

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



**Decomposição de sinais
eletromiográficos utilizando filtros
casados**

Ailton Luiz Dias Siqueira Junior

Junho

2013

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

**Decomposição de sinais
eletromiográficos utilizando filtros
casados**

Ailton Luiz Dias Siqueira Junior

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

Área de concentração: Processamento da Informação

Banca examinadora:

Dr. Alcimar Barbosa Soares (UFU) - Orientador

Dr. Adriano Oliveira Andrade (UFU)

Dr. Eduardo Lázaro Martins Naves (UFU)

Dra. Léia Bernardi Bagesteiro (UFABC)

Dr. Raimes Moraes (UFSC)

Uberlândia

2013

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG - Brasil

S618d Siqueira Junior, Ailton Luiz Dias, 1980-
2013 Decomposição de sinais eletromiográficos utilizando filtros casados
/ Ailton Luiz Dias Siqueira Junior. - 2013.
143 f. : il.

Orientador: Alcimar Barbosa Soares.
Tese (doutorado) – Universidade Federal de Uberlândia, Programa
de Pós-Graduação em Engenharia Elétrica.
Inclui bibliografia.

1. Engenharia elétrica - Teses. 2. Eletromiografia - Teses. I. Soares,
Alcimar Barbosa. II. Universidade Federal de Uberlândia. Programa de
Pós-Graduação em Engenharia Elétrica. III. Título.

CDU: 621.3

Decomposição de sinais eletromiográficos utilizando filtros casados

Ailton Luiz Dias Siqueira Junior¹

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. Dr. Edgard Afonso Lamounier Júnior

Coordenador do curso de Pós-Graduação

¹A bolsa de estudo para parte desta pesquisa foi concedida pelo CNPq, Brasil.

*“O que sabemos é uma gota;
o que ignoramos é um oceano”.*

(Isaac Newton)

Agradecimentos

A **DEUS** por tudo.

À minha esposa **Fábia**, pelo seu carinho, paciência e solidariedade nos momentos mais difíceis.

Aos meus filhos **Marina** e **Hugo**, por sempre me esperarem com um sorriso aberto.

Aos meus pais, **Ailton** e **Moema**, por seus cuidados, carinho e atenção em todos os momentos, e por sempre me apoiarem incondicionalmente.

Aos meus irmãos **Homero** e **Gustavo**, por estarem sempre ao meu lado prontos para ajudar.

Ao professor **Alcimar**, que me orientou com paciência, dedicação, companheirismo e amizade durante todas as etapas deste trabalho.

Ao professor **Adriano Andrade**, que me incentivou a desenvolver esse projeto e forneceu algumas das ferramentas utilizadas nesse trabalho.

À professora **Ângela**, a qual me ajudou na revisão de boa parte desse trabalho.

Aos demais professores do BioLab (Laboratório de Engenharia Biomédica e Automática) por sempre estarem dispostos a ajudar durante a execução deste trabalho.

Aos meus queridos amigos do BioLab (Laboratório de Engenharia Biomédica e Automática), de ontem, hoje e sempre. A todos vocês meu muito obrigado!

Aos meus queridos amigos e colegas do Instituto Federal do Triângulo Mineiro (IFTM), em especial aos professores **Rodrigo Grassi, André e Marco Maciel** que me ajudaram muito nesses últimos anos.

À todos **professores e funcionários** da Universidade Federal de Uberlândia sempre dispostos a ajudar e a **Marly** pelo apoio de sempre na secretaria da pós-graduação.

Enfim, à **todos** aqueles que de alguma forma contribuíram para este trabalho.

Ao Instituto Federal do Triângulo Mineiro, que me liberou das minhas atividades docentes para a conclusão desse trabalho.

Ao CNPq, pelo suporte financeiro a esta pesquisa.

Resumo

SIQUEIRA, J. A. L. D. *Decomposição de sinais eletromiográficos utilizando filtros casados.* Tese de Doutorado. Faculdade de Engenharia Elétrica da Universidade Federal de Uberlândia. Uberlândia, 2013.

A detecção e classificação dos potenciais de ação de unidade motora (PAUMs) de sinais EMG é uma ferramenta importante no estudo do sistema neuromuscular. A partir de informações dessa classificação é possível diagnosticar distúrbios motores.

Entretanto, apesar de existirem diversas propostas na literatura para executar tais ações, a grande maioria depende de algoritmos complexos e instrumentação específica. Dependendo do sistema, o custo computacional ou o mecanismo de captação envolvendo, matrizes de eletrodos, pode limitar sua utilização em aplicações clínicas, biofeedback ou em sistemas embarcados para controle de próteses. Outra questão importante consiste na detecção e classificação de disparos em sinais com baixa relação sinal ruído (SNR). Um método capaz de operar em sinais com baixa SNR é interessante em aplicações onde não se pode controlar completamente a coleta do sinal. Como exemplo, podemos citar aplicações da eletromiografia em interfaces homem máquina (IHM), onde o posicionamento dos eletrodos pode ser realizado por um usuário com pouco treinamento e o ambiente pode conter alto nível de interferência eletromagnética, diminuindo a SNR do sinal captado.

Como solução para tais problemas, foram propostas duas metodologias complementa-

res: a primeira delas (MD-FC) se baseia no uso de bancos de filtros casados para detecção e classificação de PAUMs em sinais EMG, enquanto a segunda (MAD-FC) é uma proposta de aprimoramento da primeira para situações com altas probabilidades de sobreposição de disparos de MUAPs. As metodologias propostas buscaram atingir aqueles objetivos sem um aumento excessivo no custo computacional, tratando sinais com níveis variados de ruídos e considerando a questão de sobreposição de PAUMs, comuns em sinais EMG.

Os resultados demonstraram que o sistema MD-FC é capaz de detectar disparos isolados com precisão de 96% em média para relação sinal ruído de 10 dB com até 10 unidades motoras ativas, porém seu desempenho diminuído na presença de altos níveis de sobreposição de PAUMS. O segundo MAD-FC que foi elaborado de forma a aprimorar a detecção sobre ondas sobrepostas, e é capaz de detectar e classificar os disparos de sinais com até 10 unidades motoras ativas com taxa de classificação correta maior do que 79,80% em média e com SNR de 20 dB. Para sinais com SNR de 10 dB esse valor é de 75,19% em média. Em geral, o método MAD-FC apresentou performance superior ao MD-FC em cerca de 20%.

Os dois métodos são bastante eficientes no uso de recursos computacionais. Eles foram criadas de forma a analisar os sinais EMG em janelas de 50 milissegundos em menos de 5 milissegundos a partir de um computador desktop padrão, o que permite sua utilização em sistemas de detecção e classificação de PAUMs em tempo real.

Palavras-chave

Eletromiografia; Decomposição de sinais EMG; Filtros casados; Processamento de sinais biomédicos

Abstract

SIQUEIRA, J. A. L. D. *EMG signal decomposition using matched filters*. PhD Thesis.
Faculty of electrical Engineering. University of Uberlândia. Uberlândia, 2013.

The detection and classification of EMG motor unit action potentials (MUAP) is an important tool in the study of the neuromuscular system, allowing for a number of applications, such as the diagnoses of motor disorders.

However, although there are several methods described in the literature to perform such actions, the majority relies on complex algorithms and specific instrumentation. Depending on the system, the computational cost or the detection mechanism, sometimes involving electrode arrays, may limit its use in clinical applications, biofeedback or embedded systems for controlling artificial prostheses. Another important issue is the detection and classification of firing MUAPs in signals with low signal to noise ratio (SNR). A method capable of operating with low SNR is paramount for applications, such as the use of electromyography in human machine interfaces (HMI), where the positioning and fixation of the electrodes may be performed by a non-trained user, and the signal can be contaminated by high levels of electromagnetic interference.

As a solution for such problems, two complementary methods were proposed: the first (MD-FC) is based on the use of banks of matched filters for detection and classification MUAPs in EMG signals, whereas the second (MAD-FC) is proposed as an improvement

from the first, aiming situations with a high probability of overlapping firing MUAPs. The proposed methods sought to achieve those goals without an excessive increase in computational cost, treating signals with variable noise levels and considering the overlapping of MUAPs.

The results showed that the MD-FC system is able to accurately detect 96% of isolated MUAPs in signals with SNR of 10 dB and up to 10 active motor units. However, the performance is reduced in the presence of high levels of overlapping MUAPs, as expected. The second method (MAD-FC) was designed to improve the detection of overlapping MUAPs. The results showed that the MAD-FC is able to detect and classify firing MUAPs in signals with up to 10 active motor units and SNR of 20 dB at rates of success higher than 79.80%, on average. When the SNR is decreased to 10dB the rates of success reach at least 75.19%, on average (even in this case with a high percentage of overlapping). In general, the MAD-FC showed rates of success around 20% better than the MD-FC method.

Both methods are quite efficient when using computational resources. They were created in order to process EMG windows of 50 milliseconds in less than 5 milliseconds, when using a standard desktop computer. This feature allows their use in applications requiring MUAPs detection and classification in real time.

Keywords

Electromyography; EMG signal decomposition; Matched filters; Biomedical singnal processing

Conteúdo

1	Introdução	1
1.1	Definição do Problema	3
1.2	Objetivos	4
1.2.1	Objetivos específicos	5
1.3	Estrutura do trabalho	5
2	Decomposição de sinais EMG	7
2.1	Instrumentação	10
2.2	Pré-processamento	11
2.3	Segmentação de sinais EMG	14
2.4	Extração de características	18
2.5	Agrupamento de PAUMs	21
2.6	Tratamento de sobreposições de PAUMs	27
2.7	Resultados da decomposição	29
2.8	Metodologias de validação	33
2.9	Considerações sobre os métodos de decomposição existentes	37

3 Filtros casados	40
3.1 Definição	43
3.2 Características e propriedades	46
3.3 Exemplos de aplicação de filtros casados	49
3.4 Considerações iniciais sobre a aplicação de filtros casados na detecção e classificação de sinais EMG	52
4 Proposta	54
4.1 Detecção de PAUMs usando filtros casados	55
4.2 Classificação de PAUMs usando filtros casados	58
4.3 Método para detecção de PAUMs baseado em filtros casados (MD-FC) . .	62
4.4 Efeitos da sobreposição	67
4.5 Método aprimorado para detecção de PAUMs baseado em filtros casados (MAD-FC)	70
5 Resultados	75
5.1 Índices para avaliação	75
5.2 Conjunto de dados simulados	77
5.2.1 Resultados do MD-FC	78
5.2.1.1 Grupo 1: Sinais sem sobreposição e relação sinal-ruído de 200 dB	79
5.2.1.2 Grupo 2: Sinais sem sobreposição e relação sinal-ruído de 20 dB	80
5.2.1.3 Grupo 3: Sinais sem sobreposição e relação sinal-ruído de 10 dB	82

5.2.1.4	Grupo 4: Sinais com sobreposição e relação sinal-ruído de 200 dB	83
5.2.1.5	Grupo 5: Sinais com sobreposição e relação sinal-ruído de 20 dB	84
5.2.1.6	Grupo 6: Sinais com sobreposição e relação sinal-ruído de 10 dB	84
5.2.2	Resultados do MAD-FC	86
5.2.2.1	Grupo 1: Sinais sem sobreposição e relação sinal-ruído de 200 dB	87
5.2.2.2	Grupo 2: Sinais sem sobreposição e relação sinal-ruído de 20 dB	88
5.2.2.3	Grupo 3: Sinais sem sobreposição e relação sinal-ruído de 10 dB	89
5.2.2.4	Grupo 4: Sinais com sobreposição e relação sinal-ruído de 200 dB	89
5.2.2.5	Grupo 5: Sinais com sobreposição e relação sinal-ruído de 20 dB	91
5.2.2.6	Grupo 6: Sinais com sobreposição e relação sinal-ruído de 10 dB	93
5.3	Sinal real - Um estudo de caso	93
5.4	Considerações sobre os resultados obtidos	98
6	Discussão	99
6.1	Desempenho do MD-FC	99
6.2	Desempenho do MAD-FC	100

6.3 Considerações finais	104
7 Conclusões e trabalhos futuros	107
7.1 Trabalhos Futuros	109
A Formas de ondas dos PAUMs	111
Referências	112

Lista de Figuras

1.1	Processo de decomposição de sinais EMG, obtendo os PAUMs componentes do sinal. (modificado de De Luca et al.(1)).	2
2.1	Processo de decomposição de sinais EMG, obtendo os PAUMs do qual o sinal é formado. (modificado de De Luca et al.(1))	7
2.2	Diagrama de blocos de um sistema de decomposição de sinais EMG típico.	8
2.3	Exemplo de pré-processamento de um sinal EMG usando EMD: (a) o sinal EMG original, (b) o sinal EMG após a aplicação da técnica e (c) o resíduo (modificado de Andrade et al.(2)).	13
2.4	Exemplo pré-processamento de um sinal EMG usando um filtro diferencial de segunda ordem: (a) sinal EMG original, (b) o sinal após a aplicação do filtro (modificado de McGill, Cummins e Dorfman(3)).	13
2.5	Exemplo do processo de segmentação. (a) Sinal EMG original e (b) janelas contendo apenas as regiões de atividade que podem ser PAUMs isoladas ou sobrepostas.	15
2.6	Exemplo do processo de segmentação por limiar de amplitude. Observe que a técnica apresentou problemas na detecção do segundo e do terceiro PAUMs devido à inversão de fase e a variação de amplitude do sinal. . . .	16

2.7 Exemplo de segmentação utilizando as janelas aplicadas sobre os picos do sinal.	17
2.8 Exemplo de diagrama de dispersão.	22
2.9 Exemplo de dendrograma ilustrando o agrupamento de um conjunto com cinco elementos. Modificado de Everitt et al.(4).	23
2.10 Exemplo de tratamento de sobreposições baseado em um algoritmo de busca sequencial (modificado de Fang, Agarwal e Shahani(5)).	28
2.11 Exemplo de resultados relacionados com a forma de onda dos PAUMs (6). No lado esquerdo, tem-se o <i>shimmer plot</i> , contendo um conjunto de 25 PAUMs. No lado direto, tem-se o gabarito da unidade motora, obtido através da média dos 25 PAUMs encontrados.	30
2.12 Exemplo de resultado relacionado com as características dos disparos dos PAUMs (modificado de De Luca et al.(1)): (A) Gráfico dos TPAUMs de cada unidade motora, marcando o momento e o percentual de força associado ao primeiro disparo de cada unidade motora; (B) Intervalo entre disparos em função do tempo; (C) Média da frequência de disparos em função do tempo; (D) Forma de onda de cada PAUM apresentada em cada eletrodo. Note que os três primeiros gráficos incluem ainda a força aplicada na contração (em preto).	31
2.13 Exemplo de histograma do intervalo entre disparos de um conjunto de unidades motoras (modificado de RASHEED, Stashuk e KAMEL(7)).	35
2.14 Diagrama que ilustra o método de validação de sistemas de decomposição de sinais EMG segundo a proposta de Nawaba, Chang e De Luca (modificado de De Luca e Hostage(8)). Em destaque encontram-se as falhas no processo de decomposição identificadas ao comparar o resultados decomposição do sinal EMG em relação ao sinal reconstruído.	37

3.1 Ilustração de um sistema típico de radar.	41
3.2 Ilustração da detecção de pulsos em um sistema de comunicação binário usando filtros casados: (a) O sinal transmitido, (b) o sinal misturado ao ruído, (c) o sinal filtrado (em azul); amostragem (pontos em destaque) e o limiar de comparação (em vermelho).	42
3.3 Método para obtenção da resposta ao impulso de um filtro casado. (a) A forma de onda do sinal que irá ser utilizada para gerar o filtro. (b) O sinal invertido no tempo. (c) A resposta ao impulso de um dos possíveis filtros casados.	47
3.4 Pulso retangular ($g(t)$) e a resposta ao impulso ($h(t)$) do filtro casado correspondente.	49
3.5 Saída do filtro casado, tendo como entrada apenas o sinal $g(t)$	50
3.6 (a) Pulso retangular. (b) Pulso adicionado de um ruído branco. (c) Saída do filtro casado.	51
3.7 Possível metodologia para aplicação de filtros casados para detecção e classificação de PAUMs em sinais EMG.	53
4.1 Diagrama de blocos de um detector baseado em filtros casados. A saída (a) ocorre quando é aplicado um sinal $x(t)$ formado apenas pelo ruído $n(t)$. A saída (b) ocorre quando a um sinal $x(t)$, composto pela soma do pulso $s(t)$ com o ruído $n(t)$, é aplicado na entrada do filtro.	55
4.2 Forma de onda do disparo de uma unidade motora $g(t)$ e a resposta ao impulso de um filtro casado associado à mesma $h(t)$	57
4.3 Exemplo de aplicação de um filtro casado em um sinal EMG com apenas uma unidade motora.	58
4.4 Diagrama de blocos de um receptor M-ário.	59

4.5	Diagrama de blocos de um banco de filtros casados aplicados a sinais EMG.	60
4.6	Exemplo de um sinal EMG composto por 3 unidades motoras aplicado a um banco com 3 filtros casados.	61
4.7	Método proposto de utilização de um banco de filtros para detecção e classificação de disparos de unidade motora.	63
4.8	Exemplo da saída do detector de máximos locais.	64
4.9	Exemplo do janelamento aplicado pelo classificador.	65
4.10	Exemplo de análise do classificador. Em (a) tem-se um destaque do disparo de maior duração no tempo e que define o tamanho da janela de análise. Em (b) tem-se a entrada do classificador e em (c) a saída. Foram destacados nos dois casos as janelas de análise utilizadas pelo classificador.	66
4.11	Exemplos de sobreposições. (a) Parcial, (b) completa e (c) destrutiva.	68
4.12	Exemplo de saída do MD-FC para os diversos tipos de sobreposição.	69
4.13	Exemplo de utilização do resíduo na resolução de sobreposições.	72
4.14	Método aprimorado para detecção de PAUMs baseado em filtros casados (MAD-FC).	72
5.1	Exemplo de saída do MD-FC para um sinal com 5 unidades motoras sem sobreposição e SNR de 200 dB (Grupo 1).	80
5.2	Exemplo de saída do MD-FC para um sinal com 5 unidades motoras sem sobreposição e SNR de 20 dB (Grupo 2).	81
5.3	Exemplo de saída do MD-FC para um sinal com 5 unidades motoras sem sobreposição e SNR de 10 dB (Grupo 3).	82
5.4	Exemplo de saída do MD-FC para um sinal com 5 unidades motoras com sobreposição e SNR de 200 dB (Grupo 4).	83

5.5 Exemplo de saída do MD-FC para um sinal com 5 unidades motoras com sobreposição e SNR de 20 dB (Grupo 5).	85
5.6 Exemplo de saída do MD-FC para um sinal com 5 unidades motoras com sobreposição e SNR de 10 dB (Grupo 6).	86
5.7 Exemplo de saída do MAD-FC para um sinal com 5 unidades motoras sem sobreposição e SNR de 200 dB (Grupo 1).	87
5.8 Exemplo de saída do MAD-FC para um sinal com 5 unidades motoras sem sobreposição e SNR de 20 dB (Grupo 2).	88
5.9 Exemplo de saída do MAD-FC para um sinal com 5 unidades motoras sem sobreposição e SNR de 10 dB (Grupo 3).	89
5.10 Comparação entre as respostas dos algoritmos (a) MD-FC e (b) MAD-FC para um sinal com 5 unidades motoras com sobreposição e SNR de 200 dB (Grupo 4).	91
5.11 Comparação entre as respostas dos algoritmos (a) MD-FC e (b) MAD-FC para um sinal com 5 unidades motoras com sobreposição e SNR de 20 dB (Grupo 5).	92
5.12 Comparação entre as respostas dos algoritmos (a) MD-FC e (b) MAD-FC para um sinal com 5 unidades motoras com sobreposição e SNR de 10 dB (Grupo 6).	94
5.13 Amostra de um sinal EMG real e a comparação entre as respostas do método MAD-FC com a de um especialista.	95
5.14 Resultados da decomposição de um sinal EMG real composto por quatro unidades motoras. Na primeira coluna é apresentado o <i>shimmer plot</i> de cada unidade motora. Na segunda coluna, o histograma entre disparos. Na terceira coluna é exibida uma amostra do trem de disparos detectados pelo algoritmo.	97

A.1 Exemplo de 9 formas de onda utilizadas para a criação de um banco de filtros.	111
---	-----

Lista de Tabelas

2.1	Características da aquisição e condicionamento utilizados em sistemas de decomposição baseados em eletrodos invasivos. Fc_{inf} : Frequência de corte inferior, Fc_{sup} : Frequência de corte superior, Faq : Frequência de aquisição.	12
2.2	Características da aquisição e condicionamento utilizados em sistemas de decomposição baseados em eletrodos de superfície. Fc_{inf} : Frequência de corte inferior, Fc_{sup} : Frequência de corte superior, Faq : Frequência de aquisição.	14
5.1	Resultados do MD-FC para sinais sem sobreposição e com SNR de 200 dB (Grupo 1). Cada célula contém a média do índice e o desvio padrão entre parenteses.	80
5.2	Resultados do MD-FC para sinais sem sobreposição e com SNR de 20 dB (Grupo 2). Cada célula contém a média do índice e o desvio padrão entre parenteses.	81
5.3	Resultados do MD-FC para sinais sem sobreposição e com SNR de 10 dB (Grupo 3). Cada célula contém a média do índice e o desvio padrão entre parenteses.	82
5.4	Resultados do MD-FC para sinais com sobreposição e com SNR de 200 dB (Grupo 4). Cada célula contém a média do índice e o desvio padrão entre parenteses.	84

5.5 Resultados do MD-FC para sinais com sobreposição e com SNR de 20 dB (Grupo 5). Cada célula contém a média do índice e o desvio padrão entre parenteses.	85
5.6 Resultados do MD-FC para sinais com sobreposição e com SNR de 10 dB (Grupo 6). Cada célula contém a média do índice e o desvio padrão entre parenteses.	86
5.7 Resultados do MAD-FC para sinais sem sobreposição e com SNR de 200 dB (Grupo 1). Cada célula contém a média do índice e o desvio padrão entre parenteses.	88
5.8 Resultados do MAD-FC para sinais sem sobreposição e com SNR de 20 dB (Grupo 2). Cada célula contém a média do índice e o desvio padrão entre parenteses.	89
5.9 Resultados do MAD-FC para sinais sem sobreposição e com SNR de 10 dB (Grupo 3). Cada célula contém a média do índice e o desvio padrão entre parenteses.	90
5.10 Resultados do MAD-FC para sinais com sobreposição e com SNR de 200 dB (Grupo 4). Cada célula contém a média do índice e o desvio padrão entre parenteses.	92
5.11 Resultados do MAD-FC para sinais com sobreposição e com SNR de 20 dB (Grupo 5). Cada célula contém a média do índice e o desvio padrão entre parenteses.	93
5.12 Resultados do MAD-FC para sinais com sobreposição e com SNR de 10 dB (Grupo 6). Cada célula contém a média do índice e o desvio padrão entre parenteses.	94
5.13 Resultados do MAD-FC para o sinal real. Cada célula contém a média do índice e o desvio padrão entre parenteses.	96

6.1	Resumo dos resultados para o MD-FC.	102
6.2	Resumo dos resultados para o MAD-FC.	102
6.3	Comparação entre os resultados obtidos com o MAD-FC e alguns métodos descritos recentemente na literatura.	104

Lista de Acrônimos

DSP - *Digital signal processor* ou Processador digital de sinais

EMD - *Empirical Mode Decomposition*

EMD - *Empirical Mode Decomposition*

EMG - Eletromiográfico ou Eletromiografia

FIR - Finite impulse response ou resposta finita ao impulso

FPGA - *Field-programmable gate array*

IED - Intervalo entre disparos

IHM - Interface Homem Máquina

MCV - Máxima contração voluntária

PAUM - Potencial de Ação de Unidade Motora

TPAUM - Trem de Potenciais de Ação de Unidade Motora

UM - Unidade Motora

Capítulo 1

Introdução

A Eletromiografia é o estudo da função muscular através da detecção do sinal elétrico que os músculos produzem (9). O sinal eletromiográfico (EMG) é formado pela sobreposição de vários sinais básicos, denominados potenciais de ação de unidades motoras (PAUM). Cada PAUM corresponde ao potencial de ação que ativa uma unidade motora (UM), gerando uma contração muscular.

Uma unidade motora é definida como o conjunto do neurônio motor e fibras musculares enervadas pelo mesmo, sendo esta a menor unidade funcional do músculo que pode ser ativada voluntariamente. A forma do PAUM está relacionada ao arranjo da unidade motora que a gerou. Além disso, o número de unidades motoras recrutadas e a taxa de disparo de cada PAUM estão relacionadas com a força de contração muscular (10, 11).

A análise dos PAUMs pode auxiliar um profissional a identificar se existe a presença de um distúrbio motor e se este tem origem no neurônio motor (neuropatia) ou se está relacionado com alguma lesão nas fibras motoras ou atrofia (miopatia) (12). Por exemplo, pacientes com distúrbios miopáticos podem apresentar PAUMs com amplitudes variáveis, múltiplas fases, conjuntos de PAUMs monofásicos de pequena duração, presença de potenciais de fibrilação e picos positivos de curta duração (13, 14). Neuropatias, por sua vez, podem gerar PAUMs de grande amplitude e formas complexas devido a reinervação

colateral, lacunas nas sobreposições de PAUMs durante a máxima contração voluntária e mudanças no padrão de recrutamento de unidades motoras (15, 16, 17).

É possível detectar visualmente os PAUMs em EMG captado quando apenas algumas UMs estão ativas na região onde foi posicionado o eletrodo. Entretanto, para casos com um número maior de UMs ativas, faz-se necessária a utilização de técnicas especiais, num processo denominado decomposição de EMG. Um sinal EMG decomposto fornece informações temporais e morfológicas. As informações temporais fornecem um descrição completa do intervalo entre pulsos, taxa de disparo e características de sincronização. A morfologia dos PAUMs fornecem informações relacionadas a anatomia e a saúde das fibras musculares (1, 11). A Figura 1.1 ilustra o processo de decomposição de sinais EMG, onde os trens de potenciais de ação de unidades motoras (TPAUM) são obtidos a partir do sinal EMG, e cada TPAUM está relacionado ao processo de ativação de uma UM por seu respectivo neurônio motor.

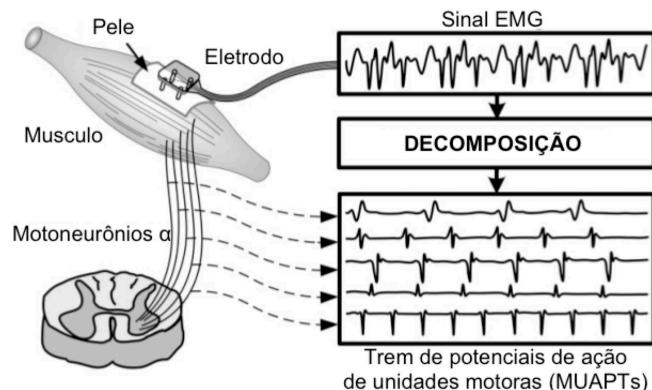


Figura 1.1: Processo de decomposição de sinais EMG, obtendo os PAUMs componentes do sinal. (modificado de De Luca et al.(1)).

1.1 Definição do Problema

Nas últimas três décadas, foram desenvolvidas diversas técnicas para a decomposição de sinais EMG (18, 19, 3, 20, 10, 21, 22, 5, 23, 24, 25, 1, 26, 27, 28, 29), utilizando diferentes metodologias e algoritmos de processamento de sinal. Entretanto, a maioria dessas técnicas possuem um alto custo computacional e nenhuma destas é capaz de realizar uma eficiente decomposição de sinais EMG em tempo real.

Com um sistema de decomposição em tempo real, além da aplicação tradicional, na avaliação de neuropatias e miopatias, surgem novas aplicações que podem beneficiar-se dessa nova ferramenta. Como exemplo, pode-se citar o controle de próteses e interfaces homem máquina (IHMs), além de terapias baseadas em *biofeedback*. Essas aplicações podem utilizar, como parâmetro de entrada, informações dos TPAUMs fornecidos por um sistema de decomposição de sinais EMG em tempo real. Com isso, pode ser possível atingir uma melhor precisão e controlar um número maior de elementos em próteses e IHMs ou criar novos tratamentos baseados em *biofeedback*.

Um dos objetivos de um trabalho interdisciplinar que vem sendo desenvolvido atualmente pelo grupo de pesquisa do Laboratório de Engenharia Biomédica da Faculdade de Engenharia Elétrica da Universidade Federal de Uberlândia é o de desenvolver um novo treinamento com *biofeedback* para modulação neuroplástica em pacientes com espasticidade após acidente vascular encefálico.

Um acidente vascular encefálico pode alterar a funcionalidade de conexões sinápticas comprometendo um número alto de atividades neurais excitatórias ou inibitórias. Isso promove uma deficiência no mecanismo de controle neural e, consequentemente, uma desordem motora funcional. Após algumas semanas do acidente, o paciente geralmente apresenta espasticidade, hiperreflexia e padrões de movimento em massa denominados sinergias obrigatórias (30). Nesses casos, a espasticidade, segundo a teoria clássica, decorre da perda de influência inibitória descendente (via retículo-espinhal) ocasionadas por lesões do trato córtico-espinhal que se constitui em via mediadora de influências supra-espinhais

sobre a medula espinhal (31, 32).

Uma hipótese de um novo tratamento para tal problema envolve a utilização de meios que promovam a ocorrência da plasticidade sináptica; esta consiste-se na organização neural promovida por fenômenos fisiológicos de origem bioelétrica e que está presente em todas as etapas da ontogenia, incluindo tanto a fase adulta como o envelhecimento (33). Através dessa reorganização neural, talvez seja possível modular os potenciais de ação que surgem da perda da influência inibitória descendente, recuperando a função motora.

O grupo de pesquisa propõe uma maneira de ativar a plasticidade sináptica através de treinamentos baseados em *biofeedback*, em especial através do *miofeedback*. No caso do *miofeedback*, este poderia ser realizado através de parâmetros comumente calculados do sinal EMG, como por exemplo o RMS de uma janela, a envoltória do sinal ou mesmo a frequência mediana instantânea. O problema é que esses parâmetros, apesar de relacionados com a atividade neurológica, fornecem um mecanismo indireto, podendo ser de pouca serventia para esses casos. Assim, a detecção e classificação dos disparos dos potenciais de ação de unidades motoras em tempo real, onde as informações sobre os mecanismos neurais são identificadas, proporcionando meios para atingir o objetivo proposto.

1.2 Objetivos

Um dos focos de estudo nas áreas da engenharia é a detecção de sinais em meio ao ruído. Como exemplo, tem-se a técnica de utilização de filtros digitais especiais, denominados filtros casados, em sistemas de radar e sonar (34, p. 24) e sistemas de comunicação digital (35, p. 248). Como filtros digitais são amplamente utilizados em sistemas em tempo real, eles podem fornecer uma possível solução para o problema da detecção e classificação dos disparos das unidades motoras presentes nos sinais EMG. Esse trabalho tem como objetivo propor e validar técnicas para detecção e classificação de disparos de unidades motoras em sinais EMG baseado em tais filtros.

1.2.1 Objetivos específicos

Para atingir esse objetivo, este trabalho deverá atingir as seguintes metas:

- Avaliar o estado da arte de filtros casados em engenharia.
- Elaboração da proposta de uma metodologia de detecção e classificação de sinais EMG baseado em filtros casados.
- Implementação da metodologia proposta.
- Validação da metodologia.

1.3 Estrutura do trabalho

Este capítulo inicial apresentou as motivações principais desse trabalho e seus objetivos. Nos capítulos seguintes, são apresentadas as técnicas e etapas do desenvolvimento de uma metodologia para detecção e classificação de disparos de Ums em sinais EMG, baseado em filtros casados. Estruturalmente, o texto está dividido na seguinte forma:

- Capítulo 2: Este capítulo apresenta uma visão geral dos sistemas de decomposição de sinais EMG e seus princípios de funcionamento. Além de fazer uma análise das vantagens e limitações desses sistemas.
- Capítulo 3: No capítulo, é realizada uma revisão sobre filtros casados apresentando sua definição, características e propriedades e exemplos de aplicação.
- Capítulo 4: O capítulo apresenta uma proposta uma metodologia para detecção e classificação de sinais EMG baseada em filtros casados.
- Capítulo 5: Neste capítulo, serão apresentados os experimentos e resultados para validação da metodologia proposta.

- Capítulo 6: Este capítulo discute os resultados obtidos e os compara com os demais métodos correlatos encontrados.
- Capítulo 7: No capítulo final serão apresentadas as conclusões deste trabalho e sugestões para estudos futuros.

Capítulo 2

Decomposição de sinais EMG

O capítulo anterior apresentou uma definição do processo de decomposição de sinais EMG como sendo aquele capaz de separar os trens de pulso de unidades motoras (TPAUMs) a partir do sinal EMG (Figura 2.1). Os TPAUMs estão relacionados com os potenciais de ação que percorrem os motoneurônios alfa, e estão diretamente relacionados com o controle motor por parte do sistema nervoso.

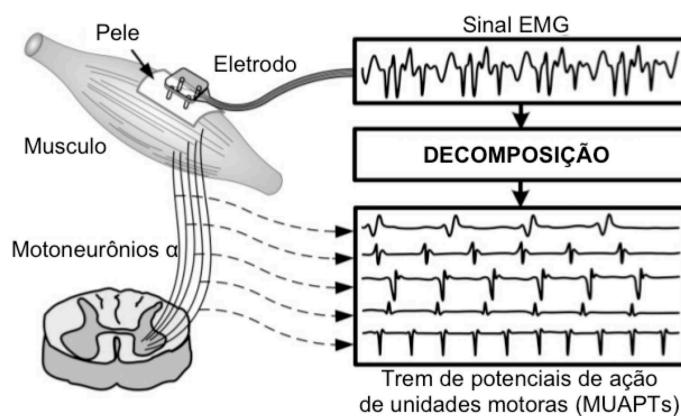


Figura 2.1: Processo de decomposição de sinais EMG, obtendo os PAUMs do qual o sinal é formado. (modificado de De Luca et al.(1))

O processo de decomposição pode ser realizado de forma manual ou automática. O

diagrama de blocos típico de um sistema de decomposição EMG é apresentado na Figura 2.2. O sistema é composto de uma etapa de captura de sinais EMG, que corresponde ao conjunto da instrumentação utilizada para registrar a atividade miográfica. Esta etapa é composta pelos eletrodos, os circuitos de condicionamento de sinal, o sistema de aquisição de dados e o software de registro e controle do equipamento.

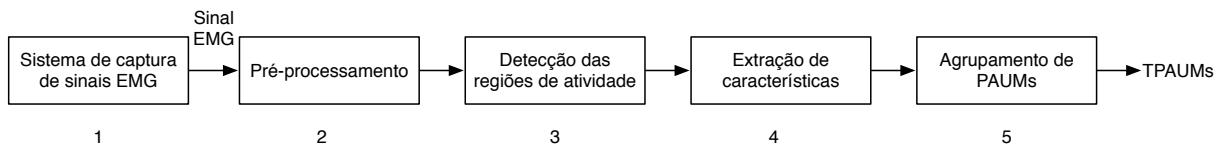


Figura 2.2: Diagrama de blocos de um sistema de decomposição de sinais EMG típico.

A etapa de pré-processamento, visa melhorar a relação sinal-ruído ou evidenciar os PAUMs. Tipicamente, são utilizados filtros digitais para tal finalidade, mas alguns sistemas utilizam algoritmos mais complexos, como descrito posteriormente.

A próxima fase é responsável pela detecção de regiões de atividade EMG. Este processo consiste em dividir o sinal eletromiográfico em segmentos que contenham potenciais de ação de unidades motoras isolados ou sobrepostos, descartando os intervalos constituídos apenas de ruídos (19). Nesta segmentação dos sinais EMG, procura-se realizar a detecção da atividade eletromiográfica da forma mais precisa possível, com o objetivo de se detectar uma janela contendo até mesmo apenas um PAUM ou uma sobreposição no tempo de alguns PAUMs.

A etapa de extração de características recebe o conjunto de regiões de atividades da etapa anterior e constrói um vetor num espaço multidimensional associado com as características do segmento encontrado. Esse vetor pode incluir desde a própria forma de onda do sinal a outros elementos como, por exemplo, o valor máximo e mínimo do sinal e o número de fases, onde cada fase do sinal EMG consiste em uma mudança da taxa de variação da amplitude do sinal que está associada aos efeitos fisiológicos da despolarização e repolarização da membrana das células musculares. Essa mudança pode gerar máximos e mínimos locais, inversões de amplitude e platôs no sinal.

Os vários PAUMs de um trem de PAUMs possuem características semelhantes por serem fruto do somatório dos potenciais de ação de uma mesma unidade motora. Essas características formam uma espécie de assinatura dos PAUMs da unidade motora e possuem uma pequena variação entre cada disparo. Dessa forma, ao aplicar um algoritmo de agrupamento sobre os vetores de características, serão agrupados os PAUMs semelhantes que geralmente correspondem a um trem de PAUMs, processo este realizado na última etapa de processamento. A partir dos grupos gerados é possível realizar a reconstrução dos trens de PAUMs, sintetizando um sinal com as informações da forma de onda e do tempo de disparo de cada PAUM.

Como pode ser visto, um sistema para decomposição de sinais EMG é algo complexo, em que os resultados obtidos dependem tanto da instrumentação utilizada, quanto das técnicas de processamento de sinal. A escolha do tipo de eletrodo, frequência de amostragem, algoritmos de detecção, extração de características e agrupamento variam significativamente entre os diversos sistemas existentes. Dessa forma, é preciso avaliar profundamente todas as etapas de captura e processamento de sinais a fim de obter o melhor desempenho possível.

Um mecanismo bem simples de classificação automática de PAUMs no sinal EMG consiste em esquemas de detecção através de limiares de tensão aplicados sobre o sinal EMG (36, 21, 20). Nessa técnica, um limiar, geralmente correspondente ao maior pico dos PAUMs, é utilizado para disparar o gatilho de um osciloscópio, gerando o traçado do PAUM no mesmo. A técnica requer que um eletrodo de agulha seja posicionado de modo que o PAUM de interesse possua o maior pico do sinal. Com isso, é possível verificar a forma de onda do PAUM e estimar a sua taxa de disparo. Apesar de simples e de fácil implementação, essa técnica apresenta as seguintes limitações: é bastante dependente da relação sinal ruído, só é capaz de detectar um único PAUM no sinal e é propensa a erros de classificação devido a sobreposição de PAUMs que podem gerar picos que ultrapassam o limiar definido além de *crosstalk* de unidades motoras vizinhas.

A partir da década de oitenta surgiram uma série de trabalhos que lidam com a

decomposição completa de sinais EMG, envolvendo sistemas para classificar automaticamente PAUMs referentes a várias unidades motoras e tratar sobreposições de maneira automática. Nas seções a seguir, são detalhados os elementos constituintes desses sistemas, além de outras considerações sobre questões relacionadas com a decomposição de sinais EMG.

2.1 Instrumentação

Os primeiros sistemas de decomposição utilizavam eletrodos invasivos para detecção do sinal (18, 3, 20, 10, 21); os sistemas atuais tendem a utilizar eletrodos de superfície (23, 25, 37, 1, 28, 38, 39) para fornecer um maior conforto aos voluntários. É interessante frisar que a forma do PAUM capturado depende do tipo, forma, tamanho e posicionamento do eletrodo. Eletrodos com pequena área de contato e micro-eletrodos captam sinais de frequências mais altas, relacionados a poucas UMs cujas as fibras estão próximas. Já eletrodos com uma grande área de contato ou macro-eletrodos captam sinais de frequências mais baixas, relativos a um grande número de UMs. Consequentemente, sinais oriundos de eletrodos de área de contato pequena ou micro eletrodos apresentam, com maior frequência, a ocorrência de PAUMs isoladas e a contribuição de fibras individuais é mais evidente, simplificando o processo de decomposição (11). *Arrays* de eletrodos podem ser utilizados para realizar uma filtragem espacial do sinal (25, 38, 40) ou para coletas multicanais (1, 40, 41, 42, 39). A captura de mais de um canal pode auxiliar no processo de decomposição ou fornecer uma forma de validação do sistema através da técnica das “duas fontes” proposta por Mambrizo e De Luca(43) que consiste em capturar o sinal EMG em dois eletrodos muito próximos e comparar o resultado da decomposição de cada canal em busca de inconsistências. Detalhes dessa técnica serão apresentadas mais adiante neste capítulo.

Ainda com relação a instrumentação, a taxa de aquisição do sinal e os filtros devem acompanhar as características dos eletrodos utilizados. Eletrodos invasivos e micro-

eletrodos captam sinais de frequências mais altas. Portanto, nestes sistemas, os sinais coletados devem ser condicionados utilizando filtros passa-faixa com frequência de corte superior atingindo valores de até 10 kHz. A Tabela 2.1 resume as características dos filtros para os sistemas de decomposição que utilizam eletrodos invasivos, onde é possível observar essa característica. Lefever e De Luca(18) e Ren et al.(26) utilizam um filtro passa-alta com frequência de corte mais elevada que os demais numa tentativa de evidenciar melhor os PAUMs; entretanto, isso pode levar a eliminação de PAUMs com espectro formado por frequências menores. Para eletrodos de superfície, o sinal ocupa uma faixa menor do espectro de frequências, podendo ser utilizados filtros com frequências de corte superior ajustada para valores menores. A Tabela 2.2 resume as características dos sistemas de aquisição utilizados para a decomposição de sinais EMG de superfície, onde é possível verificar a utilização de filtros com frequência de corte superior de, no máximo, 2 kHz. Para os sinais de superfície, o ideal é que sejam coletados com uma banda de 10 Hz até 1 kHz (44), enquanto que a frequência de corte superior para eletrodos invasivos deve ser superior a 3kHz. Deve-se observar ainda que a taxa de aquisição do sinal deve obedecer ao teorema de Nyquist, assumindo pelo menos duas vezes o valor da frequência máxima do sinal (45, 46).

2.2 Pré-processamento

Esta é uma etapa opcional, que visa melhorar a relação sinal ruído e/ou evidenciar melhor os picos do sinal, a fim de destacar os PAUMs. Alguns sistemas utilizam filtros digitais do tipo passa-faixa com frequência de corte inferior acima de 100 Hz para atenuar ruídos da rede elétrica e flutuações de baixa frequência, geralmente relacionadas a ruídos ou PAUMs distantes do eletrodo (18, 10, 22, 24, 1, 29). Outros sistemas utilizam filtros diferenciais para destacar os picos do sinal, facilitando a identificação dos PAUMs (3, 20, 23). Outras técnicas de processamento como, por exemplo, *Wavelets* (5, 26) e *Empirical Mode Decomposition* (EMD) (28, 2) também já foram utilizadas nessa etapa com a mesma finalidade. Alguns sistemas só atingem níveis de precisão satisfatórios após essa etapa de

Tabela 2.1: Características da aquisição e condicionamento utilizados em sistemas de decomposição baseados em eletrodos invasivos. $F_{c_{inf}}$: Frequência de corte inferior, $F_{c_{sup}}$: Frequência de corte superior, F_{aq} : Frequência de aquisição.

Referência	$F_{c_{inf}}$	$F_{c_{sup}}$	F_{aq}
Lefever e De Luca(18)	1.000 Hz	10.000 Hz	50.000 Hz
Gerber et al.(19)	32 Hz	3.000 Hz	10.000 Hz
McGill, Cummins e Dorfman(3)	8 Hz	5.000 Hz	10.000 Hz
Hassoun, Chuanming e Spitzer(20)	2 Hz	10.000 Hz	20.000 Hz
Christodoulou e Pattichis(10)	3 Hz	10.000 Hz	20.000 Hz
Wellig, Moschytz e Läubli(22)	150 Hz	3.000 Hz	10.000 Hz
Fang, Agarwal e Shahani(5)	100 Hz	5.000 Hz	12.000 Hz
Ren et al.(26)	2.000 Hz	10.000 Hz	30.000 Hz
Florestal, Mathieu e Malanda(27)	3 Hz	3.000 Hz	8.000 Hz
Farina et al.(40)	500 Hz	5.000 Hz	10.000 Hz
Florestal, Mathieu e McGill(42)	5 Hz	5.000 Hz	10.000 Hz
Holobar et al.(39)	500 Hz	5.000 Hz	-

pré-processamento. Entretanto, deve-se tomar cuidado com a técnica utilizada, pois essa pode gerar falsos picos que podem ser classificados erroneamente como PAUMs, ou até mesmo eliminar PAUMs do sinal (11).

A Figura 2.3 apresenta um exemplo do resultado obtido com a técnica EMD (2). Observe que o filtro foi capaz de remover boa parte dos ruídos presentes no sinal EMG, melhorando significativamente a relação sinal-ruído do sinal utilizado no restante do processamento. Uma outra técnica proposta consiste na utilização de um filtro diferencial para evidenciar os picos do sinal (Figura 2.4).

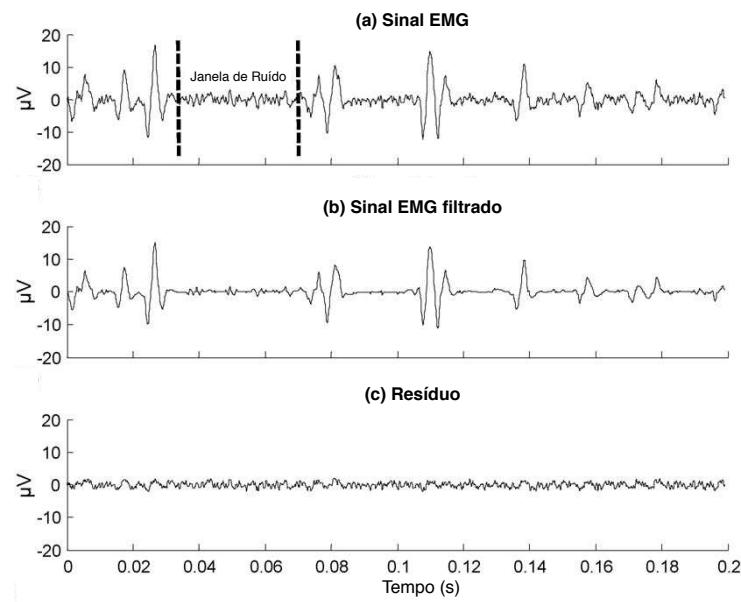


Figura 2.3: Exemplo de pré-processamento de um sinal EMG usando EMD: (a) o sinal EMG original, (b) o sinal EMG após a aplicação da técnica e (c) o resíduo (modificado de Andrade et al.(2)).

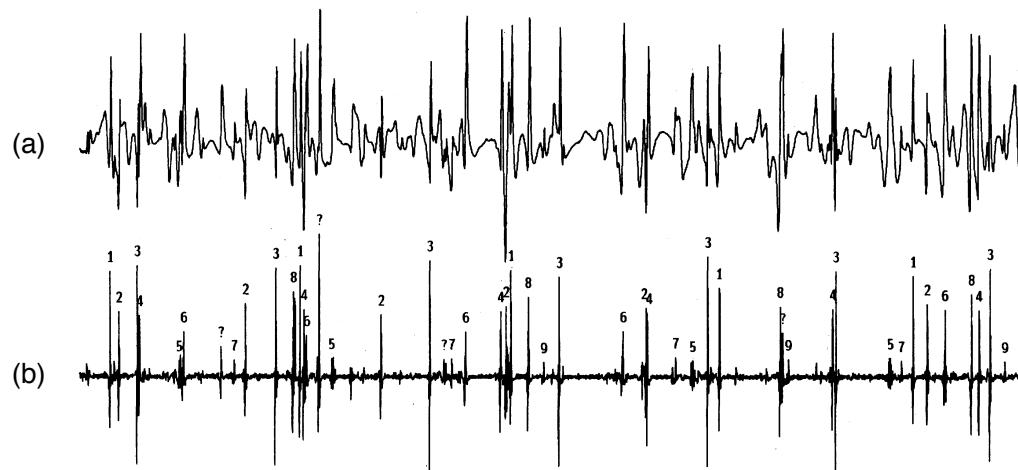


Figura 2.4: Exemplo pré-processamento de um sinal EMG usando um filtro diferencial de segunda ordem: (a) sinal EMG original, (b) o sinal após a aplicação do filtro (modificado de McGill, Cummins e Dorfman(3)).

Tabela 2.2: Características da aquisição e condicionamento utilizados em sistemas de decomposição baseados em eletrodos de superfície. $F_{c_{inf}}$: Frequência de corte inferior, $F_{c_{sup}}$: Frequência de corte superior, F_{aq} : Frequência de aquisição.

Referência	$F_{c_{inf}}$	$F_{c_{sup}}$	F_{aq}
Xu, Xiao e Chi(23)	5 Hz	800 Hz	10.000 Hz
Chauvet et al.(25)	10 Hz	1.000 Hz	10.000 Hz
Holobar e Zazula(37)	10 Hz	500 Hz	2.048 Hz
Garcia, Okuno e Azakawa(47)	70 Hz	1.000 Hz	10.000 Hz
Theis e García(48)	70 Hz	1.000 Hz	10.000 Hz
Andrade, Nasuto e Kyberd(28)	10 Hz	2.000 Hz	10.000 Hz
Kleine et al.(38)	3 Hz	400 Hz	2.000 Hz
Farina et al.(40)	10 Hz	500 Hz	2.048 Hz
Holobar et al.(39)	10 Hz	500 Hz	1.650 Hz

2.3 Segmentação de sinais EMG

O processo de detecção de atividade, também denominado de segmentação, consiste em analisar o sinal coletado, dividindo-o em janelas que contenham PAUMs, descartando as regiões do sinal constituídas apenas de atividade base e ruídos. A Figura 2.5 ilustra o processo, exibindo o sinal EMG original e as quatro janelas de atividade identificadas, sendo que, neste exemplo, as três primeiras janelas correspondem a PAUMs isoladas e a quarta janela a uma sobreposição de PAUMs.

Para a realização da segmentação duas estratégias são comumente utilizadas: a detecção através de limiares e a detecção através dos picos do sinal. No primeiro caso um limiar de comparação é definido a partir de um parâmetro do sinal EMG. Quando a amplitude desse parâmetro está acima do limiar é detectada a presença de PAUMs. Parâmetros comumente utilizados são a amplitude do sinal (18, 3, 5, 1, 27), a variância (21, 22, 29) e a potência do sinal (24, 26). Andrade, Nasuto e Kyberd(28) utilizaram um limiar aplicado sobre a envoltória do sinal obtida através da transformada de Hilbert.

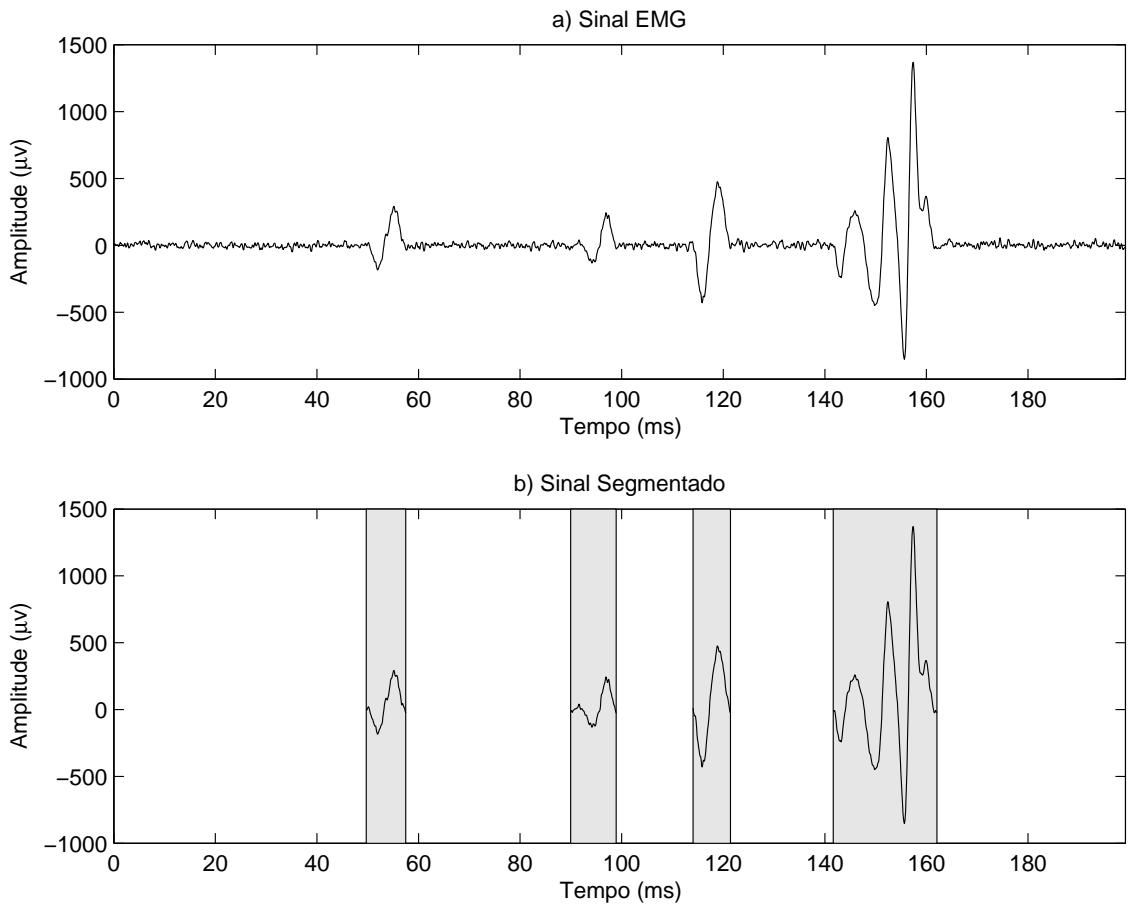


Figura 2.5: Exemplo do processo de segmentação. (a) Sinal EMG original e (b) janelas contendo apenas as regiões de atividade que podem ser PAUMs isoladas ou sobrepostas.

A Figura 2.6 exemplifica o processo de segmentação usando um limiar de amplitude. O valor do limiar é definido a partir da atividade base e partes do sinal que ultrapassam o limiar correspondem às regiões de atividade.

Como pode ser observado na Figura 2.6, esse tipo de técnica permite detectar, com boa precisão, o início e o fim da atividade; porém, encontra problemas com quedas momentâneas e inversões de fase do parâmetro de comparação utilizado, além de ser dependente da relação sinal ruído. A maioria dos métodos baseados nessa técnica aplicam algum processamento extra para contornar essas limitações. Um exemplo seria definir o fim da atividade apenas quando o sinal permanecer abaixo do limiar por um determinado

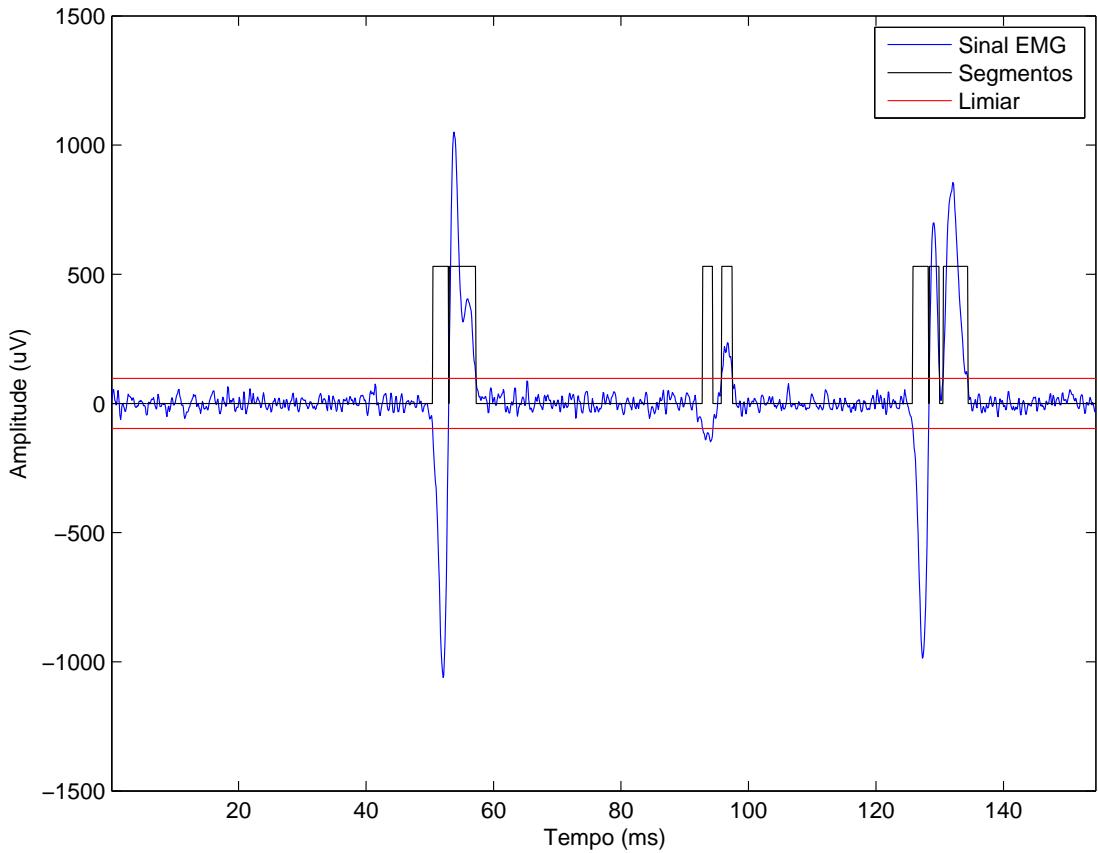


Figura 2.6: Exemplo do processo de segmentação por limiar de amplitude. Observe que a técnica apresentou problemas na detecção do segundo e do terceiro PAUMs devido à inversão de fase e a variação de amplitude do sinal.

tempo.

A segunda estratégia consiste em detectar os picos do sinal e definir uma janela centralizada em torno do pico, onde essa janela é considerada como uma região de atividade (20, 10, 23, 25). A Figura 2.7 ilustra a técnica. Os máximos locais P1, P2 e P3 são encontrados pelo algoritmo e os segmentos são definidos como sendo as janelas J1, J2 e J3 que estão centralizadas em relação aos picos correspondentes.

Por utilizar uma janela fixa centralizada nos picos do sinal, obtém-se automaticamente

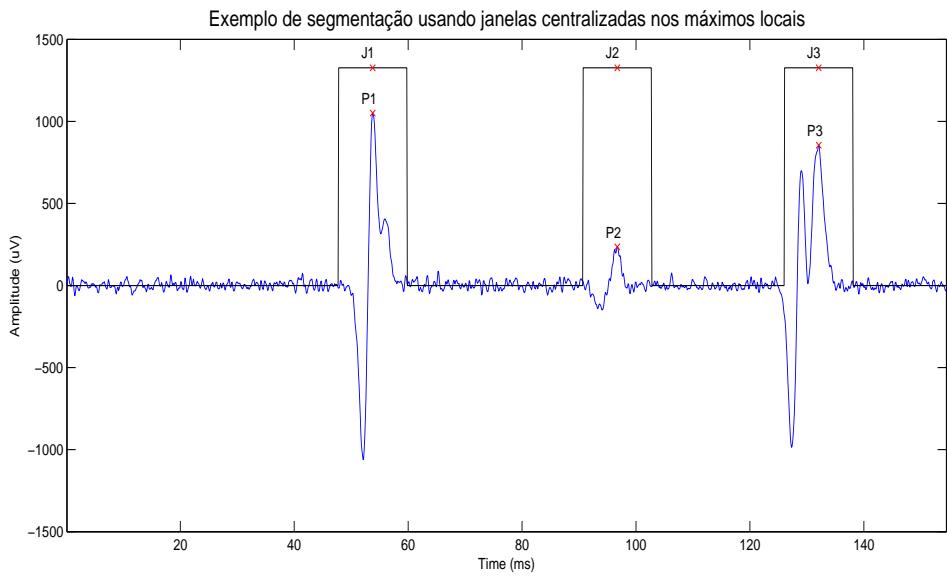


Figura 2.7: Exemplo de segmentação utilizando as janelas aplicadas sobre os picos do sinal.

um alinhamento dos picos e um número de amostras constantes que podem facilitar a etapa de agrupamento em algoritmos de decomposição. Porém, essa técnica não é capaz de detectar precisamente o início e o fim da atividade. Outro problema da técnica refere-se ao tamanho da janela. Uma janela muito grande pode incluir partes de um PAUM vizinho, enquanto uma janela pequena pode não incluir parte de uma sobreposição de PAUMs com maior duração.

Como pode ser observado, cada método tem as suas vantagens e desvantagens. O método do limiar permite detectar com boa precisão o início e o fim da atividade, porém encontra problemas com quedas momentâneas e inversões de fase do parâmetro utilizado, além de ser dependente da relação sinal ruído. Já o sistema de detecção por picos, geralmente, define uma janela fixa, dificultando uma detecção precisa do início e do fim da atividade. Todas essas limitações podem influir nas próximas etapas de um sistema de decomposição. Por exemplo, caso se utilize uma segmentação baseada em uma janela centralizada no maior pico, evita-se o processo de alinhamento numa etapa futura, facili-

tando o processo. Entretanto, ao definir um tamanho de janela muito grande, pode-se ter uma grande variabilidade nas regiões próximas às bordas que conteriam ruídos ou partes de outros PAUMs próximos; isto dificulta o agrupamento e exige a aplicação de algum filtro ou outro tipo de processamento nessas áreas.

2.4 Extração de características

Os segmentos do sinal obtidos na etapa de processamento anterior são considerados como candidatos a PAUM e serão utilizados como entrada para a etapa de extração de características. Assume-se que as características possuam uma variação pequena e gradual entre disparos de uma mesma unidade motora e se diferenciem das demais, formando uma espécie de assinatura. Vários sistemas utilizam um vetor de características composto pelas amostras do sinal (20, 10, 21, 23, 25, 28). Outras características no domínio do tempo também são utilizadas como, por exemplo, as máximas inclinações positiva e negativa, amplitude de pico a pico, número de fases, duração do segmento (19, 29) e parâmetros dos extremos locais e inversões de fase (sequência, magnitude, intervalos) (27). Existem ainda, sistemas que utilizam, como características, parâmetros no domínio da frequência ou no domínio tempo-frequência, como, por exemplo, coeficientes de transformadas de Fourier (3) e Wavelets (22, 5, 24, 26).

Stashuk(11) enumerou alguns fatores que devem ser levados em consideração para de definição das características a serem utilizadas na construção dos vetores:

- Qual é o requisito computacional de armazenamento e o tamanho total dos vetores de características?
- Qual é o esforço computacional necessário para extrair as características?
- Qual é a relação sinal-ruído e a variância de cada característica?
- Qual é a correlação entre as características?

- Qual é a capacidade de discriminação das características escolhidas?
- Qual é a sensibilidade da representação ao alinhamento da forma de onda do segmento encontrado?
- Qual é o efeito da sobreposição de PAUMs na característica?
- Qual é o efeito da variação da forma de onda do PAUM na característica?

Observando essas questões, pode-se fazer uma análise a fim de detectar vantagens e limitações da utilização de determinada característica do sinal EMG no sistema de decomposição. Por exemplo, uma das opções na construção dos vetores de características consiste em utilizar as amostras do sinal, onde o valor de amplitude de cada amostra é considerada como uma característica. Deve-se observar que, neste caso, podemos ter problemas com o requisito computacional de processamento, principalmente em sistemas que trabalham a taxas de amostragem mais altas. Isso ocorre pois o tamanho do vetor de características é o mesmo do número de amostras do segmento, e ao utilizar um vetor de características com um número grande de elementos tem-se um aumento do custo computacional da etapa seguinte, onde é realizada uma série de operações matemáticas sobre esses vetores.

Ainda com relação à utilização das próprias amostras como características, a relação sinal-ruído do sinal capturado influí diretamente na relação sinal-ruído da característica, pois as próprias amostras do sinal foram utilizadas na sua construção. Existem também problemas com relação ao alinhamento, pois uma pequena diferença de fase entre dois PAUMs detectados pode fazer com que dois disparos de uma mesma unidade motora sejam erroneamente divididos em dois grupos por não possuírem características correspondentes. Alguns sistemas que utilizam essa técnica empregam algum processamento extra na etapa de extração de características a fim de conseguir um bom alinhamento e uma padronização no número de amostras. Da mesma forma, a sobreposição de PAUMs e variações na forma de onda entre os disparos da unidade motora também geram problemas para os algoritmos de agrupamento. Entretanto, o uso dessa característica parece estar presente em vários

trabalhos, pois a forma de onda apresenta uma boa capacidade de discriminação e possui um baixo custo computacional de extração, além de estar bastante relacionada com a nossa capacidade de discriminação visual utilizada na identificação manual do PAUMs.

Outra possibilidade para a construção do vetor de características consiste na utilização de parâmetros relacionados com as fases do sinal (número de fases, sequência, amplitude e intervalo de tempo entre os máximos e mínimos locais). Esses parâmetros demandam um pequeno custo computacional na sua extração, mas obtém-se um grande benefício na redução do número de elementos do vetor de características, o que pode gerar um ganho de performance global. Tal situação ocorre devido à diminuição do custo computacional nas etapas de agrupamento, como pode ser observado na discussão de Florestal, Mathieu e Malanda(27).

Comparando o uso de parâmetros das fases do sinal com o caso anterior, onde as amostras do sinal são utilizadas na construção do vetor de características, observa-se que esta ainda apresenta problemas com relação à sobreposição. Entretanto, as características de fase de um PAUM possuem uma variabilidade menor, quando comparadas com as amostras do PAUM. Por exemplo, as características de fase não variam entre dois pulsos não alinhados e possuem uma certa tolerância à presença de ruídos e a algumas variações menores da forma de onda. Ainda assim, é mantida uma boa capacidade de discriminação de PAUMs de unidades motoras diferentes, pois essas características de fase estão diretamente relacionadas com a forma de onda do disparo.

Algoritmos que utilizam transformadas do sinal, como por exemplo a transformada de Fourier e Wavelets, são os que apresentam maior custo computacional. Contudo, assim como na utilização de características baseadas nos parâmetros das fases do sinal, Wavelets podem ser utilizadas para reduzir o tamanho do vetor de característica (49). Isso facilita a etapa de agrupamento, gerando um aumento de performance no algoritmo como um todo. Ao se utilizar os coeficientes de transformadas como característica, busca-se elementos para realizar uma nova classificação do sinal, o que pode fazer com que o vetor de características resultante tenha uma melhor capacidade de discriminação. Porém, isso

é discutível. Problemas na classificação de sinais com mudanças na forma de onda e PAUMs similares baseada em coeficientes da transformada de Wavelet tem sido relatados (26).

Ao observar essas questões, percebe-se que o uso de parâmetros de fase na construção do vetor de características, é um bom compromisso entre o custo computacional da extração e os benefícios em relação à variabilidade e discriminação das características. A utilização das amostras do sinal ainda se apresenta como uma opção bastante interessante, principalmente pela questão do custo computacional. Seu principal problema consiste na questão do alinhamento dos segmentos de atividade. Uma boa forma de contornar esse problema é a utilização de algoritmos de segmentação baseados em janelas centralizadas nos maiores picos dos PAUMs, onde, ao final do processo, os sinais já se encontrariam alinhados.

2.5 Agrupamento de PAUMs

O agrupamento consiste identificar um conjunto de objetos que sejam mais similares entre si quando comparados a outros objetos do conjunto analisado. Algoritmos para tal finalidade geralmente recebem um conjunto de vetores no espaço multidimensional, onde cada vetor corresponde a um elemento do conjunto e cada índice do vetor corresponde a uma característica do elemento. Diversas técnicas podem ser utilizadas para dividir os elementos do conjunto em grupos, das quais uma das mais simples é a análise visual.

Um exemplo simples de separação através da análise visual consiste na utilização de um diagrama de dispersão como ferramenta. A Figura 2.8 ilustra um diagrama de dispersão gerado com base em duas características dos elementos, através do qual é possível detectar claramente dois grupos distintos.

Da mesma forma, na etapa de agrupamento de PAUMs, os vetores de características correspondentes as diversas regiões de atividades são divididos em grupos com características similares. O número exato de grupos é inicialmente desconhecido, e cada grupo

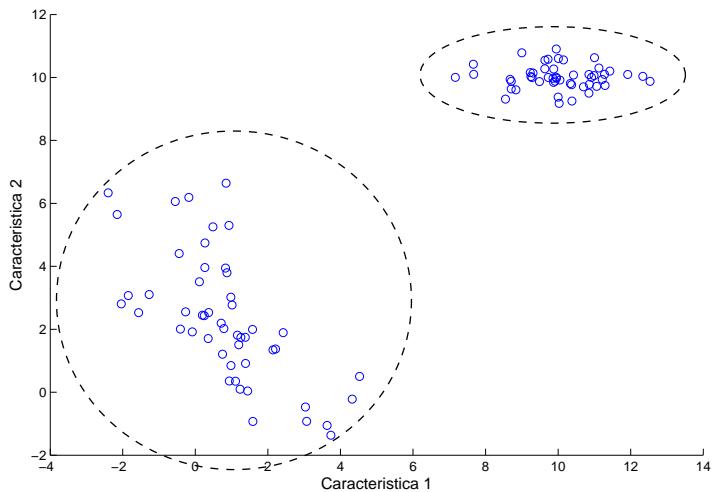


Figura 2.8: Exemplo de diagrama de dispersão.

possui um protótipo das características típicas das formas de onda das regiões de atividade que o compõem. Este protótipo, correspondente à média do grupo, forma uma espécie de gabarito que também é desconhecido de antemão. Ao final do processo de agrupamento, cada grupo corresponderá a um TPAUM ou a um conjunto de sobreposições de PAUMs. Para identificar cada caso, basta verificar o número de elementos do grupo. TPAUMs possuem um número grande de elementos, já que a forma de onda de uma PAUM varia pouco entre cada disparo. Já os conjuntos de sobreposições de PAUMs possuem poucos elementos, pois a probabilidade de uma mesma sobreposição ocorrer várias vezes em um sinal EMG é pequena. Deve-se observar que para a técnica funcionar, é preciso que o número de sobreposições seja menor do que o número de PAUMs isolados, o que torna necessário a utilização de eletrodos com pequena área de captação. Dessa forma, mesmo os sistemas que trabalham com a captura do sinal EMG de superfície usam eletrodos especiais, com pequena área de contato.

Após a definição dos grupos correspondentes a TPAUMs, já é possível estimar alguns parâmetros do sinal EMG. Por exemplo, o número de unidades motoras é estimado como sendo o número de grupos com grande número de elementos obtidos pelo algoritmo de

agrupamento. É também possível calcular um PAUM modelo, que representa a forma de onda típica da unidade motora. Pode-se obter também informações temporais, estimar a taxa de disparo de cada TPAUM e reconstruir uma estimativa do seu disparo.

Técnicas de agrupamento hierárquico, envolvendo a separação dos elementos nos grupos, num processo iterativo, podem ser usadas nesta etapa. Existem dois métodos para esse processo, um chamado aglomerativo e outro divisivo. No método aglomerativo, considera-se inicialmente cada elemento do conjunto como sendo um grupo individual. A cada iteração, os dois elementos mais próximos são combinados até o ponto de se obter um único grupo. No processo divisivo ocorre o inverso; assume-se, inicialmente, um único grupo com todos os elementos e a cada interação, esse grupo é dividido em vários grupos com uma quantidade menor de elementos, até que se obtenha um número de grupos igual ao número de elementos do conjunto (4). Ao final é possível montar uma estrutura em árvore com vários níveis, denominada dendrograma (Figura 2.9).

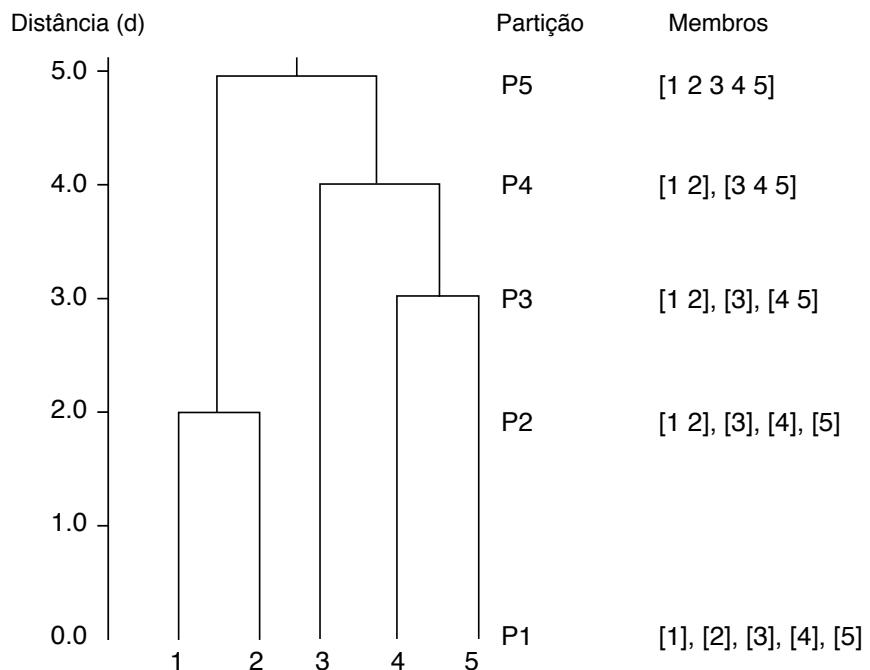


Figura 2.9: Exemplo de dendrograma ilustrando o agrupamento de um conjunto com cinco elementos. Modificado de Everitt et al.(4).

Ao interromper o dendrograma em um nível específico, obtém-se um determinado número de grupos. Na Figura 2.9, na região inferior, todos os elementos estão separados, ou seja, um grupo para cada elemento. Na região superior, ocorre o inverso; um grupo único constituído de todos os elementos. Ao efetuar um corte horizontal pouco acima da distância 3.0, encontramos três grupos: um contendo os elementos 1 e 2, outro contendo os elementos 4 e 5 e, por fim, o elemento 3 isolado.

Para gerar o dendrograma, o algoritmo calcula uma matriz que contém as distâncias entre todos os elementos individuais, a partir do vetor de características, utilizando uma equação específica. Um exemplo é o cálculo da distância Euclidiana entre os vetores a e b realizado através da Equação 2.1, onde o índice i representa o índice do elemento dentro do vetor de características. No método aglomerativo, por exemplo, é encontrada a menor distância entre dois elementos usando a matriz de distâncias. Os dois elementos selecionados são agrupados e uma nova matriz de distâncias é gerada, substituindo os elementos agrupados por um único elemento equivalente e o processo se repete. Ao acompanhar as uniões de elementos durante os passos do processo é possível construir a estrutura em árvore do dendrograma.

$$\|a - b\| = \sqrt{\sum_i (a_i - b_i)^2} \quad (2.1)$$

Vários sistemas de decomposição de sinais EMG utilizam técnicas de agrupamento hierárquico (19, 21, 5, 24, 26, 27, 38). Entretanto, uma dificuldade de utilização dessa técnica na decomposição de sinais EMG consiste na definição do nível de “corte”, que está relacionado com o número de UMs captadas no sinal. Como não se sabe de antemão qual o número de unidades motoras no sinal, não é possível determinar precisamente o nível de corte. Além disso, alguns ruídos de artefato e sobreposições de PAUMs podem aparecer na forma de grupos extras, que não devem ser considerados como sendo PAUMs de uma unidade motora. Deve-se observar ainda, que, para execução dessa técnica, é necessário que já se disponha de todos os elementos que serão classificados e o número de iterações necessárias será diretamente proporcional ao número de elementos a serem classificados.

Dessa forma, o custo computacional aumenta com o número segmentos de atividade e com o tamanho do vetor de características, podendo limitar a aplicação da técnica em sistemas em tempo real.

Outra maneira de realizar o agrupamento de dados é através de algoritmos que definem um número inicial de grupos e associam os elementos a esses grupos distintos. Um desses algoritmos é o *k-means*, em que, após a definição do número de grupos, é escolhido um conjunto de pontos no espaço multidimensional (centroïdes) para representá-los. No início do algoritmo, a escolha é feita de forma aleatória e os elementos do conjunto de dados são associados aos centroïdes mais próximos. Uma função de erro é definida e o erro é calculado para essa associação. A posição dos centroïdes é então reajustada usando a média dos elementos que fazem parte do grupo. O processo se repete até que ocorra uma convergência segundo algum critério como, por exemplo, até que o erro atinja um mínimo local.

O algoritmo *k-means* apresenta menor custo computacional se comparado com os métodos hierárquicos. Porém, em alguns casos, pode-se ter dificuldades para se obter a convergência do parâmetro escolhido, sendo necessária a repetição do processo, sorteando-se novos valores iniciais. Assim como nos métodos hierárquicos, tem-se o problema da definição do número inicial de grupos, pois não se sabe com antecedência o número de unidades motoras contidas no sinal EMG e é necessário que todo o conjunto de amostras esteja presente para realizar o processamento.

Um terceiro grupo de mecanismos consiste em algoritmos de agrupamento incremental (50). Nesse tipo de algoritmo, considera-se inicialmente apenas um grupo composto pelo primeiro elemento do conjunto. O algoritmo passa a analisar o próximo elemento do conjunto e verifica se ele pode ser associado a um dos grupos existentes, utilizando, por exemplo, um limiar aplicado sobre a distância do elemento aos grupos. Caso o elemento não seja associado a nenhum grupo, cria-se um novo grupo a partir das características do elemento e o processo continua até que todos os elementos sejam analisados. Exemplos de aplicação dessa técnica na decomposição de sinais EMG podem ser encontrados nos

trabalhos de McGill, Cummins e Dorfman(3) e De Luca et al.(1).

Um dos problemas com essa abordagem na decomposição de sinais EMG consiste na definição do limiar que determina a criação de um novo grupo. A escolha errada do limiar pode levar a problemas no agrupamento. Por exemplo, um limiar muito pequeno pode dividir um grupo em vários, ou seja, uma unidade motora existente pode ser divida em várias unidades motoras. Já um limiar muito grande pode fazer com que vários grupos diferentes se aglomerem em um único grupo, unindo os PAUMs de várias unidades motoras diferentes. Uma opção interessante é associar o tamanho do limiar com a variância da distância característica do grupo em relação ao centroide do grupo. A técnica tem como vantagem o fato de ter um custo de processamento menor que o das outras duas abordagens apresentadas, principalmente pelo fato de não envolver processos iterativos ou depender de algum tipo de convergência. Ela pode, inclusive, ser aplicada em tempo real, já que não necessita de todo o conjunto de dados para a realização do agrupamento. Outra vantagem é que o algoritmo determina automaticamente o número de grupos de acordo com as características dos elementos, evitando problemas como a definição do número inicial de grupos, necessária no algoritmo *k-means*, ou definição do nível de corte, exigida em algoritmos hierárquicos.

Outras técnicas de agrupamento também podem ser encontradas na literatura. Hassoun, Chuanming e Spitzer(20) e Xu, Xiao e Chi(23) propuseram algoritmos baseados em redes neurais e Chauvet et al.(25) apresentaram um sistema baseado em lógica Fuzzy. Holobar e Zazula(51); Garcia, Okuno e Azakawa(47) e Theis e García(48) desenvolveram sistemas baseados na separação cega de fontes, onde a maior limitação dessa técnica consiste na captura do sinal, que deve ser feita através de arrays de eletrodos, e o número de elementos do array deve ser superior ao número de fontes de sinal. No caso da eletromiografia, as fontes de sinal correspondem as unidades motoras, dessa forma um músculo com cerca de 40 unidades motoras necessita de um array de eletrodos com mais de 40 elementos de captação.

2.6 Tratamento de sobreposições de PAUMs

Após a etapa de agrupamento dos PAUMs, alguns grupos irão conter poucos elementos, distinguindo-se dos demais. Esses grupos provavelmente correspondem a sobreposições de PAUMs que ocorrem devido a característica assíncrona do disparo das unidades motoras. Vários algoritmos visam tratar a sobreposição dos PAUMs a fim de melhorar a precisão do sistema de decomposição de sinais EMG. Pode-se classificá-los em duas categorias: algoritmos de busca sequencial e algoritmos baseados em modelagem (11).

Nos algoritmos de busca sequencial, uma sobreposição de PAUMs é comparada com os modelos de PAUMs encontrados, deslocados em várias posições no tempo. Ao encontrar a melhor associação entre um dos modelos e a sobreposição, é gerado um sinal residual subtraindo-se os dois elementos. O processo se repete sobre esse sinal residual até um determinado critério de parada, como por exemplo, o aumento da energia no sinal residual de uma etapa para outra.

A Figura 2.10 ilustra os passos do algoritmo de busca sequencial proposto por Fang, Agarwal e Shahani(5). O primeiro gráfico na região esquerda contém a sobreposição de PAUMs e o número abaixo indica o valor da energia do sinal. O sinal é correlacionado com a forma de onda modelo de cada unidade motora e a que melhor se correlaciona é escolhida. No primeiro passo do exemplo, o segundo PAUM foi escolhido. O modelo e a sobreposição são alinhados através dos maiores picos do sinal. É calculado o resíduo subtraindo as amostras da sobreposição das amostras do modelo do PAUM. Calcula-se a energia do resíduo e o processo se repete sobre o resíduo enquanto a energia do resíduo estiver diminuindo. Note que, a cada passo, o gábarito associado é removido da análise nas passos seguintes.

Lefever e De Luca(18); Christodoulou e Pattichis(10); Fang, Agarwal e Shahani(5); De Luca et al.(1) e Florestal, Mathieu e McGill(42) utilizam-se de algoritmos de busca sequencial para tratamento da sobreposição de PAUMs. Todos eles empregam algum

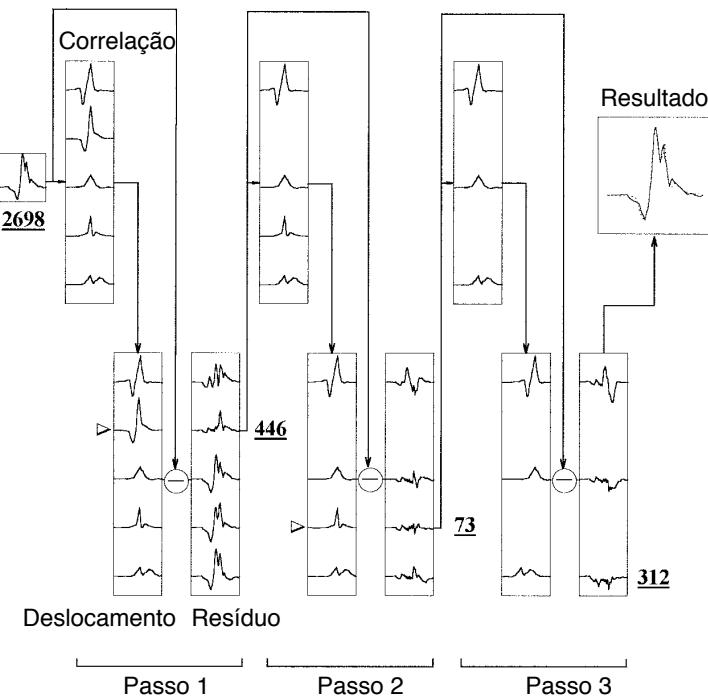


Figura 2.10: Exemplo de tratamento de sobreposições baseado em um algoritmo de busca sequencial (modificado de Fang, Agarwal e Shahani(5)).

tipo de otimização para limitar as comparações entre o modelo da unidade motora e a sobreposição, como no exemplo do alinhamento dos picos, o que diminui o tempo de processamento.

Na técnica baseada na modelagem da sobreposição, um conjunto de modelos de sobreposição é construído e esses modelos são comparados diretamente com o segmento encontrado. Os modelos são construídos a partir das formas de onda média das unidades motoras já encontradas e deslocadas em várias posições diferentes no tempo. A equação 2.2 representa o modelo matemático de sobreposições proposto por Gerber et al.(19), onde M corresponde ao número de PAUMs presente na sobreposição, s_k corresponde ao k -ésimo modelo da forma de onda das unidades motoras encontradas, a_k a um ganho aplicado ao gabarito e $c(t)$ a um termo residual de correção. A Equação 2.2 é utilizada para sintetizar um conjunto de sobreposições variando-se os parâmetros de ganho, modelo de

PAUM e deslocamento, e cada elemento desse conjunto é comparado com a sobreposição encontrada a fim de encontrar a melhor correspondência.

$$r(t) = \sum_{k=1}^M a_k s_k(t - \tau_k) + c(t) \quad (2.2)$$

Além de Gerber et al.(19), Nikolic et al.(21) e Zarei, Maghooli e Firoozabadi(29) utilizam-se dessa estratégia para o tratamento de sobreposições de PAUMs. Essa metodologia apresenta um custo computacional superior à busca sequencial (11) e, se fossem calculados todos os modelos possíveis a partir das variações de número de unidades motoras, dos modelos de PAUMs e dos deslocamentos, o custo computacional seria proibitivo. Assim, geralmente, utiliza-se alguma informação para reduzir o número de modelos a serem avaliados, como, por exemplo, uma estimativa de qual PAUM possui maior probabilidade de disparo naquele momento ou a utilização de coletas multicanais, onde é possível detectar os PAUMs ainda separados (19, 21, 29).

2.7 Resultados da decomposição

Os resultados da decomposição envolvem informações relacionadas com a forma de onda dos PAUMs e com a taxa de disparo dos trens de PAUMs. Com relação à forma de onda dos PAUMs, tipicamente são apresentados dois tipos de gráficos, um denominado *shimmer plot* e outro que contém o gabarito do PAUM (Figura 2.11).

No *shimmer plot*, são alinhados os maiores picos de cada PAUM referente a uma unidade motora e é desenhado o conjunto de curvas, uma sobre a outra. Nele é possível observar a variabilidade da forma de onda do PAUM entre os diversos disparos e, em alguns casos, é possível até detectar alguns erros de classificação pelo algoritmo. Um modelo de forma de onda típico do PAUM também é apresentado. Esse modelo pode ser gerado de diversas formas, como por meio da média, da mediana, da moda ou do cancelamento de interferências (11).

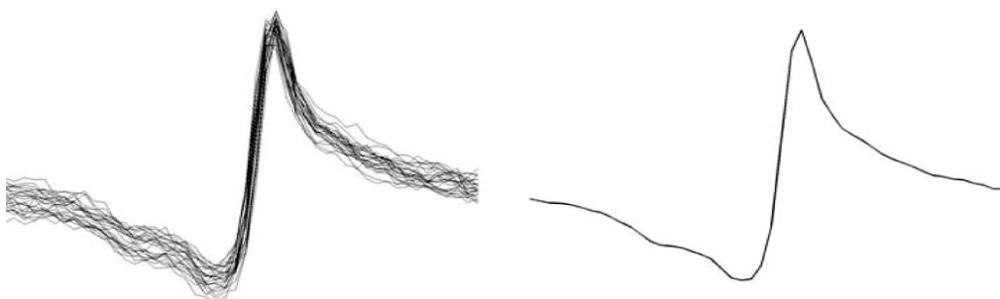


Figura 2.11: Exemplo de resultados relacionados com a forma de onda dos PAUMs (6). No lado esquerdo, tem-se o *shimmer plot*, contendo um conjunto de 25 PAUMs. No lado direito, tem-se o gabarito da unidade motora, obtido através da média dos 25 PAUMs encontrados.

Conforme mencionado no Capítulo 1, a análise da forma de onda permite detectar a presença de distúrbios motores. Através desses gráficos, é possível detectar PAUMs com amplitudes variáveis, múltiplas fases, conjuntos de PAUMs monofásicos de pequena duração, presença de potenciais de fibrilação e picos positivos de curta duração que podem estar associados a neuropatias (13, 14). É possível ainda verificar se o sinal apresenta PAUMs de grande amplitude e formas complexas devido a reinervação colateral, característica de neurapatias (15, 16, 17). Outra aplicação consiste na estimativa do número de fibras musculares presentes na unidade motora, obtido por meio da forma de onda do PAUM através da aplicação de uma dupla diferenciação do sinal (52, 11).

Além da forma de onda, os sistemas de decomposição de sinais EMG apresentam informações temporais relacionadas com as características de disparo de cada unidade motora encontrada. A Figura 2.12 exemplifica um conjunto de gráficos, propostos por De Luca et al.(1), que apresentam informações temporais.

Na coleta de sinal, que originou os gráficos da Figura 2.12, foram colhidos dados de quatro canais de eletromiografia e um canal auxiliar que media a força aplicada através de uma célula de carga. Um sistema de *biofeedback* foi utilizado para fazer com que o vo-

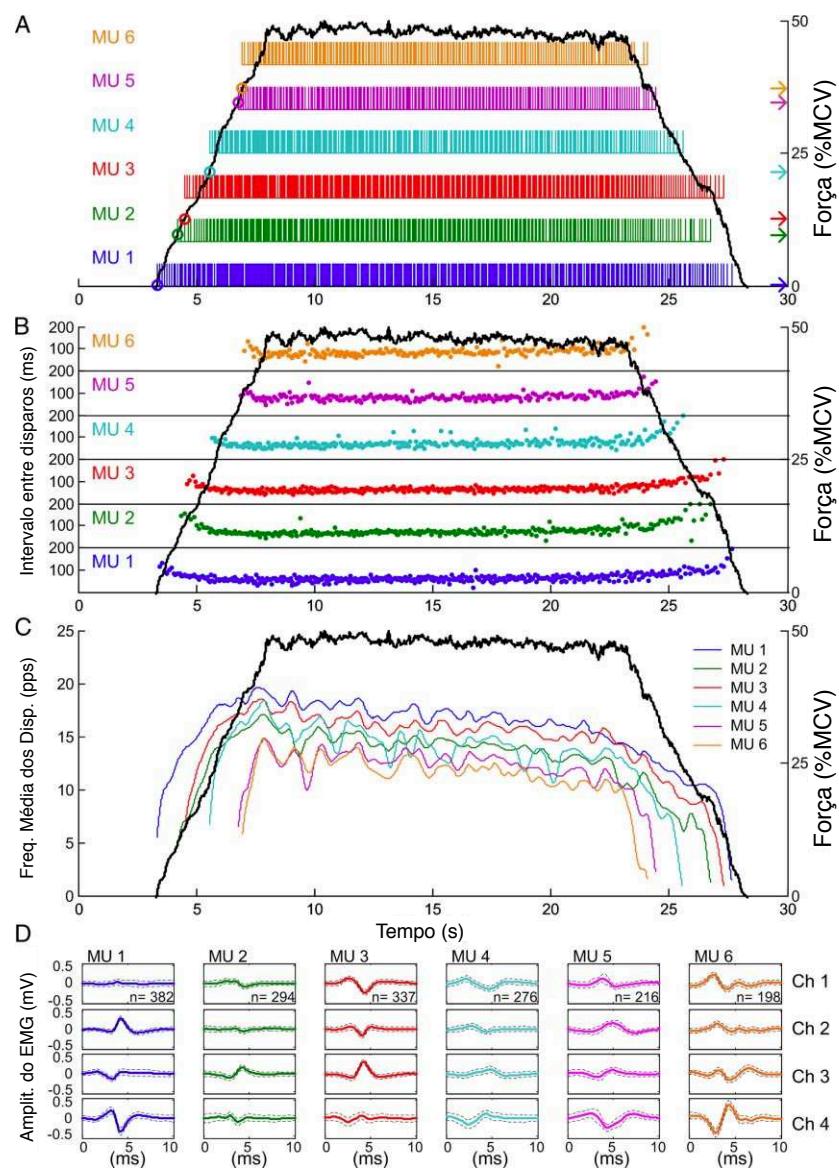


Figura 2.12: Exemplo de resultado relacionado com as características dos disparos dos PAUMs (modificado de De Luca et al.(1)): (A) Gráfico dos TPAUMs de cada unidade motora, marcando o momento e o percentual de força associado ao primeiro disparo de cada unidade motora; (B) Intervalo entre disparos em função do tempo; (C) Média da frequência de disparos em função do tempo; (D) Forma de onda de cada PAUM apresentada em cada eletrodo. Note que os três primeiros gráficos incluem ainda a força aplicada na contração (em preto).

luntário fosse aumentando gradativamente a força aplicada em uma contração isométrica até que atingisse 50% da máxima contração voluntária (MCV). O voluntário aplicava essa força por cerca de 20 segundos e, em seguida, a diminuía gradativamente. Nos gráficos *A*, *B* e *C* da Figura 2.12 é possível observar a força aplicada em preto.

A Figura 2.12a apresenta os trens de PAUMs das unidades motoras encontrados. Através do gráfico é possível identificar o instante no tempo onde ocorreu cada disparo encontrado pelo algoritmo associado a respectiva unidade motora. O gráfico apresenta também informações sobre a sequência de ativação das unidades motoras, indicando o momento do primeiro disparo e o valor da força aplicada relacionadas a cada unidade motora.

O segundo gráfico (Figura 2.12b) é construído a partir do intervalo entre disparos (IED) calculado através diferença de tempo entre dois disparos consecutivos de uma unidade motora. Ele exibe a variação do IED ao longo do tempo, onde o valor do IED corresponde à distância vertical dos pontos ao eixo inferior. Esse gráfico é bastante útil para encontrar erros de classificação, já que é esperado uma pequena variação do IED ao longo do tempo, de modo que pontos dispersos da curva central provavelmente correspondem a PAUMs incorretamente classificados.

No terceiro gráfico, tem-se a curva da média móvel da taxa de disparo das unidades motoras (Figura 2.12c). Essa variação é calculada a partir de uma janela móvel do tipo *Hanning* com um segundo de comprimento aplicado sobre os trens de pulsos. A média é calculada apenas durante o momento da contração isotônica. Nesse gráfico, sempre se observa um decaimento da média móvel ao longo do tempo.

Por fim, é apresentada na Figura 2.12d a forma de onda do gabinete de cada unidade motora para cada um dos canais de captados, nas linhas sólidas. Existe ainda uma linha tracejada que indica o desvio padrão da forma de onda de cada grupo de PAUMs encontrado e pode funcionar como alternativa para o *shimmer plot*.

Essas informações temporais sobre o disparo dos PAUMs fornecem uma boa visualização dos mecanismos de controle do sistema nervoso que não são visíveis nas análises

típicas do sinal eletromiográfico da forma tradicional. De Luca e Hostage publicaram recentemente um trabalho no qual verificam que vários esquemas de controle do sistemas nervoso podem ser visualizados através da técnica e estão de acordo com vários outros estudos existentes, de forma que é possível utilizar as informações obtidas por esses sistemas tanto na pesquisa, quanto na prática clínica (8).

2.8 Metodologias de validação

À medida que foram desenvolvidos os vários sistemas de decomposição de sinais EMG, várias metodologias foram propostas para validá-los. Porém, até hoje, ainda não se chegou à definição de uma metodologia padrão que deve ser observada por todos. As metodologias existentes podem ser divididas em análise a partir de sinais sintéticos, análise qualitativa e análise quantitativa.

Atualmente, o único contexto no qual se tem certeza da quantidade de unidades motoras, da forma de onda e dos momentos dos disparos é quando sinais sintetizados são utilizados. Vários autores utilizam-se dessa técnica para validação inicial dos seus sistemas (18, 5, 23, 24, 25, 26, 27, 28, 40, 48, 37). O grande problema dessa metodologia é que muitas vezes o modelo utilizado pelo algoritmo de sintetização de sinais EMG não é capaz de simular todas as nuances que ocorrem no processo fisiológico e na captura do sinal EMG. Isso limita, porém não descarta, o uso da técnica, de forma que vários autores a combinam com outros mecanismos como, por exemplo, a análise qualitativa das características estatísticas dos disparos (18, 5, 23, 24, 25, 26, 27, 28, 40, 37).

Na análise qualitativa, compara-se os resultados da decomposição com as informações fisiológicas já consagradas na literatura sobre os processos de contração muscular e a eletromiografia, em busca de erros de classificação. Esse tipo de análise é feito praticamente com todos os sistemas de decomposição de sinais EMG. Um exemplo simples consiste em verificar o intervalo entre disparos. Intervalos muito curtos podem indicar falhas do algoritmo, pois o músculo necessita de um intervalo mínimo entre as contrações. Além

disso, normalmente, existe uma pequena variabilidade no intervalo entre disparos de uma unidade motora que pode ser utilizada na detecção de falhas do sistema de decomposição.

Uma ferramenta bastante útil nesse sentido é o histograma do intervalo entre disparos, para detecção de erros de classificação (Figura 2.13). Através do histograma é possível detectar uma tendência central do intervalo entre disparos (IED) e verificar a sua variabilidade. Intervalos muito distantes dessa tendência central podem estar relacionados a dois fatores: a associação errada de um PAUM a uma respectiva unidade motora, ou a perda de um ou mais disparos dentro de um sequência de pulsos. O segundo caso pode ser facilmente identificado, pois esse disparo aparece na forma de um IED múltiplo da tendência central, o primeiro caso mencionado aparece na forma de um IED muito curto. Entretanto, alguns distúrbios motores podem gerar variações no intervalo entre disparos e tal técnica não pode ser utilizada nesses casos.

Para realização de uma análise quantitativa do sistema de decomposição de sinais EMG, foram propostas as seguintes metodologias:

- Utilização de “padrões ouro” definidos por especialistas (18).
- A metodologia das “duas fontes” (43).
- A metodologia baseada na reconstrução do sinal EMG (53).

Vários sistemas utilizam os chamados “padrões ouro” como ferramenta de validação (18, 25, 26, 27, 28, 42, 47). Basicamente, o mesmo sinal é decomposto automaticamente pelo sistema proposto e manualmente por um especialista. Assume-se como sendo corretas as definições do especialista e verifica-se as concordâncias entre os dois resultados. Em alguns casos, são criados aplicativos interativos para facilitar o trabalho do especialista na decomposição dos sinais EMG. O problema dessa metodologia é que se assume que o especialista está sempre correto, o que nem sempre é verdade. Dessa forma, o resultado pode variar de acordo com a experiência, o tempo e até mesmo as ferramentas utilizadas pelo especialista.

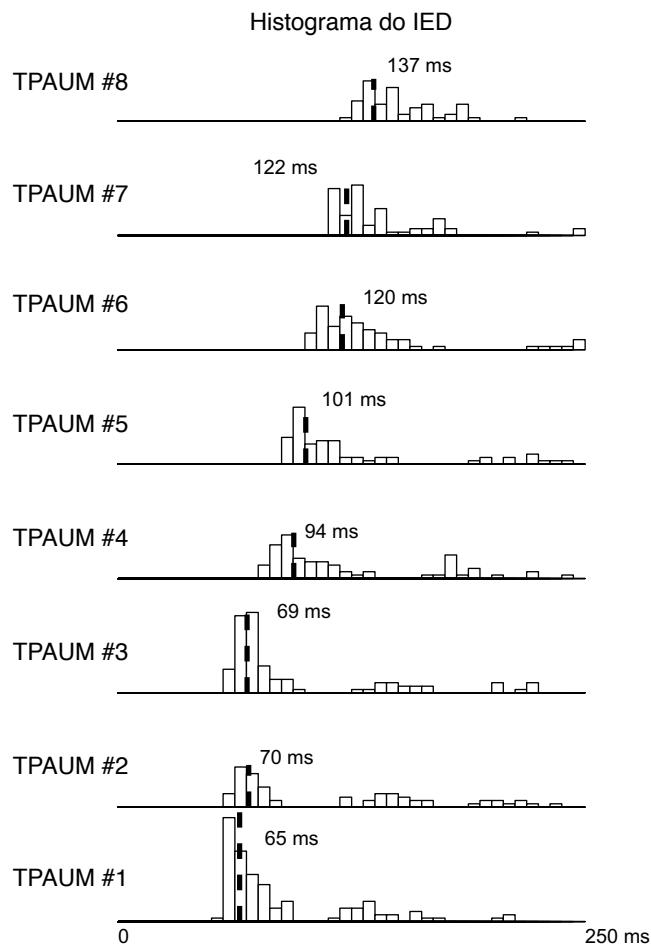


Figura 2.13: Exemplo de histograma do intervalo entre disparos de um conjunto de unidades motoras (modificado de RASHEED, Stashuk e KAMEL(7)).

A metodologia das “duas fontes” foi proposta inicialmente por Mambrizo e De Luca(43). O método consiste no posicionamento de dois eletrodos próximos para captar, basicamente, os mesmos PAUMs. Os algoritmos de decomposição são aplicados aos dois sinais e é verificado a concordância entre os dois resultados a procura de erros. Mambrizo e De Luca(43) definem a precisão do algoritmo de acordo com a Equação 2.3, onde D corresponde ao número de PAUMs totais encontrados e E ao número de PAUMs que não estão em concordância entre os dois canais. Os trabalhos de De Luca et al.(1) e De Luca e Hostage(8) são exemplos que validaram seus sistemas a partir da técnica das “duas

fontes”.

$$P = \frac{D - E}{D} \quad (2.3)$$

Assim como na análise qualitativa, através da metodologia das “duas fontes”, é possível detectar erros no processo de decomposição, auxiliando na validação do sistema. Porém, a metodologia não permite definir exatamente o nível de acerto do algoritmo, o que só é possível de ser feito a partir de sinais sintéticos.

Recentemente, Nawab, Chang e De Luca(53) apresentaram uma nova metodologia baseada na reconstrução do sinal EMG a partir dos trens de PAUMs decompostos. A Figura 2.14 ilustra os passos necessários para a verificação da precisão do algoritmo. Primeiro, é realizada a decomposição do sinal EMG e o sinal isolado de cada unidade referente ao trem de PAUMs é gerado. É calculado ainda um resíduo, que corresponde aos ruídos presentes no sinal. Os trens de PAUMs são utilizados para sintetizar um novo sinal EMG. Esse sinal é composto pela soma dos trens com um ruído gaussiano sintético com mesmo valor RMS do resíduo. O sinal sintetizado passa novamente pelo algoritmo de decomposição e quantifica-se a concordância entre a primeira e a segunda decomposição com a mesma equação utilizada na técnica das duas fontes (Equação 2.3).

Esse esquema ainda sofre dos mesmos problemas da metodologia das duas fontes, pois não é capaz de definir exatamente qual a precisão do algoritmo, justamente pelo fato do padrão de recrutamento não ser conhecido. Entretanto, a técnica pode ser uma boa ferramenta para verificar a repetibilidade do algoritmo.

Como pode ser observado, as técnicas anteriormente apresentadas possuem limitações com relação à avaliação de desempenho das técnicas de decomposição de sinais EMG. Por isso, ainda não foi definida uma estratégia única, através da qual todos os sistemas de decomposição são avaliados. Assim, talvez um melhor mecanismo de avaliação envolva a utilização de várias das técnicas citadas; ou seja, a avaliar sinais sintéticos para definir uma estimativa da precisão do algoritmo e empregar as demais para detectar inconsistências,

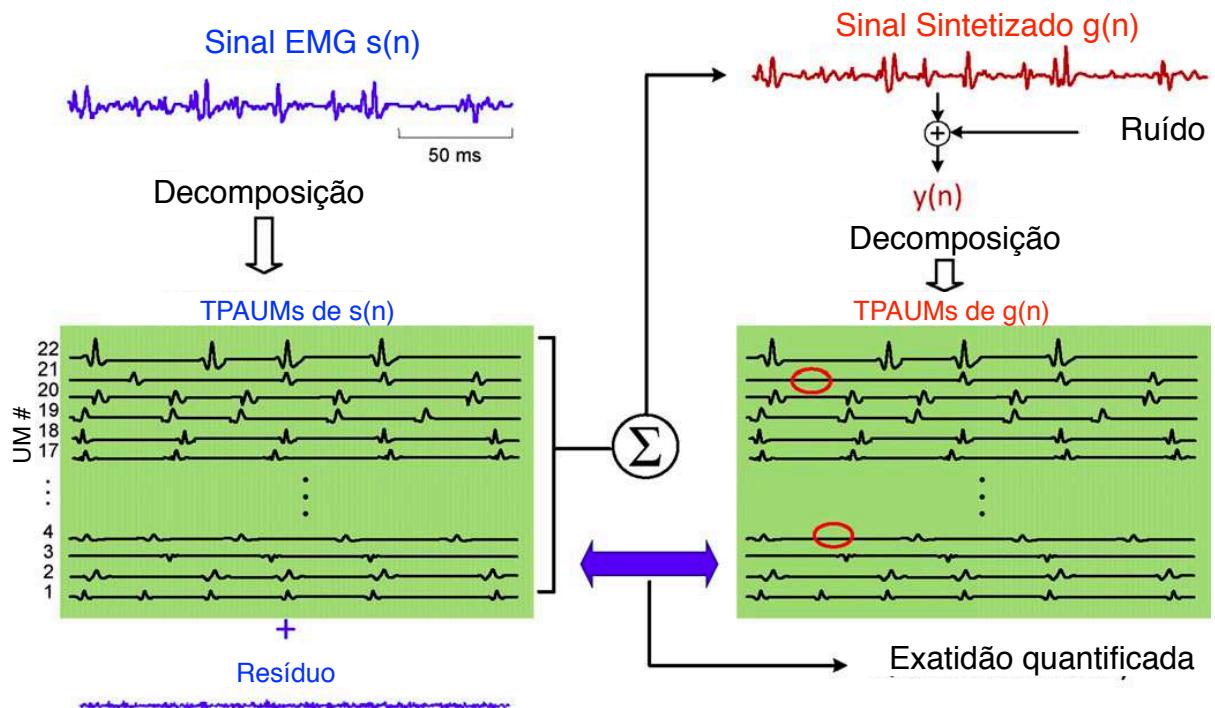


Figura 2.14: Diagrama que ilustra o método de validação de sistemas de decomposição de sinais EMG segundo a proposta de Nawaba, Chang e De Luca (modificado de De Luca e Hostage(8)). Em destaque encontram-se as falhas no processo de decomposição identificadas ao comparar o resultados decomposição do sinal EMG em relação ao sinal reconstruído.

que são medidas indiretas do nível de erro e repetibilidade do sistema de decomposição.

2.9 Considerações sobre os métodos de decomposição existentes

Como descrito no decorrer deste capítulo, uma grande variedade de técnicas já foram utilizadas com a finalidade de realizar a decomposição de sinais EMG. Entretanto, observando-se o diagrama de blocos típico de um sistema de decomposição, percebe-se

que ele é composto de um conjunto de etapas sequenciais o que, pode-se contribuir para a propagação de erros ao longo do procedimento (Figura 2.2). Observa-se ainda, uma interdependência entre as etapas devido a sua característica sequencial. Dessa forma, se ocorrerem erros em uma etapa no início do processo, estes serão propagados para as demais etapas. Podendo chegar ao ponto de exigir algum tipo de processamento extra ao final do processo para aumentar a precisão do sistema.

Além disso, os trabalhos publicados avaliam o sistema como um todo. Seria interessante verificar cada etapa do processamento separadamente, o que poderia ajudar a entender melhor quais os algoritmos de cada etapa apresentam melhor desempenho. Isso deve ser feito especialmente para as etapas de pré-processamento, segmentação e extração de características. Dessa forma, seria possível identificar os efeitos do pré-processamento sobre os PAUMs, qual o melhor algoritmo para segmentação de um sinal EMG, e quais as características dos PAUMs que melhor evidenciam os sinais oriundos de diferentes unidades motoras.

Dependendo da técnica escolhida, o tempo de processamento aumenta consideravelmente com o número de amostras de sinal. Podem ocorrer também, problemas com a convergência, o que levaria a um tempo de processamento indefinido. Além disso, técnicas de agrupamento hierárquico e o *k-means* necessitam realizar a análise sobre todo o sinal, o que limita algumas aplicações em tempo real. Em aplicações clínicas, onde esse tempo de processamento pode ser mais importante do que a precisão do algoritmo (11), o agrupamento é a etapa que mais limita esse tipo de aplicação. Dessa forma, um aprimoramento ou uma nova metodologia em substituição a essa etapa pode permitir o surgimento de novas aplicações clínicas. Outra etapa que consome bastante tempo de processamento e ainda apresenta muitos problemas, é o tratamento de sobreposições. Essa é uma etapa opcional que geralmente é realizada com a finalidade de aumentar a precisão do algoritmo.

Uma alternativa a esses problemas, envolve a utilização de separação cega de fontes na decomposição de sinais EMG. A técnica consiste em utilizar um array de eletrodos a fim de separar os TPAUMs de cada unidade motora. Para que a técnica funcione, é necessário

que o número de elementos de captação seja superior ao número de fontes, que no caso correspondem ao número de unidades motoras. Dependendo do músculo a ser estudado, o número de elementos de captação é muito grande, o que torna a instrumentação complexa e cara.

Dessa forma, ainda se faz necessário um esforço maior no sentido de simplificar o processo de decomposição. A proposta deste trabalho, como descrito anteriormente é propor uma metodologia baseada em um banco de filtros, onde cada filtro é preparado de forma a detectar precisamente os disparos de uma unidade motora. Isso eliminaria etapas que consomem um grande tempo de processamento como, por exemplo, a etapa de agrupamento. O sistema poderia ser implementado baseado em recursos especiais de processadores atuais o que viabilizaria sua aplicação em tempo real em sistemas embarcados. Tal estratégia permitira novas aplicações para a decomposição de sinais EMG, especialmente nas áreas clínicas e de reabilitação.

Capítulo 3

Filtros casados

No capítulo anterior, foi sugerido que a utilização de um método baseado em bancos de filtros, pode ser capaz de realizar a decomposição de sinais EMG. Seguindo essa estratégia, um banco de filtros digitais é aplicado ao sinal EMG para realizar a decomposição, onde cada filtro é construído de forma a ser capaz de detectar os disparos de uma unidade motora.

Para avançar no desenvolvimento dessa estratégia é preciso definir um tipo de filtro específico para essa aplicação. Filtros casados são amplamente utilizados em sistemas de radar e sonar (34, p. 24) e sistemas de comunicação digital (35, p. 248).

Um sistema de radar consiste em um transceptor (transmissor/receptor) que gera e transmite pulsos senoidais com frequências na faixa de micro-ondas (Figura 3.1). O sinal viaja através do espaço na velocidade da luz e é refletido ao encontrar um objeto no caminho. O transceptor recebe o eco do sinal, que se apresenta atenuado e adicionado de ruídos oriundos do canal de propagação (54, p. 22). Filtros casados são utilizados para detectar a presença do sinal transmitido misturado ao ruído do canal de transmissão e, a partir do processamento digital desse sinal e do tempo de retorno, estimar a distância e a velocidade do objeto.

Sistemas de comunicação digital utilizam filtros casados para auxiliar na identificação

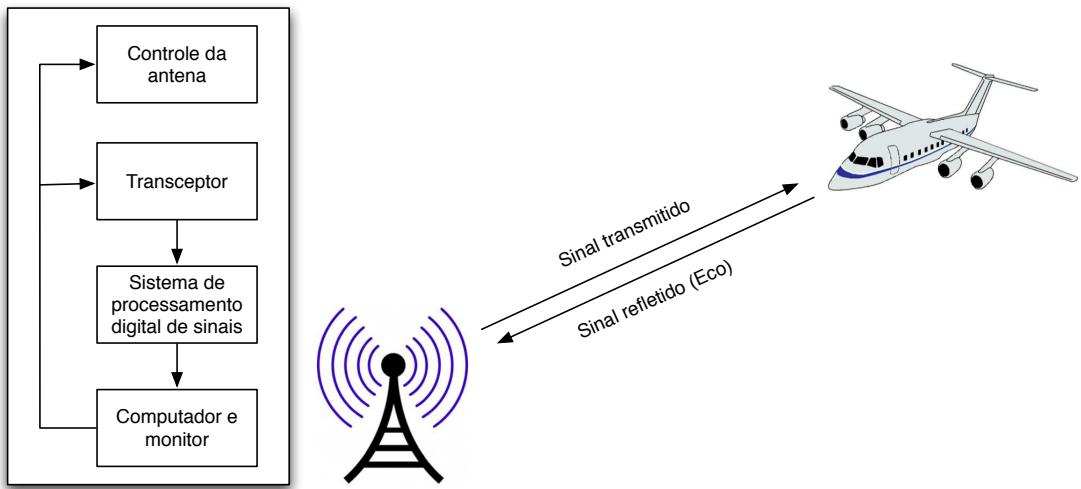


Figura 3.1: Ilustração de um sistema típico de radar.

de símbolos que foram transmitidos através de canais ruidosos. O sinal recebido é constituído de uma onda de curta duração, correspondente ao símbolo, adicionada de um ruído branco. Após a aplicação de um filtro casado sobre o sinal, um limiar é utilizado para verificar a hipótese da presença ou não do símbolo de interesse no sinal recebido. Sistemas de comunicação binários utilizam um único filtro casado para essa detecção, assumindo que, na ausência do símbolo relacionado ao filtro, o outro símbolo está presente.

A Figura 3.2 ilustra esse processo, apresentando um diagrama de blocos do sistema e os sinais associados com as saídas de cada etapa. Um sinal binário (Figura 3.2a) é transmitido por um canal, incorporando um ruído branco em sua saída (Figura 3.2b). O sinal é então submetido a um filtro casado e a saída desse filtro (Figura 3.2c) é enviada a um amostrador. A amostragem do sinal é realizada nos momentos destacados pela grade do gráfico e o sinal nesses pontos é comparado com um determinado limiar (Figura 3.2d). Pontos acima do limiar são considerados como sendo o valor binário “1” e o caso contrário como sendo o valor binário “0”, obtendo uma reconstrução do sinal transmitido.

Existem sistemas de comunicação que trabalham com a detecção de mais de dois símbolos. Estes geralmente empregam bancos de filtros casados, onde cada filtro é preparado para detectar um símbolo específico em um sinal ruidoso (55). Deseja-se investigar se

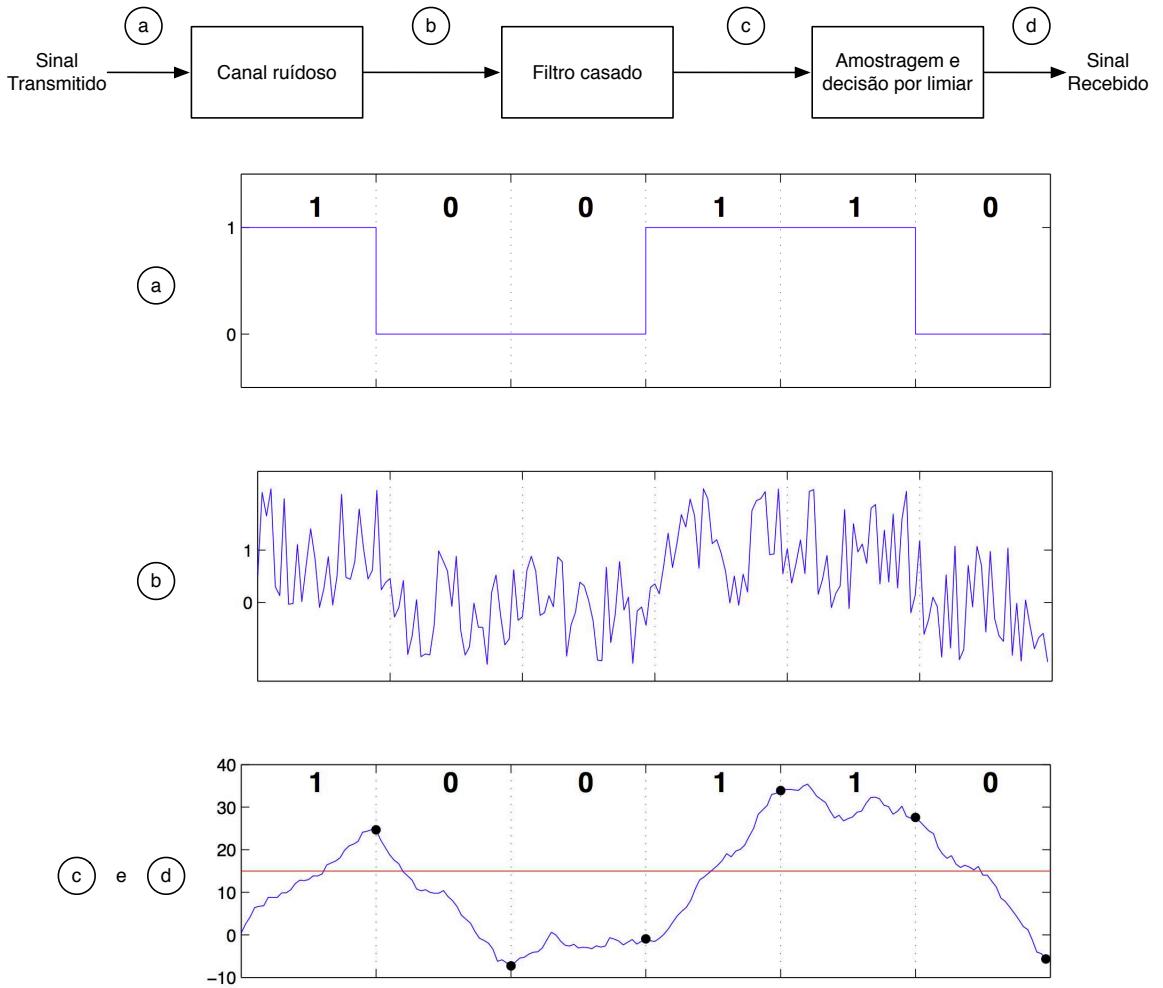


Figura 3.2: Ilustração da detecção de pulsos em um sistema de comunicação binário usando filtros casados: (a) O sinal transmitido, (b) o sinal misturado ao ruído, (c) o sinal filtrado (em azul); amostragem (pontos em destaque) e o limiar de comparação (em vermelho).

essa mesma estratégia pode ser aplicada na decomposição de sinais EMG. Considerando-se que a forma de onda do disparo de uma unidade motora (UM) constitua um símbolo, talvez seja possível encontrar os disparos de uma dada UM em um sinal EMG usando um filtro casado.

Dessa forma, nas seções seguintes será apresentada uma revisão sobre filtros casados,

destacando suas características, e uma análise inicial da aplicabilidade dessa técnica na decomposição de sinais EMG.

3.1 Definição

O filtro casado é um sistema ótimo para detectar um sinal conhecido sob ruído gaussiano aditivo (35). Considerando a situação em que um sinal $x(t)$, composto por uma onda previamente conhecida e de duração finita no tempo $g(t)$, é contaminado com um ruído gaussiano branco aditivo $w(t)$, é possível modelar o sinal $x(t)$ segundo a Equação 3.1, onde T corresponde ao tempo de observação do sinal.

$$x(t) = g(t) + w(t), \quad 0 \leq t \leq T \quad (3.1)$$

Ao aplicar um filtro linear e invariante no tempo, cuja a resposta ao impulso é dada por $h(t)$, tem-se como resposta o sinal $y(t)$ dado pela Equação 3.2. Os termos $g_0(t)$ e $n(t)$ correspondem, respectivamente, à convolução das componentes do sinal $g(t)$ e $w(t)$ por $h(t)$:

$$y(t) = g_0(t) + n(t) \quad (3.2)$$

Dessa forma, é desejado definir um filtro cuja a função de transferência maximize a relação sinal-ruído na saída em um determinado instante de tempo T . A relação sinal-ruído (η) nessa situação é dada pela Equação 3.3 onde $|g_0(T)|^2$ corresponde à potência instantânea do sinal de saída relacionado a $g(t)$, E é o operador esperança e $E[n^2(t)]$ equivale à potência média do ruído.

$$\eta = \frac{|g_0(T)|^2}{E[n^2(t)]} \quad (3.3)$$

Sendo $G(f)$ a transformada de Fourier de $g(t)$, e $H(f)$ a resposta em frequência do

filtro, então $g_0(t)$ corresponde à transformada inversa de Fourier da multiplicação de $H(f)$ e $G(f)$ (Equação 3.4).

$$g_0(t) = \int_{-\infty}^{\infty} H(f)G(f)e^{j2\pi ft}df \quad (3.4)$$

Dessa forma, quando a saída de $g_0(t)$ é amostrada no tempo T e na ausência do ruído, tem-se a potência instantânea do sinal, segundo a Equação 3.5.

$$|g_0(T)|^2 = \left| \int_{-\infty}^{\infty} H(f)G(f)e^{j2\pi fT}df \right|^2 \quad (3.5)$$

Levando em conta apenas o efeito do filtro sobre o ruído ($w(t)$), a densidade espectral de potência ($S_N(f)$) do ruído de saída ($n(t)$) é igual a densidade espectral de potência do ruído de entrada ($N_0/2$) multiplicado pelo quadrado do módulo da resposta em frequência do filtro $H(f)$ (Equação 3.6).

$$S_N(f) = \frac{N_0}{2} |H(f)|^2 \quad (3.6)$$

Substituindo as equações 3.5 e 3.6 na equação 3.3, obtém-se:

$$\eta = \frac{\left| \int_{-\infty}^{\infty} H(f)G(f)e^{j2\pi fT}df \right|^2}{\frac{N_0}{2} |H(f)|^2} \quad (3.7)$$

Segundo a desigualdade de Schwarz, pode-se dizer que dado duas funções complexas (ϕ_1 e ϕ_2) da variável real x que satisfazem as seguintes condições:

$$\int_{-\infty}^{\infty} |\phi_1(x)|^2 dx < \infty \quad (3.8)$$

e

$$\int_{-\infty}^{\infty} |\phi_2(x)|^2 dx < \infty \quad (3.9)$$

tem-se:

$$\left| \int_{-\infty}^{\infty} \phi_1(x)\phi_2(x)dx \right|^2 \leq \int_{-\infty}^{\infty} |\phi_1(x)|^2 dx \int_{-\infty}^{\infty} |\phi_2(x)|^2 dx \quad (3.10)$$

A desigualdade da Equação 3.10 persiste se, e somente se:

$$\phi_1(x) = k\phi_2^*(x) \quad (3.11)$$

onde k é uma constante real e o asterisco corresponde ao conjugado complexo.

Retornado ao problema, pode-se aplicar a desigualdade de Schwarz, e definir $\phi_1(x) = H(f)$ e $\phi_2(x) = G(f)e^{j2\pi fT}$. Dessa forma, podemos reescrever a Equação 3.7 como:

$$\eta \leq \frac{2}{N_0} \int_{-\infty}^{\infty} |G(f)|^2 df \quad (3.12)$$

Ao observar a Equação 3.12, percebe-se que o lado direito dessa relação não depende da resposta em frequência do filtro ($H(f)$), mas somente da energia do sinal e da densidade espectral de potência do ruído. Consequentemente, a relação sinal-ruído de pico de pulso será máximo quando $H(f)$ for escolhido de modo que a igualdade da Equação 3.12 persista, ou seja:

$$\eta_{max} = \frac{2}{N_0} \int_{-\infty}^{\infty} |G(f)|^2 df \quad (3.13)$$

Para que isso ocorra, deve-se escolher um valor ótimo de $H(f)$. Para encontrar esse valor, será utilizada a Equação 3.11, a qual, no contexto atual, produz:

$$H_{otm}(f) = kG^*(f)e^{j2\pi fT} \quad (3.14)$$

Para encontrar a resposta ao impulso desse filtro ótimo, calcula-se a transformada inversa de Fourier, conforme a Equação:

$$h_{otm}(t) = k \int_{-\infty}^{\infty} G^*(f)e^{-j2\pi f(T-t)} df \quad (3.15)$$

Se $g(t)$ for um sinal real, pode-se escrever que $G^*(f) = G(-f)$, dessa forma pode-se reescrever a Equação 3.15 como:

$$\begin{aligned}
h_{otm}(t) &= k \int_{-\infty}^{\infty} G(-f) e^{-j2\pi f(T-t)} df \\
&= k \int_{-\infty}^{\infty} G(f) e^{j2\pi f(T-t)} df \\
&= kg(T-t)
\end{aligned} \tag{3.16}$$

Portanto, segundo a equação 3.16, um filtro casado possui resposta ao impulso proporcional ao sinal de entrada ($g(t)$), invertido e deslocado no tempo. A Figura 3.3 ilustra como pode ser obtida a resposta ao impulso de um filtro casado para uma dada forma de onda, primeiro invertendo a forma de onda no tempo (Figura 3.3b) e depois aplicando um deslocamento e um ganho (k) ao sinal (Figura 3.3c).

A resposta ao impulso pode ser utilizada para filtrar um sinal. Ao realizar a convolução de um sinal de entrada com a resposta ao impulso de um sistema linear invariante no tempo, obtém-se a saída do sistema. Essa operação é bastante simples de ser feita em sistemas de processamento digital (56), de forma que um filtro casado é basicamente um filtro de resposta ao impulso finita (*Finite impulse response - FIR*), cujos coeficientes correspondem às amostras do sinal $g(t)$ invertidas no tempo e multiplicadas por um fator de escala (k).

3.2 Características e propriedades

Para continuar a análise dos filtros casados, é preciso mencionar algumas características e propriedades relativas à sua aplicação. O primeiro passo nesse sentido é entender o significado da saída de um filtro casado. Como descrito, um filtro casado é um sistema ótimo para detectar um sinal conhecido sob ruído gaussiano aditivo (35); para se obter a resposta em frequência de um filtro casado, procurou-se determinar um sistema que maximiza a relação sinal-ruído de uma mistura de um sinal conhecido com um ruído gaussiano. Com essas duas questões em mente, é possível supor indevidamente que um filtro casado é utilizado para eliminar o ruído. Porém, o que se obtém de um filtro casado

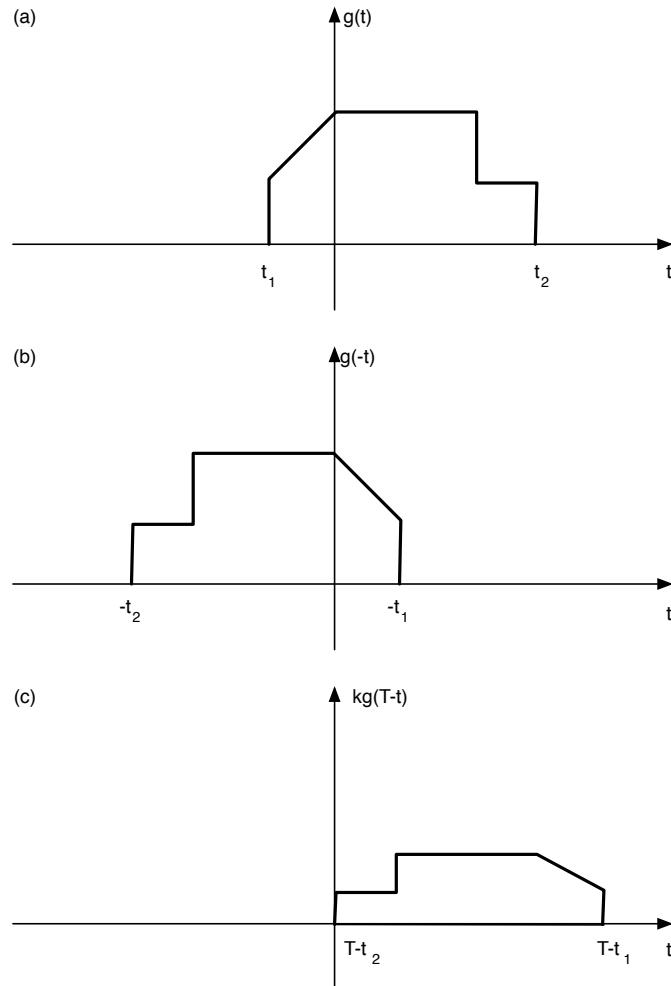


Figura 3.3: Método para obtenção da resposta ao impulso de um filtro casado. (a) A forma de onda do sinal que irá ser utilizada para gerar o filtro. (b) O sinal invertido no tempo. (c) A resposta ao impulso de um dos possíveis filtros casados.

é um sistema cuja a saída maximiza a relação sinal-ruído em um dado instante (T). Dessa forma, a saída de um filtro casado é, de certa forma, proporcional à relação sinal-ruído da entrada.

Caso o sinal associado ao filtro casado não esteja presente, a relação sinal-ruído é baixa e a saída do filtro corresponde a um ruído de baixa amplitude. Porém, se existir, a relação sinal-ruído aumenta até atingir um máximo, ou seja, a saída do filtro irá aumentar

e gerar um pico. A detecção desses picos na saída do filtro permite detectar a presença de um determinado sinal previamente conhecido.

Pela definição, a saída de um filtro casado para um sinal de entrada $x(t)$, onde $x(t)$ é composto pela forma de onda conhecida $g(t)$ e por um ruído gaussiano (Equação 3.1), pode ser descrita como sendo a convolução desse sinal com a resposta ao impulso $h(t)$ do conjugado complexo do sinal $g(t)$ multiplicado por uma constante k . Nesse sentido, tem-se:

$$y(t) = x(t) \otimes h(t) = \int_{-\infty}^{\infty} x(\tau)h(t - \tau)d\tau = \int_{-\infty}^{\infty} x(\tau)kg^*[T - (t - \tau)]d\tau \quad (3.17)$$

onde \otimes representa a convolução.

Se considerarmos o caso especial onde $k = 1$ e $T = 0$ podemos simplificar a Equação 3.17 como:

$$y(t) = \int_{-\infty}^{\infty} x(\tau)g^*(\tau - t)d\tau \quad (3.18)$$

A Equação 3.18 corresponde à correlação cruzada do sinal $x(t)$ com $g(t)$. Ou seja, a Equação 3.18 nos diz que a saída de um filtro casado está relacionada com a correlação cruzada do sinal de entrada e o sinal que originou o filtro (34, p 27). Se considerarmos que a correlação cruzada é uma ferramenta que permite detectar a similaridade entre duas formas de onda, podemos inferir que um filtro casado é um sistema cuja a saída mede o grau de similaridade entre duas formas de onda.

Outra característica importante pode ser observada a partir da Equação 3.13, que define a relação sinal-ruído. O teorema de Rayleigh define que a energia de um sinal $g(t)$ é dada por:

$$E = \int_{-\infty}^{\infty} |g(t)|^2 dt = \int_{-\infty}^{\infty} |G(f)|^2 df \quad (3.19)$$

então, substituindo a Equação 3.19 na Equação 3.12, tem-se que a relação sinal-ruído

máxima é dada por

$$\eta_{max} = \frac{2E}{N_0} \quad (3.20)$$

onde E corresponde a energia do sinal que originou o filtro casado.

A Equação 3.20 indica o valor máximo da saída de um filtro casado e mostra que a relação sinal-ruído de pico do pulso de um filtro casado depende somente da relação da energia do sinal pela densidade espectral de potência do ruído branco na entrada do filtro (35). É interessante observar que não existe nenhum tipo de dependência da forma de onda, duração e largura do espectro do sinal de entrada (55), o que pode auxiliar na aplicação da detecção de PAUMs, já que as várias unidades motoras apresentam formas de onda diferentes.

3.3 Exemplos de aplicação de filtros casados

O exemplo a seguir é apresentado para demonstrar as ideias previamente discutidas através da aplicação de um filtro casado para um sinal bem simples. O filtro casado será construído tendo como base um pulso retangular de largura T apresentado na Figura 3.4a. A resposta ao impulso do filtro ($h(t)$) casado é mostrada na Figura 3.4b.

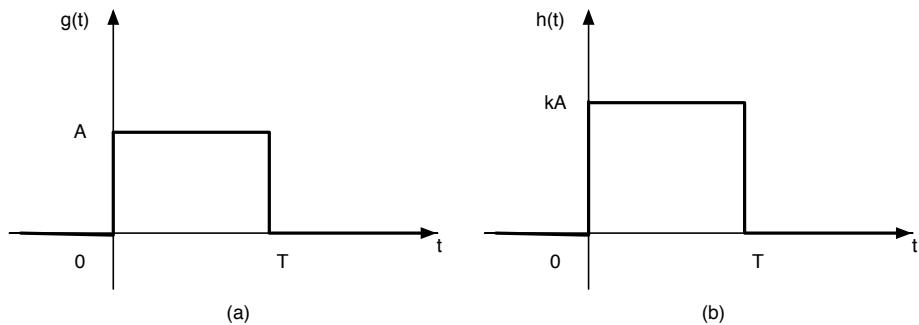


Figura 3.4: Pulso retangular ($g(t)$) e a resposta ao impulso ($h(t)$) do filtro casado correspondente.

Se considerarmos apenas o sinal $g(t)$ sendo aplicado ao filtro construído, é possível

obter a saída deste através da convolução entre $g(t)$ e $h(t)$. Dessa forma, a saída do filtro se comporta como mostrado na Figura 3.5.

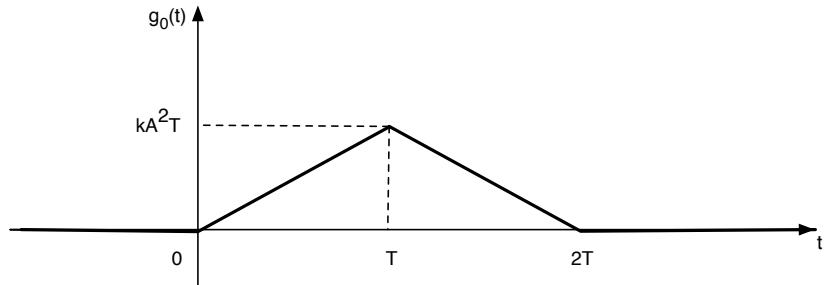


Figura 3.5: Saída do filtro casado, tendo como entrada apenas o sinal $g(t)$.

Observe que, nesse caso, a energia do sinal $g(t)$ é dada por

$$E = \int_{-\infty}^{\infty} |g(t)|^2 dt = \int_0^T A^2 dt = A^2 T \quad (3.21)$$

então, o valor de pico da saída do filtro referente ao sinal $g(t)$ é:

$$g_0(T) = kA^2 T = kE \quad (3.22)$$

Para determinar a relação sinal-ruído no instante T , é necessário obter primeiro a média quadrática do ruído, dada por

$$\overline{n_0^2} = \frac{N_0}{2} \int_{-\infty}^{\infty} |H(f)|^2 df = \frac{N_0}{2} \int_{-\infty}^{\infty} |h(t)|^2 dt = \frac{N_0}{2} \int_0^T |kA|^2 dt = \frac{N_0}{2} k^2 A^2 T \quad (3.23)$$

Assim, a relação sinal-ruído no instante T é

$$\eta = \frac{g_0^2(T)}{\overline{n_0^2}} = \frac{(kA^2 T^2)^2}{(N_0/2) k^2 A^2 T} = \frac{2A^2 T}{N_0} = \frac{2E}{N_0} \quad (3.24)$$

Este resultado confirma o que foi descrito anteriormente sobre o valor máximo da relação sinal-ruído.

A Figura 3.6 apresenta uma simulação do processo de detecção de um pulso retangular em um sistema digital. O pulso em questão tem amplitude unitária e tem a largura de 200 amostras em um sinal de 2000 amostras (Figura 3.6a). Foi sintetizado um segundo

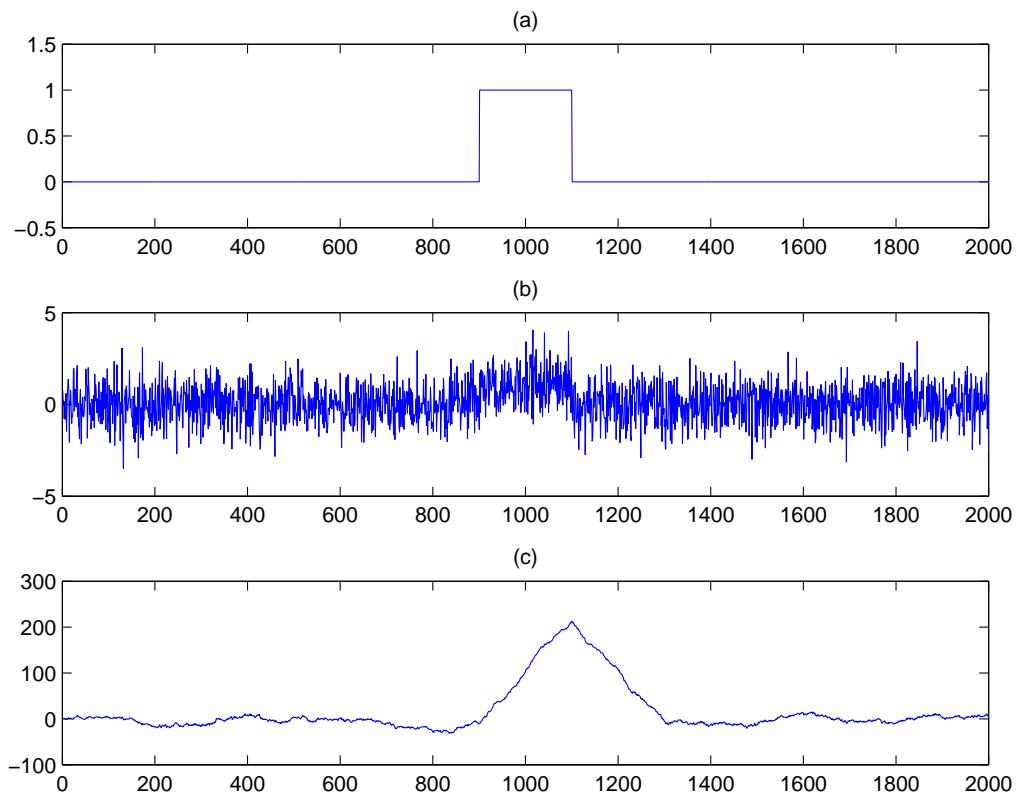


Figura 3.6: (a) Pulso retangular. (b) Pulso adicionado de um ruído branco. (c) Saída do filtro casado.

sinal, adicionando-se um ruído branco (Figura 3.6b) e calculada a saída do filtro casado correspondente (Figura 3.6).

Observe que tem-se a presença de um sinal semelhante ao encontrado na Figura 3.5. É evidente que a onda apresenta algum ruído, porém ainda é possível identificar um máximo na amostra de número 1100 que corresponde ao tempo T que está associado ao momento do término do pulso. Ou seja, através da procura desses máximos é possível detectar não só a presença do pulso como estimar o momento de sua ocorrência.

3.4 Considerações iniciais sobre a aplicação de filtros casados na detecção e classificação de sinais EMG

No processo de formação de um sinal EMG, um trem de PAUMs (TPAUM) pode ser modelado na forma um conjunto de pulsos que se repete. O sinal EMG é formado a partir do somatório de vários TPAUMs e dos ruídos de artefatos inerentes à coleta desses sinais. Dessa forma, caso seja conhecido um dos pulsos do TPAUM, este pode ser utilizado na construção de um filtro casado capaz de detectar os demais disparos da unidade motora presentes no sinal EMG.

PAUMs são sinais de duração finita, requisito básico da aplicação de filtros casados. Além disso, uma característica importante dos filtros casados é a independência da forma de onda do sinal que o origina. Ou seja, não importa a forma de onda do PAUM gerado pela unidade motora. Ainda assim, será possível criar um filtro específico para detectar os outros disparos produzidos pela UM.

Um banco de filtros casados, onde cada filtro é construído de forma a detectar a presença dos disparos oriundos de uma unidade motora, pode fornecer a base para a implementação de uma metodologia para detecção e classificação de disparos de unidades motoras em sinais EMG (Figura 3.7).

Em sistemas digitais, a implementação de um filtro casado equivale a implementação de um filtro digital do tipo FIR. Essa implementação pode ser feita facilmente em *software*. Para se obter um sistema em tempo-real, esse software pode utilizar de recursos especiais dos processadores atuais a fim de reduzir o tempo de processamento.

Um fator que pode dificultar a aplicação dos filtros casados nesse problema é a falta de controle que se tem sobre a forma de onda utilizada. Em sistemas de comunicação digital e radar, o projetista do sistema é quem define a forma de onda sinal transmitido ($g(t)$). Já na aplicação em sinais EMG, essa forma é previamente definida de acordo com a constituição anatômica do indivíduo e não pode ser manipulada. Inclusive, essa forma de

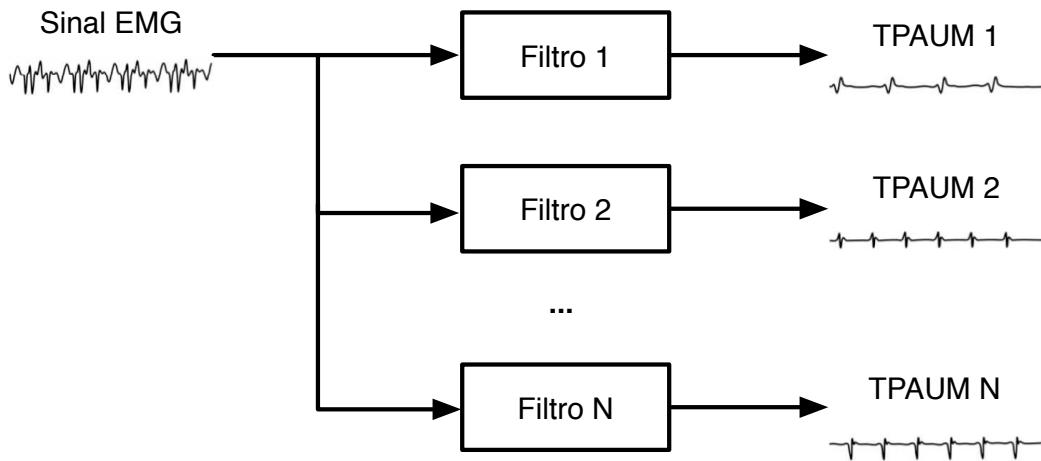


Figura 3.7: Possível metodologia para aplicação de filtros casados para detecção e classificação de PAUMs em sinais EMG.

onda é inicialmente desconhecida; porém, como destacado no capítulo a seguir, proposta alternativa para esse problema é apresentada.

É preciso entender também o efeito da aplicação dos filtros casados na presença de PAUMs de unidades motoras que não originaram o filtro e de sobreposições de PAUMs. Como situações semelhantes também ocorrem em sistemas de comunicação digital com vários símbolos, pretende-se através das soluções desses sistemas resolver o problema em questão.

Com isso, é esperado que filtros casados possam ser utilizados para fornecer um mecanismo de detecção e classificação de PAUMs em sinais EMG de forma rápida e eficiente, mesmo na presença de níveis significativos de artefatos.

Capítulo 4

Proposta

Sistemas de decomposição de sinais EMG são ferramentas importantes para análise da atividade muscular. Os resultados da decomposição de um sinal EMG podem ser utilizados no auxílio ao diagnóstico, tratamento e estudo aprofundado de disfunções neuromusculares do ponto de vista funcional. Além disso, informações sobre o controle dos músculos esqueléticos e os efeitos de doenças, envelhecimento e fadiga sobre este podem ser obtidos através da técnica (11).

Por muito tempo, a aplicação clínica de sistemas de decomposição de sinais EMG foi bastante restrita, principalmente devido ao tempo de processamento necessário para realizar a decomposição dos sinais. Nas últimas décadas, diversas técnicas foram propostas melhorando o desempenho em termos de precisão de detecção e tempo de processamento.

Ainda assim, existem poucas aplicações da técnica em tempo real e em sistemas embarcados. Sistemas capazes de detectar e classificar em tempo real os disparos das unidades motoras a partir do sinal EMG podem permitir o desenvolvimento de novos tratamentos de neuropatias e miopatias baseados em *biofeedback*, fornecer novos mecanismos para controle de próteses, dentre outras aplicações.

Como já mencionado, filtros casados são utilizados há bastante tempo em aplicações de engenharia, como radar, sistemas de comunicação. Em sistemas de comunicação, existem

receptores que realizam a detecção de símbolos transmitidos por canais ruidosos em tempo real. Nestes receptores, cada símbolo é transmitido na forma de um sinal finito no tempo, o que se assemelha com as características típicas de um disparo de uma unidade motora em um sinal EMG.

4.1 Detecção de PAUMs usando filtros casados

Segundo Turin(55), uma das aplicações dos filtros casados consiste na detecção da presença de um pulso conhecido misturado a um ruído branco (Figura 4.1). Neste caso, um sinal $x(t)$, composto pela adição de um pulso de duração finita conhecido $s(t)$ a um ruído branco $n(t)$, passa por um filtro $h(t)$ cuja a resposta pode ocorrer de duas formas. No caso do sinal $x(t)$ possuir apenas a componente de ruído, temos uma situação onde a resposta do filtro é mínima (Figura 4.1a). Caso o sinal $x(t)$ contenha uma mistura do pulso $s(t)$ com o ruído $n(t)$, a saída do filtro apresenta um pico no instante de detecção t_0 (Figura 4.1b).

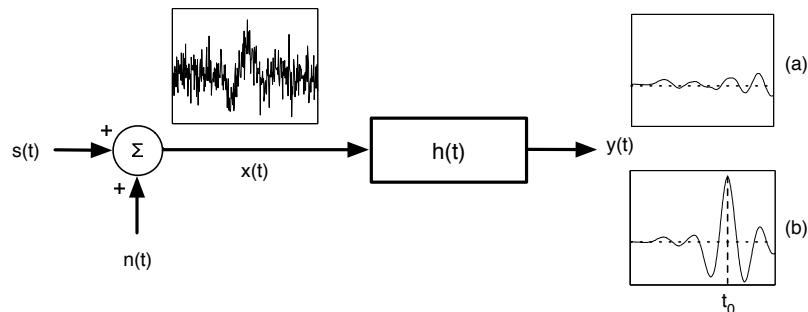


Figura 4.1: Diagrama de blocos de um detector baseado em filtros casados. A saída (a) ocorre quando é aplicado um sinal $x(t)$ formado apenas pelo ruído $n(t)$. A saída (b) ocorre quando a um sinal $x(t)$, composto pela soma do pulso $s(t)$ com o ruído $n(t)$, é aplicado na entrada do filtro.

Stashuk(11) apresenta um modelo matemático para trem de PAUMs de uma unidade motora, onde :

$$MAUPT_j(t) = \sum_{k=1}^{Mj} MUAP_{jk}(t - \delta_{jk}) \quad (4.1)$$

$MAUPT_j(t)$ corresponde ao trem de PAUMs da j-ésima unidade motora; $MUAP_{jk}(t)$ corresponde à forma de onda do k-ésimo disparo da unidade motora; M_j corresponde ao número de disparos que a unidade motora gerou e δ_{jk} o momento do disparo dessa unidade. É interessante observar que cada disparo da unidade motora em estado normal é único, porém retém características de forma semelhantes aos demais disparos.

Ainda segundo Stashuk(11), o sinal EMG resultante pode ser modelado segundo a Equação 4.2.

$$EMG(t) = \sum_{j=1}^{N_m} MUAPT_j(t) + n(t) \quad (4.2)$$

Onde $MUAPT_j(t)$ é j-ésimo trem de PAUMs; N_m equivale ao número de unidades motoras ativas; $n(t)$ equivale ao ruído presente no sinal.

Dessa forma, supondo que seja captado um sinal EMG $x(t)$ constituído pelos disparos de apenas uma unidade motora, este sinal seria dado pela Equação 4.3.

$$EMG(t) = MUAPT_1(t) + n(t) \quad (4.3)$$

Supondo ainda, que seja conhecida a forma de onda média dos disparos da unidade motora em questão $s(t)$, é possível definir um filtro casado cuja a resposta ao impulso $h(t)$ é dada pela equação:

$$h(t) = k \cdot s(T - t) \quad (4.4)$$

Onde k e T são constantes e podem ser definidas de forma arbitrária. Tal filtro pode ser utilizado para detectar os disparos das unidades motoras de forma equivalente ao apresentado na Figura 4.1.

A Figura 4.2 ilustra um exemplo onde a resposta ao impulso de um filtro casado foi obtida a partir de um disparo de uma unidade motora. Neste caso foi definido que $k = 1$ e que T seja equivalente à duração do pulso da unidade motora (≈ 10 ms). Dessa forma, a resposta ao impulso do filtro equivale à inversão no tempo da forma de onda da unidade motora $g(t)$ deslocada de T .

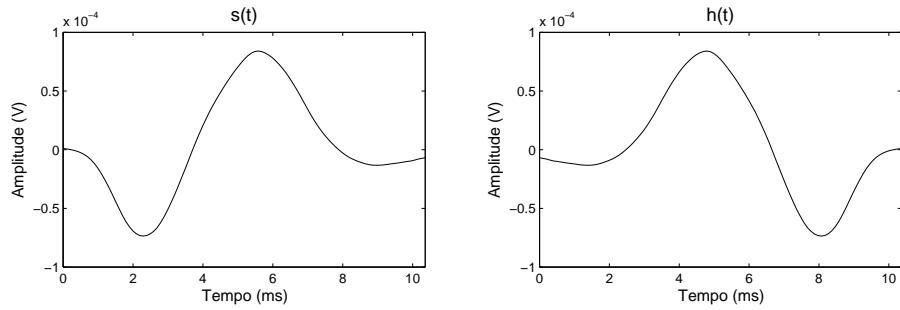


Figura 4.2: Forma de onda do disparo de uma unidade motora $g(t)$ e a resposta ao impulso de um filtro casado associado à mesma $h(t)$.

Por fim, podemos definir a resposta de um filtro casado, para um dado sinal $x(t)$, como a convolução no tempo entre o sinal e a resposta ao impulso do filtro $h(t)$ (Equação 4.5).

$$y(t) = \int_{-\infty}^{\infty} x(\tau)h(t - \tau)d\tau \quad (4.5)$$

A Figura 4.3 apresenta um exemplo de resposta de um filtro casado $h(t)$ para um sinal EMG. O sinal (Figura 4.3a) foi gerado pelo simulador proposto por Andrade(57) e tem uma relação sinal ruído de 200dB e apenas uma unidade motora. A resposta ao impulso do filtro foi obtida a partir do primeiro disparo da unidade motora. A resposta do filtro, apresentada na Figura 4.3b, também destaca os máximos locais encontrados na saída do filtro. Os instantes de ocorrência desses máximos foram utilizados como referência para marcação das linhas verticais na Figura 4.3a. Como pode ser observado, os máximos locais da saída do filtro podem ser utilizados para determinar o instante de tempo onde cessa o disparo da unidade motora.

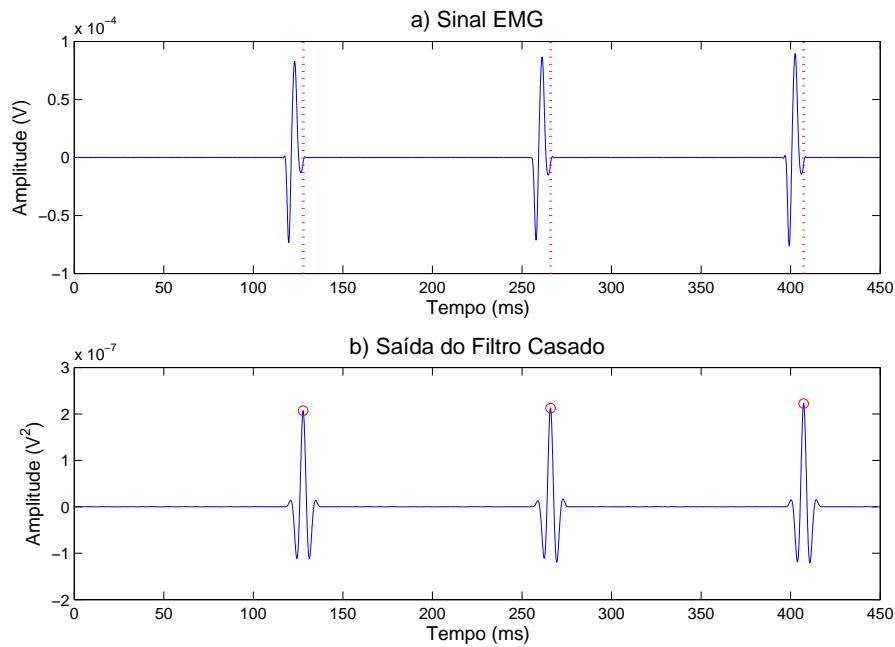


Figura 4.3: Exemplo de aplicação de um filtro casado em um sinal EMG com apenas uma unidade motora.

4.2 Classificação de PAUMs usando filtros casados

Outra aplicação importante para filtros casados consiste na classificação de pulsos transmitidos. Um exemplo dessa aplicação são os receptores M-ários utilizados em sistemas de comunicação para a classificação de símbolos recebidos, onde cada símbolo corresponde a uma forma de onda diferente. Nestes sistemas, os símbolos são transmitidos por um canal ruidoso e, no receptor, a classificação é realizada através dos filtros casados como mostrado no diagrama de blocos da Figura 4.4.

No receptor da Figura 4.4 cada filtro $h_i(t)$ é construído a partir da forma de onda de um dos símbolos transmitidos (Equação 4.4). O sinal recebido $r(t)$ é aplicado a todos os filtros e amostrado no instante T_M , quando a saída dos filtros é máxima. Aos valores amostrados são acrescidos do valor de *bias* a_i e uma comparação entre os valores é realizada. A decisão sobre qual símbolo foi recebido é tomada em favor do maior valor de b_i detectado pelo

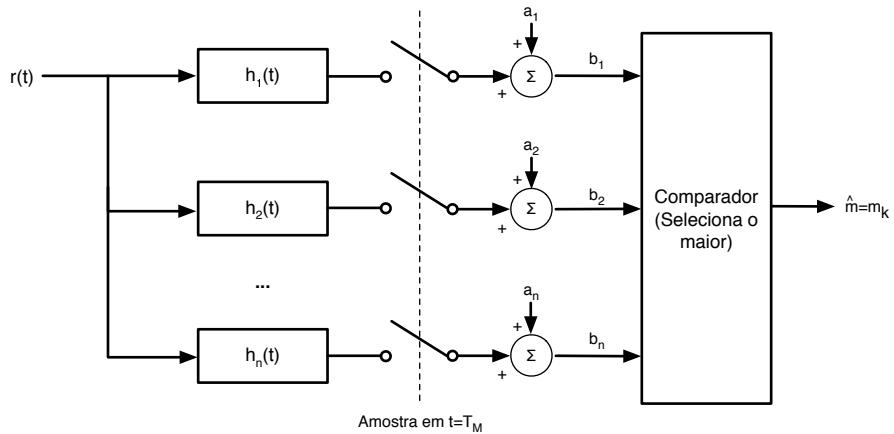


Figura 4.4: Diagrama de blocos de um receptor M-ário.

comparador.

O valor de *bias* é definido pela Equação 4.6 (58), onde N_0 corresponde ao valor constante que define o espectro do ruído branco, $P(m_i)$ a probabilidade de ocorrência do pulso do filtro no sinal e E_i a energia do pulso que foi utilizado na construção do filtro.

$$a_i = \frac{1}{2}[N_0 \ln P(m_i) - E_i] \quad (4.6)$$

Para casos onde a probabilidade de ocorrência dos pulsos é igual, o termo $N_0 \ln P(m_i)$ passa a ser o mesmo para todos os símbolos. Como está se fazendo uma seleção a partir do maior termo pode-se, nesse caso, simplificar a Equação 4.6, obtendo:

$$a_i = -\frac{E_i}{2} \quad (4.7)$$

Em sistemas de comunicação, onde as formas de ondas dos símbolos são definidas pelo projetista do sistema, o instante de amostragem pode ser facilmente definido. Geralmente, todos os pulsos possuem a mesma duração e os filtros são construídos com deslocamento T (Equação 4.4) igual à duração do pulso. Assim, o instante T_M equivale à duração do pulso de origem.

Para aplicar esse mesmo mecanismo para detecção de PAUMs em um sinal EMG deve-se observar que os pulsos que definem a forma dos disparos das unidades motoras possuem durações diferentes. Dessa forma, os máximos dos filtros não irão ocorrer no mesmo instante, impedindo o uso do amostrador. Isso pode ser percebido ao analisar as saídas b_i de forma contínua, aplicando um sinal EMG na entrada. Para exemplificar tal situação, um sinal composto por três unidades motoras ativas foi simulado e aplicado a uma conjunto de filtros casados e os sinais b_i capturados conforme a Figura 4.5. Foi assumido que todas as unidades motoras possuem a mesma probabilidade de disparo, de forma que o valor de *bias* a_i foi definido segundo a Equação 4.7.

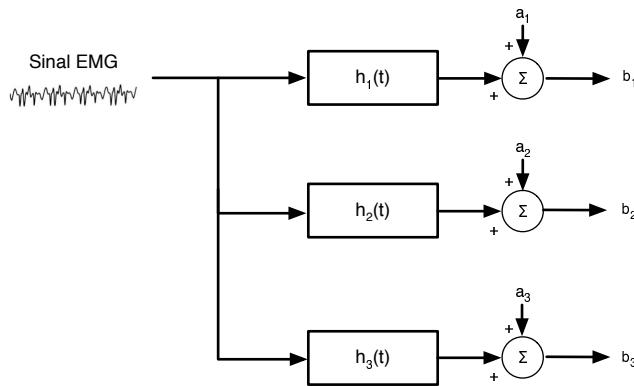


Figura 4.5: Diagrama de blocos de um banco de filtros casados aplicados a sinais EMG.

A Figura 4.6a apresenta um exemplo de saída nesse caso. Nela é apresentada uma pequena janela do sinal EMG composto por três unidades motoras, onde é possível identificar três disparos em sequência sem a ocorrência de sobreposição. Na Figura 4.6b, tem-se as saídas dos três filtros casados já subtraídos da metade da energia do sinal (sinais b_i da Figura 4.5). Através da Figura 4.6b, é possível observar que os três filtros respondem com um pico de amplitude para todas as unidades motoras. O momento de ocorrência do máximo dos três filtros não ocorre de forma alinhada, como previsto. É possível observar que, neste caso, o pico de saída do filtro correspondente à unidade motora do disparo é maior do que os demais picos que se encontram em uma janela próxima, no tempo, para os três sinais. Dessa forma, através dessa análise e baseando-se na ideia de classificação

dos receptores M-ários (Figura 4.4), tem-se indícios de que é possível identificar qual a unidade motora correspondente ao disparo.

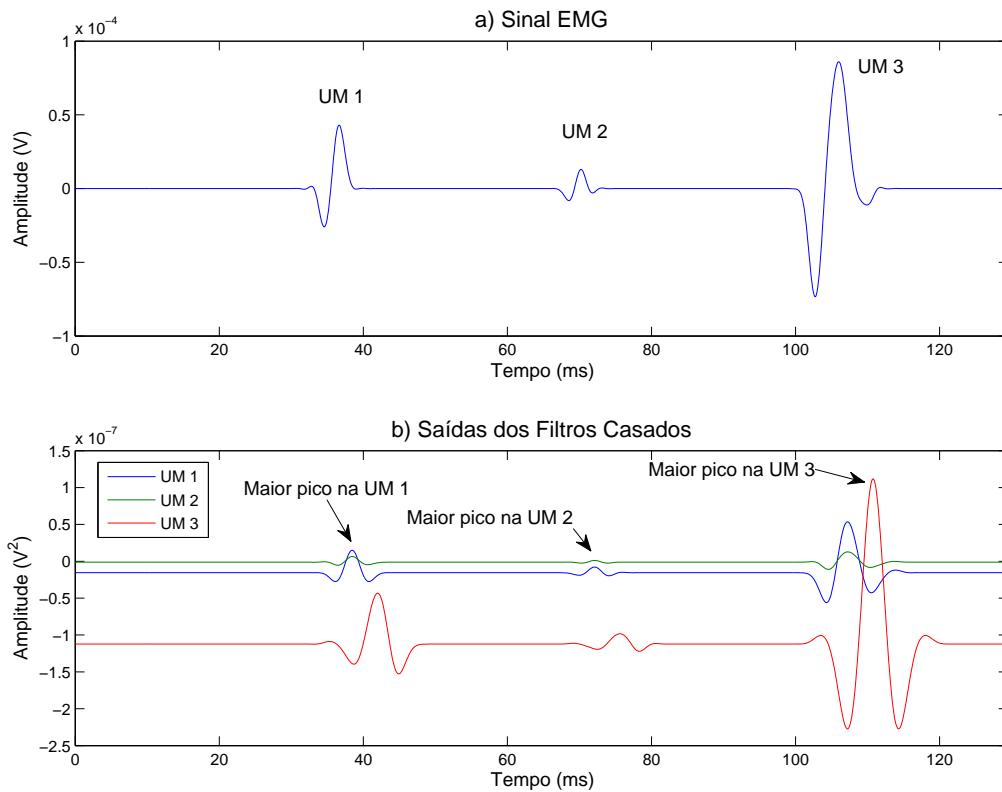


Figura 4.6: Exemplo de um sinal EMG composto por 3 unidades motoras aplicado a um banco com 3 filtros casados.

A partir dessa capacidade dos filtros casados para detectar e classificar pulsos de curta duração sob sinais adicionados a um ruído branco, são propostas dois métodos para detecção e classificação de disparos de UMs. As seções a seguir detalham os métodos propostos.

4.3 Método para detecção de PAUMs baseado em filtros casados (MD-FC)

Nas seções anteriores, discutiu-se que filtros casados são capazes de detectar e classificar pulsos com morfologia conhecida na presença de ruído branco. Essa situação assemelha-se ao modelo de um sinal EMG (Equações 4.1 e 4.2). Entretanto, algumas questões devem ser esclarecidas.

A primeira consiste na determinação da forma de onda das unidades motoras. Para determiná-las, é possível aplicar um sistema de decomposição de sinais EMG sobre uma amostra do sinal. Esse sinal pode ser coletado através de um protocolo específico, por exemplo, contração isométrica de curta duração. Através da decomposição, as formas de onda médias dos disparos de cada unidade motora são encontradas e utilizadas como parâmetro de entrada para o sistema de detecção e classificação.

Outra questão que deve ser tratada consiste no não alinhamento dos picos das saídas dos filtro (Figura 4.6). Nesse caso, o amostrador (Figura 4.4) deve ser removido do sistema e o comparador precisa analisar os máximos locais em um intervalo, comparando os picos que ocorrem em uma região próxima.

A partir dessas premissas, propõe-se a metodologia da Figura 4.7 para a detecção de disparos de unidades motoras contidos em sinais EMG.

Nesta metodologia, o sinal EMG é aplicado a um banco de filtros casados construídos a partir das formas de onda média dos disparos das unidades motoras e aplicado o nível de *bias* ($-E_i/2$), conforme exemplificado na seção anterior. Um detector de máximos locais é incluído na saída de cada filtro do banco para detectar os possíveis disparos das unidades motoras.

A detecção dos máximos é realizada aplicando um filtro de média móvel de ordem 3 sobre o sinal para suavizar oscilações de alta frequência. Em seguida, são detectados apenas os picos positivos do sinal, ou seja, aqueles cuja a saída do filtro casado supera o

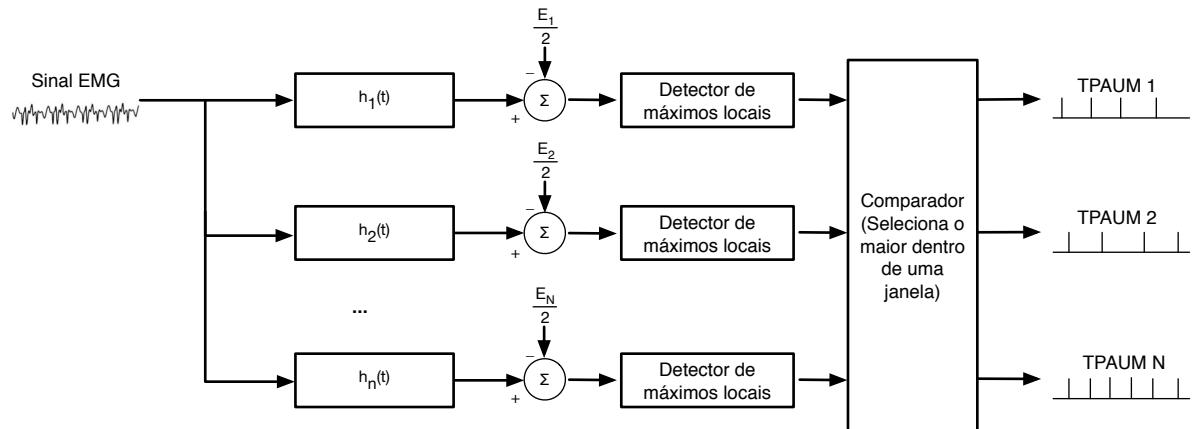


Figura 4.7: Método proposto de utilização de um banco de filtros para detecção e classificação de disparos de unidade motora.

nível de $bias -E_i/2$. Essa decisão visa evitar que picos de baixa amplitude, relacionados com a saída de sinais contendo apenas ruído fossem detectados, diminuindo a precisão do método.

O detector de máximos locais é importante, pois ele é quem define o momento do disparo da unidade motora. Porém sozinho, ele não é capaz de classificar qual a unidade motora efetuou o disparo; isto é realizado na etapa seguinte. Para entender melhor o processo de detecção, o exemplo da Figura 4.6 será retomado. A Figura 4.8 complementa aquele exemplo, exibindo o sinal de saída do detector de máximos locais (Figura 4.8c).

Pode-se observar pela Figura 4.8c que o detector de máximos locais define que existem dois possíveis disparos ocorrendo pouco antes de 40 ms. Isso ocorre, pois a saída dos filtros casados dessas duas unidades motoras apresentam picos positivos nessa região.

Para o segundo PAUM da Figura 4.8a, tem-se a detecção apenas do disparo da unidade motora 2. Apesar das saídas dos filtros da unidade motora 1 e 2 apresentarem um pico nessa região um disparo não é detectado, pois esses picos tem amplitude menor do que zero e são descartados da análise.

Por fim, tem-se com o terceiro PAUM a detecção das três unidades motoras como

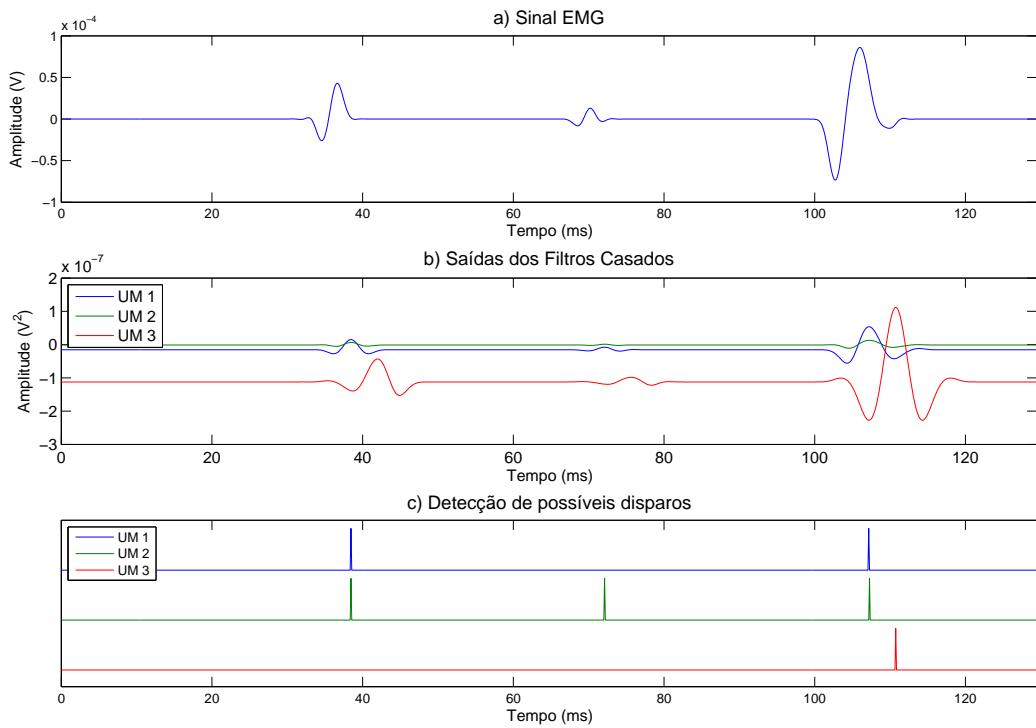


Figura 4.8: Exemplo da saída do detector de máximos locais.

possíveis candidatas entre 100 e 120 ms. Observe que, nesse caso, os três disparos detectados não estão alinhados. Dessa forma, a comparação para a classificação do disparo deve levar em conta essa questão.

A saída do detector de máximos locais é aplicada ao comparador que identifica qual a unidade motora efetuou o disparo. Para isso, o método analisa os possíveis disparos encontrados e verifica se, próximo a cada um deles, não existe um disparo de outra unidade motora com amplitude maior.

O processo de classificação é realizado em janelas de 50 ms. Esse intervalo foi definido por ser superior dobro da duração dos maiores PAUMs encontrados em sinais EMG (9). A janela de análise se desloca em intervalos de 25 ms e apenas o intervalo central (25 ms) da janela de 50 ms é utilizado na saída da análise, de forma a evitar inconsistências que

ocorrem próximas do início e do fim da janela. A Figura 4.9 ilustra o processo sobre uma pequena amostra. Nela, são definidas três janelas de 50 ms sobre o sinal EMG. A saída do classificador é destacada abaixo a partir de cada uma das janelas. Observe que elas são concatenadas sem nenhum tipo de sobreposição.

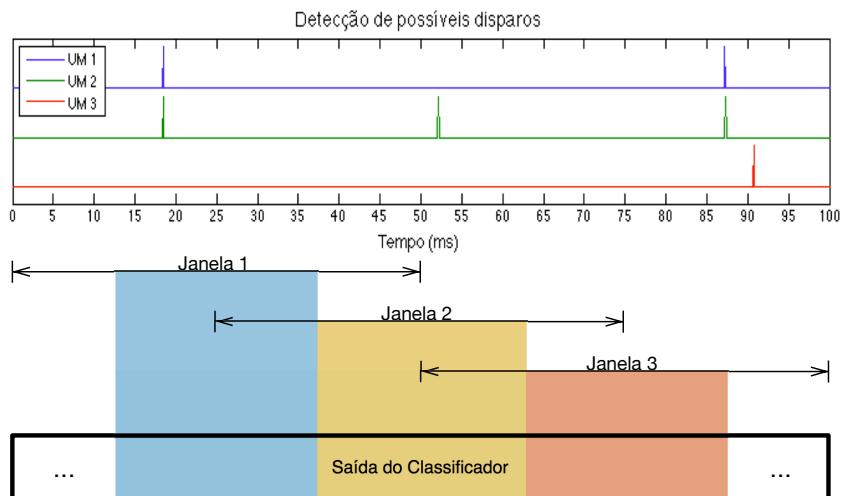


Figura 4.9: Exemplo do janelamento aplicado pelo classificador.

Para cada janela, são analisados os possíveis disparos encontrados pelo detector de máximos locais. Em cada disparo, é definida uma região de análise ao seu redor. Essa região tem o tamanho igual a duas vezes a duração do PAUM que originou o filtro da unidade motora e é centralizada no seu instante de disparo. É verificado então se existe outro disparo dentro dessa região no qual a amplitude seja maior do que a amplitude do disparo em análise. Caso exista um outro disparo de maior amplitude, esse disparo é descartado do processo. Caso contrário, o disparo é incluído na saída do classificador. O procedimento então prossegue, analisando os demais possíveis disparos.

A Figura 4.10 retoma o exemplo anterior, ilustrando o processo de classificação. Para esse exemplo, utilizou-se uma janela de 130 ms, diferente do que ocorre na metodologia proposta, para facilitar a compreensão. O classificador percorre as saídas dos detectores de pico de maneira simultânea para as unidades motoras 1 e 2, pouco antes de 40 ms após o início do sinal. São definidas janelas centralizadas em cada pico, com tamanho igual

ao dobro do comprimento da unidade motora equivalente ao sinal detectado. A análise é realizada para cada possível disparo. Dessa forma, o pico 1 é o primeiro a ser analisado (Figura 4.10b). A janela de análise desse pico é definida logo acima dele. Dentro dessa janela, observa-se a existência de um pico também para a UM 2. São comparadas as amplitudes dos dois picos e, nesse caso, a amplitude do pico 1 é maior do que a amplitude do pico 2, sendo registrado esse pico na saída (Figura 4.10c).

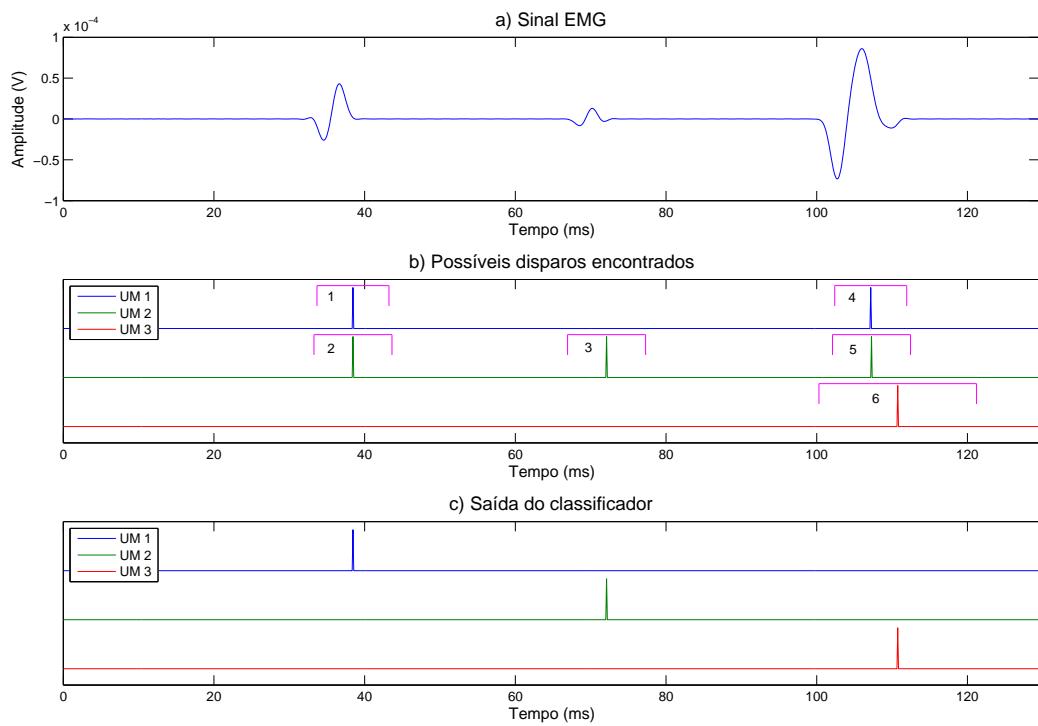


Figura 4.10: Exemplo de análise do classificador. Em (a) tem-se um destaque do disparo de maior duração no tempo e que define o tamanho da janela de análise. Em (b) tem-se a entrada do classificador e em (c) a saída. Foram destacados nos dois casos as janelas de análise utilizadas pelo classificador.

Destaca-se que, mesmo já tendo sido comparado com o pico 1, o pico 2 ainda não é descartado. Uma região de análise é definida a partir dele, na qual encontramos o pico 1 (Figura 4.10b). Novamente, como o pico 1 é maior do que o pico 2, este não é incluído

na saída (Figura 4.10c). Este procedimento, apesar de resultar em uma mesma resposta para as duas avaliações é importante, pois em alguns casos pode resolver determinados tipos de sobreposições.

Em seguida, o método passa a pesquisar os picos seguintes, localizando o pico 3 (Figura 4.10b). Como ele é o único existente dentro da região de análise, este é incluído na saída (Figura 4.10c).

Ao continuar a análise são encontrados os pico 4, 5 e 6 (Figura 4.10b). O procedimento é repetido para cada um deles, ao final, verifica-se que apenas o pico da unidade motora 3 é incluído na saída (Figura 4.10c).

4.4 Efeitos da sobreposição

Quando duas ou mais unidades motoras disparam ao mesmo tempo ou numa sucessão temporal próxima, o potencial detectado equivale ao somatório algébrico dos potenciais individuais destas unidades motoras e é denominado “sobreposição de PAUMs” (11).

Segundo Stashuk(11), existem três tipos de sobreposições:

1. **Parcial:** Esse tipo de sobreposição ocorre quando dois ou mais PAUMs são disparados em instantes de tempo próximos, onde os picos do sinal não se sobrepõem.
2. **Completa:** Dois ou mais PAUMs se sobrepõem de forma que seus picos ocorram em instantes de tempo muito próximos. Nesse caso, é gerado um pico de grande amplitude, em relação ao restante do sinal.
3. **Destrutiva:** O somatório dos PAUMs ocorre de tal forma que os picos encontram-se em fases opostas, podendo até se cancelarem ou gerando um potencial de baixa amplitude.

A Figura 4.11 ilustra os três casos descritos. Nos três casos, pode-se observar que a forma de onda difere dos padrões médios das unidades motoras originais que foram

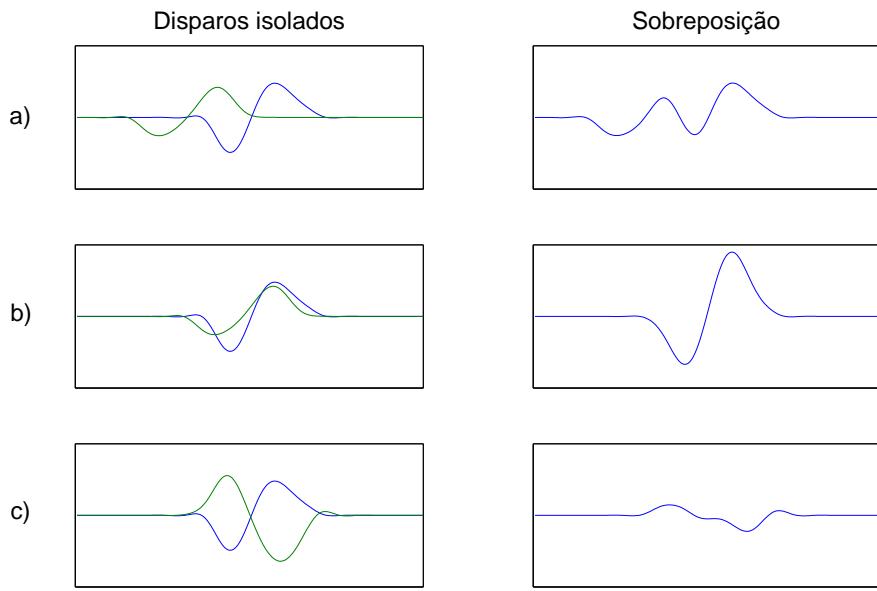


Figura 4.11: Exemplos de sobreposições. (a) Parcial, (b) completa e (c) destrutiva.

utilizados para construção do banco de filtros casados. No caso de sobreposições parciais, parte da forma de onda dos PAUMs é mantida. Em especial, as partes que definem o início e o fim da sobreposição. Dessa forma, é provável que o método proposto seja capaz de detectar pelo menos um dos disparos da sobreposição, nesse caso.

Tem-se também uma modificação significativa na forma de onda no caso de sobreposições completas. Entretanto, os efeitos se somam na maior parte do tempo, de forma que a energia dos PAUMs individuais continuam presentes na sobreposição. Como os filtros casados visam maximizar a saída de energia, é possível que, para essa situação, pelo menos um dos disparos possa ser encontrado.

No caso de sobreposições destrutivas, tem-se um problema maior, pois o sinal resultante geralmente apresenta uma energia menor que o sinal original. Esse é o tipo de sobreposição mais complexo de ser decomposto, pois os sinais apresentam baixa amplitude e grande deformação e, por consequência, o método proposto terá dificuldades em detectar e classificar esses disparos.

A Figura 4.12 ilustra as três situações descritas anteriormente. Um sinal EMG foi sintetizado com três unidades motoras distintas de forma que apresentasse apenas sobreposições. O primeiro potencial, até 20 ms, equivale a uma sobreposição parcial das unidades motoras 1 e 2. Os instantes onde ocorrem o término do disparo de cada unidade motora são marcados acima do sinal EMG com uma cruz. Os disparos detectados pelo MD-FC também foram representados acima do sinal com um círculo. Observa-se que, para essa sobreposição parcial, o MD-FC foi capaz de detectar o segundo disparo, correspondente a unidade motora 2.

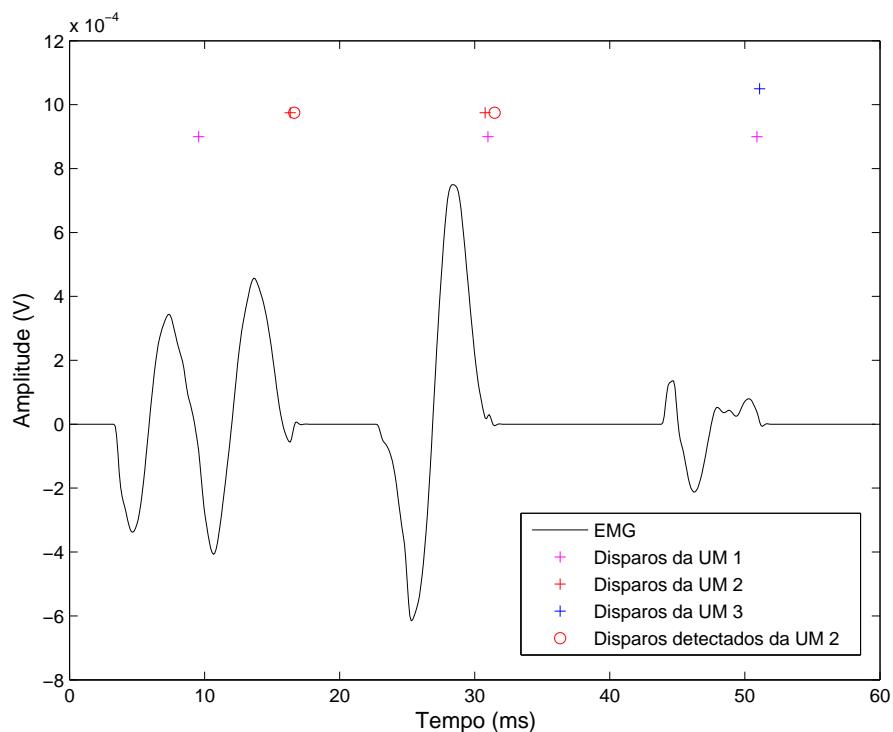


Figura 4.12: Exemplo de saída do MD-FC para os diversos tipos de sobreposição.

Entre 20 e 40 ms, o sinal EMG apresenta uma sobreposição completa. Ainda assim o método foi capaz de identificar com boa precisão o disparo da unidade motora 2, classificando-o corretamente. A terceira sobreposição, que ocorre entre 40 e 60 ms, é destrutiva. Nesse caso, o método não foi capaz de detectar nenhum dos dois disparos.

Pelo exemplo anterior, é possível verificar que o método MD-FC não é capaz de resolver adequadamente sobreposições de PAUMs, o que é também comum para a maior parte das técnicas encontradas na literatura. A própria estratégia de usar uma janela na classificação gera essa limitação, impedindo que o método resolva sobreposições muito próximas. Entretanto, o método ainda é capaz de, em boa parte casos, detectar corretamente pelo menos um dos disparos que constituem uma sobreposição. De posse dessa informação, pode ser possível melhorar o desempenho do método a partir da análise de resíduos. A próxima seção apresenta uma evolução do MD-FC com este aprimoramento.

4.5 Método aprimorado para detecção de PAUMs baseado em filtros casados (MAD-FC)

Para melhorar a capacidade de detecção dos disparos em meio a sobreposições de PAUMs, é proposto um segundo método baseado na análise do resíduo.

A Equação 4.8 modela uma janela do sinal EMG composta por uma sobreposição de PAUMs. Nessa equação, EMG_{Sob} equivale a forma de onda do sinal EMG dentro da janela que define a sobreposição, $MUAP_j(t)$ equivale ao pulso do disparo da j -ésima unidade motora, τ_j corresponde ao instante de disparo da unidade motora, N_m equivale ao número de unidades motoras que compõem a sobreposição e $n(t)$ corresponde ao ruído.

$$EMG_{Sob}(t) = \sum_{j=1}^{N_m} MUAP_j(t - \tau_j) + n(t) \quad (4.8)$$

Ao aplicar o método original (MD-FC) sobre uma sobreposição, observou-se que esse pode ser capaz de detectar um dos disparos das unidades motoras. Caso um dos disparos (disparo i) seja detectado, também é definido o seu instante de ocorrência (τ_i). Assumindo que a forma de onda do disparo i seja aproximadamente igual à forma de onda que gerou o coeficiente do filtro casado da i -ésima unidade motora, é possível reconstruir esse disparo $MUAP_i(t - \tau_i)$ de forma isolada por meio da seguinte equação:

$$MUAP_i(t - \tau_i) \approx h_i(T_i - t - \tau_i) \quad (4.9)$$

Onde $h_i(t)$ corresponde à resposta ao impulso do filtro casado que detectou o disparo, e T equivale a duração dessa resposta no tempo. Caso a onda obtida para Equação 4.9 seja subtraída do sinal EMG, tem-se o resíduo $R(t)$:

$$R(t) = \sum_{j=1}^{N_m} MUAP_j(t - \tau_j) + n(t) - h_i(T - t - \tau_i) \quad (4.10)$$

$$R(t) \approx \sum_{j=1, j \neq i}^{N_m} MUAP_j(t - \tau_j) + n(t) \quad (4.11)$$

Pode-se observar que Equação 4.11 equivale aproximadamente ao sinal EMG sem a componente da unidade motora detectada pelo método. Com isso, ao aplicar novamente o MD-FC sobre o resíduo, uma nova unidade motora pode ser detectada e o processo pode ser repetido até restar apenas o ruído.

A Figura 4.13 exemplifica graficamente o processo acima. Na Figura 4.13a, tem-se o processo de formação da sobreposição de duas unidades motoras. Note que não foi incluído o ruído nesse exemplo para facilitar a interpretação do processo. Supondo que, ao aplicar o MD-FC, seja detectado o disparo da unidade motora 2 e o sinal dessa unidade seja reconstruído e subtraído da sobreposição (Figura 4.13b), o resíduo passa a ser formado apenas pelo disparo da unidade motora 1. O processo de detecção MD-FC pode ser aplicado novamente, detectando o disparo da unidade motora 1. Ao calcular o novo resíduo, será encontrado apenas o ruído. Assim, o MD-FC não irá detectar mais nenhum disparo, encerrando o processo (Figura 4.13c).

Desta forma, a Figura 4.14 apresenta uma proposta de evolução da MD-FC visando aprimorar o mecanismo de detecção de disparos sobrepostos.

Na Figura 4.14, é possível identificar os mesmos elementos que definem o MD-FC. Estão presentes o banco de filtros casados, os detectores de máximos locais e o comparador que realiza a classificação dos disparos. Entretanto, a saída do classificador é utilizada

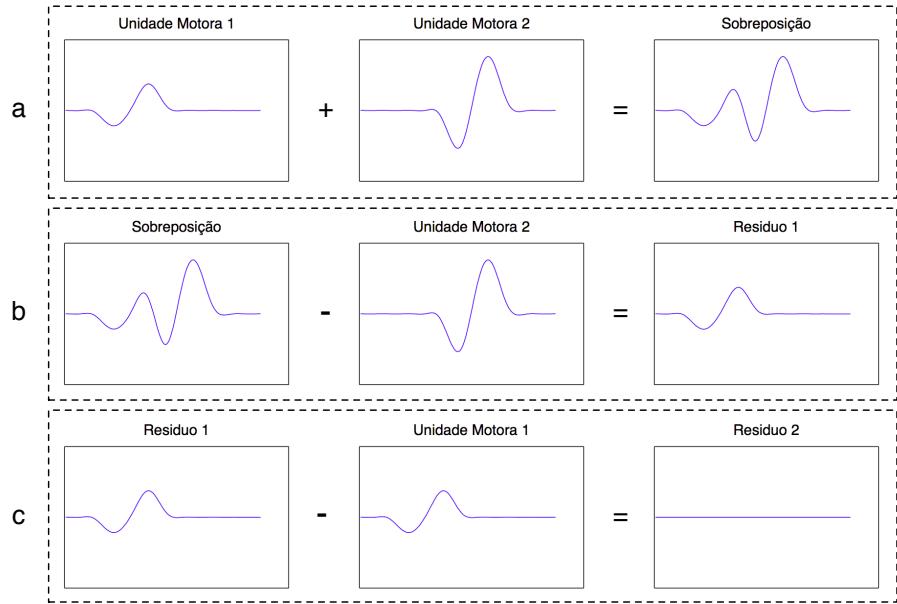


Figura 4.13: Exemplo de utilização do resíduo na resolução de sobreposições.

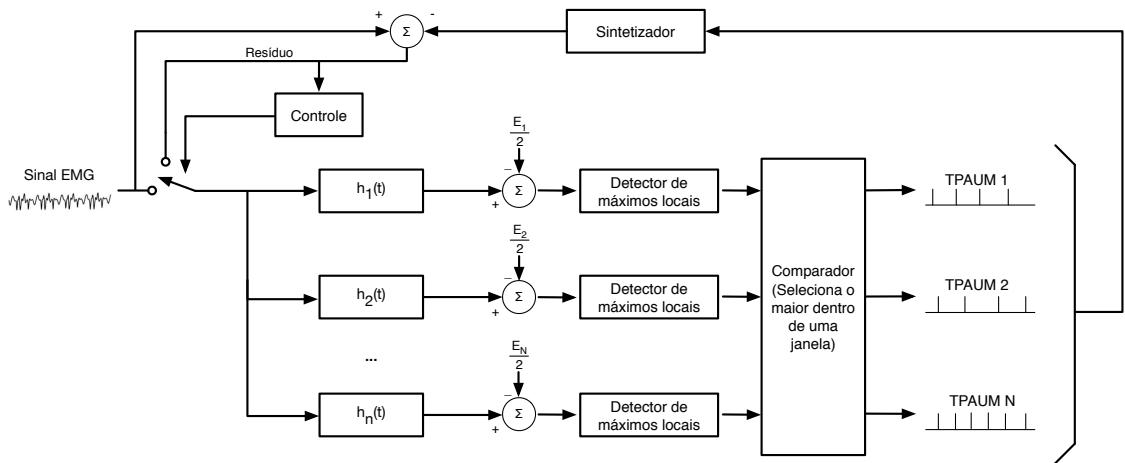


Figura 4.14: Método aprimorado para detecção de PAUMs baseado em filtros casados (MAD-FC).

para sintetizar um sinal com os disparos detectados e, ao subtrair o sinal sintetizado do sinal EMG de entrada, é encontrado o resíduo.

O sintetizador utiliza as informações das formas de onda do banco de filtros e os disparos detectados para construir uma estimativa da saída dos disparos já detectados. A

Equação 4.8, apresentada anteriormente, indica como é possível sintetizar o sinal referente ao disparo de uma unidade motora. Dessa forma, o sintetizador deve calcular o somatório desses sinais sintéticos, de forma que sua saída pode ser calculada pela Equação 4.12.

$$EMG_{Rec}(t) = \sum_{i=1}^N h_i(T_i - t - \tau_i) \quad (4.12)$$

Onde N corresponde ao número de disparos já detectados pelo simulador dentro da janela de análise, $h_i(t)$ equivale à resposta ao impulso do i -ésimo disparo detectado, T_i corresponde à duração do i -ésimo disparo e τ_i equivale ao instante onde foi detectado o disparo. O resíduo é encontrado subtraindo o sinal sintetizado EMG_{Rec} do sinal EMG.

No MAD-FC (Figura 4.14), existe uma chave que alterna o sinal de entrada dos filtros casados entre o sinal EMG e o resíduo. No início da análise, o sinal EMG é selecionado e os primeiros disparos são detectados. O resíduo então é calculado, e o controle muda a posição da chave de forma que o banco de filtros casados receba o resíduo. Conforme, descrito anteriormente, espera-se que, assim, possam ser detectados novos disparos que serão adicionados ao conjunto de disparos detectados e um novo sinal é sintetizado. O processo se repete com o resíduo calculado, até que uma condição de parada seja atingida, encerrando o processo.

A condição de parada é definida no bloco de controle (Figura 4.14), que define também a posição da chave. Para isso, o controle faz uma análise do resíduo para determinar se o processo de detecção deve prosseguir ou não. Um possível critério de parada envolve a análise da energia do resíduo, onde o método encerraria o processo de detecção quando, por exemplo, a energia do resíduo fosse menor do que a energia do ruído.

Entretanto, tal estratégia não prevê falhas na detecção. Em alguns casos, o classificador pode classificar erroneamente a unidade motora que originou um disparo. Dessa forma, pode ocorrer que, ao sintetizar o novo sinal e calcular o resíduo, não seja subtraído nenhum disparo. Com isso, pode ser que a energia do resíduo aumente continuamente. Para evitar esse problema, o critério de parada proposto é uma análise da energia em cada iteração do método, onde o processo é encerrado quando a energia do resíduo aumentar

de uma iteração para outra.

O método proposto foi construído a partir de técnicas típicas de processamento digital de sinais. Este método foi elaborado de forma a poder ser implementado em conjunto com os diversos sistemas que envolvam o uso da eletromiografia. Pode-se utilizar na implementação, por exemplo, processadores digitais de sinais (DSPs), FPGAs ou na forma de rotinas de software em um computador *desktop*. Para este trabalho, optou-se implementar o método na forma de rotinas de software que executam sobre a plataforma Matlab em um computador *desktop* padrão.

O próximo capítulo irá apresentar os experimentos e avaliações para quantificar o desempenho de ambas as propostas, uma vez que a performance de cada um estará associado a múltiplos fatores (número de UMs ativas, sobreposição e ruídos). Assim pode ser que uma das metodologias seja mais eficiente que outra em determinada situação e vice-versa. Ou seja, através dos experimentos, pode-se verificar se um método é superior a outro em todas as situações, ou existem momentos em que se deve optar por um método específico.

Capítulo 5

Resultados

No capítulo anterior, foram apresentadas duas propostas para detectar e classificar os disparos de unidades motoras em sinais EMG (MD-FC e MAD-FC). Para avaliar os métodos propostos, sinais EMG foram simulados e os resultados obtidos foram comparados com o padrão ouro gerado pelo simulador. É apresentado também um estudo de caso que analisa um sinal real.

5.1 Índices para avaliação

Os disparos detectados pelos MD-FC e MAD-FC foram comparados com os tempos de disparo fornecidos pelo simulador com uma tolerância de 2,5 ms. Tal tolerância equivale à metade da duração típica dos menores PAUMs encontrados nos músculos esqueléticos (9). Para cada disparo classificado pelo método, podem ocorrer duas situações: disparos que possuam um equivalente no padrão ouro do simulador dentro da faixa de tolerância são considerados positivos verdadeiros, os que não possuam equivalente no padrão ouro do simulador são definidos como falsos positivos. São verificados também, os disparos que existem no padrão ouro e não foram detectados pelo método. Esses são definidos como sendo falsos negativos. Para avaliar a capacidade de detecção, os seguintes índices de avaliação foram utilizados:

- Taxa de classificação correta,
- Precisão,
- Taxa de falsos positivos,
- Taxa de falsos negativos.

A taxa de classificação correta é definida pela Equação 5.1:

$$CC = \frac{TP}{N_{Sim}} \times 100 \quad (5.1)$$

Onde TP corresponde aos disparos corretamente detectados pelo método e N_{Sim} corresponde ao número de disparos fornecido pelo simulador.

A precisão do método é dada pela Equação 5.2. Essa precisão define qual a porcentagem dos pulsos detectados pelo método corresponde realmente a disparos existentes no sinal EMG.

$$P = \frac{TP}{N_{Alg}} \times 100 \quad (5.2)$$

Onde TP equivale novamente aos disparos corretamente detectados pelo método e N_{Alg} corresponde ao total de disparos detectados pelo mesmo.

A taxa de falsos positivos é definida pela Equação 5.3:

$$T_{FP} = \frac{FP}{N_{Sim}} \times 100 \quad (5.3)$$

Onde FP corresponde número de falsos positivos do método e N_{Sim} corresponde ao número de disparos fornecido pelo simulador. Esse indicador foi escolhido por ser uma forma de indexar o nível do erro de classificação do método.

Já a taxa de falsos negativos é definida pela Equação 5.4:

$$T_{FN} = \frac{FN}{N_{Sim}} \times 100 \quad (5.4)$$

Onde FN corresponde número de falsos negativos do método e N_{Sim} corresponde ao número de disparos fornecido pelo simulador. Esse indicador é uma maneira de identificar a capacidade do método de detectar corretamente os momentos dos disparos.

Os índices foram calculados para cada unidade motora e as estatísticas desses índices serão apresentadas nas próximas seções.

5.2 Conjunto de dados simulados

Sinais simulados foram escolhidos como primeira metodologia de avaliação, pois é a única forma de obter os padrões exatos de disparos da unidade motora e de obter os índices diretos de precisão. O simulador utilizado foi proposto por Andrade(57) e utiliza uma base de dados que contém disparos de unidades motoras reais previamente classificados. Modelos de distribuições de pontos (*Point Distribution Model*) são utilizados para gerar PAUMs únicos que ainda mantenham as características bases das unidades motoras, de forma semelhante ao que ocorre fisiologicamente nos músculos esqueléticos. Em seguida, são gerados os trens de pulsos de cada unidade motora com base nas características fisiológicas dos disparos. Esses trens de pulsos são utilizados para determinar os tempos de disparo de cada PAUM, formando os trens de pulso de unidade motora (TPAUM). O sistema também sintetiza um sinal que irá representar ruído. Isso é feito a partir de uma amostra do ruído previamente coletado de um sinal EMG real. Por fim, os sinais dos TPAUMs e do ruído são somados para se obter o sinal EMG sintetizado.

O simulador permite ao operador definir o número de unidades motoras presente no sinal EMG (até 15 unidades), o tempo de simulação e o valor da relação sinal-ruído. Ao final de sua execução, o simulador fornece informações sobre cada unidade motora gerada, as formas de onda de cada PAUM e os trens de pulsos de disparos. Essas informações foram utilizadas para avaliar o sistema de detecção proposto.

Para validação dos métodos, vários conjuntos de dados foram criados para verificar o seu desempenho. Cada grupo é composto por 40 sinais com diferentes números de unidades motoras. O número de unidades motoras presentes no sinal variou de 3 a 10 unidades, com cinco sinais para cada caso. Cada sinal simulado representa uma coleta de 30 segundos com frequência de aquisição de 10.040Hz.

Esses conjuntos de dados foram divididos em seis grupos:

Grupo 1: Sinais sem sobreposição de PAUMs e relação sinal-ruído de 200db.

Grupo 2: Sinais sem sobreposição de PAUMs e relação sinal-ruído de 20db.

Grupo 3: Sinais sem sobreposição de PAUMs e relação sinal-ruído de 10db.

Grupo 4: Sinais com sobreposição de PAUMs e relação sinal-ruído de 200db.

Grupo 5: Sinais com sobreposição de PAUMs e relação sinal-ruído de 20db.

Grupo 6: Sinais com sobreposição de PAUMs e relação sinal-ruído de 10db.

Os grupos de sinais sem sobreposição (Grupos 1 a 3) visam avaliar a capacidade do método de detectar e classificar os disparos isolados das unidades motoras. Nos demais grupos, tem-se a simulação completa das características das unidades motoras, incluindo as sobreposições de PAUMs. Os grupos também foram divididos em vários níveis de relação sinal-ruído para avaliar os efeitos desse parâmetro no desempenho dos métodos. Cada grupo terá seus resultados avaliados individualmente para cada uma das metodologias propostas.

5.2.1 Resultados do MD-FC

O MD-FC realiza a classificação direta dos sinais utilizando o banco de filtros casados. Esse método é preparado para detectar e classificar as unidades motoras isoladas e não

realiza a análise do resíduo para tentar resolver as sobreposições. Dessa forma, espera-se que ele consiga detectar bem as unidades motoras isoladas e tenha uma queda de desempenho ao ser aplicado sobre sinais que envolvam ondas sobrepostas. As seções a seguir apresentam os resultados de cada grupo.

5.2.1.1 Grupo 1: Sinais sem sobreposição e relação sinal-ruído de 200 dB

O grupo 1 visa avaliar a capacidade de classificação e detecção dos vários disparos de unidades motoras. Nesse grupo de sinais, o nível de ruído é muito baixo e não se tem o efeito da sobreposição. Dessa forma, é esperado um alto desempenho do MD-FC.

A Figura 5.1 apresenta um exemplo com parte de um dos sinais do grupo 1. O sinal contém 5 unidades motoras sem sobreposição. Na figura, é apresentado o sinal EMG analisado e são identificados os disparos de cada unidade motora com uma cruz e os disparos detectados pelo método com um círculo. Para melhorar a visualização, cada unidade motora é associada a um deslocamento no eixo Y. Observando-se a Figura 5.1, percebe-se pela que o MD-FC foi capaz de detectar e classificar corretamente todos os disparos dentro da janela. Isso pode ser verificado, observando-se que tantos os disparos do padrão ouro (símbolo da cruz), quanto os disparos detectados pelo método (círculo) ocorrem no mesmo instante de tempo.

A Tabela 5.1 apresenta os resultados obtidos pelo MD-FC para o grupo 1. Foi calculado a média e o desvio padrão de cada índice para o grupo e subgrupos de sinais. O valor da média do índice é apresentado nas respectivas colunas com o desvio padrão entre parenteses. O grupo de sinais foi dividido em vários subgrupos de acordo com o número de unidades motoras. Cada linha da tabela corresponde a um subgrupo. Por exemplo, o primeiro subgrupo é composto por sinais com 3 a 5 unidades motoras totalizando 15 sinais. Ao final da tabela, é apresentado o resultado geral do grupo, contendo a média geral dos índices encontrados.

Observe que o método foi capaz de detectar e classificar mais de 99% dos dis-

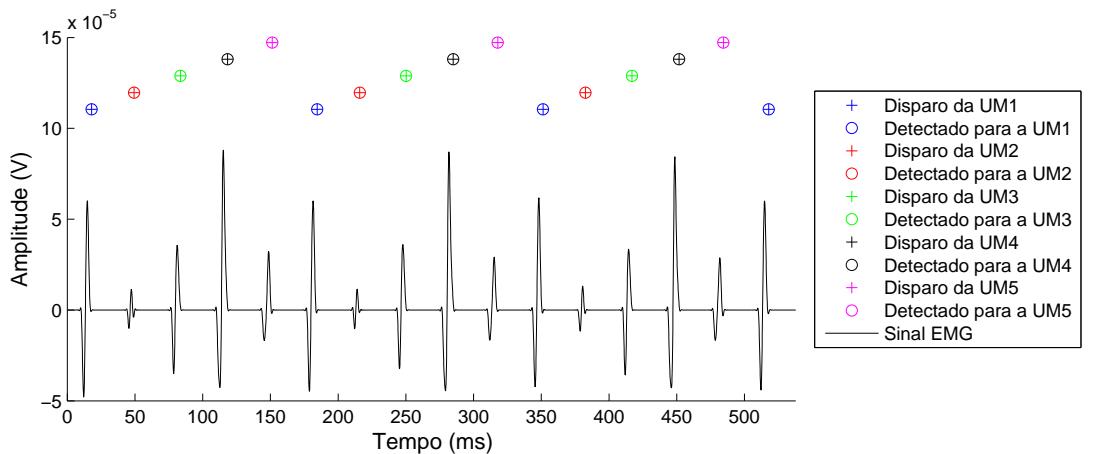


Figura 5.1: Exemplo de saída do MD-FC para um sinal com 5 unidades motoras sem sobreposição e SNR de 200 dB (Grupo 1).

Tabela 5.1: Resultados do MD-FC para sinais sem sobreposição e com SNR de 200 dB (Grupo 1). Cada célula contém a média do índice e o desvio padrão entre parenteses.

N. UMs	CC (%)	P (%)	T_{FP} (%)	T_{FN} (%)
3-5	99,63 (0,32)	100,00 (0,00)	0,00 (0,00)	0,37 (0,32)
6-8	99,49 (0,40)	100,00 (0,00)	0,00 (0,00)	0,51 (0,40)
9-10	99,19 (0,71)	100,00 (0,00)	0,00 (0,00)	0,81 (0,71)
3-10	99,42 (0,55)	100,00 (0,00)	0,00 (0,00)	0,58 (0,55)

paros corretamente. Lembrando que, mesmo sem a presença dos ruídos, cada disparo da unidade motora é único, sofrendo variações na sua forma equivalentes ao que ocorre fisiologicamente em músculos esqueléticos.

5.2.1.2 Grupo 2: Sinais sem sobreposição e relação sinal-ruído de 20 dB

Este grupo apresenta uma relação sinal ruído típica de coletas de boa qualidade obtidas através com bons equipamentos. A Figura 5.2 apresenta uma pequena amostra do sinal com os disparos das unidades motoras e a saída do método, de maneira similar à Figura

5.1. Note que mesmo com a presença desse nível de ruído, o MD-FC ainda é capaz de detectar corretamente todos os disparos dentro da janela de análise em questão.

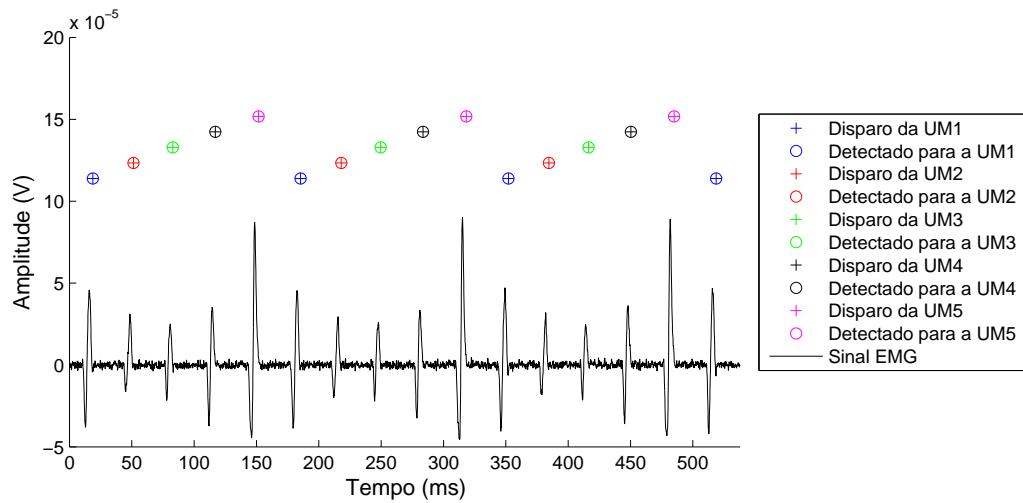


Figura 5.2: Exemplo de saída do MD-FC para um sinal com 5 unidades motoras sem sobreposição e SNR de 20 dB (Grupo 2).

A Tabela 5.2 apresenta os resultados obtidos pelo MD-FC para o grupo 2 da mesma forma que o caso anterior. Observa-se que existe uma pequena queda de desempenho no índice de classificação correta e na precisão do MD-FC em relação ao grupo 1, indicando alguma influência do ruído no desempenho do mesmo. Ainda assim, as taxas de classificação correta permanecem acima de 99%.

Tabela 5.2: Resultados do MD-FC para sinais sem sobreposição e com SNR de 20 dB (Grupo 2). Cada célula contém a média do índice e o desvio padrão entre parenteses.

N. UMs	CC (%)	P (%)	T_{FP} (%)	T_{FN} (%)
3-5	99,55 (0,58)	99,93 (0,46)	0,07 (0,47)	0,45 (0,58)
6-8	99,43 (0,51)	99,94 (0,32)	0,06 (0,32)	0,57 (0,51)
9-10	99,17 (0,73)	99,98 (0,15)	0,02 (0,15)	0,83 (0,73)
3-10	99,36 (0,63)	99,95 (0,31)	0,05 (0,32)	0,64 (0,63)

5.2.1.3 Grupo 3: Sinais sem sobreposição e relação sinal-ruído de 10 dB

Esse terceiro grupo de sinais visa verificar a influência da redução da relação sinal ruído no desempenho do método. A Figura 5.3 apresenta uma pequena amostra do sinal e o resultado da detecção da mesma forma que nas seções anteriores.

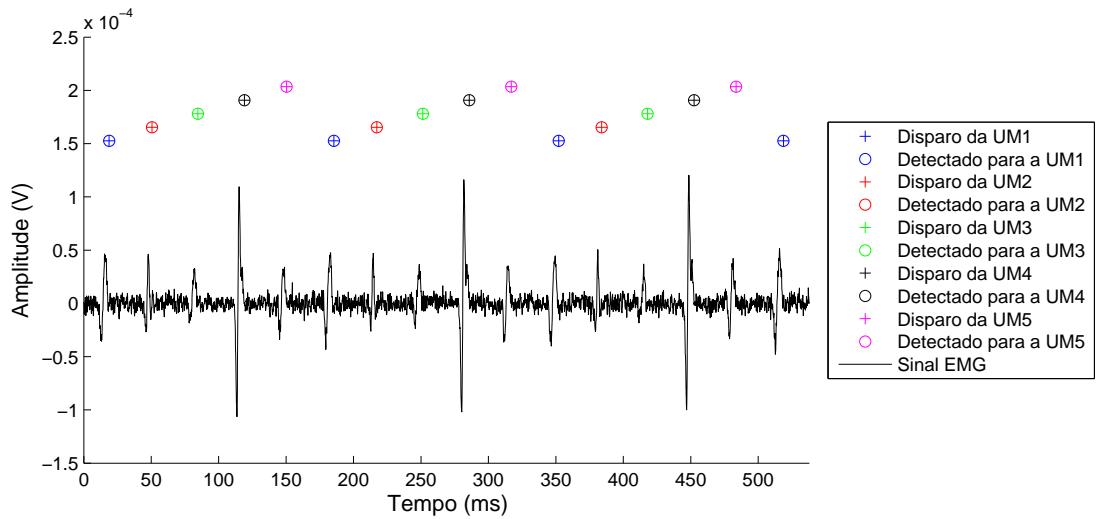


Figura 5.3: Exemplo de saída do MD-FC para um sinal com 5 unidades motoras sem sobreposição e SNR de 10 dB (Grupo 3).

Os resultados gerais para o grupo são apresentados na Tabela 5.3.

Tabela 5.3: Resultados do MD-FC para sinais sem sobreposição e com SNR de 10 dB (Grupo 3). Cada célula contém a média do índice e o desvio padrão entre parenteses.

N. UMs	CC (%)	P (%)	T_{FP} (%)	T_{FN} (%)
3-5	99,19 (1,49)	97,89 (8,27)	3,42 (16,07)	0,81 (1,49)
6-8	97,32 (5,87)	95,98 (9,52)	5,65 (16,10)	2,68 (5,87)
9-10	96,75 (4,43)	94,23 (13,87)	11,72 (42,60)	3,25 (4,43)
3-10	97,54 (4,72)	95,78 (11,12)	7,36 (28,87)	2,46 (4,72)

A Tabela 5.3 demonstra que o método apresenta uma queda de desempenho em relação aos grupo 1 e 2, conforme esperado. Ainda assim, o método consegue manter uma taxa

de detecção e classificação correta maior do que 97% em média. Merece destaque, nesse experimento, a maior taxa de falsos positivos para sinais com 9 a 10 unidades motoras. A taxa indica que o método começou a ter algumas dificuldades na classificação das unidades motoras, apesar de ainda manter uma boa taxa de classificação.

5.2.1.4 Grupo 4: Sinais com sobreposição e relação sinal-ruído de 200 dB

Esse grupo avalia os efeitos da sobreposição sobre o MD-FC. Esperada-se uma queda no desempenho do método, pois é provável que o mesmo não detecte boa parte dos disparos que envolvam sobreposições. A Figura 5.4 apresenta uma pequena amostra do sinal e o resultado da detecção, da mesma forma que nas seções anteriores.

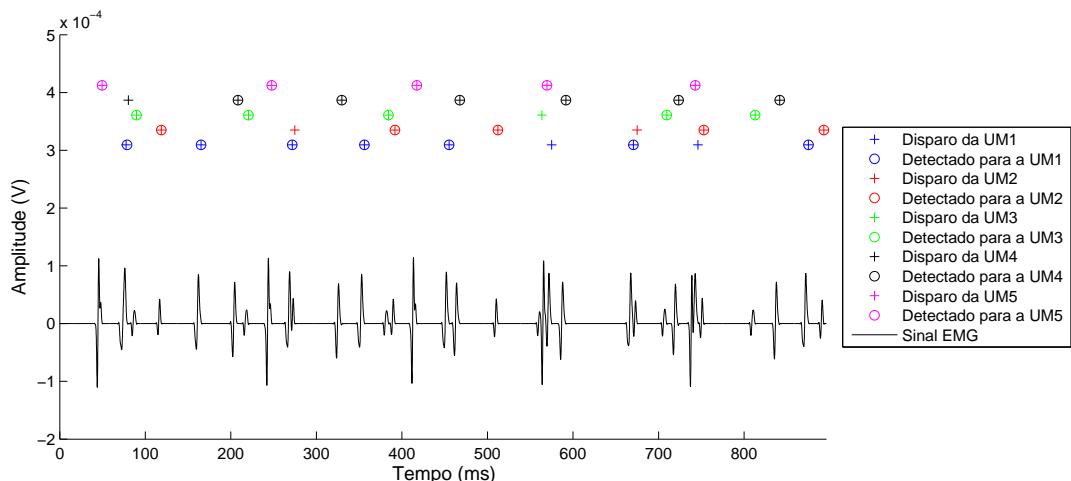


Figura 5.4: Exemplo de saída do MD-FC para um sinal com 5 unidades motoras com sobreposição e SNR de 200 dB (Grupo 4).

Observa-se que, na presença de sobreposições de PAUMs, o MD-FC não foi capaz de identificar todos os disparos, gerando um grande número de falsos negativos.

A Tabela 5.4 apresenta os resultados desse método para todos os sinais do grupo. Observa-se pela tabela que há uma diminuição no índice de classificação correta em todos os casos. Entretanto, mantém-se um alto nível de precisão (88% em média). Essas taxas

podem ser explicadas analisando os dois outros índices, onde percebe-se que o MD-FC tem dificuldade de detectar disparos em sobreposições, o que pode ser verificado pela alta taxa de falsos negativos (40% em média). Entretanto, os disparos que ele detecta são em sua maioria corretamente classificados, o que pode ser verificado pela baixa taxa de falsos positivos (7%).

Tabela 5.4: Resultados do MD-FC para sinais com sobreposição e com SNR de 200 dB (Grupo 4). Cada célula contém a média do índice e o desvio padrão entre parenteses.

N. UMs	CC (%)	P (%)	T_{FP} (%)	T_{FN} (%)
3-5	77,01 (14,10)	95,55 (4,88)	3,70 (4,50)	22,99 (14,10)
6-8	60,57 (18,10)	89,81 (9,11)	7,31 (8,10)	39,43 (18,10)
9-10	46,06 (20,17)	83,26 (12,29)	10,09 (10,16)	53,94 (20,17)
3-10	59,06 (21,52)	88,74 (10,77)	7,49 (8,63)	40,94 (21,52)

5.2.1.5 Grupo 5: Sinais com sobreposição e relação sinal-ruído de 20 dB

Este grupo ilustra sinais típicos de boa qualidade coletados com bons equipamentos. Com ele temos uma situação próxima ao que é encontrada na maioria dos laboratórios que trabalham com pesquisa de sinais EMG.

A Tabela 5.5 apresenta os resultados para esse grupo. Através da sua análise, tem-se um desempenho ligeiramente superior em relação ao Grupo 4. Entretanto, os resultados aparentam estar muito próximos e a melhora pode estar relacionada com a variabilidade gerada pela utilização de sinais diferentes, ou seja, o desempenho pode ser considerado praticamente o mesmo nos dois casos.

5.2.1.6 Grupo 6: Sinais com sobreposição e relação sinal-ruído de 10 dB

Esse último grupo representa sinais com baixa relação sinal-ruído. Nesses casos, o nível de ruído pode superar a amplitude de disparos de determinadas unidades motoras,

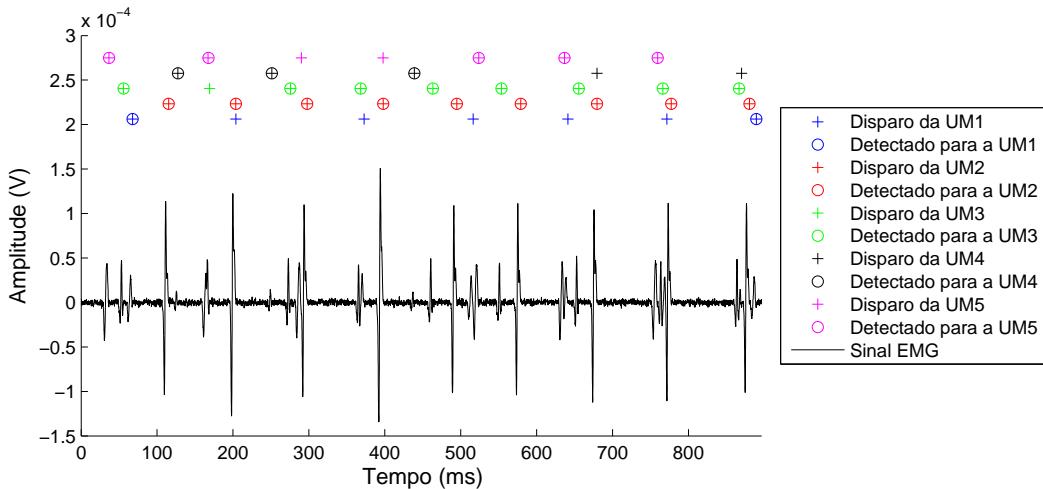


Figura 5.5: Exemplo de saída do MD-FC para um sinal com 5 unidades motoras com sobreposição e SNR de 20 dB (Grupo 5).

Tabela 5.5: Resultados do MD-FC para sinais com sobreposição e com SNR de 20 dB (Grupo 5). Cada célula contém a média do índice e o desvio padrão entre parenteses.

N. UMs	CC (%)	P (%)	T_{FP} (%)	T_{FN} (%)
3-5	78,25 (12,62)	96,99 (3,88)	2,45 (3,47)	21,75 (12,62)
6-8	61,83 (17,27)	91,49 (7,47)	6,10 (6,27)	38,17 (17,27)
9-10	51,39 (18,51)	85,45 (11,19)	9,41 (9,01)	48,61 (18,51)
3-10	61,81 (19,57)	90,55 (9,53)	6,47 (7,41)	38,19 (19,57)

dificultando a detecção e classificação das mesmas. Observe que na Figura 5.6, onde tem-se uma amostra de sinal desse grupo, o nível de ruído atinge quase a metade da amplitude das unidades motoras de menor magnitude.

A Tabela 5.6 apresenta os resultados dessa situação. Nos resultados desse experimento, observa-se, como esperado, uma queda de desempenho em relação ao caso anterior, indicando uma influência no nível de ruído no desempenho do sistema.

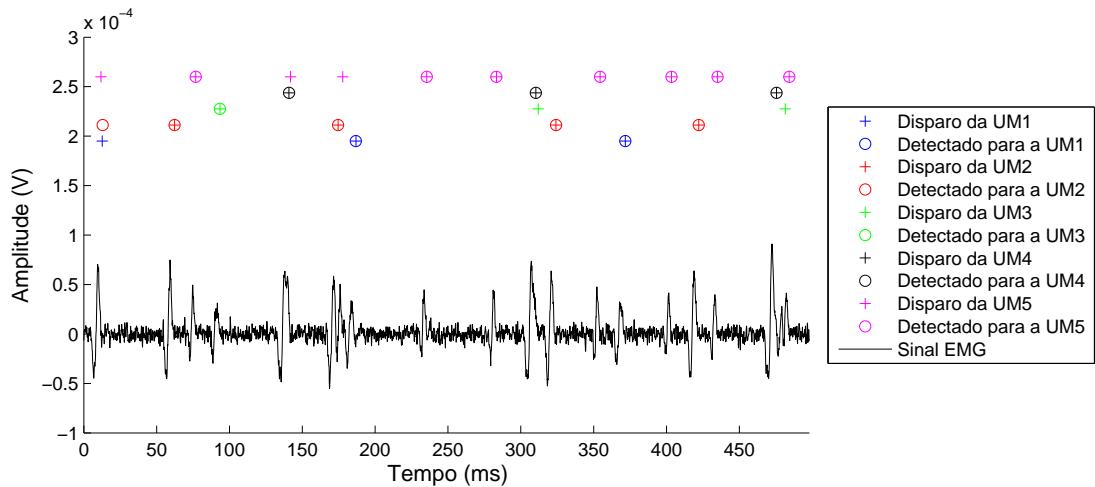


Figura 5.6: Exemplo de saída do MD-FC para um sinal com 5 unidades motoras com sobreposição e SNR de 10 dB (Grupo 6).

Tabela 5.6: Resultados do MD-FC para sinais com sobreposição e com SNR de 10 dB (Grupo 6). Cada célula contém a média do índice e o desvio padrão entre parenteses.

N. UMs	CC (%)	P (%)	T_{FP} (%)	T_{FN} (%)
3-5	77,70 (15,72)	92,24 (13,03)	8,42 (24,57)	22,30 (15,72)
6-8	55,76 (19,47)	80,47 (16,31)	17,44 (35,58)	44,24 (19,47)
9-10	47,59 (20,23)	72,12 (21,74)	30,49 (57,22)	52,41 (20,23)
3-10	57,84 (22,11)	80,14 (19,35)	20,13 (43,68)	42,16 (22,11)

5.2.2 Resultados do MAD-FC

A seção anterior analisou o desempenho do método de classificação e detecção de sinais EMG com sinais sem sobreposição, com sobreposição e com vários níveis de relação sinal-ruído. Os resultados demonstram que a presença de PAUMs sobrepostos influencia a capacidade de detecção do MD-FC. Para contornar tal limitação, aprimoramento foi proposto para tratar os casos onde se tem uma sobreposição de unidades motoras, gerando um novo método denominado MAD-FC. O novo método foi avaliado a partir dos mesmos grupos de sinais da Seção 5.3. Isso inclui os grupos que não possuem sobreposição para

tentar identificar se a alteração do método original influencia na detecção e classificação de um disparo isolado.

5.2.2.1 Grupo 1: Sinais sem sobreposição e relação sinal-ruído de 200 dB

A Figura 5.7 apresenta a saída do MAD-FC para este grupo. Observe que o método conseguiu detectar e classificar corretamente todos os disparos presentes no sinal EMG dentro da janela.

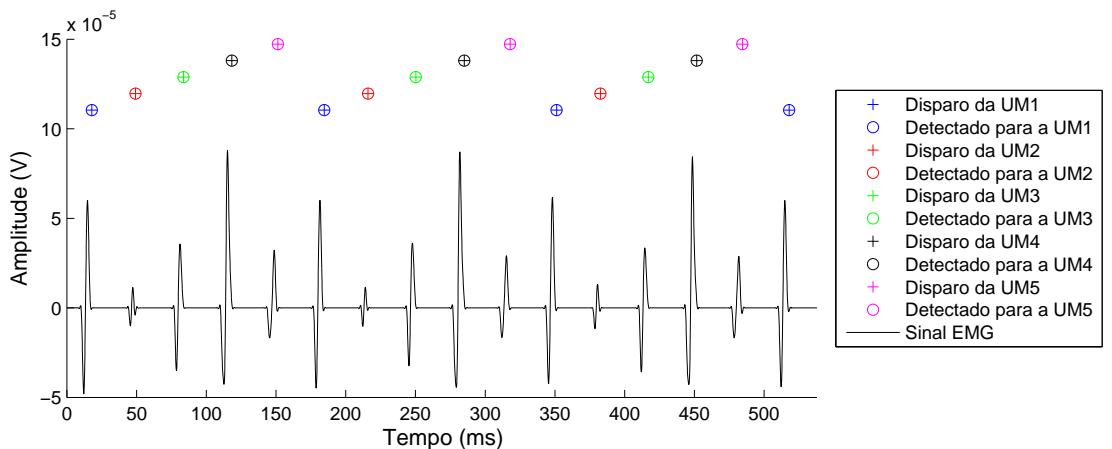


Figura 5.7: Exemplo de saída do MAD-FC para um sinal com 5 unidades motoras sem sobreposição e SNR de 200 dB (Grupo 1).

A Tabela 5.7 apresenta os resultados do MAD-FC para o Grupo 1 de dados. Observe que, nesse caso, a taxa de classificação correta mantém-se acima de 99% para todos os casos. Os resultados demonstram uma pequena queda no índice de precisão em relação à saída do MD-FC. Isso pode indicar que variações na forma de onda dos PAUMs em relação ao modelo que origina o filtro podem gerar pequenos resíduos que possivelmente foram responsáveis pelo aumento do número de falsos positivos.

Tabela 5.7: Resultados do MAD-FC para sinais sem sobreposição e com SNR de 200 dB (Grupo 1). Cada célula contém a média do índice e o desvio padrão entre parenteses.

N. UMs	CC (%)	P (%)	T_{FP} (%)	T_{FN} (%)
3-5	99,63 (0,32)	99,68 (1,48)	0,34 (1,60)	0,37 (0,32)
6-8	99,49 (0,40)	98,95 (4,50)	1,31 (5,93)	0,51 (0,40)
9-10	99,19 (0,71)	99,02 (6,55)	1,78 (12,08)	0,81 (0,71)
3-10	99,42 (0,55)	99,15 (4,93)	1,26 (8,24)	0,58 (0,55)

5.2.2.2 Grupo 2: Sinais sem sobreposição e relação sinal-ruído de 20 dB

Nesse segundo experimento com o MAD-FC, avaliou-se a influência do ruído na classificação correta dos disparos isolados. A Figura 5.8 apresenta uma visualização da saída do MAD-FC, em que se observa que o método ainda é capaz de detectar e classificar corretamente todos os disparos dentro dessa janela.

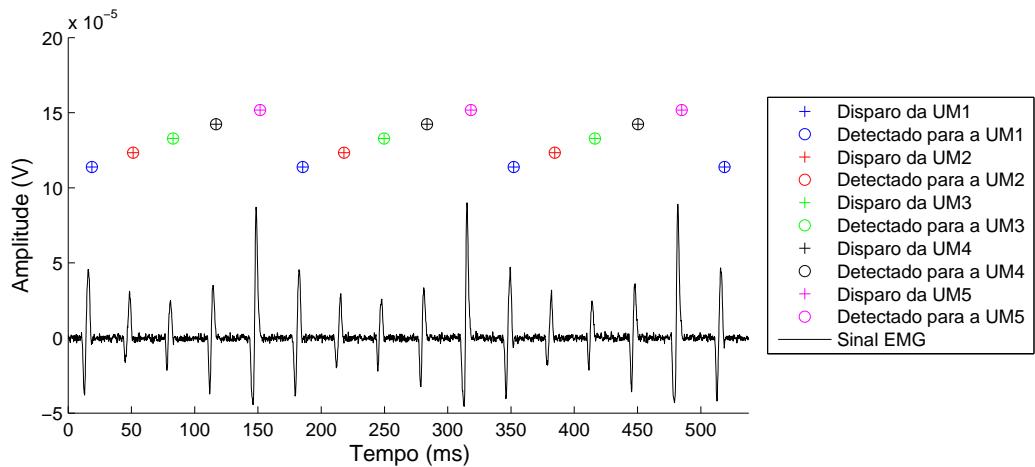


Figura 5.8: Exemplo de saída do MAD-FC para um sinal com 5 unidades motoras sem sobreposição e SNR de 20 dB (Grupo 2).

Os resultados obtidos pelo MAD-FC com os sinais do Grupo 2 são apresentados na Tabela 5.8. Os resultados são similares ao da Tabela 5.2 indicando que, mesmo sob ruído, o método ainda consegue classificar e detectar disparos isolados de unidades motoras. Isso

pode ser verificado pelo fato da taxa de classificação correta manter-se, em média, acima de 99% e com a precisão média acima de 96%. Novamente, observa-se uma queda de precisão em sinais com mais de 8 unidades motoras por influência do ruído.

Tabela 5.8: Resultados do MAD-FC para sinais sem sobreposição e com SNR de 20 dB (Grupo 2). Cada célula contém a média do índice e o desvio padrão entre parenteses.

N. UMs	CC (%)	P (%)	T_{FP} (%)	T_{FN} (%)
3-5	99,55 (0,58)	99,10 (3,80)	1,08 (4,67)	0,45 (0,58)
6-8	99,43 (0,51)	99,39 (3,93)	0,84 (5,72)	0,57 (0,51)
9-10	99,17 (0,73)	96,71 (10,75)	5,58 (20,58)	0,83 (0,73)
3-10	99,36 (0,63)	98,35 (7,28)	2,62 (13,30)	0,64 (0,63)

5.2.2.3 Grupo 3: Sinais sem sobreposição e relação sinal-ruído de 10 dB

Com este terceiro experimento com o MAD-FC, foi avaliada a influência de um nível maior de ruído na classificação correta dos disparos isolados. A Figura 5.9 apresenta a resposta do método em que, novamente, o método conseguiu classificar corretamente todos os disparos dentro da janela apresentada.

A Tabela 5.9 apresenta os resultados obtidos pelo MAD-FC com os sinais do Grupo 3. É possível observar que, mesmo havendo uma queda de desempenho, o ruído influiu pouco nos índices do MAD-FC. Resultado semelhante ao que ocorreu com o MD-FC, indicando que a segunda metodologia proposta também consegue detectar e classificar corretamente disparos isolados nessa situação.

5.2.2.4 Grupo 4: Sinais com sobreposição e relação sinal-ruído de 200 dB

Pelos resultados do MD-FC, percebeu-se que este tem dificuldades em detectar disparos em meio a sobreposições de PAUMs. Este experimento irá evidenciar se a alteração proposta no MAD-FC será capaz de aprimorar a detecção e classificação nesses casos.

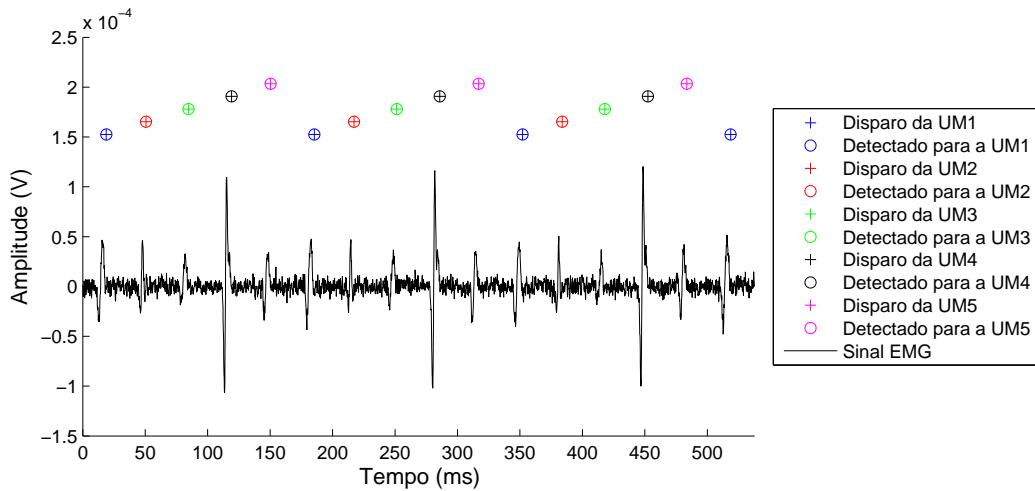


Figura 5.9: Exemplo de saída do MAD-FC para um sinal com 5 unidades motoras sem sobreposição e SNR de 10 dB (Grupo 3).

Tabela 5.9: Resultados do MAD-FC para sinais sem sobreposição e com SNR de 10 dB (Grupo 3). Cada célula contém a média do índice e o desvio padrão entre parenteses.

N. UMs	CC (%)	P (%)	T_{FP} (%)	T_{FN} (%)
3-5	99,15 (1,57)	97,00 (11,66)	6,39 (29,66)	0,85 (1,57)
6-8	97,32 (5,87)	94,13 (14,18)	11,39 (36,94)	2,68 (5,87)
9-10	96,72 (4,41)	92,96 (17,84)	21,96 (83,32)	3,28 (4,41)
3-10	97,52 (4,73)	94,36 (15,15)	14,10 (57,51)	2,48 (4,72)

Espera-se que, para esse grupo, os índices de desempenho melhorem em relação ao MD-FC, justificando o processamento extra.

A Figura 5.10 apresenta uma comparação entre as saídas dos métodos MD-FC e MAD-FC. Na Figura 5.10a, tem-se a saída do MD-FC, onde é possível perceber as falhas na detecção do método. Na Figura 5.10b, tem-se a saída do MAD-FC, onde percebe-se que este foi capaz de detectar e classificar corretamente boa parte dos disparos que não foram detectados pelo MD-FC. A exceção fica por conta do disparo da UM 4 que ocorre em cerca de 100 ms, onde foi erroneamente classificado como sendo um disparo da UM

3. Ainda assim, dos 6 disparos não detectados pelo MD-FC, 5 deles foram corretamente detectados e classificados pelo MAD-FC.

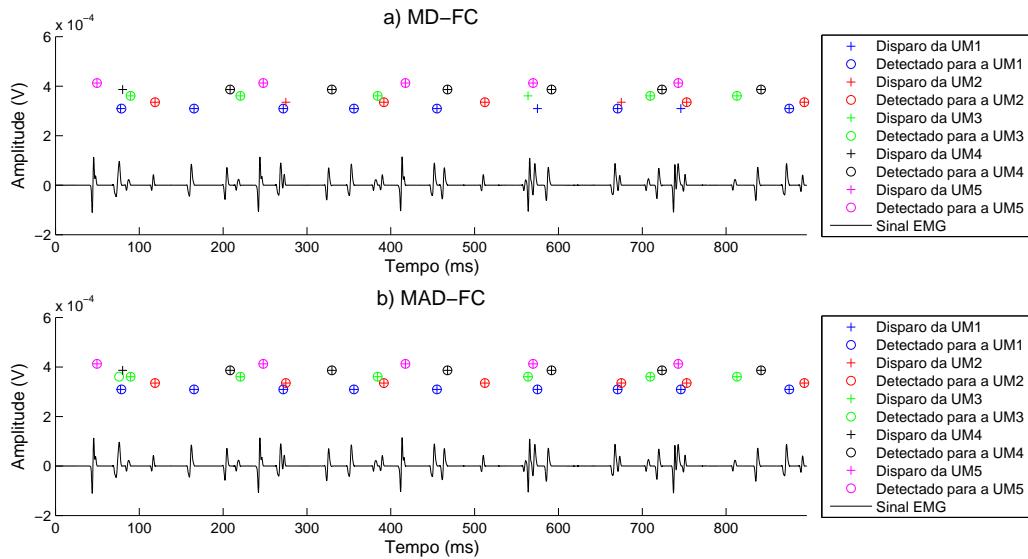


Figura 5.10: Comparaçāo entre as respostas dos algoritmos (a) MD-FC e (b) MAD-FC para um sinal com 5 unidades motoras com sobreposição e SNR de 200 dB (Grupo 4).

A Tabela 5.10 apresenta os resultados para esse grupo de sinais. Como esperado, o índice de classificação correta apresentou uma melhora substancial em relação à Tabela 5.4. Houve aumento médio superior a 30% em relação ao método sem tratamento de sobreposições. Pode-se observar, pela Tabela 5.10, que este ganho está relacionado, principalmente, à diminuição da taxa de falsos negativos obtida com o tratamento de sobreposição.

5.2.2.5 Grupo 5: Sinais com sobreposição e relação sinal-ruído de 20 dB

Conforme mencionado, esse experimento analisa sinais na situação típica em laboratórios de pesquisa, envolvendo sinais de boa qualidade, com baixa relação sinal-ruído. A Figura 5.11 reproduz a mesma análise para um sinal do Grupo 5 com os dois métodos propostos feita na seção anterior. Note que o MAD-FC foi capaz de detectar boa parte

Tabela 5.10: Resultados do MAD-FC para sinais com sobreposição e com SNR de 200 dB (Grupo 4). Cada célula contém a média do índice e o desvio padrão entre parenteses.

N. UMs	CC (%)	P (%)	T_{FP} (%)	T_{FN} (%)
3-5	91,07 (5,63)	95,24 (4,65)	4,68 (4,91)	8,95 (5,63)
6-8	79,46 (10,25)	87,13 (10,11)	12,55 (11,93)	20,55 (10,26)
9-10	66,92 (13,01)	78,85 (13,65)	19,98 (18,45)	33,11 (12,99)
3-10	77,56 (14,01)	85,98 (12,36)	13,45 (14,85)	22,46 (14,01)

dos disparos sobrepostos.

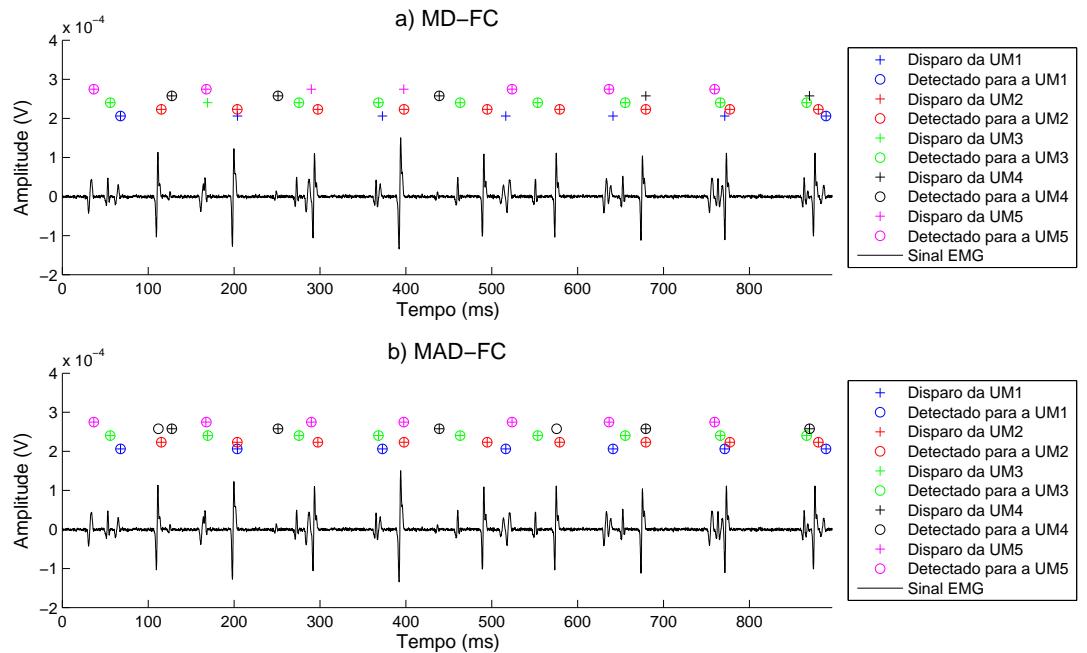


Figura 5.11: Comparação entre as respostas dos algoritmos (a) MD-FC e (b) MAD-FC para um sinal com 5 unidades motoras com sobreposição e SNR de 20 dB (Grupo 5).

A Tabela 5.11 apresenta os resultados para esse caso. Os resultados demonstram que o sistema apresenta boa capacidade de detecção e classificação para sinais de boa qualidade, atingindo 92% de taxa de classificação correta média e 94,97 de índice de precisão para

sinais com até 5 unidades motoras, com uma melhoria global em torno de 30% em relação ao MD-FC (Tabela 5.5).

Tabela 5.11: Resultados do MAD-FC para sinais com sobreposição e com SNR de 20 dB (Grupo 5). Cada célula contém a média do índice e o desvio padrão entre parenteses.

N. UMs	CC (%)	P (%)	T_{FP} (%)	T_{FN} (%)
3-5	92,78 (5,21)	95,10 (8,22)	5,64 (11,73)	7,22 (5,21)
6-8	80,57 (9,30)	86,99 (10,65)	13,17 (13,99)	19,44 (9,28)
9-10	70,74 (11,62)	80,73 (12,35)	18,32 (15,38)	29,27 (11,63)
3-10	79,80 (12,62)	86,58 (12,07)	13,32 (14,78)	20,21 (12,63)

5.2.2.6 Grupo 6: Sinais com sobreposição e relação sinal-ruído de 10 dB

O último experimento avalia a capacidade do método de detecção e classificação de disparos em sinais ruidosos. Esses sinais podem simular situações que envolvem a má fixação dos eletrodos ou coletas realizadas em ambientes ruidosos. A Figura 5.12 novamente apresenta uma comparação entre os métodos propostos.

Os resultados do Grupo 6 são apresentados na Tabela 5.12, onde fica evidenciado que existe uma queda de desempenho devido ao ruído. Ainda assim, o método consegue atingir uma taxa de classificação correta média de 90% com precisão média de 91% para sinais com até 5 unidades motoras ativas. Em relação ao MD-FC, a melhoria global de desempenho foi de cerca de 30% (Tabela 5.6).

5.3 Sinal real - Um estudo de caso

A análise dos sinais simulados permitiu identificar um melhor desempenho do algoritmo MAD-FC em relação ao MD-FC, especialmente em sinais que envolvem sobreposições. Para avaliar melhor a resposta do MAD-FC em uma situação clínica, um estudo

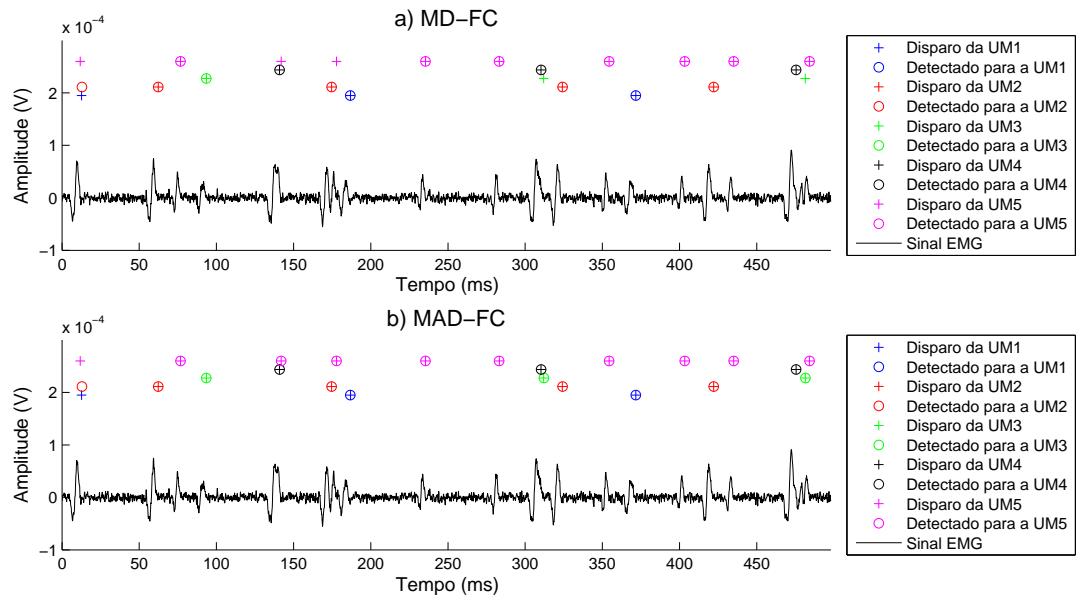


Figura 5.12: Comparaçāo entre as respostas dos algoritmos (a) MD-FC e (b) MAD-FC para um sinal com 5 unidades motoras com sobreposição e SNR de 10 dB (Grupo 6).

Tabela 5.12: Resultados do MAD-FC para sinais com sobreposição e com SNR de 10 dB (Grupo 6). Cada célula contém a média do índice e o desvio padrão entre parenteses.

N. UMs	CC (%)	P (%)	T_{FP} (%)	T_{FN} (%)
3-5	90,13 (8,29)	91,75 (12,57)	11,65 (33,48)	9,91 (8,28)
6-8	74,37 (12,86)	79,34 (16,44)	26,61 (52,54)	25,66 (12,84)
9-10	66,65 (13,89)	72,04 (21,21)	48,23 (92,98)	33,40 (13,86)
3-10	75,19 (15,19)	79,54 (19,05)	31,06 (68,59)	24,85 (15,18)

de caso foi realizado envolvendo um sinal real. Para isso, a resposta do método MAD-FC foi comparada com a de um especialista. Nessa análise, foi utilizado um sinal eletromiográfico de superfície coletado utilizando um eletrodo laplaciano (59). O sinal corresponde a uma contração isométrica de longa duração e possui quatro unidades motoras ativas. O sinal foi coletado com um sistema de condicionamento composto por um filtro passa faixa entre 10 e 1.000Hz e aquisicionado a uma taxa de 10kHz durante 120 segundos.

Foi aplicado um filtro digital *butterworth* de ordem 10 entre 100 e 1.000Hz para remover oscilações de baixa frequência do sinal. O sinal também inclui anotações dos PAUMs classificados por um especialista.

A Figura 5.13 apresenta uma pequena amostra do sinal utilizado. Nela foram incluídos os instantes de detecção anotados pelo especialista e os encontrados pelo algoritmo. É possível verificar que existe uma boa concordância entre o algoritmo e o especialista para as unidade motoras 1, 2 e 3. Na unidade motora 4 encontramos algumas divergências, provavelmente por se tratar de uma unidade motora de pequena amplitude, com pouca energia, bastante misturada ao ruído de base.

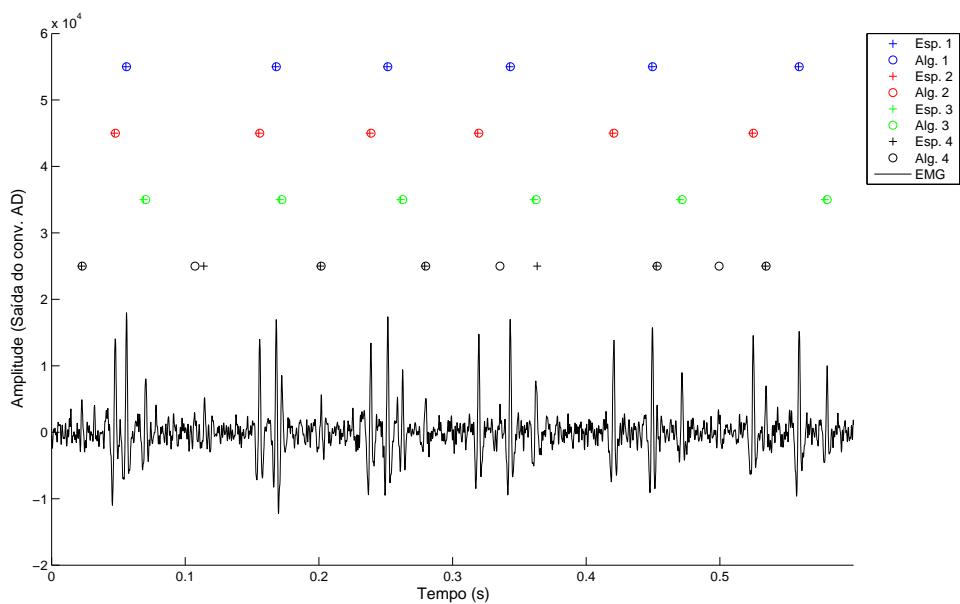


Figura 5.13: Amostra de um sinal EMG real e a comparação entre as respostas do método MAD-FC com a de um especialista.

Foram calculados os mesmos índices utilizados com os sinais simulados, usando as anotações do especialista como padrão ouro. Apesar de utilizarmos as denominações “classificação correta”, “precisão” e “taxa de falsos positivos” e “falsos negativos”; nesse caso não podemos afirmar que o padrão ouro está totalmente correto. Dessa forma, esses

índices fornecem apenas um indicativo da concordância entre o resultado do algoritmo e do especialista e não podem ser utilizados como medida de desempenho direta. A Tabela 5.13 apresenta os resultados para esse sinal.

Tabela 5.13: Resultados do MAD-FC para o sinal real. Cada célula contém a média do índice e o desvio padrão entre parenteses.

N. UMs	CC (%)	P (%)	T_{FP} (%)	T_{FN} (%)
4	76,73 (9,9)	77,60 (18,04)	26,74 (28,2)	23,27 (9,9)

Os resultados demonstram que existe uma concordância elevada entre o algoritmo e o especialista. Tal fato pode ser observado pela taxa de classificação correta e a precisão do algoritmo acima de 76%. Percebe-se que existem divergências entre o algoritmo e o especialista, que podem ser observadas através da taxa de falsos positivos. Tal fato está relacionado com a falha na detecção dos PAUMs da unidade motora 4 (Figura 5.13).

Para evidenciar essa questão, um conjunto de resultados da decomposição é apresentado na Figura (5.14). Nela é apresentado o *shimmer plot*, o histograma do intervalo entre disparos (IED) e uma amostra do trem de disparos detectados para cada unidade motora. Percebe-se nos resultados, que o algoritmo é capaz de detectar bem as três primeiras unidades motoras. Observa-se nesses casos uma consistência no *shimmer plot* e uma resposta típica de uma decomposição correta no histograma do IED. Os histogramas dessas unidades motoras apresentam uma forma próxima à de uma gaussiana, onde é possível estimar a taxa média do disparo através da moda do intervalo entre disparos.

Entretanto o algoritmo teve dificuldades com a unidade motora 4. É possível observar pelo *shimmer plot* que esta é uma unidade motora de baixa amplitude, com pouca energia. O histograma do IED não se apresenta na forma gaussiana e existe uma tendência para intervalos de curta duração. Tal fato é justificado pela amplitude da unidade motora em questão, onde o algoritmo pode confundir um determinado ruído de artefato de baixa frequência com um disparo da unidade motora, gerando um número grande de falsos positivos.

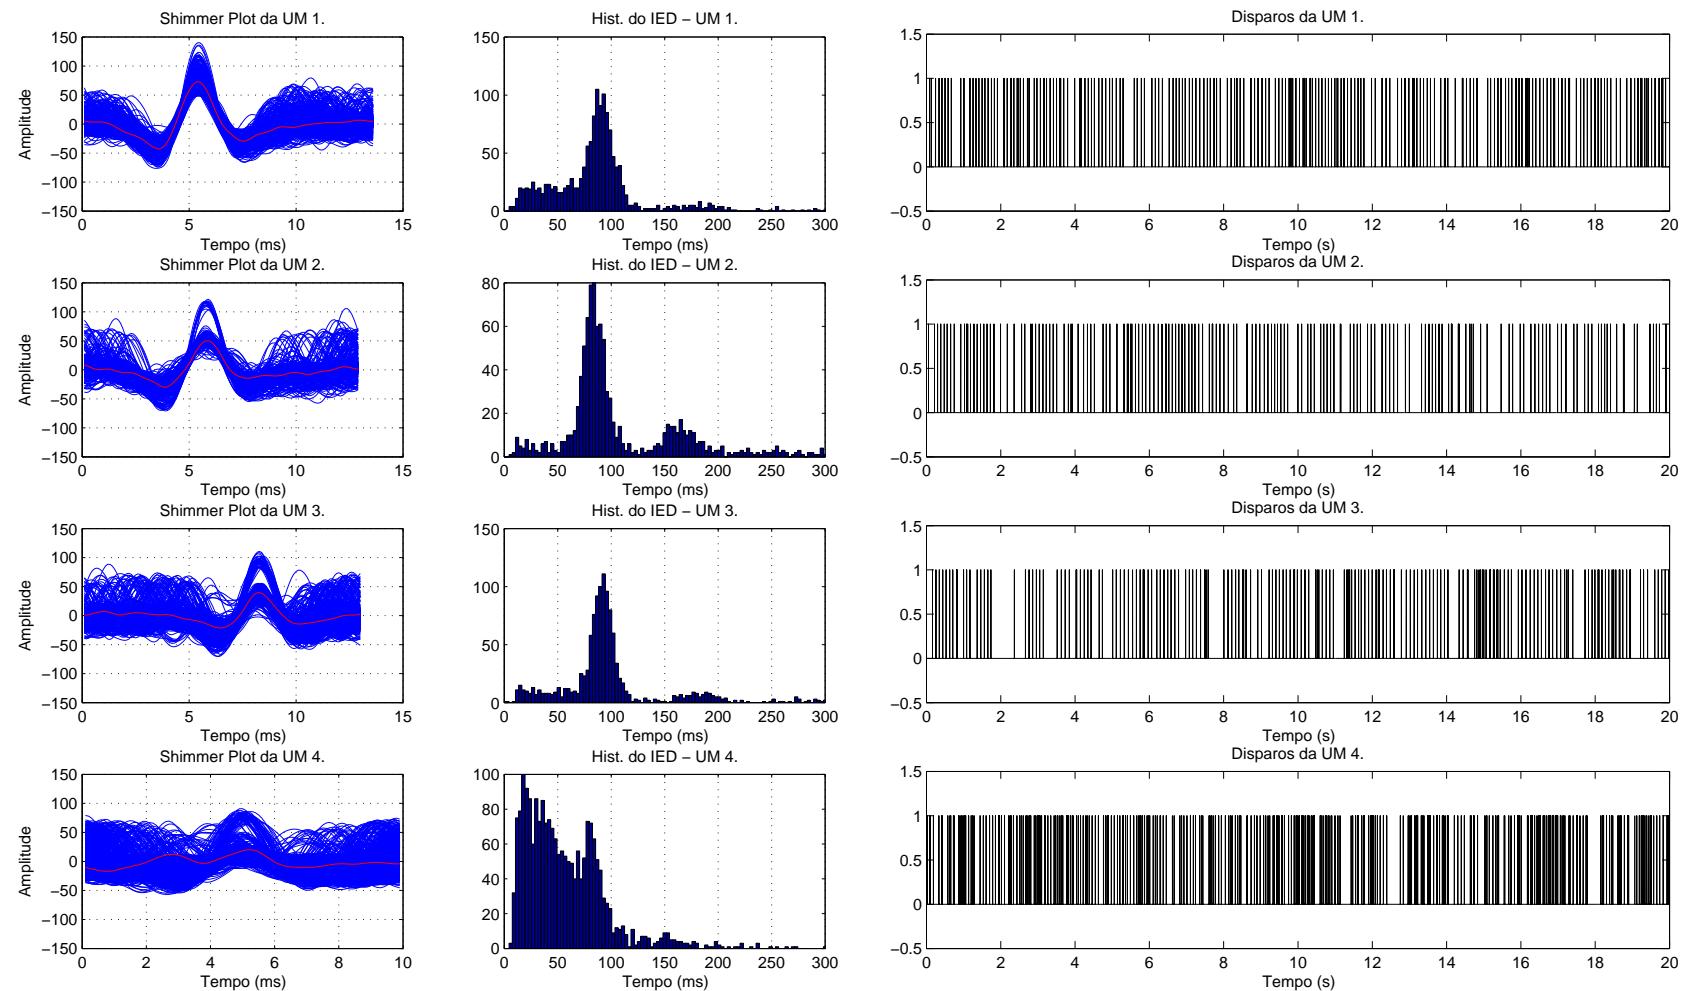


Figura 5.14: Resultados da decomposição de um sinal EMG real composto por quatro unidades motoras. Na primeira coluna é apresentado o *shimmer plot* de cada unidade motora. Na segunda coluna, o histograma entre disparos. Na terceira coluna é exibida uma amostra do trem de disparos detectados pelo algoritmo.

5.4 Considerações sobre os resultados obtidos

Os resultados obtidos até aqui demonstram que o primeiro método proposto é capaz de detectar e classificar com alta precisão disparos isolados de unidades motoras. Os experimentos mostraram que mesmo sob alto ruído os métodos são capazes de detectar corretamente em média cerca de 96% dos disparos isolados. Porém, o MD-FC tem seu desempenho diminuído para sinais que apresentem sobreposições.

Aprimoramento do MD-FC foi proposto e os resultados demonstram que o mesmo (MAD-FC) apresenta ganho de cerca de 30% na taxa média de classificação correta para sinais EMGs com relação sinal-ruído de 20 dB. Esse aumento no desempenho também pode ser observado nos demais casos, onde a relação sinal-ruído diminui.

Um estudo de caso com sinais reais foi realizado. Seus resultados demonstram uma concordância entre os resultados do MAD-FC com os obtidos por um especialista. O *shimmer plot* e o histograma do IED indicam que o método é capaz de detectar com boa precisão as diferentes unidades motoras, bem como sua taxa de disparo.

Capítulo 6

Discussão

No Capítulo 4, foram apresentados dois métodos para a detecção e classificação de disparos de unidades motoras: MD-FC e MAD-FC, sendo o segundo uma versão de aprimorada do primeiro que identifica sobreposição de disparos de PAUMs. A performance de ambos foi verificada por meio de um conjunto de experimentos, descritos no Capítulo 5, realizados com o objetivo de verificar a capacidade dos mesmos em diferentes situações e envolvendo sinais EMG sintetizados a partir de disparos de unidades motoras isoladas ou sobrepostas, em quantidades variadas e com diferentes intensidades de ruídos. Também foi realizado um estudo de caso envolvendo sinais reais, onde foi comparada a resposta do MAD-FC com a de um especialista.

6.1 Desempenho do MD-FC

Os resultados apresentados no Capítulo 5, demonstram que o MD-FC é capaz de classificar corretamente disparos isolados e que a influência do nível de ruído nesses casos é pequena. Tal fato pode ser observado analisando as Tabelas 5.1, 5.2 e 5.3, que apresentam uma taxa média de classificação correta superior a 97%.

Entretanto, ao analisar sinais que apresentam sobreposição de PAUMs, o método

MD-FC apresenta uma queda de desempenho significativa (Tabela 6.1). A taxa de classificação correta, em sinais típicos (SNR 20 dB) cai de 99% para 59% na presença de sinais sobrepostos. Ainda assim, o método mantém um índice de precisão acima de 80%, demonstrando que boa parte dos disparos que o método é capaz de encontrar são corretamente classificados.

Os índices de falsos positivos e falsos negativos fornecem uma visão mais detalhada das capacidades do MD-FC (o índice de falsos negativos pode ser utilizado para identificar o nível de falha de detecção, e o índice de falsos positivos pode ser correlacionado com erros de classificação). Dessa forma, observa-se que, na presença de sobreposições, tem-se um aumento nos dois índices, conforme esperado. Entretanto, o método apresenta índices de falsos positivos bem menores que os índices de falsos negativos, indicando que a principal razão para a queda no desempenho (incapacidade de detectar parte dos disparos) ocorreu devido à sobreposição.

6.2 Desempenho do MAD-FC

Conforme descrito, o MAD-FC foi projetado com o objetivo de melhorar a performance do método base (MD-FC) em situações de sobreposição de disparos de PAUMs, através da análise do resíduo entre o sinal de entrada e a resposta do classificador. A proposta aprimorada partiu da verificação de dados simulados que o método base é capaz de classificar corretamente diversos disparos mesmo em casos de sobreposição. Assim, um PAUM corretamente detectado pode ser subtraído da sobreposição, gerando um resíduo que, em tese, equivale aos PAUMs restantes (Equação 4.11). Assim, esperava-se uma melhoria de desempenho do MAD-FC em relação ao MD-FC.

Para permitir comparações entre os métodos, aferindo se o segundo de fato aprimora as capacidades do primeiro, exatamente o mesmo conjunto de sinais utilizado para testar o MD-FC foi utilizado para avaliar o MAD-FC.

A Tabela 6.2 apresenta um resumo dos resultados obtidos pelo MAD-FC nas diversas

situações de teste. Observe que a modificação implementada para aprimoramento do método praticamente não influi na detecção de PAUMs isolados. Isso pode ser observado, comparando-se os resultados das Tabelas 6.1 e 6.2 para os grupos 1, 2 e 3.

Contudo, observa-se uma melhoria significativa na taxa de classificação correta (cerca de 30%) no caso de sinais que envolvem sobreposições de PAUMs. Ou seja, o método consegue detectar e classificar uma quantidade de disparos muito superior ao MD-FC. As taxas de falsos negativos também caíram, em média, aproximadamente 20%, indicando que o MAD-FC é capaz de detectar mais de 50% dos disparos perdidos pelo MD-FC.

No experimento envolvendo sinais reais, o algoritmo MAD-FC foi capaz de detectar com boa precisão os disparos de três das quatro unidades motoras ativas. Isso pode ser verificado pelos histogramas do IED (Figura 5.14) que apresentam forma próxima à de uma gaussiana, típica de contrações isométricas. O algoritmo obteve uma taxa de concordância com relação ao resultado obtido pelo especialista de 76% em média.

Verifica-se também, pelo estudo envolvendo sinais reais, que o método possui dificuldades com PAUMs de baixa amplitude e pouca energia. O algoritmo teve dificuldades de detectar os disparos da unidade motora 4 que possuem tal característica. Outras propostas da literatura também reportam essa dificuldade, descartando a análise desses trens de PAUMs (60, 42).

Uma limitação dos dois métodos propostos está na incapacidade destes detectarem novas unidades motoras. Os algoritmos propostos não possuem um mecanismo para determinar que um disparo detectado pertence a uma outra unidade motora que não foi incluída no banco de filtros. Isso pode levar a alguns erros de classificação em contrações que envolvam um aumento no nível de contração muscular.

Recentemente Glaser, Holobar e Zazula(61) propuseram um sistema que realiza a detecção e classificação de disparos em unidades motoras em tempo real. Porém, a decomposição *on-line* somente é atingida após uma etapa de treinamento de cerca de 3 segundos de dados. Este sistema atinge índices de classificação correta 99% para sinais com SNR de 20dB e 5 unidades motoras ativas. Tal resultado foi obtido através da análise de sinais

Tabela 6.1: Resumo dos resultados para o MD-FC.

Grupo	Sobrepl.	SNR (dB)	N. UMs	CC (%)	P (%)	T_{FP} (%)	T_{FN} (%)
1	Não	200	3-10	99,42 (0,55)	100,00 (0,00)	0,00 (0,00)	0,58 (0,55)
2	Não	20	3-10	99,36 (0,63)	99,95 (0,31)	0,05 (0,32)	0,64 (0,63)
3	Não	10	3-10	97,54 (4,72)	95,78 (11,12)	7,36 (28,87)	2,46 (4,72)
4	Sim	200	3-10	59,06 (21,52)	88,74 (10,77)	7,49 (8,63)	40,94 (21,52)
5	Sim	20	3-10	61,81 (19,57)	90,55 (9,53)	6,47 (7,41)	38,19 (19,57)
6	Sim	10	3-10	57,84 (22,11)	80,14 (19,35)	20,13 (43,68)	42,16 (22,11)

Tabela 6.2: Resumo dos resultados para o MAD-FC.

Grupo	Sobrepl.	SNR (dB)	N. UMs	CC (%)	P (%)	T_{FP} (%)	T_{FN} (%)
1	Não	200	3-10	99,42 (0,55)	99,15 (4,93)	1,26 (8,24)	0,58 (0,55)
2	Não	20	3-10	99,36 (0,63)	98,35 (7,28)	2,62 (13,30)	0,64 (0,63)
3	Não	10	3-10	97,52 (4,73)	94,36 (15,15)	14,10 (57,51)	2,48 (4,72)
4	Sim	200	3-10	77,56 (14,01)	85,98 (12,36)	13,45 (14,85)	22,46 (14,01)
5	Sim	20	3-10	79,80 (12,62)	86,58 (12,07)	13,32 (14,78)	20,21 (12,63)
6	Sim	10	3-10	75,19 (15,19)	79,54 (19,05)	31,06 (68,59)	24,85 (15,18)

oriundos de uma matriz de eletrodos com 30 elementos de captação (matriz de 6x5). O MAD-FC é capaz de obter índices de classificação correta menores (92,78%), entretanto necessita de coletar o sinal de apenas um canal para obter tal resultado.

Um algoritmo proposto por Parsaei e Stashuk(60) consegue atingir uma taxa de classificação correta de 86,4% para sinais entre 3 e 11 unidades motoras ativas. Tal resultado é obtido através de pós-processamento que utiliza informações da forma de onda e da taxa de disparos para validar os TPAUMs encontrados. Isso limita a aplicação dessa proposta a captura de sinais específicos e não permite a aplicação em tempo real. O algoritmo gasta até 26 segundos para processar uma janela de 10 segundos de um sinal EMG. Novamente, o MAD-FC atinge taxa de classificação correta menor (79,8% para sinais entre 3 e 10 unidades motoras), porém obtém esse resultado sem depender de algoritmos de pós-processamento para validação dos resultados encontrados. Além disso, o MAD-FC é bem mais rápido que o algoritmo proposto por Parsaei, sendo capaz de analisar um sinal de 30 segundos de dados em cerca de 5 segundos.

Marateb et al.(62) apresentaram um método que realiza a detecção e classificação dos disparos a partir de um único canal. Seus resultados são analisados através de um padrão ouro definido por uma decomposição manual assistida por um software de apoio. A técnica atinge uma taxa de acerto de 93% em média e foi capaz de detectar e classificar 9 das 11 unidades motoras ativas do sinal. Essa proposta também não é capaz de realizar a decomposição em tempo real, sinais de 10 segundos precisam de 35 segundos para serem analisados. Nosso método foi capaz de detectar e classificar corretamente até 10 unidades motoras com uma taxa de acerto de 79,80% em sinais simulados. O tempo de processamento no caso do MAD-FC também é menor, como foi descrito.

Florestal, Mathieu e McGill(42) apresentaram um algoritmo que atinge índices de classificação correta de 95% para 75% das unidades motoras analisadas. Essa classificação correta varia entre 53 e 100% envolvendo todas as amostras. Tal método atinge esses resultados utilizando matrizes de eletrodos, porém pode ser utilizado com sistemas envolvendo um único canal com até 12 unidades motoras ativas. O método de Florestal

é rápido, porém a análise em tempo real só pode ser obtida para coletas envolvendo um canal. Nesse caso, os índices de classificação correta diminuem. A classificação correta para o algoritmo MAD-FC varia entre 54,56% e 100% e é capaz de analisar sinais com até 10 unidades motoras utilizando apenas um canal, ou seja, o algoritmo MAD-FC possui desempenho equivalente ao proposto por Florestal. A Tabela 6.3 resume a comparação dos resultados obtidos pelo MAD-FC e os métodos recentes encontrados na literatura.

Tabela 6.3: Comparaçāo entre os resultados obtidos com o MAD-FC e alguns mētódos descritos recentemente na literatura.

Técnica	Captação	Número de UMs	CC (%)	SNR
Florestal, Mathieu e McGill(42)	Matrizes	25	92	>20 dB
Holobar et al.(39)	Matrizes	11	95	>20 dB
Marateb et al.(62)	Um canal	11	93	>20 dB
Parsaei e Stashuk(60)	Matrizes	11	86	>20 dB
Glaser, Holobar e Zazula(61)	Matrizes	5	99	>20 dB
		10	79,8	20 dB
MAD-FC	Um canal	5	92,78	20 dB
		5	90,13	10 dB

6.3 Considerações finais

Conforme descrito, observa-se que o MAD-FC supera com grande margem o MD-FC no quesito de precisão, colocando-o como a melhor escolha entre os dois mētódos propostos, principalmente quando envolve sinais EMG em grandes níveis de força, quando a probabilidade de ocorrência de sobreposições aumenta consideravelmente.

Em relação à instrumentação, os mētódos foram preparados para realizar a sua análise sobre um canal de dados. Entretanto, é possível utilizá-los também com sinais oriundos de matrizes de eletrodos. Para tal, basta aplicar o mētodo para cada um dos sinais

captados pela matriz. Para que o algoritmo seja capaz de realizar a sua função, basta que seja possível identificar alguns PAUMs isolados no mesmo. Dessa forma, os eletrodos devem possuir apenas uma pequena área de contato o que define uma resolução espacial pequena. Essa condição é satisfeita em eletrodos invasivos, permitindo a sua aplicação direta. Já com eletrodos de superfície, tem-se alguns casos que envolvem eletrodos com área de contato maior, como, por exemplo, os eletrodos de barras. Esse tipo de eletrodo não é recomendado para essa aplicação. O ideal é utilizar-se de eletrodos com pequena área de contato, como os eletrodos propostos por Nawab, Chang e De Luca(53). Dessa forma, os métodos propostos não estão limitados a sua utilização com eletrodos de agulha ou superfície, podendo ser aplicados sobre sinais oriundos de ambos.

Apesar das pequenas diferenças nos algoritmos, as implementações de ambas as metodologias em software podem ser executadas muito rapidamente em sistemas computacionais padrão, permitindo sua aplicação em sistemas em tempo real. Os testes realizados em computador desktop com Processador Intel i5® e 8GB de RAM e sobre a plataforma do Matlab, cada janela de dados de 50 ms é processada em cerca de 5 ms. Outras forma de implementação do método podem ser realizadas usando outros mecanismos. Exemplos incluem a implementação utilizando processadores digitais de sinais (DSPs), FPGAs, entre outros. É possível também utilizar instruções especiais presentes nas CPUs atuais para melhorar o tempo de execução do método. Um exemplo, são as instruções SIMD (*Single Instruction Multiple Data*), que permitem o processamento ágil de vetores de dados típicos nos blocos de processamento digital de sinais incluídos nos métodos propostos.

Os métodos propostos também se destacam por não utilizarem características estatísticas dos disparos como parte do método de detecção. Essas características são utilizadas para corrigir erros classificação por diversas propostas alternativas descritas na literatura (5, 1). A opção pelo uso de elementos estatísticos, conforme descrito pelos autores, limita a aplicação da técnica para sinais EMG resultantes de contrações isométricas com força constante e de curta duração limitação esta inexistente nos métodos propostos.

De forma similar, os métodos propostos tem potencial para minimizar a quantidade

de canais EMG necessários para detecção e classificação correta. De fato, todas as modelagens e experimentos foram preparados para utilização de informações (EMG) provenientes de apenas um canal. Alguns métodos clássicos, muito utilizados e citados na literatura, utilizam como entrada vários sinais EMG, oriundos de matrizes de eletrodos (1, 27, 40, 51, 38). A vantagem de se utilizar de uma matriz de eletrodos, é que esta permite a cobertura de uma área maior, ao mesmo tempo que permite o aumento da resolução espacial, principalmente quando se utiliza elementos de captação de dimensões pequenas (1 a 2 mm de diâmetro). O uso de tais matrizes permite que alguns desses sistemas sejam capazes de identificar um grande número de unidades motoras. Entretanto, nesses casos, o sistema de captação pode se tornar mais complexo e exigir um tempo de processamento muito considerável (Florestal, 2009; DE LUCA et al., 2006). Apesar destas questões não serem, de fato, limitadores definitivos para a aplicação daquela técnica, uma vez que as tecnologias certamente evoluirão muito rapidamente, superando aquelas limitações, a minimização da quantidade de canais pode simplificar o projeto dos dispositivos, em termos de geometria e custos, além de tornar o processamento mais rápido, aproximando-os de aplicações clínicas e sistemas embarcados.

Capítulo 7

Conclusões e trabalhos futuros

Detectar e classificar os disparos das unidades motoras em sinais EMG é um problema que vem sendo estudado a várias décadas. Diversos algoritmos foram propostos tentando realizar essa função com diferentes níveis de sucesso. Dentre os desafios encontrados ao se desenvolver esses algoritmos, incluem-se os efeitos dos ruídos na precisão do algoritmo e a análise das sobreposições, dentre outros. A tendência observada na literatura é de um aumento na complexidade dos métodos visando tratar esses problemas. Assim, alguns autores tem propostos sistemas que exigem mecanismos de captura complexos ou equipamentos de alto desempenho para obterem resultados significativos. Tal complexidade, aliada às grandes dificuldades daqueles métodos em situação de ruído e grande percentual de sobreposições de MUAPs, tem impedido a utilização da ferramenta na prática clínica ou aplicações como biofeedback e controle de próteses.

As metodologias propostas, denominadas MD-FC e MAD-FC, contribuem para as pesquisas na área à medida que possibilitam um mecanismo de detecção e classificação de disparos de MUAPs em situações com altos níveis de ruídos e até mesmo alto percentual de sobreposições de MUAPs.

Esse trabalho apresentou uma visão do estado da arte das técnicas de detecção e classificação de disparos de unidades motoras presentes nos sistemas de decomposição de

sinais EMG. Foram revisados os vários mecanismos utilizados e analisadas as vantagens e limitações descritas pelos seus autores. Dentre as limitações identificadas está, o fato dos algoritmos possuírem um custo computacional alto, exigirem esquemas de detecção complexos e dificuldades com sinais de baixa relação sinal-ruído.

Visando solucionar esses problemas, foi verificada a utilização de filtros casados como ferramenta de detecção e classificação de sinais em sistemas de comunicação e radar. Um estudo sobre a técnica foi realizado, identificando as propriedades e capacidades da mesma.

Dessa forma foram propostas duas arquiteturas, MD-FC e MAD-FC, que realizem a detecção e classificação de disparos de unidades motoras de forma eficiente. Os algoritmos propostos buscaram atingir os seus objetivos sem um aumento excessivo no custo computacional e utilizando sinais oriundos de um único eletrodo. As metodologias propostas baseiam-se num banco de filtros casados construídos a partir de um modelo padrão dos disparos das unidades motoras presentes no sinal EMG. O MAD-FC foi apresentado como um aprimoramento do algoritmo original (MD-FC), onde é analisado o resíduo para detectar um número maior de disparos em meio a sobreposições.

O MD-FC foi capaz de detectar e classificar 97% dos disparos sem ocorrência de sobreposição, entretanto, tem seu desempenho reduzido na presença da mesma. Ao analisar o MAD-FC foi observado uma melhoria de 20% no processo de detecção em relação ao método original em meio a sinais que envolvam PAUMs sobrepostos.

Os resultados demonstraram também que o algoritmo MAD-FC é capaz de detectar e classificar os disparos de até 5 unidades motoras, incluindo ondas sobrepostas, com taxa de classificação correta maior do que 90% em média. Um estudo de caso com sinais reais foi realizado demonstrando que existe uma concordância entre os resultados do MAD-FC com os obtidos por um especialista. Através do *shimmer plot* e o histograma do IED desse sinal tem-se indicativos que o método é capaz de detectar com boa precisão as diferentes unidades motoras, bem como sua taxa de disparo. Com isso, o objetivo de propor e validar um algoritmo de detecção e classificação de disparos de unidades motoras em sinais EMG

foi atingido.

As implementações dos métodos em software demonstram que estes são capazes de analisar, e classificar corretamente, janelas de sinais de 50 ms em cerca de 5 ms, apontando seu potencial imediato para aplicações em tempo-real.

Os métodos propostos também se caracterizam por não utilizarem características estatísticas dos disparos como parte do método de detecção, o que possibilita sua aplicação em situações envolvendo atividades EMG gerais, enquanto a maior parte das metodológicas propostas na literatura são limitadas a contrações isométricas com força constante e de curta duração.

7.1 Trabalhos Futuros

Como todo trabalho científico, este tem como principal objetivo contribuir para o estado da arte, apontando novas fronteiras para o conhecimento na área. Assim, seus resultados não se limitam aos aqui apresentados. Além disso, apesar da proposta lançar as bases para novas pesquisas, esta possui algumas limitações que devem ser abordadas em trabalhos futuros. Neste sentido, podemos citar as seguintes pesquisas para evolução dos trabalhos aqui apresentados:

- Implementar estratégias para segmentação de sinais EMG, permitindo a definição de PAUMs padrão (as formas de onda iniciais utilizadas na criação dos filtros casados) em tempo de execução. Ao realizar essa função o método será expandido para um sistema de decomposição completo, eliminando a etapa de segmentação preliminar, necessária para as metodologias aqui propostas.
- Investigar se ao utilizar as taxas de disparos e o nível de ruído para alterar o nível de *bias* dinamicamente (Equação 4.6) é possível se obter melhores resultados.
- Verificar se é possível melhorar o desempenho ao atualizar os coeficientes dos bancos dos filtros casados ao encontrar novos disparos. Dessa forma, é possível que o método

seja capaz de acompanhar as variações fisiológicas que ocorrem em uma contração muscular de longa duração.

- Aprimorar a resolução de sobreposições, buscando aumentar a precisão do algoritmo através de outras formas de análise do resíduo para validar a detecção correta do banco de filtros, diminuindo a ocorrência de falsos positivos.
- Investigar a utilização do algoritmo proposto em aplicações, como terapias de biofeedback para tratamento de espasticidade em pós-AVE e controle de próteses de membros artificiais, dentre outras.

Apêndice A

Formas de ondas dos PAUMs

A Figura A.1 apresenta um exemplo com as formas de ondas dos PAUMs que originaram o banco de filtros. Tais ondas foram utilizadas para decompor um sinal sintético envolvendo 9 unidades motoras. Elas equivalem ao primeiro disparo de cada unidade motora sem a presença do ruído.

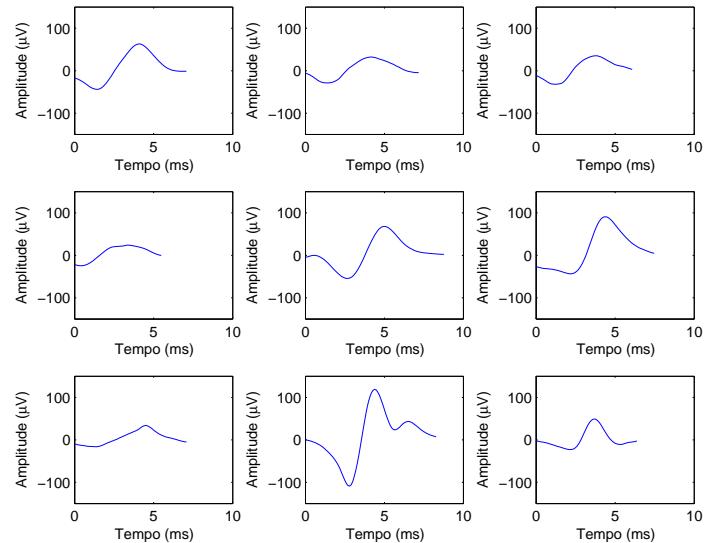


Figura A.1: Exemplo de 9 formas de onda utilizadas para a criação de um banco de filtros.

Referências

- 1 DE LUCA, C. J. et al. Decomposition of surface EMG signals. *Journal of Neurophysiology*, v. 96, n. 3, p. 1646–1657, Jan 2006.
- 2 ANDRADE, A. O. et al. EMG signal filtering based on empirical mode decomposition. *Biomedical Signal Processing and Control*, v. 1, n. 1, p. 44–55, 1 2006.
- 3 MCGILL, K. C.; CUMMINS, K. L.; DORFMAN, L. J. Automatic decomposition of the clinical electromyogram. *Biomedical Engineering, IEEE Transactions on*, v. 32, n. 7, p. 470–477, 1985.
- 4 EVERITT, B. S. et al. *Cluster Analysis*. 5. ed. : John Wiley & Sons, 2011.
- 5 FANG, J.; AGARWAL, G. C.; SHAHANI, B. T. Decomposition of multiunit electromyographic signals. *Biomedical Engineering, IEEE Transactions on*, v. 46, n. 6, p. 685–697, 1999.
- 6 FLORESTAL. A Genetic Algorithm for the Resolution of Superimposed Motor Unit Action Potentials. *Biomedical Engineering, IEEE Transactions on*, v. 54, n. 12, p. 2163–2171, 2007.
- 7 RASHEED, S.; STASHUK, D.; KAMEL, M. A software package for interactive motor unit potential classification using fuzzy k-NN classifier. *Computer Methods And Programs In Biomedicine*, v. 89, n. 1, p. 56–71, jan. 2008.

- 8 DE LUCA, C. J.; HOSTAGE, E. C. Relationship Between Firing Rate and Recruitment Threshold of Motoneurons in Voluntary Isometric Contractions. *Journal Of Neurophysiology*, v. 104, n. 2, p. 1034–1046, 2010.
- 9 BASMAJIAN, J. V.; DE LUCA, C. J. *Muscles alive: Their functions revealed by electromyography*. 5. ed. : Williams & Wikins, 1985.
- 10 CHRISTODOULOU, C. I.; PATTICHIS, C. S. A new technique for the classification and decomposition of EMG signals. In: *Neural Networks, 1995. Proceedings., IEEE International Conference on*. 1995. v. 5, p. 2303–2308.
- 11 STASHUK, D. EMG signal decomposition: how can it be accomplished and used? *Journal of electromyography and kinesiology*, v. 11, n. 3, p. 151–73, Jun 2001.
- 12 PINO, L. J. et al. Motor unit potential characterization using “pattern discovery”. *Medical Engineering & Physics*, v. 30, n. 5, p. 563–573, 2008.
- 13 HAN, J. J. et al. Using electromyography to assess function in humans and animal models of muscular dystrophy. *Physical medicine and rehabilitation clinics of North America*, v. 16, n. 4, p. 981–97, x, Nov 2005.
- 14 BARBOI, A.; BARKHAUS, P. Electrodiagnostic testing in neuromuscular disorders. *Neurologic clinics*, v. 22, n. 3, p. 619–641, Jan 2004.
- 15 GOOCH, C. L.; WEIMER, L. H. The electrodiagnosis of neuropathy: basic principles and common pitfalls. *Neurologic clinics*, v. 25, n. 1, p. 1–28, Feb 2007.
- 16 LACOMIS, D. Electrodiagnostic approach to the patient with suspected myopathy. *Neurologic clinics*, v. 20, n. 2, p. 587–603, Jan 2002.
- 17 KENNETT, R. Clinical neurophysiology. *Medicine*, v. 36, n. 10, p. 556–561, 2008.
- 18 LEFEVER, R. S.; DE LUCA, C. J. A procedure for decomposing the myoelectric signal into its constituent action potentials - Part I: Technique, theory, and

- implementation. *Biomedical Engineering, IEEE Transactions on*, v. 29, n. 3, p. 149–157, 1982.
- 19 GERBER, A. et al. A new framework and computer program for quantitative EMG signal analysis. *Biomedical Engineering, IEEE Transactions on*, BME-31, n. 12, p. 857–863, 1984.
- 20 HASSOUN, M. H.; CHUANMING, W.; SPITZER, A. R. NNERVE: Neural network extraction of repetitive vectors for electromyography - Part I - algorithm. *Biomedical Engineering, IEEE Transactions on*, v. 41, n. 11, p. 1039–1052, 1994.
- 21 NIKOLIC, M. et al. Detailed analysis of motor unit activity. In: *Engineering in Medicine and Biology Society, 1997. Proceedings of the 19th Annual International Conference of the IEEE*. 1997. v. 3, p. 1257–1260 vol.3.
- 22 WELLIG, P.; MOSCHYTZ, G. S.; LÄUBLI, T. Decomposition of EMG signals using time-frequency features. *Engineering in Medicine and Biology Society, 1998. Proceedings of the 20th Annual International Conference of the IEEE*, v. 3, p. 1497–1500 vol.3, 1998.
- 23 XU, Z.; XIAO, S.; CHI, Z. ART2 neural network for surface EMG decomposition. *Neural Computing & Applications*, v. 10, n. 1, p. 29–38, 2001.
- 24 ZENNARO, D. et al. A decomposition software package for the decomposition of long-term multi-channel electromyographic signals. *Engineering in Medicine and Biology Society, 2001. Proceedings of the 23rd Annual International Conference of the IEEE*, v. 2, p. 1070–1073 vol.2, 2001.
- 25 CHAUVET, E. et al. Automatic identification of motor unit action potential trains from electromyographic signals using fuzzy techniques. *Medical and Biological Engineering and Computing*, v. 41, n. 6, p. 646–653, 2003.
- 26 REN, X. et al. MUAP extraction and classification based on wavelet transform and ICA for EMG decomposition. *Medical and Biological Engineering and Computing*, v. 44, n. 5, p. 371–382, 05 2006.

- 27 FLORESTAL, J. R.; MATHIEU, P. A.; MALANDA, A. Automated decomposition of intramuscular electromyographic signals. *Biomedical Engineering, IEEE Transactions on*, v. 53, n. 5, p. 832–839, 2006.
- 28 ANDRADE, A. O.; NASUTO, S. J.; KYBERD, P. Extraction of motor unit action potentials from electromyographic signals through generative topographic mapping. *Journal of the Franklin Institute*, v. 344, n. 3-4, p. 154–179, 2007.
- 29 ZAREI, E.; MAGHOOLI, K.; FIROOZABADI, S. M. P. A new approach for EMG decomposition based on overlaps solution. *Digital Signal Processing, 2007 15th International Conference on*, p. 119–122, 2007.
- 30 LITTLE, J. W.; MASSAGLI, T. L. Espasticidade e anormalidades do tônus muscular associadas. In: *Tratado de Medicina de Reabilitação - Princípios e Prática*. : Manole, 2002. v. 2, cap. 40, p. 1049–1066.
- 31 MAYER, N. H. Clinicophysiologic concepts of spasticity and motor dysfunction in adults with an upper motoneuron lesion. *Muscle & Nerve*, v. 20, n. 6, p. 1–14, 1997.
- 32 TEIVE, H. A. G.; ZONTA, M.; KUMAGAI, Y. Tratamento da espasticidade: uma atualização. *Arq. Neuro-Psiquiatr.*, v. 56, n. 4, p. 852–858, 1998.
- 33 DUDAI, Y. *The neurobiology of memory: Concepts, findings, trends*. New York, NY, US: Oxford University Press, 1989.
- 34 LEVANON, N.; MOZESON, E. *Radar Signals*. New Jersey: John Wiley & Sons, 2004.
- 35 HAYKIN, S. *Communication Systems*. 4. ed. New York: John Wiley & Sons, 2001.
- 36 LEWICKI, M. S. A review of methods for spike sorting: the detection and classification of neural action potentials. *Network: Computation in Neural Systems*, v. 9, n. 4, p. R53–78, Nov 1998.

- 37 HOLOBAR, A.; ZAZULA, D. Correlation-based decomposition of surface electromyograms at low contraction forces. *Medical and Biological Engineering and Computing*, v. 42, n. 4, p. 487–495, 2004.
- 38 KLEINE, B. U. et al. Using two-dimensional spatial information in decomposition of surface EMG signals. *Journal of electromyography and kinesiology*, v. 17, n. 5, p. 535–548, 2007.
- 39 HOLOBAR, A. et al. Estimating motor unit discharge patterns from high-density surface electromyogram. *Clinical Neurophysiology*, v. 120, n. 3, p. 551–562, 2009.
- 40 FARINA, D. et al. Detecting the unique representation of motor-unit action potentials in the surface electromyogram. *Journal Of Neurophysiology*, v. 100, n. 3, p. 1223–1233, 2008.
- 41 NAWAB, S. H.; WOTIZ, R. P.; DE LUCA, C. J. Decomposition of indwelling EMG signals. *Journal of Applied Physiology*, v. 105, n. 2, p. 700–710, 2008.
- 42 FLORESTAL, J.; MATHIEU, P.; MCGILL, K. Automatic decomposition of multichannel intramuscular EMG signals. *Journal of Electromyography and Kinesiology*, v. 19, n. 1, p. 1–9, 2009.
- 43 MAMBRITO, B.; DE LUCA, C. J. A technique for the detection, decomposition and analysis of the EMG signal. *Electroencephalography And Clinical Neurophysiology*, v. 58, n. 2, p. 175–188, ago. 1984.
- 44 DE LUCA, C. J.; ADAM, A. Precision decomposition of intramuscular electromyographic signals. In: WINDHORST, U.; JOHASSON, H. (Ed.). *Modern Techniques on Neuroscience Research*. Heidelberg: Springer, 1999. cap. 27, p. 757–776.
- 45 NYQUIST, H. Certain topics in telegraph transmission theory. *Proceedings of the IEEE*, v. 90, n. 2, p. 280–305, 2002.
- 46 SHANNON, C. E. Communication in the presence of noise. *Proceedings of the IEEE*, v. 86, n. 2, p. 447–457, 1998.

- 47 GARCIA, G. A.; OKUNO, R.; AZAKAWA, K. A decomposition algorithm for surface electrode-array electromyogram. *Engineering in Medicine and Biology Magazine, IEEE*, v. 24, n. 4, p. 63–72, 2005.
- 48 THEIS, F. J.; GARCÍA, G. A. On the use of sparse signal decomposition in the analysis of multi-channel surface electromyograms. *Signal Processing*, v. 86, n. 3, p. 603–623, 3 2006.
- 49 WELLIG, P.; MOSCHYTZ, G. Analysis of wavelet features for myoelectric signal classification. *Electronics, Circuits and Systems, 1998 IEEE International Conference on*, v. 3, p. 109–112 vol.3, set. 1998.
- 50 VIJAYA, P.; MURTY, M. N.; SUBRAMANIAN, D. Leaders–Subleaders: An efficient hierarchical clustering algorithm for large data sets. *Pattern Recognition Letters*, v. 25, n. 4, p. 505–513, mar. 2004.
- 51 HOLOBAR, A.; ZAZULA, D. Multichannel Blind Source Separation Using Convolution Kernel Compensation. *Signal Processing, IEEE Transactions on*, v. 55, n. 9, p. 4487–4496, set. 2007.
- 52 STASHUK, D. Detecting single fiber contributions to motor unit action potentials. *Muscle & Nerve*, v. 22, n. 2, p. 218–229, 1999.
- 53 NAWAB, S. H.; CHANG, S.-S.; DE LUCA, C. J. High-yield decomposition of surface EMG signals. *Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology*, abr. 2010.
- 54 VASECHI, S. V. *Multimedia Signal Processing: Theory and Applications in Speech, Music and Communications.* : John Wiley & Sons, 2007.
- 55 TURIN, G. An introduction to matched filters. *Information Theory, IRE Transactions on*, v. 6, n. 3, p. 311–329, jun. 1960.
- 56 NADOVICH, C. T. *Synthetic Instruments - Concepts and Applications*. Burlington, Massachusetts, Estados Unidos: Elsevier, 2005.

- 57 ANDRADE, A. O. *Decomposition and Analysis of Electromyographic Signals*. Tese (Doutorado) — School of Systems Engineering Cybernetics, University of Reading, Novembro 2005.
- 58 LATHI, B. P.; DING, Z. *Sistemas de Comunicações Analógicos e Digitais Modernos*. 4. ed. Rio de Janeiro: LTC, 2012.
- 59 HOGREL, J.-Y. *Conjunto de dados online R011*. jul. 2013. Disponível em: <<http://www.emglab.net>>.
- 60 PARSAEI, H.; STASHUK, D. EMG Signal Decomposition Using Motor Unit Potential Train Validity. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, p. –, set. 2012.
- 61 GLASER, V.; HOLOBAR, A.; ZAZULA, D. Real-time motor unit identification from high-density surface emg. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, n. 99, p. 1, 2013.
- 62 MARATEB, H. R. et al. Robust decomposition of single-channel intramuscular EMG signals at low force levels. *Journal of Neural Engineering*, v. 8, n. 6, 2011.