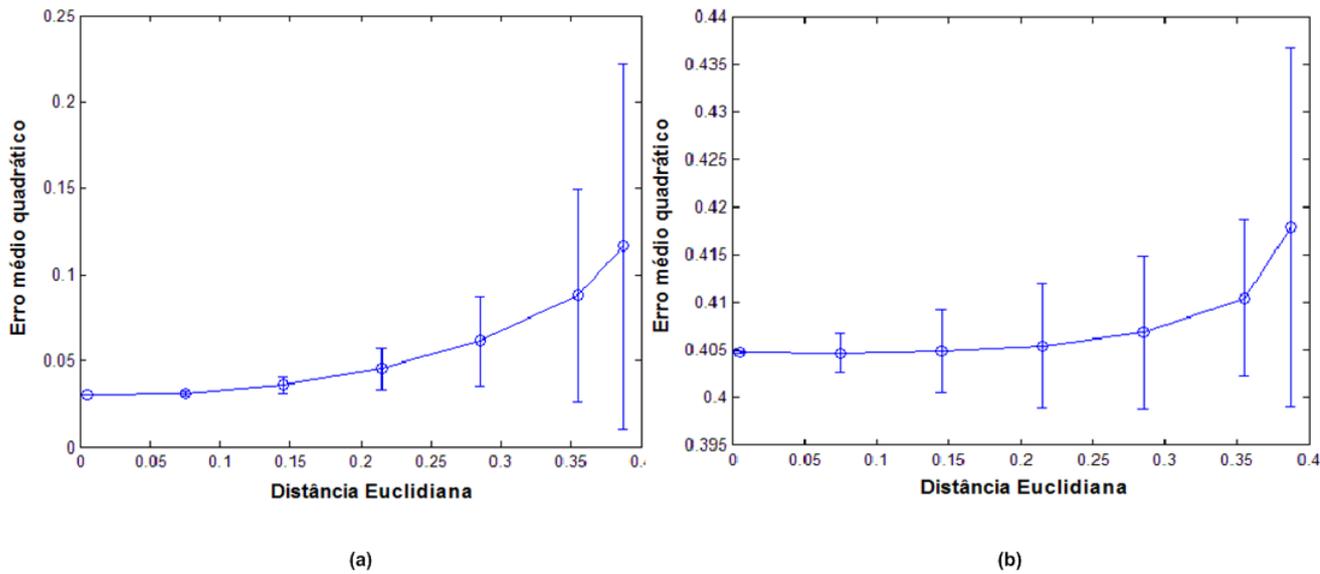


Figura 6.15: Resultado da simulação 3 com o MOM - **(a):** O erro médio entre as matrizes A_{otimo} e $A_{Estimativa}$ de acordo com a distância entre as matrizes A_{otimo} e $A_{Vizinho}$; **(b):** O erro médio entre as matrizes B_{otimo} e $B_{Estimativa}$ de acordo com a distância entre as matrizes B_{otimo} e $B_{Vizinho}$. As linhas verticais (em azul) representam a variância de cada erro médio. As linhas verticais (em azul) representam a variância de cada erro médio.

Note que média da Distância Euclidiana entre as matrizes $A_{Vizinho}$ e A_{otimo} (eixo X) aumenta de acordo com o aumento do erro global (eixo y). E ainda, é possível verificar que a média da Distância Euclidiana entre as matrizes $B_{Vizinho}$ e B_{otimo} (eixo X) aumenta de acordo com o aumento do erro global (eixo y).

Finalmente, é possível observar que a distância entre as matrizes $A_{Vizinho}$ e A_{otimo} , $B_{Vizinho}$ e B_{otimo} (no eixo x), aumentam enquanto a verossimilhança (eixo y) decresce (Figura 6.16).

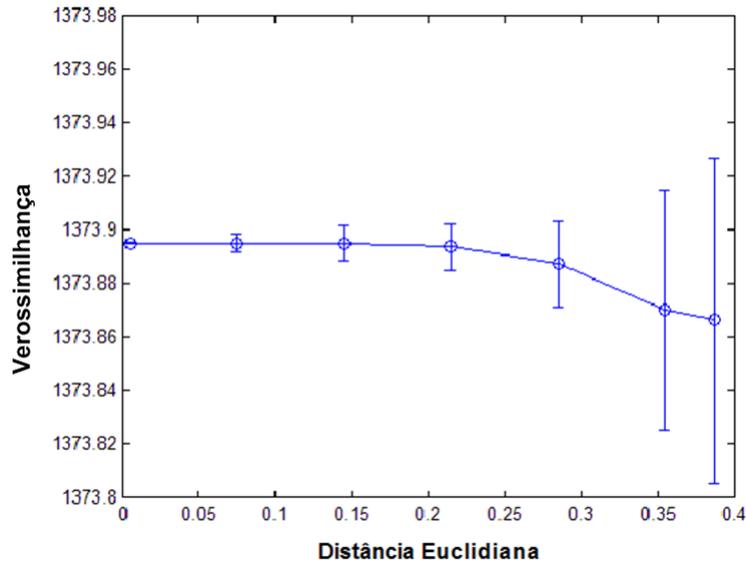


Figura 6.16: A média da verossimilhança de acordo com a distância entre as matrizes A_{otimo} e $A_{Vizinho}$, e B_{otimo} e $B_{Estimativa}$. As linhas verticais (em azul) representam a variância de cada verossimilhança.

Os resultados apresentados nas simulações acima, mostram que o algoritmo Baum-Welch é sensível às condições iniciais do MOM. Após a análise dos resultados, é possível observar que uma inicialização inadequada dos parâmetros do MOM pode resultar em valores diferentes e distantes dos valores considerados ótimos e ideais. De maneira geral, observou-se que o erro médio quadrático entre os parâmetros estimados e os iniciais, aumenta de acordo com o aumento da Distância Euclidiana entre os valores iniciais e os ótimos. A verossimilhança diminui quando a distância entre os valores iniciais e atuais aumenta.

Independente da técnica utilizada para gerar os parâmetros, é importante verificar se os parâmetros atuais são próximos ao máximo global, pois esta proximidade irá garantir que os parâmetros obtidos estão próximos das soluções reais. Assim, se os valores iniciais estiverem distantes do máximo global, o algoritmo de otimização pode não ser capaz de alcançar o máximo global, isto é, ele pode ficar estagnado em um máximo local.

Entretanto, apesar da pequena variação que foi observada nos valores da verossimilhança e no erro médio quadrático, é importante ressaltar que, dependendo da aplicação do MOM, esta diferença pode resultar em respostas erradas do MOM. Por exemplo, no projeto proposto, uma pequena variação no modelo do MUAP pode ser o suficiente para

classificá-lo em um outro grupo, isto é, classicá-lo de maneira errada e inferindo que o MUAP foi gerado por uma outra Unidade Motora.

Dessa forma, é necessário investigar uma outra técnica que possa otimizar um pouco mais os parâmetros do MOM, de forma a aumentar a probabilidade dos parâmetros inicialmente estimados alcançarem o máximo global. A técnica proposta nesse trabalho para esta finalidade é a Evolução Diferencial.

6.3.2 Evolução Diferencial: estudos e simulações

Conforme já apresentado no Capítulo 3, o algoritmo Baum-Welch é utilizado para reestimar/otimizar os parâmetros do Modelo Oculto de Markov. Entretanto, ele possui algumas limitações quando a função a ser otimizada apresenta vários máximos-locais. Nessa situação, o algoritmo *Baum-Welch* pode otimizar os parâmetros para algum máximo-local, não necessariamente o melhor máximo-local ou o máximo-global. Dessa forma, é necessária a utilização de alguma técnica para aumentar a probabilidade dos parâmetros do MOM serem otimizados para o máximo-global. É importante notar que a otimização dos parâmetros do MOM é um problema de otimização multimodal, visto que existem diversos máximos-locais nesse processo de otimização. Dessa forma, a técnica de otimização a ser utilizada neste problema, deverá trabalhar com otimização de funções multimodais.

Sendo assim, propõe-se o uso do algoritmo Evolução Diferencial (ED) com o propósito de utilizá-lo para a reestimação/otimização dos parâmetros do MOM. Os métodos utilizados neste estudo, bem como os resultados, são apresentados a seguir.

6.3.2.1 Avaliação do desempenho do algoritmo Evolução Diferencial

Para avaliar a eficiência do algoritmo ED no processo de otimização de funções multimodais, é necessário selecionar uma função custo que apresente vários máximos locais. Uma função custo é a função em que um algoritmo de otimização irá procurar a melhor resposta, isto é, o ótimo global.

Para verificar o comportamento do algoritmo ED, a função de Rastriving (6.15), que representa um problema de otimização multimodal, foi selecionada como função custo.

$$f(x, y) = (20 + x^2 + y^2) - 10 \times (\cos(2\pi \times x)) + (\cos(2\pi \times y)) \quad (6.15)$$

A Figura 6.17 apresenta o gráfico 3D de uma função de Rastring, que possui diversos mínimos e máximos locais.

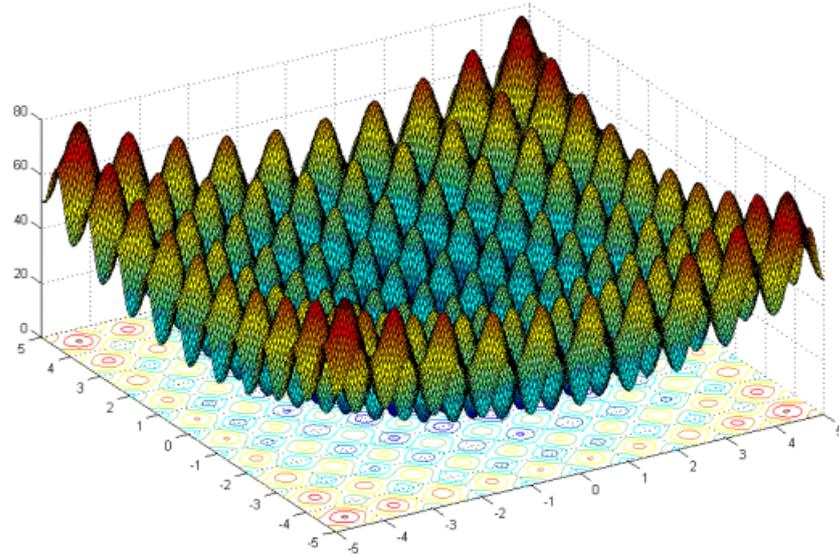


Figura 6.17: Gráfico 3D de uma função de Rastring.

Para avaliar o desempenho do algoritmo ED no processo de minimização (encontrar o mínimo global) e maximização (encontrar o máximo global) da função de Rastring, deverá ser avaliado se ele é capaz de escapar dos vários vários máximos-locais.

Considere a função de Rastring no domínio para x e y :

- $-5 \leq x \leq 5$;
- $-5 \leq y \leq 5$.

Neste caso, a função de Rastring possui neste domínio o mínimo global em $(x, y) = (0, 0)$, com mínimo global $= f(x, y) = 0$; e possui 4 máximos globais em $(x, y) = (4.5, 4.55)$, $(x, y) = (-4.5, 4.44)$, $(x, y) = (4.5, -4.55)$ e $(x, y) = (-4.5, -4.55)$, com máximo global $= f(x, y) = 80.46$.

Após diversas simulações para encontrar os melhores parâmetros de controle do ED para este problema específico, os seguintes valores de controle foram obtidos:

- $D = 2$;
- $CR = 0.8$ (constante de cruzamento);
- $F = 0.8$ (constante de mutação);

- NP = 100 (quantidade de membros da população);
- Quantidade de iterações: 1000;
- Quantidade de simulações: 1000

O código original do algoritmo da ED, escrito por Rainer Storn e Kenneth Price [132] [133], que foi utilizado para realizar as simulações, foi obtido a partir de [179].

Resultados do algoritmo ED

Para verificar a performance da otimização multimodal do algoritmo ED na função de Rastriving, ele foi executado em dois casos distintos: maximização e minimização.

Para ilustrar os resultados obtidos com as simulações realizadas na função de Rastriving, são apresentados três tipos de análises:

1. *Estimativa da quantidade média de membros da população, após 1000 simulações, que alcançaram uma vizinhança pré-definida da solução ótima:* a vizinhança é definida em termos de porcentagem (%), que representa a proximidade entre a solução ótima e o resultado da função custo aplicada aos membros da população. Quanto maior for a porcentagem, maior será a proximidade entre a solução ótima e os membros da população.
2. *Gráfico de contorno:* apresenta a distribuição da população antes e após a otimização;
3. A quantidade média de membros da população, para cada vizinhança próxima à solução ótima, é estimada em cada iteração, após 1000 simulações.

Minimização

A Figura 6.18 apresenta o resultado de uma simulação utilizando o algoritmo ED para a minimização da função de Rastriving. No topo da Figura 6.18.(a) é apresentada a distribuição inicial da população (em vermelho). É importante observar que todos os membros da população estão localizados na base de atração de um ótimo local. Após a otimização, os membros da população ficaram estagnados em um ótimo local (Figura 6.18.(b)).

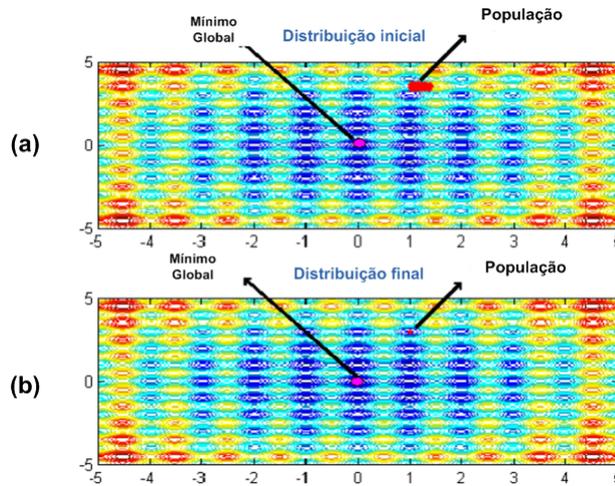


Figura 6.18: Resultado da minimização da função Rastriving utilizando o algoritmo ED **(a)** Distribuição inicial da população antes da execução do algoritmo ED. **(b)** Distribuição final da população, após executar o algoritmo ED. As setas indicam a solução ótima (mínimo global), a distribuição inicial e final da população.

A Figura 6.19 mostra que a quantidade média de membros da população que alcançaram as vizinhanças investigadas da solução ótima (mínimo global) foi zero. Isto significa que o algoritmo não foi capaz de mover a população para o mínimo global e nem para regiões próximas ao mínimo global.

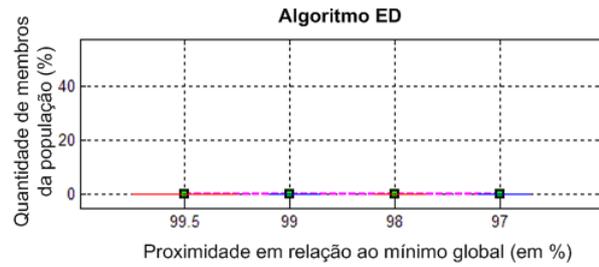


Figura 6.19: Estimativa da quantidade média de membros da população que, após 1000 simulações, alcançaram as vizinhanças próximas ao mínimo global, utilizando o algoritmo ED para minimização da função de Rastriving.

Os resultados ilustram a limitação dos operadores genéticos da ED, que não criaram uma diversidade suficiente dentro da população para explorar outras regiões do espaço de busca além da base de atração do local ótimo.

Maximização

A Figura 6.20 apresenta um resultado típico da simulação utilizando o algoritmo padrão ED. A Figura 6.20.(a) mostra a distribuição inicial da população (em vermelho). É importante observar que todos os membros da população estão localizados em um ótimo local. Após a otimização, os membros da população não escaparam de um ótimo local (Figura 6.20.(b)).

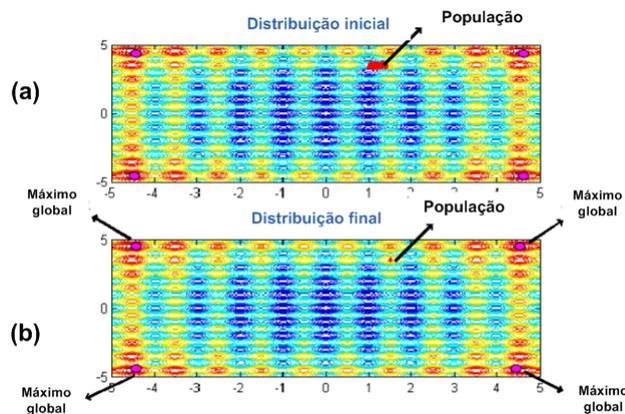


Figura 6.20: Resultado da maximização da função Rastriving utilizando o algoritmo ED (a) Distribuição inicial da população. (b) Distribuição final da população, após executar o algoritmo ED. As setas indicam os máximos globais (soluções ótimas), a distribuição inicial e final da população.

A Figura 6.21 apresenta os resultados da aplicação do algoritmo padrão ED. A média de membros da população que alcançaram o máximo global foi zero em todas as vizinhanças investigadas. Isto significa que o algoritmo não foi capaz de mover a população para o máximo global, conforme pode ser visualizado na Figura 6.21.

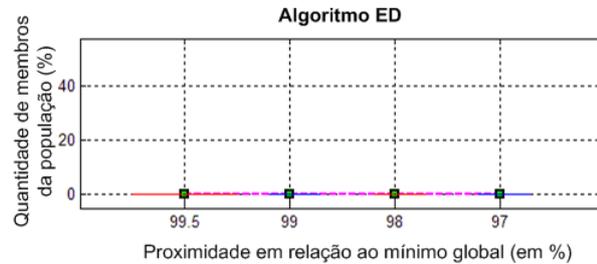


Figura 6.21: Estimativa da quantidade média de membros da população que, após 1000 simulações, alcançaram as vizinhanças próximas ao máximo global, utilizando o algoritmo ED para maximização da função de Rastriving.

O algoritmo Evolução Diferencial (ED) é uma eficiente ferramenta de otimização, já estudada e aplicada em casos de otimização envolvendo múltiplos máximos-locais. Entretanto, quando todos os membros da população estão na base de atração de um ótimo local (mínimo ou máximo local), a população não consegue escapar deste local. Assim, é necessário um estudo para verificar uma possível modificação no algoritmo ED para aumentar a probabilidade dos membros da população escaparem de uma base atração de um ótimo local e, desta forma, aumentar a probabilidade do algoritmo ED alcançar a solução ótima.

6.3.2.2 Proposta do algoritmo Evolução Diferencial com Seleção Probabilística (EDSP)

Para melhorar a performance do ED, foi proposta uma modificação na etapa de seleção dos membros da população. O objetivo desta modificação é aumentar a probabilidade dos membros da população escaparem de uma base de atração de um ótimo local.

No algoritmo ED, a seleção da nova população é realizada utilizando uma condição determinística, isto é, habitualmente, no algoritmo ED, a seleção é realizada através da escolha do membro (\mathbf{X} ou \mathbf{V}) que está mais próximo da solução ótima [136].

A proposta é aliviar o determinismo da seleção para manter a diversidade da população e, conseqüentemente, permitir que os membros da população escapem da base de atração

do local ótimo. Assim, o que se propõe é introduzir a seleção probabilística de um novo membro da população, para induzir a diversidade da população. À este novo algoritmo, vamos chamar de Evolução Diferencial com Seleção Probabilística (EDSP).

No algoritmo EDSP foi definida uma probabilidade de seleção dos membros da população em termos de suas funções custo, conforme (6.16) e (6.17).

$$P(X) = \frac{(f(X) + K)}{(f(X) + K) + (f(V) + K)} \quad (6.16)$$

$$P(V) = 1 - P(X) \quad (6.17)$$

A constante K em (6.16) é adicionada para garantir que $P(\mathbf{X})$ seja sempre maior do que zero. O valor de K irá depender da função custo utilizada no algoritmo.

A solução probabilística proposta acima ainda mantém alguma pressão na população que move para a solução ótima, porém permite uma diversidade muito maior, pois admite sub-escolhas, o que é necessário para mover os membros além dos limites das bases de atração. A implementação da seleção probabilística é realizada utilizando um número aleatório c , proveniente de uma distribuição uniforme em um intervalo unitário e comparado com a probabilidade de seleção de \mathbf{X} . As modificações necessárias para o caso da minimização e maximização, são apresentadas a seguir:

- **Minimização**

Neste caso, é necessário escolher o membro da população que possui a menor função custo. O pseudo-código apresentado na Figura 6.22 ilustra este processo.

```

if (P(V) < c)
    then U = V;
else U = X;
```

Figura 6.22: Minimização: estágio de seleção probabilística do algoritmo EDSP.

- **Maximização**

Neste caso, é necessário escolher o membro da população que possui a maior função custo. O pseudo-código apresentado na Figura 6.23 ilustra este processo.

```
if (P(V) > c)
    then U = V;
    else U = X;
```

Figura 6.23: Maximização: estágio de seleção probabilística do algoritmo EDSP.

Resultados do algoritmo EDSP

Para avaliar as modificações propostas no algoritmo EDSP, o mesmo protocolo de configuração dos estágios da Evolução Diferencial, descrito na seção anterior, foi utilizado. Os resultados que serão apresentados a seguir mostram o comportamento do algoritmo EDSP na otimização global da função de Rastring.

Minimização

A Figura 6.24 apresenta o comportamento do algoritmo EDSP no processo de minimização da função de Rastring. Na Figura 6.24.(a) é apresentada a distribuição inicial da população (em vermelho), em que todos os membros da população estão localizados na base de atração de um ótimo local. Após a otimização com o algoritmo EDSP, note que os membros da população conseguiram escapar do ótimo local (Figura 6.24.(b)).

A Figura 6.25 apresenta a concentração estimada da população na regiões vizinhas à solução ótima (mínimo global). As barras verticais representam o intervalo de confiança para a média de membros da população, que foi calculada utilizando a técnica Bootstrap [180]. Note que em algumas regiões vizinhas à solução ótima, o número médio de membros da população foi maior do que zero. Isso significa que o algoritmo EDSP foi capaz de mover a população para uma região próxima à solução ótima.

A Figura 6.26 apresenta a média de membros da população que alcançaram a vizinhança próxima à solução ótima (99% de proximidade) em função do tempo (número de iterações), utilizando o algoritmo EDSP. Este gráfico também possibilita a visualização da convergência da população para a solução ótima durante a evolução dos algoritmos ED e EDSP.

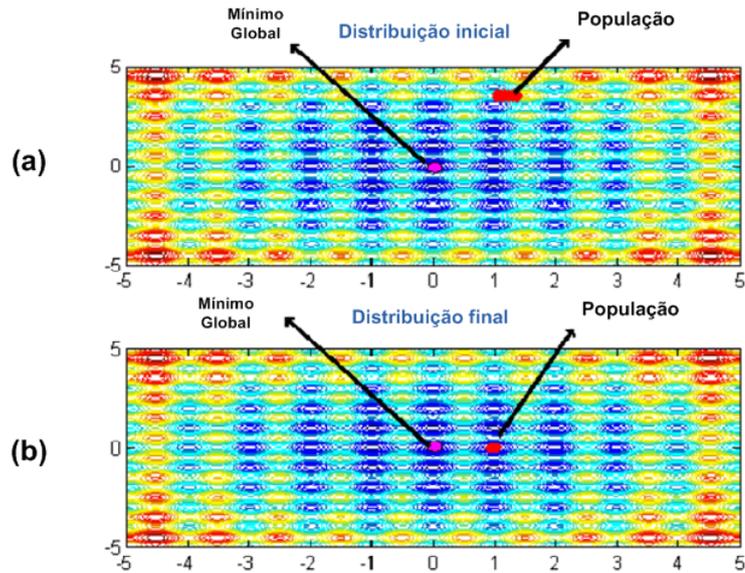


Figura 6.24: Resultado da minimização da função de Rastrigin utilizando o algoritmo EDSP:(a) Distribuição inicial da população. (b) Distribuição final da população, após a execução do algoritmo EDSP. As setas indicam o mínimo global (solução ótima), a distribuição inicial e final da população.

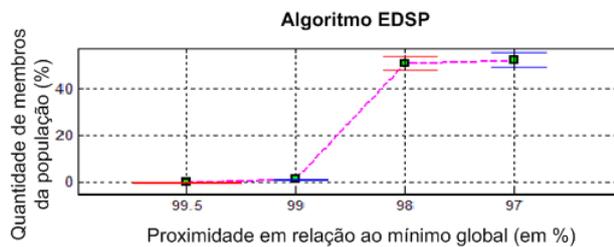


Figura 6.25: Estimativa da quantidade média de membros da população que, após 1000 simulações, alcançaram as vizinhanças próximas ao mínimo global, utilizando o algoritmo EDSP para minimização da função de Rastrigin.

Maximização

A Figura 6.27 mostra o resultado de uma simulação utilizando o algoritmo EDSP. A Figura 6.27.(a) apresenta a distribuição inicial da população (em vermelho) - todos os membros da população estão localizados em um ótimo local. Repare que após a otimização, os membros da população conseguiram escapar do ótimo local e se deslocaram para as proximidades de um máximo global (Figura 6.27.(b)).

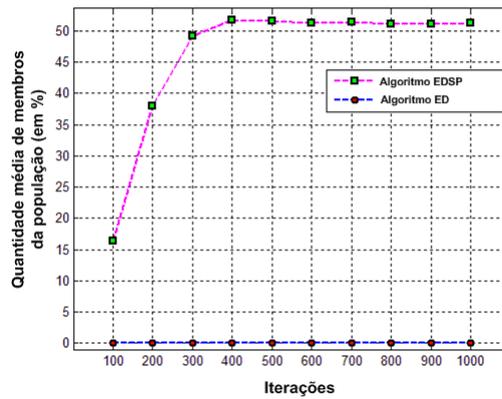


Figura 6.26: Comparação entre os resultados dos algoritmos ED e EDSP na minimização da função de Rastrig: quantidade média de membros da população que atingiram a vizinhança mais próxima à solução ótima (99% de proximidade), em cada iteração.

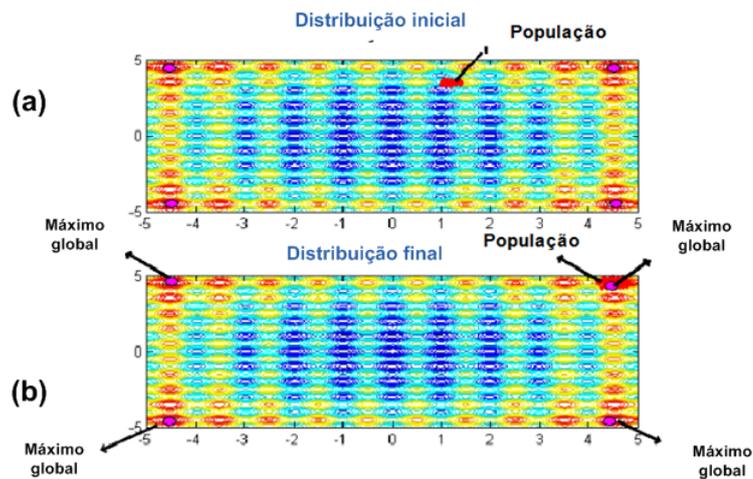


Figura 6.27: - Resultado do algoritmo EDSP para a maximização da função de Rastrig: (a) Distribuição inicial da população. (b) Distribuição final da população, após executar o algoritmo EDSP. As setas indicam a solução ótima (máximo global), a distribuição inicial e final da população.

A Figura 6.28 apresenta a concentração estimada da população nas regiões vizinhas à solução ótima (máximo global). As barras verticais representam o intervalo de confiança para a média. É importante notar que em todas as vizinhanças próximas à solução ótima, a média de membros da população que atingiu estas regiões, foi maior do que zero. Isso significa que o algoritmo EDSP foi capaz de mover a população para uma região próxima ao máximo global (solução ótima).

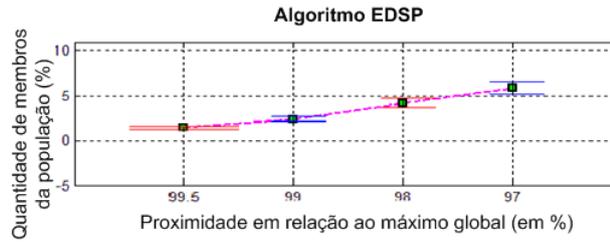


Figura 6.28: Estimativa da quantidade média de membros da população que, após 1000 simulações, alcançaram as vizinhanças próximas ao mínimo global, utilizando o algoritmo EDSP para a maximização da função de Rastring.

A Figura 6.29 apresenta a média de membros da população que alcançaram a vizinhança próxima à solução ótima (99% de proximidade) em função do tempo (número de iterações), utilizando o algoritmo EDSP. E ainda, o gráfico da Figura 6.29 apresenta a convergência da população para a solução ótima durante a evolução dos algoritmos ED e EDSP.

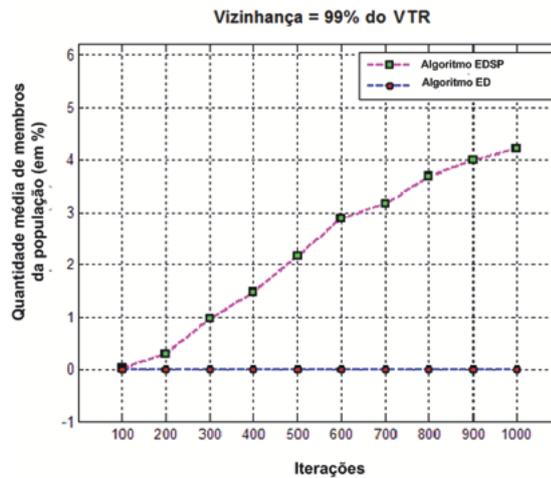


Figura 6.29: Comparação entre os resultados dos algoritmos ED e EDSP na maximização da função de Rastring: quantidade média de membros da população que atingiram a vizinhança mais próxima à solução ótima (99% de proximidade), em cada iteração.

Os resultados apresentados indicam que as alterações realizadas no estágio de seleção do algoritmo ED, que resultaram no algoritmo EDSP, melhoraram significativamente o processo de otimização. Nos dois casos analisados, minimização e maximização da função Rastring, o algoritmo EDSP foi capaz de mover a população da base de atração do local ótimo em que ela estava inicialmente e movê-la para uma vizinhança próxima à solução

ótima. É importante lembrar que o algoritmo ED não permitiu que a população escapasse do ótimo local, considerando estes mesmos casos.

O algoritmo proposto EDSP é importante em problemas de otimização multimodais, quando os algoritmos convencionais encontram dificuldade de escapar do ótimo local. A probabilidade de sucesso do algoritmo EDSP mostraram ser maiores do que o algoritmo ED. As simulações realizadas contribuíram para a investigação do comportamento do ED e o algoritmo proposto EDSP pode ser muito útil nas aplicações de otimização no mundo real. Nesta pesquisa, todos os processos de otimização serão realizados utilizando o algoritmo EDSP.

6.3.2.3 Otimização dos parâmetros do Modelo Oculto de Markov utilizando o algoritmo EDSP

Conforme destacado anteriormente, um estágio importante na utilização dos Modelos Ocultos de Markov é a inicialização dos parâmetros do modelo. A inicialização deve considerar o conhecimento sobre o problema em que será aplicado o MOM e, também, as técnicas de otimização para estimar os melhores parâmetros iniciais para uma determinada função custo e, conseqüentemente, para estimar a melhor verossimilhança.

Assim, propõe-se a inicialização dos parâmetros dos Modelos Ocultos de Markov utilizando o algoritmo EDSP, com o objetivo de obter a maior verossimilhança para o MOM. Entretanto, antes de utilizar o algoritmo EDSP é necessário verificar a sua eficiência em relação a outros algoritmos clássicos utilizados na otimização dos parâmetros do MOM.

Protocolo Experimental

Para avaliar os algoritmos de otimização dos parâmetros do MOM, o processo Markoviano foi gerado utilizando a HMM *toolbox* do Matlab (6.18):

$$[\mathbf{O}, \text{estados}] = \text{hmmgenerate}(T, A_{\text{original}}, B_{\text{original}}) \quad (6.18)$$

Onde:

- \mathbf{O} é o vetor de observações gerado pela *toolbox*;
- **estados** é o vetor que contém o estado que gerou cada observação;

- T é o número total de observações;
- $A_{original}$ é a matriz de probabilidade de transição entre os estados;
- $B_{original}$ é a matriz de probabilidade observação.

Os operadores genéticos *mutação* e *cruzamento* no EDSP requerem a transformação das matrizes $A_{original}$ e $B_{original}$ em um vetor unidimensional ab :

$$A_{original} = \begin{pmatrix} a_{11} & a_{12} & a_{1N} \\ \dots & \dots & \dots \\ a_{N1} & a_{N2} & a_{NN} \end{pmatrix} \quad (6.19)$$

$$a = [a_{11} \quad a_{12} \quad \dots \quad a_{NN}] \quad (6.20)$$

$$B_{original} = \begin{pmatrix} b_{11} & b_{12} & b_{1N} \\ \dots & \dots & \dots \\ b_{N1} & b_{N2} & b_{NN} \end{pmatrix} \quad (6.21)$$

$$b = [b_{11} \quad b_{12} \quad \dots \quad b_{NN}] \quad (6.22)$$

$$ab = [a_{11} \quad a_{12} \quad \dots \quad a_{NN} \quad b_{11} \quad b_{12} \quad \dots \quad b_{NM}] \quad (6.23)$$

As configurações dos parâmetros do EDSP foram:

- D = tamanho do vetor \mathbf{ab} ;
- CR = 0.8 (constante de cruzamento);
- F = 0.8 (constante de mutação);
- NP = 100 (número de membros da população);
- Número de iterações: 1000;
- Número de simulações: 1000 - cada uma delas com um conjunto de dados diferente.

A quantidade de estados e símbolos foram escolhidos considerando que são estes valores, em média, que serão utilizados neste trabalho; conforme será detalhado no Capítulo 7. Assim, dois tipos de MOM foram considerados:

1. Um Modelo Oculto de Markov com 2 estados ($N = 2$) e 3 símbolos ($M = 3$);
2. Um Modelo Oculto de Markov com 5 estados ($N = 5$) e 4 símbolos ($M = 4$);

Para avaliar os resultados, para cada tipo de modelo foi calculada a verossimilhança do conjunto de dados utilizando os parâmetros estimados pelo melhor membro da população. E ainda, para comparar os resultados obtidos pelas diferentes estratégias para estimar os parâmetros \mathbf{A} e \mathbf{B} do MOM, foi gerado um gráfico que mostra a média da verossimilhança do MOM de acordo com a variação destes parâmetros. Seis diferentes estratégias foram consideradas para estimar os parâmetros \mathbf{A} e \mathbf{B} , são elas:

1. *Matriz Original*

As matrizes \mathbf{A} e \mathbf{B} foram configuradas para $\mathbf{A}_{original}$ e $\mathbf{B}_{original}$, respectivamente. Observe que estas mesmas matrizes foram utilizadas para a geração da seqüência de observações, conforme (6.18)

2. *Matriz Original + Baum Welch (BW)*

O modelo foi inicializado com as matrizes \mathbf{A} e \mathbf{B} configuradas para $\mathbf{A}_{original}$ e $\mathbf{B}_{original}$, respectivamente, e então otimizadas pelo algoritmo Baum Welch;

3. *Aleatório*

As matrizes \mathbf{A} e \mathbf{B} foram inicializadas com números aleatórios;

4. *Aleatório + Baum Welch (BW)*

As matrizes \mathbf{A} e \mathbf{B} foram inicializadas com números aleatórios, e então otimizadas pelo algoritmo Baum Welch;

5. *EDSP*

As matrizes \mathbf{A} e \mathbf{B} foram otimizadas pelo algoritmo EDSP;

6. *EDSP + Baum Welch (BW)*

As matrizes \mathbf{A} e \mathbf{B} foram otimizadas pelo EDSP e então otimizadas pelo Baum Welch;

A verossimilhança do MOM para uma determinada seqüência \mathbf{O} foi estimada utilizando a HMM *toolbox* do Matlab:

$$[\text{verossimilhanca}] = \text{hmmdecode}(\mathbf{A}, \mathbf{B}, \mathbf{O}) \quad (6.24)$$

O intervalo de confiança para a média da verossimilhança foi calculada utilizando a técnica Bootstrap [180] [181] [182] [183].

Resultados

MOM com dois estados ($N = 2$) e três símbolos ($M = 3$)

Neste caso, o MOM possui dois estados ($N = 2$) e três símbolos ($M = 3$), que foram gerados utilizando a *toolbox* do Matlab. O vetor de observações \mathbf{O} foi gerado com T igual a 100. O mesmo conjunto de observações \mathbf{O} foi utilizado para cada uma das seis estratégias distintas descritas no protocolo experimental.

A Figura 6.30 apresenta a verossimilhança das observações para as seis diferentes estratégias para estimar os parâmetros do modelo. No caso do EDSP e EDSP+BW, a média da verossimilhança do melhor membro da população, de 1000 simulações, é apresentada. As barras horizontais representam o intervalo de confiança para cada média, utilizando a técnica Bootstrap.

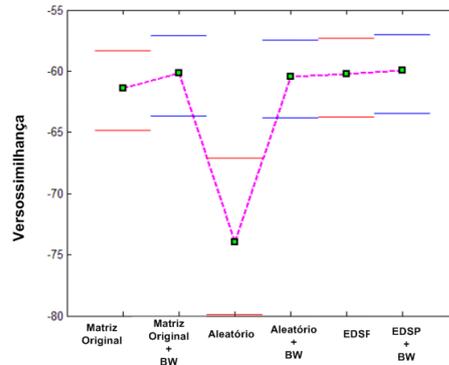


Figura 6.30: Média da verossimilhança de um MOM para um conjunto de dados utilizando seis estratégias distintas para estimar os parâmetros \mathbf{A} e \mathbf{B} . No caso do algoritmo EDSP, as matrizes \mathbf{A} e \mathbf{B} foram selecionadas considerando o melhor membro da população. As barras horizontais representam os limites superior e inferior do intervalo de confiança da média.

MOM com cinco estados ($N = 5$) e quatro símbolos ($M = 4$)

Neste caso, foi gerado o MOM com cinco estados ($N = 5$) e quatro símbolos ($M = 4$). A Figura 6.31 apresenta a verossimilhança do MOM para as seis diferentes estratégias

utilizadas para estimar os parâmetros do modelo.

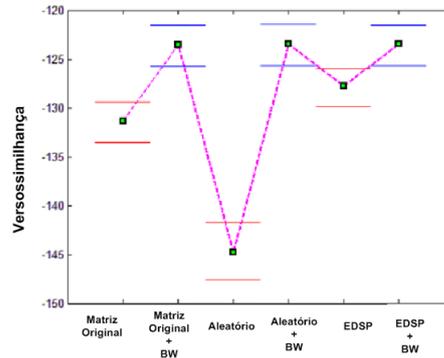


Figura 6.31: Média da verossimilhança de um MOM com 5 estados e 4 símbolos para um conjunto de dados utilizando seis estratégias distintas para estimar os parâmetros \mathbf{A} e \mathbf{B} . Para algoritmo EDSP, as matrizes \mathbf{A} e \mathbf{B} foram selecionadas considerando o melhor membro da população. As barras horizontais são os limites superior e inferior do intervalo de confiança da média.

Discussão

A partir dos resultados apresentados anteriormente é possível comparar o comportamento das seis diferentes estratégias para a inicialização dos parâmetros do MOM.

Nos casos analisados, a verossimilhança da técnica da Matriz Original foi menor do que as seguintes estratégias de otimização: Matriz Original + BW, EDSP e EDSP + BW. Isto ocorreu porque, apesar das matrizes $\mathbf{A}_{original}$ e $\mathbf{B}_{original}$ terem gerado a seqüência \mathbf{O} , não significa que estas matrizes sejam as melhores para gerar esta seqüência, isto é, elas podem apenas ser próximas das matrizes ótimas. Quanto menor for a Distância Euclidiana entre as matrizes estimadas e as "melhores" matrizes, para uma determinada seqüência de observações (\mathbf{O}), maior será a verossimilhança do MOM para a seqüência \mathbf{O} . Então, se um algoritmo de otimização é aplicado para estas matrizes, é possível encontrar a melhor solução e, conseqüentemente, elas terão uma maior verossimilhança.

No caso da estratégia Aleatória, em todas as simulações ela obteve a verossimilhança do MOM mais baixa. Isto é explicado pelo fato de que as matrizes geradas nesta estratégia são aleatórias, e a possibilidade delas gerarem a seqüência \mathbf{O} é pequena, e, conseqüentemente, a verossimilhança do MOM será sempre a menor. Mas se o algoritmo BW for aplicado para esta estratégia (Aleatório + BW), é possível obter uma verossimilhança maior do

que a Matriz Original.

E ainda, a inicialização dos parâmetros do MOM com o EDSP funciona tão bem quanto as outras estratégias quando temos um pequeno número de estados (N) e símbolos (M). Entretanto, quando temos um número maior de estados e símbolos, o seu comportamento pode ser melhorado se for otimizado com o algoritmo BW (EDSP + BW).

Como se sabe, a otimização dos parâmetros do MOM é um problema multimodal, isto é, ele possui muitos mínimos e máximos locais, que são as soluções ótimas. Assim, se durante a otimização, os parâmetros ficarem presos em um ótimo local, o modelo pode não alcançar a melhor verossimilhança possível. Quando é utilizada uma abordagem padrão de otimização, como Baum Welch, que é uma técnica local, corre-se o risco dos parâmetros do MOM ficarem presos em um ótimo local. Desta forma, como mostram os resultados apresentados anteriormente, uma alternativa interessante para evitar este possível comportamento é utilizar o otimizador global EDSP.

Os resultados apresentados demonstram que o algoritmo EDSP aumenta a probabilidade de termos uma melhora na inicialização dos parâmetros do MOM. Desta forma, o método EDSP, pode ser agregado aos diferentes tipos de estratégias que são utilizadas para inicializar os parâmetros do Modelo Oculto de Markov.

6.3.3 Avaliação da qualidade de grupos de MUAPs

Neste trabalho, para realizar o agrupamento de MUAPs será utilizado o algoritmo Agrupamento Espectral. E, conforme apresentado anteriormente, é necessário realizar uma avaliação/validação dos grupos formados por qualquer algoritmo de agrupamento. Tal validação tem como objetivo verificar a similaridade entre os membros de um mesmo grupo, o que é um fator que indica que o agrupamento foi realizado de maneira adequada. Neste projeto, será realizada apenas a validação interna dos grupos, visto que os padrões de MUAPs não são conhecidos *a priori*; o que inviabiliza a validação externa dos grupos.

Para a validação dos grupos de MUAPs será utilizado, também, o algoritmo de Evolução Diferencial EDSP em conjunto com o método de verificação de similaridade de MUAPs proposto por [15].

Considerando o resultado do estudo descrito em [15], no estágio de verificação de similaridade de padrão entre os MUAPs, foram selecionadas as características propostas por aqueles autores [15]. De acordo com aqueles pesquisadores, os MUAPs gerados por

uma mesma Unidade Motora possuem as características de similaridade entre elas nas posições 5 a 25 e 50 a 80, considerando um MUAP representado por 100 pontos (Figura 6.32).

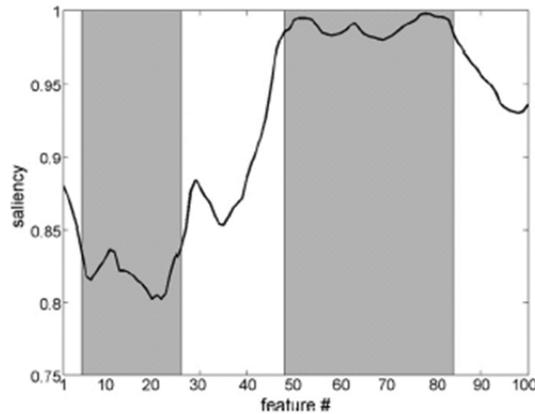


Figura 6.32: Representação das regiões (sombreado) de maior similaridade entre MUAPs gerados por uma mesma Unidade Motora [15].

Dessa forma, com a seleção do conjunto de características propostas por [15], é possível avaliar a qualidade de um grupo de MUAPs. Assim, basta verificar a convergência de tais características para os MUAPs pertencentes a um mesmo grupo: se eles foram selecionados para o mesmo grupo, então eles devem ter sido gerados pela mesma Unidade Motora. Uma forma de verificar a convergência de tais características para o conjunto de MUAPs de um mesmo grupo é utilizar a técnica Evolução Diferencial EDSP.

Conforme já foi apresentado no Capítulo 4, a Evolução Diferencial tem como objetivo convergir os indivíduos de uma população para uma solução ótima. Neste caso, o objetivo da Evolução Diferencial é convergir os MUAPs para um padrão único, utilizando as características propostas por [15]. Se a convergência acontecer, significa que todos os MUAPs realmente foram gerados pela mesma Unidade Motora, isto é, a qualidade do grupo de MUAPs foi validada e o grupo foi formado de maneira adequada. Caso contrário, significa que pode existir um ou mais MUAPs no grupo que não foram gerados pela mesma Unidade Motora, indicando que a qualidade do grupo não foi totalmente satisfatória.

Resultados

Para utilizar o algoritmo EDSP com a finalidade de agrupamento de MUAPs, foram

realizadas simulações considerando os seguintes casos:

1. Apenas 1 padrão de MUAP;
2. Múltiplos padrões de MUAPs;

Em todas as simulações, foram utilizados padrões de MUAPs provenientes do banco de dados de sinal EMG descrito no ANEXO II.

1 - Um único padrão de MUAP

Para esta simulação, os parâmetros do algoritmo EDSP foram definidos como a seguir:

- $D = 100$ (dimensão do cromossomo);
- $CR = 0.8$ (constante de cruzamento);
- $F = 0.8$ (constante de mutação);
- $NP = 76$ (número de membros da população);
- Número de iterações: 1000;

Neste grupo, foram consideradas 76 MUAPs que possuem o mesmo padrão morfológico. A Figura 6.33 apresenta o resultado da aplicação do algoritmo EDSP no conjunto de MUAPs.

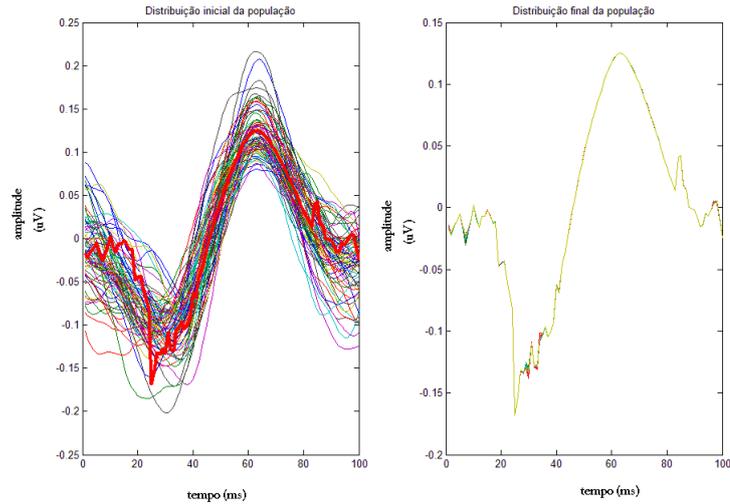


Figura 6.33: Agrupamento de um conjunto de 76 MUAPs utilizando o algoritmo EDSP. **Distribuição inicial da população:** apresenta os 76 MUAPs antes do início da otimização (a linha vermelha representa a média de todos os MUAPs; **Distribuição final da população:** apresenta a convergência de todos os MUAPs para um único padrão, após a execução do EDSP.

Após a execução do EDSP, 100% da população de MUAPs convergiu para um único padrão morfológico. Assim, é possível afirmar que o algoritmo EDSP foi capaz de agrupar os MUAPs em um único padrão morfológico, que representa o padrão de MUAP gerado pela Unidade Motora responsável por gerar aqueles MUAPs.

2 - Múltiplos padrões de MUAPs

Os parâmetros do algoritmo EDSP foram definidos como a seguir:

- $D = 100$ (dimensão do cromossomo);
- $CR = 0.8$ (constante de cruzamento);
- $F = 0.8$ (constante de mutação);
- $NP = 163$ (número de membros da população);
- Número de iterações: 1000;

Nesta segunda simulação foram utilizados quatro diferentes tipos de padrões de MUAPs (Figura 6.34).

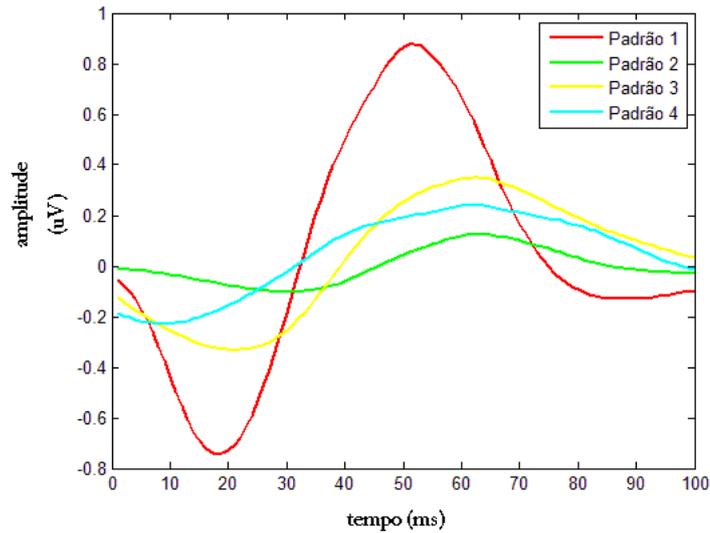


Figura 6.34: Quatro diferentes padrões de MUAPs que serão utilizados para a validação de grupos de MUAPs utilizando o algoritmo Evolução Diferencial.

A Figura 6.35 apresenta o resultado da otimização dos MUAPs utilizando o EDSP.

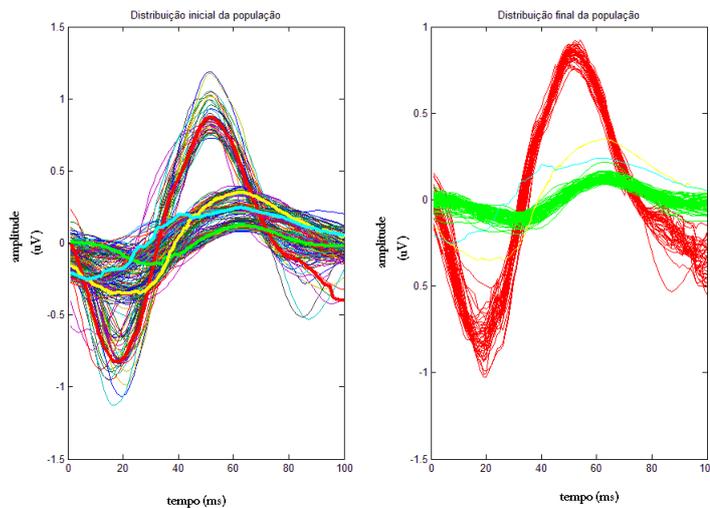


Figura 6.35: Agrupamento de um conjunto de quatro padrões de MUAPs utilizando o algoritmo EDSP. **Distribuição inicial da população:** apresenta os 163 MUAPs antes do início da otimização (as linhas coloridas representam a média de cada um dos cinco padrões de MUAPs); **Distribuição final da população:** apresenta a convergência de todos os membros da população para um dos quatro padrões existentes.

Nesta simulação, o agrupamento realizado pelo algoritmo EDSP apresentou a seguinte convergência para os 4 grupos de MUAPs (Tabela 6.1):

Tabela 6.1: Convergência dos MUAPs após a execução do EDSP.

Padrão de MUAP	Convergência da população para um padrão único	População na vizinhança do padrão único
1	85%	100%
2	100%	100%
3	98%	100%
4	82%	100%

Ao analisar os resultados do EDSP, é importante lembrar o aspecto probabilístico do algoritmo. Dessa forma, pode ocorrer que não aconteça a convergência de 100% da população para um padrão único, mas 100% da população está localizada em uma região próxima à este padrão. Assim, ao avaliar a convergência dos MUAPs para um padrão único, é necessário considerar uma margem de erro, que representa o aspecto probabilístico do EDSP e, dessa forma, é necessário avaliar as regiões vizinhas ao padrão encontrado para verificar se houve convergência da população para aquela região. Neste contexto, de acordo com a tabela 6.1 é possível concluir que o EDSP também obteve sucesso nas simulações: ele foi capaz de otimizar os MUAPs e agrupá-los em um dos 4 padrões morfológicos aos quais eles pertenciam, pois 100% dos MUAPs convergiram para regiões vizinhas a um padrão único de MUAP.

Após as análises realizadas, é possível concluir que com algoritmo EDSP, os MUAPs irão convergir para um padrão único se, e somente se, todos os MUAPs membros de um grupo pertencerem ao mesmo padrão morfológico, isto é, se tiverem sido gerados pela mesma Unidade Motora. Dessa forma, essa técnica é extremamente interessante para a avaliação da qualidade de grupos de MUAPs, pois se o grupo tiver um ou mais MUAPs morforlogicamente diferente dos demais, estes não irão convergir para o padrão morfológico do grupo. Assim, ao final da execução do algoritmo, será possível verificar que o grupo não está coeso, isto é, que não existe similaridade de características entre todos os MUAPs daquele grupo.

6.4 Conclusão

Este capítulo apresentou a estrutura do sistema de decomposição de sinal eletromiográfico de superfície utilizando Modelo Oculto de Markov. Foram apresentados, também, os detalhes de implementação das etapas que foram desenvolvidas neste trabalho. No próximo capítulo serão apresentados os métodos utilizados para a validação do sistema e os resultados obtidos.

Capítulo 7

Validação do sistema desenvolvido e resultados

7.1 Introdução

O capítulo 6 apresentou a estrutura e detalhou todos os passos do desenvolvimento do Sistema de Decomposição de Sinais EMG de superfície utilizando Modelo Oculto de Markov. Para validar a metodologia e os resultados do sistema, dois tipos de dados são utilizados:

1. Sinais EMG sintéticos;
2. Sinais EMG reais.

7.1.1 Sinais EMG sintéticos

Para o processo de validação do sistema proposto, foi utilizado um gerador de sinais EMG sintéticos, desenvolvido por [5]. Neste simulador, para a geração do sinal EMG, são consideradas as características de inter-pulsos dos MUAPs resultantes de investigações do músculo Interósseo Dorsal I.

Este simulador de sinais EMG permite que o usuário simule o hardware e gere sinais EMG sintéticos de acordo com a configuração dos seguintes parâmetros:

- **Quantidade de Unidades Motoras ativas:**

O usuário deve informar ao simulador a quantidade de Unidades Motoras que estarão

ativas no sinal EMG. Essa configuração define a quantidade de padrões morfológicos de MUAPs distintos que serão gerados;

- **Tempo:**

O tempo de simulação do sinal EMG em milisegundos (ms);

- **Frequência de amostragem:**

A frequência de amostragem desejada para o sinal EMG sintético deverá ser informada, obedecendo-se o Teorema de Nyquist. Dessa forma, para o sinal EMG, a frequência de amostragem mínima deverá ser 1024 Hz;

- **Relação sinal-ruído:**

A relação sinal-ruído também deverá ser fornecida ao sistema. Quanto maior for a relação sinal-ruído, maior a intensidade do sinal em relação ao nível de ruído inserido no mesmo.

A Figura 7.1 apresenta um exemplo de um código, na linguagem Matlab, que utiliza as funções do simulador desenvolvido por [5] para gerar um sinal EMG sintético.

```
t = 15000; %Tempo de simulação do sinal EMG (ms)
Fs = 10040; %Frequência de amostragem (Hz)
Nmus = 2; %Quantidade de Unidades Motoras ativas
SNR = 20; %Relação sinal-ruído (dB)
AmplifierGain = 10000; %Ganho do amplificador

[MU1,t,Fs] = exp_GenerateMUAPT(t,Fs,Nmus);
[EMG1] = exp_GenerateEMG(MU1,SNR,AmplifierGain);
```

Figura 7.1: Exemplo de utilização do Simulador de Sinais EMG sintéticos, desenvolvido por [5].

O benefício da utilização desse simulador se deve ao fato que, de posse de sinais EMG com características conhecidas (quantidade de Unidades Motoras e sua seqüência de disparos), é possível avaliar o resultado do sistema desenvolvido.

7.1.2 Sinais EMG reais

O banco de dados de sinais eletromiográficos reais que foi utilizado para a validação do projeto proposto foi disponibilizado por *Andrade, A. O.* [5]. Os dados foram coletados de 15 voluntários que executaram 6 diferentes tipos de contração muscular. No total, estão armazenados 900 segundos de sinal EMG neste banco de dados.

Os sinais foram obtidos por meio de dados experimentais, amostrados a 10 kHz e coletados utilizando eletrodos de referência (TECA NCS2000, Oxford Instrument Medical, Ag/AgCl), array de eletrodos de superfície (MedTech Systems Ltd, Ag/AgCl) e eletrodos invasivos (TECA X53153, Oxford Instruments Medical) e eletrodo de agulha, os quais foram posicionados no músculo Interósseo Dorsal I dos voluntários (Figura 7.2).

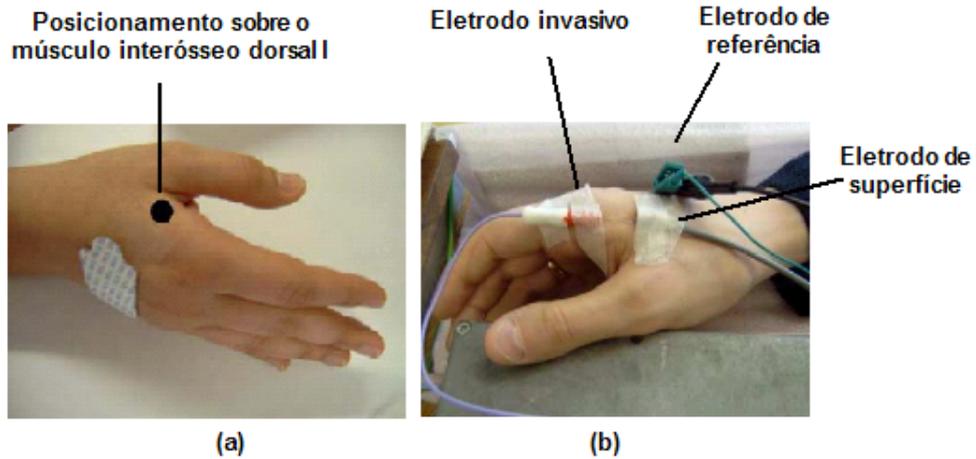


Figura 7.2: a) Posicionamento do músculo Interósseo Dorsal I; b) Posicionamento dos eletrodos de superfície, invasivo e de referência - modificado de [5].

A vantagem da utilização deste banco de dados no processo de validação do sistema proposto é a utilização do array de eletrodos. Este array é composto por 2 eletrodos, duplo diferencial, com área de captação de 1mm de diâmetro cada e distantes 3 mm um do outro (centro a centro) (Figura 7.3).

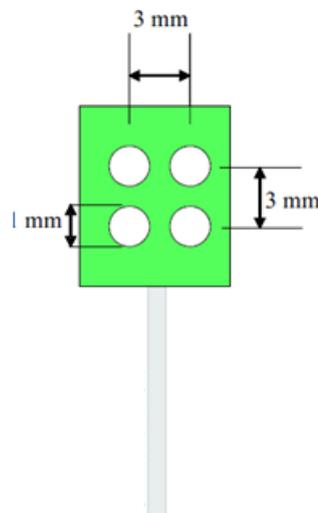


Figura 7.3: Representação do array de eletrodos utilizado na coleta dos sinais EMG de [5].

Desta forma, tem-se 2 eletrodos de superfície bastante próximos para captar o mesmo sinal EMG e dois canais EMG armazenando estes sinais. Assim, o sinal EMG captado por esses dois eletrodos serão bastante similares devido à proximidade dos eletrodos. Este contexto é propício para o processo de validação do sistema proposto, pois é possível

avaliar a resposta do sistema proposto nos dois canais e verificar a coerência entre os resultados fornecidos.

O ANEXO B apresenta mais informações sobre o protocolo experimental utilizado na coleta dos sinais que compõem este banco de dados de sinais EMG.

7.2 Resultados

Para realizar o procedimento do processo de validação do sistema proposto, foram realizadas simulações com os sinais EMG sintéticos e reais, conforme especificados na seção anterior. Os resultados dos testes de validação, bem como a discussão dos mesmos está relatada a seguir.

7.2.1 Sinais EMG sintéticos

No processo de validação utilizando sinais EMG sintéticos, são apresentados a seguir dois testes com sinais EMG com diferentes quantidades de Unidades Motoras ativas.

A - Teste 1:

Para este teste de validação, foi gerado um sinal EMG sintético com as seguintes características:

- Tempo de simulação: 1000 ms;
- Frequência de amostragem: 10000 Hz;
- Quantidade de Unidades Motoras: 3;
- Relação sinal-ruído: 20 dB;
- **Sinal EMG:**

A Figura 7.4 apresenta o sinal EMG sintético gerado pelo simulador, de acordo com as especificações anteriormente descritas.

Na Figura 7.4 é possível visualizar os MUAPs que compõe o sinal EMG que foi gerado pelo simulador. O próximo passo, que é a detecção dos MUAPs, é realizado pelo software EMG Decomposition BR.

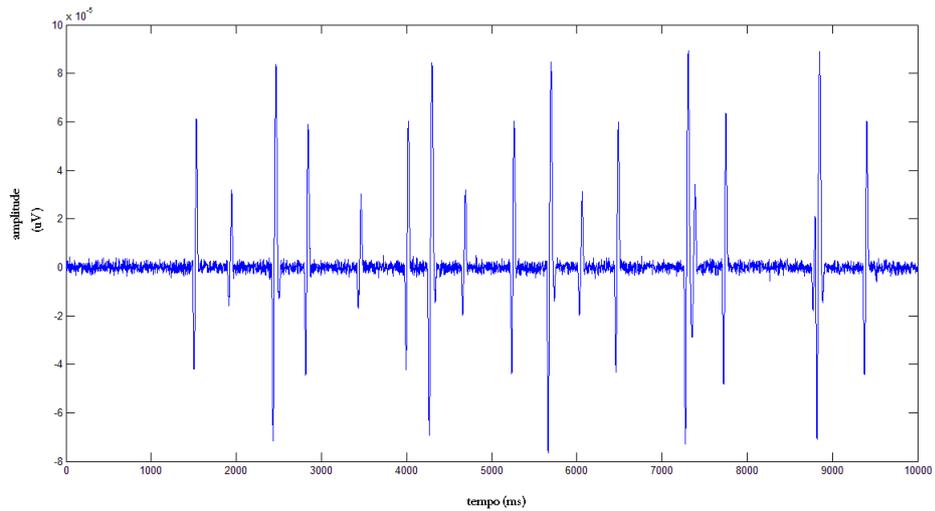


Figura 7.4: Sinal EMG sintético com 3 Unidade Motoras ativas. Neste sinal EMG existem 3 padrões de MUAP distintos, e cada um deles representa o padrão morfológico gerado por uma Unidade Motora ativa.

- **Detecção dos MUAPs do sinal EMG:**

A Figura 7.5 apresenta os MUAPs detectados pelo software EMG Decomposition BR. As linhas tracejadas e a contínuas indicam, respectivamente, o início e o final de cada MUAP.

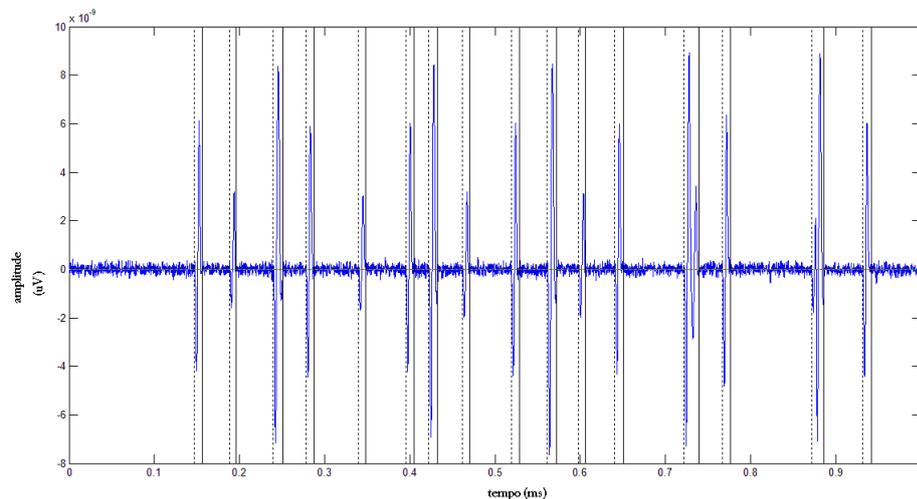


Figura 7.5: Teste 1: MUAPs detectados no sinal EMG, delimitados pelas linhas tracejadas e contínuas verticais.

Após realizada a etapa de detecção dos MUAPs, o próximo passo é realizado pelo

sistema proposto: agrupamento dos MUAPs.

- **Agrupamento dos MUAPs:**

A etapa de agrupamento de MUAPs, utilizando Modelo Oculto de Markov e Agrupamento Espectral, resultou em 3 grupos morfologicamente distintos de MUAPs, conforme mostra a Figura 7.6. Isto significa que o sistema detectou 3 Unidades Motoras ativas no sinal EMG analisado.

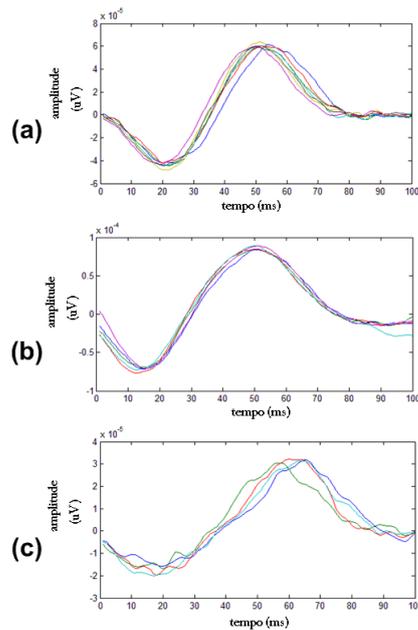


Figura 7.6: Grupos de MUAPs detectados na etapa de agrupamento do projeto proposto: (a) Grupo de MUAPs com padrão morfológico do tipo 1; (b) Grupo MUAPs com padrão morfológico do tipo 2; (c) Grupo de MUAPs com padrão morfológico do tipo 3.

Após a etapa de agrupamento, é necessário avaliar a qualidade dos grupos detectados, ou seja, é necessário avaliar a coesão morfológica entre os MUAPs pertencentes a um mesmo grupo.

Avaliação da qualidade dos grupos de MUAPs:

Conforme já foi relatado no Capítulo 6, para a avaliação da qualidade do grupos de MUAPs foi utilizado o algoritmo de Evolução Diferencial EDSP. Este algoritmo tem como função avaliar a qualidade do agrupamento realizado pelo Modelo Oculto de Markov e Agrupamento Espectral. Em outras palavras, o EDSP irá verificar se os MUAPs pertencentes a um mesmo grupo realmente apresentam o mesmo padrão morfológico.

– Grupo 1 de MUAPs:

A Figura 7.7 apresenta o resultado da avaliação da qualidade do grupo 1 de MUAPs, utilizando o algoritmo EDSP. Após a execução do EDSP, 100% dos MUAPs convergiram para um único padrão morfológico, o que indica que o grupo 1 de MUAPs está coeso.

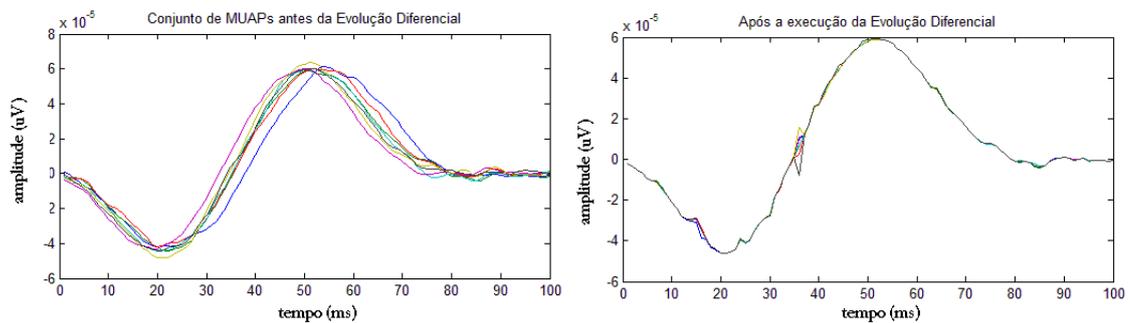


Figura 7.7: Avaliação da qualidade do grupo 1 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.

– **Grupo 2 de MUAPs:**

A Figura 7.8 apresenta o resultado da avaliação da qualidade do grupo 2 de MUAPs. Após a execução do algoritmo EDSP, 100% dos MUAPs convergiram para um único padrão morfológico, o que comprova que o grupo 2 de MUAPs também está coeso.

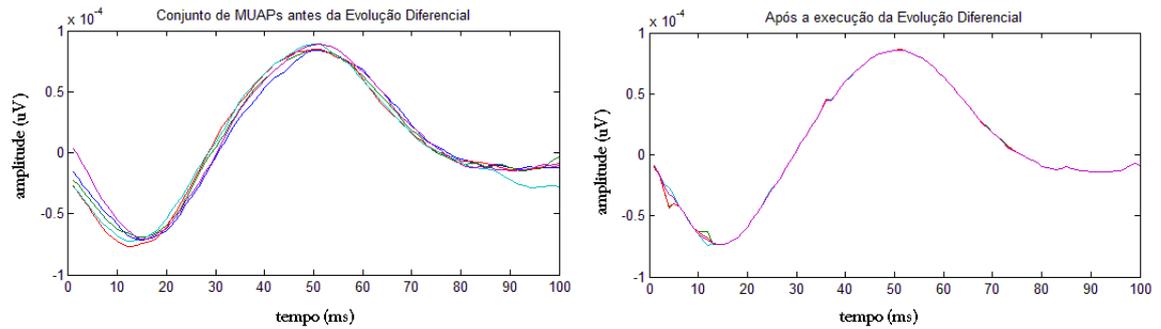


Figura 7.8: Avaliação da qualidade do grupo 2 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.

– **Grupo 3 de MUAPs:**

A Figura 7.9 apresenta a avaliação da qualidade do grupo 3 de MUAPs. Após a execução do algoritmo EDSP, 100% dos MUAPs deste grupo convergiram para um único padrão morfológico, o que mostra que o grupo 3 de MUAPs está coeso.

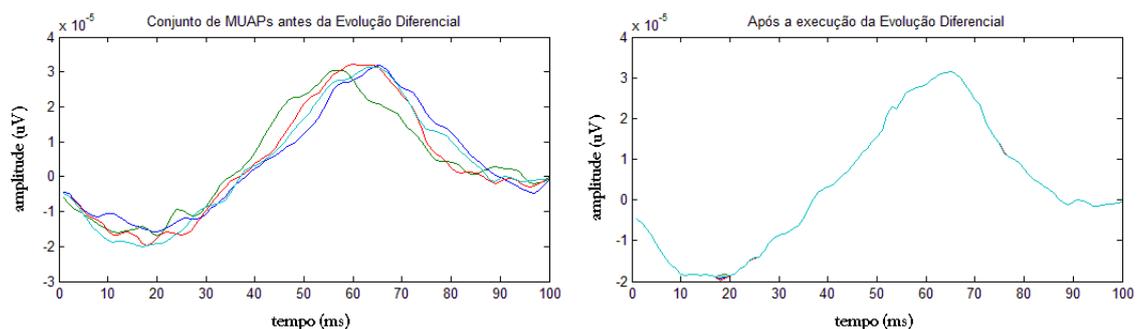


Figura 7.9: Avaliação da qualidade do grupo 3 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.

• **Seqüência de disparos das Unidade Motoras no sinal EMG:**

Após a etapa de agrupamento, temos a quantidade de Unidades Motoras ativas no sinal EMG e sabemos, também, os MUAPs que foram gerados por uma determinada Unidade Motora. Dessa forma, é possível retornar ao sinal EMG e determinar a seqüência de disparos das Unidades Motoras daquele sinal analisado (Figura 7.10). Analisando a correlação entre a seqüência de disparo dos Unidades Motoras do sinal EMG sintético com aquela gerada através do sistema proposto, foi avaliada a correlação entre estas seqüências e verificou-se que $\rho = 0.99$.

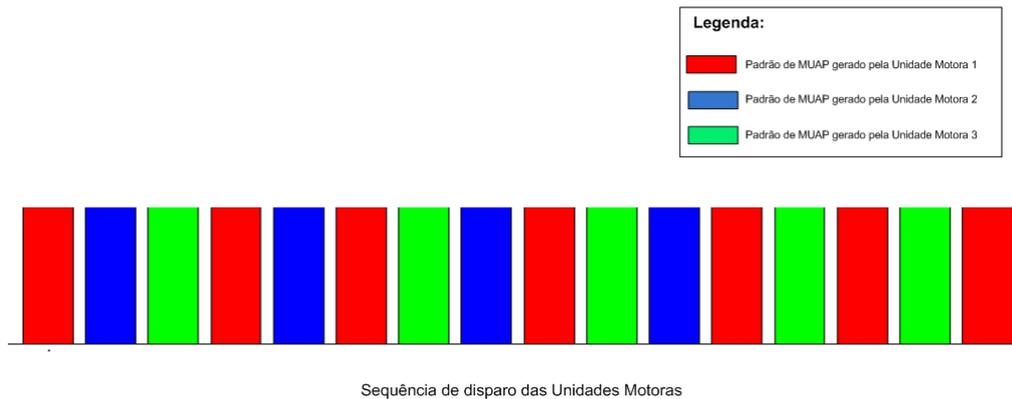


Figura 7.10: Resultado do sistema proposto: seqüência de disparos das Unidades Motoras.

Neste primeiro teste, o estágio inicial realizado pelo sistema foi a etapa de detecção de MUAPs do sinal EMG (Figura 7.5). Após o estágio de detecção de MUAPs, o sistema desenvolvido executou a etapa de agrupamento. Como resultado desta etapa, o sistema realizou o agrupamento de MUAPs e identificou 3 padrões morfológicos de MUAPs (Figura 7.6) e, considerando que uma Unidade Motora, geralmente, produz um padrão morfológico único de MUAP, é possível dizer que o algoritmo de Agrupamento Espectral identificou 3 Unidades Motoras ativas no sinal EMG - que é exatamente a quantidade de Unidades Motoras utilizadas para gerar o sinal EMG sintético.

E ainda, para a avaliação da qualidade dos grupos de MUAPs identificados pelo algoritmo Agrupamento Espectral, isto é, para avaliar a similaridade de padrão entre os MUAPs membros de um mesmo grupo (coesão entre os membros), foi utilizada a técnica Evolução Diferencial, implementada pelo algoritmo EDSP. Conforme já foi detalhado no Capítulo 5, o algoritmo Evolução Diferencial tem a capacidade de convergir os MUAPs que possuem o mesmo padrão morfológico para a mesma forma de onda. Dessa forma, se após a execução do algoritmo não houver convergência para um padrão único, significa

que os MUAPs não possuem o mesmo padrão morfológico, isto é, a qualidade do grupo não está adequada. Caso contrário, se houver convergência para um único padrão de MUAP, significa que o grupo está coeso, isto é, existe similaridade de padrão entre todos os MUAPs pertencentes ao grupo.

Assim, as Figuras 7.7, 7.8 e 7.9 apresentam o resultado da técnica Evolução Diferencial para os grupos identificados na Figura 7.6. Em cada uma dessas figuras, é possível visualizar o conjunto de MUAPs pertencentes ao grupo em análise e certificar a convergência do algoritmo EDSP para um padrão único: em todos os 3 grupos investigados, o EDSP otimizou 100% da população de MUAPs para um único padrão morfológico. Desta forma, é possível inferir que o Modelo Oculto de Markov e o algoritmo Agrupamento Espectral atingiu uma boa qualidade na formação dos grupos de MUAPs, pois foi comprovado pela técnica Evolução Diferencial que existe uma forte similaridade de padrão entre os membros dos grupos analisados.

Desta forma, de acordo com as informações provenientes da etapa de agrupamento a respeito da classificação de cada MUAP em relação à Unidade Motora que a gerou, o sistema forneceu a seqüência de disparos das Unidades Motoras presentes no sinal EMG analisado (Figura 7.10). Avaliando a correlação entre esta seqüência de disparos e aquela que realmente gerou o sinal sintético, foi observado um coeficiente $\rho = 0.99$, o que indica uma alta correlação entre as duas seqüências.

B - Teste 2:

Para este teste de validação, foi gerado um sinal EMG sintético com as seguintes características:

- Tempo de simulação: 8000 ms;
- Freqüência de amostragem: 10000 Hz;
- Quantidade de Unidades Motoras: 5;
- Relação sinal-ruído: 20 dB;
- **Sinal EMG:**

A Figura 7.11 apresenta o sinal EMG que foi gerado pelo simulador, de acordo com as especificações anteriormente descritas.

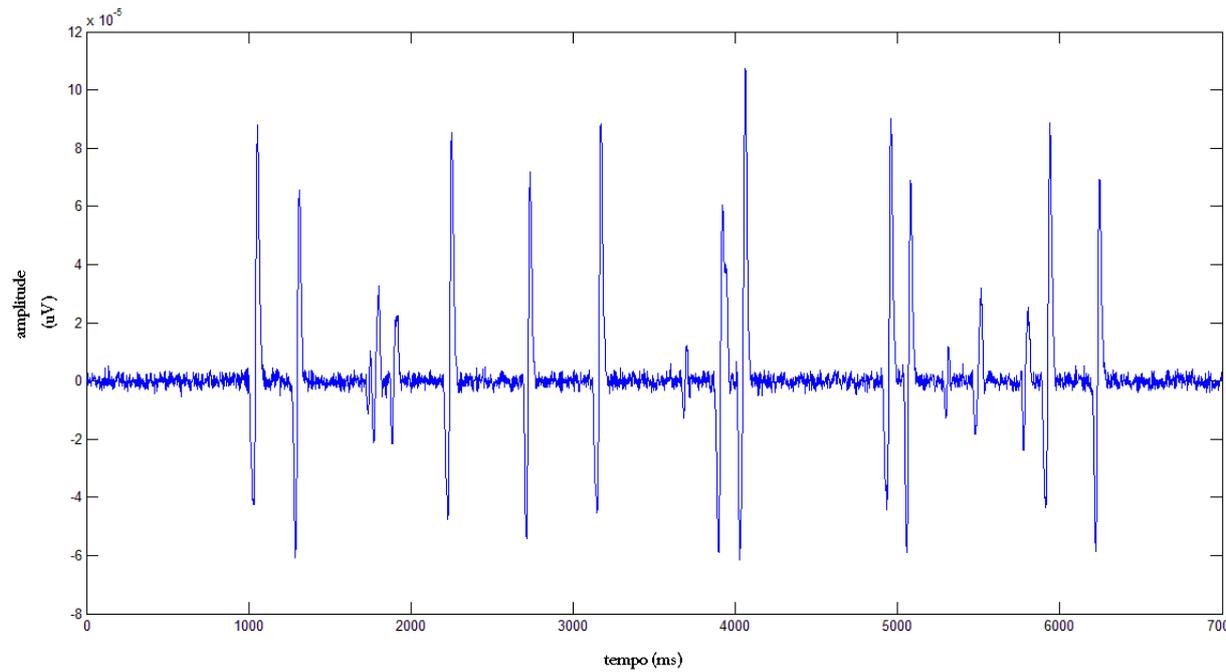


Figura 7.11: Sinal EMG sintético com 5 Unidade Motoras ativas.

- **Deteção de MUAPs do sinal EMG:**

Inicialmente, foi utilizado o software EMG Decomposition-Br para realizar a deteção dos MUAPs no sinal EMG analisado. Na Figura 7.12 as linhas verticais pontilhadas e verticais indicam, respectivamente, o início e o final de cada um dos MUAPs detectados.

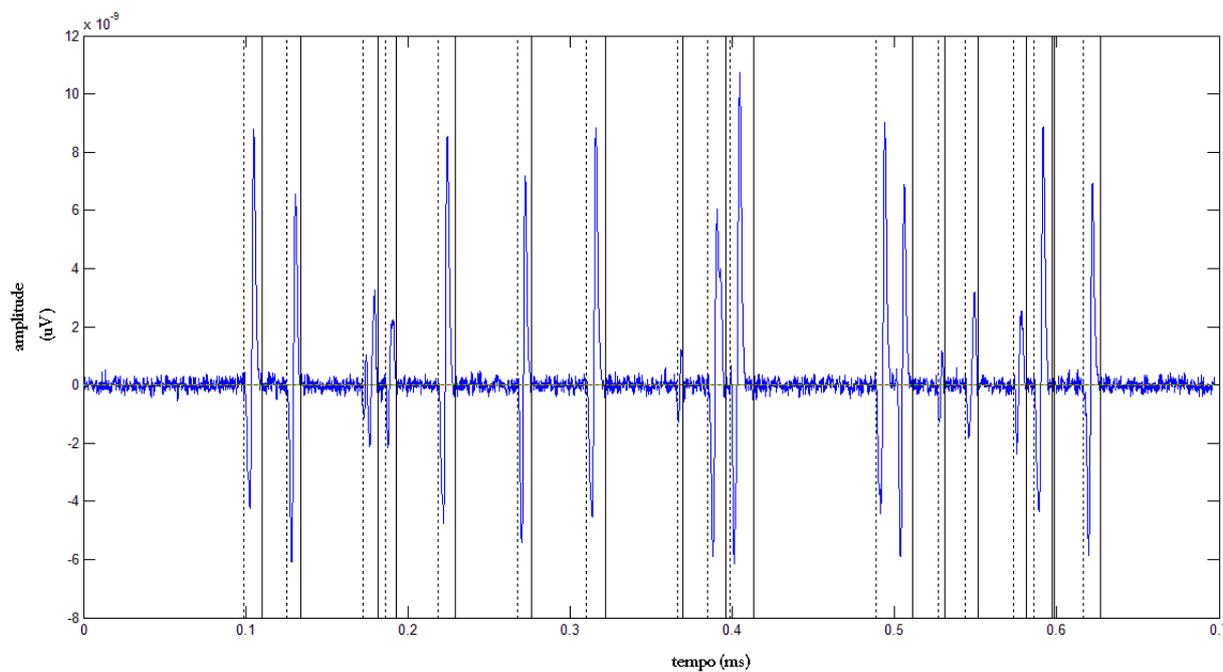


Figura 7.12: Teste 2: MUAPs detectados no sinal EMG sintético, delimitados pelas linhas tracejadas e contínuas verticais.

- **Agrupamento dos MUAPs:**

A etapa de agrupamento de MUAPs, utilizando Modelo Oculto de Markov e Agrupamento Espectral, resultou em 5 grupos, morfologicamente distintos, de MUAPs, conforme mostra a Figura 7.13.

Após a etapa de agrupamento, é necessário avaliar a coesão morfológica entre os MUAPs pertencentes a um mesmo grupo.

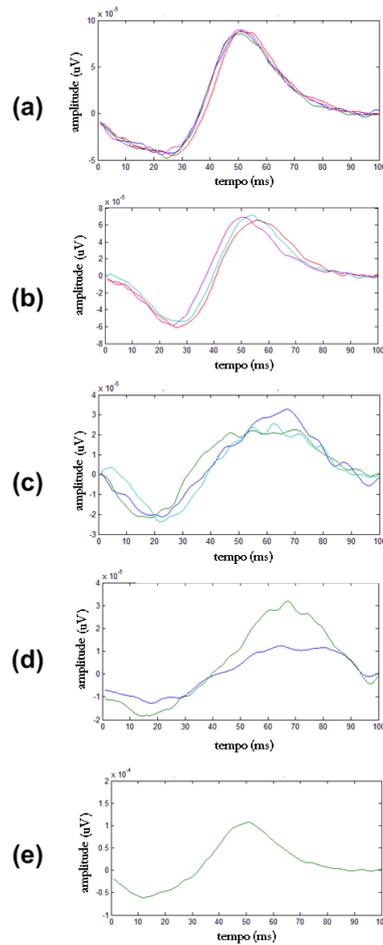


Figura 7.13: Grupos de MUAPs detectados na etapa de agrupamento do projeto proposto: **(a)** Grupo de MUAPs com padrão morfológico do tipo 1; **(b)** Grupo de MUAPs com padrão morfológico do tipo 2; **(c)** Grupo de MUAPs com padrão morfológico do tipo 3; **(d)** Grupo de MUAPs com padrão morfológico do tipo 4; **(e)** Grupo de MUAPs com padrão morfológico do tipo 5.

Avaliação da qualidade dos grupos de MUAPs:

Para a avaliação da qualidade dos grupos de MUAPs foi utilizado o algoritmo de Evolução Diferencial EDSP. Este algoritmo tem como função verificar se os MUAPs pertencentes a um mesmo grupo realmente apresentam o mesmo padrão morfológico. Em cada um dos 5 grupos de MUAPs analisados, verificou-se que o algoritmo EDSP conseguiu validar a qualidade do grupo, isto é, conseguiu detectar apenas um padrão morfológico em cada grupo (Figuras 7.14, 7.15, 7.16, 7.17 e 7.18). Nos grupos 2 e 3, o EDSP alcançou a convergência de 98% e 99% da população de MUAPs,

respectivamente. Nos demais grupos, alcançou 100% de convergência dos MUAPs para um único padrão.

– Grupo 1 de MUAPs:

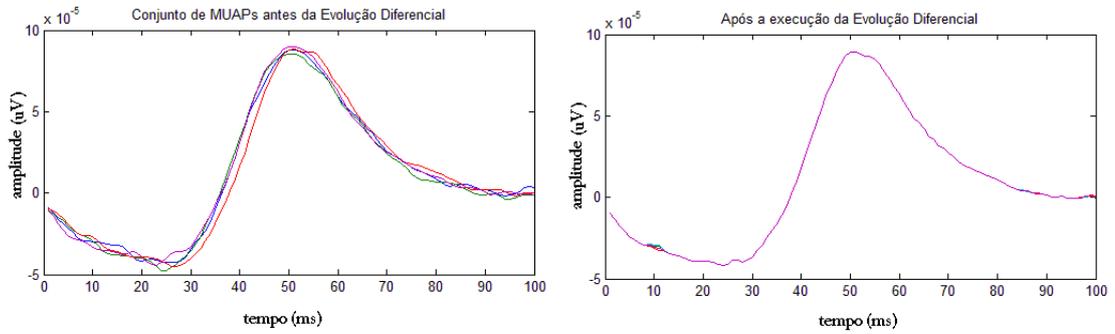


Figura 7.14: Avaliação da qualidade do grupo 1 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.

– Grupo 2 de MUAPs:

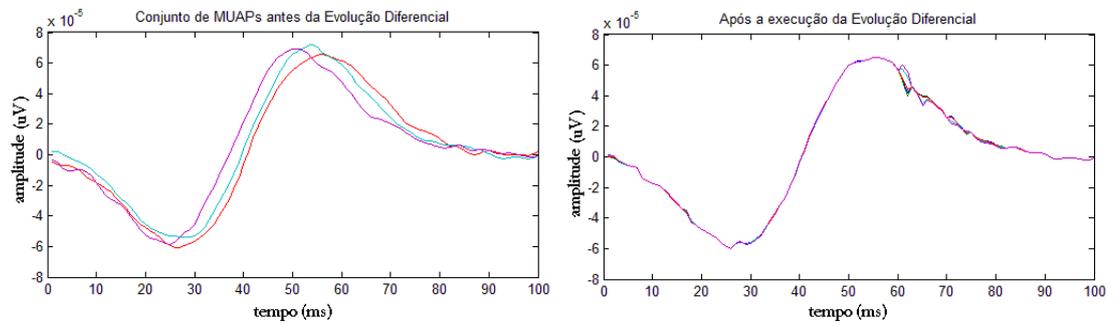


Figura 7.15: Avaliação da qualidade do grupo 2 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.

– Grupo 3 de MUAPs:

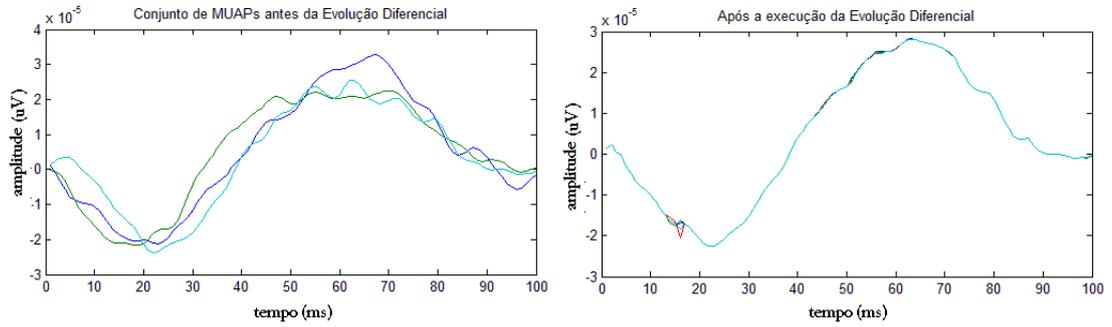


Figura 7.16: Avaliação da qualidade do grupo 3 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.

– Grupo 4 de MUAPs:

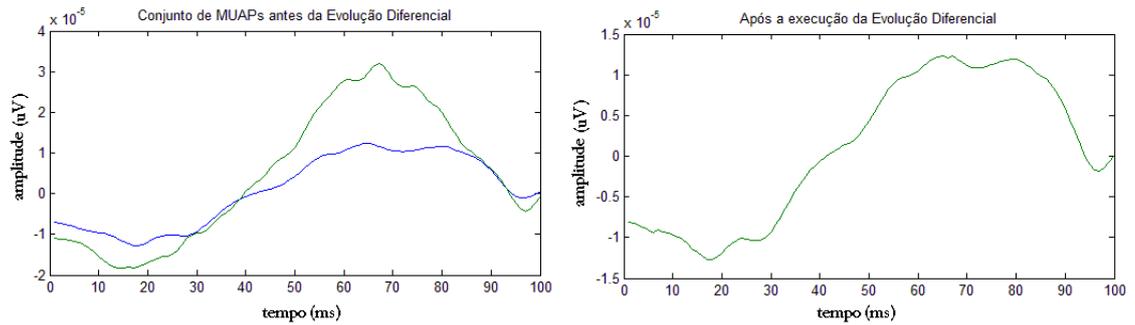


Figura 7.17: Avaliação da qualidade do grupo 4 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.

– Grupo 5 de MUAPs:

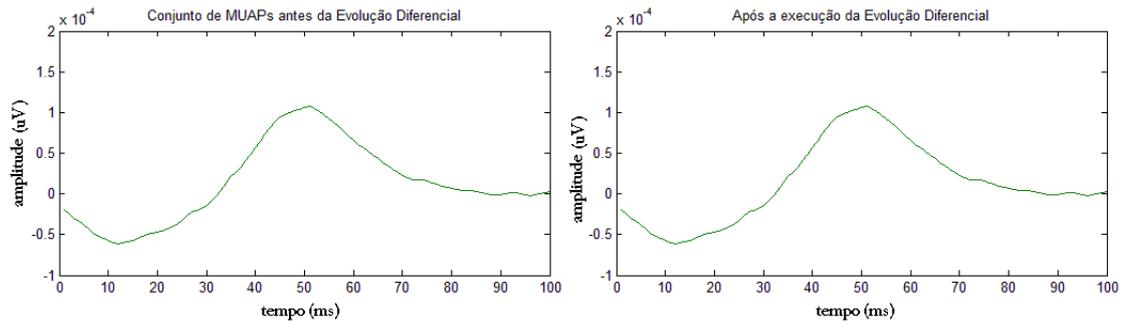


Figura 7.18: Avaliação da qualidade do grupo 5 de MUAPs utilizando o algoritmo de Evolução Diferencial EDSP.

- **Seqüência de disparos das Unidades Motoras do sinal EMG:**

Realizada a etapa de agrupamento, temos a quantidade de Unidades Motoras ativas no sinal EMG e sabemos os MUAPs que foram gerados por uma determinada Unidade Motora. Assim, é possível retornar ao sinal EMG e determinar a seqüência de disparos das Unidades Motoras daquele sinal analisado (Figura 7.19). Analisando a correlação entre a seqüência de disparo das Unidades Motoras do sinal EMG sintético com aquela gerada através do sistema proposto, verificou-se o coeficiente de correlação $\rho = 0.98$.

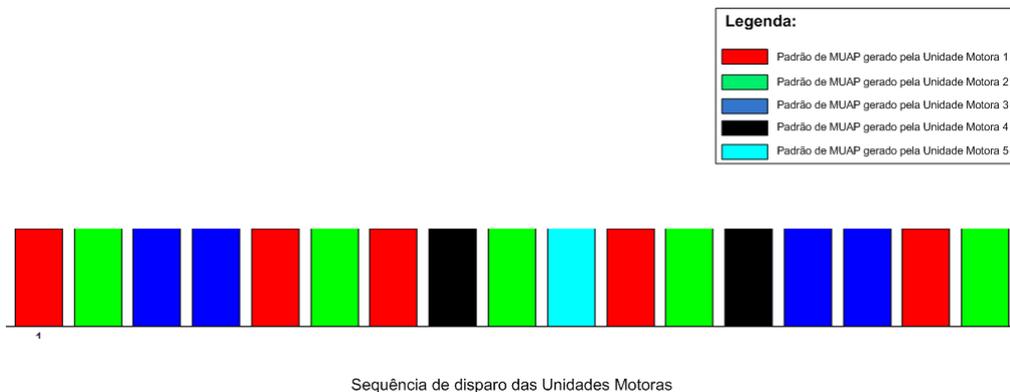


Figura 7.19: Resultado do sistema proposto: seqüência de disparos das Unidades Motoras.

Neste teste de validação, inicialmente foi realizado pelo sistema a etapa de detecção de MUAPs do sinal EMG (Figura 7.12). Após o estágio de detecção de MUAPs, o sistema desenvolvido executou a etapa de agrupamento. Como resultado desta etapa, o sistema realizou o agrupamento de MUAPs e identificou 5 padrões morfológicos de MUAPs (Figura

7.13) - que é exatamente a quantidade de Unidades Motoras utilizadas para gerar o sinal EMG sintético.

Para a avaliação da qualidade dos grupos de MUAPs identificados pelo algoritmo Agrupamento Espectral, foi utilizada a técnica Evolução Diferencial, implementada pelo algoritmo EDSP . Assim, as Figuras 7.14, 7.15, 7.16, 7.17 e 7.18 apresentam o resultado da técnica Evolução Diferencial para os grupos identificados na Figura 7.13. Os grupos atingiram convergência de MUAPs de 100%, 98%, 99%, 100% e 100%, respectivamente. Assim, é possível certificar a convergência do algoritmo Evolução Diferencial para um padrão único de MUAPs em cada um dos grupos analisados. Desta forma, é possível inferir que o Modelo Oculto de Markov e o algoritmo Agrupamento Espectral atingiram uma boa qualidade na formação dos grupos de MUAPs, pois estes apresentaram uma forte similaridade de padrão entre os membros de todos os grupos analisados.

E ainda, de acordo com as informações provenientes da etapa de agrupamento a respeito da classificação de cada MUAP em relação à Unidade Motora que a gerou, o sistema forneceu a seqüência de disparos das Unidades Motoras presentes no sinal EMG analisado (Figura 7.19). Para avaliar a corretude desta seqüência, foi calculada a correlação entre ela e a seqüência original que gerou o sinal sintético, e foi obtido um coeficiente de correlação $\rho = 0.98$, o que indica uma alta correlação entre as duas seqüências.

7.2.2 Sinais EMG reais

No processo de validação com sinais EMG reais, foram realizados testes com os sinais da base de dados de sinais EMG (ANEXO B), utilizando os dois canais coletados pelo array de eletrodos.

Como forma de validação dos resultados do sistema, foram verificadas as correlações das respostas do sistema entre os sinais provenientes dos dois eletrodos do array. A tabela 7.1 apresenta um resumo da aplicação do sistema nos sinais EMG coletados de 15 voluntários. Para cada voluntário, são apresentados:

- A quantidade de Unidades Motoras detectadas no sinal EMG proveniente do eletrodo 1;
- A quantidade de Unidades Motoras detectadas no sinal EMG proveniente do eletrodo 2;
- O coeficiente de correlação ρ entre a seqüência de disparos das Unidades Motoras dos dois sinais EMG, coletados pelos 2 eletrodos do array;
- A média do coeficiente de correlação ρ entre os padrões morfológicos dos MUAPs detectados entre os dois sinais EMG, coletados pelos 2 eletrodos do array. Esta média foi calculada com base no coeficiente de correlação entre todos os grupos de padrões morfológicos de MUAPs detectados nos dois sinais EMG.

Tabela 7.1: Resumo do resultado do sistema proposto após a aplicação de sinais EMG reais.

Voluntário	Eletrodo 1	Eletrodo 2	ρ seqüências	ρ MUAPs
1	2	2	0.88	0.91
2	3	3	0.92	0.89
3	3	3	0.89	0.91
4	2	2	0.90	0.75
5	3	3	0.93	0.79
6	2	2	0.86	0.87
7	2	2	0.92	0.96
8	3	3	0.88	0.93
9	3	3	0.88	0.91
10	2	2	0.82	0.77
11	2	2	0.88	0.91
12	3	3	0.90	0.94
13	2	2	0.70	0.84
14	4	4	0.71	0.83
15	3	3	0.88	0.94

De acordo com o exposto na tabela 7.1, em todos os testes realizados, o sistema proposto detectou a mesma quantidade de Unidades Motoras ativas para os dois sinais EMG analisados. Este resultado era esperado pois, considerando a proximidade dos dois eletrodos, eles realmente deveriam detectar a mesma quantidade de Unidades Motoras ativas.

E ainda, analisando o coeficiente de correlação entre a seqüência de disparo das Unidades Motoras estimadas para os dois sinais EMG de cada voluntário, verificou-se que em todos os casos analisados o sistema detectou um alto coeficiente de correlação entre eles. Isto significa que o sistema proposto detectou seqüências de disparos de Unidades Motoras correlacionadas nos dois sinais EMG analisados. Este resultado também era esperado, considerando a proximidade em que os dois eletrodos estavam posicionados.

É possível verificar que a técnica Evolução Diferencial EDSP também apresentou um resultado satisfatório, visto que o coeficiente de correlação médio extraído através da

comparação do formato padrão dos MUAPs entre os dois sinais EMG apresentou, em todos os casos analisados, um alto coeficiente de correlação. E ainda, este resultado mostra que o sistema proposto detectou os mesmos padrões morfológicos de MUAPs nos dois sinais EMG analisados. Este resultado reflete a avaliação do agrupamento, visto que a correlação entre o formato dos MUAPs foi calculada a partir do padrão detectado pelo EDSP. Dessa forma, pode-se afirmar que a avaliação da coesão e qualidade dos grupos de MUAPs obteve sucesso.

Os resultados obtidos através dos sinais EMG reais foram coerentes com aqueles que eram esperados para a validação do sistema proposto. A escolha desta base de dados de sinais EMG se deve, principalmente, ao fato de ter disponível sinais EMG coletados por eletrodos próximos (array de eletrodos). Esta configuração era uma condição necessária para poder validar o sistema proposto para sinais EMG reais, pois devido à proximidade dos eletrodos, a decomposição dos sinais EMG detectados por eles deveria ser coerente. Sendo assim, a coerência obtida entre os resultados desses dois canais EMG, denota a correteude do sistema desenvolvido.

7.3 Discussão

Nos dois tipos de testes realizados, com sinais EMG sintéticos e reais, o sistema forneceu os seguintes resultados sobre a decomposição do sinal EMG analisado:

- Quantidade de Unidade Motoras ativas;
- Padrão morfológico do MUAP gerado por cada Unidade Motora;
- Seqüência de disparo das Unidades Motoras.

Nos testes realizados com sinais EMG sintéticos, o sistema detectou corretamente a quantidade de Unidades Motoras ativas e apresentou, também, uma forte correlação entre a seqüência de disparos das Unidades Motoras geradas pelo sistema proposto e pelo sinal sintético - cujas características já eram conhecidas. E também, nos teste realizados com sinais EMG reais, o sistema proposto apresentou resultados coerentes, pois a mesma quantidade de Unidades Motoras foi detectada analisando o sinal EMG dos dois eletrodos do array, em todos os casos analisados.

Quanto à detecção da seqüência de disparo das Unidades Motoras, note que na tabela 7.1, através da análise do coeficiente de correlação ρ , houve uma correlação forte entre todas as seqüências de disparo de Unidades Motoras analisadas. Este resultando demonstra que o sistema desenvolvido detectou a seqüência correta de disparo das Unidades Motoras, pois houve coerência na correlação entre as duas seqüências de disparo das Unidades Motoras detectadas através do sinal EMG coletado dos 2 eletrodos do array. E também, na análise do sinal sintético, o sistema apresentou um alto coeficiente de correlação entre a seqüência de disparo das Unidades Motoras detectadas por meio da análise do sinal EMG sintético e a seqüência que, de fato, gerou este sinal EMG.

E ainda, ao comparar o padrão morfológico gerado pelo sistema para cada sinal analisado do array de eletrodos, o sistema também obteve uma forte correlação em todos os casos analisados. Para os dois eletrodos, o sistema detectou padrões morfológicos de MUAPs similares, isto é, detectou a mesma quantidade de Unidades Motoras ativas e o mesmo padrão morfológico de MUAP gerado por cada uma delas. Dessa forma, podemos inferir que o sistema forneceu respostas coerentes com aquelas que foram propostas.

É importante ressaltar a utilização do algoritmo EDSP para a avaliação da qualidade de um grupo de MUAPs e, também, na apresentação do padrão morfológico de um determinado grupo de MUAPs - o resultado final da aplicação do algoritmo EDSP é exatamente o padrão morfológico do MUAP gerado pela Unidade Motora. Em todos os testes realizados, houve uma convergência de 100% da população de MUAPs para um padrão morfológico único, quando considerada a vizinhança próxima do padrão detectado. Este resultado reflete muito bem o ótimo funcionamento da seleção probabilística implementada no algoritmo EDSP, pois mostra que a população, em nenhum caso analisado, ficou estagnada em um ótimo local e impedida de atingir o ótimo global.

Foi possível verificar, que a otimização dos parâmetros do Modelo Oculto de Markov com o algoritmo EDSP também comprovou ser eficiente, considerando que em todos os casos analisados, o MOM foi gerado de maneira que a verossimilhança entre os MOM dos MUAPs do sinal EMG apresentassem a proximidade necessária para ser realizado o agrupamento, utilizando o Algoritmo Espectral, e assim, detectar a quantidade de Unidades Motoras ativas. Se o MOM não tivesse sido gerado corretamente, esta condição teria sido refletida no agrupamento, pois não seria possível identificar corretamente a quantidade de Unidades Motoras ativas e a coesão do grupo de MUAPs detectados não

teria sucesso quando avaliado com o EDSP.

Não obstante, os outros sistemas de decomposição de sinais EMG de superfície já existentes, utilizam padrões pré-definidos de MUAPs para realizar o agrupamento dos MUAPs e, assim, detectar a quantidade de Unidades Motoras ativas. Entretanto, o sistema proposto não precisa saber, *a priori*, quais são os padrões de MUAP, pois será criado um Modelo Oculto de Markov para cada MUAP detectado e, através do Agrupamento Espectral, eles serão agrupados em seus devidos grupos. Dessa forma, a não-utilização de padrões pré-definidos de MUAPs também é um diferencial das técnicas implementadas no projeto. A representação de cada MUAP por um MOM, utilizando a técnica de extração de características apresentada no capítulo 6 é um avanço científico nas pesquisas de decomposição de sinais EMG de superfície, visto que não é necessário fazer o agrupamento supervisionado de MUAPs, isto é, não é necessário saber, *a priori*, os possíveis padrões de MUAPs que deverão ser encontrados no sinal EMG.

Assim, é possível concluir que o modelo gráfico-probabilístico Modelo Oculto de Markov, a técnica Agrupamento Espectral e a Evolução Diferencial EDSP possuem potencial de aplicabilidade na decomposição de sinais EMG de superfície. E ainda, estas ferramentas apresentaram resultados coerentes e coesos em todos os testes de validação realizados. Dessa forma, este conjunto de ferramentas é promissor e pode ser uma nova direção para as pesquisas na área de decomposição de sinais EMG de superfície.

7.4 Conclusão

Este capítulo apresentou os resultados obtidos no processo de validação do sistema proposto. De acordo com as discussões apresentadas na seção anterior, os resultados do sistema desenvolvido apresentaram uma boa resposta em todas as análises realizadas no que tange à:

- Determinação da quantidade de Unidades Motoras ativas nos sinais EMG;
- Determinação da seqüência de disparo das Unidades Motoras no sinal EMG analisado;
- Apresentação do padrão morfológico do MUAP gerado por cada Unidade Motora.

No próximo capítulo serão apresentadas as considerações finais e os trabalhos futuros que podem ser realizados a partir dessa pesquisa.

Capítulo 8

Considerações finais e trabalhos futuros

8.1 Conclusões gerais

A captação dos sinais fisiológicos provenientes do Sistema NeuroMotor, que pode ser realizada pela eletromiografia, tem sido cada vez mais utilizada na prática clínica para auxiliar o terapeuta no diagnóstico clínico. Desta forma, a identificação e classificação dos MUAPs de um sinal EMG de superfície é de extrema importância para o diagnóstico de distúrbios motores.

Entretanto, poucos esforços foram concentrados no que tange à decomposição de sinais EMG de superfície. A maior parte dos sistemas de decomposição de sinais EMG são específicos para o sinal proveniente de eletrodos invasivos, e isto, conforme já detalhado no capítulo 1, pode gerar alguns inconvenientes para alguns tipos de pacientes e tratamentos. Neste contexto, tomando como inspiração os modelos gráficos-probabilísticos que já são utilizados para o processamento do sinal EEG de superfície com significativo sucesso, este trabalho apresenta um sistema de decomposição de sinais EMG de superfície utilizando Modelos Ocultos de Markov, no intuito de auxiliar a prática clínica e as terapias de Biofeedback.

Para o detalhamento do sistema desenvolvido, no capítulo 2 foi apresentada uma revisão sobre os principais conceitos dos sinais EMG: fisiologia, captação e pré-processamento do sinal EMG. E ainda, foram apresentados os estágios do processo de decomposição do sinal EMG, relatando as técnicas já utilizadas na comunidade científica para este

propósito. E também, foi apresentado o software EMG-Decomposition Br, o qual é utilizado, parcialmente (apenas as etapas de pré-processamento e detecção dos MUAPs), no desenvolvimento do sistema proposto.

Já no capítulo 3, foi introduzida a técnica Modelo Oculto de Markov, apresentando os detalhes mais relevantes deste modelo. E também, foi realizado um estudo sobre as estratégias ideais para a inicialização dos parâmetros do modelo. Este estudo foi uma etapa fundamental para o correto entendimento do modelo e dos parâmetros de configuração do mesmo. Como resultado desse estudo, foi verificado que seria necessário utilizar um algoritmo de otimização global na etapa de inicialização dos parâmetros do modelo. A técnica selecionada para esta finalidade foi a Evolução Diferencial, devido a sua característica de otimização multimodal.

Assim, no capítulo 4 foi realizada uma revisão sobre a técnica Evolução Diferencial e foi detectado um inconveniente no algoritmo de implementação desta técnica: os elementos a serem otimizados apresentaram tendência a ficar estagnados em ótimos-locais, e assim, poderia não ser possível encontrar a melhor solução para a inicialização dos parâmetros do MOM. Dessa forma, foi proposta uma modificação no algoritmo Evolução Diferencial (EDSP), e esta modificação aprimorou significativamente o resultado da técnica Evolução Diferencial.

Em seguida, no capítulo 5, foi apresentada a técnica Agrupamento Espectral, a qual foi utilizada no estágio de agrupamento dos MUAPs, em conjunto com o Modelo Oculto de Markov Contínuo. Para a avaliação da qualidade do grupo de MUAPs detectado pelo Agrupamento Espectral, foi utilizado, também, o algoritmo Evolução Diferencial EDSP, que apresentou ser apropriado para validação interna de grupos de MUAPs provenientes de agrupamento não-supervisionado.

No capítulo 6, foi apresentado toda a estrutura do projeto proposto e foi mostrado, detalhadamente, o desenvolvimento de cada uma das etapas do projeto proposto. E também, este capítulo apresentou todas as implementações realizadas para o desenvolvimento do projeto.

No capítulo 7 foram apresentados os testes realizados para a validação do sistema proposto. Através dos resultados obtidos é possível inferir que o sistema de decomposição de sinais EMG de superfície proposto neste trabalho possui um funcionamento coerente com os resultados esperados. A boa correlação observada nos resultados apresentados para

os sinais EMG sintéticos, que eram os casos em que a composição do sinal (quantidade de Unidades Motoras ativas e a sequência de MUAPs) era conhecida, o sistema mostrou-se coerente em todas as etapas analisadas: agrupamento e geração do Modelo Oculto de Markov. E ainda, a técnica Evolução Diferencial mostrou-se eficaz para a análise dos grupos de MUAPs gerados pelo Agrupamento Espectral. Além de verificar a similaridade entre os MUAPs de um mesmo grupo, a técnica apresenta o padrão morfológico de MUAP de cada grupo.

Não obstante, na análise dos sinais reais, o sistema desenvolvido também apresentou resultados bastante coesos e coerentes entre os dois sinais provenientes do array de eletrodos. Conforme já dito anteriormente, para a validação do sistema era necessário que houvesse a coerência entre os resultados, visto que os dois sinais foram coletados por eletrodos muito próximos.

Sendo assim, é possível afirmar que o sistema desenvolvido apresentou resultados coerentes no que tange à:

- Identificação da quantidade de Unidades Motoras ativas no sinal EMG;
- Apresentação dos padrões morfológicos de MUAPs presentes no sinal EMG;
- Identificação da sequência de disparos das Unidades Motoras no sinal EMG analisado.

É importante ressaltar a potencialidade do Modelo Oculto de Markov e o Agrupamento Espectral para o processo de agrupamento dos MUAPs de um sinal EMG de superfície. E também, o EDSP mostrou ser uma boa ferramenta para a otimização dos parâmetros do MOM e para o processo de avaliação da qualidade interna dos grupos de MUAPs. Essas ferramentas, que ainda não tinham sido fruto de pesquisas na área de decomposição de sinais EMG, se destacam como excelentes técnicas para processamento de sinal EMG de superfície.

Finalmente, pode-se concluir de maneira positiva a hipótese colocada no Capítulo 1: é possível realizar a decomposição de sinais eletromiográficos de superfície utilizando modelo gráfico-probabilístico.

O sistema desenvolvido não tem a intenção de resolver todos os problemas relativos à decomposição de sinais EMG de superfície, porém ele apresenta uma nova abordagem e novas técnicas que produzem resultados úteis para a prática clínica e terapias de Biofeedback.

A arquitetura do modelo proposto constitui um avanço nas pesquisas de decomposição de eletromiografia de superfície.

Todos os resultados dos estudos realizados até o momento, foram publicados/submetidos em conferências e periódicos relevantes da área (ANEXO A).

8.2 Limitações do sistema

Apesar das inovações das técnicas propostas no sistema desenvolvido e dos satisfatórios resultados obtidos, o sistema proposto apresenta algumas limitações:

- A validação do sistema foi realizada somente para o músculo Intérosseio Dorsal I;
- O sistema não considera e não trata o fenômeno *cross-talk* e a superposição de MUAPs;
- O sistema não considera o caso de duas ou mais Unidades Motoras gerarem o mesmo padrão morfológico de MUAP, isto é, considera-se que cada Unidade Motora gera um padrão morfológico de MUAP distinto;
- O sistema considera que uma Unidade Motora sempre gera um mesmo padrão de MUAP.

8.3 Trabalhos futuros

A partir do trabalho desenvolvido, outros estudos podem ser realizados para aprimorar os resultados e a aplicação do sistema proposto:

- Investigação da utilização deste sistema em técnicas de Biofeedback;
- Validação, aplicação e análise do sistema desenvolvido em sinais EMG provenientes de outros grupos musculares;
- Investigação da utilização deste sistema na prática clínica;
- Estimativa da seqüência de disparos das Unidades Motoras (ANEXO C);
- Cálculo da probabilidade de disparo de Unidades Motoras (ANEXO C).

Referências bibliográficas

- [1] L. Lundy, *Neurociência-Fundamentos para a reabilitação*. Rio de Janeiro: Guanabara Koogan, 2000.
- [2] C. J. D. Luca, A. Adam, R. Wotiz, L. D. Gilmore, and H. Nawab, “Decomposition of surface emg signals,” *Neurophysiology*, vol. 96, pp. 1646–1657, 2006.
- [3] F. Pellegrino, “Avaliação da função neuromuscular: eletroneuromiografia. disponível em: <http://www.neurolatinvet.com/por/publi/neuromus.htm>. acesso: Junho-2010.”
- [4] E. L. M. Naves, “Modelagem e simulação do controle da postura ereta humana quasi-estática com reflexos neuromusculares,” Tese de doutorado, Universidade Federal de Uberlândia, 2006.
- [5] A. O. Andrade, “Decomposition and analysis of electromyographic signals,” Thesis, University of Reading, 2005.
- [6] A. C. Guyton, *Tratado de fisiologia médica*, 10th ed. Philadelphia: PA, 2002.
- [7] K. R. d. Barros, “Metodologia para classificação de sinais emg para controle de próteses com baixo esforço computacional,” Ph.D. dissertation, Universidade Federal de Uberlândia, 2005.
- [8] C. J. D. Luca, “Surface electromyography: detection and recording,” 1985.
- [9] K. Murphy, “Dynamic bayesian networks,” 2002.
- [10] H. Boulard and S. Bengio, “Hidden markov models,” in *The Handbook of Brain Theory and Neural Networks*, M. A. Arbib, Ed. London: The Mit Press, 2003, pp. 528–533.

- [11] R. D. U. B. Desai, “A tutorial on hidden markov models,” Indian Institute of Technology,” Technical Report n. SPANN-96.1, 1996, 56.
- [12] D. E. Goldberg, *Genetic algorithms in search, optimization and learning machine*. Canadá: Addison-Wesley, 1989.
- [13] R. Gamperle, S. D. Müller, and P. Koumoutsakos, “A parameter study for differential evolution,” Swiss Federal Institute of Technology Zürich, Tech. Rep., 2006.
- [14] K. Kanar, “Structure-oriented behavior tests in model validation.” Master, Bogazici University, 1999.
- [15] A. Vellido and A. O. Andrade, “Determination of feature relevance for the grouping of motor unit action potentials through a generative mixtures model,” *Biomedical signal processing and control*, pp. 111–127, 2007.
- [16] D. C. Preston and B. E. Shapiro, *Electromyography and neuromuscular disorders*. Philadelphia: Elsevier, 1998.
- [17] D. D. Barwick, “Clinical electromyography,” in *Disorders of voluntary muscle*, S. J. Walton, Ed. New York: Churcill Livingstone, 1981, pp. 952–975.
- [18] A. O. Andrade, “Metodologia para classificação de sinais emg no controle de membros artificiais,” dissertação de Mestrado, Universidade Federal de Uberlândia, 2000.
- [19] S. R. Devasahayam, *Signals and Systems in Biomedical Engineering*. New York: Kluwer Academic Plenum Publishers, 2000.
- [20] R. Merletti, “Electromyography - physiology, engineering and noninvasive application,” I. Press, Ed., New York, 2004, p. 494.
- [21] D. Stashuk, “Emg signal decomposition: how can it accomplished and used?” *Journal of Electromyography and kinesiology*, vol. 11, pp. 151–173, 2001.
- [22] J. V. Basmajian; and C. J. D. Luca, *Muscles alive*, 5th ed. USA: Williams and Wilkins, 1985.
- [23] D. W. Stashuk, “Decomposition and quantitative analysis of clinical electromyographic signals,” *Medical Engineering and Physics*, vol. 21, pp. 389–404, 1999.

- [24] H. Broman, “Knowledge based signal processing in the decomposition of myoelectric signals,” *IEEE Engineering in Medicine and Biology Magazine*, pp. 24–28, 1988.
- [25] D. Farina, A. Crosetti, and R. Merletti, “A model for the generation of synthetic intramuscular emg signals to test decomposition algorithms,” *IEEE transactions on biomedical engineering*, vol. 48, pp. 66–77, 2001.
- [26] S. L. Pullman, D. D. Goodin, A. I. Marquinez, S. Tabbal, and M. Rubin, “Clinical utility of surface emg: report of the therapeutics and technology assessment subcommittee of the american academy of neurology,” *Neurology*, vol. 55, no. 2, pp. 171–177, 2000.
- [27] C. Sauvage, M. Manto, A. Adam, R. Roark, P. Jissendi, and C. J. d. Luca, “Ordered motor unit firing behavior in acute cerebellar stroke,” *Neurophysiology*, vol. 96, pp. 2769–2774, 2006.
- [28] L. J. Pino, D. W. Stashuk, S. G. Boe, and T. J. Doherty, “Motor unit potential characterization using pattern discovery,” *Medical Engineering and Physics*, pp. 563–573, 2008.
- [29] G. Pfeiffer, “The diagnostic power of motor unit potential analysis: an objective bayesian approach,” *Muscle and nerve*, vol. 22, pp. 584–591, 1999.
- [30] G. Pfeiffer and K. Kunze, “Discriminant classification of motor unit potentials (mups) successfully separates neurogenic and myopathic conditions. a comparison of multi and univariate diagnostic algorithms for mup analysis,” *Electroencephalography and clinical neurophysiology*, vol. 97, 1995.
- [31] D. W. Stashuk, “Decomposition and quantitative analysis of clinical electromyographic signals,” *Medical Engineering and Physics*, vol. 21, pp. 389–404, 1999.
- [32] S. H. Nwabi, R. P. Wotiz, and C. J. d. Luca, “Decomposition of indwelling emg signals,” *Journal of Applied Physiology*, vol. 15, pp. 700–710, 2008.
- [33] T. J. Doherty and D. Stashuk, “Decomposition based quantitative electromyography: methods and initial normative data in five muscles,” *Muscle and nerve*, vol. 28, pp. 204–211, 2003.

- [34] X. Ren, X. Hu, Z. Wang, and Z. Yan, “Muap extraction and classification based on wavelet transform and ica for emg decomposition,” *Medical and biological engineering and computing*, vol. 44, pp. 371–382, 2006.
- [35] N. Sheikholeslammi and D. Stashuk, “Supervised mutual-information based feature selection for motor unit action potential classification,” *Medical and Biological engineering*, vol. 35, pp. 661–670, 1997.
- [36] K. S. Tucker, “Electromyography: some methodological problems and issues,” *Physical Therapy*, vol. 73, no. 10, pp. 698–710, 1993.
- [37] B. Obermaier, C. Guger, C. Neuper, and G. Pfurtscheller, “Hidden markov models for online classification of single trial eeg data,” *Pattern Recognition Letters*, vol. 22, pp. 1299–1309, 2001.
- [38] T. Al-Ani, Y. Haman, R. Fodil, and D. Isabey, “Using hidden markov models for sleep breathing identification,” *Simulation Modelling Practice and Theory*, vol. 12, pp. 117–128, 2004.
- [39] A. Flexer, P. Sykacek, I. Rezek, and G. Dorffner, “Using hidden markov models to build an automatic, continuous and probabilistic sleep stager,” *IEEE*, pp. 627–631, 2000, 55.
- [40] L. R. Rabiner and B. H. Juang, “An introduction to hidden markov models,” *IEEE ASSP Magazine*, pp. 4–16, 1986, 51.
- [41] P. Smyth, “Clustering sequences with hidden markov models,” in *Advances in Neural Information Processing Systems*, M. C. Mozer, Ed. MIT Press, 1997, 99.
- [42] W. Zuo-Ying and X. Xi, “Duration distribution based hmm for speech recognition,” *Front. Electr. Electron. China*, vol. 1, pp. 26–30, 2006, 131.
- [43] L. R. Rabiner, “A tutorial on hidden markov models and selected applications in speech recognition,” *IEEE*, vol. 77, pp. 257–286, 1989, 53.
- [44] W. H. Wollaston, “The croonian lecture,” *Philosophical Transaction of the Royal Society of London*, vol. 100, pp. 1–15, 1810.

- [45] J. R. Cram; G. S. Kasman; and J. Holtz, *Introduction to surface electromyography*, 1st ed. Maryland, USA: Aspen publishers, 1998.
- [46] J. V. Basmajian, “Electrodes and electrode connectors,” in *New developments in Electromyography and Clinical Neurophysiology*, J. E. Desmedt, Ed. Karger, Basel, 1973, vol. 1, pp. 502–510.
- [47] J. R. Cram, “The history of surface electromyography,” *Applied Pshychophysiology and Biofeedback*, vol. 28, pp. 81–91, 2003.
- [48] D. D. Barwick, “Clinical electromyography,” in *Disorders of voluntary muscle*, S. J. Walton, Ed. New York: Churcill Livingstone, 1981, pp. 952–975.
- [49] R. Rudel; and J. Senges, “Experimental myotonia,” in *New developments in Eletromyography and Clinical Neurophysiology*, J. E. Desmedt, Ed. Karger, Basel, 1973, vol. 1, pp. 483–491.
- [50] E. Kuhn, *New Developments in Electromyography and Clinical Neurophysiology*, 1973, vol. 1.
- [51] F. C. Brown and C. B. W. Parry, “Neuromuscular stimulation and transmission,” in *Disorders of voluntary muscle*, S. J. Wanton, Ed. New York: Churcill Livingstone, 1981, pp. 907–927.
- [52] J. N. Walton and D. Gardner-Medwin, “Progressive muscular dystrophy and the myotonic disorders,” in *Disorders of Voluntary Muscle*, S. J. Walton, Ed. Neuw York: Churchill Livingstone, 1981, pp. 482–515.
- [53] M. J. Aminoff, *Electromyography in clinical practice*. Churcill Livingstone, 1998.
- [54] R. Merletti, D. Farina, M. Gazzoni, A. Merlo, P. Ossola, and A. Rainoldi, “Surface electromyography: a window on the muscle, a glimpse on the central nervous system,” *Europa Medicophysica*, vol. 37, pp. 57–68, 2001.
- [55] M. J. Zwarts, G. Drost, and D. F. Stegeman, “Recent progress in the diagnostic use of surface emg for neurological diseases,” *Journal of Electromyography and Kinesiology*, vol. 10, no. 5, pp. 287–291, 2000.

- [56] B. Jonsson, “Electromyography kinesiology: aims and fields of use,” in *New Developments in Electromyography and Clinical neurophysiology*, J. E. Desmedt, Ed. Karger, Basel, 1973, vol. 1, pp. 498–501.
- [57] G. L. Soderberg and L. M. Knutson, “A guide for use and interpretation of kinesio-logic electromyographic data,” *Physical Therapy*, vol. 80, no. 5, 2000.
- [58] M. G. Benedetti, “Muscle activation intervals and emg envelope in clinical gait analysis,” *IEEE Engineering in Medicine and Biology*, vol. November/December, pp. 33–34, 2001.
- [59] A. B. Soares, “Shape memory alloy actuators for upper limb prostheses,” Ph.D. dissertation, University of Edinburgh, 1997.
- [60] A. B. Soares, A. O. Andrade, E. Lamounier, and R. Carrijo, “The development of a virtual myoelectric prosthesis controlled by an emg pattern recognition system based on neural networks,” *Journal of Intelligent Information Systems*, vol. 21, no. 2, pp. 127–141, 2003.
- [61] E. A. Clancy, S. Bouchard, and D. Rancourt, “Estimation and application of emg amplitude during dynamic contractions,” *IEEE Engineering in Medicine and Biology*, vol. November/December, pp. 47–54, 2001.
- [62] R. Merletti and D. Farina, “Surface emg processing: introduction to the special issue,” *Biomedical signal processing and control*, pp. 115–117, 2008.
- [63] P. Shenoy, K. . Miller, B. Crawford, and R. P. N. Rao, “Online electromyographic control of a robotic prosthesis,” *IEEE Transactions on Biomedical Engineering*, vol. 55, no. 3, pp. 1128–1135, 2008.
- [64] S. R. Devasahayam, *Signals and Systems in Biomedical Engineering*. New York: KA PP, 2000.
- [65] A. P. R. d. Souza, “Uma proposta de metodologia para determinação de envelope de atividade eletromiográfica,” Dissertação de Mestrado, Universidade Federal de Uberlândia, 2005.

- [66] S. E. Widamalm and M. M. A. Jr, "Method for identification and classification of single motor unit potentials in diagnostic electromyography," *Journal of Oral Rehabilitation*, vol. 17, pp. 49–59, 1990.
- [67] R. S. LeFever, A. P. Xenakis, and C. J. D. Luca, "A procedure for decomposing the myoelectric signal into its constituent action potentials- part ii: execution and test accuracy," *IEEE Transactions on Biomedical Engineering*, vol. 29, no. 3, pp. 158–164, 1982.
- [68] R. S. LeFever and C. J. D. Luca, "A procedure for decomposing the myoelectric signal into its constituent action potentials-part i: technique, theory and implementation," *IEEE Transactions on Biomedical Engineering*, vol. 29, no. 3, pp. 149–157, 1982.
- [69] J. Fang, G. C. Agarwal, and B. T. Shahani, "Decomposition of motor unit electromyographic signals," *IEEE Transactions on Biomedical Engineering*, vol. 46, no. 6, pp. 685–697, 1999.
- [70] E. Chauvet, O. Fokapu, J. Y. Hogrel, D. Gamet, and J. Duchene, "Automatic identification of motor unit action potential trains from electromyographic signals using fuzzy techniques," *Medical and biological engineering and computing*, vol. 41, no. 6, pp. 646–653, 2003.
- [71] X. Ren, Z. Yan, Z. Wang, and X. Hu, "Noise reduction based on ica decomposition and wavelet transform for the extraction of motor unit action potentials," *Journal of Neuroscience Methods*, vol. 158, pp. 313–322, 2006.
- [72] S. Widmanlm and M. M. A. Jr., "Method for identification and classification of single motor unit potentials in diagnostic electromyography," *Journal of Oral Rehabilitation*, pp. 49–59, 1990.
- [73] C. J. D. Luca, "Decomposition of the emg signal into constituent motor unit action potentials," *Muscles Nerve*, vol. 18, pp. 1492–1494, 1995.
- [74] G. H. Loudon, N. B. Jones, and A. S. Sehmi, "New signal processing techniques for the decomposition of emg signals," *Medical and Biological Engineering*, vol. 30, pp. 591–599, 1992.

- [75] M. S. Lewicki, “A review of methods for spike sorting: the detection and classification of neural action potentials,” *Comput. Neural Syst.*, vol. 9, pp. 53–58, 1998.
- [76] D. Zennaro, P. Wllig, v. M. Koch, G. S. Moschytz, and t. Laubli, “A software package for the decomposition of long-term multichannel emg signals using wavelet coefficients,” *IEEE Transactions on Biomedical Engineering*, vol. 50, no. 1, pp. 58–69, 2003.
- [77] A. O. Andrade, S. J. Nasuto, and P. Kyberd, “Extraction of motor unit action potentials from electromyographic signals through generative topographic mapping,” *Journal of the Franklin Institute*, vol. 344, pp. 154–179, 2007.
- [78] A. O. Andrade, S. Nasuto, P. Kyberd, and C. M. Sweeney-Reed, “Emg signal filtering based on empirical mode decomposition,” *Biomedical Signal Processing and Control*, pp. 44–55, 2006.
- [79] A. O. Andrade, S. Nasuto, and P. Kyberd, “Extraction of motor unit action potentials from electromyographic signals through generative topographic mapping,” *Journal of The Franklin Institute*, pp. 154–179, 2006.
- [80] A. O. Andrade, S. Nasuto, P. Kyberd, and C. M. Seeney-Reed, “Generative topographic mapping applied to clustering and visualization of motor unit action potentials,” *Bio Systems*, pp. 273–284, 2005.
- [81] K. Aas, L. Eikvil, and R. B. Huseby, “Applications of hidden markov chains in image analysis,” *Pattern Recognition*, vol. 34, no. 4, pp. 703–713, 1999, 91.
- [82] T. Petrie, “Probabilistic functions of finite state markov chains,” *The Annals of Mathematical Statistics*, vol. 40, pp. 97–115, 1969.
- [83] M. A. Mohamed and P. Gader, “Generalized hidden markov models - part i: Theoretical frameworks,” *IEEE Transactions on fuzzy systems*, vol. 8, pp. 67– 81, 2000, 62.
- [84] A. Schliep, “A bayesian approach to learning hidden markov model topology with applications to biological sequence analysis,” Dissertation, Universität zu Köln, 2001.

- [85] I. Visser, M. E. J. Rijamakers, and P. C. M. Molenaar, “Confidence intervals for hidden markov model parameters,” *British Journal of Mathematical and Statistical Psychology*, vol. 53, pp. 317–327, 2000, 59.
- [86] K.-S. Lee, “Emg-based speech recognition using hidden markov models with global control variables,” *IEEE Transactions on Biomedical Engineering*, pp. 930–940, 2008.
- [87] W. H. Laverty, M. J. Miket, and I. W. Kelly, “Simulation of hidden markov models with excel,” *The Statistician*, vol. 51, pp. 31–40, 2002, 189.
- [88] J. Picone, “Continuous speech recognition using hidden markov models,” *IEEE ASSP Magazine*, pp. 26–41, 1990, 63.
- [89] S. Bengio, “Multimodal speech processing using asynchronous hidden markov models,” *Information Fusion*, vol. 5, pp. 81–89, 2004, 187.
- [90] A. Kundu and A. Bayya, “Speech recognition using hybrid hidden markov model and nn classifier,” *International Journal of speech technology*, vol. 2, pp. 227–240, 1998, 167.
- [91] T. L. Nwe, S. W. Foo, and L. C. d. Silva, “Speech emotion recognition using hidden markov models,” *Speech Communication*, vol. 41, pp. 603–623, 2003, 119.
- [92] J. d. Veth and H. Boulard, “Comparison of hidden markov model techniques for automatic speaker verification in real world conditions,” *Speech Communication*, vol. 17, pp. 81–90, 1995, 121.
- [93] K. Aas, L. Eikvil, and T. Andersen, “Text recognition from grey level images using hidden markov models,” 2007, 85.
- [94] S. A. Adeed, C. Higgins, and D. Elliman, “Off line recognition of handwritten arabic words using multiple hidden markov models,” *Knowledge Based Systems*, vol. 17, pp. 75–79, 2004, 171.
- [95] T. Artieres, N. Gauthier, P. Gallinari, and B. Dorizzi, “A hidden markov models combination framework for handwriting recognition,” *International JOurnal on Document Analysis and Recognition*, no. 5, 2002, 163.

- [96] S. K. Kim, S. M. Park, J. K. Lee, and H. J. Kim, "On line recognition of korean characters using art neural network and hidden markov model," *Journal of Systems Architecture*, vol. 44, pp. 971–984, 1998, 145.
- [97] K. Nathan, A. Senior, and J. Subrahmonia, "Initialization of hidden markov models for unconstrained on line handwriting recognition," in *Acoustics, Speech, and Signal Processing*, vol. 6, Atlanta, 1996, pp. 3502–3505, 114.
- [98] H. S. Park and S. W. Lee, "Off line recognition of large set handwritten characters with multiple hidden markov models," *Pattern Recognition*, vol. 29, no. 2, pp. 231–244, 1995, 142.
- [99] G. Saon, "Cursive word recognition using a random field based hidden markov model," *International JOurnal on Document Analysis and Recognition*, vol. 1, pp. 199–208, 1999, 170.
- [100] L. Yang, B. K. Widjaja, and R. Prasad, "Application of hidden markov models for signature verification," *Pattern Recognition*, vol. 28, pp. 161–170, 1995, 146.
- [101] R. Granat and A. Donnellan, "A hidden markov model based tool for geophysical data exploration," *Pure and Applied Geophysics*, vol. 159, pp. 2271–2283, 2002, 168.
- [102] J. Horneegger, H. Niemann, D. Paulus, and G. Schlottke, "Object recognition using hidden markov models," in *Pattern Recognition in Practice IV*, Vileland, Netherlands, 1994, pp. 37–44, 88.
- [103] M. Ibrahim, N. John, M. Kabuka, and A. Younis, "Hidden markov models-based 3d mri brain segmentation," *Image and vision computing*, pp. 1065–1079, 2006, 176.
- [104] A. V. Nefian and M. H. Hayes, "Face detection and recognition using hidden markov models," in *International Conference on Image Processing*, vol. 1, 1998, pp. 141–145, 87.
- [105] M. Dong, D. He, P. Banerjee, and J. Keller, "Equipment health diagnosis and prognosis using hidden semi-markov models," *Int. J. Manuf Technol*, vol. 30, pp. 738–749, 2006, 128.

- [106] H. Uguz, A. Arslan, and I. Turkoglu, “A biomedical system based on hidden markov model for diagnosis of the heart valve diseases,” *Pattern Recognition Letters*, vol. 28, pp. 395–404, 2007, 109.
- [107] K. Fielding and D. W. Ruck, “Recognition of moving light displays using hidden markov models,” *Pattern Recognition*, vol. 28, no. 9, pp. 1415–1421, 1995, 139.
- [108] R. Iyer, H. Gish, M.-H. Siu, G. Zavaliagos, and S. Matsoukas, “Hidden markov models for trajectory modeling,” 2007, 100.
- [109] R. Hassan, B. Nath, and M. Kirley, “A data clustering algorithm based on single hidden markov model,” in *International Multiconference on Computer Science and Information Technology*, 2006, pp. 57–66, 105.
- [110] A. A. Kassim, Z. Mian, and M. A. Mannan, “Tool condition classification using hidden markov model based on fractal analysis of machined surface textures,” *Machine Vision and Applications*, vol. 17, pp. 327–336, 2006, 165.
- [111] J. Moldenhauer, T. Beth, and U. Mende, “Hidden markov models for the analysis and classification of ultrasound data,” *International Congress Series*, vol. 1268, pp. 231–236, 2004, 172.
- [112] A. Panuccio, M. Bicego, and V. Murino, “A hidden markov model based approach to sequential data clustering,” in *Structural, Syntactic and statistical pattern recognition*, T. Caelli and A. Amin, Eds. Springer, 2002, pp. 734–742, 94.
- [113] K. S. A. M. R. Rosenfeld, “Learning hidden markov model structure for information extraction,” in *AAAI Workshop on Machine Learning for Information Extraction*, 1999, 52.
- [114] W. D. Penny and S. J. Roberts, “Gaussian observation hidden markov models for eeg analysis,” Imperial College,” Technical Report, 1998, 92.
- [115] A. Cohen, “Hidden markov models in biomedical signal processing,” *20th Annual International Conference of the IEEE engineering in medicine and biology society*, vol. 3, 1998, 28.

- [116] I. Gat, N. Tishby, and M. Abeles, “Hidden markov modeling of simultaneously recorded cells in the associative cortex of behaving monkeys,” *Network: Computation in neural systems*, vol. 8, no. 3, pp. 197–322, 1997, 102.
- [117] A. Koshki, “Modelling ecg signals with hidden markov models,” *Artificial Intelligence in Medicine*, vol. 8, pp. 453–471, 1996, 132.
- [118] W. Xu, J. Wu, Z. Huang, and C. Guan, “Kernel based hidden markov model with applications to eeg signal classification,” *Biomedical Engineering*, pp. 401–404, 2005, 93.
- [119] F. M. Shubeita and P. O. A. Navaux, “Computação evolutiva e lógica fuzzy,” Universidade Federal do Rio Grande do Sul, Tech. Rep., 2003.
- [120] J. R. Kosa, *Genetic programming: on the programming of computers by means of natural selection*. USA: MIT, 1992.
- [121] S. Nolfi and D. Parisi, “Evolution of artificial neural networks,” in *The Handbook of Brain Theory and Neural Networks*, M. A. Arbib, Ed. London: The MIT Press, 2003.
- [122] S. Kwong, C. W. Chau, K. R. Man, and K. S. Tang, “Optimisation of hmm topology and its model parameters by genetic algorithms,” *Pattern Recognition*, vol. 34, pp. 509–522, 2001, 162.
- [123] K. W. Beisel and B. Fritsch, “Evolution of genetic networks,” in *The Handbook of Brain Theory and Neural Networks*, M. A. Arbib, Ed. London: The MIT Press, 2003.
- [124] S. Nolfi, “Evolution and learning in neural networks,” in *The Handbook of Brain Theory and Neural Networks*, M. A. Arbib, Ed. London: The MIT Press, 2003.
- [125] E. Raimann, “Geração de rotas urbanas virtuais usando algoritmos genéticos,” Ph.D. dissertation, Universidade Federal de Uberlândia, 2007.
- [126] M. Mitchell, *An Introduction to Genetic Algorithms*. The MIT Press, 1998.
- [127] K. F. Man, K. S. Tang, and S. Kwong, *Genetic Algorithms*. London: Springer, 2001.

- [128] R. I. A. Davis and B. C. Lovell, “Comparing and evaluating hmm ensemble training algorithms using train and test condition number criteria,” *Pattern Anal Applic*, vol. 6, pp. 327–336, 2003, 129.
- [129] L. Chambers, *The practical handbook of Genetic Algorithms*. Florida: Champaman Hall, 2001.
- [130] S. F. d. Silva, “Realimentação de relevância via algoritmos genéticos aplicada à recuperação de imagens,” Ph.D. dissertation, Universidade Federal de Uberlândia, 2007.
- [131] J. Rees and G. J. Koehler, “Learning genetic algorithm parameters using hidden markov models,” *European Journal of Operational Research*, vol. 175, pp. 806–820, 2006, 110.
- [132] K. V. Price, R. M. Storn, and J. A. Lampinen, *Differential Evolution - A Practical Approach to Global Optimization*. Springer, 2005.
- [133] R. Storn and K. Price, “Differential evolution - a simple and efficient heuristic for global optimization over continuous spaces,” *Journal of Global Optimization*, vol. 11, pp. 341–359, 1997.
- [134] X. Li, “Efficient differential evolution using speciation for multimodal function optimization,” in *Conference on Genetic and Evolutionary Computation*, Washington DC, 2005, pp. 873–880.
- [135] T. Robic and B. Filipic, “Demo: Differential evolution for multiobjective,” Jozef Stefan Institute, Tech. Rep., 2005.
- [136] L. S. Roger, M. S. Tan, and G. P. Rangaiah, “Global optimization of benchmark and phase equilibrium problems using differential evolution,” National University of Singapore, Tech. Rep., 2006.
- [137] S. Sharma, “Cluster analysis,” in *Applied Multivariate Techniques*. USA: John Wiley and Sons, 1996, pp. 185–236.
- [138] A. K. Jain;, M. N. Murty;, and P. J. Flynn, “Data clustering: a review,” *ACM Computing Surveys*, vol. 31, no. 3, pp. 264–323, 1999.

- [139] R. Xu; and D. W. W. II, “Survey of clustering algorithms,” *IEEE Transactions on Neural Networks*, vol. 16, no. 3, pp. 645–678, 2005.
- [140] A. K. Jain; and R. C. Dubes, *Algorithms for clustering data*, 1st ed. New Jersey: Prentice Hall, 1988.
- [141] J. G. Dy; and C. Brodley, “Feature selection for unsupervised learning,” *Journal of Machine Learning Research*, vol. 5, pp. 845–889, 2004.
- [142] W. W. Hsieh, “Nonlinear multivariate and time series analysis by neural network methods,” *Reviews of Geophysics*, vol. 42, no. 1, pp. 1–44, 2004.
- [143] R. O. Duda;, P. E. Hart;, and D. G. Stork, *Pattern classification*. USA: John Wiley and Sons, 2001.
- [144] L. Kaufman; and P. Rousseeuw, *Finding Groups in Data: An Introduction to Cluster Analysis*, 1 ed. Wiley-Interscience, 1990.
- [145] U. V. Luxburg, “A tutorial on spectral clustering,” *Statistics and Computing*, vol. 17, no. 4, pp. 395–416, 2007.
- [146] L. Liu;, J. Kang;, J. YU;, and Z. Wang, “A comparative study on unsupervised feature selection methods for text clustering,” in *Proceeding of Natural Language Processing and Knowledge Engineering '05*, 2005.
- [147] R. Jin;, C. Ding;, and F. Kang;, “A probabilistic approach for optimizing spectral clustering,” in *In advances in neural information processing*, 2005.
- [148] T. Buhler; and M. Hein, “Spectral clustering base on the graph p-laplacian,” Saarland University, Tech. Rep., 2006.
- [149] U. V. Luxburg;, M. Belkin;, and O. Bousquet, “Consistency of spectral clustering,” Institute for Biological Cybernetics, Tech. Rep., 2004.
- [150] Y. Chi;, X. Song;, D. Zhou;, K. Hino;, and B. Tseng, “On evolutionary spectral clustering,” *ACM Transactions on Knowledge Discovery from data*, vol. 3, no. 4, 2009.

- [151] D. Garcia-Garcia, “A new distance measure for model-based sequence clustering,” *IEEE Transactions on pattern analysis and machine intelligence*, vol. 31, no. 7, pp. 1325–1331, 2009.
- [152] A. Y. Ng.;, M. I. Jordan; and Y. Weiss, “On spectral clustering: Analysis and an algorithm,” in *Advances in Neural Information Processing Systems*. MIT-Press, 2001, pp. 849–856.
- [153] F. R. Bach; and M. I. Jordan, “Learning spectral clustering,” in *Advances in neural information processing*. MIT Press, 2003.
- [154] Z. Wu; and R. Leahy, “An optimal graph theoretic approach to data clustering: theory and its application to image segmentation,” *IEEE Transactions on pattern analysis and machine intelligence*, vol. 15, no. 11, pp. 1101–1113, 1993.
- [155] S. E. Schaeffer, “Graph clustering,” *Computer Science Review*, vol. 1, pp. 27–64, 2007.
- [156] F. R. K. Chung, “Spectral graph theory,” *American Mathematical Society*, 1997.
- [157] C. Ding; X. He; H. Zha; M. Gu; and H. Simon, “A min-max cut algorithm for graph partitioning and data clustering,” in *IEEE Int. Conf. Data Mining*, 2001.
- [158] L. Hagen; and A. Kahng, “Fast spectral methods for ratio cut partitioning and clustering,” in *Proc. of IEEE International Conference on Computer Aided Design*, 1991, pp. 10–13.
- [159] J. Shi; and J. Malik; “Normalized cuts and image segmentation,” *IEEE Transactions on pattern analysis and machine intelligence*, vol. 22, pp. 888–905, 2000.
- [160] L. Hagen; and A. B. Kahng, “New spectral methods for ratio cut partitioning and clustering,” *Computer-Aided Design of Integrated Circuits and Systems, IEEE Transactions*, vol. 11, no. 9, pp. 1074–1085, 1992.
- [161] G. H. Golub; and C. F. V. Loan, *Matrix Computations*. Johns Hopkins University Press, 1996.

- [162] B. Mohar, “The laplacian spectrum of graphs,” in *Graph, theory, cominatorics and applications*, Y. Alavi; and A. J. Schewenk, Eds. New Youk: John Wiley, 1991, vol. 2.
- [163] C. Fraley; and A. E. Raftery, “How many clusters? which clustering method? answers via model-based cluster analysis,” *The Computer Journal*, vol. 41, pp. 578–588, 1998.
- [164] A. Hardy, “On the number of clusters,” *Computational statistics and data analysis*, vol. 23, pp. 83–96, 1996.
- [165] L. Zelnik-Manor; and P. Perona, “Self-tuning spectral clustering,” in *Advances in Neural Information Processing Systems*. MIT Press, 2004, pp. 1601–1608.
- [166] Y. Barlas; and K. Kanar, “Automated dynamic pattern recognition and testing,” *System Dynamics Review*, 2003.
- [167] Y. He; and A. Kundu, “2-d shape classification using hidden markov model,” *IEEE Trans. Patt. Anal. Machine Intell*, vol. PAMI, no. 13, pp. 1172–1184, 1991.
- [168] E. Seidemann, I. Melijson, M. Abeles, H. Bergman, and E. Vaadia, “Simultaneously recorded single units in the frontal cortex go through sequences of discrete and states in monkeys performing a delayed localization task,” *The Journal of Neuroscience*, vol. 2, no. 16, pp. 752–768, 1996, 101.
- [169] P. J. Bickel, Y. Ritov, and T. Ryden, “Asymptotic normality of the maximum-likelihood estimator for general hidde markov modelse,” *The Annals of statistics*, vol. 26, pp. 1664–1635, 1998.
- [170] R. V. Babu, B. Anantharaman, K. R. Ramakrishnan, and S. H. Srinivasan, “Compressed domain action classification using hmm,” *Pattern Recognition Letters*, vol. 23, pp. 1203–1213, 2002, 160.
- [171] X. Ji, J. Li-Ling, and Z. Sun, “Mining gene expression data using a novel approach based on hidden markov models,” *FEBS Letters*, pp. 125–131, 2003, 175.
- [172] K. T. Abou-Moustafa, M. Cheriet, and C. Y. Suen, “On the structure of hidden markov models,” *Pattern Recognition Letters*, vol. 25, pp. 923–931, 2004, 116.

- [173] K. C. Jung, S. M. Yoon, and H. J. Kim, “Continuous hmm applied to quantization of on line korean character spaces,” *Pattern Recognition Letters*, vol. 21, pp. 303–310, 2000, 137.
- [174] M. J. Reyes-Gomez and D. P. W. Elli, “Selection, parameter estimation and discriminative training of hidden markov models for generic acoustic modeling,” in *International conference on multimedia and expo*, vol. 2, 2003, pp. 73–76, 95.
- [175] D. K. Kim and N. S. Kim, “Maximum a posteriori adaptation of hmm parameters based on speaker space projection,” *Speech Communication*, vol. 42, pp. 59–73, 2004, 185.
- [176] T. Petrie, “Probabilistic functions of finite state markov chains,” *The Annals of Mathematical Statistics*, vol. 40, pp. 97–115, 1969.
- [177] Z. Ghahramani, “Graphical models: Parameters learning,” in *The Handbook of Brain Theory and Neural Networks*, M. A. Arbibi, Ed. London: The MIT Press, 2003.
- [178] A. Howard and C. Rorres, *Álgebra Linear com Aplicações*. Porto Alegre: Bookman, 2001.
- [179] R. S. Kenneth Price, “Differential evolution. disponível em: <http://www.icsi.berkeley.edu/storn/code.html>. acesso: Junho-2008,” 2006.
- [180] R. W. Johnson, “An introduction to the bootstrap,” *Teaching Statistics*, vol. 23, no. 2, pp. 49–54, 2001, 25.
- [181] Z. Psaradakis, “Blockwise bootstrap testing for stationarity,” no. *Statistics and probability letters*, pp. 562–570, 2006, 12.
- [182] A. M. Zoubir and B. Boashash, “The bootstrap and its application in signal processing,” *IEEE signal processing magazine*, pp. 57–76, 1998, 26.
- [183] A. M. Zoubir and D. R. Iskander, “Bootstrap matlab toolbox,” *Software Reference Manual*, 1998, 24.

Apêndice A

Publicações

Os artigos listados abaixo são referentes aos resultados que foram publicados e submetidos durante a realização desta pesquisa.

- SA, A. A. R; SOARES, A. B; ANDRADE, A. O; NASUTO, S. J. **An optimization proposal in Differential Evolution algorithm based on probabilistic selection to escape from local optima**, Evolutionary Computation, 2010. (Submetido)
- SA, A. A. R; SOARES, A. B; ANDRADE, A. O; NASUTO, S. J. **On the clustering of Motor Unit Action Potentials using continuous Hidden Markov Model and Spectral Clustering**, Computational Intelligence, 2010. (Submetido)
- SA, A. A. R; SOARES, A. B; ANDRADE, A. O; NASUTO, S. J. **Decomposition of sEMG using Hidden Markov Model**, Biomedical Engineering, 2010. (Submetido).
- SA, A. A. R; SOARES, A. B; ANDRADE, A. O; NASUTO, S. J. **On the clustering of motor unit action potentials based in Differential Evolution algorithm**, Proceedings of the IEEE, V.1, p. 338-342, 2010.
- SA, A. A. R; ANDRADE, A. O; SOARES, A. B; NASUTO, S. J. **On the initialization of Hidden Markov Models parameters using Differential Evolution**, CBEB 2008 (Congresso Brasileiro de Engenharia Biomédica), Salvador - Brasil, 2008. Anais: CD-ROM.

- SA, A. A. R; ANDRADE, A. O; SOARES, A. B; NASUTO, S. J. **A Study Regarding initialization of Hidden Markov Models Parameters using Differential Evolution**, BICS 2008 (Brain Inspired Cognitive Systems), São Luis - Brasil, 2008. Anais: disponível em “<http://www.ufma.br/bics2008>”.
- SA, A. A. R; ANDRADE, A. O; SOARES, A. B; NASUTO, S. J. **On the initialization of parameters of Hidden Markov Models**, V CEEL (Conferência e Estudos em Engenharia Elétrica), Uberlândia - Brasil, 2007. Anais: CD-ROM.
- SA, A. A. R; ANDRADE, A. O; SOARES, A. B; NASUTO, S. J. **A Proposal of a Modification in the Standard Differential Evolution Algorithm to Escape from Local Optima**, BICS 2008 (Brain Inspired Cognitive Systems), São Luis - Brasil, 2008. Anais: disponível em “<http://www.ufma.br/bics2008>”.
- SA, A. A. R; ANDRADE, A. O; SOARES, A. B; NASUTO, S. J. **Estimation of Hidden Markov Models Parameters using Differential Evolution**, AISB 2008 Convention (Swarm Intelligence Algorithms and Applications), Aberdeen - Scotland, 2008. Anais: CD-ROM.
- SA, A. A. R; ANDRADE, A. O; SOARES, A. B; NASUTO, S. J. **Exploration vs. Exploitation in Differential Evolution**, AISB 2008 Convention (Swarm Intelligence Algorithms and Applications), Aberdeen - Scotland, 2008. Anais: CD-ROM.
- SA, A. A. R; ANDRADE, A. O; SOARES, A. B; NASUTO, S. J. **A study regarding the initialization of parameters of Hidden Markov Models**, V ERMAC (Encontro Regional de Matemática Aplica), Uberlândia - Brasil, 2007. Anais: CD-ROM.

Apêndice B

Protocolo de coleta dos sinais EMG

Os sinais EMG utilizados neste trabalho foram disponibilizados por *Andrade, A. O.* [5]. Para realizar a coleta destes sinais, o pesquisador obteve a aprovação do comitê de ética de Berkshire Local Research Ethics Committe (REC 33/04). O procedimento adotado para a coleta dos sinais EMG está relatado a seguir.

B.1 Detecção do sinal EMG

Os eletrodos utilizados para a detecção do sinal EMG foram:

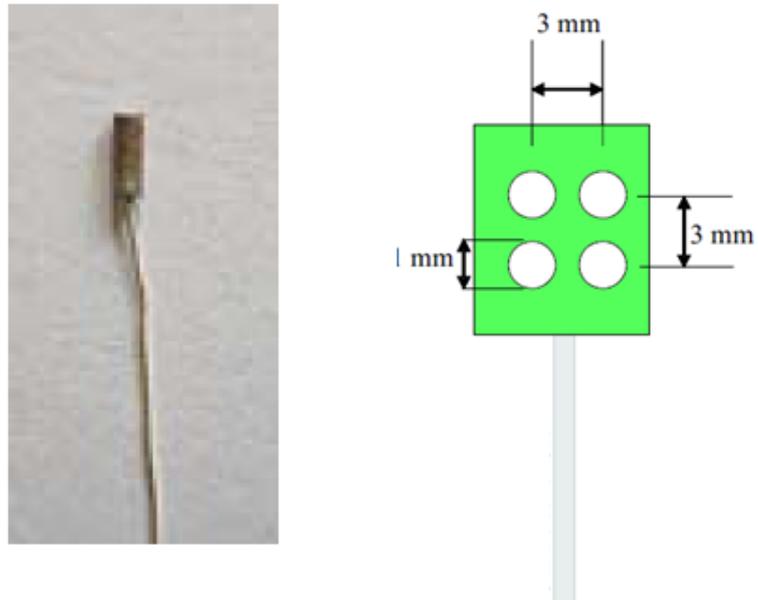
- **Eletrodo de referência:**

Eletrodos descartáveis (TECA NCS2000, Oxford Instruments Medical) foram utilizados para esta finalidade. Estes eletrodos possuem gel, adesivo e contato Ag/AgCl;

- **Eletrodos de superfície:** Array de eletrodos passivos foram utilizados (MedTech Systems Ltd, Ag/AgCl, com 1mm de diâmetro) (Figura B.1).

- **Eletrodo de agulha:**

Eletrodos concêntricos descartáveis de agulha (TECA X53153, Oxford Instruments Medical, comprimento de 25 mm, diâmetro de 0.3 mm e área de captação de 0.03 mm_2).



Array de eletrodos

Figura B.1: Representação do array de eletrodos utilizado na coleta dos sinais EMG de [5].

B.2 Posicionamento dos eletrodos no músculo

O músculo investigado foi o Interósseo Dorsal I, que é um músculo superficial e localizado entre o dedo polegar e o indicador (Figura B.2).

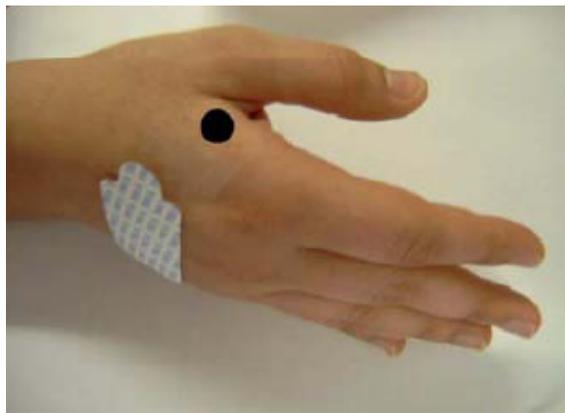


Figura B.2: A marca preta indica a localização do músculo Interósseo Dorsal I [5].

Os eletrodos de superfície foram posicionados na direção das fibras musculares, o de agulha foi inserido no músculo Interósseo Dorsal I e o eletrodo de referência foi posicionado no dorso da mão, conforme Figura B.3.



Figura B.3: Exemplo mostrando o posicionamento dos eletrodos de agulha e de superfície no músculo Interósseo Dorsal I [5].

B.3 Protocolo Experimental

Para a realização dos experimentos, antes da fixação dos eletrodos, a pele de cada voluntário foi limpa com álcool. Na região em que foi afixado o eletrodo de superfície, foi aplicado gel abrasivo e, em seguida, gel condutor para atenuar os possíveis ruídos detectados com o sinal EMG.

Durante o experimento, 15 voluntários foram orientados a manter uma contração isométrica do músculo Interósseo Dorsal I durante 30 segundos. Este músculo é ativado pela abdução do dedo indicador (Figura B.4).

Foram realizados dois tipos de experimentos: um que requeria controle de força e outro em que não era necessário a mensuração da força. Nos experimentos em que era necessário um controle de força, um software de Biofeedback fornecia a informação necessária para o usuário sobre a força que deveria ser exercida em uma plataforma de força. Já nos experimentos em que não era necessário a mensuração da força, os voluntários realizaram uma contração isométrica fraca. Todos os sinais foram amostrados a 10 kHz.

B.4 Aquisição de dados

Inicialmente, foi configurado no software que irá realizar a coleta de dados os parâmetros da digitalização dos dados: frequência de amostragem, número de canais e duração do

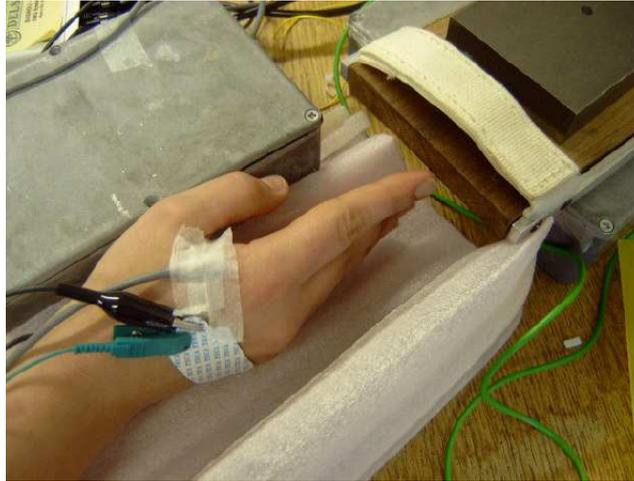


Figura B.4: Exemplo de abdução do dedo indicador para ativar o músculo Interósseo Dorsal I [5].

experimento. O software que realiza a coleta é dotado de uma tela de biofeedback, a qual apresenta um retorno visual ao voluntário a respeito da força que ele está realizando durante o experimento. O objetivo do usuário na tela de biofeedback é controlar, através da força utilizada no movimento de abdução do dedo indicador, a profundidade de um peixe no fundo do mar (Figura B.5). O objetivo deste software é tornar o experimento menos cansativo e mais motivador para o usuário, fazendo com que ele mantenha a concentração na tarefa que ele está executando.

Após a configuração dos parâmetros de digitalização e a verificação do correto posicionamento dos eletrodos no músculo de interesse, os dados são digitalizados e armazenados em um laptop. A Figura B.6 apresenta os principais componentes do módulo de aquisição de dados desenvolvido por [5].

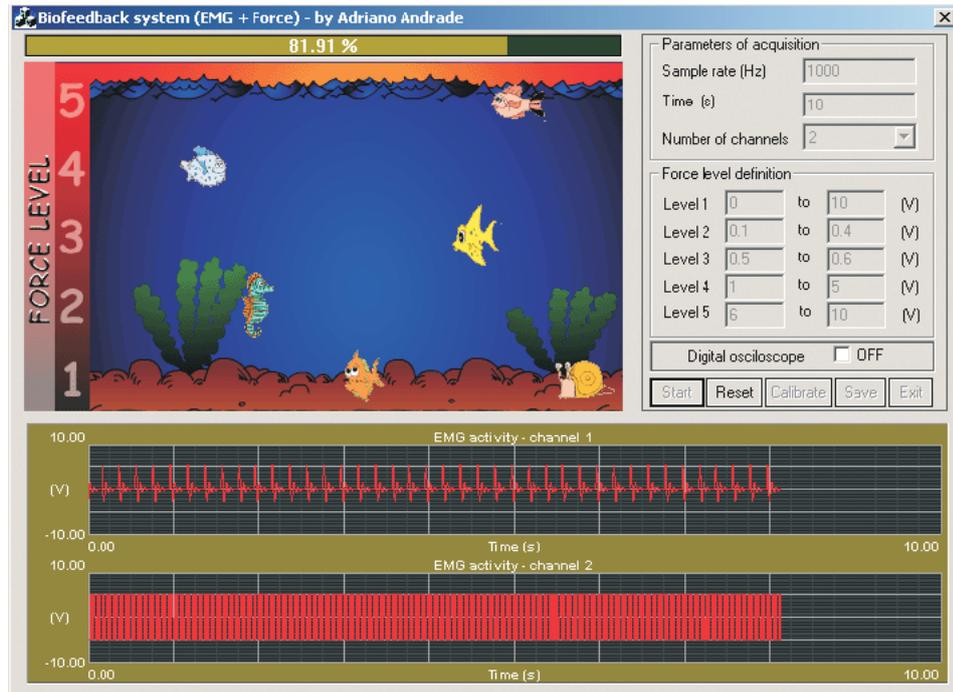


Figura B.5: Interface gráfica do software de Biofeedback. Durante os experimentos, o objetivo do voluntário era controlar o movimento do peixe laranja, de acordo com a força utilizada no movimento de abdução do dedo indicador [5].

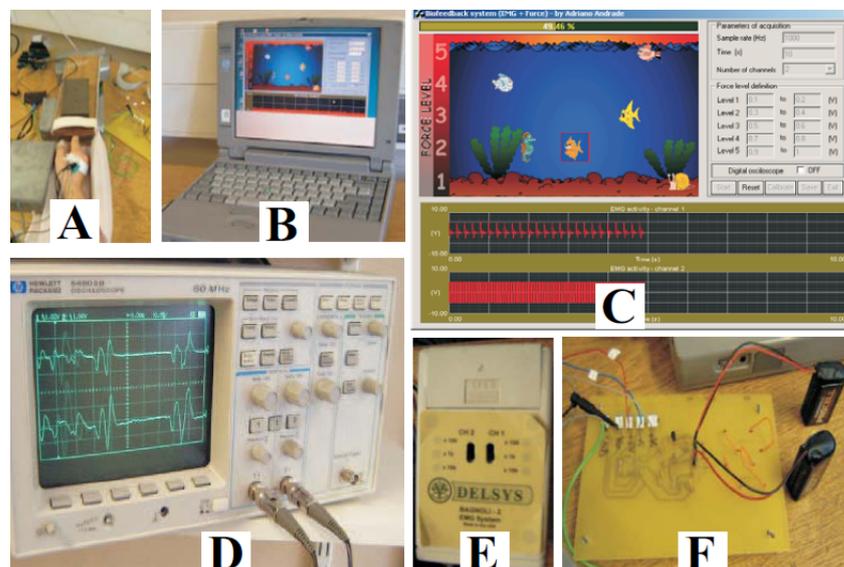


Figura B.6: Principais componentes da unidade de aquisição de dados: A) Plataforma de força; B) Laptop com placa de aquisição; C) Software de Biofeedback; D) Osciloscópio digital; E) Amplificador EMG; F) Amplificador da plataforma de força [5].

Apêndice C

Estimativa da seqüência de disparos das Unidades Motoras

Após a detecção da quantidade de Unidades Motoras ativas no sinal EMG, na etapa de Agrupamento, bem como a classificação de cada MUAP na série temporal do sinal EMG, é possível gerar um Modelo Oculto de Markov (Figura C.1) para realizar a estimativa da seqüência de disparos das Unidades Motoras e calcular probabilidade de disparo de cada Unidade Motora em um determinado instante, conforme será apresentado a seguir.

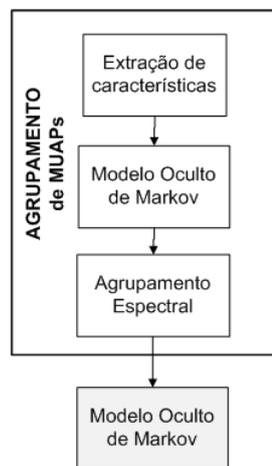


Figura C.1: Etapa pós-agrupamento de MUAPs: MOM para estimar a seqüência de disparo das Unidades Motoras.

Para gerar o Modelo Oculto de Markov, os seguintes parâmetros deverão ser configurados:

- Quantidade de estados:

O primeiro passo para gerar o modelo é determinar a quantidade de estados. Como o objetivo de realizar a estimativa da seqüência de disparo das Unidades Motoras é calcular a probabilidade de disparo das mesmas, cada estado representará uma Unidade Motora. Sendo assim, a quantidade de estados do Modelo Oculto de Markov discreto será igual à quantidade de grupos estimados pelo Agrupamento Espectral, isto é, será igual à quantidade Unidades Motoras ativas;

- **Matriz de Transição de Estados:**

Em seguida, é necessário determinar os valores que irão compor Matriz de Transição de Estados do MOM. A partir dos resultados da etapa de Agrupamento, é possível obter tais valores. Esse procedimento é executado da seguinte forma:

1. *Classificação dos MUAPs no sinal EMG:*

Conforme já foi apresentado anteriormente, um dos resultados fornecidos pela etapa de Agrupamento é a classificação de cada MUAP em um grupo. E, nesta pesquisa, um grupo representa uma Unidade Motora. Sendo assim, temos como resultado do estágio de Agrupamento a informação sobre qual Unidade Motora gerou determinada MUAP. Dessa forma, é possível retornar à série temporal do sinal EMG e classificar cada MUAP (Figura C.2).

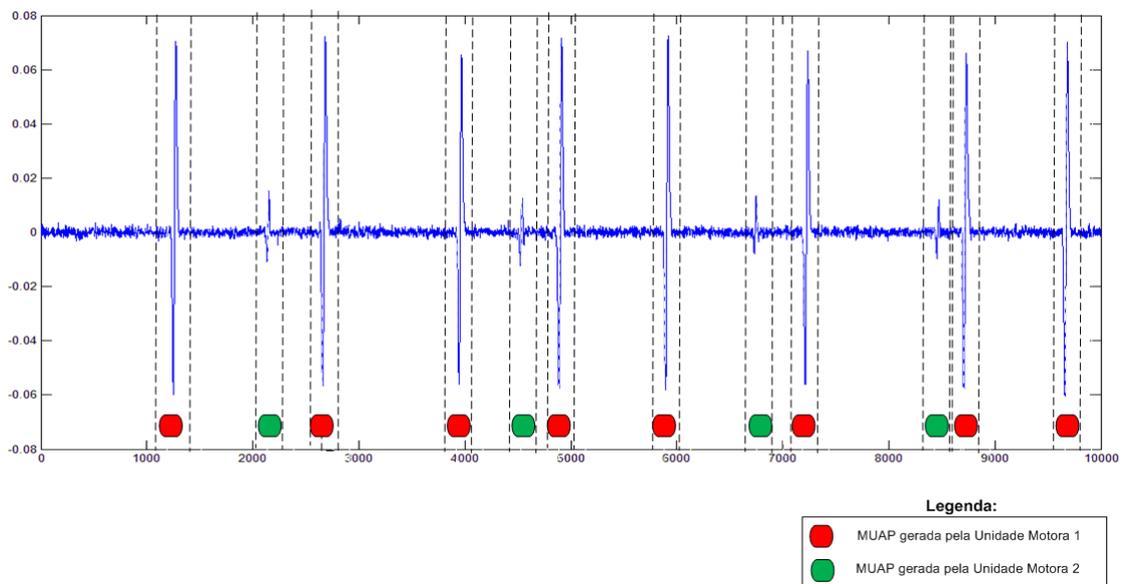


Figura C.2: Exemplo de classificação dos MUAPs existentes no sinal EMG, após a execução do estágio de Agrupamento.

2. *Estatística calculada a partir da seqüência de MUAPs do sinal EMG:*

A partir da seqüência de MUAPs classificadas no sinal EMG, é possível calcular a probabilidade de transição de disparo entre as Unidades Motoras e preencher a Matriz de Transição de Estados do MOM.

• **Matriz de Observações:**

Neste Modelo Oculto de Markov, o conceito de observação será abstrato, pois será relacionado ao fato de um determinado padrão de MUAP ser gerado por uma Unidade Motora. Desta forma, considerando que cada Unidade Motora gera apenas um padrão morfológico de MUAP, a Matriz de Observações (B) será uma matriz nula e com a diagonal igual a 1, conforme C.1.

$$B = \begin{pmatrix} 1 & 0 & 0 & \dots & 0 \\ 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & \dots & 1 \end{pmatrix} \quad (C.1)$$

• **Topologia do Modelo Oculto de Markov:**

Para este Modelo Oculto de Markov, a topologia será o ergódico (totalmente conectado), pois há a possibilidade de transição entre todos os estados, isto é, existe a probabilidade de transição de disparos entre todas as Unidades Motoras (Figura C.3).

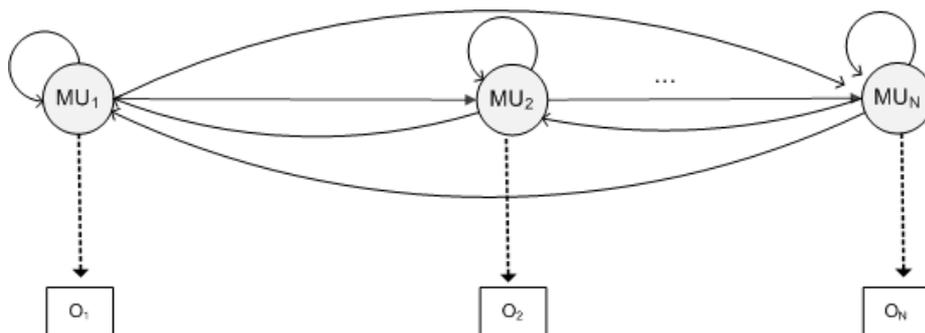


Figura C.3: Exemplo de topologia ergódica, representando a transição de disparo entre as Unidades Motoras (estados do Modelo Oculto de Markov). As observações O representam a geração de um determinado padrão de MUAP pela Unidade Motora.

Após a configuração dos parâmetros iniciais do modelo, eles são otimizados utilizando os algoritmos Baum-Welch e Evolução Diferencial EDSP.

Finalizando todas estas etapas, o Modelo Oculto de Markov está configurado para gerar os seguintes resultados: estimativa da sequência de disparo das Unidades Motoras e probabilidade de disparo das Unidades Motoras.

Para realizar um teste com este modelo, foi gerado um sinal EMG sintético com as seguintes características:

- Tempo de simulação: 1000 ms;
- Frequência de amostragem: 10000 Hz;
- Quantidade de Unidades Motoras: 3;
- Relação sinal-ruído: 20 dB;

A seguir são apresentados alguns resultados com MOM.

• **Sinal EMG:**

A Figura C.4 apresenta o sinal EMG sintético que foi gerado pelo simulador, de acordo com as especificações anteriormente descritas.

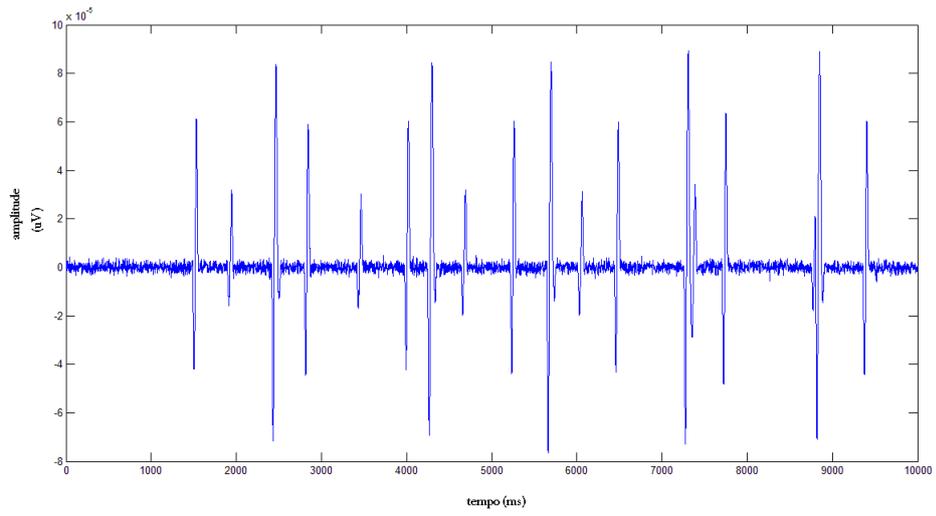


Figura C.4: Sinal EMG sintético com 3 Unidade Motoras ativas.

- Detecção de MUAPs do sinal EMG:

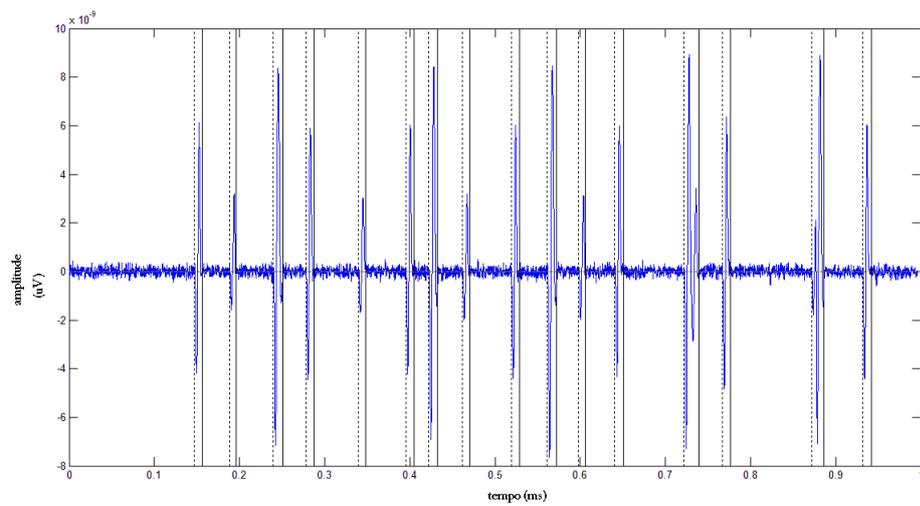


Figura C.5: MUAPs detectados no sinal EMG, delimitados pelas linhas tracejadas verticais.

- Seqüência de disparos das Unidades Motoras do sinal EMG:

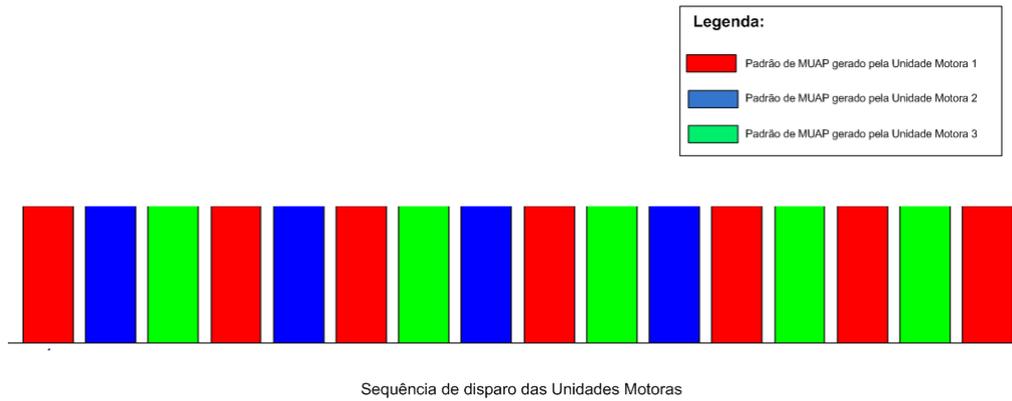


Figura C.6: Determinação da seqüência de disparos das Unidades Motoras.

1. Avaliação da qualidade dos grupos de MUAPs:

– Grupo 1 de MUAPs:

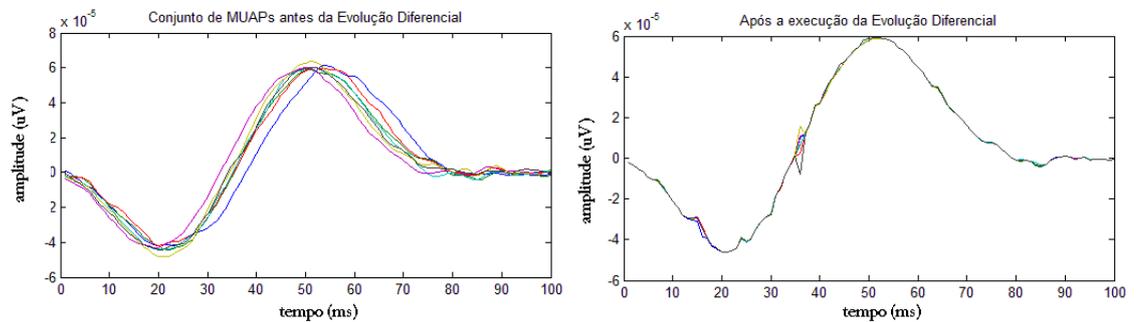


Figura C.7: Avaliação da qualidade do grupo 1 de MUAPs utilizando o algoritmo EDSP.

– Grupo 2 de MUAPs:

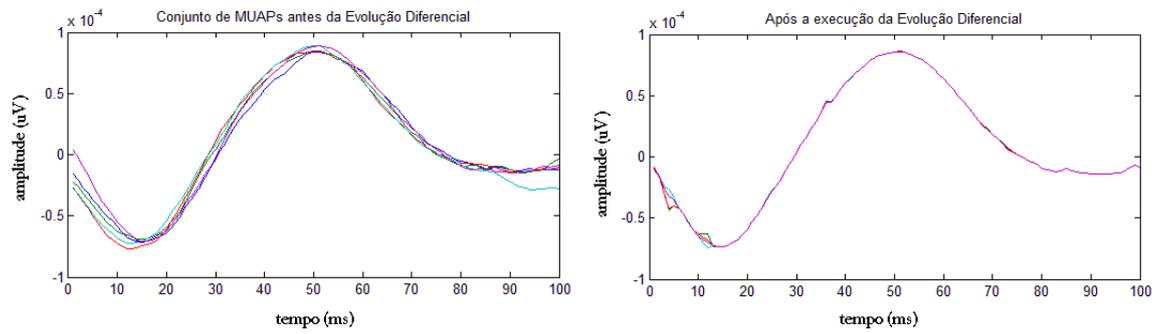


Figura C.8: Avaliação da qualidade do grupo 2 de MUAPs utilizando o algoritmo EDSP.

– Grupo 3 de MUAPs:

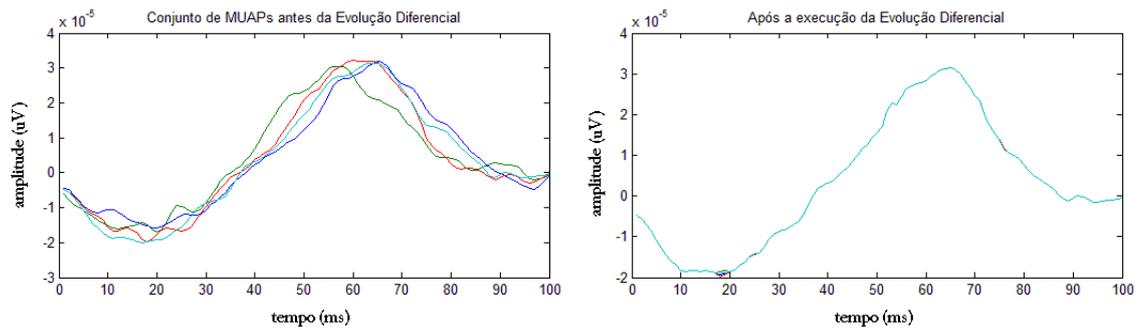


Figura C.9: Avaliação da qualidade do grupo 3 de MUAPs utilizando o algoritmo EDSP.

- Estimativa da seqüência de disparo das Unidade Motoras:

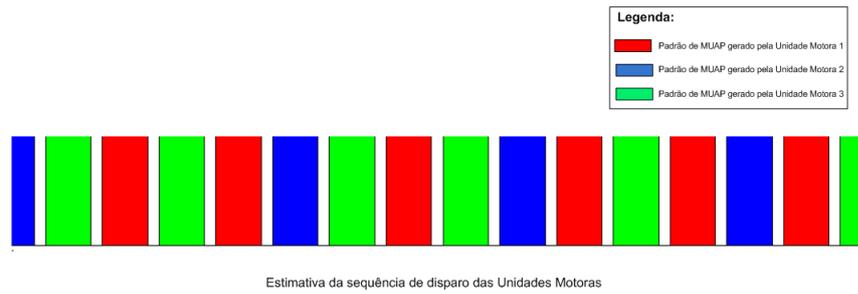


Figura C.10: Predição da seqüência de disparo das Unidades Motoras.

1. Gráfico da distribuição de freqüência dos disparo das Unidades Motoras: sinal EMG analisado X seqüência de predição gerado pelo MOM:

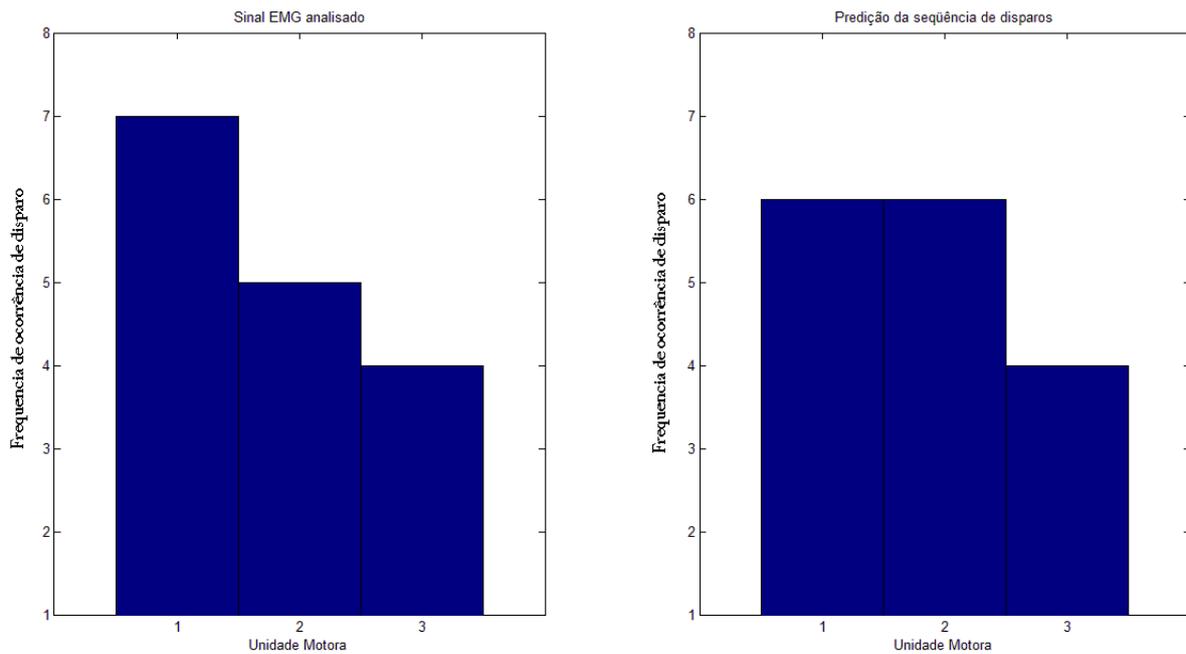


Figura C.11: Distribuição da freqüência dos disparo das Unidades Motoras: sinal EMG sintético analisado e estimativa da sequencia de disparos das Unidades Motoras geradas pelo MOM.

2. Gráfico da distribuição da frequência de disparo das Unidades motoras: sinal EMG analisado X média de 1000 seqüências geradas pelo MOM:

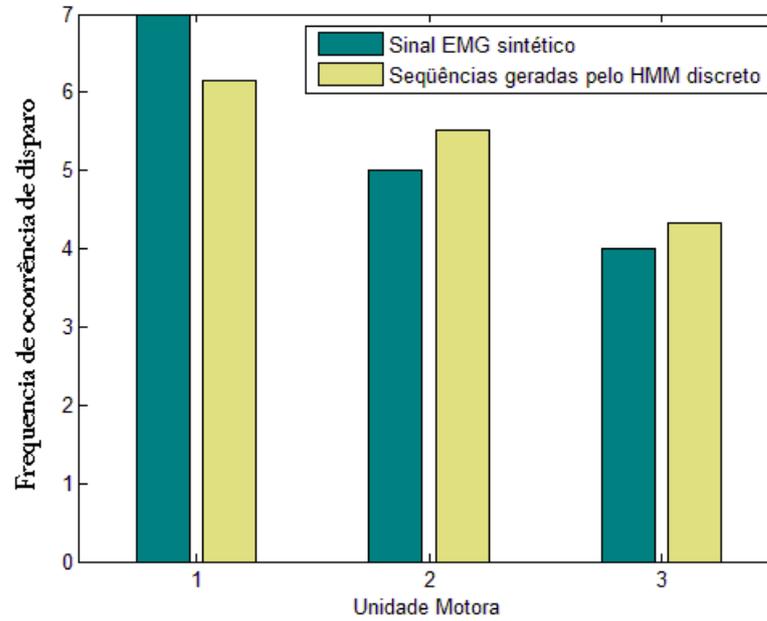


Figura C.12: Distribuição da frequência de disparo das Unidades motoras: sinal EMG e média de 1000 seqüências geradas pelo Modelo Oculto de Markov discreto.

3. Gráfico de erro:

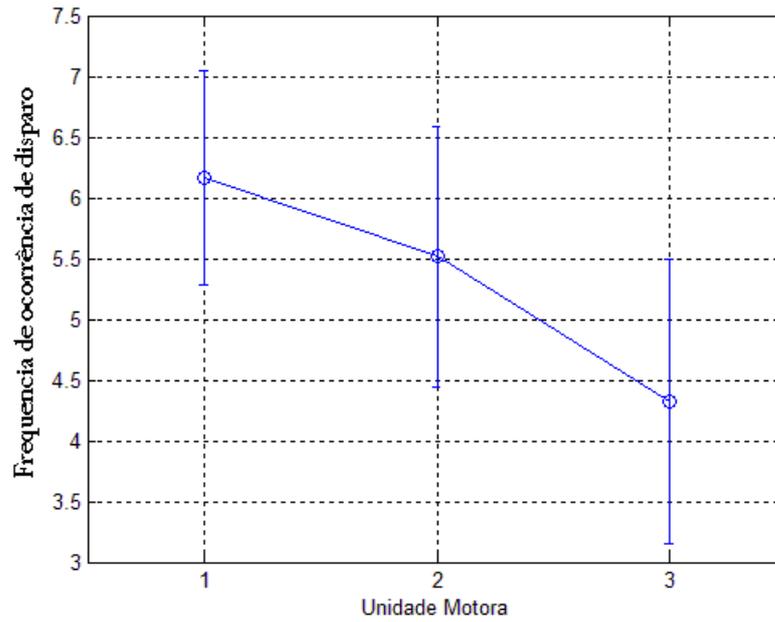


Figura C.13: Média da distribuição da frequência de disparo das Unidades motoras de 1000 seqüências geradas pelo Modelo Oculto de Markov Discreto. As linhas verticais indicam o erro calculado em relação ao desvio padrão da média.

4. *Intervalo de confiança:*

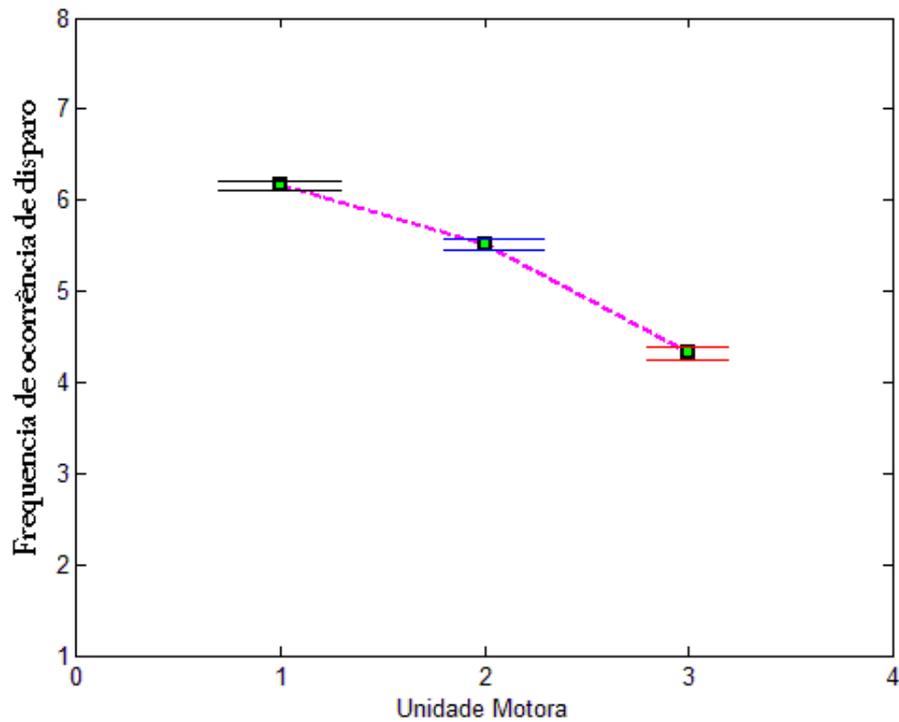


Figura C.14: Média da distribuição da frequência de disparo das Unidades motoras de 1000 seqüências geradas pelo Modelo Oculto de Markov discreto. As linhas horizontais delimitam o intervalo de confiança de cada média.

- **Probabilidade de disparo das Unidades Motoras:**

Neste teste, o estágio inicial realizado pelo sistema foi a etapa de detecção de MUAPs do sinal EMG. Na Figura C.4 é possível visualizar os MUAPs do sinal EMG, que foi gerado com 3 Unidades Motoras.

Após o estágio de detecção de MUAPs, o sistema desenvolvido executou a etapa de agrupamento. Como resultado desta etapa, o sistema realizou o agrupamento de MUAPs e identificou 3 padrões morfológicos de MUAPs e, considerando que uma Unidade Motora, geralmente, produz um padrão morfológico único de MUAP, é possível dizer que o algoritmo de Agrupamento Espectral identificou 3 Unidades Motoras ativas no sinal EMG. Desta forma, de acordo com as informações provenientes da etapa de agrupamento a respeito da classificação de cada MUAP, o sistema forneceu a seqüência de disparos das Unidades Motoras presentes no sinal EMG analisado (Figura C.6).

E ainda, para a avaliação da qualidade dos grupos de MUAPs identificados pelo algoritmo Agrupamento Espectral, isto é, para avaliar a similaridade de padrão entre

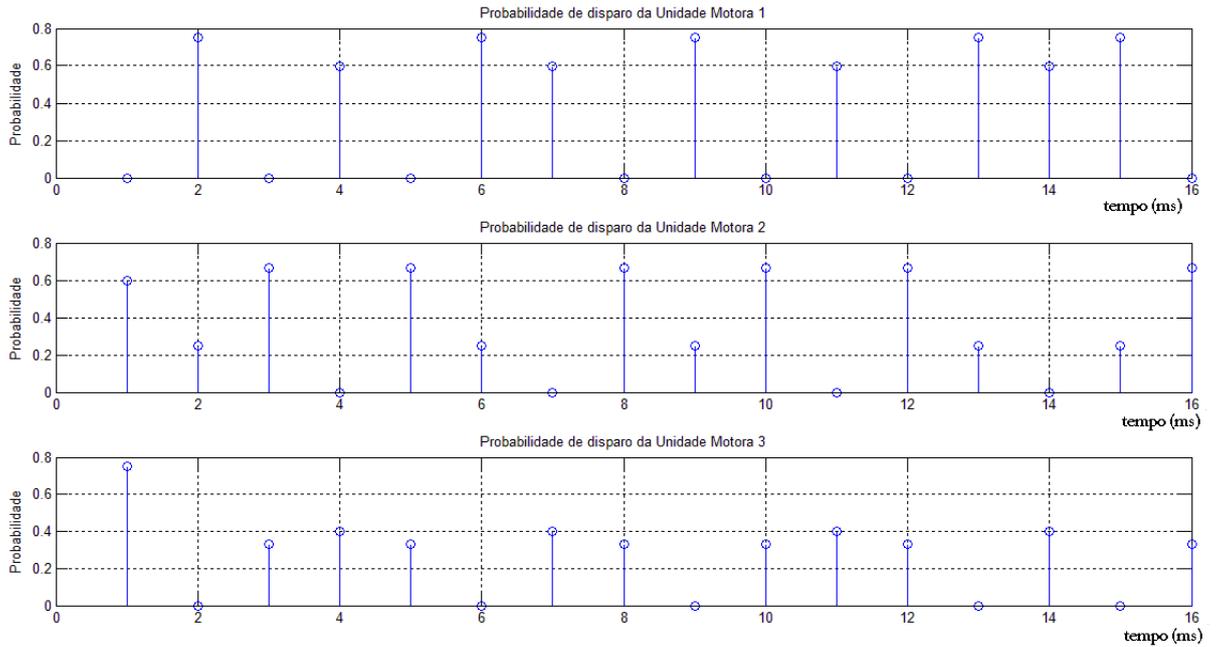


Figura C.15: Probabilidade de disparo das Unidades Motoras.

os MUAPs membros de um mesmo grupo (coesão entre os membros), foi utilizada a técnica Evolução Diferencial EDSF. Conforme já foi detalhado no Capítulo 5, o algoritmo Evolução Diferencial tem a capacidade de convergir os MUAPs que possuem o mesmo padrão morfológico. Dessa forma, se após a execução do algoritmo não houver convergência para um padrão único, significa que os MUAPs não possuem o mesmo padrão morfológico, isto é, a qualidade do grupo não está adequada. Caso contrário, se houver convergência para um único padrão de MUAP, significa que o grupo está coeso, isto é, existe similaridade de padrão entre todos os MUAPs pertencentes ao grupo.

Assim, as Figuras C.7, C.8 e C.9 apresentam o resultado da técnica Evolução Diferencial para os grupos de MUAPs identificados. Em cada um dos grupos, houve uma convergência de 100% da população de MUAPs para um padrão morfológico único. Desta forma, é possível inferir que o algoritmo Agrupamento Espectral atingiu uma boa qualidade na formação dos grupos de MUAPs, pois foi comprovado pela técnica Evolução Diferencial que existe uma forte similaridade de padrão entre os membros do grupo analisado.

Após realizado o agrupamento dos MUAPs, foi gerado o Modelo Oculto de Markov, que é responsável por estimar a seqüência de disparo das Unidades Motoras detectadas no sinal EMG. O resultado desse estágio está apresentado na Figura C.10, onde cada disparo

de Unidade Motora é representado por uma cor distinta.

Para avaliar a corretude da seqüência de disparos das Unidades Motoras, apresentada na Figura C.10 foi gerado o gráfico da distribuição de freqüência de disparos das Unidades Motoras: do sinal EMG sintético analisado e da seqüência gerada pelo Modelo Oculto de Markov. A Figura C.11 apresenta um comparativo entre a distribuição de freqüência de disparo das 3 Unidades Motoras do sinal EMG sintético e da seqüência gerada pelo Modelo Oculto de Markov. É importante verificar que existe uma diferença não muito significativa entre a freqüência de ocorrência de disparos de cada Unidade Motora, comparando o histograma do sinal EMG sintético com o gráfico da predição da seqüência de disparos (Figura C.11).

Para certificar que a pequena diferença entre os histogramas (Figura C.11) não era resultado de um único resultado esporádico, isto é, que as freqüências de disparos não são exclusivas da seqüência de disparos apresentada na figura C.10 e sim do Modelo Oculto de Markov que foi gerado para modelar e predizer a seqüência de disparos das Unidades Motoras do sinal analisado, foram geradas 1000 seqüências a partir do Modelo Oculto de Markov. Em seguida, foi calculada a média da freqüência de disparo das Unidades Motoras nas 1000 seqüências geradas, conforme apresenta a Figura C.12.

Neste novo contexto, o histograma apresentado na Figura C.11 foi confirmado, pois na Figura C.12, as proporções das freqüências de disparo das Unidades Motoras apresentadas na Figura C.11 foram mantidas. Para certificar a variação das freqüências de disparo nas 1000 seqüências geradas, é apresentado o gráfico de erro na Figura C.13, onde as barras verticais indicam o desvio padrão das freqüências de ocorrência de disparo em relação à média destas freqüências ($média + desvio\ padrão$ e $média - desvio\ padrão$). Mais uma vez, foi confirmada a pequena variação da média das freqüências de disparo das Unidades Motoras nas seqüências geradas pelo Modelo Oculto de Markov.

E ainda, para confirmar a confiabilidade da média das freqüências de disparo das Unidades Motoras, foi calculado o intervalo de confiança da média dessas freqüências, conforme apresenta a Figura C.14. É possível verificar, mais uma vez, o estreito intervalo de variação da média das freqüências de ocorrência de disparos das seqüências geradas pelo Modelo Oculto de Markov.

Finalmente, com base na média de 1000 seqüências geradas pelo Modelo Oculto de Markov e na Matriz de Transição de Estados deste Modelo, é calculada a probabilidade

de disparo de cada uma das Unidades Motoras ativas, conforme apresenta a Figura C.15. Considerando que o sinal EMG foi gerado por um simulador de sinais EMG sintéticos, percebe-se que a probabilidade de disparo das Unidades Motoras apresenta uma distribuição balanceada. Entretanto, é possível observar que a Unidade Motora 3, no geral, possui uma probabilidade de disparo menor do que as demais. Esta afirmação é corroborada com os histogramas apresentados nas Figuras C.11 e C.12, onde é possível verificar que a Unidade Motora 3 sempre possui uma frequência de disparo menor do que as demais.