

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO
DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

Decomposição de Sinais Eletromiográficos de Superfície Misturados Linearmente Utilizando Análise de Componentes Independentes

Autor

Tiago Paggi de Almeida

Orientador

Prof. Dr. Antônio Augusto Fasolo Quevedo

Tese de Mestrado apresentada à Faculdade de Engenharia Elétrica e de Computação como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: **Engenharia Biomédica**.

Banca Examinadora:

Prof. Dr. Antônio Augusto Fasolo Quevedo (DEB/FEEC/UNICAMP)

Prof. Dr. Leonardo Tomazeli Duarte (FCA/UNICAMP)

Prof. Dr. Eduardo Tavares Costa (DEB/FEEC/UNICAMP)

Campinas – SP
13 de junho de 2012

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA E ARQUITETURA - BAE - UNICAMP

AL64d Almeida, Tiago Paggi de
Decomposição de sinais eletromiográficos de superfície
misturados linearmente utilizando análise de componentes
independentes / Tiago Paggi de Almeida. --Campinas, SP: [s.n.],
2012.

Orientador: Antônio Augusto Fasolo Quevedo .
Dissertação de Mestrado - Universidade Estadual de Campinas,
Faculdade de Engenharia Elétrica e de Computação.

1. Eletromiografia. 2. Processamento e detecção de sinais. 3.
Entropia (Teoria da informação). 4. Teoria da estimativa -
Processamento de dados. 5. Engenharia biomédica. I. Quevedo,
Antônio Augusto Fasolo. II. Universidade Estadual de Campinas.
Faculdade de Engenharia Elétrica e de Computação. III. Título.

Título em Inglês: Decomposition of linearly mixed surface electromyographic signals using
independent component analysis

Palavras-chave em Inglês: Electromyography, Detection and signal processing, Entropy
(Information theory), Theory of estimation - Data processing,
Biomedical engineering

Área de concentração: Engenharia Biomédica

Titulação: Mestre em Engenharia Elétrica

Banca examinadora: Leonardo Tomazeli Duarte, Eduardo Tavares Costa

Data da defesa: 13-06-2012

Programa de Pós Graduação: Engenharia Elétrica

COMISSÃO JULGADORA - TESE DE MESTRADO

Candidato: Tiago Paggi de Almeida

Data da Defesa: 13 de junho de 2012

Título da Tese: "Decomposição de Sinais Eletromiográficos de Superfície Misturados Linearmente Utilizando Análise de Componentes Independentes"

Prof. Dr. Antônio Augusto Fasolo Quevedo (Presidente): Antônio Augusto Quevedo

Prof. Dr. Leonardo Tomazeli Duarte: Leonardo Tomazeli Duarte

Prof. Dr. Eduardo Tavares Costa: Eduardo Tavares Costa

Resumo

A eletromiografia é uma prática clínica que permite inferir sobre a integridade do sistema neuromuscular, o que inclui a análise da unidade funcional contrátil do sistema neuromuscular, a unidade motora. O sinal eletromiográfico é um sinal elétrico resultante do transiente iônico devido potenciais de ação de unidades motoras capturados por eletrodos invasivos ou não invasivos. Eletrodos invasivos capturam potenciais de ação de até uma única unidade motora, porém o procedimento é demorado e incômodo. Eletrodos de superfície permitem detectar potenciais de ação de modo não invasivo, porém resultam na mistura de potenciais de ação de várias unidades motoras, resultando em um sinal com aparência de ruído aleatório, dificultando uma análise. Técnicas de Separação Cega de Fontes, como Análise de Componentes Independentes, têm se mostrado eficientes na decomposição de sinais eletromiográficos de superfície nos constituintes potenciais de ação de unidades motoras. Este projeto tem como objetivo desenvolver um protótipo capaz de capturar sinais mioelétricos de superfície e analisar a viabilidade da separação de sinais eletromiográficos intramusculares misturados linearmente, utilizando Análise de Componentes Independentes. O sistema proposto integra uma matriz de eletrodos com até sete canais, um módulo de pré-processamento, um software para controle da captura dos sinais eletromiográficos de superfície e o algoritmo FastICA em ambiente MATLAB® para separação dos sinais eletromiográficos. Os resultados mostram que o sistema foi capaz de capturar sinais eletromiográficos de superfície e os sinais eletromiográficos intramusculares misturados linearmente foram separados de forma confiável.

Palavras-chave: *Eletromiografia de Superfície, Separação Cega de Fontes, Análise de Componentes Independentes, Processamento de Sinais Biológicos.*

Abstract

Electromyography is a clinical practice that provides information regarding the physiological condition of the neuromuscular system, which includes the analysis of the contractile functional unit of the neuromuscular system, known as motor unit. The electromyographic signal is an electrical signal resultant from ionic transient regarding motor unit action potentials captured by invasive or non-invasive electrodes. Invasive electrodes are able to detect action potentials of even one motor unit, although the procedure is time consuming and uncomfortable. Surface electrodes enable detecting action potential non-invasively, although the detected signal is a mixture of action potentials from several motor units within the detection area of the electrode, resulting in a complex interference pattern which is difficult to interpret. Blind Source Separation techniques, such as Independent Component Analysis, have proven effective for decomposing surface electromyographic signals into the constituent motor unit action potentials. The objective of this project was to develop a system in order to capture surface myoelectric signals and to analyze the viability for decomposing intramuscular myoelectric signals that were mixed linearly, using independent component analyzes. The system includes an electrode matrix with up to seven channels, a pre-processing module, a software for controlling surface myoelectric signals capture, and the FastICA algorithm in MATLAB® for the intramuscular myoelectric signals decomposition. The results show that the system was able to capture surface myoelectric signals and was capable of decomposing the intramuscular myoelectric signals that were previously linearly mixed.

Keywords: *Surface Electromyography, Blind Source Separation, Independent Components Analysis, Biological Signal Processing.*

Aos meus amados pais, irmã e esposa.

Agradecimentos

Inicialmente gostaria de agradecer, o que eu acredito ser, a Força Maior, que nos guia, orienta e nos protege,

a minha esposa Karina, pelo encanto da sua convivência, pelo amor e por sempre me dar a coragem necessária para seguir meus sonhos mesmo em tempos adversos,

aos meus pais Paulo e Fátima, meu porto seguro, e minha irmã Carolina, que sempre me apoiaram e guiaram nas minhas decisões,

ao meu orientador, Prof. Dr. Antônio Augusto Fasolo Quevedo, que esteve sempre presente em todas as etapas do projeto, desde a idéia à implementação e que acreditou no meu potencial em um momento que ninguém mais o faria,

a todos os professores do Departamento de Engenharia Biomédica, em especial ao Prof. Dr. José Bassani pelas valiosas dicas quanto à confecção dos eletrodos de prata cloretada com dimensão reduzida,

a Prof. Dra. Anamarli Nucci, da Faculdade de Ciências Médicas, pelas valiosas sugestões quanto ao Comitê de Ética,

ao Instituto Eldorado, em especial a Haroldo Onisto, Rodrigo Giroto e Renato Silva, por gentilmente confeccionarem as placas de circuito impresso utilizadas neste trabalho,

a Freescale Brasil por gentilmente doar o módulo Tower MC9S08MM,

aos amigos e colegas do grupo de Engenharia de Reabilitação, em especial a Alexandre Ferri, Jeferson Genaro, Ricardo Lanna pelas ricas conversas e discussões,

aos amigos e colegas de Mestrado, em especial a Jair Goulart, Leard Oliveira e Fernando Andrade e pelas discussões, sugestões, risadas, amizade e constante apoio,

a todos os amigos, funcionários e técnicos do Departamento de Engenharia Biomédica e Centro de Engenharia Biomédica da UNICAMP,

a todos os meus amigos pelas horas de lazer e por tornar a vida mais alegre, em especial a Guilherme Pimentel pelas ligações em plena madrugada e amizade sem preço,

a todos àqueles que direta ou indiretamente ajudaram a tornar meus sonhos possíveis.

Apoio

Este trabalho contou com o apoio financeiro do CNPq – Conselho Nacional de Desenvolvimento Científico e Tecnológico, processo 134491/2010-6.

Sumário

LISTA DE FIGURAS.....	XVII
LISTA DE TABELAS.....	XXI
LISTA DE ABREVIÇÕES.....	XXIII
CAPÍTULO 1 – INTRODUÇÃO	25
CAPÍTULO 2 – OBJETIVO	29
CAPÍTULO 3 – REVISÃO BIBLIOGRÁFICA.....	31
3.1 A ELETROMIOGRAFIA.....	33
3.1.1 A Unidade Motora	33
3.1.2 O Potencial de Ação.....	34
3.1.3 A Contração Muscular.....	36
3.1.4 O Sinal Eletromiográfico	37
3.1.5 Eletrodos Invasivos.....	39
3.1.6 Eletrodos de Superfície.....	40
3.1.7 Configuração dos Eletrodos.....	42
3.1.8 Fatores que Afetam o Sinal Eletromiográfico.....	44
3.1.9 Eletrônica do Sistema de Detecção de Sinais Eletromiográficos	45
3.2 SEPARAÇÃO CEGA DE FONTES.....	46
3.2.1 A Separação de Fonte por ICA	49
3.2.2 Pré-processamento para ICA.....	50
3.2.3 Medidas de Gaussianidade.....	54
3.2.4 FastICA	59
3.2.5 Outros Métodos de Separação Cega de Fontes	62

CAPÍTULO 4 – MATERIAIS E MÉTODOS	67
4.1 SISTEMA PARA CAPTURA E SEPARAÇÃO DE SINAIS ELETROMIOGRÁFICOS	67
4.1.1 Fonte de Alimentação	68
4.1.2 Matriz de Eletrodos.....	69
4.1.3 Primeiro Estágio de Amplificação.....	70
4.1.4 Segundo estágio de Amplificação	73
4.1.5 Grampeador de Tensão	74
4.1.6 Conversor A/D.....	75
4.1.7 Interface de Comunicação Serial	77
4.1.8 Interface Periférica Serial.....	77
4.1.9 O TOWER MC9S08MM.....	78
4.1.10 O Computador Pessoal.....	81
4.1.11 Software de Captura	81
4.1.12 Software para Decomposição dos Sinais EMG.....	84
4.2 VALIDAÇÃO.....	87
4.2.1 Especificações Técnicas do Sistema de Captura.....	87
4.2.2 Captura de Sinais Eletromiográficos de Superfície.....	88
4.2.3 Separação de Sinais Conhecidos	89
4.2.4 Separação de Sinais Eletromiográficos	94
4.2.5 Métricas Utilizadas na Análise dos Resultados.....	96
CAPÍTULO 5 – RESULTADOS	99
5.1 ESPECIFICAÇÕES TÉCNICAS DO SISTEMA DE CAPTURA.....	99
5.2 CAPTURA DE SINAIS ELETROMIOGRÁFICOS DE SUPERFÍCIE.....	101
5.2.1 Eletrodos Comerciais	101
5.2.2 Matriz de Eletrodos.....	103
5.3 SEPARAÇÃO DE SINAIS CONHECIDOS.....	105
5.4 SEPARAÇÃO DE SINAIS ELETROMIOGRÁFICOS	113
CAPÍTULO 6 – DISCUSSÃO.....	119
6.1 ESPECIFICAÇÕES TÉCNICAS DO SISTEMA DE CAPTURA.....	119
6.2 CAPTURA DE SINAIS ELETROMIOGRÁFICOS DE SUPERFÍCIE.....	121
6.2.1 Eletrodos Comerciais	122
6.2.2 Matriz de Eletrodos.....	123
6.3 SEPARAÇÃO DE SINAIS CONHECIDOS.....	124
6.4 SEPARAÇÃO DE SINAIS ELETROMIOGRÁFICOS	128
6.5 CONSIDERAÇÕES GERAIS E TRABALHOS FUTUROS	129

CAPÍTULO 7 – CONCLUSÃO	133
REFERÊNCIAS BIBLIOGRÁFICAS	135
APÊNDICE A – CONSTINUAÇÃO DOS RESULTADOS.....	143

Lista de Figuras

Figura 3.1 – Representação de uma unidade motora (Modificado de Pozzo <i>et al</i> , 2004a).	33
Figura 3.2 – Estruturas do músculo esquelético. O músculo esquelético é envolto por um tecido conjuntivo, a fâscia. O músculo é composto por estruturas chamadas fascículos, formadas por fibras musculares. As fibras possuem miofibrilas, compostas por miofilamentos e por sarcômeros, a unidade contrátil muscular (Modificado de Felici & Sbriccoli, 2006).	34
Figura 3.3 – Representação de um potencial de ação (PA) vinculado à variações na condutância da membrana de células excitáveis para íons de Na^+ e K^+ (Modificado de Loeb & Ghez, 2000). Explicação no texto.	35
Figura 3.4 – Representação da junção neuromuscular e o acoplamento excitação contração (Modificado de Won, 2012). Explicação no texto.	36
Figura 3.5 – Representação de duas UMs propagando MUAPs e a captura de sinal sEMG.	37
Figura 3.6 – Efeito do volume condutor em sinais EMG. a) Mapeamento entre ganho e frequência de sinais sEMG em relação à distância (D) entre fonte (UM) e a área de captura (Modificado de Pozzo <i>et al</i> , 2004a). b) Representação do sinal EMG capturado por meio invasivo e não invasivo em diferentes distâncias entre fonte (UM) e a área de captura. É possível notar como sinais invasivos capturados mais próximos da UM possuem sinais com “picos” e “vales” mais evidentes (Modificado de Zwarts & Stegeman, 2003).	38
Figura 3.7 – Eletrodos invasivos (Modificado de De Luca, 2006). a) Exemplos de tipos de eletrodos de agulha. O lado direito mostra, em detalhe, a área ativa de captura do eletrodo. De cima para baixo: 1) Eletrodo de agulha sólido para única fibra. A área escura representa a superfície da agulha; 2) Eletrodo de agulha concêntrica com uma superfície de detecção monopolar formado pela área transversal de um fio com diâmetro de $200\mu\text{m}$; 3) Eletrodo de agulha concêntrica com duas superfícies de detecção monopolar; 4) Eletrodo para detectar uma fibra muscular pela área transversal de um fio de diâmetro de $25\mu\text{m}$; 5) Macroeletrodo com área transversal do fio de diâmetro de $25\mu\text{m}$ e com a cânula da agulha (área escura) utilizada como superfície de captura; 6) Eletrodo quadrifilar com quatro fios com área transversal de diâmetro $50\mu\text{m}$; 7) Eletrodo multifilar com uma fileira de eletrodos. b) Eletrodo de fio bipolar.	39
Figura 3.8 – Sinal EMG resultante da mistura de vários MUAPs (Modificado de De Luca, 2006).	40
Figura 3.9 – Exemplo de eletrodos de superfície. a) Esquema de eletrodo de superfície passivo com as constituintes estruturas (Modificado de Pozzo <i>et al</i> , 2004a). b) Eletrodo de superfície bipolar ativo, com espaço entre barras de 10mm, espessura das barras 1mm e 10mm de comprimento (Modificado de De Luca, 2006).	41
Figura 3.10 – Configuração de eletrodos (Modificado de De Luca, 2006). a) Configuração monopolar. b) Configuração bipolar.	43
Figura 3.11 – Amplitude e frequência do sinal EMG em relação ao posicionamento de eletrodos (Modificado de De Luca, 1997).	45

Figura 3.12 – Ilustração do <i>Cocktail-party Problem</i> (Modificado de Duarte, 2006).....	47
Figura 3.13 – A modelagem da eletromiografia na separação cega de fontes considerando apenas três UMs e três sinais sEMG bipolares. Os MUAPs são fontes independentes $s_n(t)$, o tecido subcutâneo e outros fatores influenciam a matriz de mistura \mathbf{A} e os sinais EMG capturados são as misturas $x_m(t)$	48
Figura 3.14 – Modelo do Problema de Separação Cega de Fontes (Modificado de Duarte, 2006).....	49
Figura 3.15 – Etapas para Separação Cega de Fontes.....	50
Figura 3.16 – Ilustração da PCA. a) <i>Scatter plot</i> entre duas variáveis com distribuição dos dados observados após mistura indicando duas componentes principais. b) Relação entre as componentes principais (autovetores) e os respectivos autovalores (Modificado de Semmlow & Yuan, 2002).....	53
Figura 3.17 – Exemplo de branqueamento de duas fontes independentes (s_1, s_2) com distribuição uniforme (Modificado de Suyama, 2007). (a) Distribuição das fontes originais (s_1, s_2). (b) Distribuição dos dados observados após a mistura (x_1, x_2). (c) Distribuição após o branqueamento (x'_1, x'_2).....	53
Figura 3.18 – Representação do plano da curtose limitado pelo círculo unitário em \mathbf{q} . Explicação no texto. (Modificado de Hyvärinen <i>et al</i> , 2001).....	55
Figura 3.19 – Representação da varredura da matriz de separação \mathbf{W} pra localizar pontos de curtose mínima ou máxima. a) Rotação de \mathbf{W} no gráfico de dispersão entre duas variáveis branqueadas gerando a combinação linear $\mathbf{W}^T \mathbf{z}$. b) Diferentes valores de curtose em função do ângulo de \mathbf{W} em $\mathbf{W}^T \mathbf{z}$ (Modificado de Hyvärinen <i>et al</i> , 2001). 56	56
Figura 3.20 – Distribuição de duas variáveis gaussianas. (Modificado de Hyvärinen & Oja, 2000).....	57
Figura 3.21 – Entropia ($H(p)$) referente à probabilidade (p) vinculada ao lançamento de uma moeda (Modificado de Cover & Thomas, 1991).....	58
Figura 3.22 – Relação entre entropia e informação mútua (Modificado de Cover & Thomas, 1991).	65
Figura 3.23 – Estrutura do sistema separador no critério Infomax (Modificado de Romano <i>et al</i> , 2009).	66
Figura 4.1 – Diagrama em blocos do sistema de captura e separação de sinais eletromiográficos de superfície.	67
Figura 4.2 – Matriz de eletrodos com oito elementos em uma fileira. Cada eletrodo tem 2mm de diâmetro. Oito elementos permitem até sete canais bipolares. a) Esquemático da matriz de eletrodos compondo o suporte de acrílico e os oito eletrodos de Ag-AgCl. b) Foto da matriz de eletrodos que foi utilizada na validação deste trabalho.	70
Figura 4.3 – Amplificador de biopotenciais para um canal, integrando um amplificador de instrumentação INA129 com ganho de 20dB, filtro passa-alta acoplado ao INA129 frequência de corte em 10Hz e um filtro passa-baixa Butterworth de dois pólos, na configuração Sallen-Key, com frequência de corte de 1kHz.	72
Figura 4.4 – Configuração dos amplificadores diferenciais dos sete canais.	72
Figura 4.5 – Níveis de atenuação/ganho logaritmo do PGA (Modificado de National Semiconductor, 1994).....	74
Figura 4.6 – LM1973 na realimentação de um amplificador operacional. Nessa condição, o sistema atua como amplificador de ganho logarítmico (Modificado de National Semiconductor, 1994).....	74
Figura 4.7 – Circuito grampeador de tensão.	75
Figura 4.8 – Diagrama funcional do SPI (Modificado de Freescale, 2010a).	78

Figura 4.9 – Fluxograma dos processos controlados pelo TWR-S08MM128.	80
Figura 4.10 – Fluxograma para o software de captura e controle de ganho.	83
Figura 4.11 – Interface gráfica do software de captura e controle de ganho.	84
Figura 4.12 – Fluxo de dados do sistema de análise e decomposição de sinais EMG.	85
Figura 4.13 – Interface gráfica do software para decomposição de sinais EMG.	85
Figura 4.14 – Quatro etapas da validação do sistema.	87
Figura 4.15 – Circuito de mistura para sinais conhecidos.	90
Figura 4.16 – Configuração de montagem para captura dos sinais conhecidos.	90
Figura 4.17 – Domínio do tempo e da frequência de fontes que foram posteriormente misturadas e utilizadas na validação da separação de sinais conhecidos. a) Senóide 40Hz; b) Senóide 500Hz; c) Ruído branco; d) <i>User1</i> ; e) <i>User2</i> ; f) <i>User3</i> ; g) <i>Waveform</i> ; h) <i>Burst</i> 100Hz.	93
Figura 4.18 – Sinais utilizados na validação de separação de sinais EMG em pares no domínio do tempo e frequência. Esses sinais estão no site da Physiobank (Physiobank, 2011). a) sinal EMG saudável de um paciente do sexo masculino de 44 anos; b) sinal EMG com miopatia devido polimiosite de um paciente do sexo masculino de 57 anos; c) sinal EMG com neuropatia como consequência de radiculopatia de um paciente do sexo masculino de 62 anos; d) ruído gaussiano gerado pelo MATLAB®.	95
Figura 5.1 – Ganho e resposta em frequência do filtro passa-faixa com frequência de corte inferior em aproximadamente 10Hz e frequência de corte superior em aproximadamente 900Hz.	100
Figura 5.2 – Linearidade do conversor A/D com coeficiente de linearidade $R^2 = 1,00$	100
Figura 5.3 – Domínio do tempo e frequência da primeira captura de sinal sEMG com eletrodos comerciais. O gráfico superior mostra 5s do sinal sEMG na primeira captura. O gráfico do meio mostra o detalhe de 500ms do sinal sEMG na primeira captura. O gráfico inferior mostra análise espectral dos 5s do sinal sEMG na primeira captura.	101
Figura 5.4 – Domínio do tempo e frequência da segunda captura de sinal sEMG com eletrodos comerciais. O gráfico superior mostra 5s do sinal sEMG na segunda captura. O gráfico do meio mostra o detalhe de 500ms do sinal sEMG na segunda captura. O gráfico inferior mostra análise espectral dos 5s do sinal sEMG na segunda captura.	102
Figura 5.5 – Domínio do tempo e frequência da terceira captura de sinal sEMG com eletrodos comerciais. O gráfico superior mostra 5s do sinal sEMG na terceira captura. O gráfico do meio mostra o detalhe de 500ms do sinal sEMG na terceira captura. O gráfico inferior mostra análise espectral dos 5s do sinal sEMG na terceira captura.	102
Figura 5.6 – Primeira captura de sinal sEMG com a matriz de eletrodos: a) 5s do sinal sEMG na primeira captura. A área demarcada mostra os 500ms em análise. b) Detalhe de 500ms sinal sEMG na primeira captura. Área em destaque mostra possíveis MUAPs. c) Análise espectral dos 5s do sinal sEMG na primeira captura.	104
Figura 5.7 – Resultados da separação de sinais originais do Teste 1. a) SIR entre fontes originais e misturas para a captura 1. b) SIR e Correlação entre fontes originais e fontes separadas para a captura 1. c) SIR e Correlação entre fontes originais e fontes separadas. d) Média de Correlação entre fontes originais e fontes separadas. e) SIR e Correlação entre fontes originais.	106
Figura 5.8 – Resultados da separação de sinais conhecidos do Teste 2. a) SIR entre fontes conhecidas e misturas para a captura 1. b) SIR e Correlação entre fontes conhecidas e fontes separadas para a captura 1. c) SIR e Correlação	

entre fontes conhecidas e fontes separadas. d) Média de Correlação entre fontes conhecidas e fontes separadas. e) SIR e Correlação entre fontes conhecidas.....	107
Figura 5.9 – Resultados da separação de sinais conhecidos do Teste 3. a) SIR entre fontes conhecidas e misturas para a captura 1. b) SIR e Correlação entre fontes conhecidas e fontes separadas para a captura 1. c) SIR e Correlação entre fontes conhecidas e fontes separadas. d) Média de Correlação entre fontes conhecidas e fontes separadas. e) SIR e Correlação entre fontes conhecidas.....	108
Figura 5.10 – Resultados da separação de sinais conhecidos do Teste 4. a) SIR entre fontes conhecidas e misturas para a captura 1. b) SIR e Correlação entre fontes conhecidas e fontes separadas para a captura 1. c) SIR e Correlação entre fontes conhecidas e fontes separadas. d) Média de Correlação entre fontes conhecidas e fontes separadas. e) SIR e Correlação entre fontes conhecidas.....	109
Figura 5.11 – Resultados da separação de sinais conhecidos do Teste 5. a) SIR entre fontes conhecidas e misturas para a captura 1. b) SIR e Correlação entre fontes conhecidas e fontes separadas para a captura 1. c) SIR e Correlação entre fontes conhecidas e fontes separadas. d) Média de Correlação entre fontes conhecidas e fontes separadas. e) SIR e Correlação entre fontes conhecidas.....	110
Figura 5.12 – Resultados da separação de sinais conhecidos do Teste 6. a) SIR entre fontes conhecidas e misturas para a captura 1. b) SIR e Correlação entre fontes conhecidas e fontes separadas para a captura 1. c) SIR e Correlação entre fontes conhecidas e fontes separadas. d) Média de Correlação entre fontes conhecidas e fontes separadas. e) SIR e Correlação entre fontes conhecidas.....	111
Figura 5.13 – Três misturas capturadas para o Teste 2, no domínio do tempo e da frequência, que engloba as fontes originais <i>burst</i> , senóide de 500Hz e ruído branco. a) Mistura 1. b) Mistura 2. c) Mistura 3.....	112
Figura 5.14 – Três sinais estimados pelo processo de separação para o Teste 2, no domínio do tempo e da frequência, que engloba as fontes originais <i>burst</i> , senóide de 500Hz e ruído branco. a) Resultado A separou o <i>burst</i> . b) Resultado B separou o ruído. c) Resultado C separou a senóide de 500Hz.....	113
Figura 5.15 – Resultados da separação dos sinais EMG do Teste 1. a) SIR entre sinais EMG originais e sinais misturados. b) SIR e Correlação entre sinais EMG originais e fontes estimadas.....	114
Figura 5.16 – Resultados da separação dos sinais EMG do Teste 2. a) SIR entre sinais EMG originais e sinais misturados. b) SIR e Correlação entre sinais EMG originais e fontes estimadas.....	114
Figura 5.17 – Resultados da separação dos sinais EMG do Teste 3. a) SIR entre sinais EMG originais e sinais misturados. b) SIR e Correlação entre sinais EMG originais e fontes estimadas.....	115
Figura 5.18 – Resultados da separação dos sinais EMG do Teste 4. a) SIR entre sinais EMG originais e sinais misturados. b) SIR e Correlação entre sinais EMG originais e fontes estimadas.....	115
Figura 5.19 – Resultados da separação dos sinais EMG do Teste 5. a) SIR entre sinais EMG originais e sinais misturados. b) SIR e Correlação entre sinais EMG originais e fontes estimadas.....	115
Figura 5.20 – Quatro misturas geradas com os sinais mostrados na Figura 4.18 para o segundo teste da separação de sinais EMG, no domínio do tempo e da frequência. a) Mistura 1. b) Mistura 2. c) Mistura 3. d) Mistura 4.	116
Figura 5.21 – Quatro sinais EMG estimados para o segundo teste da separação de sinais EMG, no domínio do tempo e da frequência. a) Resultado A separou o sinal EMG com neuropatia. b) Resultado B separou o sinal EMG saudável. c) Resultado C separou o sinal EMG com miopatia. d) Resultado D separou ruído branco.....	117

Lista de Tabelas

Tabela 4.1 – Relação de fontes utilizadas em cada teste. As fontes 40Hz e 500Hz referem-se à senóides com frequências equivalentes; o ruído branco é um sinal que apresenta componentes de frequência em toda a faixa espectral; as fontes *User1*, *User1*, *User3* e *Waveform* são ondas que estavam previamente gravadas na memória do gerador de função e tiveram apenas a amplitude de tensão ajustadas; o *burst* é uma forma de onda que é caracterizada por segmentos de atividade e segmentos de ausência de sinal. No caso, os segmentos de atividade foram configurados como senóides de 100Hz espaçados por períodos de ausência de sinal. 91

Tabela 5.1 – Ruído do Sistema de Captura. A análise 1 mostra o ruído do sistema considerando ganho mínimo inicial; a análise 2 mostra o ruído do sistema após ajuste dos ganhos de cada canal com influência do ganho; a análise 3 mostra o ruído do sistema após ajuste dos ganhos de cada canal, referente à entrada. 100

Lista de Abreviações

- Conversor A/D: Conversor Analógico/Digital
- AMUSE: *Algorithm for Multiple Unknown Source Extraction* – Algoritmo para Extração de Múltiplos Sinais Desconhecidos
- CEB: Centro de Engenharia Biomédica
- CMRR: *Common-Mode Rejection Ratio* – Razão de Rejeição de Modo Comum
- fdp: função de densidade de probabilidade
- ICA: *Independent Component Analysis* – Análise de Componentes Independentes
- Infomax: *Information Maximization* – Maximização da Informação
- JADE: *Joint Approximate Diagonalization of Eigenmatrices*
- LPCv: Laboratório de Pesquisa Cardiovascular
- MOSI: *Master Out Slave In* – Saída do Mestre Entrada do Escravo
- MPF: Método do Ponto Fixo
- MUAP: *Motor Unit Action Potential* – Potencial de Ação de uma Unidade Motora
- PA: Potencial de Ação
- PCA: *Principal Component Analysis* – Análise de Componentes Principais
- PDB: *Programmable Delay Block* – Bloco de Atraso Programável
- PGA: *Programmable Gain Amplifier* – Programador de Ganho Programável
- RNA: Redes Neurais Artificiais
- SCA: *Sparse Component Analysis* – Análise por Componentes Esparsos
- SCI: *Serial Communication Interface* – Interface de Comunicação Serial
- Sinal EMG: Sinal Eletromiográfico
- Sinal sEMG: Sinal Eletromiográfico de Superfície
- SIR: *Signal-to-Interference Ratio* – Relação Sinal Interferência

- SNC: Sistema Nervoso Central
- SOBI: *Second-Order Blind Identification* – Identificação Cega de Segunda Ordem
- SPI: *Serial Peripheral Interface* – Interface Periférica Serial
- PC: *Personal Computer* – Computador Pessoal
- UM: Unidade Motora

Capítulo 1

Introdução

A eletromiografia é uma técnica clínica que resulta em um sinal elétrico que representa o transiente iônico devido à potenciais de ação propagados pela membrana celular de fibras musculares previamente a uma contração muscular. Esses potenciais de ação são fenômenos bioquímicos tudo-ou-nada que, uma vez disparados, são propagados longitudinalmente às fibras musculares, disparando vias bioquímicas que culminam na contração muscular. Os transientes iônicos relacionados aos potenciais de ação das fibras musculares são propagados através do tecido subcutâneo devido a um fenômeno conhecido como volume condutor. Eletrodos invasivos ou não invasivos capturam e convertem os transientes iônicos propagados no volume condutor em sinais elétricos. A atividade elétrica capturada com o uso da eletromiografia é conhecida como sinal eletromiográfico, ou eletromiograma, e sua análise permite inferir sobre a integridade e o estado fisiológico do sistema neuromuscular como um todo e de suas componentes, que incluem neurônios motores, junções neuromusculares e fibras musculares.

A unidade funcional contrátil do sistema neuromotor engloba diversas fibras musculares inervadas por um mesmo neurônio motor, e é conhecida como unidade motora. Um músculo é composto por milhares de unidades motoras. Portanto, a análise da integridade e do estado

fisiológico do sistema neuromotor implica na análise das unidades motoras que compõem um músculo.

A contração de uma unidade motora tem início quando potenciais de ação são propagados através do axônio de um neurônio motor. Esses potenciais de ação despolarizam terminações axônicas, disparando a liberação de neurotransmissores na junção neuromuscular. Os neurotransmissores podem se associar com canais iônicos presentes na membrana das fibras musculares da unidade motora, alterando sua permeabilidade iônica, gerando um fluxo iônico, alterando, por sua vez, o potencial elétrico da membrana celular. Caso esse potencial atinja certo patamar, um potencial de ação é disparado e propagado longitudinalmente através da membrana das fibras musculares da unidade motora, disparando vias bioquímicas que culminam na contração da unidade motora. A composição de potenciais de ação gerados pelas fibras musculares inervadas pelo mesmo neurônio motor é chamada de potencial de ação da unidade motora. A eletromiografia visa capturar esses sinais mioelétricos.

Em condições patológicas do sistema neuromotor, as características dos potenciais de ação das unidades motoras podem sofrer alterações. Logo, sinais eletromiográficos são amplamente utilizados em diagnósticos de doenças neuromusculares, análise de marcha, acompanhamento fisioterapêutico, análise de fadiga muscular, ativação de próteses, entre outros.

A captura de sinais eletromiográficos pode ser feita de forma invasiva e não invasiva. O método invasivo é realizado com o uso de eletrodos de agulha ou fios, permitindo a captura de potenciais de ação de até uma única unidade motora. Desta forma pode-se inferir, através dessa configuração, sobre a anatomia das fibras musculares e a taxa de disparo do neurônio motor. Contudo, essas técnicas invasivas tendem a ser muito demoradas e desconfortáveis ao paciente, além de danificar tecidos e serem foco para potenciais infecções.

As técnicas não invasivas utilizam eletrodos de superfície sem a necessidade do uso de eletrodos de agulhas ou fios. Porém, a área de captura desses eletrodos é grande, o que leva a uma visão mais global do músculo. Essa configuração permite localizar zonas de inervação e inferir a velocidade de condução dos potenciais de ação nas fibras musculares.

Os sinais eletromiográficos capturados com eletrodos de superfície são superposições espaço-temporais de potenciais de ação de várias unidades motoras dentro do limite de abrangência do eletrodo que depende de inúmeros fatores, resultando em um sinal com aparência de ruído aleatório, de difícil interpretação, o que dificulta a análise dos potenciais de ação de uma única unidade motora. Desta forma, é impossível inferir sobre os potenciais de ação das unidades motoras individualmente e sobre a função de mistura que ocorre durante a propagação dos potenciais de ação até a superfície da pele devido aos diversos tecidos presentes entre o ponto de geração dos potenciais de ação até o ponto de captura do sinal eletromiográfico. Logo, a eletromiografia de superfície ainda possui algumas limitações que devem ser entendidas e consideradas para seu bom uso como, por exemplo, a influência de sinais mioelétricos provenientes de músculos adjacentes, que podem gerar ruídos ou *crosstalk* no sinal capturado. Adicionalmente, a estratégia de recrutamento de músculos esqueléticos realizado pelo sistema nervoso central é complexa, e baseia-se em mais músculos que o estritamente necessário para um único movimento, o que pode aumentar ainda mais a complexidade do sinal eletromiográfico.

Pesquisadores vêm analisando técnicas para decompor sinais EMG em suas constituintes MUAPs com objetivo final de isolar a atividade elétrica de cada uma das UMs presentes na área de captura do eletrodo para os diversos fins. O sinal EMG decomposto fornece todas as informações disponíveis no sinal EMG. As informações de tempo fornecem uma descrição completa sobre o intervalo interpulso, taxa de disparo e características de sincronismo entre UMs. A morfologia das formas dos MUAPs fornecem informações sobre a anatomia e condição fisiológica das fibras musculares.

Um dos principais temas em processamento de sinais diz respeito à recuperação de sinais de interesse (fontes) através unicamente da observação de misturas desses mesmos sinais. Este paradigma representa o princípio essencial do processamento não-supervisionado (cego) de sinais, e, conseqüentemente, da separação cega de fontes. Na separação cega de fontes, a recuperação dos sinais de interesse é feita com base apenas em suas misturas. No problema proposto neste trabalho, tem-se somente conhecimento dos sinais eletromiográficos de superfície que são misturas dos sinais de interesse, ou seja, potenciais de ação das unidades

motoras. Contudo, não se tem conhecimento prévio do sistema de mistura, tampouco da atividade elétrica das unidades motoras individualmente.

A separação cega de fontes compreende métodos que visam estimar sinais originais, ou fontes, a partir de um conjunto de misturas que contém as fontes. Um desses métodos é a análise de componentes independentes, uma técnica de processamento de sinal que visa expressar um conjunto de variáveis aleatórias como sendo combinações lineares de variáveis estatisticamente independentes. Nesse contexto, observam-se m variáveis aleatórias x_1, x_2, \dots, x_m que, assume-se, são combinações lineares de n componentes desconhecidas s_1, s_2, \dots, s_n , estatisticamente independentes. Adicionalmente, assume-se que $n \leq m$. Arranjando as variáveis observadas x_i em um vetor $\mathbf{x} = (x_1, x_2, \dots, x_m)^T$ e as componentes s_i em um vetor $\mathbf{s} = (s_1, s_2, \dots, s_n)^T$, tem-se a seguinte relação linear:

$$\mathbf{x} = \mathbf{A}\mathbf{s} \quad (1.1)$$

onde \mathbf{A} é uma matriz de mistura desconhecida $m \times n$.

A análise de componentes independentes visa estimar as componentes originais de s_i a partir das misturas x_m ou, de forma equivalente, estimar a matriz de mistura \mathbf{A} . Essa técnica, contudo, consegue estimar somente variáveis independentes com distribuição não-gaussiana, com somente uma das fontes podendo ter distribuição gaussiana. Adicionalmente, a análise de componentes independentes não consegue estimar a amplitude do sinal e tampouco a variância das fontes.

Neste contexto, pode-se considerar os sinais eletromiográficos de superfície como sendo as variáveis observadas (x_1, x_2, \dots, x_m) , e as componentes desconhecidas (s_1, s_2, \dots, s_n) assumem o papel dos potenciais de ação das unidades motoras. Logo, estimar as componentes de \mathbf{s} implica em decompor os sinais eletromiográficos de superfície \mathbf{x} nos constituintes potenciais de ação das unidades motoras.

Capítulo 2

Objetivo

ESTE projeto tem como objetivo desenvolver um sistema multicanais capaz de capturar sinais eletromiográficos de superfícies fidedignos, gerando um ambiente propício para a utilização da análise de componentes independentes na decomposição de sinais eletromiográficos em suas constituintes componentes, e realizar uma análise inicial da viabilidade da utilização da análise de componentes independentes na decomposição de sinais com as características dos sinais eletromiográficos através de um cenário controlado ao misturar linearmente sinais eletromiográficos intramusculares provenientes de um banco de dados.

Capítulo 3

Revisão Bibliográfica

A eletromiografia engloba a captura de sinais elétricos gerados previamente à contração de um músculo esquelético. O sinal eletromiográfico (sinal EMG) pode ser definido como a soma algébrica dos potenciais de ação (PA) das unidades motoras (UM) dentro do limite de abrangência de um eletrodo (Basmajian & De Luca, 1985). Desta forma, o sinal EMG é complexo e de difícil análise. O sinal EMG fornece informações importantes sobre a integridade do sistema neuromuscular e sobre o recrutamento de grupos musculares. Logo, é amplamente utilizado na área da saúde em diagnósticos de doenças neuromusculares (Wood *et al*, 2001; Drost *et al*, 2001), análise de marcha, acompanhamento fisioterapêutico e análise de fadiga muscular (Zwarts & Stegeman, 2003), ativação de próteses (Graupe & Cline, 1975), entre outros.

Com o objetivo de auxiliar na análise desse sinal para os diversos fins, pesquisadores têm trabalhado na decomposição de sinais EMG de superfície (sinais sEMG) nos constituintes PAs de cada UM (MUAP – *Motor Unit Action Potential*). O sinal EMG decomposto fornece todas as informações disponíveis no sinal EMG. As informações de tempo fornecem uma descrição completa sobre o intervalo interpulso, taxa de disparo e características de sincronismo entre UMs. A morfologia das formas dos MUAPs fornecem informações sobre a anatomia e condição fisiológica das fibras musculares (De Luca *et al*, 2006).

Técnicas de Separação Cega de Fontes (BSS – *Blind Source Separation*) têm se mostrado promissoras para separação de sinais sEMG, com aplicações em análise da estratégia do sistema nervoso central (SNC) na contração muscular, detecção de intervalos de ativação muscular e controle de próteses. Em 1982, LeFever e De Luca (LeFever & De Luca, 1982) desenvolveram uma técnica híbrida para a decomposição de sinais EMG invasivos que conta com a perícia do usuário na identificação de MUAPs e em técnicas estatísticas para cálculo da taxa de disparo dos MUAPs. Em 1985, McGill e colaboradores (McGill *et al*, 1985) conseguiram separar automaticamente MUAPs de sinais EMG invasivos utilizando filtros diferenciadores e análise espectral ao invés de técnicas no domínio do tempo. Um longo período se passou até que técnicas computacionais mais avançadas pudessem auxiliar nessa tarefa. Redes Neurais Artificiais (RNA) foram utilizadas para analisar e separar sinais EMG (Kelly *et al*, 1990; Hiraiwa *et al*, 1990; Gazzoni *et al*, 2004). Em 2004, Farina e colaboradores (Farina *et al*, 2004b) conseguiram separar sinais EMG de dois grupos musculares distintos utilizando técnicas de BSS que utilizam estatística de segunda ordem. No mesmo ano, Holobar e Zazula (Holobar & Zazula, 2004) desenvolveram um procedimento para decompor sinais sEMG também utilizando técnicas estatísticas de segunda ordem. Nakamura e colaboradores (Nakamura *et al*, 2004a; Nakamura *et al*, 2004b) conseguiram isolar MUAPs de uma mesma UM em uma componente independente a partir de sinais sEMG utilizando Análise de Componentes Independentes (ICA – *Independent Components Analysis*) e compararam os resultados com sinais descorrelacionados por Análise de Componentes Principais (PCA – *Principal Components Analysis*), concluindo que a ICA deve ser utilizada somente como um dentro de vários passos para decomposição de sinais sEMG. García e colaboradores (García *et al*, 2005) utilizaram ICA como uma etapa na decomposição de sinais sEMG em contrações até 60% da máxima contração voluntária, que incluía também uma série de filtros digitais (Usui & Amidror, 1982) além de técnicas de template matching. Em 2006, De Luca e colaboradores (De Luca *et al*, 2006) conseguiram separar sinais EMG com precisão de até 91% utilizando um complexo algoritmo que inclui filtros digitais, inteligência artificial e técnicas estatísticas. Em 2007, pesquisadores conseguiram identificar MUAPs a partir de sinais sEMG capturados com amplificadores monopulares, calculando as formas bipolares e a Laplaciana do sinal (Kleine *et al*, 2007).

3.1 A Eletromiografia

3.1.1 A UNIDADE MOTORA

O SNC envia comandos a músculos esqueléticos através de PAs por meio de axônios de neurônios motores alfa. O corpo celular desses neurônios é localizado na medula espinhal e suas terminações axônicas inervam fibras musculares, formando uma região conhecida como junção neuromuscular ou placa motora. Uma UM consiste em um conjunto de fibras musculares inervadas pelo mesmo neurônio motor alfa (LeFever & De Luca, 1982) (Figura 3.1). Os músculos esqueléticos são ligados aos ossos do esqueleto, possibilitando movimento. Esses músculos possuem fascículos que, por sua vez, são conjuntos de fibras musculares (Figura 3.2). O número de fibras musculares controladas por um único neurônio motor varia bastante, de 50 a 1000, e o número de UM presentes em um músculo, por sua vez, varia entre 10 a 3000 (Loeb & Ghez, 2000). Essas características dependem do grupo muscular em questão.

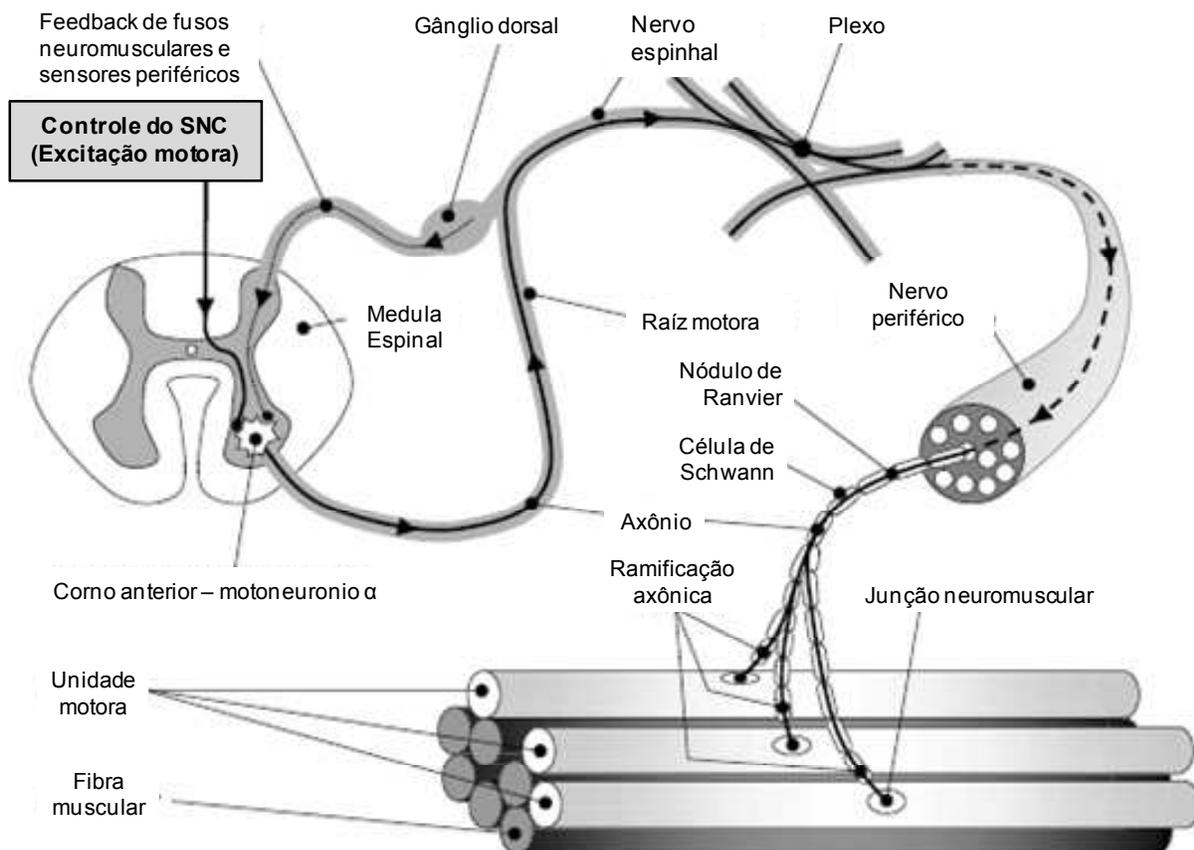


Figura 3.1 – Representação de uma unidade motora (Modificado de Pozzo *et al*, 2004a).

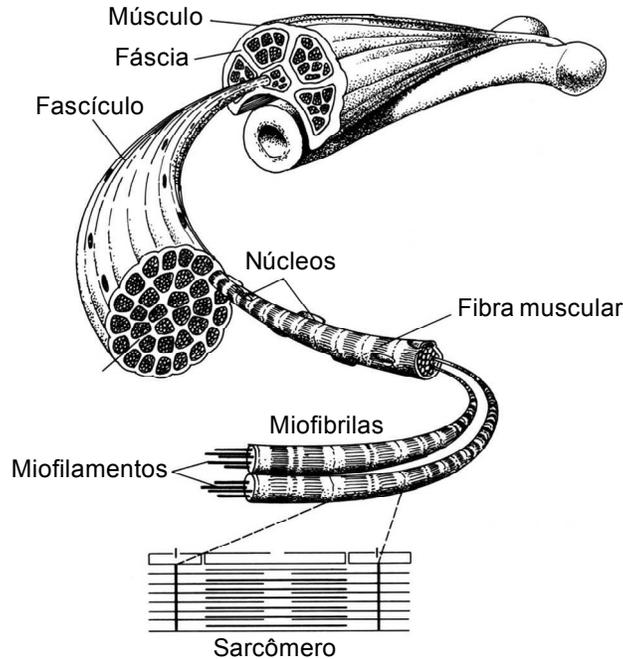


Figura 3.2 – Estruturas do músculo esquelético. O músculo esquelético é envolto por um tecido conjuntivo, a fáscia. O músculo é composto por estruturas chamadas fascículos, formadas por fibras musculares. As fibras possuem miofibrilas, compostas por miofilamentos e por sarcômeros, a unidade contrátil muscular (Modificado de Felici & Sbriccoli, 2006).

As fibras musculares são células multinucleadas delimitadas pelo sarcolema. Seu citoplasma é chamado de sarcoplasma, onde se encontra o retículo sarcoplasmático, que armazena Ca^{2+} , importante para contração muscular. Cada fibra muscular contém miofibrilas que ocupam quase todo o volume intracelular. As miofibrilas são formadas por um conjunto de sarcômeros, que por sua vez, são formados por filamentos grossos de proteínas polimerizadas de miosina e filamentos finos de actina. Esses filamentos são parcialmente intercalados e superpostos, e a interação entre eles promove a contração muscular (Loeb & Ghez, 2000).

3.1.2 O POTENCIAL DE AÇÃO

O PA é um fenômeno tudo-ou-nada caracterizado por variações do potencial elétrico ao longo da membrana celular observados em células excitáveis como neurônios e fibras musculares. A origem dessas variações ocorre devido alterações da permeabilidade, ou condutância, da membrana celular a certos íons.

Quando em repouso, a membrana é mais permeável ao K^+ e outros íons como Cl^- , Mg^{2+} e Ca^{2+} , porém é virtualmente impermeável ao Na^+ . Desta forma, o potencial da membrana celular

em repouso tende ao potencial de repouso do K^+ (Figura 3.3). Adicionalmente, a concentração de K^+ é maior no meio intracelular quando comparada ao meio extracelular, e a concentração de Na^{2+} é menor no meio intracelular quando comparada ao meio extracelular.

Quando excitada por neurotransmissores ou por variações no potencial elétrico nas suas imediações, a condutância da membrana ao Na^{2+} aumenta abruptamente, causando um influxo transiente de Na^{2+} na célula, seguindo o gradiente de concentração desse íon. O potencial de membrana tende ao potencial de repouso do Na^{2+} como consequência do aumento da condutância a esse íon, causando uma despolarização brusca. A alta condutância ao Na^{2+} é transiente, e a condutância ao K^+ aumenta logo em seguida, causando um efluxo desse íon, seguindo seu gradiente de concentração. Desta forma, o potencial de membrana tende ao potencial de repouso do K^+ , causando uma hiperpolarização no potencial de membrana. Após esse transiente iônico, os canais de Na^{2+} e K^+ passam por um período refratário no qual não podem ser ativados. Durante esse período, bombas de membrana realizam a troca de íons de tal forma a resgatar o potencial de repouso de membrana, retirando Na^{2+} da célula e resgatando K^+ do meio extracelular. Uma representação do transiente da condutância da membrana para os íons Na^{2+} e K^+ , o valor dos potenciais de repouso para ambos os íons e a morfologia do PA podem ser vistos na Figura 3.3 (Loeb & Ghez, 2000).

Uma vez disparado, o PA contribui para a despolarização de regiões vizinhas da membrana. Ao atingir um patamar, um PA é disparado nessa nova região, propagando o potencial de ação longitudinalmente à membrana.

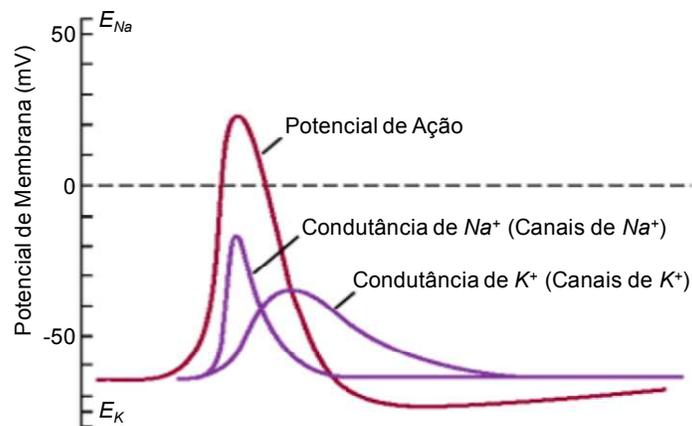


Figura 3.3 – Representação de um potencial de ação (PA) vinculado à variações na condutância da membrana de células excitáveis para íons de Na^+ e K^+ (Modificado de Loeb & Ghez, 2000). Explicação no texto.

3.1.3 A CONTRAÇÃO MUSCULAR

A contração muscular ocorre através de um mecanismo conhecido como acoplamento excitação-contração (Figura 3.4). Quando um PA atinge a terminação axônica de um neurônio motor, essa região é despolarizada, causando um influxo de Ca^{2+} que, por sua vez, dispara a fusão de vesículas contendo neurotransmissor (acetilcolina, ACh) na membrana celular, liberando ACh na fenda sináptica, que se difunde e se associa a receptores colinérgicos nicotínicos presentes no sarcolema. Quando associados, esses receptores abrem canais de Na^{2+} ou K^{+} , permitindo fluxo desses íons, que pode causar despolarização da membrana. Caso essa despolarização atinja certo patamar, um PA é disparado e propagado longitudinalmente pelo sarcolema, ativando canais voltagem-dependentes mecanicamente ligados a canais de Ca^{2+} presentes na membrana do retículo sarcoplasmático. Desta forma, quando despolarizados, os canais voltagem-dependentes abrem os canais de Ca^{2+} no retículo sarcoplasmático e o Ca^{2+} contido no retículo segue seu gradiente de concentração em direção ao sarcoplasma. Esse Ca^{2+} promove o ciclo de pontes cruzadas e o encurtamento do sarcômero que, por sua vez, gera contração muscular até que o Ca^{2+} seja bombeado de volta ao retículo sarcoplasmático (Buchanan *et al*, 2009).

O SNC regula a força exercida por um músculo durante uma contração através de dois mecanismos: o número de UMs recrutadas e a modulação da taxa de disparos de PAs de cada UM (Loeb & Ghez, 2000).

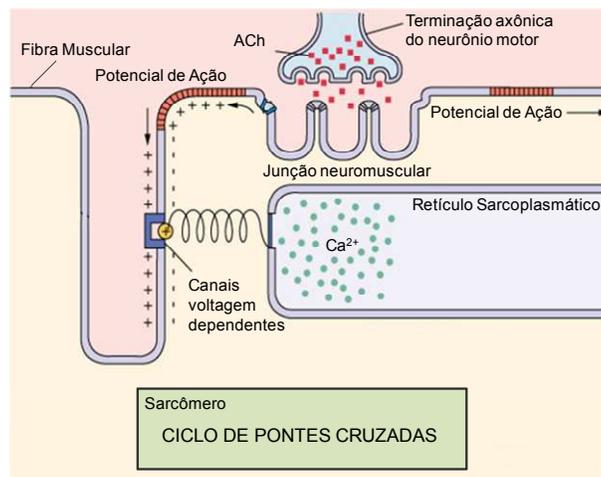


Figura 3.4 – Representação da junção neuromuscular e o acoplamento excitação-contração (Modificado de Won, 2012). Explicação no texto.

3.1.4 O SINAL ELETROMIOGRÁFICO

Uma forma de estudar as características do sistema neuromuscular é através da análise de PAs associados ao recrutamento de UMs. MUAPs podem ser detectados invasivamente ou na superfície da pele. O processo de detecção de sinais EMG envolve a transdução de correntes iônicas, presentes nos sistemas biológicos em geral, em corrente elétrica por eletrodos (Pozzo *et al*, 2004a). O sinal EMG é o sinal elétrico resultante da atividade elétrica de UMs recrutadas durante uma contração muscular, propagados até a área de captura de eletrodos (Figura 3.5) (García *et al*, 2005).

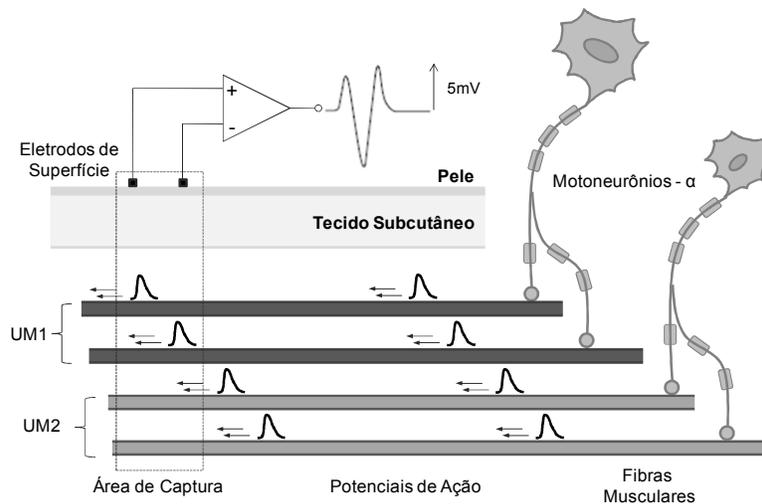


Figura 3.5 – Representação de duas UMs propagando MUAPs e a captura de sinal sEMG.

A propagação dos MUAPs gera um campo elétrico que pode ser percebido em qualquer ponto do espaço. O potencial gerado por uma UM pode ser detectado, portanto, em regiões relativamente longe da fonte. Os tecidos localizados entre as fontes e os eletrodos de captura têm um comportamento de filtro passa-baixa, e quanto mais longe o sistema de captura for posicionado da fonte, maior será a influência desse filtro no sinal capturado (Figura 3.6a). Esse comportamento é conhecido como efeito volume condutor, e as características desse efeito afetam diretamente o sinal detectado (Pozzo *et al*, 2004a). Dependendo do tipo de captura, o efeito volume condutor pode apresentar um efeito considerável ou desprezível no sinal EMG (Figura 3.6b).

No caso de capturas invasivas, a área de captura é localizada muito próxima das fontes, e o sinal propagado até os eletrodos sofre pouca influência dos tecidos presentes entre as fontes e

os eletrodos. Nesse caso, o sinal capturado apresenta componentes de frequência até 5kHz. Contudo, no caso de sinais EMG capturados de forma não invasiva, ou seja, na superfície da pele, o sistema de detecção é localizado muito longe das fontes, e o sinal propagado até os eletrodos sofre muita influência dos tecidos presentes entre as fontes e os eletrodos, afetando o sinal consideravelmente. O efeito de filtro passa-baixa dos tecidos limita as componentes de frequência do sinal sEMG em até 500Hz.

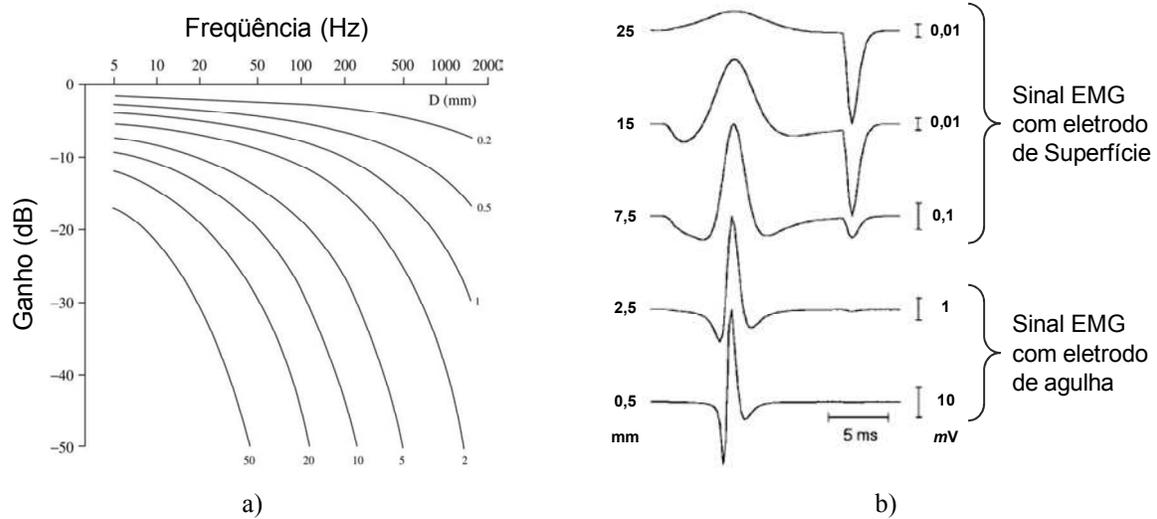


Figura 3.6 – Efeito do volume condutor em sinais EMG. a) Mapeamento entre ganho e frequência de sinais sEMG em relação à distância (D) entre fonte (UM) e a área de captura (Modificado de Pozzo *et al*, 2004a). b) Representação do sinal EMG capturado por meio invasivo e não invasivo em diferentes distâncias entre fonte (UM) e a área de captura. É possível notar como sinais invasivos capturados mais próximos da UM possuem sinais com “picos” e “vales” mais evidentes (Modificado de Zwarts & Stegeman, 2003).

A consequência do efeito volume condutor em potenciais detectados delineia a diferença entre as capturas invasivas e não invasivas. Capturas invasivas possuem alta seletividade espacial e fornecem uma informação detalhada da integridade das componentes do músculo em análise. Capturas de superfície apresentam baixa seletividade espacial e fornecem informação global do músculo em análise. A distância entre a fonte e o sistema de captura no caso de métodos não invasivos resulta em uma seletividade espacial baixa, *i.e.*, a contribuição de uma fonte não está confinada a uma pequena região. Para músculos próximos uns dos outros, pode ocorrer que os sinais gerados por um podem ser detectados nos eletrodos do outro por condução do sinal devido o efeito volume condutor. O sinal gerado por um músculo capturado em outro músculo é conhecido como *crosstalk*, e representa um problema comum em sinais sEMG.

3.1.5 ELETRODOS INVASIVOS

O sinal EMG permite inferir sobre a integridade do sistema neuromuscular pela análise das formas de onda dos MUAPs. Normalmente esses estudos são realizados utilizando-se técnicas invasivas, que utilizam eletrodos de agulha ou fio. A área de captura desses eletrodos é muito pequena, resultando em uma alta seletividade espacial, permitindo a captura de MUAPs de uma única UM. Desta forma pode-se inferir sobre a anatomia das fibras musculares e a taxa de disparo do neurônio motor. Contudo, essas técnicas invasivas tendem a ser muito demoradas e desconfortáveis ao paciente, além de danificar tecidos e serem foco para potenciais infecções (García *et al*, 2005).

Existem dois tipos de eletrodos invasivos: os de agulha e os de fio. Eletrodos de agulha são utilizados quando é necessário reposicionamento do eletrodo durante a análise, analisando vários pontos diferentes do músculo. Contudo, a agulha pode deslocar durante uma contração. Os eletrodos de fio foram desenvolvidos a fim de sanar essa dificuldade, pois possuem um gancho que os entrelaça às fibras musculares uma vez posicionados, evitando deslocamento durante a contração. Contudo, esses eletrodos não permitem reposicionamento (De Luca, 2006). Exemplos desses dois tipos de eletrodos podem ser vistos na Figura 3.7. Em geral, eletrodos invasivos são utilizados para análise de características de MUAPs, propriedade de controle das UMs e estudos cinesiográficos e neurofisiológicos em músculos mais profundos (Quevedo, 1993).

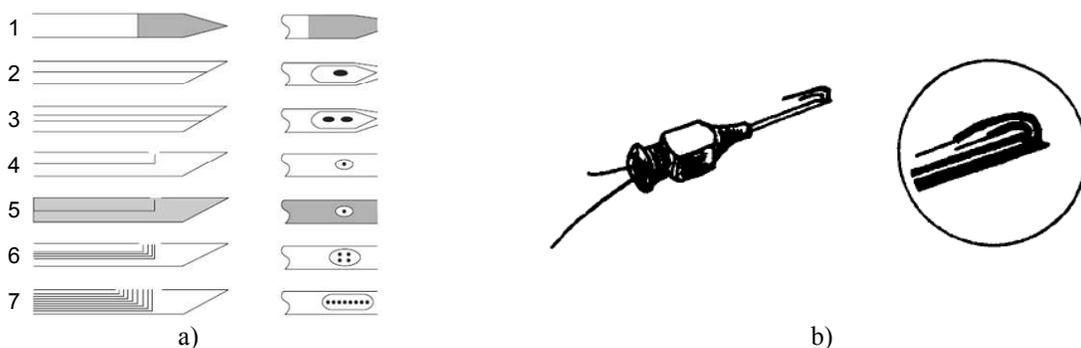


Figura 3.7 – Eletrodos invasivos (Modificado de De Luca, 2006). a) Exemplos de tipos de eletrodos de agulha. O lado direito mostra, em detalhe, a área ativa de captura do eletrodo. De cima para baixo: 1) Eletrodo de agulha sólido para única fibra. A área escura representa a superfície da agulha; 2) Eletrodo de agulha concêntrica com uma superfície de detecção monopolar formado pela área transversal de um fio com diâmetro de 200µm; 3) Eletrodo de agulha concêntrica com duas superfícies de detecção monopolar; 4) Eletrodo para detectar uma fibra muscular pela área transversal de um fio de diâmetro de 25µm; 5) Macroeletrodo com área transversal do fio de diâmetro de 25µm e com a cânula da agulha (área escura) utilizada como superfície de captura; 6) Eletrodo quadrifilar com quatro fios com área transversal de diâmetro 50µm; 7) Eletrodo multifilar com uma fileira de eletrodos. b) Eletrodo de fio bipolar.

3.1.6 ELETRODOS DE SUPERFÍCIE

As técnicas não invasivas utilizam eletrodos de superfície que capturam sinais mioelétricos na superfície da pele, sem a necessidade da inserção de eletrodos de agulhas ou fios dentro do músculo. Porém, a área de captura desses eletrodos é grande, resultando em uma baixa seletividade espacial. Desta forma, os sinais sEMG capturados são superposições espaço-temporais de vários MUAPs que sofrem influência do filtro passa-baixa devido ao efeito volume condutor e dependem de fatores como a espessura e condutividade das camadas subcutâneas, da profundidade da fonte e da geometria dos eletrodos, resultando em um sinal com aparência de ruído aleatório, de difícil interpretação (Figura 3.8). Com isso, torna-se impossível obter qualquer informação *a priori* das fontes (nesse caso, os MUAPs) e da função de mistura dessas fontes que ocorre durante a propagação dos PAs até a superfície da pele (Farina *et al*, 2004b). A decomposição desses sinais complexos nas suas MUAPs constituintes fornece todas as informações disponíveis no sinal EMG. As informações de tempo fornecem uma descrição completa sobre o intervalo interpulso, taxa de disparo e características de sincronismo entre UMs. A morfologia das formas dos MUAPs fornecem informações sobre a anatomia e condição fisiológica das fibras musculares.

Sinais sEMG permitem uma análise global do músculo (Holobar & Zazula, 2004), e sinais sEMG de alta resolução permitem identificar zonas de inervação e inferir sobre a velocidade de condução dos PAs pelas fibras musculares (Merletti *et al*, 2008). Normalmente, eletrodos de superfície são utilizados em estudos cinesiológicos e neurofisiológicos em músculos superficiais e em interfaces com dispositivos externos (Quevedo, 1993).

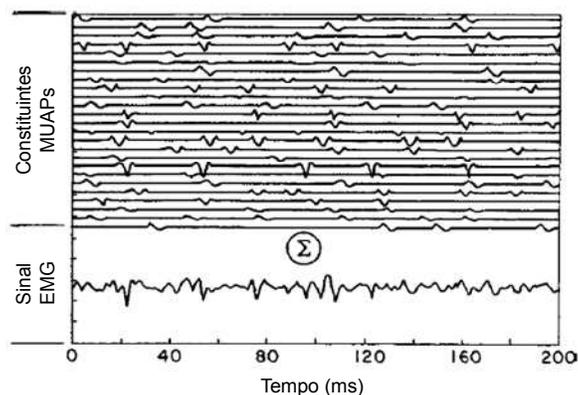


Figura 3.8 – Sinal EMG resultante da mistura de vários MUAPs (Modificado de De Luca, 2006).

Eletródos de superfície podem ser divididos em duas categorias: ativos e passivos (Figura 3.9). Eletródos passivos possuem uma superfície de detecção condutiva, normalmente de metal, com o qual correntes através da pele são captadas pela interface eletrodo-pele. A forma mais simples de eletródos passivos consiste em discos de prata que aderem à pele. Nessa situação, melhora-se significativamente o contato elétrico com a aplicação de gel condutor entre o eletrodo e a pele. A corrente iônica que surge no gel é transformada em corrente elétrica no eletrodo. Para melhores resultados, pode-se remover a camada superficial de pele, conhecida por *stratum corneum*, através de leve abrasão. É necessário garantir um bom contato entre o eletrodo e a pele, o que pode ser feito fixando-se os eletródos na pele com fitas adesivas. Eletródos de superfície normalmente já vêm com uma região com adesivo para facilitar o posicionamento e fixação (De Luca, 2006).

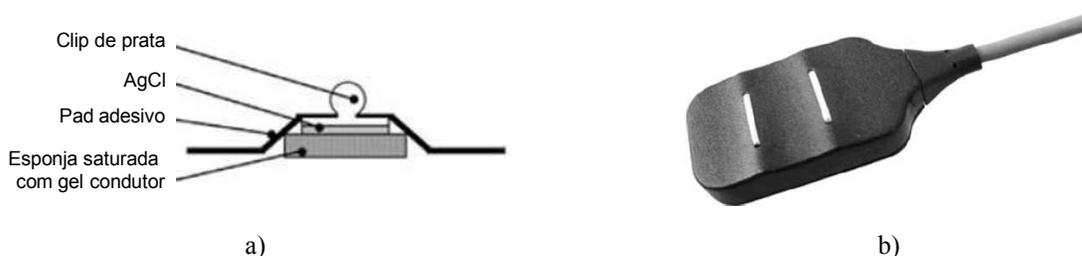


Figura 3.9 – Exemplo de eletródos de superfície. a) Esquema de eletrodo de superfície passivo com as constituintes estruturas (Modificado de Pozzo *et al*, 2004a). b) Eletrodo de superfície bipolar ativo, com espaço entre barras de 10mm, espessura das barras 1mm e 10mm de comprimento (Modificado de De Luca, 2006).

Os eletródos de superfície passivos mais comumente utilizados são do tipo Ag-AgCl, utilizados junto com gel condutor contendo íons de cloreto, devido a alta confiabilidade, baixo custo e baixo potencial de meia-célula. O potencial de meia-célula é um potencial que surge entre o metal e o eletrólito e, se esse potencial for muito elevado, pode prejudicar a captura dos sinais a em questão (Cobbold, 1974). Em 2005, Tallgren e colaboradores (Tallgren *et al*, 2005) mostraram, através de um estudo comparativo, que eletródos de Ag-AgCl são os mais recomendáveis para captura de biopotenciais.

Eletródos de superfície ativos apresentam um amplificador de alta impedância de entrada integrado ao encapsulamento do eletrodo. Esse arranjo o torna menos sensível à impedância da interface eletrodo-pele e, portanto, foram desenvolvidos com o intuito de eliminar o preparo da pele e a aplicação de gel condutor. Contudo, esses eletródos apresentam

um maior nível de ruído intrínseco e a qualidade dos sinais EMG capturados é menor devido a transpiração e oscilações naturais encontradas na superfície da pele (De Luca, 2006).

Contudo, eletrodos de superfície comerciais não são recomendados para aplicações em decomposição de sinais sEMG, pois, em geral, possuem dimensões muito grandes, com aproximadamente 1 centímetro de diâmetro (Pozzo *et al*, 2004b). Com tais dimensões, o sinal sEMG resultante é constituído pela atividade elétrica de uma quantidade muito grande de UMs. Vários autores desenvolveram eletrodos com dimensões reduzidas visando reduzir a área de captura. Em 2000, Kleine e colaboradores (Kleine *et al*, 2000) utilizaram uma matriz de eletrodos de ouro, arrançados em 10 eletrodos em linha e 13 em coluna, distanciados em 5mm, na estimativa da taxa de disparos de UMs estimuladas via estimulação magnética transcranial; Pozzo e colaboradores (Pozzo *et al*, 2004b) desenvolveram matriz de eletrodos com dimensões super-reduzidas sinterizando AgCl em superfícies de prata; García e colaboradores (García *et al*, 2005), desenvolveram uma matriz com 16 eletrodos de aço inoxidável, posicionados em duas colunas de oito eletrodos, presos em uma placa de acrílico, cada eletrodo com 1mm de diâmetro, 3mm de altura e distância inter-eletrodo de 2,54mm.

3.1.7 CONFIGURAÇÃO DOS ELETRODOS

Pode-se detectar a atividade elétrica emitida por um músculo previamente à contração, de forma invasiva ou não invasiva, posicionando-se um eletrodo na região a ser analisada e detectando o potencial elétrico dessa região em relação a um ponto de referência. Essa referência pode ser uma região eletricamente neutra ou uma região com a presença de potenciais elétricos não relacionados com os potenciais de interesse. Normalmente são utilizados eletrodos de superfície para definir o ponto de referência. Essa configuração de eletrodos onde existe um ponto de captura e um ponto de referência é chamada de configuração monopolar (Figura 3.10a). A principal vantagem dessa configuração é a montagem simples e rápida, contudo essa montagem resulta na captura de todos os sinais elétricos presentes na área de detecção do eletrodo, o que inclui sinais elétricos e ruídos indesejados provenientes de outras fontes além do músculo em análise (Equação 3.1) (De Luca, 2006).

$$EMG \text{ sig} = G \cdot (m + n) \quad (3.1)$$

onde $EMG \text{ sig}$ representa o sinal EMG capturado, G é o ganho do amplificador, m é o sinal mioelétrico de interesse e n representa sinais elétricos e ruídos indesejados. A configuração bipolar (Figura 3.10b) supera essa limitação utilizando duas superfícies para detectar dois potenciais do músculo em análise, cada qual em relação a um eletrodo de referência em comum (De Luca, 2006). Os dois sinais capturados passam por um amplificador diferencial que amplifica a diferença entre os dois sinais, eliminando qualquer componente de modo comum presente nos dois sinais (*e.g.*, 60Hz da rede elétrica e equipamentos elétricos).

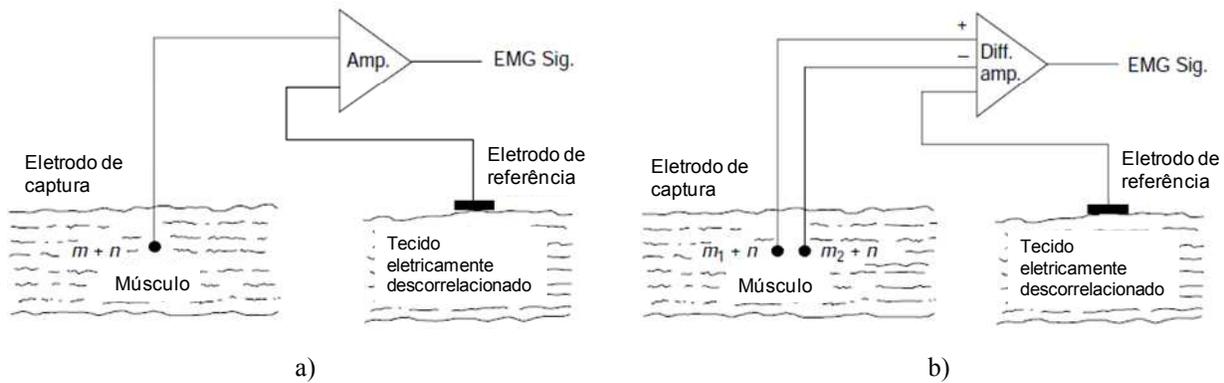


Figura 3.10 – Configuração de eletrodos (Modificado de De Luca, 2006). a) Configuração monopolar. b) Configuração bipolar.

Os sinais de interesse, gerados e emanados a partir do tecido muscular, são diferentes de uma superfície de captura para outra, devido aos eventos eletroquímicos locais que ocorrem nas fibras musculares previamente à contração. Contudo, ruídos AC provenientes de fontes externas mais distantes dos eletrodos que a fonte dos sinais de interesse (*e.g.*, 60Hz da rede elétrica e equipamentos elétricos), e ruídos DC (em geral originários do potencial de meia-célula no eletrodo) serão detectados por ambas as superfícies de detecção com formas de onda e amplitude similares, sendo subtraídos previamente à amplificação (Equação 3.2).

$$EMG \text{ sig} = G \cdot [(m_1 + n) - (m_2 + n)] = G \cdot (m_1 - m_2) \quad (3.2)$$

onde $EMG \text{ sig}$ representa o sinal EMG capturado, G é o ganho do amplificador, m_1 é o sinal mioelétrico capturado pelo primeiro eletrodo, m_2 é o sinal mioelétrico capturado pelo segundo eletrodo e n é o ruído comum capturado pelos dois eletrodos.

3.1.8 FATORES QUE AFETAM O SINAL ELETROMIOGRÁFICO

O sinal EMG sofre influência de inúmeros fatores que podem ser enumerados como: causativos, intermediários e determinísticos (De Luca, 1997).

Os fatores causativos têm um efeito básico ou essencial no sinal, e pode ser dividido em dois grupos: extrínsecos e intrínsecos. Os fatores causativos extrínsecos são associados com as estruturas dos eletrodos e seu posicionamento sobre o músculo (Figura 3.11). Incluem:

- A geometria do eletrodo (área e forma);
- A localização do eletrodo em relação aos pontos de inervação muscular e ao tendão muscular, que influencia a amplitude e freqüência do sinal;
- A localização do eletrodo em relação à lateral muscular, que influencia a quantidade de *crosstalk* capturado;
- A orientação da superfície de detecção em relação à direção das fibras musculares, que afeta a medição da velocidade de condução de PAs e, conseqüentemente, a amplitude e freqüência do sinal.

Os fatores causativos intrínsecos incluem características fisiológicas, anatômicas e bioquímicas do músculo. Diferentemente dos fatores extrínsecos, não podem ser controlados. Incluem o número e tipo de UMs recrutadas, o fluxo sanguíneo no músculo, o diâmetro das fibras musculares, a profundidade e localização das fibras musculares recrutadas em relação à área de captura dos eletrodos e quantidade de tecido entre o músculo e a área de captura dos eletrodos. Fatores determinísticos são fatores que influenciam diretamente a informação presente no sinal EMG e na força medida. Incluem: o número de UM recrutadas, a relação força-espasmo gerada por uma UM, a interação mecânica entre fibras musculares, a taxa de disparo da UM e a amplitude, duração e forma do MUAP. Fatores intermediários representam fenômenos físicos e fisiológicos influenciados por fatores causativos e, por sua vez, influenciam fatores determinísticos. Incluem: a banda passante da configuração eletrodo-amplificador diferencial, a superposição de PAs, *crosstalk* de músculos vizinhos e a velocidade de propagação de PAs pelas fibras musculares.

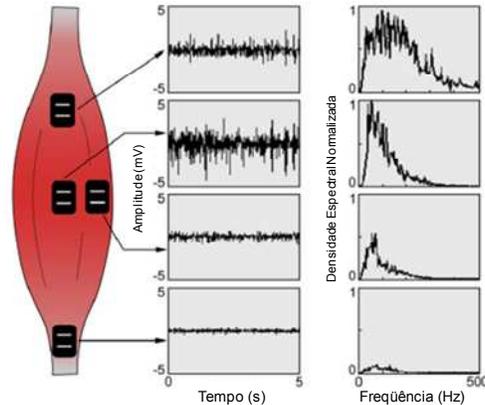


Figura 3.11 – Amplitude e frequência do sinal EMG em relação ao posicionamento de eletrodos (Modificado de De Luca, 1997).

3.1.9 ELETRÔNICA DO SISTEMA DE DETECÇÃO DE SINAIS ELETROMIOGRÁFICOS

Os principais parâmetros a serem observados em um sistema de captura de sinais EMG são (Quevedo, 1993):

- Ruído intrínseco do sistema;
- Ganho;
- Razão de rejeição de modo comum (CMRR – *Common Mode Rejection Ratio*);
- Impedância de entrada em modo comum;
- Largura da banda do sinal.

O sinal sEMG é complexo, de difícil análise e com aparência de ruído aleatório. O ruído do sistema de captura afeta diretamente os sEMG, dificultando ainda mais sua avaliação. Portanto, quanto menor o ruído do sistema de captura, melhor. Sampaio (1998) mostrou que a faixa de ruído aceitável intrínseco ao sistema de captura gira em torno de $1\mu V_{RMS}$ a $5\mu V_{RMS}$, e De Luca (1997) mostra que um sistema de captura não deve ter ruído maior que $2\mu V_{RMS}$.

O sinal sEMG possui tensões de pico da ordem de $50\mu V$ a $5mV$ (Quevedo, 1993). A fim de gerar um sinal de ótima qualidade e a um nível de tensão adequado para futuro processamento, o amplificador deve garantir uma boa amplificação, mantendo a melhor relação sinal-ruído possível (Nagel, 2000).

Quanto maior o CMRR, melhor a capacidade do sistema em minimizar ruídos em modo comum. De Luca (De Luca, 2006) recomenda CMRR acima 85dB.

A impedância de entrada do sistema auxilia a isolar o sistema de captura do sistema medido. A impedância de um sistema biológico varia entre $1\text{k}\Omega$ e $10\text{k}\Omega$ (Nagel, 000). Desta forma, quanto maior a impedância de entrada do sistema de captura, menos o sistema de captura afeta o sistema medido. Nagel (2000) mostra que sistemas de captura de sinais biológicos devem ter impedância de entrada maior que $10^9\Omega$. De Luca (De Luca, 2006) indica que a impedância de entrada de modo comum deve ser, idealmente, próximo a $10^{15}\Omega/7\text{pF}$.

O sinal sEMG possui uma faixa de frequência de 20Hz a 500Hz (De Luca, 2006), com energia dominante entre 20Hz e 150Hz (Karlsson *et al*, 2008). Logo, o sistema de captura deve limitar o sinal capturado para dentro da faixa de frequência entre, pelo menos, 20Hz a 500Hz.

García (García *et al*, 2005) decompôs sinais sEMG que foram capturados através de um sistema com impedância de entrada de modo comum de $10^{12}\Omega$, CMRR de 110dB e banda passante de 70Hz a 1kHz.

3.2 Separação Cega de Fontes

A BSS compreende métodos que visam estimar sinais originais, ou fontes, a partir de um conjunto de misturas que contém essas fontes.

Um dos problemas mais ilustrativos em BSS é o *cocktail-party problem* (Duarte, 2006). Nesse problema ilustrativo, várias pessoas se encontram em uma festa, com música, comida e bebida, formando vários grupos. Além disso, microfones foram posicionados em diferentes pontos dessa sala (Figura 3.12).

Cada microfone gera um sinal de saída (x_m) que é a composição, ou mistura, dos vários sinais presentes à festa, ou seja, as vozes das pessoas nos diferentes grupos, ou reflexões das mesmas nas paredes do ambiente, ruído de fundo e música (s_n), ponderados por efeitos presentes no meio de propagação, no caso, o ar (a_{ij}). Considerando a situação mostrada na Figura 3.12 com três microfones, tem-se:

$$\begin{aligned}x_1(t) &= a_{11}s_1(t) + a_{21}s_2(t) + a_{31}s_3(t) \\x_2(t) &= a_{12}s_1(t) + a_{22}s_2(t) + a_{32}s_3(t) \\x_3(t) &= a_{13}s_1(t) + a_{23}s_2(t) + a_{33}s_3(t)\end{aligned}\tag{3.3}$$

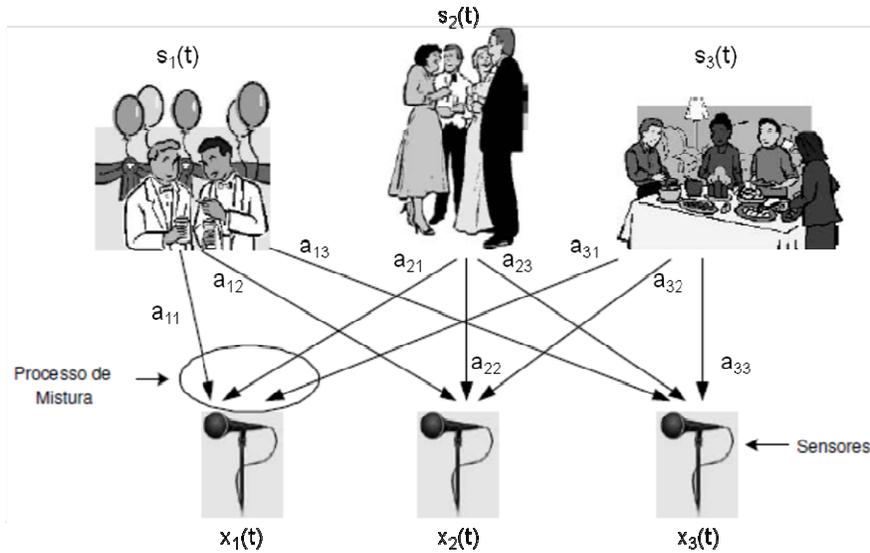


Figura 3.12 – Ilustração do *Cocktail-party Problem* (Modificado de Duarte, 2006).

De maneira geral, o problema de BSS consiste em recuperar um conjunto de sinais s_n , denominados fontes, a partir de observações x_m que são misturas desconhecidas destas fontes. O termo “cego” é usado para explicitar o fato de que as fontes não são observadas diretamente, e que o sistema de mistura é desconhecido (Suyama, 2007).

O grande interesse por parte dos pesquisadores neste problema se deve ao fato deste mesmo cenário ser encontrado em diferentes contextos, dando margem ao uso das técnicas de BSS nas mais diversas aplicações como, por exemplo, processamento de sinais biomédicos, tratamento de sinais de voz/áudio, sistemas de comunicações e análise de dados geofísicos (Suyama, 2007).

A falta de conhecimento *a priori* sobre a mistura é, de certa forma, compensada pela hipótese de que os sinais das fontes são estatisticamente independentes entre si ao utilizar ICA. Esta consideração, embora aparentemente restritiva, é uma hipótese plausível em muitos cenários práticos, e levou ao desenvolvimento da ICA, uma das técnicas mais empregadas no contexto de separação cega de fontes.

Se sinais independentes forem misturados e existirem o mesmo número de misturas, ou mais, que o número de fontes, os sinais originais podem ser extraídos a partir das misturas, sem conhecimento prévio das características dos sinais originais. A ICA consiste na separação de fontes baseada na maximização da independência estatística das fontes (Hyvärinen *et al*, 2001).

Em um sistema de captura de sinais sEMG, cada UM pode ser considerada uma fonte independente, e o sinal sEMG pode ser visto como a mistura entre diversos MUAPs, *crosstalk* de músculos adjacentes e ruídos, de forma que essa mistura depende de vários fatores, conforme mostrado na seção 3.1.8 – Fatores que Afetam o Sinal Eletromiográfico (Figura 3.13).

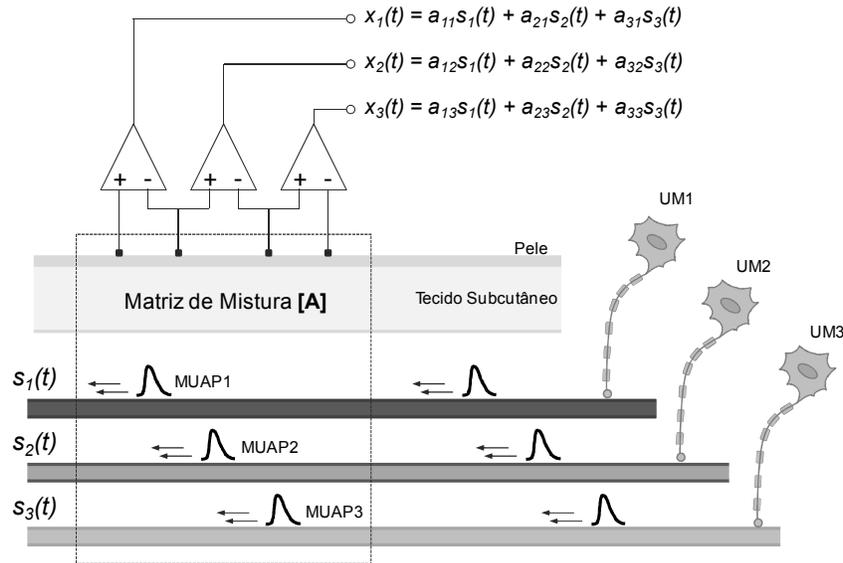


Figura 3.13 – A modelagem da eletromiografia na separação cega de fontes considerando apenas três UMs e três sinais sEMG bipolares. Os MUAPs são fontes independentes $s_n(t)$, o tecido subcutâneo e outros fatores influenciam a matriz de mistura \mathbf{A} e os sinais EMG capturados são as misturas $x_m(t)$.

Pode-se entender a técnica de ICA através da maximização da não-gaussianidade. Considere a seguinte transformação linear:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) \quad (3.4)$$

onde $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_m(t)]$ é um vetor contendo m misturas capturadas, $\mathbf{s}(t) = [s_1(t), s_2(t), \dots, s_n(t)]$ é um vetor contendo as n fontes originais e \mathbf{A} é uma matriz de mistura $m \times n$. Partindo do pressuposto que: 1) as n componentes de \mathbf{s} são não-gaussianas e independentes entre si; 2) \mathbf{A} e \mathbf{s} são desconhecidos, ou seja, não se tem informações prévias sobre as fontes tampouco sobre o processo de mistura; 3) o número de misturas é maior ou igual ao número de fontes ($m \geq n$); tem-se:

$$\mathbf{y} = \mathbf{W}\mathbf{x} = \mathbf{W}\mathbf{A}\mathbf{s} \quad (3.5)$$

onde $\mathbf{y}(t) = [y_1(t), y_2(t), \dots, y_n(t)]$ é um vetor contendo n estimativas de \mathbf{s} e \mathbf{W} é a matriz de separação $m \times n$ (Figura 3.14).

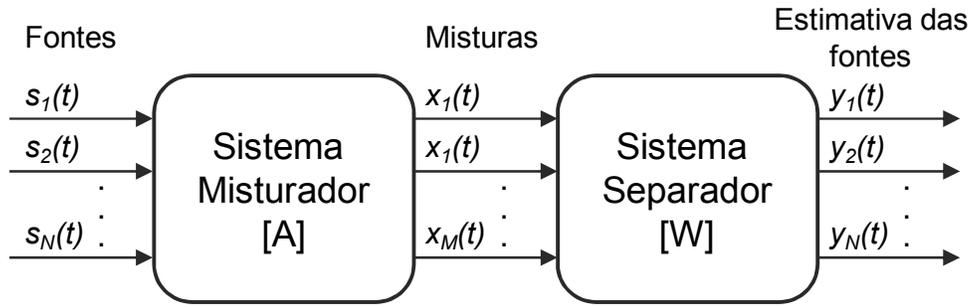


Figura 3.14 – Modelo do Problema de Separação Cega de Fontes (Modificado de Duarte, 2006).

O propósito da ICA é encontrar \mathbf{W} tal que as componentes de \mathbf{y} tenham distribuição menos gaussiana possível caso as misturas \mathbf{x} forem transformações lineares previamente branqueadas das fontes originais, garantindo independência estatística e, conseqüentemente, estimando as componentes de \mathbf{s} (Hyvärinen *et al*, 2001).

3.2.1 A SEPARAÇÃO DE FONTE POR ICA

O teorema do limite central mostra que a distribuição da soma de variáveis independentes aleatórias tende a uma distribuição gaussiana, ou seja, a soma de duas ou mais variáveis independentes aleatórias freqüentemente tem distribuição mais próxima à gaussiana que qualquer uma das variáveis originais individualmente (Hyvärinen *et al*, 2001). Considerando a existência de observações de misturas de fontes independentes (Equação 3.4), nota-se que é possível encontrar as componentes independentes originais a partir do inverso da matriz de mistura, ou seja:

$$\mathbf{s} = \mathbf{A}^{-1} \mathbf{x} \tag{3.6}$$

Desta forma, pode-se estimar componentes independentes a partir de uma combinação linear entre o vetor \mathbf{x} e uma matriz, digamos, \mathbf{W} , tal que:

$$\mathbf{y} = \mathbf{W}^T \mathbf{x} = \mathbf{W}^T \mathbf{A} \mathbf{s} = \mathbf{Q}^T \mathbf{s} \tag{3.7}$$

Ou seja, \mathbf{x} são combinações lineares de \mathbf{s} e \mathbf{y} são combinações lineares de \mathbf{x} , tal que se \mathbf{W} for o inverso de \mathbf{A} , exceto por uma componente, a combinação linear $\mathbf{W}^T \mathbf{x}$ teria como resultado exatamente uma das componentes independentes:

$$y_1 = w_{11} a_{11} s_1 + \cancel{w_{12} a_{12} s_2} + \cancel{w_{13} a_{13} s_3} \tag{3.8}$$

Na prática, no entanto, não é possível identificar \mathbf{W} desta forma, pois \mathbf{A} é desconhecido. A idéia fundamental por trás da separação por ICA é encontrar componentes estatisticamente independentes uma das outras, estimando as fontes originais. Como a composição de variáveis independentes aleatórias tende a uma distribuição mais gaussiana que as variáveis independentes isoladas, medidas de gaussianidade podem ser utilizadas como um meio para encontrar componentes independentes. Assim, \mathbf{y} é, usualmente, mais gaussiana que qualquer componente de \mathbf{s} a não ser quando \mathbf{y} se iguala a uma das componentes de \mathbf{s} (Equação 3.8).

Não é necessário saber exatamente o valor de \mathbf{Q} para igualar \mathbf{y} a \mathbf{s} . O importante é variar \mathbf{W} e analisar o grau de gaussianidade da distribuição de $\mathbf{W}^T\mathbf{x}$, já que essas são as únicas variáveis que se têm conhecimento e/ou controle. Desta forma, pode-se considerar \mathbf{W} como uma matriz que visa a maximização da não-gaussianidade da combinação linear $\mathbf{W}^T\mathbf{x}$.

Dependendo do valor (ou direção) de \mathbf{W} , o vetor \mathbf{Q} passa a ter somente uma componente diferente de zero, pois \mathbf{W} possui todas as outras componentes iguais ao inverso das componentes de \mathbf{A} , resultando em apenas uma componente independente, ou seja:

$$y_n = W_{m,n}^T x_m = Q_{m,n}^T s_n \quad (3.9)$$

Desta forma, ao maximizar a não-gaussianidade, $\mathbf{W}^T\mathbf{x}$ fornece um conjunto de componentes independentes.

3.2.2 PRÉ-PROCESSAMENTO PARA ICA

O processo de separação de fontes pode ser sintetizado através da Figura 3.15, englobando o pré-processamento das misturas e a separação das fontes. O pré-processamento, em geral, inclui a centralização e o branqueamento das matrizes de mistura. As técnicas de pré-processamento são analisadas a seguir.

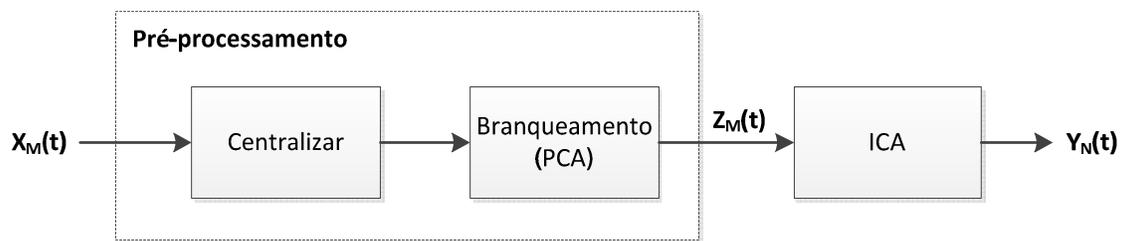


Figura 3.15 – Etapas para Separação Cega de Fontes.

Inicialmente, o vetor de misturas deve ser centralizado, ou seja, remove-se a média dos vetores contendo a mistura:

$$\mathbf{x} \leftarrow \mathbf{x} - E[\mathbf{x}] \quad (3.10)$$

Após a centralização, deve-se gerar uma representação da mistura onde suas componentes sejam brancas. Uma técnica muito conhecida e amplamente utilizada para branqueamento um vetor é a PCA. A PCA consegue eliminar redundâncias de um vetor representando-o com componentes descorrelacionadas e normalizando sua variância. A redução de redundâncias ocorre ao limitar o número de componentes a serem consideradas para recuperar o vetor, levando à compressão de dados sem perder informações importantes e à redução de ruídos (Semmlow & Yuan, 2002).

A descorrelação é uma propriedade estatística mais fraca que a independência, sendo um caso especial de independência, ou seja, sinais independentes são obrigatoriamente descorrelacionados, porém sinais descorrelacionados não são necessariamente independentes (Stone, 2004). Essa propriedade pode ser interpretada da seguinte forma (Hyvärinen *et al*, 2001): se duas variáveis são independentes, a função de densidade de probabilidade (fdp) conjunta $p_{x,y}$ pode ser obtida a partir do produto das fdps marginais p_x e p_y :

$$p_{x,y}(\mathbf{x}, \mathbf{y}) = p_x(\mathbf{x}) \cdot p_y(\mathbf{y}) \quad (3.11)$$

Qualquer momento central da fdp conjunta está implícito nos momentos centrais das fdps marginais e a fdp conjunta pode ser reconstruída a partir delas:

$$E[g_x(\mathbf{x}) \cdot g_y(\mathbf{y})] = E[g_x(\mathbf{x})] \cdot E[g_y(\mathbf{y})] \quad (3.12)$$

Duas variáveis são descorrelacionadas quando apresentarem covariância nula, ou seja:

$$C_{xy} = E[\mathbf{xy}^T] - E[\mathbf{x}]E[\mathbf{y}^T] = 0 \quad (3.13)$$

$$\therefore E[\mathbf{xy}^T] = E[\mathbf{x}]E[\mathbf{y}^T] \quad (3.14)$$

Portanto, a descorrelação é apenas um caso especial de independência, onde $g_x(\mathbf{x}) = x$ e $g_y(\mathbf{y}) = y$. Assim, a independência é uma forma generalizada de medida de correlação que

considera todos os momentos centrais da fdp $p_{x,y}$ e a covariância considera somente o segundo momento central da fdp $p_{x,y}$.

Desta forma, gerar uma representação com componentes descorrelacionadas do vetor de mistura é um passo para encontrar as componentes independentes contidas nesse vetor de misturas. Na PCA, inicialmente determina-se autovetores ortonormais do vetor de misturas (Hyvärinen *et al*, 2001). Os autovetores garantem que os elementos projetados na nova coordenada sejam ortogonais uns aos outros e, logo, descorrelacionados. Logo após, as variâncias das projeções das componentes de \mathbf{x} nos eixos da nova coordenada são maximizadas, ou seja, o primeiro eixo referente ao primeiro autovetor representa a componente com máxima variância, o segundo eixo referente ao segundo autovetor corresponde à máxima variância na direção ortogonal ao primeiro eixo. A Figura 3.16a representa esse passo. Considere um gráfico de dispersão entre duas variáveis de uma mistura qualquer (lembrando que um gráfico de dispersão é uma representação gráfica que mostra como uma variável se relaciona com outra). Nota-se que existem duas componentes principais, uma ortogonal a outra: P1 é a primeira componente principal, e representa a maior variância (autovalor) do sinal; P2 é a segunda componente principal, e representa a segunda maior variância da mistura, ortogonal à primeira componente. Esse processo é repetido até atingir-se o número de autovetores com os respectivos autovalores, que representam a variância do respectivo autovetor, de forma a representar o vetor original de forma satisfatória. O exemplo mostrado na Figura 3.16b mostra que as variâncias das componentes $N = 1$, $N = 2$ e $N = 3$ representam quase que por completo o sinal em análise, e as componentes subseqüentes possuem variância muito pequena. Dependendo do problema em questão, as componentes subseqüentes poderiam ser desconsideradas no sinal recuperado sem perda significativa de informação.

Como resultado da PCA e descorrelação, a covariância de \mathbf{x} pode ser representada da seguinte forma:

$$C_x = \mathbf{E}\mathbf{D}\mathbf{E}^T \quad (3.15)$$

onde C_x é a covariância, \mathbf{E} compõe os autovetores de \mathbf{x} e \mathbf{D} constitui as variâncias, ou autovalores, de \mathbf{x} . Como as componentes de C_x são descorrelacionadas, C_x é uma matriz

diagonal, onde os valores presentes na diagonal são os autovalores dos autovetores, correspondendo às variâncias das componentes principais.

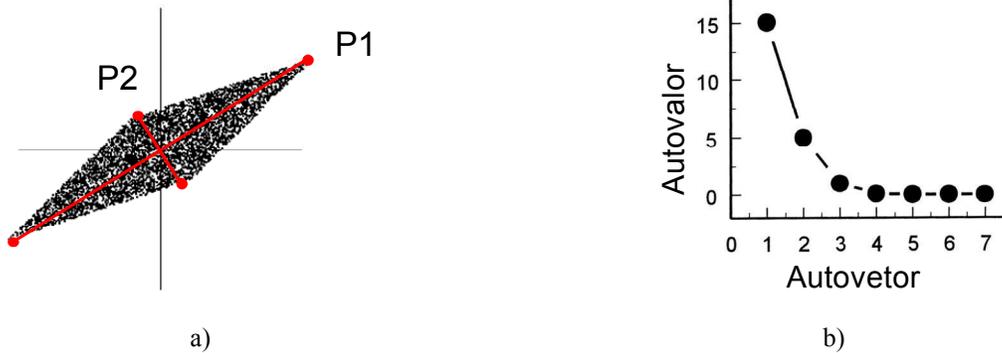


Figura 3.16 – Ilustração da PCA. a) *Scatter plot* entre duas variáveis com distribuição dos dados observados após mistura indicando duas componentes principais. b) Relação entre as componentes principais (autovetores) e os respectivos autovalores (Modificado de Semmlow & Yuan, 2002).

Logo após definir o novo vetor de misturas com componentes descorrelacionadas, a PCA realiza o branqueamento desse vetor descorrelacionado, no qual a variância é ponderada (Figura 3.17).

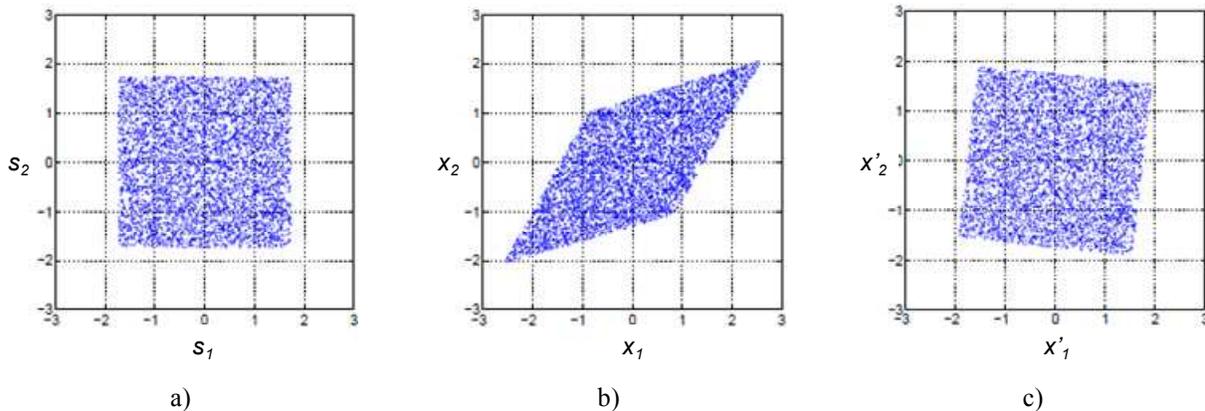


Figura 3.17 – Exemplo de branqueamento de duas fontes independentes (s_1, s_2) com distribuição uniforme (Modificado de Suyama, 2007). (a) Distribuição das fontes originais (s_1, s_2). (b) Distribuição dos dados observados após a mistura (x_1, x_2). (c) Distribuição após o branqueamento (x'_1, x'_2).

Misturas podem ser branqueadas através da seguinte manipulação matemática:

$$\mathbf{V} = \mathbf{D}^{-\frac{1}{2}} \mathbf{E}^T \tag{3.16}$$

$$\mathbf{z} = \mathbf{V} \mathbf{x} \tag{3.17}$$

onde \mathbf{x} representa o vetor de misturas com componentes descorrelacionadas, \mathbf{E} compõe os autovetores de \mathbf{x} ortonormais entre si, \mathbf{D} constitui as variâncias de \mathbf{x} , e \mathbf{z} contém as misturas

descorrelacionadas após o branqueamento, ou seja, com variância unitária. Com isso, a covariância de \mathbf{z} fornece uma matriz diagonal e unitária, ou seja, uma matriz identidade (Hyvärinen *et al*, 2001):

$$E[\mathbf{z}\mathbf{z}^T] = \mathbf{V}E[\mathbf{x}\mathbf{x}^T]\mathbf{V}^T = \mathbf{V}\mathbf{C}_x\mathbf{V}^T = \mathbf{D}^{-\frac{1}{2}}\mathbf{E}^T\mathbf{E}\mathbf{D}\mathbf{E}^T\mathbf{E}\mathbf{D}^{-\frac{1}{2}} = \mathbf{I} \quad (3.18)$$

3.2.3 MEDIDAS DE GAUSSIANIDADE

Após o pré-processamento, busca-se separar as fontes através da maximização da não-gaussianidade utilizando-se curtose ou negentropia.

A curtose é calculada utilizando-se o segundo e quarto momentos centrais de uma variável, representada por:

$$curt(x) = E[x^4] - 3(E[x^2])^2 \quad (3.19)$$

Caso a variável tenha variância unitária (segundo momento), a curtose pode ser calculada por:

$$curt(x) = E[x^4] - 3 \quad (3.20)$$

Caso a variável tenha distribuição gaussiana, a curtose é nula. Variáveis que possuem uma distribuição com um pico mais proeminente apresentam curtose positiva, e são chamadas de supergaussianas. Variáveis que possuem uma distribuição com um pico achatado apresentam curtose negativa, e são chamadas de subgaussianas (Hyvärinen *et al*, 2001).

A fim de separar sinais utilizando-se a curtose como medida de gaussianidade, consideremos que \mathbf{y} possui variância unitária, da mesma forma que \mathbf{s} , e que pode ser representado como uma transformação linear de duas componentes independentes (s_1 e s_2), de forma que:

$$\mathbf{y} = \mathbf{w}^T \mathbf{x} = \mathbf{w}^T \mathbf{A} \mathbf{s} = \mathbf{q}^T \mathbf{s} = q_1 s_1 + q_2 s_2 \quad (3.21)$$

$$E[\mathbf{y}^2] = q_1^2 + q_2^2 = 1 \quad (3.22)$$

A Equação 3.22 mostra que, como \mathbf{s} e, conseqüentemente, \mathbf{y} , possuem variância unitária, o vetor \mathbf{q} define um círculo com raio unitário. Já a curtose de \mathbf{y} é definida por:

$$\text{curt}(\mathbf{y}) = \text{curt}(q_1 s_1) + \text{curt}(q_2 s_2) = q_1^4 \text{curt}(s_1) + q_2^4 \text{curt}(s_2) \quad (3.23)$$

Considerando um caso em que as componentes de \mathbf{s} possuem curtose unitária, chega-se à função:

$$\text{curt}(\mathbf{y}) = q_1^4 + q_2^4 \quad (3.24)$$

A Equação 3.24 pode ser representada graficamente pela Figura 3.18, junto com a representação do círculo unitário definido por \mathbf{q} . A idéia é identificar pontos onde o plano formado pela Equação 3.24 possui os maiores valores dentro do círculo unitário definido por \mathbf{q} . É possível notar, a partir da Figura 3.24, que os pontos de máxima curtose definido pela Equação 3.24 coincidem com os pontos onde o vetor q_1 é nulo e q_2 é igual a ± 1 , e onde q_2 é nulo e q_1 é igual a ± 1 , ou seja, quando uma das componentes é nula, encontra-se a outra, desprezando-se o sinal. Desta forma, é possível separar s_1 e s_2 . O mesmo ocorre para distribuições com curtose diferente de 1 e diferente de zero (Hyvärinen *et al*, 2001).

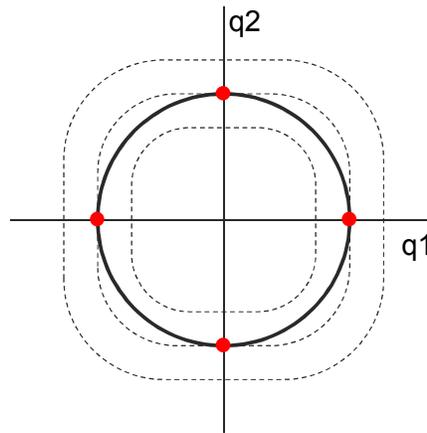


Figura 3.18 – Representação do plano da curtose limitado pelo círculo unitário em \mathbf{q} . Explicação no texto. (Modificado de Hyvärinen *et al*, 2001)

Considerando agora observações descorrelacionadas e brancas, pretende-se encontrar um vetor \mathbf{w} que maximize a não-gaussianidade de \mathbf{y} . Da Equação 3.13, tem-se:

$$\mathbf{y} = \mathbf{w}^T \mathbf{z} = \mathbf{w}^T \mathbf{V} \mathbf{x} = \mathbf{w}^T \mathbf{A} \mathbf{s} \quad (3.25)$$

A partir da Equação 3.25 é possível definir o vetor de busca \mathbf{q} da seguinte forma:

$$\mathbf{q} = (\mathbf{V} \mathbf{A})^T \mathbf{w} \quad (3.26)$$

Adicionalmente, a Equação 3.22 mostra que o vetor de busca \mathbf{q} define um círculo de raio unitário. Da Equação 3.26, tem-se que

$$\|\mathbf{q}\|^2 = (\mathbf{w}^T \mathbf{V} \mathbf{A}) (\mathbf{V}^T \mathbf{A}^T \mathbf{w}) = \|\mathbf{w}\|^2 \quad (3.27)$$

A Equação 3.27 mostra que, graças ao branqueamento, limitar \mathbf{q} em um círculo unitário equivale a limitar \mathbf{w} em um círculo unitário. Logo, \mathbf{w} pode ser utilizado como um vetor que maximiza a não-gaussianidade de \mathbf{y} .

Assim, cria-se um vetor \mathbf{w} que percorre toda a superfície da mistura decorrelacionada com variância unitária \mathbf{z} , gerando projeções $\mathbf{w}^T \mathbf{z}$. Desta forma, é possível calcular a curtose dessa projeção (Figura 3.19a). Relacionando-se o ângulo de \mathbf{w} com a curtose da projeção, pode-se identificar regiões da mistura que se aproximam de uma componente independente (Figura 3.19b). Para encontrar outras componentes independentes, basta considerar projeções de \mathbf{w} ortogonais às previamente utilizadas, pois \mathbf{z} possui componentes decorrelacionadas e, portanto, ortogonais entre si.

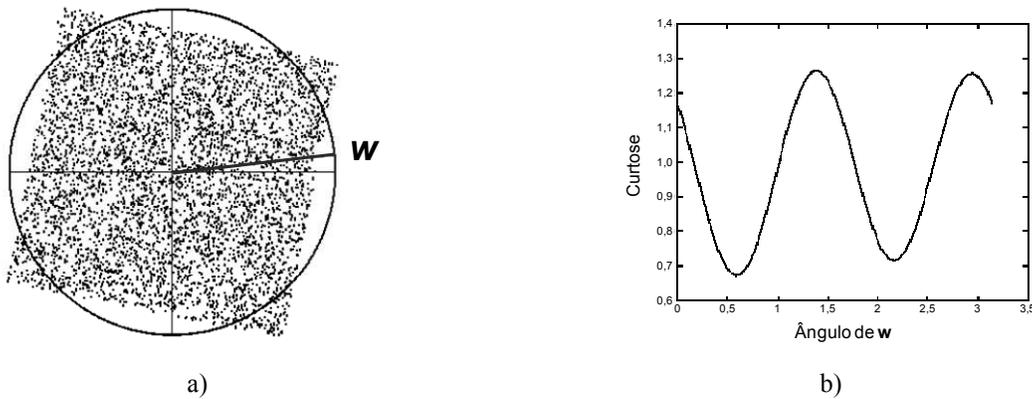


Figura 3.19 – Representação da varredura da matriz de separação \mathbf{W} pra localizar pontos de curtose mínima ou máxima. a) Rotação de \mathbf{W} no gráfico de dispersão entre duas variáveis branqueadas gerando a combinação linear $\mathbf{W}^T \mathbf{z}$. b) Diferentes valores de curtose em função do ângulo de \mathbf{W} em $\mathbf{W}^T \mathbf{z}$ (Modificado de Hyvärinen *et al*, 2001).

A ICA, contudo, não consegue separar misturas de fontes gaussianas. Isso fica claro na Figura 3.20. Ao rotacionar \mathbf{W} em uma distribuição de duas variáveis gaussianas, a projeção de \mathbf{W} na distribuição não identificará nenhum ponto de máxima nem de mínimo da curtose, pois a curtose da projeção $\mathbf{W}^T \mathbf{z}$ será sempre a mesma para qualquer direção de \mathbf{W} . Desta forma, a ICA consegue separar fontes independentes entre si e somente uma fonte gaussiana. Ou seja, caso existam duas ou mais fontes gaussianas nas misturas, a ICA não conseguirá separá-las. Outros

métodos de BSS, que utilizam apenas estatísticas de segunda ordem e exploram a informação temporal dos sinais observados, podem ser utilizados para separar fontes com distribuição gaussiana, como o AMUSE e SOBI (ver seção 3.2.5 – Outros Métodos Para Separação Cega de Fontes).

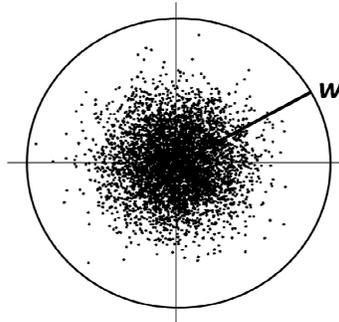


Figura 3.20 – Distribuição de duas variáveis gaussianas. (Modificado de Hyvärinen & Oja, 2000)

A curtose apresenta a desvantagem de ser muito sensível a *outliers* quando calculada a partir de amostras, ou seja, um valor fora do contexto pode alterar significativamente o valor global da curtose. Desta forma, a curtose não é um método robusto o bastante para a medida de gaussianidade. Um outro método proposto por pesquisadores é conhecido como negentropia, ou seja, a negação da entropia (Suyama, 2007).

A entropia de uma variável aleatória é a medida de incerteza dessa variável aleatória. Também pode ser entendida como a medida da quantidade de informação necessária para descrever uma variável aleatória (Cover & Thomas, 1991). Quanto mais imprevisível for uma variável aleatória, maior é a entropia dessa variável (Hyvärinen & Oja, 2000). A entropia H é definida, para valores discretos de uma variável aleatória X , como (Hyvärinen *et al*, 2001):

$$H(X) = -\sum_i P(X = a_i) \log P(X = a_i) \quad (3.28)$$

onde a_i são possíveis valores de X . Usualmente, o logaritmo na Equação 3.28 é de base 2 e a unidade de H é chamada *bit*.

A entropia pode ser ilustrada pela probabilidade do lançamento de uma moeda (Figura 3.21). Considerando cara 1 e coroa 0, nota-se que o resultado de cada lançamento é menos previsível quando $p = 0,5$. Caso $p = 1$, o resultado será obrigatoriamente cara, caso $p = 0$, o resultado será coroa. Logo, a entropia é nula, pois o resultado é perfeitamente previsível.

Contudo, caso $p = 0,5$, a habilidade de prever o resultado é mínima. Nesse último caso, a distribuição do resultado possui máxima entropia (Stone, 2004).

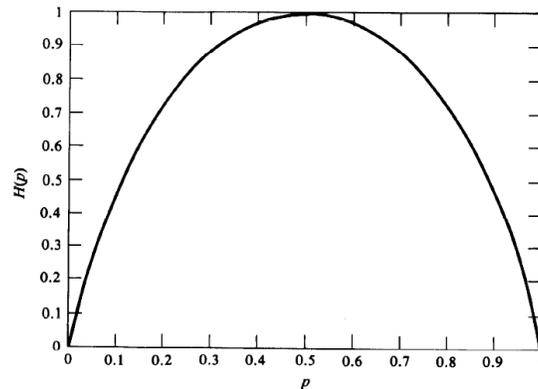


Figura 3.21 – Entropia ($H(p)$) referente à probabilidade (p) vinculada ao lançamento de uma moeda (Modificado de Cover & Thomas, 1991).

Pode-se estimar a máxima entropia de uma variável aleatória discreta através da observação dos valores adotados pela variável e, desta forma, definir a fdp dessa variável para a condição de máxima entropia dentro dos limites dos momentos da variável (*e.g.* média, variância etc.), de tal forma que essa fdp seja a mais aleatória possível. Sabe-se que variáveis com distribuição gaussiana apresentam as maiores entropias entre as variáveis aleatórias (Cover & Thomas, 1991). Isso significa que variáveis com distribuições gaussianas são mais aleatórias ou imprevisíveis que variáveis com outros tipos de distribuição. Desta forma, pode-se utilizar a entropia como medida de gaussianidade, da mesma forma como a curtose (Hyvärinen *et al*, 2001).

O critério utilizado para obter a medida de não-gaussianidade é chamado de negentropia (Equação 3.29), e é nula para variáveis com distribuição gaussiana e sempre apresenta valores positivos para variáveis não-gaussianas. Esse método é mais robusto que a curtose, porém exige um custo computacional consideravelmente maior.

$$J(y) = H(y_{gauss}) - H(y) \quad (3.29)$$

onde y_{gauss} é uma variável aleatória gaussiana com mesma variância que y . Como variáveis com distribuição gaussiana apresentam as maiores entropias entre as variáveis aleatórias, a Equação 3.29 mostra que a negentropia sempre será positiva, e será nula se, e somente se, y apresentar distribuição gaussiana.

A estimativa da negentropia é difícil e algumas aproximações devem ser feitas na prática. O método clássico para aproximação da negentropia utiliza momentos centrais como a curtose (Equação 3.30), porém essa aproximação apresenta os mesmos inconvenientes que os citados para o método da curtose.

$$J(y) \approx \frac{1}{12} \mathbf{E}[y^3]^2 + \text{curt}(y)^2 \quad (3.30)$$

Desta forma, novas aproximações foram desenvolvidas, baseadas no princípio de máxima entropia:

$$J(y) \approx \sum_i^p k_i \{ \mathbf{E}[G_i(y)] - \mathbf{E}[G_i(v)] \}^2 \quad (3.31)$$

onde k_i são constantes positivas, v é uma variável aleatória com distribuição gaussiana de média nula e variância unitária, e G_i são funções não-lineares. Considera-se que y foi centralizado e passou por branqueamento. Desta forma, a Equação 3.31 pode ser utilizada para medir a gaussianidade de forma que será nula se y apresentar distribuição gaussiana e positiva para outras distribuições (Hyvärinen & Oja, 2000).

Maiores detalhes matemáticos e teóricos referentes aos métodos de medida de gaussianidade podem ser encontrados nas referências Cover e Thomas (1991), Hyvärinen e Oja (2000), Hyvärinen *et al* (2001). Os métodos citados podem ser utilizados em uma das ferramentas de separação de fontes mais utilizadas da atualidade, o algoritmo conhecido como FastICA.

3.2.4 FASTICA

Os métodos mostrados na seção anterior para maximização da não-gaussianidade podem ser solucionados via RNA, onde a matriz de separação \mathbf{W} pode ser vista como os pesos das conexões entre os neurônios artificiais e a matriz de misturas centralizadas e brancas, \mathbf{z} , são aplicadas nas entradas da RNA. Contudo, a convergência da RNA para encontrar os pontos de não-gaussianidade é demorada e depende da escolha de uma taxa de aprendizado correta (Hyvärinen *et al*, 1997).

O algoritmo FastICA foi desenvolvido a fim de fornecer uma taxa de convergência rápida e robusta, baseado no método do ponto fixo (MPF), muito utilizado em cálculo numérico (Hyvärinen *et al*, 1997, Hyvärinen *et al*, 2001).

O MPF é utilizado para encontrar as raízes de uma equação, ou seja, encontrar soluções numéricas para uma variável que possa ser representada na forma $f(x) = 0$. Nesse contexto, seja $f(x)$ uma função contínua em $[a, b]$, intervalo que contém uma raiz ξ da equação $f(x) = 0$. O MPF consiste em transformar esta equação em uma equação equivalente $x = g(x)$ e, a partir de uma aproximação inicial x_0 , gerar a seqüência $\{x_k\}$ de aproximações para ξ pela relação $x_{k+1} = g(x_k)$, pois a função $g(x)$ é tal que $f(\xi) = 0$ se, e somente se, $g(\xi) = \xi$. Dessa forma, transforma-se o problema de encontrar um zero de $f(x)$ no problema de encontrar um ponto fixo de $g(x)$.

O FastICA integra MPF e medidas de gaussianidade por curtose ou negentropia. O FastICA por curtose é descrito brevemente a seguir. Considerando \mathbf{w} o vetor de separação e \mathbf{x} a matriz contendo as misturas centralizadas e brancas, Hyvärinen e colaboradores (Hyvärinen *et al*, 1997) mostraram que, a fim de localizar ponto de curtose máxima ou mínima da projeção $\mathbf{W}^T \mathbf{x}$, o algoritmo em RNA considera \mathbf{w} como sendo o vetor de peso da RNA e aplicando-se \mathbf{x} nas entradas da RNA. De acordo com a Equação 3.19, tem-se:

$$\text{curt}(\mathbf{w}^T \mathbf{x}) = E\left[(\mathbf{w}^T \mathbf{x})^4\right] - 3\left\{E\left[(\mathbf{w}^T \mathbf{x})^2\right]\right\}^2 = E\left[(\mathbf{w}^T \mathbf{x})^4\right] - 3\|\mathbf{w}\|^4 \quad (3.32)$$

$$J(\mathbf{w}) = E\left[(\mathbf{w}^T \mathbf{x})^4\right] - 3\|\mathbf{w}\|^4 + F(\|\mathbf{w}\|^2) \quad (3.33)$$

onde $J(\mathbf{w})$ é chamada de função custo e F é um termo presente devido à condição de $\|\mathbf{w}\| = 1$. Nesse contexto, a exata forma de F não é importante a fim de se definir o algoritmo de aprendizagem da RNA, mostrado na Equação 3.34 (Hyvärinen *et al*, 1997):

$$\mathbf{w}_{t+1} = \mathbf{w}_t \pm \mu_t \left[\mathbf{x}_t (\mathbf{w}_t^T \mathbf{x}_t)^3 - 3\|\mathbf{w}_t\|^2 \mathbf{w}_t + f(\|\mathbf{w}_t\|^2) \mathbf{w}_t \right] \quad (3.34)$$

onde \mathbf{x}_t contém os vetores de observações, μ_t é a seqüência da taxa de aprendizagem da RNA e f é a derivada de $F/2$ mostrado na Equação 3.33. O sinal “ \pm ” previamente a μ_t define se a Equação 3.34 convergirá para um ponto de curtose máximo ou mínimo.

Os pontos fixos \mathbf{w} do algoritmo de aprendizagem da RNA (Equação 3.34) são obtidos ao considerar os momentos centrais da Equação 3.34, e igualando-se o passo do peso \mathbf{w} a zero:

$$E[\mathbf{x}(\mathbf{w}^T \mathbf{x})^3] - 3\|\mathbf{w}\|^2 \mathbf{w} + f(\|\mathbf{w}\|^2) \mathbf{w} = \mathbf{0} \quad (3.35)$$

Uma iteração determinística pode ser formada a partir da Equação 3.35 utilizando-se métodos numéricos, como o MPF, e pode-se obter uma iteração rápida a partir de:

$$\mathbf{w} = a \times \left(E[\mathbf{x}(\mathbf{w}^T \mathbf{x})^3] - 3\|\mathbf{w}\|^2 \mathbf{w} \right) \quad (3.36)$$

onde a representa efeitos de normalizações ou o efeito da projeção de \mathbf{w} como um círculo unitário. As Equações 3.35 e 3.36 remetem à condição necessária do MPF, onde uma função $x=g(x)$ é gerada a partir de $f(x) = 0$.

Considerando-se que \mathbf{x} foi centralizado e possui variância unitária, os passos para identificar \mathbf{w} no algoritmo FastICA, tal que seja capaz de identificar fontes independentes contidas em \mathbf{x} , são (Hyvärinen *et al*, 1997):

1. Gera-se um vetor inicial aleatório \mathbf{w} e considera-se $k = 1$;
2. Calcula-se:

$$\mathbf{w}_k = E[\mathbf{x}(\mathbf{w}_{k-1}^T \mathbf{x})^3] - 3\mathbf{w}_{k-1} \quad (3.37)$$

onde a expectativa $E\{\cdot\}$ pode ser obtida através das várias amostras do vetor \mathbf{x} .

3. Divide-se \mathbf{w}_k por sua norma;
4. Caso $|\mathbf{w}_k^T \mathbf{w}_{k-1}|$ não for próximo o suficiente de um critério previamente estabelecido, considera-se $k = k + 1$ e volta-se ao passo 2. Caso contrário, adota-se o vetor \mathbf{w}_k como o vetor de separação para o sistema.

Desta forma, o vetor \mathbf{w}_k encontrado pelo algoritmo é igual a uma das colunas da matriz inversa da matriz de mistura, \mathbf{A}^{-1} , mostrada na Equação 3.25. Isso significa que \mathbf{w}_k separa uma das fontes não-gaussianas, de forma que $\mathbf{w}_k^T \mathbf{x}$ se iguala a uma das componentes de \mathbf{s} com um ganho devido ao vetor \mathbf{w} . Uma das vantagens desse algoritmo é que ele precisa de poucas

iterações para convergir para o ponto de não-gaussianidade, sendo necessário geralmente entre 5 e 10 iterações.

Maiores detalhes sobre o algoritmo FastICA por curtose ou negentropia podem ser encontradas em Hyvärinen *et al*, 1997, Hyvärinen e Oja, 2000, Hyvärinen *et al*, 2001 e Duarte, 2006.

3.2.5 OUTROS MÉTODOS DE SEPARAÇÃO CEGA DE FONTES

Existem vários métodos que visam separação de fontes baseado apenas no conhecimento de misturas. O conceito de ICA se baseia nas hipóteses de independência e não-gaussianidade das fontes. No entanto, dependendo da aplicação, têm-se informações *a priori* sobre a natureza das fontes, e até mesmo sobre o processo de mistura dos sinais.

Existe um grupo de métodos de BSS que utiliza apenas estatística de segunda ordem para separar fontes. São algoritmos simples e efetivos, e a separação de fontes pode ser obtida se as densidades espectrais de potência das fontes forem distintas entre si (Equação 3.38):

$$E[s_i(k)s_i(k-l)] \neq E[s_j(k)s_j(k-l)] \quad (3.38)$$

para $i \neq j$, e $l \neq 0$.

Apesar dos MUAPs possuírem a mesma densidade espectral, os algoritmos desta classe exploram a informação temporal dos sinais observados para efetuar a recuperação das fontes (Suyama, 2007), o que pode ser considerado para decomposição de sinais sEMG, já que cada UM possui taxas de disparo e velocidades de condução diferentes entre si.

Considerando-se que os sinais observados sejam ortogonais, pode-se dizer que a matriz de autocorrelação dos sinais observados para um atraso l será dada por (Suyama, 2007):

$$R_x(l) = E[\mathbf{x}(k)\mathbf{x}^T(k-l)] = \mathbf{Q}R_s(l)\mathbf{Q}^T \quad (3.39)$$

onde $R_s(l)$ denota a matriz de autocorrelação das fontes para um atraso l e \mathbf{Q} é uma matriz ortogonal qualquer.

Dois técnicas muito conhecidas de BSS que utilizam estatísticas de segunda ordem são o Algoritmo para Extração de Múltiplos Sinais Desconhecidos (AMUSE – *Algorithm for Multiple*

Unknown Source Extraction) e a Identificação Cega de Segunda Ordem (SOBI – *Second-Order Blind Identification*).

No algoritmo AMUSE, $R_s(l)$ será uma matriz diagonal, indicando que a Equação 3.39 representa a decomposição em autovalores e autovetores de $R_x(l)$. Dessa forma, realizar a decomposição de $R_x(l)$ resulta na obtenção da matriz de rotação a ser utilizada na recuperação das fontes. Contudo, o AMUSE depende da escolha correta do atraso l para o qual a matriz $R_s(l)$ apresente valores distintos (Romano *et al*, 2009).

O algoritmo SOBI pode ser entendido como uma extensão do AMUSE. Ao invés de considerar apenas um único atraso l , o SOBI considera a informação presente nas matrizes de covariância para diversos atrasos. A consideração de matrizes de covariância torna o método mais robusto a erros na estimativa do valor correto de l , já que a escolha correta deste atraso é crítica para o problema de separação (Romano *et al*, 2009).

Os métodos AMUSE e SOBI fornecem formas simples e eficientes de recuperação das fontes, com a vantagem de que não é necessário que os sinais sejam independentes entre si, apenas descorrelacionados, e também não é feita nenhuma restrição quanto a fontes gaussianas. Contudo, ainda que os espectros sejam diferentes, porém similares entre si, a separação das fontes, embora teoricamente viável, não ocorre na prática.

Enquanto o AMUSE e o SOBI são técnicas de BSS que levam em conta informação temporal dos sinais observados, uma outra técnica é utilizada quando as fontes não assumem valores negativos (ou, equivalentemente, positivos), uma condição natural em aplicações como, por exemplo, análise de imagens. A hipótese de não-negatividade ou de positividade de sinais, conhecida como análise por componentes independentes não-negativas, trabalha conjuntamente com as hipóteses de independência e não-negatividade das fontes, e estas considerações permitem derivar algoritmos simples e efetivos para separação dos sinais. Desta forma, é possível separar as fontes construindo funções custo que expressem a condição de não-negatividade dos elementos de \mathbf{y} . Após a etapa de branqueamento dos dados, recuperar as fontes seria equivalente a determinar a rotação dos dados que torna as estimativas novamente não-negativas (Romano *et al*, 2009).

Alguns pesquisadores já tratam a eletromiografia como uma técnica de análise de imagem devido à captura de sinais sEMG por matrizes de eletrodos de alta densidade (Merletti *et al*, 2008). Nesse caso, a análise por componentes independentes não-negativas poderia ser considerada para decomposição dos sinais sEMG.

Outro método utilizado para separação de fontes é conhecida como análise de componentes esparsas (SCA – *Sparse Component Analysis*). Conforme o próprio nome indica, a abordagem baseia-se na hipótese de esparsidade das fontes, ou seja, na maior parte do tempo as fontes assumem valores próximos a zero e são ativas em diferentes momentos, umas das outras (Romano *et al*, 2009). O interesse nesse método surge justamente pela característica do controle motor no recrutamento de UMs durante uma contração muscular. Cada UM possui uma frequência de disparo específica e, conseqüentemente, são ativadas em diferentes momentos umas em relação a outras, e assumem valores próximos a zero a maior parte do tempo quando não estão ativas.

Os métodos AMUSE e o SOBI levam em conta as informações de segunda ordem no problema de separação por meio de uma diagonalização da matriz de correlação (ou covariância) de um vetor que contém misturas \mathbf{x} . Já o JADE (*Joint Approximate Diagonalization of Eigenmatrices*) utiliza processos de diagonalização de matrizes que contêm informações provenientes de estatística de ordem superior. No caso, a estatística de ordem superior no JADE é definida por cumulantes (Cardoso & Souloumiac, 1993). Considera-se o JADE como um método de BSS baseado em ICA, já que também busca separar fontes baseado na independência estatística.

Cumulantes (k_n) englobam um conjunto de grandezas que fornecem outra forma de representar a fdp de uma variável aleatória. Os cumulantes de uma fdp estão relacionados aos momentos centrais de uma fdp. Por exemplo, considerando uma variável aleatória \mathbf{x} com média $\mu = E[\mathbf{x}]$ e variância $\sigma^2 = E[(\mathbf{x} - \mu)^2]$. Nesse caso, os dois primeiros cumulantes da fdp são $k_1 = \mu$ e $k_2 = \sigma^2$ (Romano *et al*, 2009).

Assim como a correlação, os cumulantes conjuntos serão nulos para qualquer ordem n se os dados forem independentes entre si. Desta forma, a idéia básica do JADE é realizar a diagonalização, não apenas da matriz de correlação, mas de diferentes matrizes de cumulantes

(Duarte, 2006). O método JADE foi originalmente proposto para sinais complexos, de forma que pode ser diretamente aplicado ao problema de separação no domínio da frequência (Suyama, 2007).

Uma técnica que merece destaque é a maximização da informação (Infomax – *Information Maximization*), intimamente relacionado com processamento não-linear provido por RNA (Romano *et al*, 2009). Conforme visto anteriormente, a entropia de uma variável aleatória fornece uma idéia da quantidade de informação que esta variável possui uma variável com distribuição gaussiana apresenta a maior entropia dentre as distribuições com mesma variância.

A entropia marginal é a entropia da própria variável ($H(X)$ ou $H(Y)$). Pode-se definir a entropia conjunta $H(X,Y)$ (Equação 3.40) como a medida da incerteza condicionada por duas variáveis aleatórias com distribuição conjunta dada por $p(x,y)$. Já a entropia condicional $H(X|Y)$ (Equação 3.41) fornece uma idéia sobre a incerteza restante em x após observar o valor de y . Desta forma, pode-se definir informação mútua $I(X;Y)$ (Equação 3.42) como sendo a quantidade de informação que Y contém em X e vice-versa. A Figura 3.22 ilustra a relação entre essas três propriedades (Cover & Thomas, 1991).

$$H(X,Y) = -\sum_x \sum_y p(x,y) \log p(x,y) \quad (3.40)$$

$$H(X|Y) = \sum_x p(x) H(Y|X=x) \quad (3.41)$$

$$I(X;Y) = H(X) - H(X|Y) \quad (3.42)$$

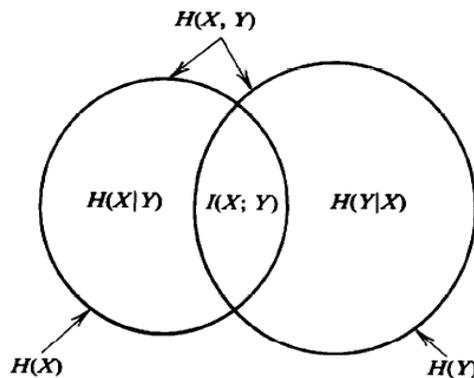


Figura 3.22 – Relação entre entropia e informação mútua (Modificado de Cover & Thomas, 1991).

Considerando a Figura 3.23, onde \mathbf{A} representa a matriz de mistura, o sistema de separação engloba uma RNA com uma parte linear (a matriz \mathbf{W}) e uma parte não-linear $f_i(\cdot)$, aplicada a cada uma das saídas y_n , de forma a definir o vetor:

$$\mathbf{f}(\mathbf{y}) = [f_1(y_1) \quad f_2(y_2) \quad \cdots \quad f_N(y_N)]^T \quad (3.43)$$

onde as funções não-lineares aumentam monotonicamente, com $f_i(-\infty)=0$ e $f_i(\infty)=1$.

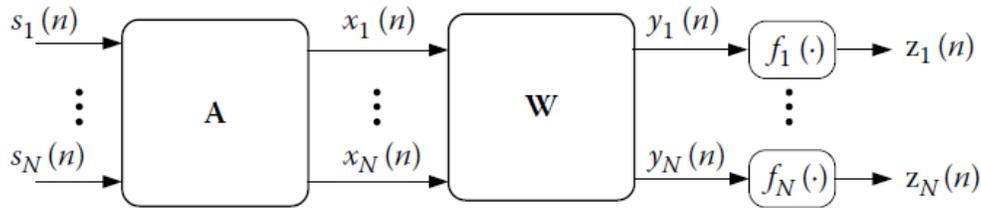


Figura 3.23 – Estrutura do sistema separador no critério Infomax (Modificado de Romano *et al*, 2009).

De acordo com o princípio do Infomax, os coeficientes da RNA devem ser ajustados de forma a maximizar a quantidade de informação presente nas saídas z_n . Isso mostra que \mathbf{W} deve ser escolhido de forma a maximizar a informação mútua entre as misturas \mathbf{x} e as fontes estimadas \mathbf{z} , $\max_{\mathbf{W}} I(\mathbf{x}, \mathbf{z})$. Na ausência de ruído, a maximização da informação mútua entre a entrada e a saída equivale à maximização da entropia conjunta das saídas \mathbf{z} , $\max_{\mathbf{W}} H(\mathbf{z})$.

A maximização da entropia conjunta é relacionada à maximização das entropias marginais e à minimização da informação conjunta entre os elementos de \mathbf{z} , ou seja:

$$H(\mathbf{z}) = \sum_{i=1}^N H(z_i) - I(\mathbf{z}) \quad (3.46)$$

Assim, a maximização da entropia conjunta tende, em geral, à redução a dependência estatística entre as componentes de saída da RNA e, conseqüentemente, à dependência entre os elementos de \mathbf{y} .

No Infomax, as funções não-lineares $f_i(\cdot)$ possuem duas funções importantes: elas limitam os valores das variáveis z_n e, conseqüentemente, das respectivas entropias; a independência estatística da saída da RNA está relacionada com a escolha adequada dessas funções não-lineares (Romano *et al*, 2009).

Capítulo 4

Materiais e Métodos

COM o intuito de se criar um ambiente propício para a decomposição de sinais sEMG nos seus constituintes MUAPs, desenvolveu-se um sistema de captura de sinais sEMG com até sete canais que permitisse coletas fidedignas da atividade mioelétrica (Figura 4.1).

4.1 Sistema para Captura e Separação de Sinais Eletromiográficos

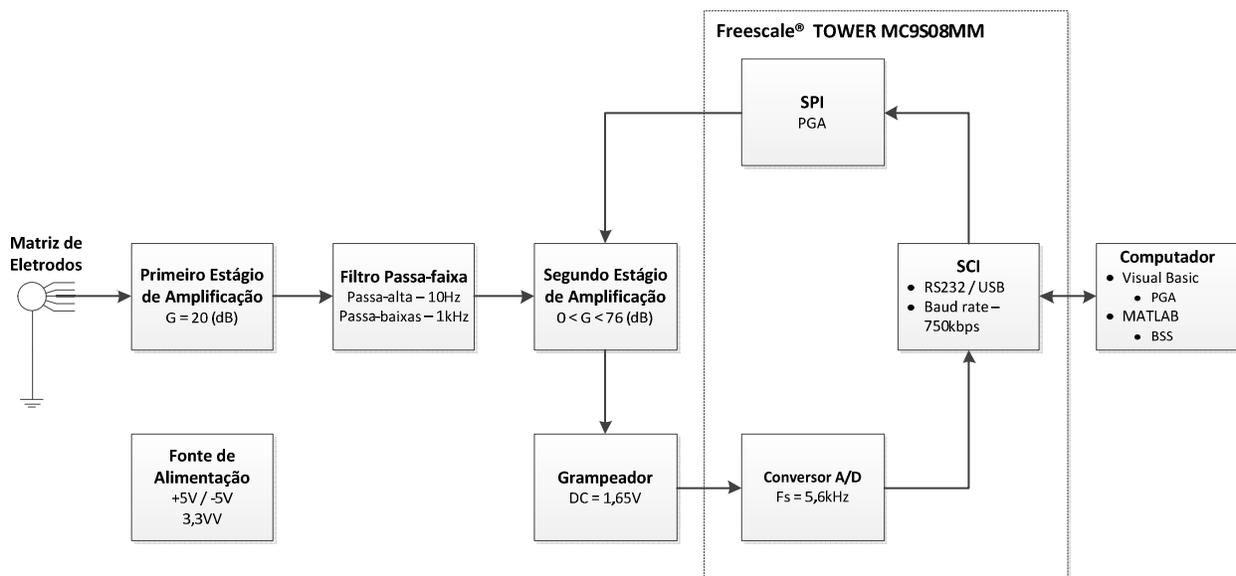


Figura 4.1 – Diagrama em blocos do sistema de captura e separação de sinais eletromiográficos de superfície.

O sistema foi desenvolvido para capturar cinco segundos de sinais sEMG. É constituído por fontes de $\pm 5V$ e $3,3V$, e cada um dos sete canais integra: primeiro estágio de amplificação e filtro passa-faixa (10Hz a 1kHz); segundo estágio de amplificação, que utiliza um amplificador de ganho programável (PGA – *Programmable Gain Amplifier*); grampeador de tensão; conversor A/D 16 bits; Interface de Comunicação Serial (SCI – *Serial Communication Interface*); Interface Periférica Serial (SPI – *Serial Peripheral Interface*); computador pessoal (PC – *Personal Computer*) tipo laptop. O conversor A/D, o SCI e SPI são módulos do TWR-S08MM128, sistema embarcado gentilmente doado pela Freescale®.

Os sinais capturados são amplificados, filtrados e transmitidos serialmente para um PC, onde são armazenados. Desenvolveu-se um *software* no PC para controle de captura de sinais sEMG em Visual Basic®. O *software* permite a visualização dos sinais capturados nos sete canais, auxiliando em uma análise inicial, verificando a qualidade dos sinais capturados. O ganho programável do PGA é calculado pelo *software* de captura, levando em consideração a amplitude dos sinais capturados. Esse ganho é transmitido para o TWR-S08MM128 via SCI que, por sua vez, encaminha o ganho para o PGA através da SPI. Os sinais sEMG capturados após atualização do ganho programável são armazenados para pós-processamento e decomposição, ambos realizados em um *software* desenvolvido em ambiente MATLAB®. O pós-processamento permite a escolha de alguns filtros digitais e a visualização de diferentes segmentos de tempo dos sinais capturados. O *software* utiliza o algoritmo FastICA (Hyvärinen & Oja, 1997) para decomposição dos sinais sEMG.

4.1.1 FONTE DE ALIMENTAÇÃO

Para alimentação dos blocos de primeiro estágio de amplificação, filtro passa-faixas e o segundo estágio de amplificação de ganho programável utilizou-se uma fonte simétrica regulada em $\pm 5V$. Duas baterias comuns de 9V foram utilizadas para gerar tensões de $\pm 9V$, sendo reguladas para $+5V$ e $-5V$ utilizando-se reguladores de tensão UA7805 (Texas Instruments) e LM7905 (National Semiconductor), respectivamente. O TWR-S08MM128 foi alimentado através do cabo USB conectado ao computador, pois consome corrente muito alta para que seja suportada por longos períodos pelas baterias de 9V. O grampeador utilizou tensão

de 3,3V regulada pelo próprio TWR-S08MM128. Durante o processo de captura, o computador (tipo *laptop*) é desconectado da rede elétrica, mantendo-se ligado através da bateria. Logo, o protótipo encontra-se totalmente isolado da rede elétrica, protegendo o paciente de eventuais choques elétricos de 60Hz e minimizando consideravelmente a probabilidade de choque elétrico geral ao paciente.

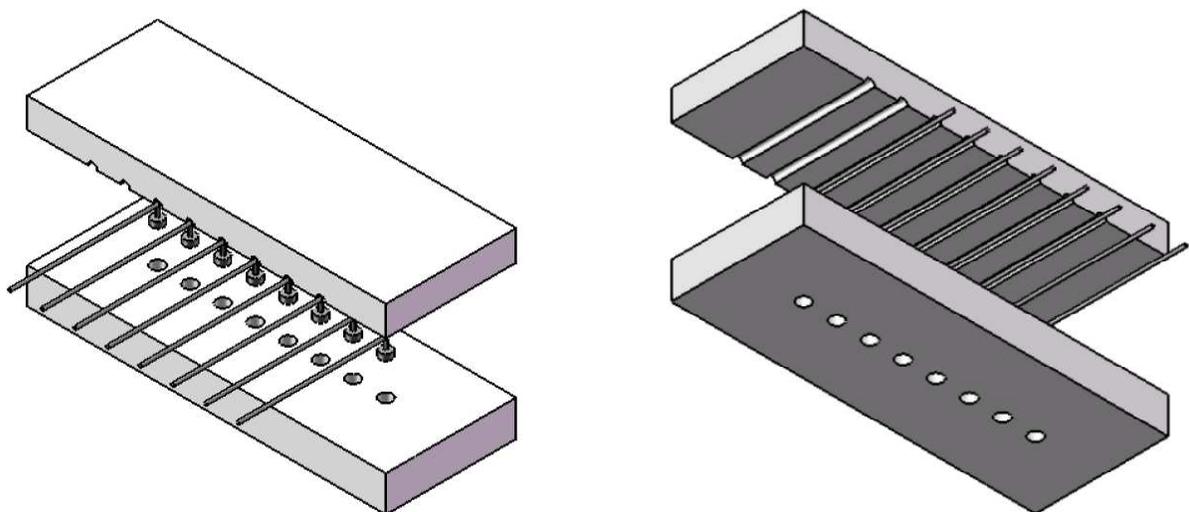
4.1.2 MATRIZ DE ELETRODOS

Eletrodos comerciais para captura sinais sEMG possuem superfície de captura muito grande para os propósitos deste trabalho, com aproximadamente um centímetro de diâmetro. Eletrodos com essas dimensões abrangem uma área de captura muito grande, capturando a atividade elétrica de várias UMs. A fim de capturar sinais elétricos de uma quantidade menor de UMs, eletrodos com dimensões reduzidas foram construídos.

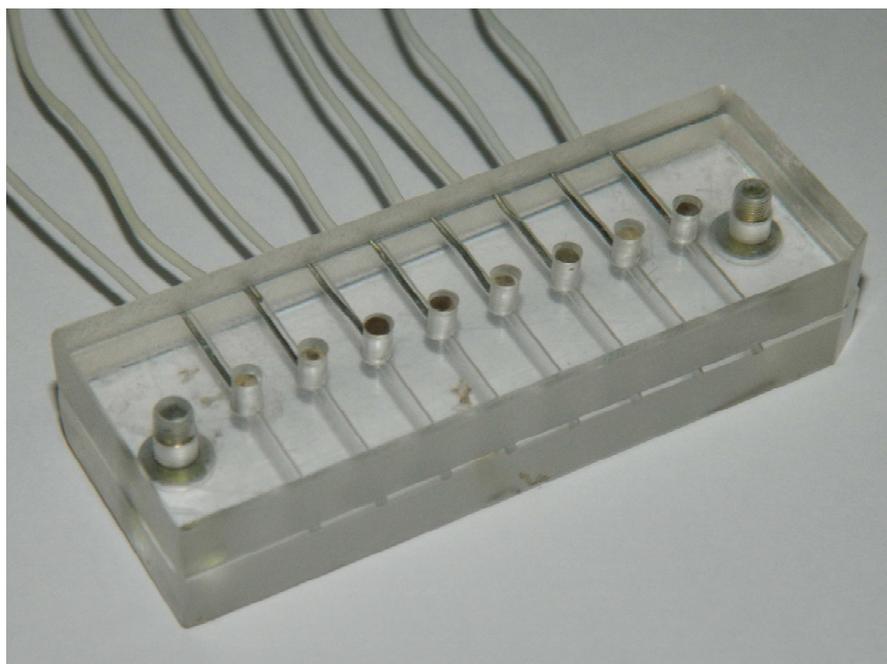
A fabricação de eletrodos de Ag-AgCl em dimensões reduzidas para captura de biopotenciais formam, por si só, uma linha de pesquisa extensa e complexa. Com o intuito de superar essa limitação, construiu-se cilindros de prata que foram, posteriormente, cloretados.

Construiu-se cilindros de prata pura, com 2mm de diâmetro e 1mm de altura. Esses cilindros foram desengordurados com éter e água deionizada, e mergulhados em uma solução contendo hipoclorito de sódio por 15 minutos, tempo suficiente para o cloreto ser depositado na prata. Esse procedimento foi baseado em uma rotina comumente realizada no Laboratório de Pesquisa Cardiovascular (LPCv) do Centro de Engenharia Biomédica (CEB) na UNICAMP em outros eletrodos, atingindo resultados satisfatórios. Os eletrodos foram posicionados em um suporte de acrílico construído no Laboratório Técnico do CEB (Figura 4.2).

O suporte de acrílico possui guias e furos para posicionar até oito eletrodos, de forma que os eletrodos fiquem alinhados e imóveis durante a captura, e igualmente espaçados em 3,5mm entre seus centros. Os cilindros são posicionados de tal forma a ficarem 1mm para dentro do suporte de acrílico, deixando um espaço entre a superfície dos eletrodos até o final do suporte de acrílico para aplicação de gel condutor. A presença de oito eletrodos no suporte de acrílico permite até sete canais de captura bipolares. Esses procedimentos foram realizados no Laboratório de Reabilitação Sensório-Motora do CEB/UNICAMP.



a)



b)

Figura 4.2 – Matriz de eletrodos com oito elementos em uma fileira. Cada eletrodo tem 2mm de diâmetro. Oito elementos permitem até sete canais bipolares. a) Esquemático da matriz de eletrodos compondo o suporte de acrílico e os oito eletrodos de Ag-AgCl. b) Foto da matriz de eletrodos que foi utilizada na validação deste trabalho.

4.1.3 PRIMEIRO ESTÁGIO DE AMPLIFICAÇÃO

Também conhecido como amplificador de biopotenciais, o primeiro estágio de amplificação é composto por um amplificador de instrumentação com entrada bipolar diferencial e um filtro passa-faixas.

A amplitude dos sinais sEMG capturados com esse protótipo pode variar de $50\mu\text{V}$ a 5mV . O sinal capturado é posteriormente convertido para valores digitais. Logo, deve-se garantir que o sinal seja amplificado de forma a garantir melhor resolução digital possível. Considerando que o conversor Analógico/Digital (Conversor A/D) é alimentado por uma tensão de $3,3\text{V}$, o sinal capturado deve ser amplificado de forma a atingir a tensão de alimentação do conversor A/D, ou seja, $3,3\text{V}$ de pico-a-pico (V_{pp}). Desta forma, o sinal sEMG deve ser amplificado em uma faixa de 660 a 66000 vezes ($56,39\text{dB} - 96,39\text{dB}$).

Contudo, o primeiro estágio de amplificação não visa amplificar o sinal capturado por completo. Uma das principais funções dessa etapa de amplificação é garantir alta impedância de entrada do sistema de captura de forma a isolar o sistema medido. Além disso, quanto maior a amplificação, menor é o CMRR apresentado pela maioria dos amplificadores, o que pode prejudicar em muito a capacidade de eliminar ruídos em modo comum, *e.g.*, 60Hz da rede elétrica.

Com isso em mente, utilizou-se o amplificador de instrumentação INA129, da Texas Instruments, devido às especificações e simplicidade de projeto. Esse componente apresenta CMRR de 106dB para ganhos entre 10 e $100(\text{V}/\text{V})$, impedância de entrada de modo comum em $10^{11}\Omega/9\text{pF}$. Com essa configuração, o INA129 apresenta resposta em frequência plana até frequências superiores a 100kHz , muito acima do desejado para nossa aplicação.

O ganho foi fixado em apenas 20dB ($10\text{V}/\text{V}$) conectando-se um resistor de $5,6\text{k}\Omega$ nos terminais indicados no INA129. Esse ganho foi dimensionado levando-se em conta o bom CMRR e impedância de entrada de modo comum nessa faixa de ganho. O ganho restante é provido pelo segundo estágio de amplificação.

A Figura 4.3 mostra o amplificador de primeiro estágio de biopotenciais para um canal, e a configuração de montagem dos amplificadores de instrumentação para os sete canais pode ser vista na Figura 4.4.

A configuração da matriz de eletrodos junto com esse tipo de montagem entre as entradas dos amplificadores INA129 garante que os sinais sEMG capturados sigam a direção de propagação dos MUAPs em análise quando posicionados corretamente no músculo em questão.

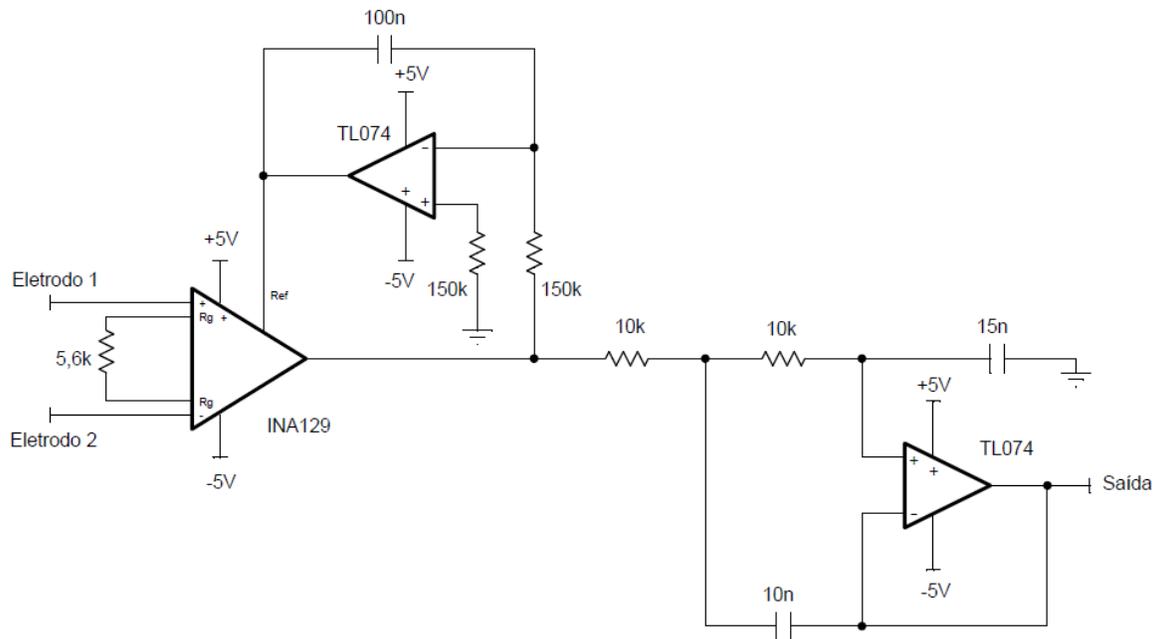


Figura 4.3 – Amplificador de biopotenciais para um canal, integrando um amplificador de instrumentação INA129 com ganho de 20dB, filtro passa-alta acoplado ao INA129 frequência de corte em 10Hz e um filtro passa-baixa Butterworth de dois pólos, na configuração Sallen-Key, com frequência de corte de 1kHz.

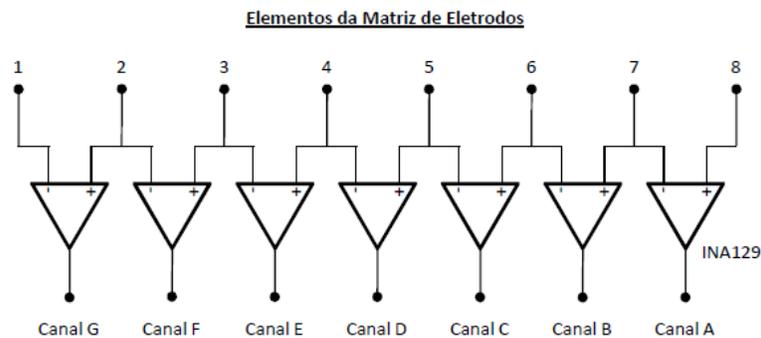


Figura 4.4 – Configuração dos amplificadores diferenciais dos sete canais.

Um filtro passa-faixas foi projetado a fim de limitar as componentes de frequência do sinal capturado ao espectro de frequência de sinais sEMG, geralmente entre 20Hz e 500Hz. Contudo, considerou-se a frequência de corte do filtro passa-baixa em 1kHz, a fim de permitir investigações em sinais sEMG de sujeitos hígidos e sujeitos com algum tipo de desordem neuromuscular que eventualmente tenha um sinal sEMG com o espectro de frequência alterado. O filtro passa-baixa é um Butterworth de dois pólos, na configuração Sallen-Key devido à sua banda passante plana e ao corte suficientemente abrupto para aplicação neste trabalho. Utilizou-se o software FilterPro Desktop Versão 3.0.28.21072, da Texas Instruments e o amplificador operacional TL074, da Texas Instruments, para projeto do filtro.

O filtro passa-alta foi projetado seguindo instruções no *datasheet* do INA129 (Texas Instruments, 2005), que mostra o projeto de um amplificador de instrumentação com acoplamento AC. A construção deste circuito envolve a conexão de um filtro passa-baixa à realimentação do INA129. Com isso, a frequência de corte estipulada para o filtro passa-baixa se torna igual à frequência de corte para o filtro passa-alta. Desta forma, projetou-se um filtro passa-alta de primeira ordem com frequência de corte em 10Hz, visando eliminar componentes DC e artefatos de movimento de baixa frequência.

4.1.4 SEGUNDO ESTÁGIO DE AMPLIFICAÇÃO

Após o sinal ser amplificado e filtrado dentro dos limites de frequência de sinais sEMG pelo primeiro estágio de amplificação, o sinal passa pelo segundo estágio de amplificação, que possui ganho variável e programável.

Diferentemente do primeiro estágio de amplificação, o segundo estágio não tem papel crucial na eliminação de ruídos de modo comum, sendo a principal função deste estágio a amplificação dos sinais sEMG.

Como o sinal fora previamente amplificado em 20dB (10V/V) pelo primeiro estágio de amplificação, a faixa de amplificação do segundo estágio deve ser de aproximadamente 36 a 76dB, respectivamente (66 a 6600 V/V) para garantir que o sinal capturado tenha no máximo a tensão de alimentação do conversor A/D, ou seja, 3,3V de pico-a-pico (V_{pp}). A fim de atender essa faixa de ganho e garantir que os vários valores possíveis de ganho, dentro da faixa especificada, também sejam atendidos com boa precisão, optou-se pelo atenuador de áudio LM1973, da National Semiconductor.

O LM1973 é, originalmente, um atenuador de áudio de três canais, com o nível da atenuação controlada via SPI, com níveis de atenuação de 0 a 76dB com decaimento logarítmico (Figura 4.5). Contudo, quando posicionado na realimentação de um amplificador operacional, no caso um TL074, o LM1973 cria a condição de PGA logarítmico (Figura 4.6). Nessa configuração, os níveis de atenuação do LM1973 se tornam valores de ganho, com maior valor de ganho de 76dB (National Semiconductor, 1994).

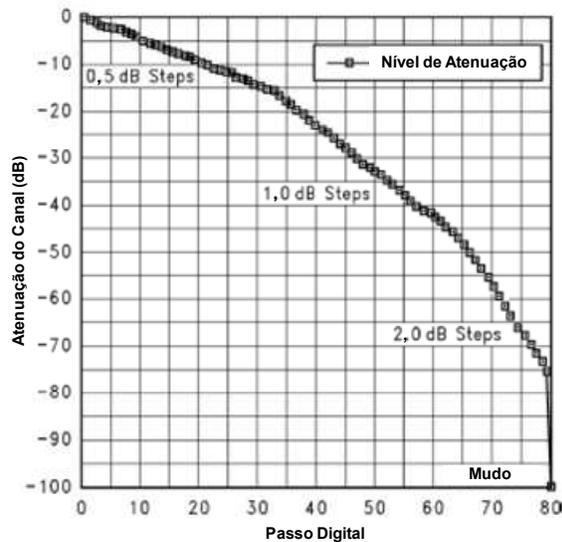


Figura 4.5 – Níveis de atenuação/ganho logarítmico do PGA (Modificado de National Semiconductor, 1994).

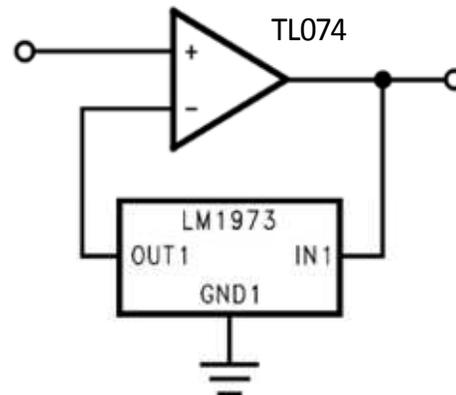


Figura 4.6 – LM1973 na realimentação de um amplificador operacional. Nessa condição, o sistema atua como amplificador de ganho logarítmico (Modificado de National Semiconductor, 1994).

O LM1973 possui três canais e o acesso, ou alteração, dos respectivos ganhos são realizados através de comunicação SPI, que envolve três vias: DATA-IN, CLOCK e LOAD/SHIFT. Para alterar o nível de ganho de um canal, o LOAD/SHIFT deve ir a nível lógico baixo por pelo menos 150ns antes da primeira borda de subida do pulso de CLOCK, e deve permanecer em nível lógico baixo durante toda a transmissão serial de cada bloco de 16 bits na via DATA-IN. A transmissão serial consiste em 8 bits iniciais para seleção do canal e 8 bits para seleção do nível de ganho. Para ambos os bytes, o bit mais significativo é enviado primeiro. Como existem sete canais, foram utilizados quatro PGAs, cada um com três canais. O controle descrito acima é realizado pelo TWR-S08MM128 e foi configurado através de programação C e blocos do Processor Expert no software Codewarrior V6.3®, disponível gratuitamente no *website* da Freescale®.

4.1.5 GRAMPEADOR DE TENSÃO

O sinal sEMG tem alterações na polaridade várias vezes no domínio do tempo, o que torna inviável a conversão A/D nessas condições, pois o conversor A/D não converte sinais negativos. Portanto, após o segundo estágio de amplificação, o sinal passa por um grameador de tensão, que adiciona um nível DC ao sinal a ser convertido. Esse nível DC é fixo em 1,65V, ou

seja, metade da tensão de alimentação do Conversor A/D. Esse valor DC, junto com o ganho variável do segundo estágio de amplificação, garante que a amplitude do sinal grampeado nunca ultrapasse 3,3V e o valor mínimo do sinal também nunca seja menor que 0V. Por exemplo, considere que um sinal sEMG foi amplificado pelo segundo estágio de amplificação e agora tenha 3,3Vpp, sendo o valor máximo de 1,65V e mínimo de -1,65V. Após o grampeador, o sinal é deslocado para cima, de tal forma que o novo valor máximo é 3,3V e o valor mínimo passa a ser 0V. Isso garante compatibilidade com o conversor A/D.

O circuito grampeador de tensão pode ser visto na Figura 4.7 e utiliza um capacitor e um divisor da tensão de alimentação do conversor A/D, garantindo sempre 1,65V de deslocamento. Nota-se pela figura que o circuito é um filtro passa-alta passivo (RC) de primeira ordem, portanto o circuito foi dimensionado para frequência de corte em 0,5Hz para não influenciar os filtros anteriores.

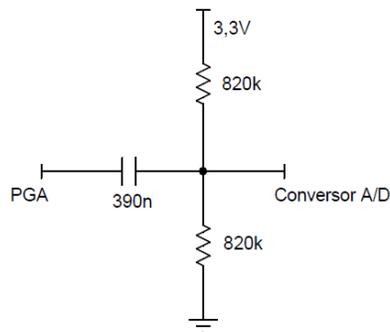


Figura 4.7 – Circuito grampeador de tensão.

4.1.6 CONVERSOR A/D

O conversor A/D do TWR-S08MM128 possui oito canais independentes, porém somente sete foram utilizados, cada qual com 16 bits de resolução, ou seja, 2 bytes. Ou seja, juntos, os sete canais formam um pacote de 14 bytes de dados. Como a tensão de alimentação do conversor A/D é de 3,3V, cada canal possui resolução de 50,35 μ V/bit.

Selecionou-se o disparo da conversão via bloco de atraso programável (PDB – *Programmable Delay Block*). O PDB é controlado via *software*, possibilitando o controle do início da conversão no momento desejado, por exemplo, em uma interrupção. O tempo de conversão foi configurado para 2,71 μ s através da seleção do barramento de *clock* em modo de conversão única.

Sabe-se, a partir do Teorema de Nyquist, que a taxa de amostragem para conversão A/D deve ser no mínimo duas vezes maior que a maior componente de frequência presente no sistema. Como a maior componente de frequência do sinal capturado foi limitada em 1kHz, a frequência de amostragem deve ser maior ou igual a 2kHz. Contudo, na prática sempre se utiliza frequências maiores que a de Nyquist por praticidade e aumento na resolução dos dados. Considerando-se a existência de sete canais de 16 bits cada, ou seja, 2 *bytes* por canal ou 14 *bytes* no total, a frequência de amostragem de Nyquist (*i.e.*, 2kHz) geraria 140kB de dados a serem armazenados em cinco segundos de captura, o que excede a memória interna para uso geral do TWR-S08MM128, de aproximadamente 128kB. Com isso, a fim de evitar o uso de memória externa, optou-se pela transmissão dos 14 *bytes* dos sete canais logo após cada conversão, ou seja, ao término de cada conversão, os 2 *bytes* de cada canal são enviados serialmente através do SCI para o computador, que salva esses dados em arquivos texto para processamento posterior. Ao término do envio dos 14 *bytes*, inicia-se uma nova conversão, e o processo se repete até completar cinco segundos de captura. Desta forma, a frequência de amostragem fica limitada pelo *baud rate* selecionado para o SCI, que no caso foi de 750kbps, e pelo tamanho do pacote a ser enviado, no caso, 14 *bytes*.

Convertendo o *baud rate* da SCI de bits para bytes, tem-se uma frequência máxima possível de envio de 93.750 bytes por segundo. Uma nova conversão é feita depois do envio do pacote de 14 *bytes*. Logo, a frequência de conversão, ou a taxa de amostragem, é de 6.696Hz. Contudo, devido ao tempo de processamento e atrasos propositais nos softwares desenvolvidos, a frequência de amostragem foi fixada em 5,6kHz, maior que a frequência de Nyquist, o que melhora significativamente a resolução temporal com conjunto de dados.

Com essa configuração, coletou-se vinte e oito mil dados para cada canal, com resolução de $50,35\mu\text{V/bit}$, durante cinco segundos de captura a uma frequência de amostragem de 5,6kHz, lembrando que o sinal convertido foi previamente amplificado pelos primeiro e segundo estágios de amplificação, portanto apresenta nível tensão próximo a 3,3Vpp.

4.1.7 INTERFACE DE COMUNICAÇÃO SERIAL

A SCI é responsável pela comunicação e transmissão entre o PC e o TWR-S08MM128 dos sinais capturados e ganhos programáveis referentes a cada canal. Os sinais capturados e os ganhos atuais dos PGAs são transmitidos do TWR-S08MM128 para o PC, e os ganhos atualizados são transmitidos do PC para o TWR-S08MM128. A interface foi configurada para trabalhar em modo *full-duplex*, *baud rate* de 750kbps a 8 bits.

O protocolo utilizado no SCI é padronizado e é possível controlar alguns parâmetros como o *baud rate* e números de bits a serem transmitidos, permitindo comunicação serial assíncrona *full-duplex* entre dispositivos, e é composto basicamente pelo gerador de *baud rate*, bloco de transmissão e bloco de recepção. Os blocos de transmissão e recepção trabalham independentemente, porém utilizam o mesmo *baud rate*. Durante operação padrão, o dispositivo monitora o status do SCI, envia dados para o buffer de transmissão quando houver dados a serem transmitidos e processa os dados quando o buffer de recepção identifica dados recém recebidos. Uma vez definidos e configurados os mesmos parâmetros do SCI no TWR-S08MM128 e no PC, o protocolo realiza todas as funções sem a necessidade de criação de código. Portanto, o projeto e testes são extremamente práticos e rápidos.

O SCI trabalha com *buffer* de recepção de tamanho ajustável. Com isso, os dados enviados por SCI são armazenados no *buffer* do PC, e são acessados à medida que o programa avança, garantindo que não ocorra perda de informações e nem alterações no *baud rate*.

4.1.8 INTERFACE PERIFÉRICA SERIAL

A SPI é responsável pela comunicação e transmissão dos níveis de ganho referentes a cada canal entre o TWR-S08MM128 e o PGA. Para tal, é necessário definir um *master* e um *slave* para definir a hierarquia de informações, ou seja, ambos podem enviar e receber dados, porém devem seguir a prioridade do *master* em relação ao *slave*. O SPI possui três vias para controle e fluxo de informações, o DATA IN/OUT, CLOCK e o CHIP SELECT.

Optou-se o TWR-S08MM128 como o *master*, já que esse é o dispositivo de processamento central. Conforme especificado no *datasheet* do PGA (LM1973), configurou-se o CLOCK do SPI em 3kHz com polaridade positiva, o DATA IN/OUT com 16 bits e transmissão do bit mais

significativo primeiro, sendo o *byte* mais significativo para seleção de canais e o menos significativo para transmissão do nível de ganho. O CHIP SELECT é controlado via software.

O nível do ganho a ser atualizado no PGA recebido pelo TWR-S08MM128 proveniente do PC é enviado para o PGA através da linha MOSI (Saída do Mestre Entrada do Escravo - *Master Out Slave In*), conforme mostrado na Figura 4.8. O valor contido no registrador do *slave* é transmitido para o *master*. O início da transmissão de dados entre o *master* e o *slave* ocorre quando o CHIP SELECT vai a nível lógico baixo por pelo menos 150ns antes da primeira borda de subida do pulso de CLOCK, e deve permanecer em nível lógico baixo durante toda a transmissão serial de cada bloco de 16 bits. Mantém-se o *master* e o *slave* sincronizados pelo mesmo CLOCK durante a operação.

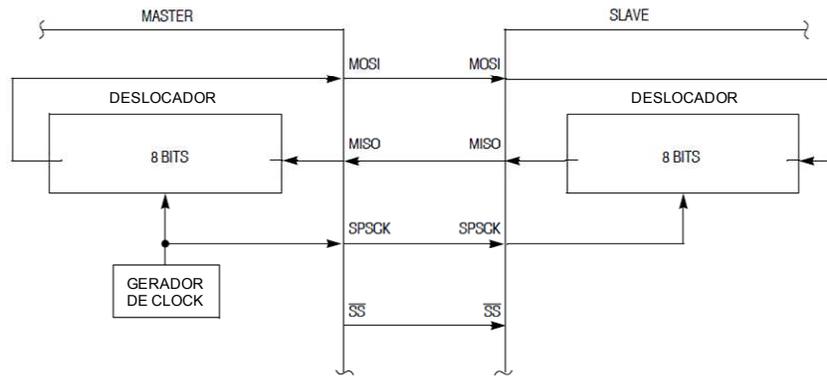


Figura 4.8 – Diagrama funcional do SPI (Modificado de Freescale, 2010a).

4.1.9 O TOWER MC9S08MM

S08MM é a série de 8 bits da família Flexis MM da Freescale® (Freescale, 2010a). Este microcontrolador possui um baixo consumo de potência, conexão USB e aquisições de dados analógicos com alta resolução (16bits), permitindo que projetistas possa integrar um maior número de componentes a baixo custo. Esta linha é ideal para aplicações médicas ou aplicações em geral que necessitem de maior precisão (Freescale, 2010b).

O TWR-S08MM128 é um módulo de demonstração e desenvolvimento de baixo custo que integra um microcontrolador MC9S08MM128. O TWR-S08MM128 pode operar como um módulo único, ou pode ser integrado como placa de controle central em um sistema TOWER com módulos periféricos, por exemplo, A/D 16 bits, módulos SCI e módulos SPI (Freescale, 2010c).

O TWR-S08MM128 foi utilizado como interface entre o sistema de condicionamento do sinal sEMG e o PC. Apesar de conter outros módulos, utilizou-se somente o conversor A/D, SCI e SPI, configurados de forma a sincronizar o processo de captura, transmissão de dados para cada canal e atualização de ganho dos PGAs. O processo de controle e rotinas do TWR-S08MM128 pode ser visto na Figura 4.9.

Durante a inicialização, o TWR-S08MM128 ajusta os ganhos dos sete PGAs para 20dB (10V/V) a fim de melhorar a resolução do sinal sEMG capturado pela primeira vez. Considerando os ganhos do primeiro estágio de amplificação e o ganho inicial do PGA, o ganho inicial total do sistema é de 40dB (100V/V). Esse ganho programável inicial é muito próximo aos limites estipulados entre 36 e 76dB, e testes mostraram que o sinal EMG capturado com esse ganho total não ultrapassa o limite estipulado pelo conversor A/D de 1,65V, *i.e.*, o sistema não satura. Caso o sistema sature, o TWR-S08MM128 possui um limitador de tensão na entrada do conversor A/D que protege as entradas do conversor.

Após o ajuste inicial do ganho programável, o sistema aguarda instruções provenientes do PC, que podem resultar em três ações: capturar sinais sEMG; atualizar os ganhos dos PGAs; reset dos ganhos dos PGAs.

Uma vez identificado a instrução para captura de sinais sEMG, o TWR-S08MM128 entra periodicamente em uma interrupção que realiza a conversão A/D dos dados dos sete canais. Após o término da conversão, os 16 bits de cada um dos sete canais são enviados serialmente através do SCI para o PC. Os 16 bits são enviados em dois pacotes de 8 bits: os 8 bits mais significativos são enviados primeiro, seguidos pela transmissão dos 8 bits menos significativos. Os dois pacotes de 8 bits são concatenados no PC posteriormente, recuperando os 16 bits originais. Essa rotina é repetida vinte e oito mil vezes (cinco segundos de captura), e o programa retorna à condição de “espera” por instruções do PC.

A atualização dos ganhos dos PGAs tem início com o envio do código do PC para o TWR-S08MM128 que indica o início da atualização. O procedimento de atualização dos ganhos dos PGAs ocorre em duas etapas. Inicialmente, o TWR-S08MM128 recebe do PC via SCI os 8 bits que representam o ganho de cada um dos canais e, logo após, o TWR-S08MM128 repassa os ganhos via SPI para cada um dos PGAs com o endereço do respectivo PGA a ser atualizado.

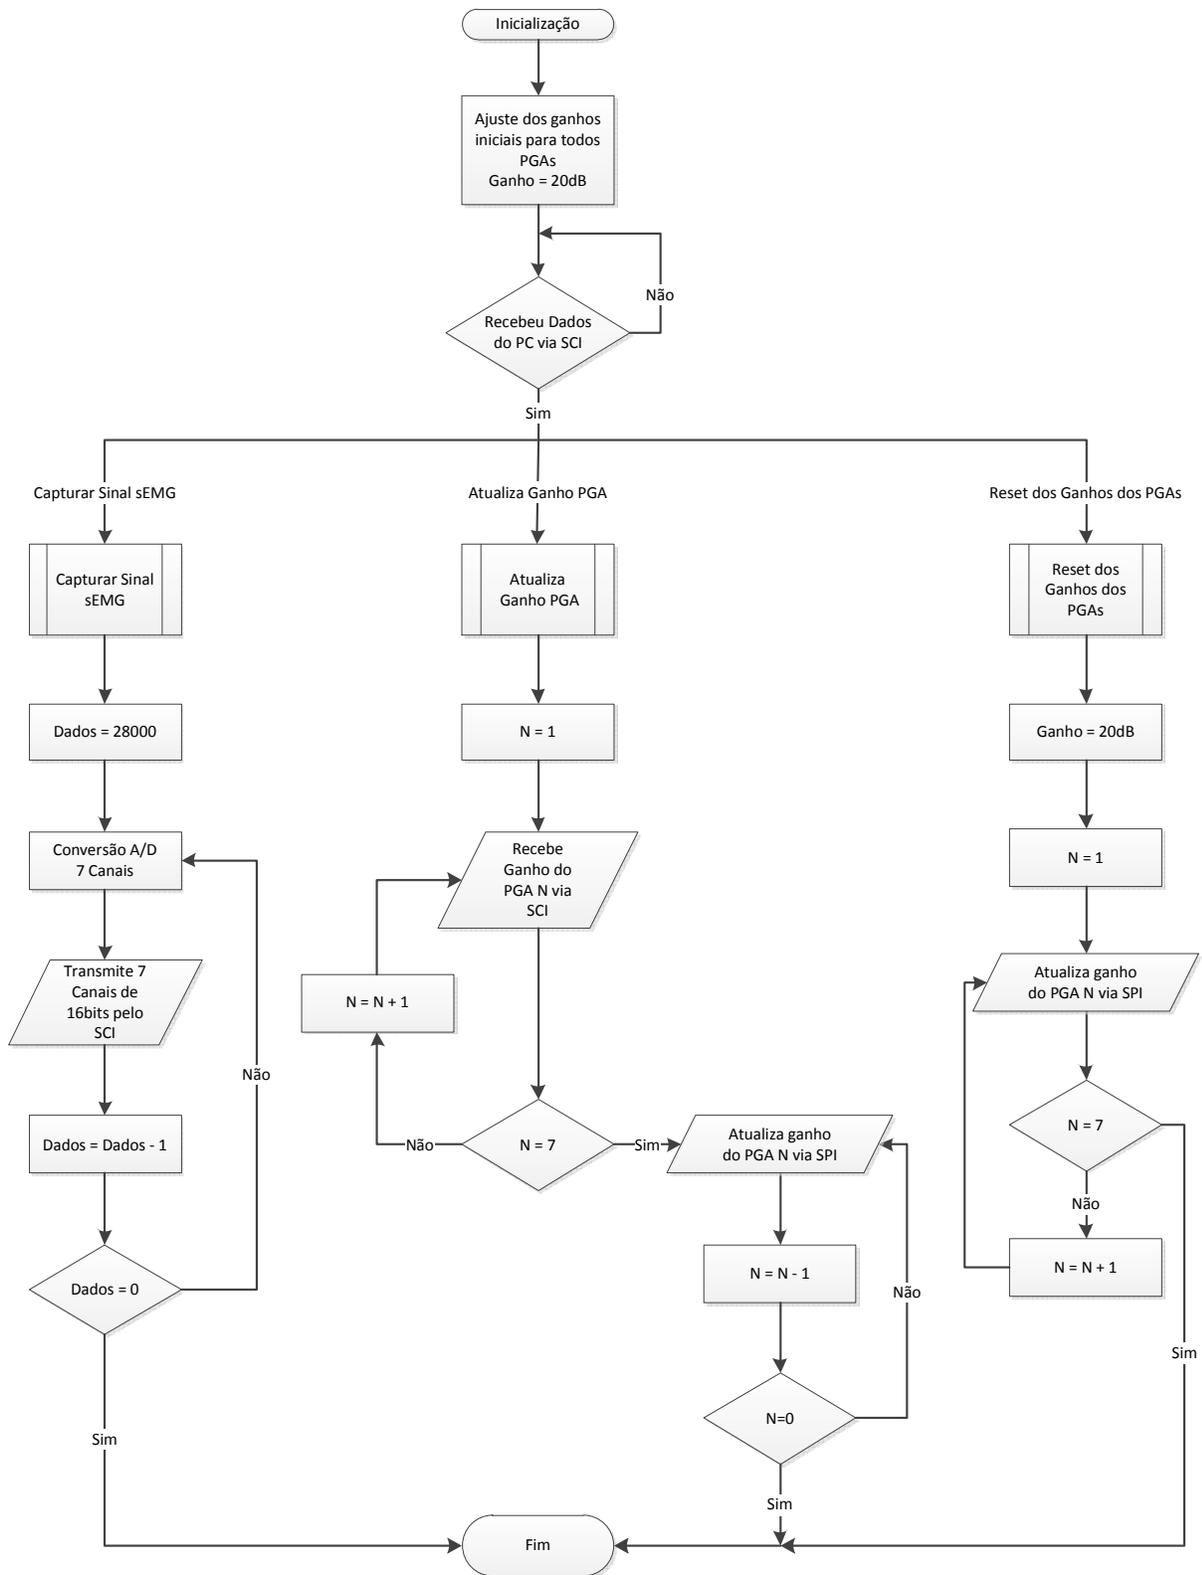


Figura 4.9 – Fluxograma dos processos controlados pelo TWR-S08MM128.

O procedimento para reset dos ganhos dos PGAs é similar ao procedimento de atualização dos ganhos dos PGAs, contudo não existe a necessidade de receber os valores de atualização dos ganhos via SCI do PC, já que o ganho inicial é fixado em 20dB.

4.1.10 O COMPUTADOR PESSOAL

O PC hospedou duas ferramentas do projeto: o software para controle de captura, desenvolvido em ambiente Visual Basic V7® e o software para decomposição dos sinais EMG capturados, desenvolvido em MATLAB®. A descrição dos processos para cada uma dessas ferramentas é detalhado a seguir.

4.1.11 SOFTWARE DE CAPTURA

Optou-se pelo desenvolvimento do software de captura em ambiente Visual Basic V7® devido à sua facilidade, funções gráficas, compatibilidade com ambiente Windows® e ferramentas confiáveis para comunicação SCI. Esse software foi desenvolvido com o intuito de: controlar os cinco segundos de captura de sinais sEMG de sete canais diferentes; ajustar o ganho programável de cada canal; fornecer informação gráfica do sinal capturado a fim de auxiliar o usuário no correto posicionamento da matriz de eletrodos em relação ao músculo do sujeito. O fluxograma do software pode ser visto na Figura 4.10, e a interface gráfica na Figura 4.11.

Durante o processo de inicialização do software, são definidos variáveis de controle, *baud rate* do SCI para comunicação com o TWR-S08MM128 (750kbps), tamanho do *buffer* do SCI, nome e diretório dos arquivos-texto onde serão salvos os dados provenientes de cada canal e ganhos iniciais dos PGAs para efeito de cálculo. O sistema então entra em um loop infinito até que o usuário indique uma ação, que induz uma interrupção a ser direcionada a uma dentre quatro sub-rotinas, de acordo com a opção do usuário: capturar sinais sEMG; atualizar os ganhos dos PGAs; reset dos ganhos dos PGAs; visualizar gráficos.

Caso o usuário selecione a instrução para captura de sinais sEMG, abre-se um arquivo de suporte para recepção dos dados via SCI. O software então envia um comando para o TWR-S08MM128 para início da conversão A/D e envio dos dados dos canais. O TWR-S08MM128 converte as informações dos canais com resolução de 16 bits, porém os dados são enviados em

dois pacotes de 8 bits, característico do SCI. Os cinco segundos de dados dos canais são enviados e salvos no buffer do SCI no PC, que posteriormente são lidos e salvos seqüencialmente no arquivo de suporte. Logo após, os arquivos-texto onde serão salvos os dados de cada canal são abertos e zerados, os dois pacotes de 8 bits referente a cada canal são lidos do arquivo de suporte e concatenados de forma a recuperar o dado original de 16 bits. Verifica-se se o módulo do dado a ser salvo no arquivo texto do canal é maior que os dados salvos anteriormente e, caso positivo, esse valor é considerado para posterior cálculo de atualização de ganho do PGA daquele canal.

Em seguida, os efeitos dos ganhos provenientes do primeiro e segundo estágio de amplificação, e o nível DC injetado pelo circuito grampeador de tensão são retirados, tendo-se desta forma o real valor da tensão do sinal sEMG capturado. Esse novo dado é finalmente salvo no arquivo do respectivo canal. Por fim, verifica-se se o arquivo de suporte chegou ao final: caso negativo, todo o processo descrito é repetido; caso positivo, fecham-se os arquivos e o sistema aguarda nova ação do usuário.

Quando o usuário seleciona o procedimento de atualização dos ganhos dos PGAs, o maior valor em módulo de cada canal é carregado, calcula-se a diferença entre esse maior valor e o maior valor permitido na escala de tensão (3,3Vpp), levando em consideração o atual ganho do PGA. A tabela de ganho do PGA foi transcrita no software, de forma que o ganho calculado é aproximado ao ganho mais próximo presente na tabela. Essa aproximação é feita de tal forma que o ganho aproximado seja menor que o ganho calculado, garantindo que não ocorra saturação após a atualização do ganho. Ou seja, o ganho da tabela é escolhido de tal forma a ser o mais próximo possível do ganho calculado, porém o ganho da tabela será sempre menor que o ganho calculado.

Após calcular e definir os novos ganhos de cada um dos PGAs, o *software* envia um pacote de dados ao TWR-S08MM128 via SCI, indicando o início do envio dos valores dos novos ganhos do PC para o TWR-S08MM128. Paralelamente, os ganhos de cada canal são mostrados em caixas de texto localizados na parte superior da interface gráfica. A visualização e conhecimento desses ganhos podem auxiliar na decisão de reposicionamento da matriz de eletrodos.

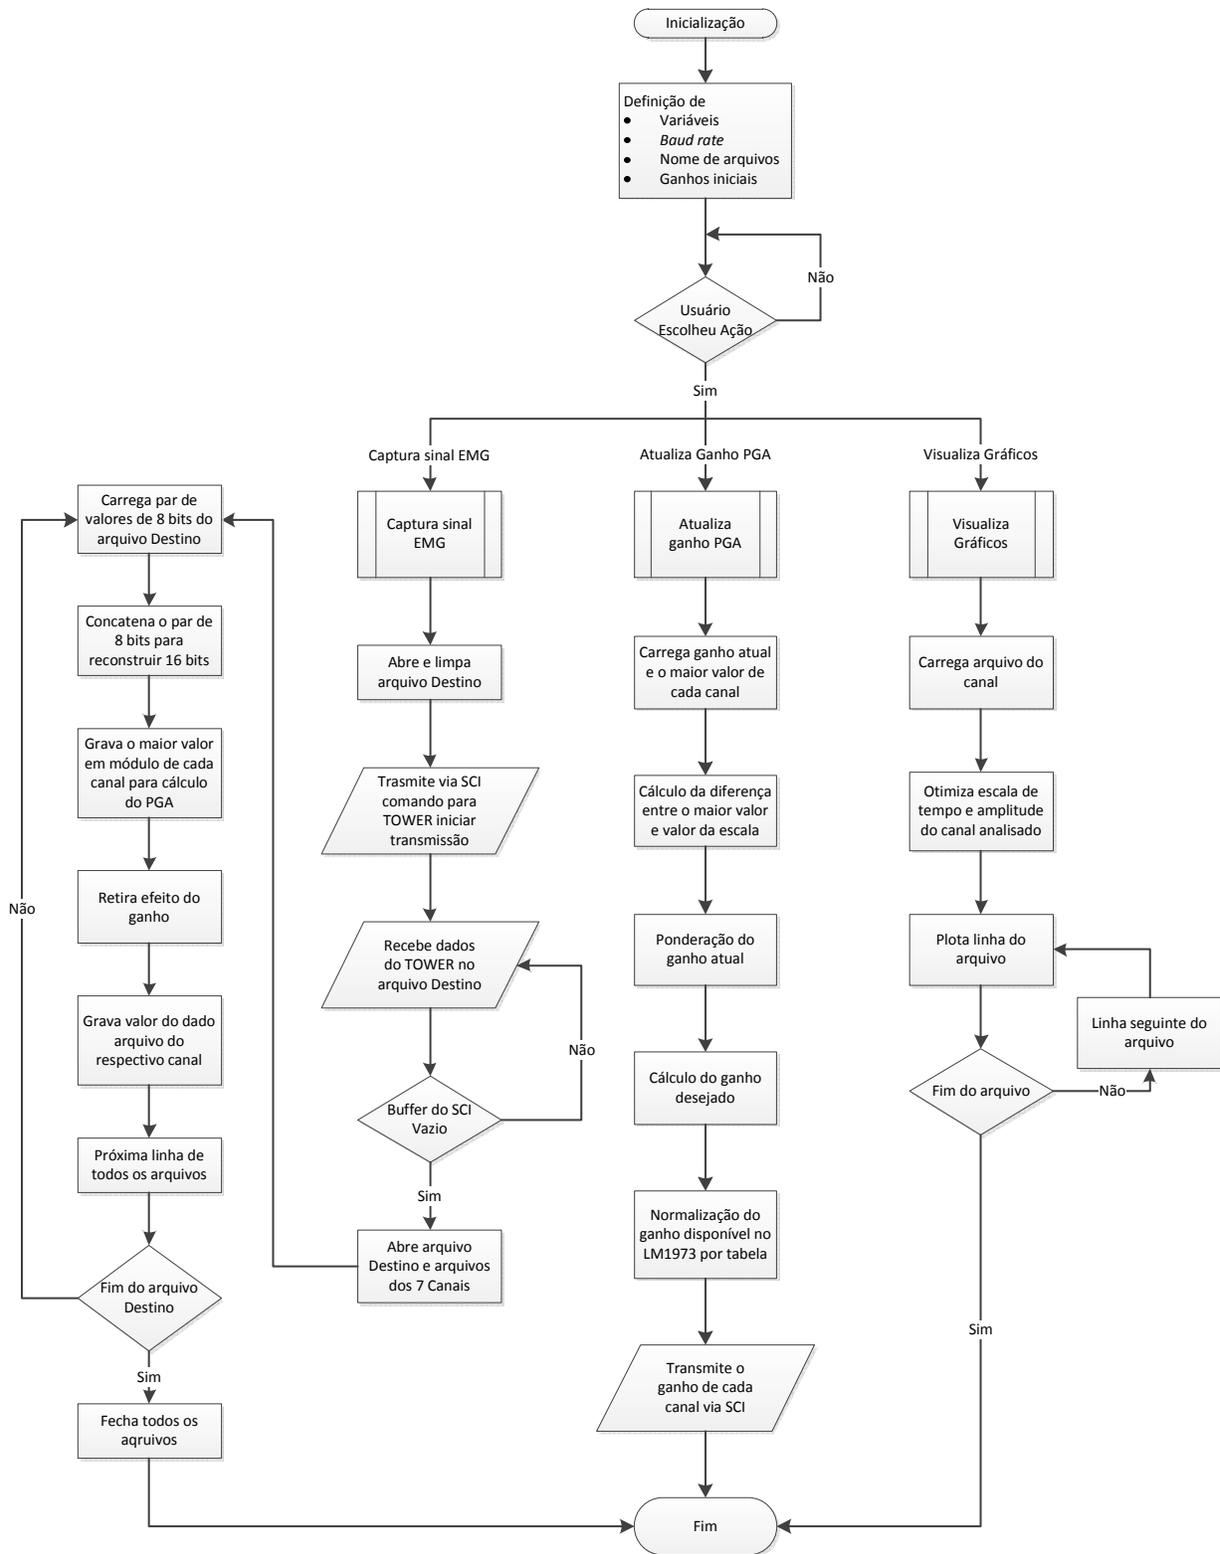


Figura 4.10 – Fluxograma para o software de captura e controle de ganho.

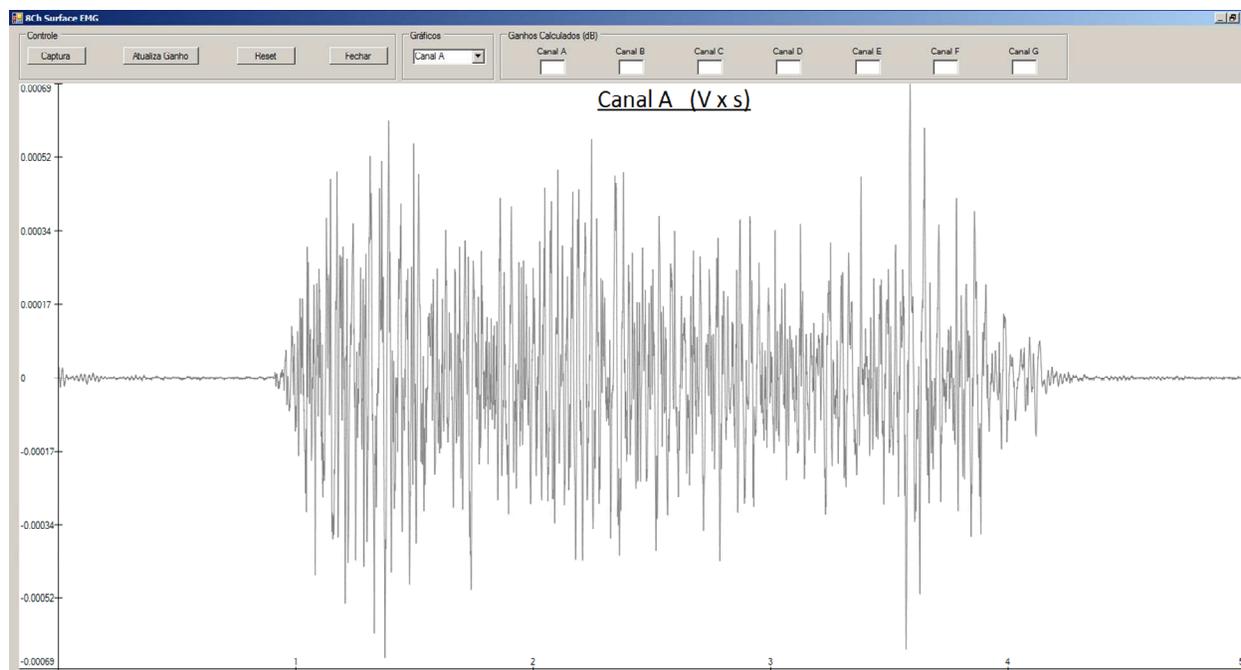


Figura 4.11 – Interface gráfica do software de captura e controle de ganho.

O processo para *reset* dos ganhos dos PGAs é mais simples, pois o ganho inicial já é gravado no TWR-S08MM128. Conseqüentemente, basta o envio de uma palavra de comando via SCI para o TWR-S08MM128 indicando a necessidade de *reset* dos ganhos.

O processo para visualização dos gráficos tem início quando o usuário seleciona um canal de interesse na interface gráfica, iniciando o carregamento do arquivo texto do respectivo canal. Verifica-se qual o maior e menor valor da amplitude do sinal, bem como na escala de tempo para ajuste da escala do gráfico. Cada linha do arquivo é plotada como um ponto no gráfico, e o processo se repete até o final do arquivo. No fim do processo, o arquivo selecionado é fechado e o sistema aguarda nova ação do usuário.

4.1.12 SOFTWARE PARA DECOMPOSIÇÃO DOS SINAIS EMG

Optou-se pela utilização do MATLAB® para o desenvolvimento do *software* para decomposição de sinais EMG devido à interface gráfica, ferramentas para processamento e devido à existência do algoritmo aberto FastICA (Hyvärinen & Oja, 1997).

O procedimento do *software* para decomposição de sinais EMG é feito por etapas, tal que o fim de uma etapa é o início de outra, onde os sinais são processados em quatro etapas principais: tempo de análise, filtros digitais, separação de fontes e visualização de canais. Além

das etapas de processamento mostradas na Figura 4.12, o *software* também calcula e mostra o sinal EMG no domínio do tempo e da frequência, além do histograma, média, desvio padrão, variância e curtose do sinal (Figura 4.13). Inicialmente, os arquivos-texto dos sete canais são carregados no programa. A partir desse ponto, o usuário indica quais tipos de análise deseja fazer.

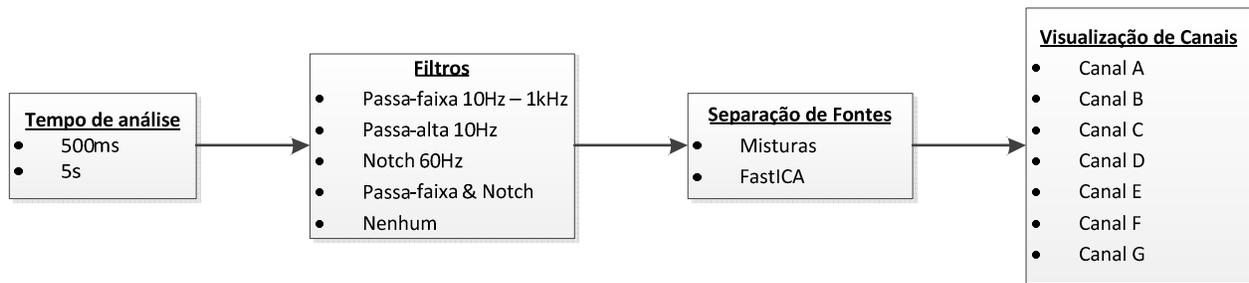


Figura 4.12 – Fluxo de dados do sistema de análise e decomposição de sinais EMG.

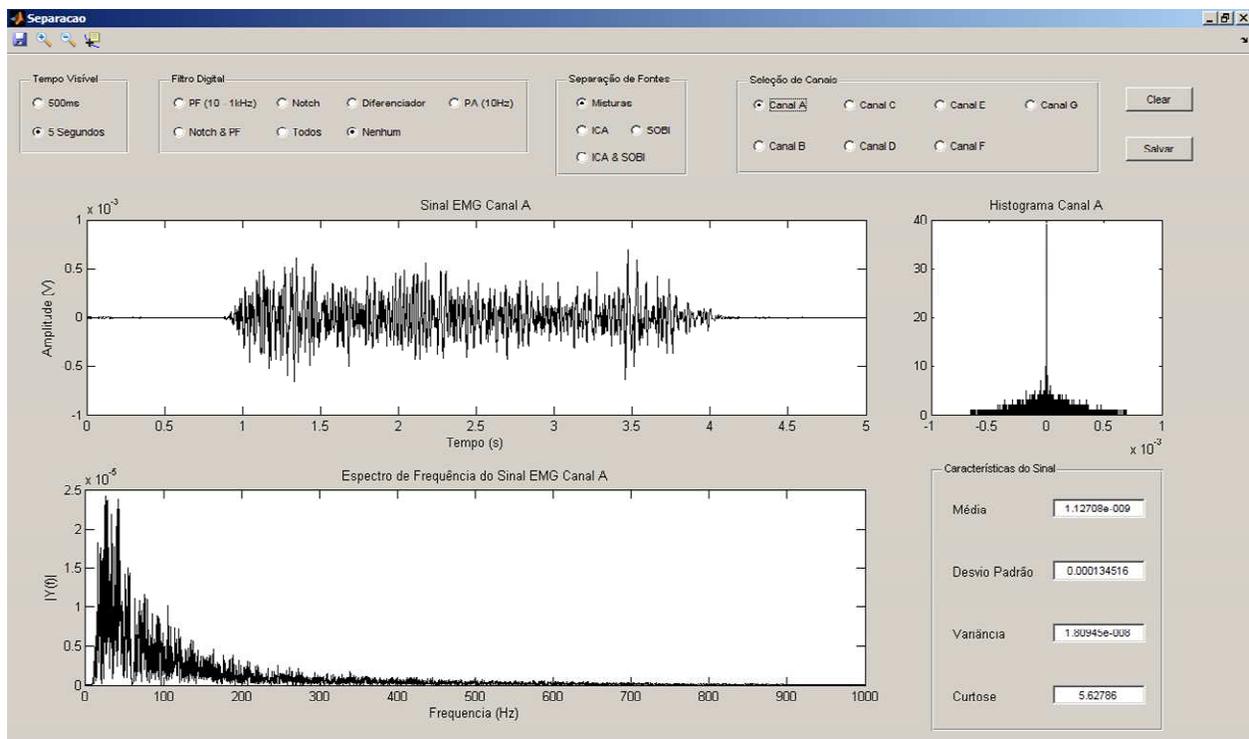


Figura 4.13 – Interface gráfica do software para decomposição de sinais EMG.

A primeira etapa a ser definida é o tempo de análise, que determina se o usuário quer analisar os cinco segundos capturados ou somente quinhentos milissegundos desse sinal. Esse segmento de tempo de quinhentos milissegundos encontra-se entre 3s e 3,5s da captura, pois é um segmento onde a contração está estabilizada e com artefatos de movimento reduzidos.

Determinado o tempo de análise, a próxima etapa de processamento trabalhará com os dados de cada canal com tempo definido pelo usuário, ou seja, quinhentos milissegundos ou cinco segundos.

A segunda etapa é a de filtragem digital. Apesar de o sinal capturado ter passado pelo filtro analógico passa-faixa, algumas componentes de frequência indesejadas ainda podem estar presentes no sinal. Desta forma, alguns filtros digitais foram dimensionados, entre eles:

- Passa-faixa 10Hz – 1kHz, integração entre um filtro passa-alta Butterworth de ordem cinco e frequência de corte em 10Hz e um filtro passa-baixa Butterworth de ordem doze e frequência de corte em 1kHz;
- Filtro passa-alta Butterworth de ordem cinco e frequência de corte em 10Hz;
- Filtro *Notch* 60Hz ordem dez com frequência central de 60Hz e banda de +/-5Hz, ou seja, um filtro rejeita-faixa com banda rejeitada entre 55Hz e 65Hz;
- Passa-faixa e filtro *Notch* 60Hz;
- Nenhum, ou seja, não é aplicado nenhum filtro digital.

Após o sinal ser processado pelos filtros digitais escolhidos pelo usuário, a etapa seguinte verifica se o usuário quer visualizar as misturas ou se deseja separar os sinais através do algoritmo FastICA. Caso o usuário selecione as misturas, o sistema não realiza nenhum processamento adicional nos sinais a serem visualizados, e os sinais são encaminhados para a etapa de visualização. Caso o usuário selecione a separação, o sistema processa o algoritmo FastICA que estima as fontes originais baseadas nas misturas. Essas estimativas são encaminhadas para a etapa de visualização.

A última etapa não realiza nenhum processamento adicional, somente possibilita a visualização das informações contidas em cada canal (Canal A a Canal G), após as etapas de processamento descritas acima. Nessa etapa é possível visualizar: as componentes de frequência dos sinais, calculadas a partir da transformada discreta de Fourier computada com um algoritmo Transformada Rápida de Fourier (FFT – *Fast Fourier Transform*); o histograma com resolução de cem mil barras, aproximando-se da forma da fdp do vetor; média; desvio padrão; variância; curtose.

4.2 Validação

A validação do protótipo foi dividida em quatro etapas (Figura 4.14): especificações técnicas do sistema de captura; captura de sinais eletromiográficos de superfície; separação de sinais conhecidos; separação de sinais eletromiográficos.

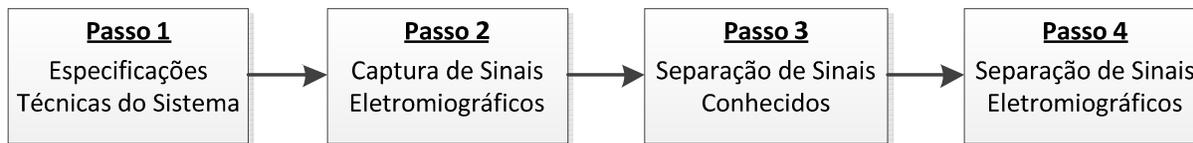


Figura 4.14 – Quatro etapas da validação do sistema.

4.2.1 ESPECIFICAÇÕES TÉCNICAS DO SISTEMA DE CAPTURA

Testes foram realizados para verificar a primeira etapa de amplificação junto com a filtragem do sinal, a linearidade do conversor A/D e o ruído intrínseco do sistema. Considerou-se o CMRR e a impedância de entrada em modo comum do INA129 como sendo as do próprio sistema de captura, já que esse componente isola o sistema de captura do sistema medido.

No teste de amplificação e filtragem do sinal, aplicou-se um sinal senoidal com amplitude de 0,2Vpp provido por um gerador de funções Tektronix AFG310. Variou-se a frequência de 0,1Hz a 5kHz, com intuito de simular desde baixas frequências provenientes de artefatos de movimento até altas frequências provenientes de outras fontes de ruído. Essa varredura de frequência foi realizada em uma escala ascendente seguindo de 0,1Hz para 5kHz e descendente seguindo de 5kHz para 0,1Hz. A resolução, ou passo, da varredura procedeu-se da seguinte forma: entre 0,1Hz e 1Hz, passo de 0,1Hz; entre 1Hz e 10Hz, passo de 1Hz; entre 10Hz e 100Hz, passo de 10Hz; entre 100Hz e 2kHz, passo de 100Hz; entre 2kHz e 5kHz, passo de 1kHz. Esse procedimento foi realizado cinco vezes, calculando-se a média e o desvio padrão em cada frequência.

O teste de linearidade do conversor A/D foi realizado com o intuito de verificar se o conversor A/D precisava de calibração adicional. Uma fonte de tensão contínua e ajustável foi conectada às entradas dos canais do conversor A/D. Realizou-se cinco segundos de captura, na qual a tensão da fonte foi variada linearmente de 0V a 3,3V, a um passo de 0,1V, tanto em escala crescente quanto decrescente. Como a captura é realizada a uma frequência de amostragem de

5,6kHz, a amostragem tem um período de aproximadamente 178 μ s. Portanto, cada passo de tensão obteve cerca de 870 capturas, permitindo o cálculo da média da tensão capturada de acordo com a quantidade de pontos amostrados. Os resultados e análises mostrados para os testes de ganho, filtragem e linearidade do conversor A/D foram feitos com o software de estatística GraphPad Prism 5®.

Para o levantamento do ruído intrínseco ao sistema de captura, aterraram-se as entradas do pré-amplificador e realizaram-se duas capturas completas, com o PC desconectado da rede elétrica, mantendo-se ligado através da bateria: uma com ganho mínimo inicial do sistema (análise 1); outra após ajuste dos ganhos de cada canal (análises 2 e 3): a análise 1 mostra o ruído com ganho mínimo inicial do sistema; a análise 2 mostra o ruído após ajuste dos ganhos de cada canal, considerando-se o efeito de ganho; a análise 3 mostra o ruído após ajuste dos ganhos de cada canal, retirando-se efeito de ganho. Os sinais passaram por um filtro passa-alta digital de quinta ordem com frequência de corte em 10Hz, com intuito de retirar resquícios de níveis DC provenientes do grampeador de tensão que não foram retirados pelo software de captura.

4.2.2 CAPTURA DE SINAIS ELETROMIOGRÁFICOS DE SUPERFÍCIE

Essa etapa valida a capacidade do sistema projetado em capturar sinais sEMG. Foram realizados dois testes para essa etapa. O primeiro teste utilizou eletrodos comerciais fornecidos pela Carbogel® e o segundo teste utilizou a matriz de eletrodos construída no Laboratório de Reabilitação Sensório-Motora do CEB/UNICAMP. A metodologia aplicada em ambos os testes envolve limpeza da pele com álcool na região em análise e uma leve abrasão com material áspero, tipo pedra pome, para remoção da camada superficial da pele, aplicação de um gel condutor para melhorar o acoplamento elétrico entre o eletrodo e pele, e o posicionamento e fixação dos eletrodos de superfície com utilização de fita adesiva. Logo após o posicionamento dos eletrodos, solicitou-se ao sujeito realizar uma contração máxima por cinco segundos para calibração e atualização dos ganhos dos PGAs. Após pausa de um minuto, o sujeito realizou contrações leves com duração de cinco segundos cada, e intervalos de descanso de no mínimo um minuto entre contrações para evitar fadiga. Todas as capturas foram realizadas em um sujeito saudável.

Como os eletrodos da Carbogel® são previamente testados, foi possível analisar o funcionamento do sistema de captura sem interferência dos possíveis ruídos que a matriz de eletrodos poderia induzir no sistema. Um par de eletrodos Carbogel®, com 1cm de diâmetro cada, foi posicionado no músculo flexor superficial dos dedos e um eletrodo de referência foi posicionado no cotovelo.

O segundo teste dessa etapa consiste em utilizar a matriz de eletrodos no lugar dos eletrodos da Carbogel®. Posicionou-se a matriz de eletrodo no bíceps brachii e um eletrodo de referência foi posicionado no cotovelo. O eletrodo de referência utilizado foi um eletrodo de superfície comercial convencional, com diâmetro de 1 centímetro, fornecido pela Carbogel®.

4.2.3 SEPARAÇÃO DE SINAIS CONHECIDOS

O sinal sEMG de superfície é uma mistura de sinais aparentemente aleatórios e de difícil análise. Logo, a validação do processo de separação de fontes utilizando sinais sEMG capturados com a matriz de eletrodos ou qualquer outro tipo de eletrodo é inviável.

Com o propósito de validar o sistema como um todo, ou seja, o sistema de captura junto com o sistema de separação de fontes, optou-se pela captura de misturas de sinais conhecidos. Dessa forma, foi possível analisar o desempenho do sistema de captura e de separação de fontes através da comparação entre os sinais originais e os sinais separados.

Considerando-se que o sistema possui somente sete canais diferenciais de captura, três canais foram selecionados para captura das misturas e outros três para captura das fontes originais. Os sinais foram misturados por uma matriz de resistores, cada canal com um *buffer* de entrada para que os sinais misturados não influenciassem as fontes originais, conforme mostrado na Figura 4.15. Optou-se por essa configuração a fim de realizar a captura das misturas e das fontes originais simultaneamente para que, no momento das análises entre fontes originais e fontes estimadas, os pares “originais e estimadas” apresentassem exatamente a mesma fase.

A Figura 4.16 mostra a configuração de montagem na entrada do primeiro estágio de amplificação. Uma vez que o sistema possui sete entradas diferenciais (INA129), e deseja-se capturar três misturas de três fontes junto com as três fontes originais, foi necessário conectar as

entradas da seguinte forma: os canais A e B são diferenças entre misturas; o canal C é a diferença entre uma mistura e uma das fontes que, mesmo com a presença de uma fonte, continua sendo uma mistura; o canal D, E, F e G são as fontes isoladas, pois são diferenças entre as respectivas fontes e o terra. É importante notar que os canais E e F são idênticos, portanto somente um desses canais será utilizado nas análises.

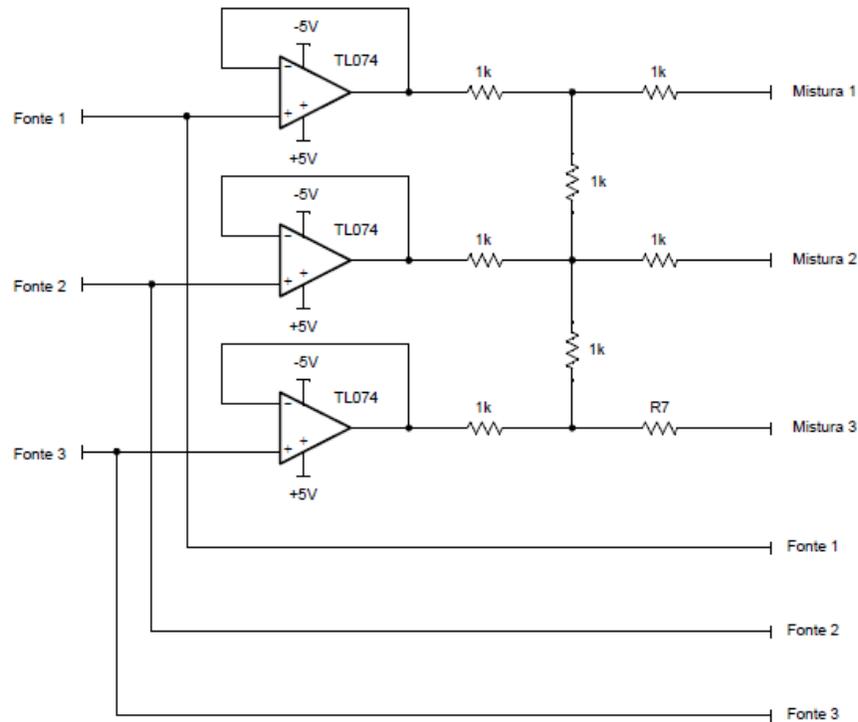


Figura 4.15 – Circuito de mistura para sinais conhecidos.

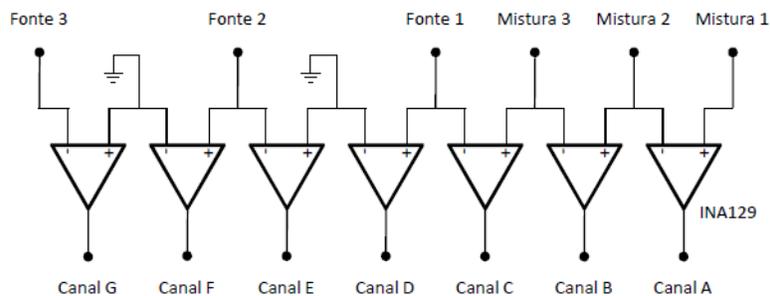


Figura 4.16 – Configuração de montagem para captura dos sinais conhecidos.

Foram realizados testes com seis tipos de misturas envolvendo oito fontes conhecidas diferentes. A disposição das oito fontes conhecidas para cada um dos seis testes é mostrada na Tabela 4.1. Para cada um dos testes, cinco capturas foram realizadas a fim de consolidar os resultados.

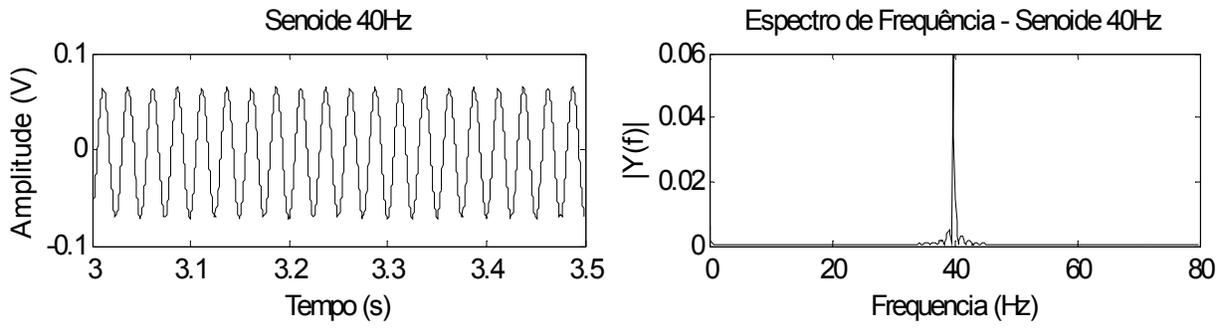
Tabela 4.1 – Relação de fontes utilizadas em cada teste. As fontes 40Hz e 500Hz referem-se à senóides com freqüências equivalentes; o ruído branco é um sinal que apresenta componentes de freqüência em toda a faixa espectral; as fontes *User1*, *User1*, *User3* e *Waveform* são ondas que estavam previamente gravadas na memória do gerador de função e tiveram apenas a amplitude de tensão ajustadas; o *burst* é uma forma de onda que é caracterizada por segmentos de atividade e segmentos de ausência de sinal. No caso, os segmentos de atividade foram configurados como senóides de 100Hz espaçados por períodos de ausência de sinal.

Teste	Fonte 1	Fonte 2	Fonte 3
1	500Hz	Ruído Branco	Waveform
2	500Hz	Ruído Branco	Burst
3	500Hz	40Hz	Ruído Branco
4	500Hz	user1	Ruído Branco
5	500Hz	user2	Ruído Branco
6	500Hz	user3	Ruído Branco

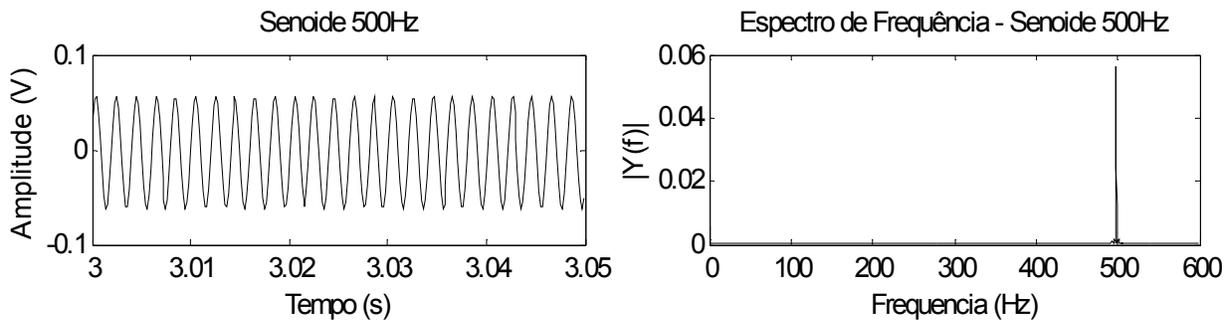
Utilizaram-se dois geradores de função para gerar todas as fontes, um Tektronix AFG310 e um Rigol DG1022. A amplitude das fontes foi ajustada considerando-se o primeiro estágio de amplificação de tal forma a não haver regulagem dos PGAs, ou seja, a amplificação do primeiro estágio foi suficiente para atingir o valor máximo da escala de tensão.

Alusivo à Tabela 4.1, as fontes 40Hz e 500Hz referem-se à senóides com freqüências equivalentes; o ruído branco é um sinal que apresenta componentes de freqüência em toda a faixa espectral; as fontes *User1*, *User1*, *User3* e *Waveform* são ondas que estavam previamente gravadas na memória do Rigol DG1022 e tiveram apenas a amplitude de tensão ajustadas; o *burst* é uma forma de onda que é caracterizada por segmentos de atividade e segmentos de ausência de sinal. No caso, os segmentos de atividade foram configurados como senóides de 100Hz espaçados por períodos de ausência de sinal. As fontes são ilustradas na Figura 4.17, junto com os respectivos espectros de freqüência.

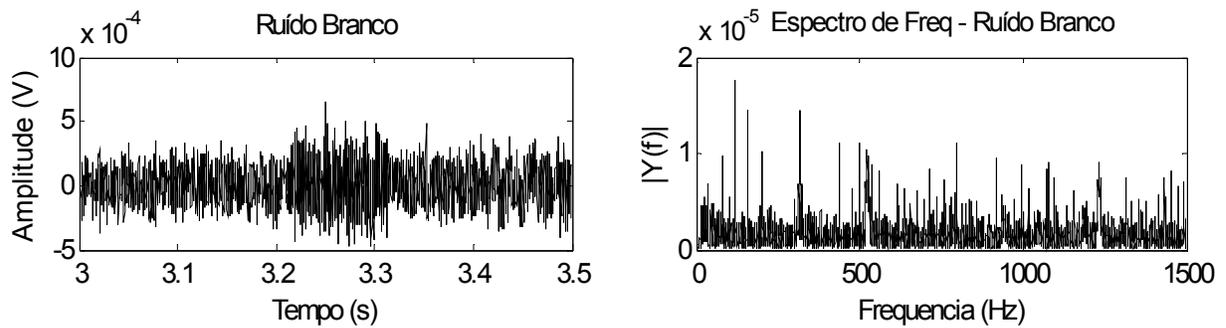
A fim de facilitar a visualização das fontes, apenas parte dos sinais é mostrada na Figura 4.17, contudo todas as fontes foram capturadas durante cinco segundos. As misturas provenientes do circuito da Figura 4.16 foram salvas em arquivos-texto e processados pelo Software de Separação Cega de Fontes.



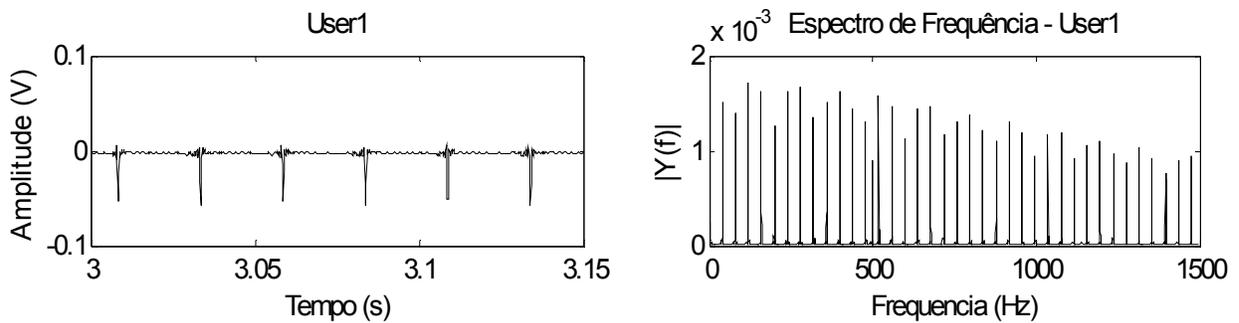
a)



b)



c)



d)

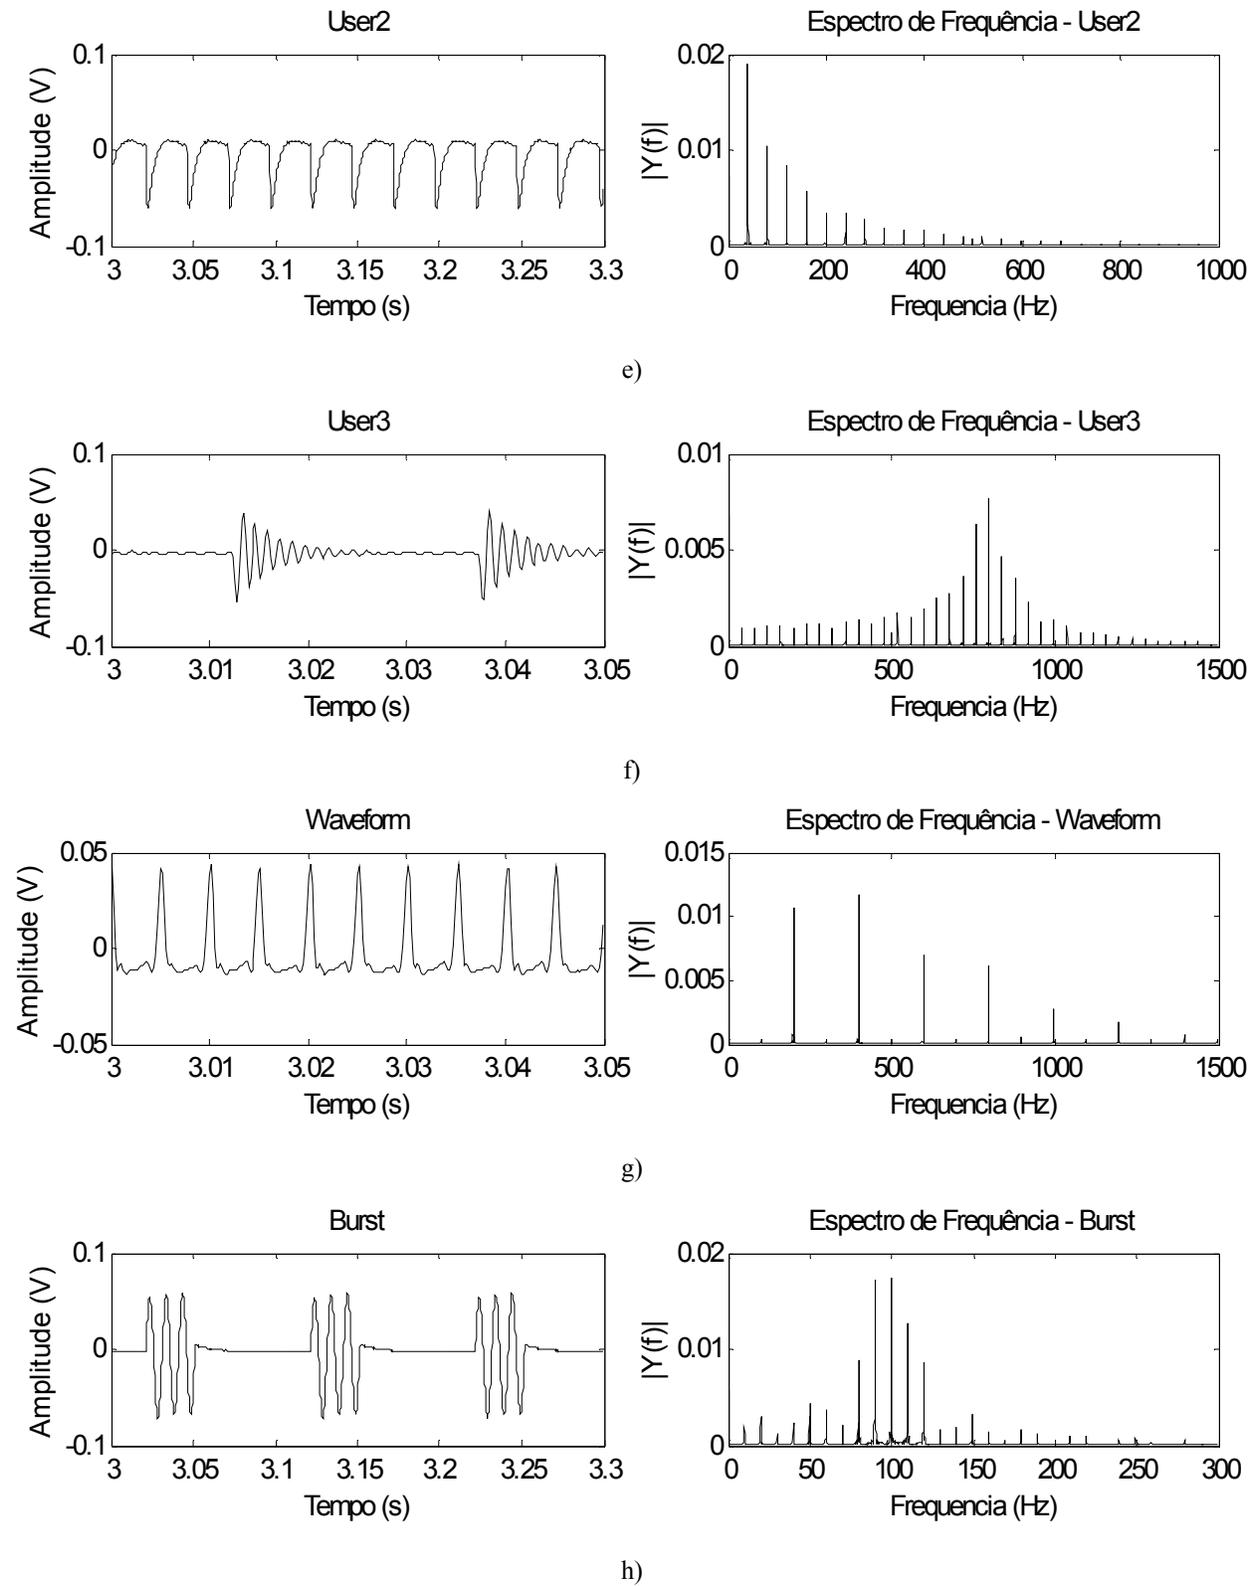


Figura 4.17 –Domínio do tempo e da frequência de fontes que foram posteriormente misturadas e utilizadas na validação da separação de sinais conhecidos. a) Senóide 40Hz; b) Senóide 500Hz; c) Ruído branco; d) *User1*; e) *User2*; f) *User3*; g) *Waveform*; h) *Burst* 100Hz.

4.2.4 SEPARAÇÃO DE SINAIS ELETROMIOGRÁFICOS

Sabe-se que a separação de fontes pelo método de ICA é possível se, e somente se, o número de fontes a serem separadas for menor ou igual ao número de misturas dessas mesmas fontes (Hyvärinen *et al*, 2001). Sabe-se também que as fibras musculares das UMs são dispostas de forma a entrelaçarem umas às outras e, desta forma, uma pequena região do músculo pode conter milhares de fibras musculares de UMs diferentes (Loeb e Ghez, 2000). Assim, mesmo limitado à contrações de baixa magnitude, é difícil garantir que o número de UMs recrutadas e presentes na composição dos sinais sEMG capturados seja menor ou igual ao número de canais do sistema.

Com isso em mente, optou-se pela utilização de sinais EMG proveniente de um banco de dados para a validação de separação de sinais EMG. Espera-se com isso gerar um cenário controlado, com a quantidade de fontes originais conhecida. Três sinais disponíveis no site da Physiobank (Physiobank, 2011), são exemplos de sinais EMG cortesia do Dr. Seward Rutkove, Departamento de Neurologia, Beth Israel Deaconess Medical Center/Harvard Medical School. Os dados foram originalmente coletados com Sistema de Monitoramento EMG Medelec Synergy N2 (Oxford Instruments Medical, Old Woking, Reino Unido). Um eletrodo de agulha concêntrica de 25mm foi posicionada no músculo tibialis anterior em cada sujeito. Solicitou-se aos pacientes a realizarem um dorsiflexão contra uma resistência. A agulha foi então reposicionada até o momento que MUAPs foram satisfatoriamente identificados. Os dados foram capturados por vários segundos até um momento em que solicitou-se aos pacientes que relaxassem, e as agulhas foram retiradas.

A Figura 4.18 mostra alguns sinais EMG desse banco de dados, sendo: a) sinal EMG saudável de um paciente do sexo masculino de 44 anos; b) sinal EMG com miopatia devido a polimiosite de um paciente do sexo masculino de 57 anos; c) sinal EMG com neuropatia como consequência de radiculopatia de um paciente do sexo masculino de 62 anos. Os sinais EMG foram condicionados por um filtro passa-alta com frequência de corte em 20Hz e um filtro passa-baixa em 5kHz. Os dados foram capturados a uma taxa de amostragem de 50kHz. Os sinais EMG foram limitados a vinte e oito mil dados por sinal, a fim de torná-los compatíveis com o sistema proposto neste trabalho, o que equivale a sete segundos de visualização. Um

ruído gaussiano foi gerado via MATLAB® de forma aleatória, gerando-se um vetor com vinte e oito mil pontos, média nula e desvio padrão de 0,1, através da função “randn”.

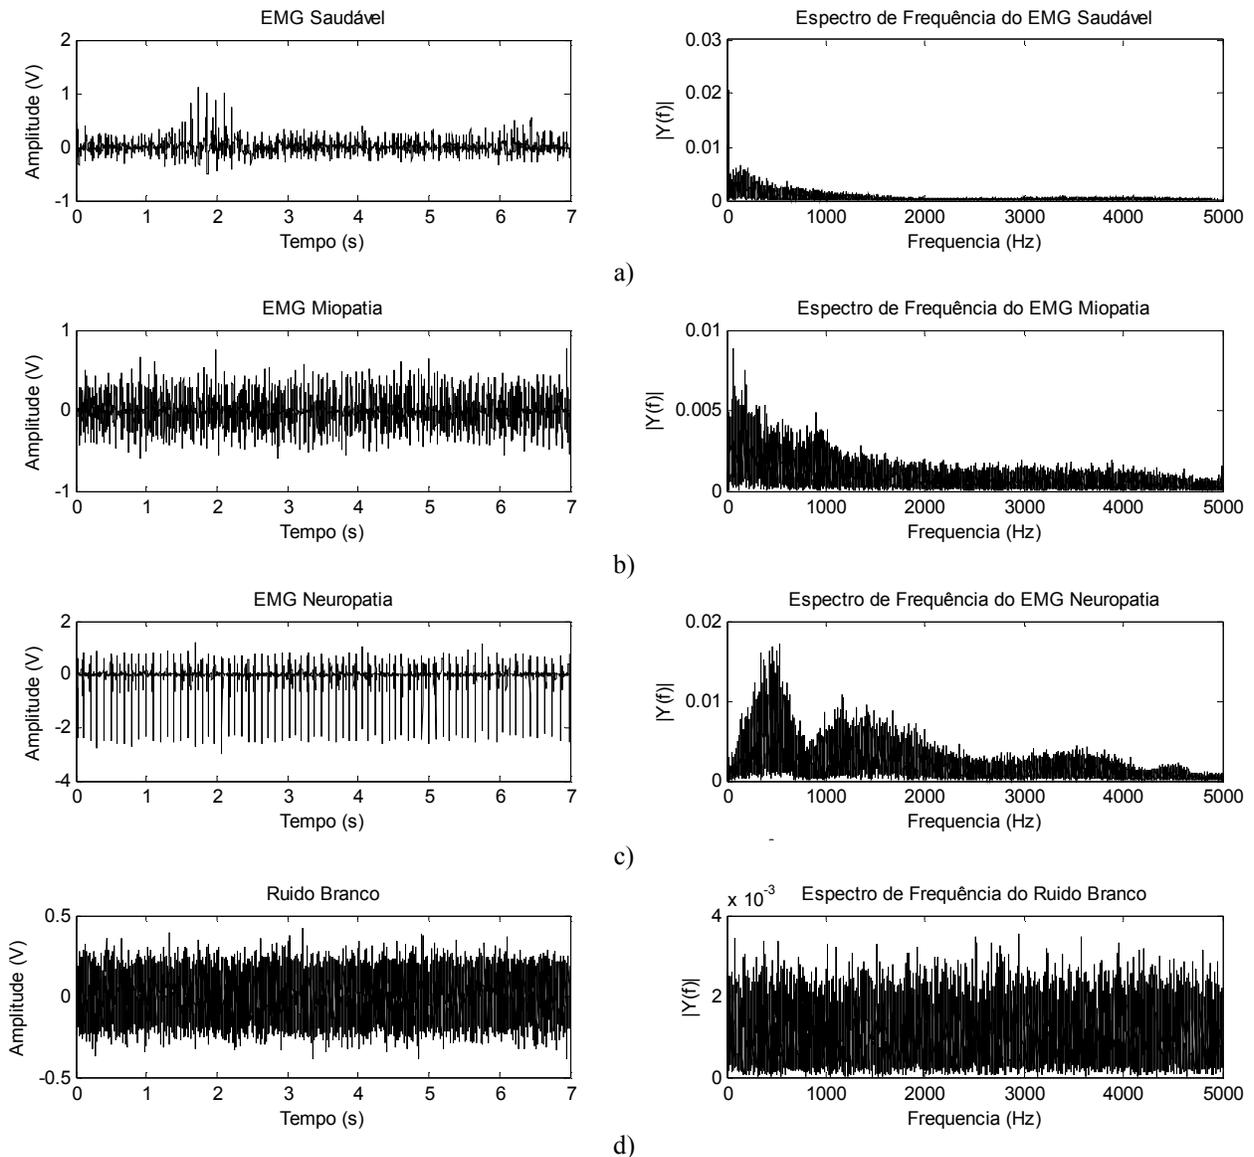


Figura 4.18 – Sinais utilizados na validação de separação de sinais EMG em pares no domínio do tempo e frequência. Esses sinais estão no site da Physiobank (Physiobank, 2011. a) sinal EMG saudável de um paciente do sexo masculino de 44 anos; b) sinal EMG com miopatia devido polimiosite de um paciente do sexo masculino de 57 anos; c) sinal EMG com neuropatia como consequência de radiculopatia de um paciente do sexo masculino de 62 anos; d) ruído gaussiano gerado pelo MATLAB®.

Foram realizados cinco testes, cada qual representando capturas de sinais EMG. Em cada teste, os sinais mostrados na Figura 4.18 foram misturados linearmente através de uma matriz de mistura com elementos desconhecidos e arbitrários, geradas no MATLAB®. As misturas

foram salvas em arquivos-texto e posteriormente processados pelo Software de Separação Cega de Fontes.

4.2.5 MÉTRICAS UTILIZADAS NA ANÁLISE DOS RESULTADOS

Para análise dos resultados da separação de sinais conhecidos e separação de sinais EMG decidiu-se comparar as misturas, fontes originais e fontes estimadas. Espera-se, com isso, validar: se as misturas geradas são diferentes misturas das fontes originais, satisfazendo um dos pré-requisitos para separar fontes por ICA; se as fontes estimadas são morfologicamente semelhantes às fontes originais, levando em conta que a ICA recupera as fontes originais com possível distorção de amplitude. Essa comparação se torna mais delicada devido às alterações nas variâncias das fontes estimadas causados pelos processos de mistura e de separação de fontes, ou seja, as amplitudes das fontes separadas são diferentes das fontes originais, apesar das morfologias serem recuperadas.

Desta forma, foi necessária a utilização de uma métrica para comparação entre misturas, fontes originais e fontes estimadas que levasse em conta a morfologia das fontes. Optou-se pela utilização da relação sinal-interferência (*Signal-to-Interference Ratio* – SIR), amplamente utilizada em telecomunicações e em trabalhos que envolvam separação cega de fontes, que mede a quantidade (em decibéis) de um sinal modulante em um sinal portador (Schobben *et al*, 1999). A SIR representa a razão entre a potência da portadora e a diferença entre a portadora e a modulante. No presente trabalho, a SIR representa a razão entre a potência da fonte conhecida e a diferença entre a fonte conhecida e a fonte estimada (Equação 4.1). Nota-se que quanto maior a semelhança entre a fonte estimada e a fonte conhecida, maior é o valor da SIR. Caso a fonte estimada for idêntica à fonte original, a SIR tende ao infinito.

$$SIR = 10 \log \frac{\overline{S^2}}{(S - SE)^2} (dB) \quad (4.1)$$

onde S representa a fonte conhecida e SE a fonte estimada após normalização.

Utilizou-se a SIR para validar a separação de sinais conhecidos e a separação de sinais EMG. Em ambos os casos, a SIR foi calculado tanto entre as fontes originais e as misturas quanto

entre as fontes originais e fontes estimadas. Calculou-se a SIR entre as fontes originais e as misturas a fim de comprovar que os sinais capturados se tratavam de diferentes misturas dos mesmos sinais originais, e também foi calculada entre as fontes originais e fontes estimadas, a fim de verificar se as fontes estimadas realmente se assemelham com as fontes originais.

Como não é possível prever a ordem em que as fontes são separadas, ou seja, não se sabe qual fonte será separada primeiro, a SIR é muito prática para identificar qual a ordem das fontes estimadas. Desta forma, pôde-se calcular a correlação estatística entre uma fonte estimada e a fonte original equivalente, a fim de verificar os resultados da separação. Calculou-se a correlação com intervalo de confiança de 95%.

A correlação linear quantifica o quão forte é a relação linear entre duas ou mais variáveis (Equação 4.2). Quando não há correlação entre duas grandezas, não existe tendência dos valores de uma grandeza influenciar os valores da segunda grandeza. No entanto, duas grandezas podem ser estatisticamente dependentes mesmo quando a correlação entre as mesmas for baixa.

O coeficiente de correlação mede o grau da correlação entre duas variáveis. Este coeficiente, normalmente representado por ρ , assume valores entre -1 e 1, sendo que $\rho = 1$ representa correlação perfeita positiva entre as duas variáveis; $\rho = -1$ representa correlação negativa perfeita entre as duas variáveis, isto é, se uma aumenta, a outra sempre diminui; $\rho = 0$ significa que as duas variáveis não dependem linearmente uma da outra.

$$\rho_{X,Y} = \frac{\text{cov}(X,Y)}{\sigma_X \sigma_Y} = \frac{E((X - \mu_X)(Y - \mu_Y))}{\sigma_X \sigma_Y} \quad (4.2)$$

Capítulo 5

Resultados

OS resultados foram organizados seguindo as quatro etapas de validação conforme Figura 4.14, ou seja, especificações técnicas do sistema de captura, captura de sinais eletromiográficos de superfície, separação de sinais conhecidos e separação de sinais eletromiográficos.

5.1 Especificações Técnicas do Sistema de Captura

Considerou-se o CMRR e a impedância de entrada em modo comum do INA129 como sendo as do próprio sistema de captura, já que esse componente isola o sistema de captura do sistema medido. Como o ganho foi fixado em 20dB, o CMRR é de 106dB e a impedância de entrada de modo comum é $10^{11}\Omega/9\text{pF}$.

A Figura 5.1 mostra o ganho e a resposta em frequência do primeiro estágio de amplificação para variações ascendentes e descendentes na frequência do sinal de entrada. As quedas de 3dB caracterizadas como as frequências de corte do filtro passa-faixa ocorrem em aproximadamente 10Hz e 900Hz. Os desvios padrão para cada ponto na Figura 5.1 foram calculados a partir das cinco capturas, contudo são muito pequenos, e ultrapassa 0,03dB.

A Figura 5.2 mostra a linearidade do conversor A/D, ou seja, o quanto a tensão convertida para valores digitais varia em relação a alterações na tensão analógica de entrada.

Desta forma, quanto mais próximo de uma reta, maior a linearidade do conversor A/D. Adicionalmente, quanto mais próximo o coeficiente de linearidade (R^2) for de 1,00, maior a linearidade. Nesse caso, R^2 é igual a 1,00 com desvio padrão 0,0053.

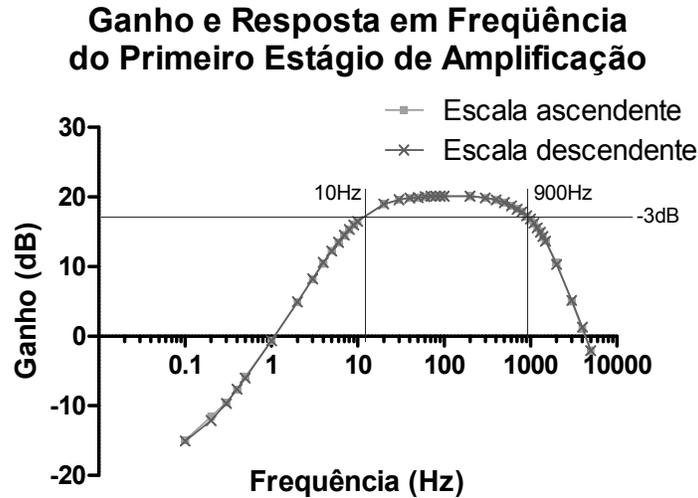


Figura 5.1 – Ganho e resposta em frequência do filtro passa-faixa com frequência de corte inferior em aproximadamente 10Hz e frequência de corte superior em aproximadamente 900Hz.

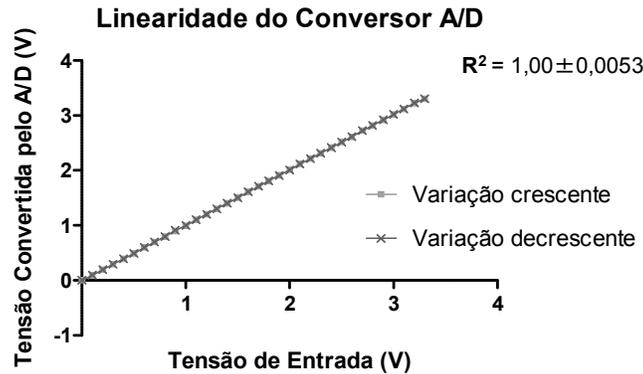


Figura 5.2 – Linearidade do conversor A/D com coeficiente de linearidade $R^2 = 1,00$.

A Tabela 5.1 mostra os valores de ruído do sistema para cada canal.

Tabela 5.1 – Ruído do Sistema de Captura. A análise 1 mostra o ruído do sistema considerando ganho mínimo inicial; a análise 2 mostra o ruído do sistema após ajuste dos ganhos de cada canal com influência do ganho; a análise 3 mostra o ruído do sistema após ajuste dos ganhos de cada canal, referente à entrada.

Ruído do Sistema de Captura (μV_{RMS})								
Análise	Canal							Média
	A	B	C	D	E	F	G	
1	121,478	80,136	81,467	113,185	96,292	72,409	91,554	93,789 ± 18,025
2	132,443	100,686	89,963	132,568	123,061	85,575	74,755	105,579 ± 23,712
3	2,641	1,598	1,797	2,361	2,190	1,915	1,672	2,025 ± 0,385

5.2 Captura de Sinais Eletromiográficos de Superfície

5.2.1 ELETRODOS COMERCIAIS

Realizaram-se três capturas de sinais sEMG do músculo flexor dos dedos em um sujeito saudável. As Figuras 5.3, 5.4 e 5.5 mostram os sinais das três capturas pós-processados no ambiente desenvolvido no MATLAB®, utilizando-se filtros digitais passa-faixa e *notch* 60Hz a fim de retirar componentes de frequências indesejáveis e facilitar a visualização do sinal sEMG capturado. Para auxiliar na visualização de algumas características dos sinais capturados, dois tipos de gráficos foram gerados: cinco segundos de captura nos domínios do tempo e frequência, e quinhentos milissegundos de captura, entre 3 e 3,5 segundos.

As três capturas seguiram o mesmo protocolo, com início de contração iniciado após aproximadamente 1 segundo do início da captura. As Figuras 5.3, 5.4 e 5.5 mostram os resultados nos domínios do tempo e frequência da primeira captura.

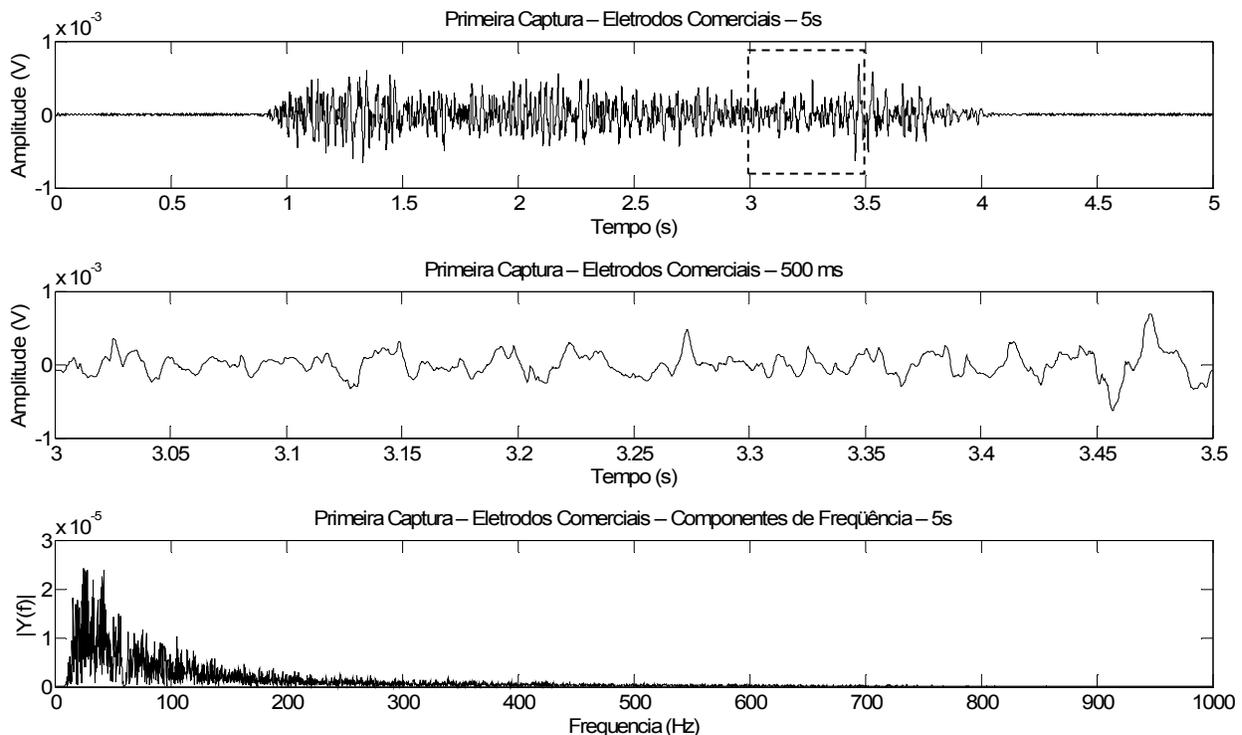


Figura 5.3 – Domínio do tempo e frequência da primeira captura de sinal sEMG com eletrodos comerciais. O gráfico superior mostra 5s do sinal sEMG na primeira captura. O gráfico do meio mostra o detalhe de 500ms do sinal sEMG na primeira captura. O gráfico inferior mostra análise espectral dos 5s do sinal sEMG na primeira captura.

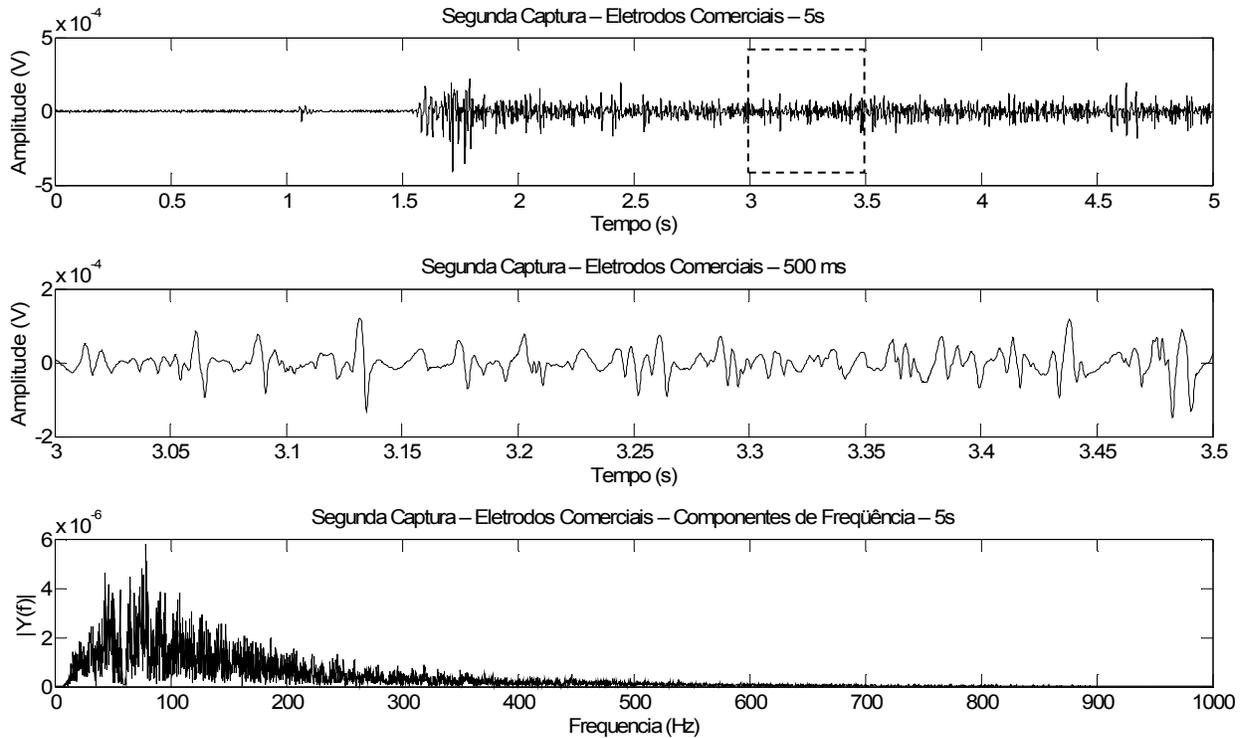


Figura 5.4 – Domínio do tempo e freqüência da segunda captura de sinal sEMG com eletrodos comerciais. O gráfico superior mostra 5s do sinal sEMG na segunda captura. O gráfico do meio mostra o detalhe de 500ms do sinal sEMG na segunda captura. O gráfico inferior mostra análise espectral dos 5s do sinal sEMG na segunda captura.

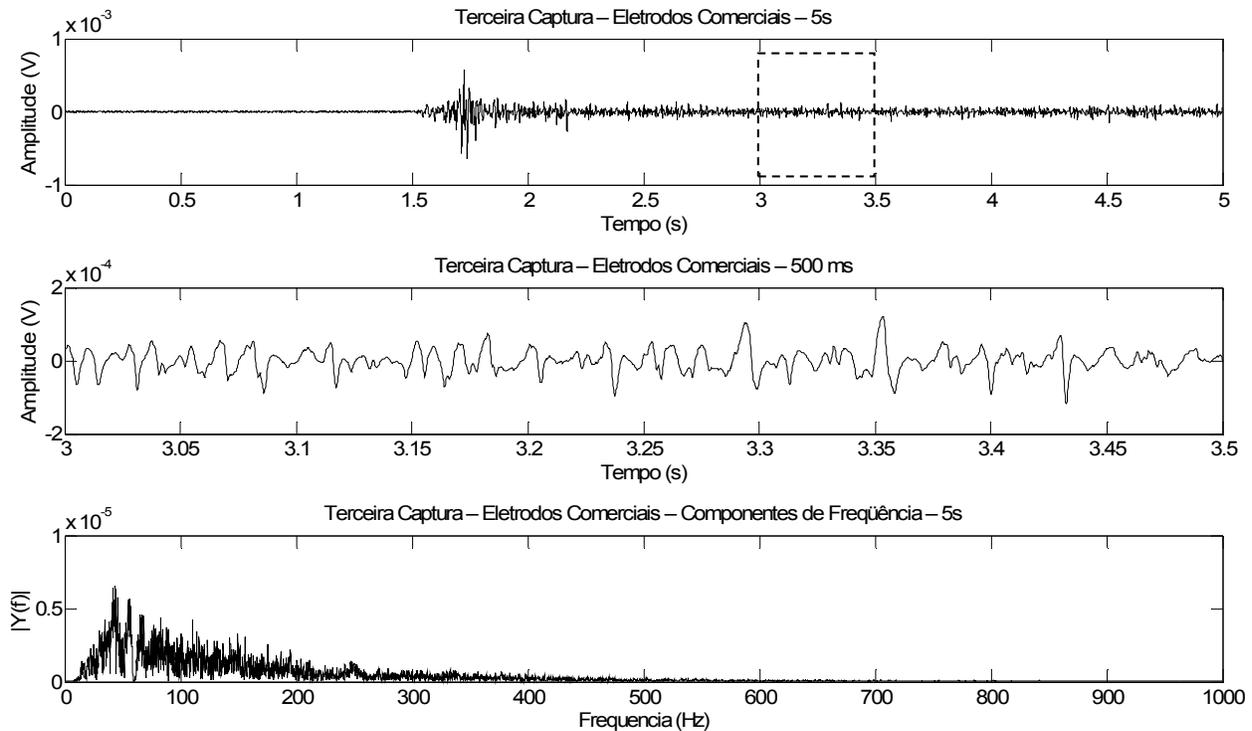
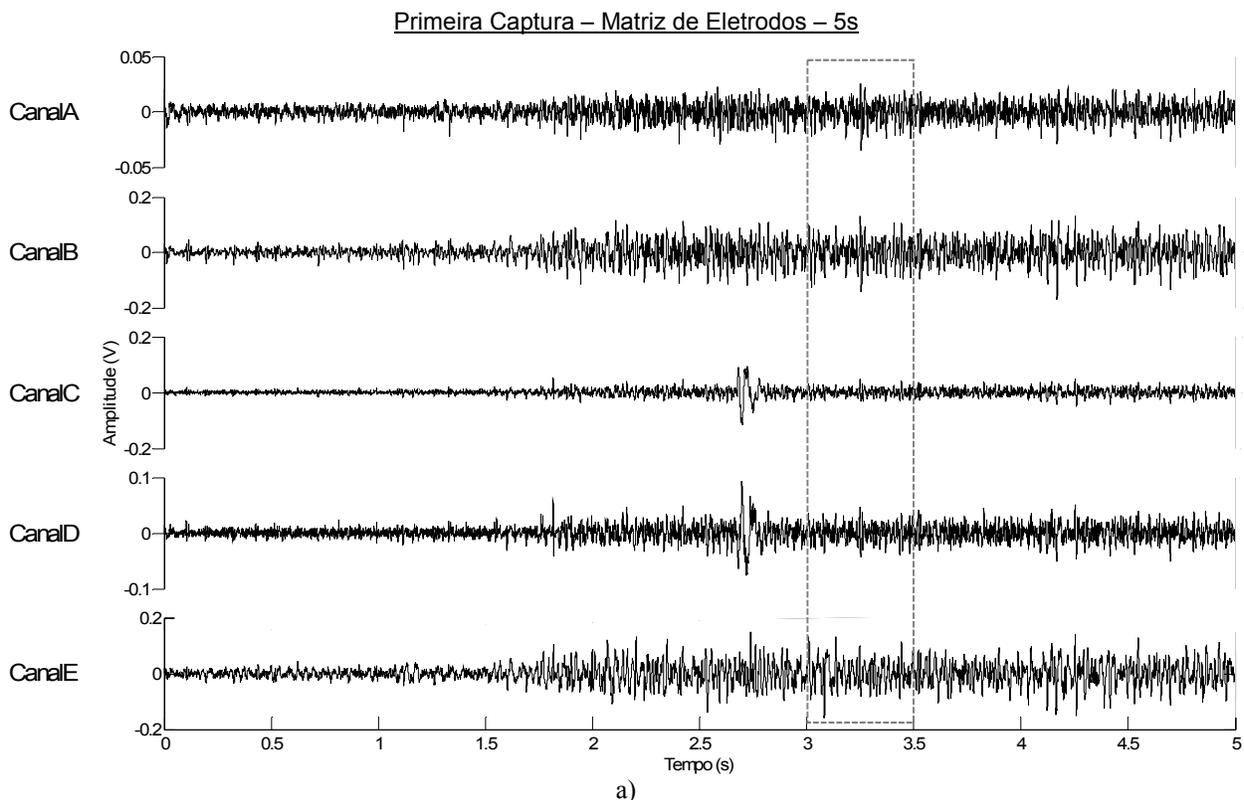


Figura 5.5 – Domínio do tempo e freqüência da terceira captura de sinal sEMG com eletrodos comerciais. O gráfico superior mostra 5s do sinal sEMG na terceira captura. O gráfico do meio mostra o detalhe de 500ms do sinal sEMG na terceira captura. O gráfico inferior mostra análise espectral dos 5s do sinal sEMG na terceira captura.

5.2.2 MATRIZ DE ELETRODOS

Foram realizadas seis capturas utilizando o mesmo protocolo utilizado para a captura de sinais sEMG com eletrodos comerciais, porém utilizando a matriz de eletrodos desenvolvida no laboratório. O pós-processamento também incluiu filtro passa-faixa e filtro *notch* 60Hz desenvolvidos em ambiente MATLAB®. Um conjunto de três gráficos foi gerado para cada captura, incluindo um gráfico com cinco segundos de captura, um gráfico com detalhe de quinhentos milissegundos, entre 3 e 3,5 segundos, e um gráfico com as componentes de frequência dos cinco segundos de captura. Cada gráfico mostra 5 canais de captura, do canal A ao canal E. Da mesma forma realizada nas capturas com eletrodos comerciais, o sujeito iniciou a contração voluntária aproximadamente um segundo após o início da captura.

A Figura 5.6 engloba os três gráficos referentes à primeira captura. A Figura 5.6a mostra os cinco segundos de captura do sinal sEMG. A Figura 5.6a mostra ainda a região de 500ms explorada em maiores detalhes na Figura 5.6b. A Figura 5.6b permite a visualização do sinal capturado em maior detalhe, capturado entre 3 segundos e 3,5 segundos. A Figura 5.6c mostra as componentes de frequência dos cinco segundos de captura.



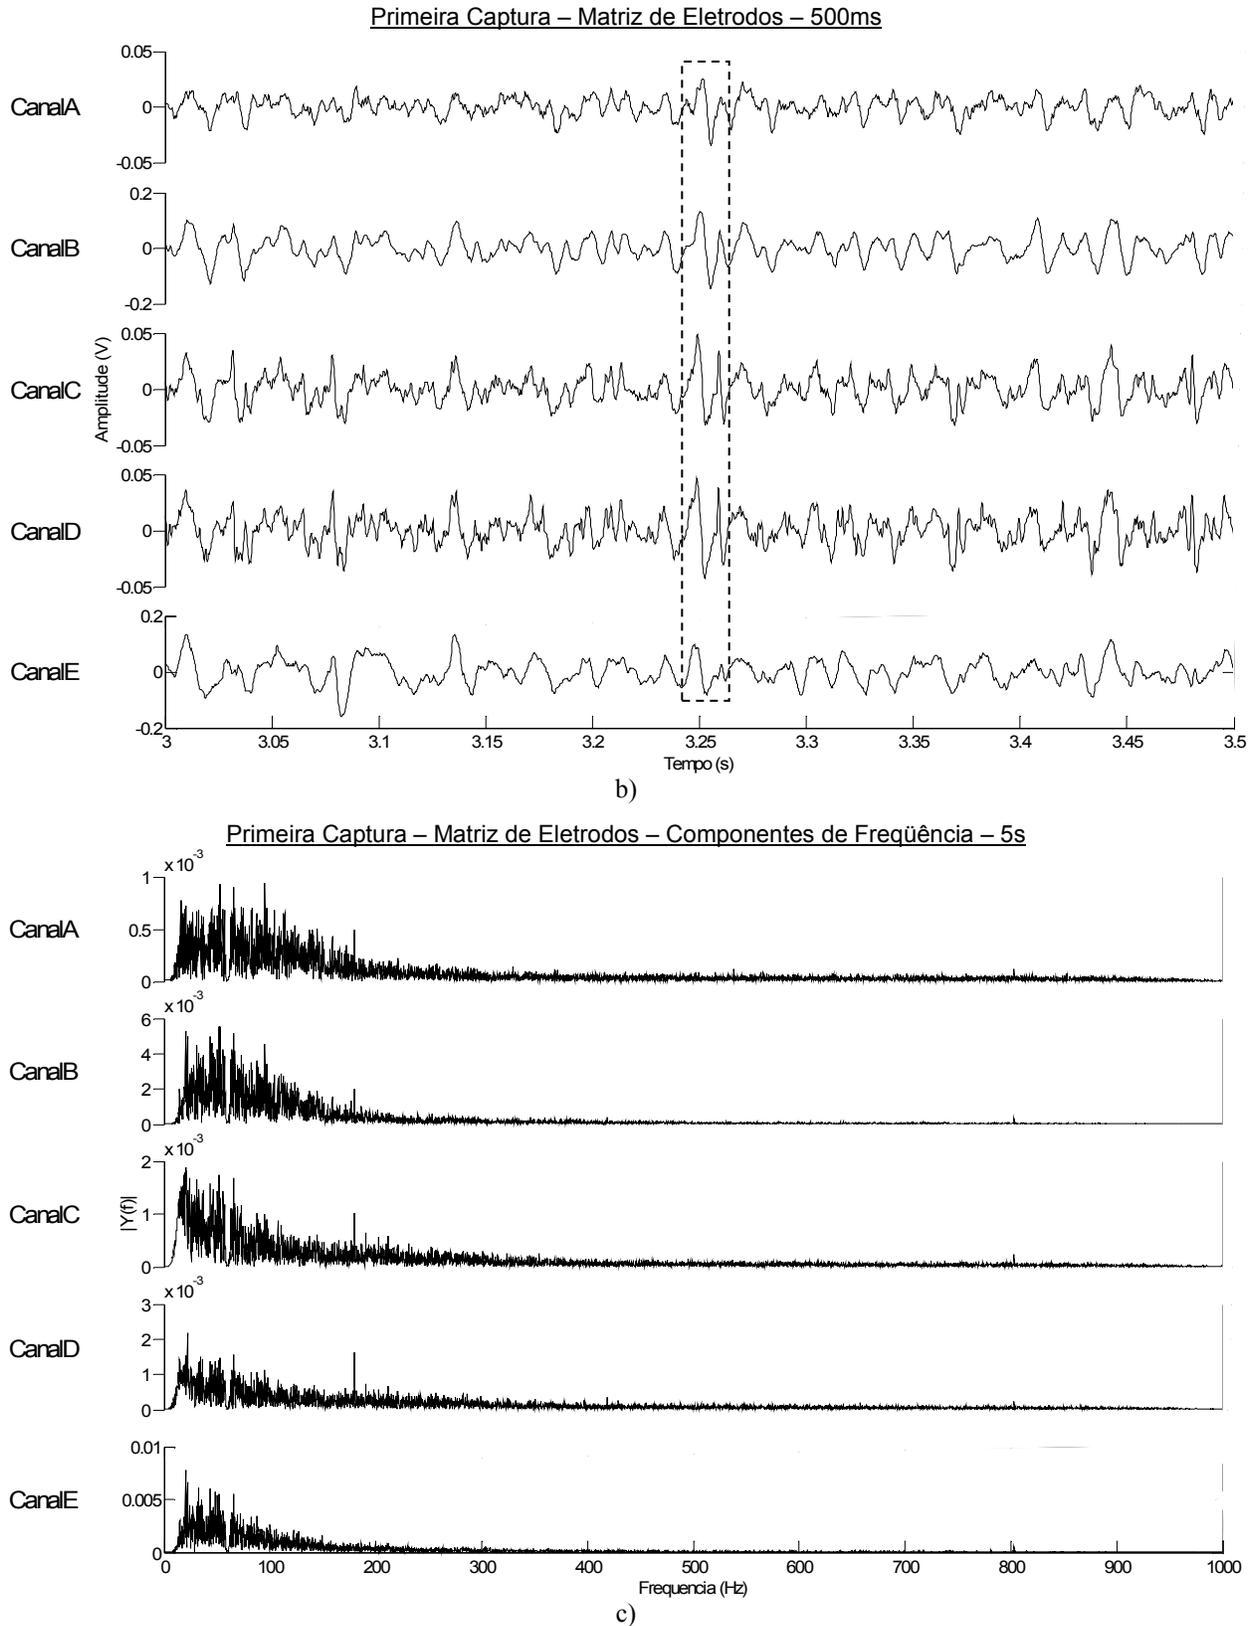


Figura 5.6 – Primeira captura de sinal sEMG com a matriz de eletrodos: a) 5s do sinal sEMG na primeira captura. A área demarcada mostra os 500ms em análise. b) Detalhe de 500ms sinal sEMG na primeira captura. Área em destaque mostra possíveis MUAPs. c) Análise espectral dos 5s do sinal sEMG na primeira captura.

Outras cinco capturas foram realizadas e os gráficos podem ser encontrados no Apêndice A. As mesmas considerações levantadas na análise do grupo de gráficos da Figura 5.6 podem ser consideradas para as capturas subseqüentes.

5.3 Separação de Sinais Conhecidos

A Tabela 4.1 e a Figura 4.17 mostram os sinais originais que foram misturados em cada um dos seis testes. Os sinais previamente misturados pelo circuito mostrado na Figura 4.15 foram capturados e separados utilizando-se o procedimento descrito no Capítulo 4, Materiais e Métodos. Cinco capturas foram realizadas para cada um dos seis testes. As Figuras 5.7 a 5.12 mostram os resultados do processo de mistura e separação desses testes. Os gráficos mostrados da Figura 5.7 à Figura 5.12 foram organizados da seguinte forma: o gráfico superior esquerdo mostra o valor da SIR entre as fontes originais e os sinais misturados de apenas uma captura, mostrando detalhes da SIR entre os canais capturados; o gráfico superior direito mostra, graficamente, o resultado da separação de fontes para uma captura, ou seja, valor da SIR entre as fontes originais e as fontes estimadas de apenas uma captura, além de mostrar o valor da correlação entre as fontes originais e fontes estimadas; o gráfico do meio à esquerda mostra, graficamente, o resultado da separação de fontes para as 5 capturas, ou seja, valor da SIR entre as fontes originais e as fontes estimadas de todas as capturas de um teste; o gráfico do meio à direita mostra, graficamente, a média de correlação entre fontes originais e fontes estimadas considerando as cinco capturas de um teste; o último gráfico, centralizado, mostra a SIR e correlação entre fontes originais para mostrar eventuais correlações entre as mesmas.

A Figura 5.7 mostra o resultado da separação dos sinais capturados durante o primeiro teste, que envolveu a mistura das fontes originais: senóide de 500Hz, ruído branco e a *Waveform*. A Figura 5.8 mostra o resultado da separação dos sinais capturados durante o segundo teste, que envolveu a mistura das fontes originais: senóide de 500Hz, ruído branco e o *Burst*. A Figura 5.9 mostra o resultado da separação dos sinais capturados durante o terceiro teste, que envolveu a mistura das fontes originais: as senóides de 500Hz e 40Hz, e ruído branco. A Figura 5.10 mostra o resultado da separação dos sinais capturados durante o terceiro teste, que envolveu a mistura das fontes originais: senóide de 500Hz, ruído branco e *User1*. A Figura 5.11 mostra o

resultado da separação dos sinais capturados durante o terceiro teste, que envolveu a mistura das fontes originais: senoíde de 500Hz, ruído branco e *User2*. A Figura 5.12 mostra o resultado da separação dos sinais capturados durante o terceiro teste, que envolveu a mistura das fontes originais: senoíde de 500Hz, ruído branco e *User3*.

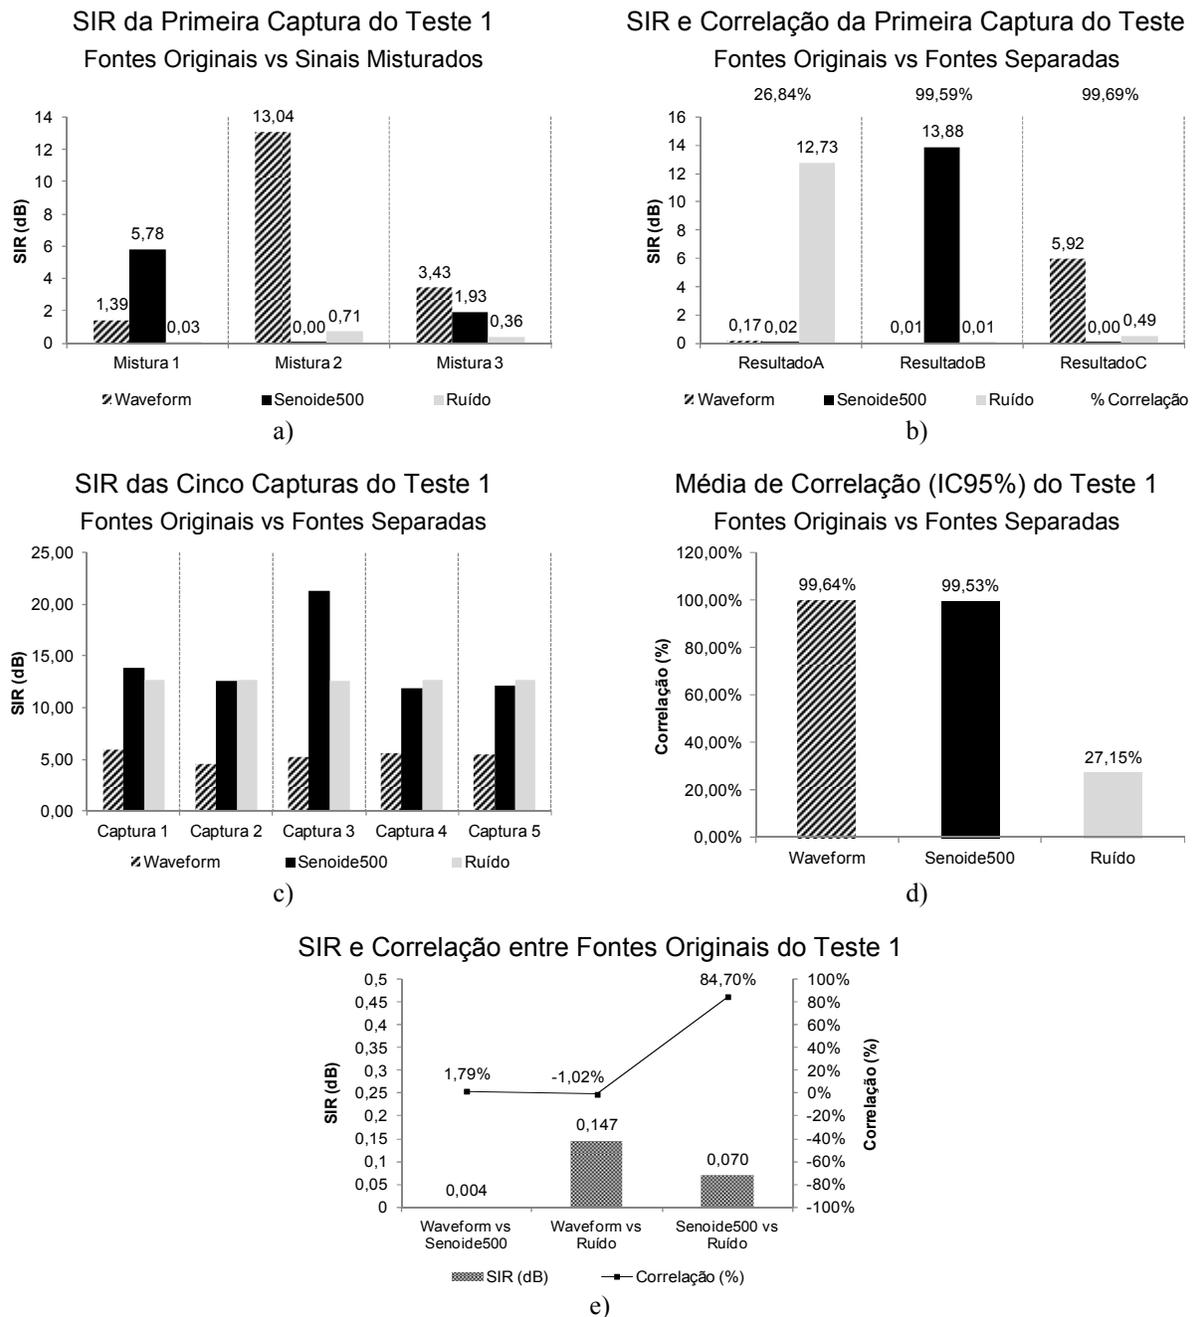


Figura 5.7 – Resultados da separação de sinais originais do Teste 1. a) SIR entre fontes originais e misturas para a captura 1. b) SIR e Correlação entre fontes originais e fontes separadas para a captura 1. c) SIR e Correlação entre fontes originais e fontes separadas. d) Média de Correlação entre fontes originais e fontes separadas. e) SIR e Correlação entre fontes originais.

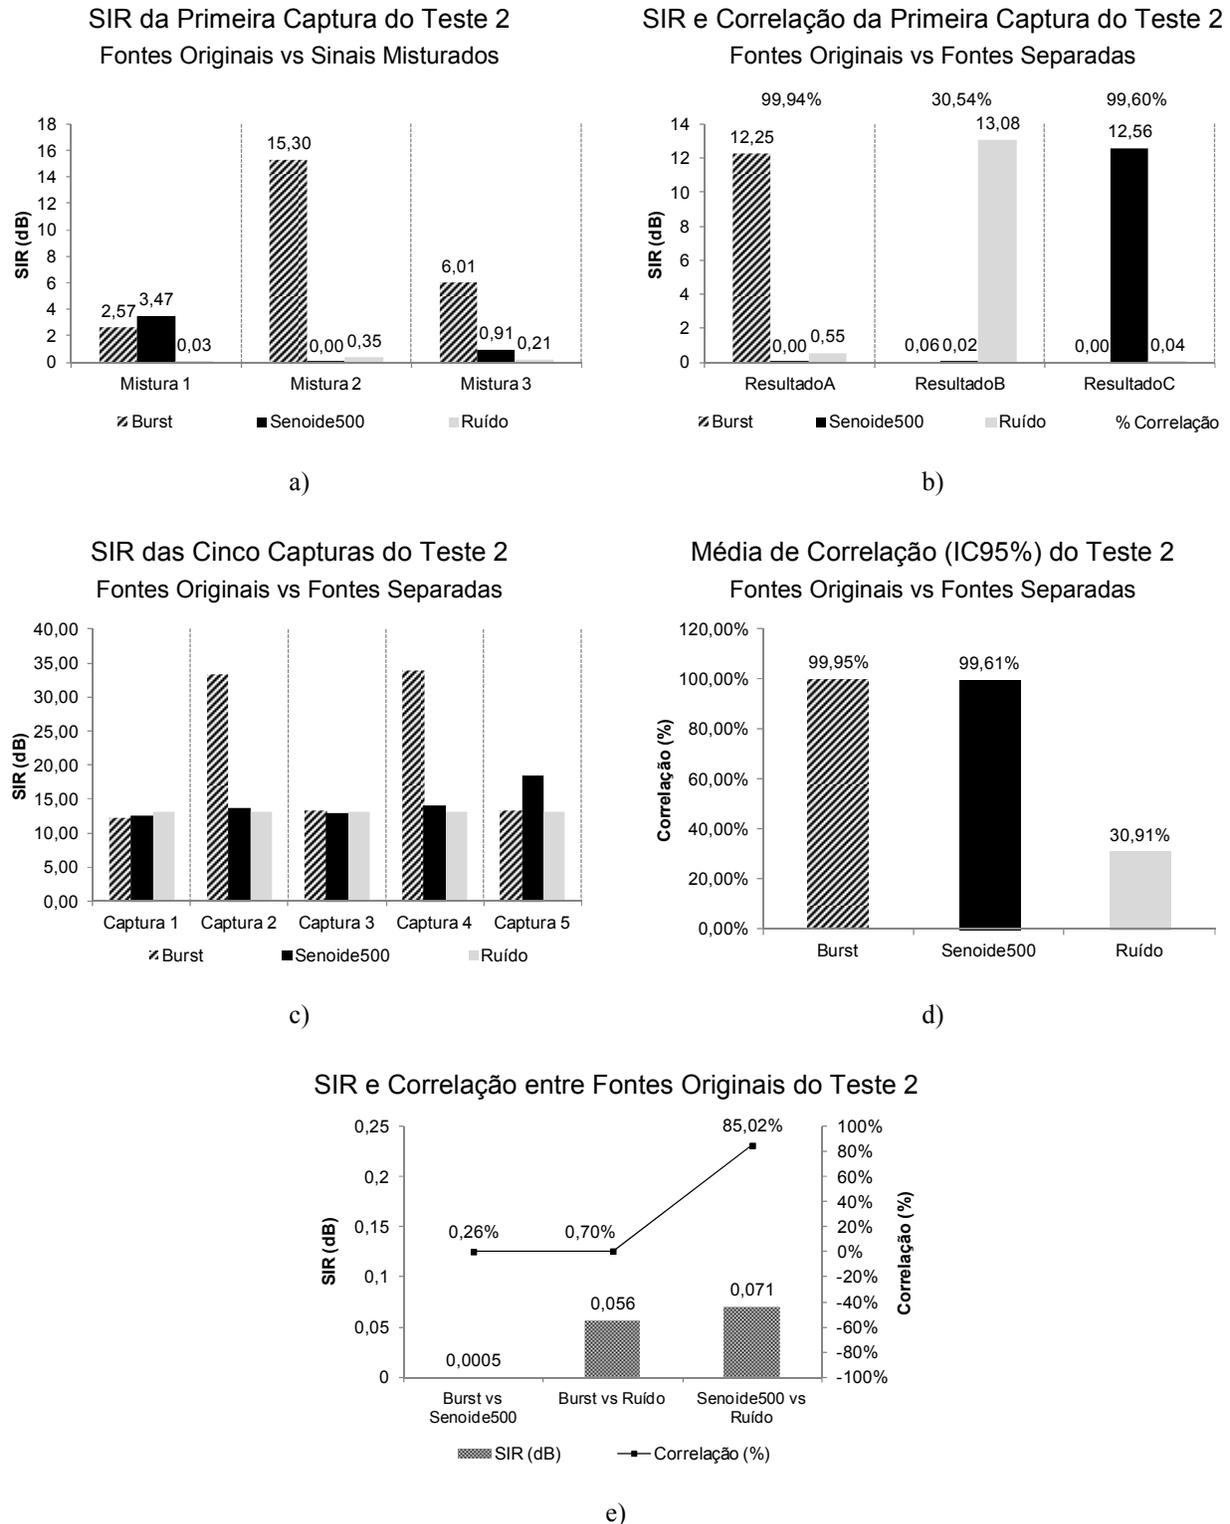


Figura 5.8 – Resultados da separação de sinais conhecidos do Teste 2. a) SIR entre fontes conhecidas e misturas para a captura 1. b) SIR e Correlação entre fontes conhecidas e fontes separadas para a captura 1. c) SIR e Correlação entre fontes conhecidas e fontes separadas. d) Média de Correlação entre fontes conhecidas e fontes separadas. e) SIR e Correlação entre fontes conhecidas.

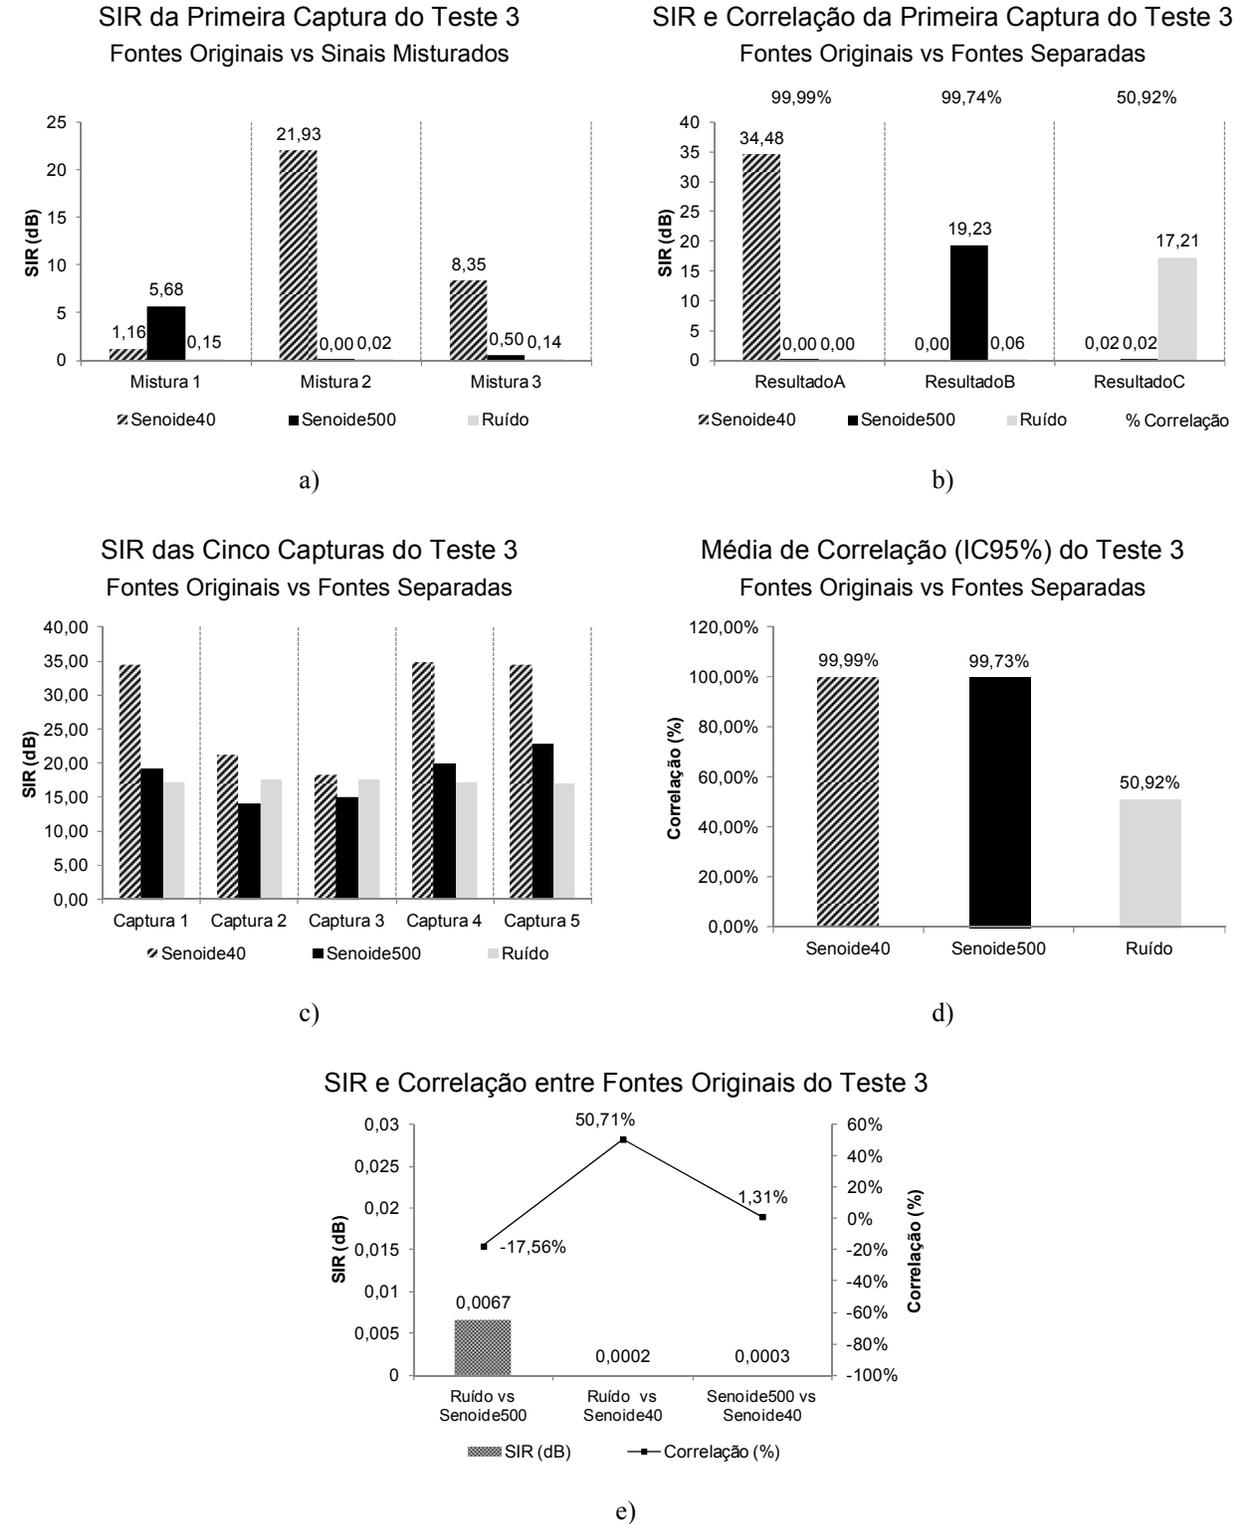


Figura 5.9 – Resultados da separação de sinais conhecidos do Teste 3. a) SIR entre fontes conhecidas e misturas para a captura 1. b) SIR e Correlação entre fontes conhecidas e fontes separadas para a captura 1. c) SIR e Correlação entre fontes conhecidas e fontes separadas. d) Média de Correlação entre fontes conhecidas e fontes separadas. e) SIR e Correlação entre fontes conhecidas.

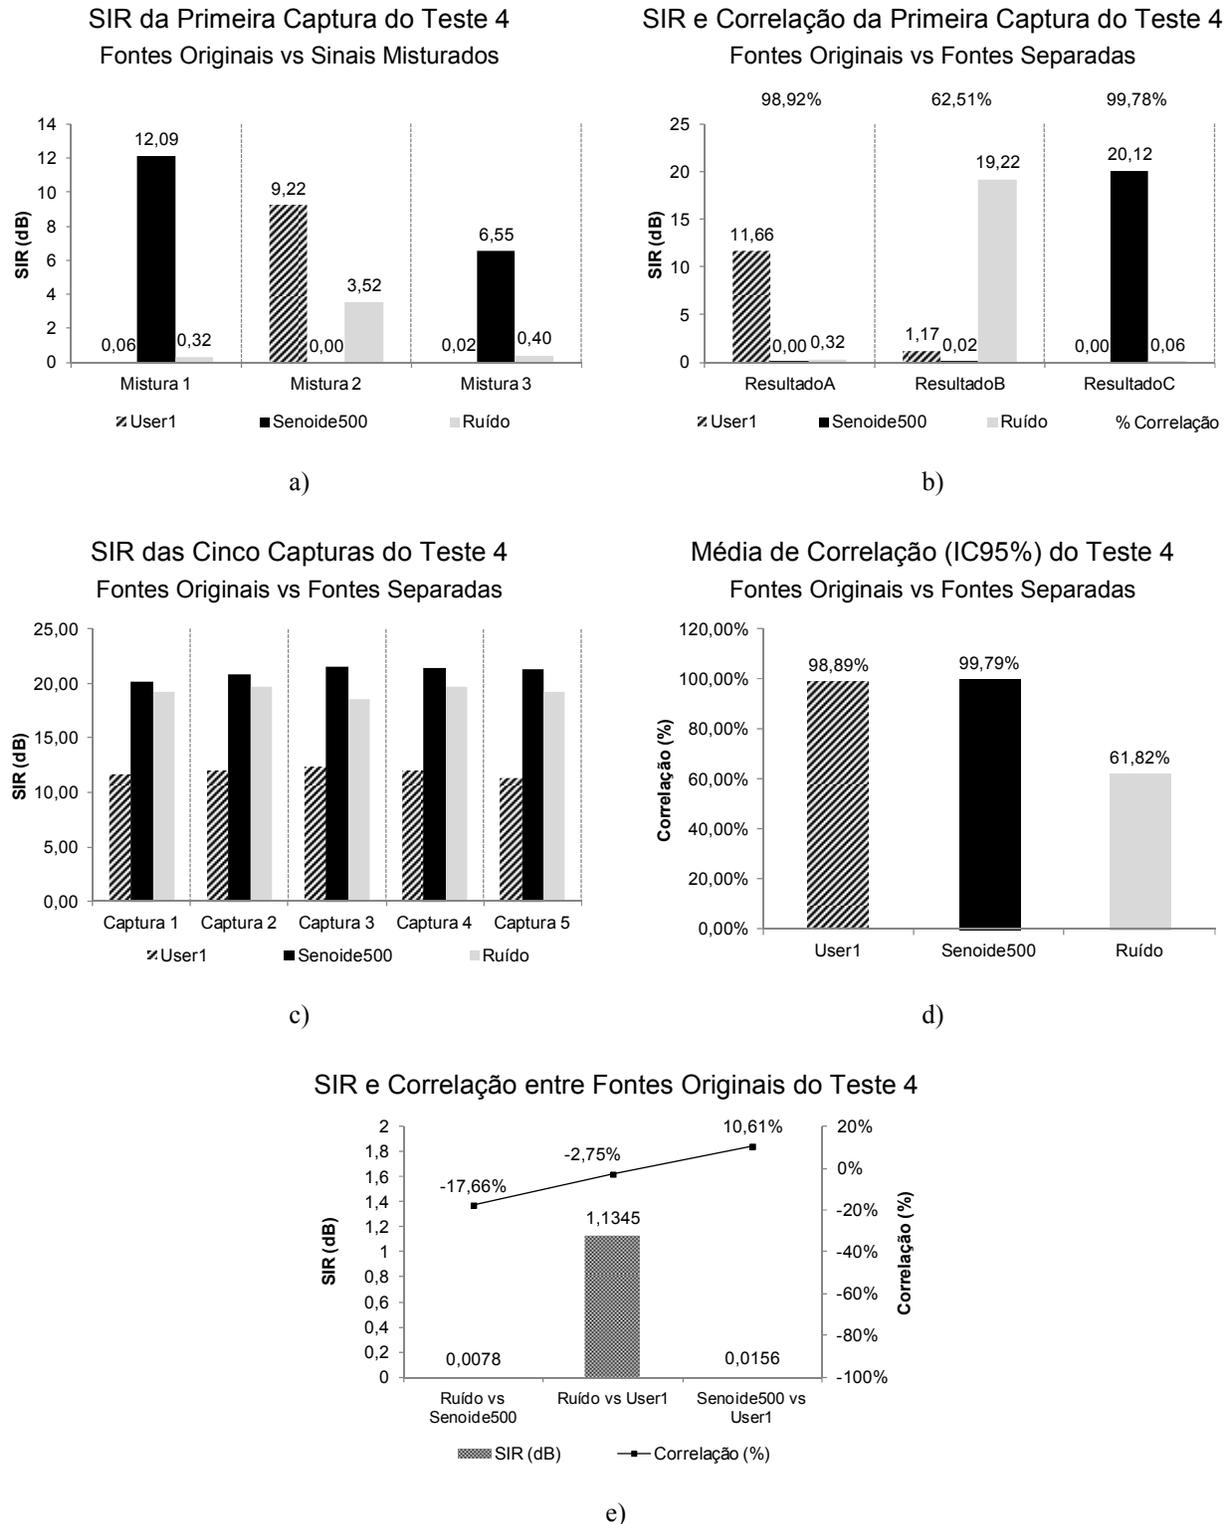
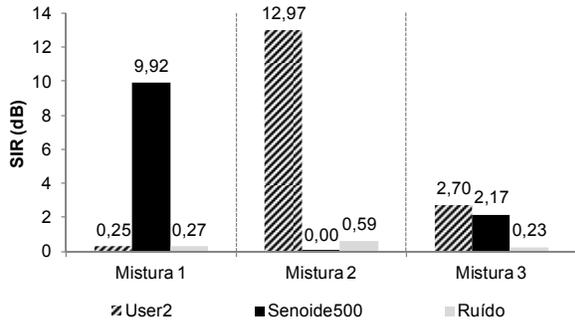


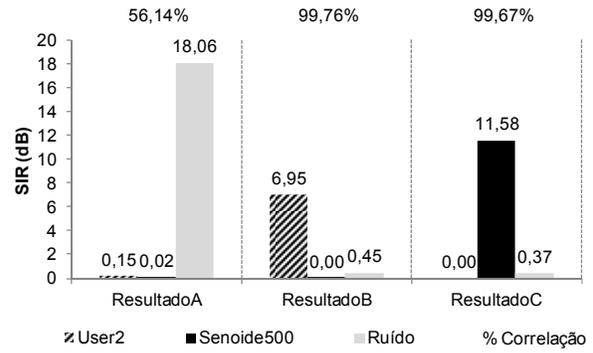
Figura 5.10 – Resultados da separação de sinais conhecidos do Teste 4. a) SIR entre fontes conhecidas e misturas para a captura 1. b) SIR e Correlação entre fontes conhecidas e fontes separadas para a captura 1. c) SIR e Correlação entre fontes conhecidas e fontes separadas. d) Média de Correlação entre fontes conhecidas e fontes separadas. e) SIR e Correlação entre fontes conhecidas.

SIR da Primeira Captura do Teste 5
Fontes Originais vs Sinais Misturados



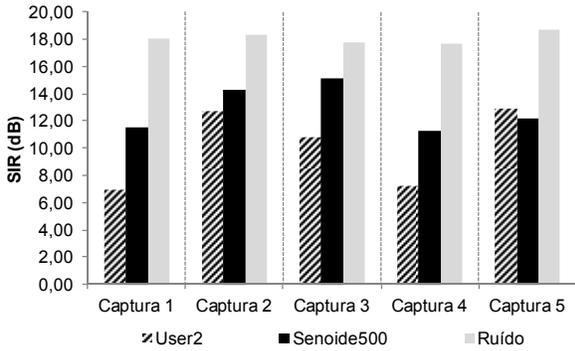
a)

SIR e Correlação da Primeira Captura do Teste 5
Fontes Originais vs Fontes Separadas



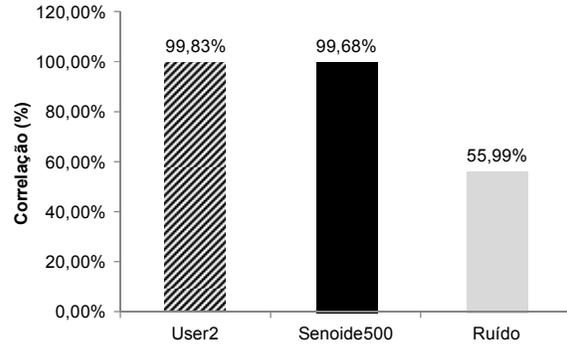
b)

SIR das Cinco Capturas do Teste 5
Fontes Originais vs Fontes Separadas



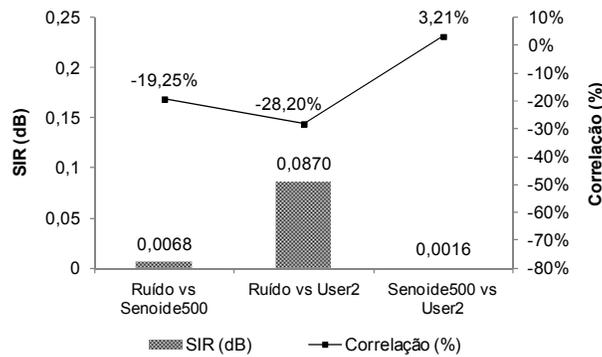
c)

Média de Correlação (IC95%) do Teste 5
Fontes Originais vs Fontes Separadas



d)

SIR e Correlação entre Fontes Originais do Teste 5



e)

Figura 5.11 – Resultados da separação de sinais conhecidos do Teste 5. a) SIR entre fontes conhecidas e misturas para a captura 1. b) SIR e Correlação entre fontes conhecidas e fontes separadas para a captura 1. c) SIR e Correlação entre fontes conhecidas e fontes separadas. d) Média de Correlação entre fontes conhecidas e fontes separadas. e) SIR e Correlação entre fontes conhecidas.

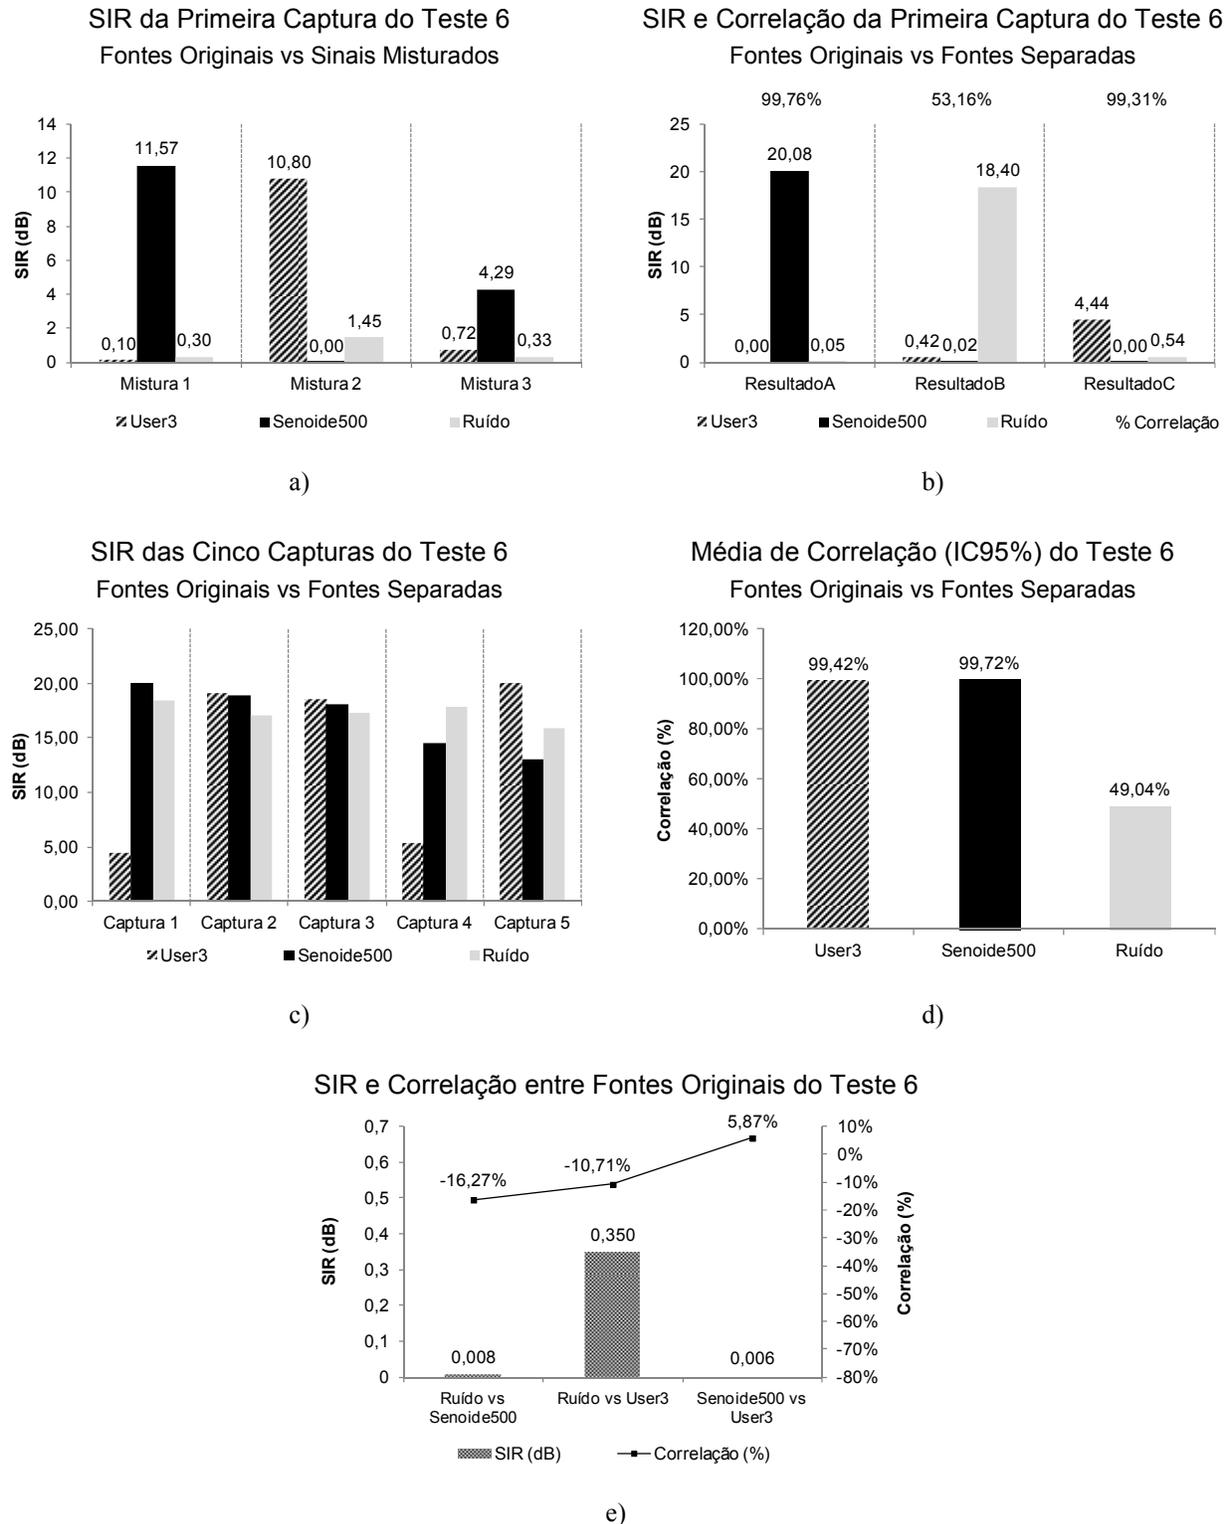


Figura 5.12 – Resultados da separação de sinais conhecidos do Teste 6. a) SIR entre fontes conhecidas e misturas para a captura 1. b) SIR e Correlação entre fontes conhecidas e fontes separadas para a captura 1. c) SIR e Correlação entre fontes conhecidas e fontes separadas. d) Média de Correlação entre fontes conhecidas e fontes separadas. e) SIR e Correlação entre fontes conhecidas.

A fim de ilustrar o processo de mistura e separação de fontes no domínio do tempo e da frequência, as Figura 5.13 e 5.14 mostram, respectivamente, as três misturas capturadas e os três sinais estimados pelo processo de separação para o Teste 2, que engloba as fontes originais *burst*, senóide de 500Hz e ruído branco. A composição de cada mistura e de cada Resultado em relação a cada fonte original pode ser analisada através da SIR mostrado na Figura 5.8. As misturas e os sinais estimados para os outros testes podem ser vistos no Apêndice A.

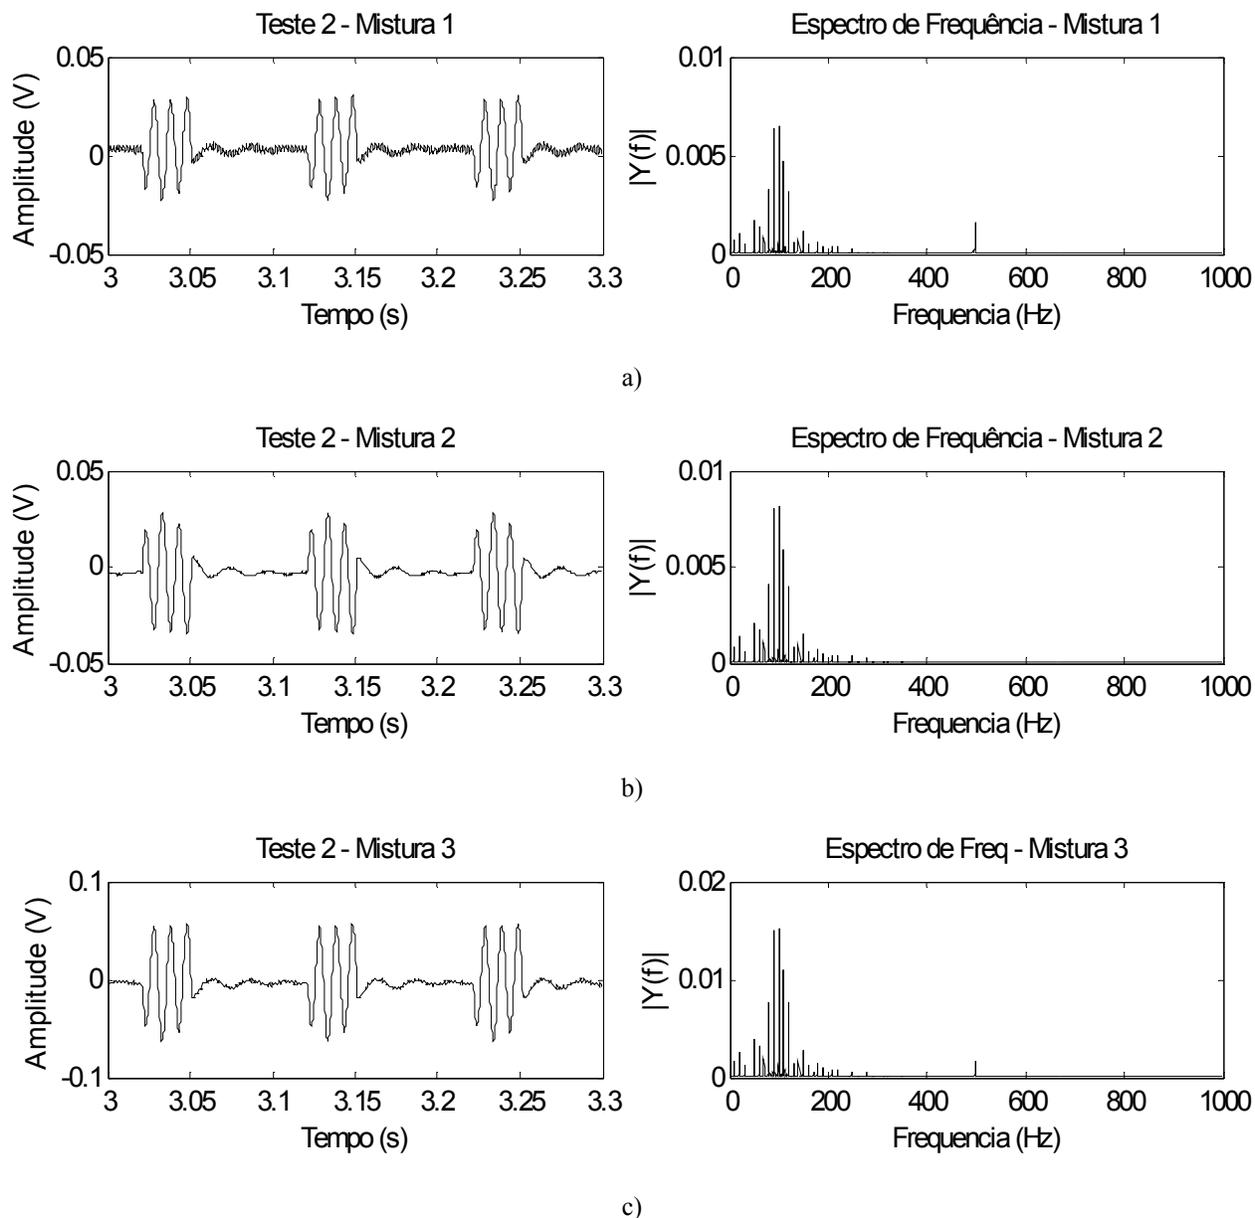


Figura 5.13 – Três misturas capturadas para o Teste 2, no domínio do tempo e da frequência, que engloba as fontes originais *burst*, senóide de 500Hz e ruído branco. a) Mistura 1. b) Mistura 2. c) Mistura 3.

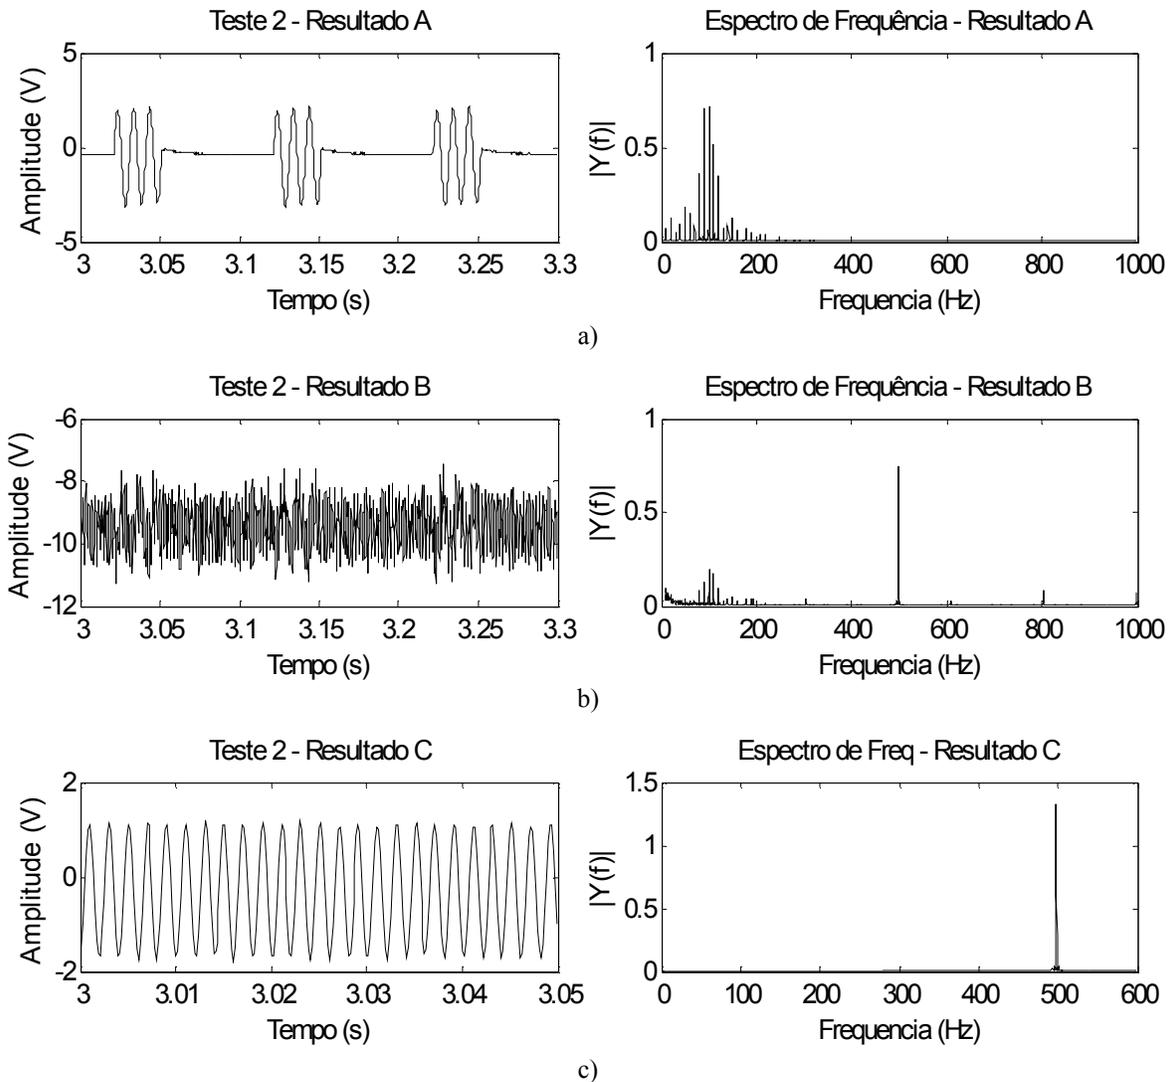


Figura 5.14 – Três sinais estimados pelo processo de separação para o Teste 2, no domínio do tempo e da frequência, que engloba as fontes originais *burst*, senóide de 500Hz e ruído branco. a) Resultado A separou o *burst*. b) Resultado B separou o ruído. c) Resultado C separou a senóide de 500Hz.

5.4 Separação de Sinais Eletromiográficos

Os sinais EMG, mostrados na Figura 4.18, mais o ruído, foram misturados linearmente no MATLAB® através de uma matriz com elementos gerados aleatoriamente através da função “randn”. Logo, o processo de mistura é desconhecido. As Figuras 5.15 a 5.19 mostram os resultados das separações dos sinais EMG intramusculares para cinco testes, sendo que cada teste possui uma mistura diferente dos sinais EMG. Cada uma dessas Figuras é composta por dois gráficos: o gráfico à esquerda mostra, graficamente, o valor do SIR entre os sinais EMG originais e os sinais misturados; o gráfico à direita direito mostra, graficamente, o resultado da

separação de fontes, ou seja, valor da SIR entre os sinais EMG originais e as fontes estimadas, além de mostrar o valor da correlação entre as fontes originais e fontes estimadas.

A Figura 5.15 mostra o resultado da separação dos sinais para o primeiro teste. A Figura 5.15a mostra a SIR entre as fontes originais e os sinais misturados. A Figura 5.15b mostra o resultado da separação de fontes para o primeiro teste, ou seja, valor da SIR e a correlação entre os sinais EMG originais e as fontes estimadas referente ao primeiro teste.

As Figuras 5.16 a 5.19 mostram o mesmo conjunto de gráficos para os testes 2, 3, 4 e 5, respectivamente. Ou seja, a Figura 5.16 mostra o resultado da separação para o teste 2; A Figura 5.17 mostra o resultado da separação para o teste 3; A Figura 5.18 mostra o resultado da separação para o teste 4; A Figura 5.19 mostra o resultado da separação para o teste 5.

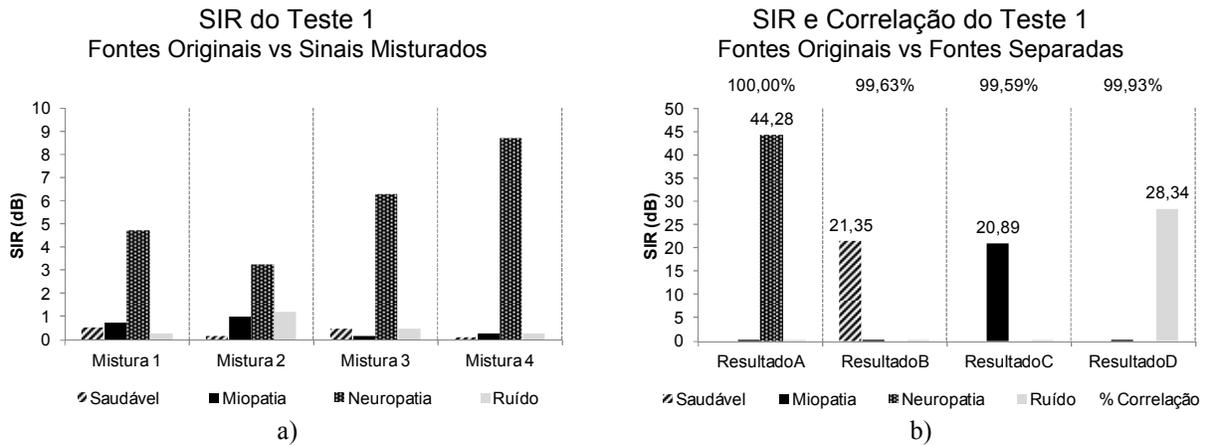


Figura 5.15 – Resultados da separação dos sinais EMG do Teste 1. a) SIR entre sinais EMG originais e sinais misturados. b) SIR e Correlação entre sinais EMG originais e fontes estimadas.

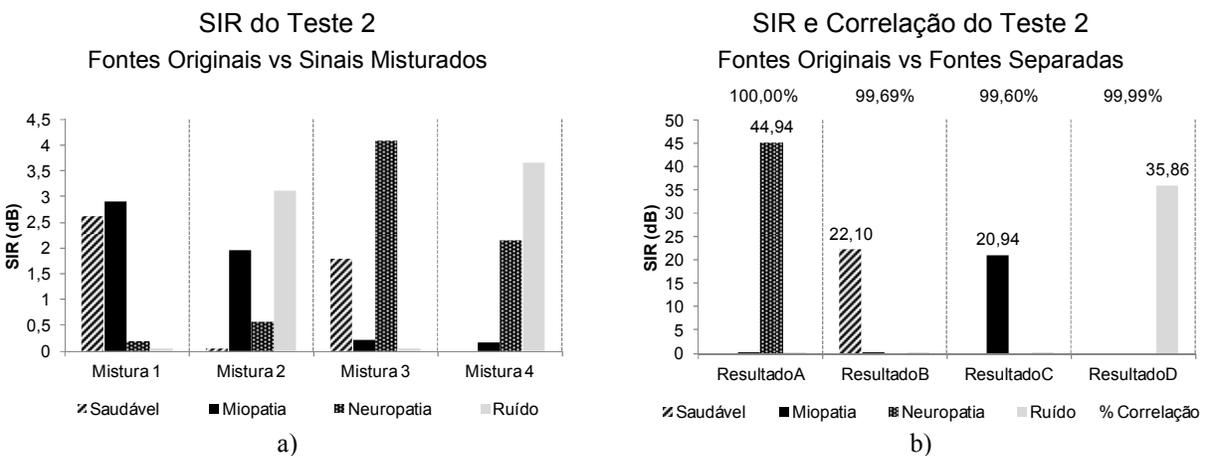


Figura 5.16 – Resultados da separação dos sinais EMG do Teste 2. a) SIR entre sinais EMG originais e sinais misturados. b) SIR e Correlação entre sinais EMG originais e fontes estimadas.

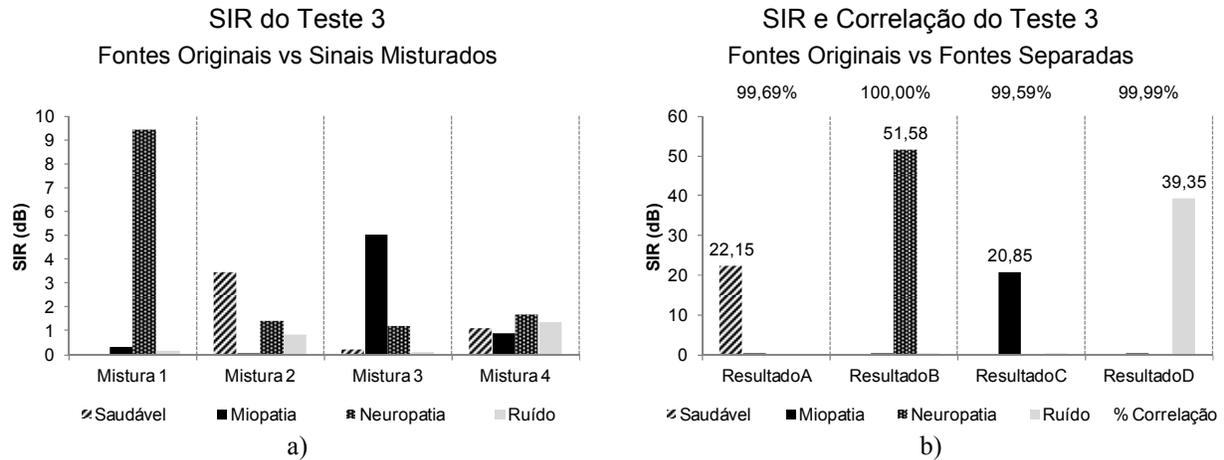


Figura 5.17 – Resultados da separação dos sinais EMG do Teste 3. a) SIR entre sinais EMG originais e sinais misturados. b) SIR e Correlação entre sinais EMG originais e fontes estimadas.

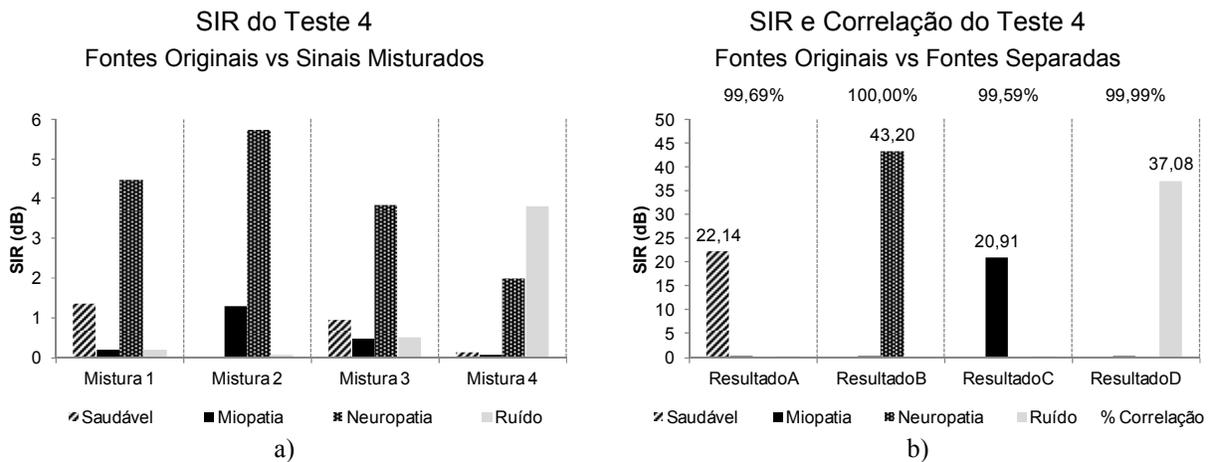


Figura 5.18 – Resultados da separação dos sinais EMG do Teste 4. a) SIR entre sinais EMG originais e sinais misturados. b) SIR e Correlação entre sinais EMG originais e fontes estimadas.

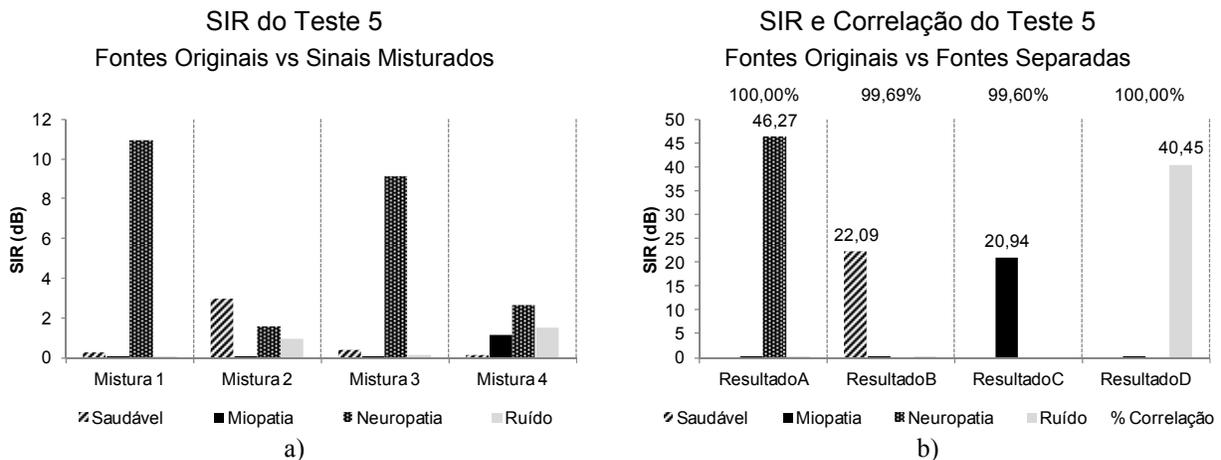


Figura 5.19 – Resultados da separação dos sinais EMG do Teste 5. a) SIR entre sinais EMG originais e sinais misturados. b) SIR e Correlação entre sinais EMG originais e fontes estimadas.

A fim de ilustrar o processo de mistura e separação de sinais EMG no domínio do tempo e da frequência, as Figura 5.20 e 5.21 mostram, respectivamente, as quatro misturas geradas e os quatro sinais EMG estimados pelo processo de separação para o Teste 2. A composição de cada mistura e de cada Resultado em relação a cada fonte original pode ser analisada através da SIR mostrado na Figura 5.16. As misturas e os sinais estimados para os outros testes podem ser vistos no Apêndice A.

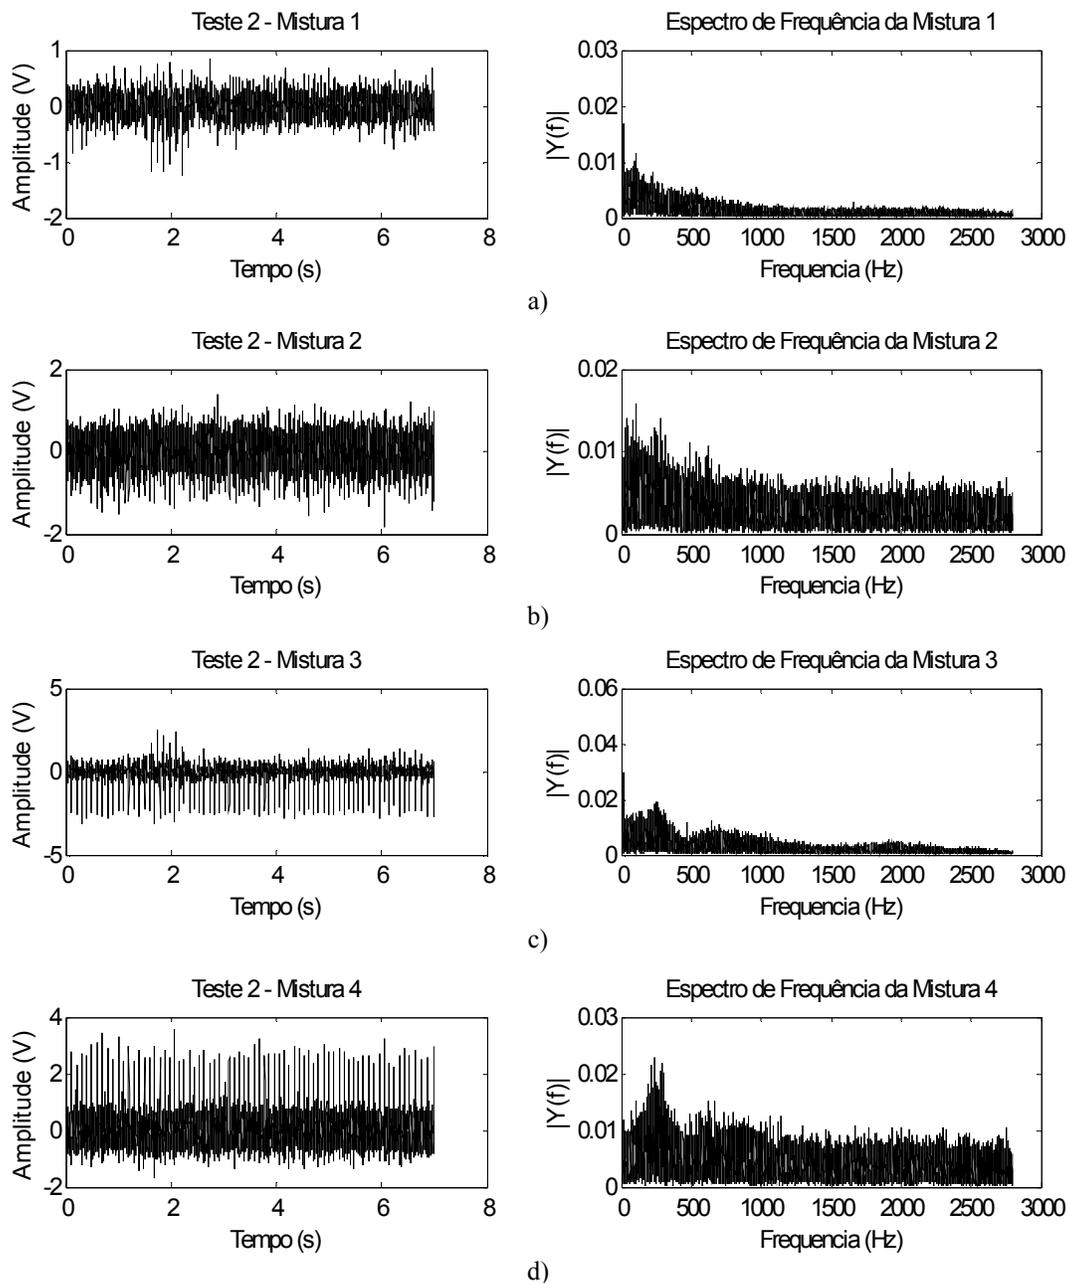


Figura 5.20 – Quatro misturas geradas com os sinais mostrados na Figura 4.18 para o segundo teste da separação de sinais EMG, no domínio do tempo e da frequência. a) Mistura 1. b) Mistura 2. c) Mistura 3. d) Mistura 4.

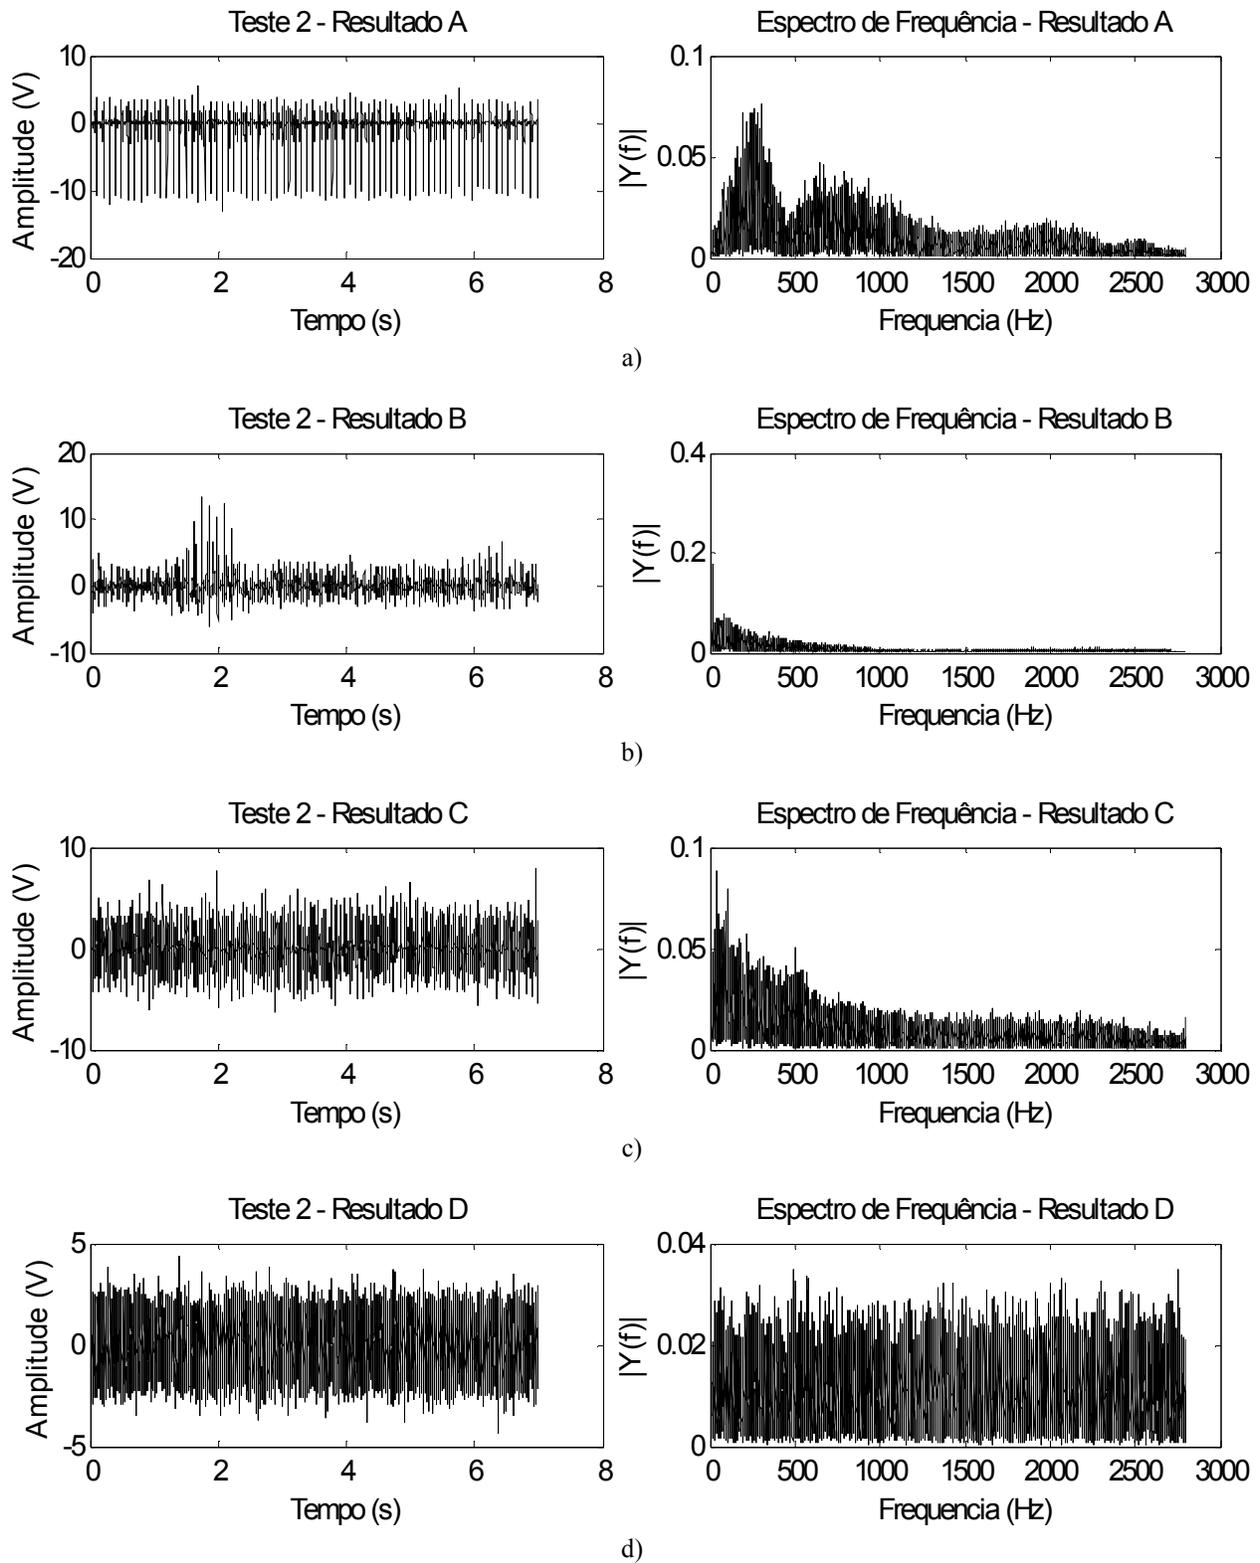


Figura 5.21 – Quatro sinais EMG estimados para o segundo teste da separação de sinais EMG, no domínio do tempo e da frequência. a) Resultado A separou o sinal EMG com neuropatia. b) Resultado B separou o sinal EMG saudável. c) Resultado C separou o sinal EMG com miopatia. d) Resultado D separou ruído branco.

Capítulo 6

Discussão

6.1 Especificações Técnicas do Sistema de Captura

A amplificação de sinais biológicos deve garantir que o sistema de captura não influencie o sistema medido, mantendo o menor nível de ruído possível e limitando as componentes de frequência do sinal capturado. Dessa forma, a fim de garantir o bom acoplamento entre o sistema de captura e o sistema medido, dividiu-se o processo de amplificação em duas etapas, de forma que a primeira etapa de amplificação possuisse ganho fixo de 20dB, garantindo alta impedância de entrada e limitando as componentes de frequência dentro da faixa de amplificação dos sinais sEMG. A segunda etapa de amplificação, por sua vez, apenas amplifica o sinal proveniente da primeira etapa, garantindo baixo nível de ruído após ajuste de ganho, não influenciando nas componentes de frequência do sinal capturado.

Nagel (2000) mostra que uma das melhores opções para amplificar biopotenciais é o amplificador de instrumentação devido às suas características, como alto CMRR e alta impedância de entrada. O amplificador de instrumentação INA129, utilizado no primeiro estágio de amplificação, possui entrada bipolar diferencial que amplifica a diferença dos potenciais nas entradas e atenua sinais semelhantes entre elas, por exemplo, 60Hz da rede elétrica. Como o ganho foi fixado em 20dB, o INA129 apresenta CMRR de 106dB e impedância

de entrada de modo comum $10^{11}\Omega/9\text{pF}$, valores que podem ser considerados satisfatórios segundo a teoria (Nagel, 2000; De Luca, 2006).

As Figura 5.1 e 5.2 mostram, respectivamente, o ganho e a resposta em frequência do primeiro estágio de amplificação para variações ascendentes e descendentes na frequência do sinal de entrada. Apesar da frequência de corte do filtro passa-baixa ocorrer, na prática, em aproximadamente 900Hz, é possível notar o platô de ganho constante entre as frequências 10Hz e 1kHz, com atenuações para frequências fora dessa faixa. Ou seja, a resposta em frequência atende as especificações para capturas de sinais sEMG. Além disso, o fato da frequência de corte ser em 900Hz não afeta a qualidade do sinal sEMG capturado, tendo em vista que o sinal sEMG possui componentes de frequência significativas até 500Hz devido ao efeito de filtro passa-baixas de tecidos subcutâneos (De Luca, 2006; Karlsson *et al*, 2008). Esse erro na frequência de corte (de 1kHz para 900Hz) pode ter surgido devido a aproximações numéricas durante cálculos e a erros e flutuações nos valores dos componentes eletrônicos, como resistores e capacitores, utilizados no projeto do filtro.

A linearidade do conversor A/D garante que o processo de amostragem e conversão do sinal capturado não distorça o sinal capturado. A Figura 5.2 mostra a linearidade do conversor A/D, ou seja, o quanto a tensão convertida para valores digitais varia em relação a alterações na tensão analógica de entrada. Nota-se pelo gráfico que o conversor A/D varia linearmente com as alterações na tensão de entrada, com R^2 igual a $1,00 \pm 0,0053$. Apesar do TWR-S08MM128 possuir um recurso de pré-calibração do conversor A/D, os resultados mostram que esse processo pode ser opcional, poupando tempo e custo computacional.

A Tabela 5.1 mostra o ruído do sistema de captura para cada canal. Os ruídos mostrados na Tabela 5.1 indicam que o sistema configurado apenas com ganho inicial não é ideal para captura de sinais sEMG, com média $93,789\mu\text{V}_{\text{RMS}}$ para a análise 1 (De Luca, 1997). Ao ajustar o ganho da segunda etapa de amplificação e considerando o efeito do ganho, a análise 2 permite uma comparação direta com a análise 1. Os resultados mostram que o ruído é constante e intrínseco ao sistema, pois o ruído na saída não é alterado significativamente ao ajustar o ganho da segunda etapa de amplificação. Ao retirar o efeito de ganho e referir o ruído à entrada do

sistema (análise 3), o sistema adequada às condições para captura de sinais sEMG, com média de ruído de $2,025\mu\text{VRMS}$, comprovando a importância da segunda etapa de amplificação.

Os dois principais geradores de ruído são, muito provavelmente, o TWR-S08MM128 e o PC. Apesar de terem um papel fundamental na captura e processamento dos dados, os dois componentes possuem uma infinidade de osciladores e outras fontes de ruído que podem facilmente ser propagadas para o restante do circuito, aumentando significativamente o nível de ruído do sistema como um todo.

6.2 Captura de Sinais Eletromiográficos de Superfície

Os sinais sEMG capturados nas duas etapas de validação de captura de sinais sEMG, ou seja, com eletrodos comerciais e com a matriz de eletrodos, passaram por filtros digitais projetados em MATLAB®. Esse artifício foi utilizado com o intuito de eliminar componentes de frequências indesejáveis que ainda existiam no sinal capturado, mesmo com a presença dos filtros analógicos no sistema de captura.

Optou-se pela utilização de dois filtros digitais: o passa-faixa 10Hz – 1kHz e o filtro *notch* 60Hz. O filtro passa-faixa auxiliou principalmente na eliminação de níveis DC resultantes do grameador. Apesar do software de captura subtrair o valor DC aplicado no sinal durante a etapa de grameação, pequenas flutuações de tensão poderiam comprometer o valor médio do sinal. O filtro passa-alta com frequência de corte em 10Hz presente no filtro passa-faixa elimina qualquer indício nessa direção. O filtro *notch* 60Hz teve um papel de importância ainda maior. Apesar de completamente isolado da rede elétrica, o sistema foi frequentemente influenciado pela frequência de 60Hz, provavelmente por indução eletromagnética. Como o sistema de captura não possui filtro *notch* 60Hz analógico, a frequência de 60Hz se tornou muito evidente nos sinais capturados. Dessa forma, foi necessário aplicar o filtro *notch* 60Hz projetado em MATLAB®, que eliminou as componentes de 60Hz com sucesso, permitindo ótima visualização dos sinais capturados.

6.2.1 ELETRODOS COMERCIAIS

As Figuras 5.3, 5.4 e 5.5 mostram os sinais das três capturas de sinais sEMG utilizando eletrodos comerciais pós-processados no ambiente desenvolvido no MATLAB®. Esses sinais fornecem uma perspectiva interessante dos sinais capturados, mostrando componentes que se assemelham a MUAPs encontrados na literatura (Basmajian & De Luca, 1985; García *et al*, 2005; De Luca, 2006).

A Figura 5.3 mostra os resultados nos domínios do tempo e frequência da primeira captura. Durante essa captura, o sujeito iniciou a contração muscular após 1 segundo do início da captura, e interrompeu a contração após 4 segundos de captura, ou seja, durante os cinco segundos, houve apenas 3 segundos de contração, entre os segundos 1 e 4. Infere-se, portanto, que o sinal capturado está sincronizado com a contração muscular, pois existe silêncio muscular durante o primeiro segundo de captura, seguido pela presença de atividade mioelétrica até o quarto segundo de captura e, por fim, nota-se silêncio muscular após esse período, que perdurou até o final da captura, suportando a hipótese que os sinais visualizados são referentes à atividade mioelétrica proveniente dos músculos durante a contração muscular.

Na segunda captura (Figura 5.4), a contração foi iniciada após 1,5 segundo do início da captura. Nota-se uma oscilação localizada em aproximadamente 1 segundo, causada por um espasmo que o sujeito realizou involuntariamente previamente à contração sustentada.

Na terceira captura (Figura 5.5) pode-se perceber que a amplitude do sinal capturado é maior durante os primeiros instantes de captura. Contudo, após esse período, a amplitude cai indicando que o recrutamento de UMs foi estabilizado para sustentar a contração.

A composição espectral das três capturas suporta a hipótese que os sinais capturados são sinais de sEMG saudável, pois as principais componentes de frequência se encontram entre 10Hz e 500Hz, sendo bastante atenuado e até desprezível fora dessa faixa. Adicionalmente, a faixa de frequência entre 20Hz e 150Hz possui a maior parte da energia dominante do sinal, correspondendo a resultados de outros pesquisadores (Karlsson *et al*, 2008).

6.2.2 MATRIZ DE ELETRODOS

A Figura 5.6 engloba os três gráficos referentes à primeira captura. Os resultados das outras capturas podem ser visualizados no Apêndice A.

A Figura 5.6a mostra os cinco segundos de captura do sinal sEMG. É possível notar que a qualidade do sinal não é tão boa quanto o sinal EMG capturado com eletrodos comerciais. A área de captura dos elementos sensores da matriz de eletrodos é significativamente menor que a área de captura de eletrodos comerciais. Logo, espera-se que o sinal sEMG capturado com a matriz de eletrodos realmente tenha menor amplitude e menor relação sinal-ruído devido à atividade elétrica de menos UMs dentro da área de captura dos elementos sensores. O silêncio muscular durante o primeiro segundo de captura não é tão discernível quanto o presente durante as capturas de sinais sEMG com eletrodos comerciais, mostrando que, apesar de capturar sinais sEMG, o processo de cloretagem dos eletrodos realizado no Laboratório de Reabilitação Sensório-Motora do CEB/UNICAMP não foi adequado. Adicionalmente, apenas algumas capturas podem ser feitas com a matriz de eletrodos, pois o cloreto dissocia da prata em um período muito curto, suportando a hipótese de processo de cloretagem inadequado.

Pode-se notar o aumento acentuado da atividade elétrica sincronizada com o início da contração voluntária realizada pelo sujeito após o primeiro segundo de captura. A Figura 5.6a mostra ainda a região de 500ms explorada em maiores detalhes na Figura 5.6b.

A Figura 5.6b permite a visualização do sinal capturado em maior detalhe, entre 3 segundos e 3,5 segundos, permitindo a análise de algumas componentes, indicados pelas linhas tracejadas, que se assemelham a MUAPs encontrados na literatura (Basmajian & De Luca, 1985; García *et al*, 2005; De Luca, 2006). Adicionalmente, A Figura 5.6b mostra que algumas componentes similares são encontradas nos diferentes canais, também indicados pelas linhas tracejadas. Como os eletrodos foram posicionados longitudinalmente, ou seja, seguindo o sentido das fibras musculares, espera-se que essas componentes repetidas nos diferentes canais sejam MUAPs se propagando na direção das fibras, pois se fossem ruídos aleatórios, esses ruídos seriam aleatórios também entre os canais. A Figura 5.6c mostra as componentes de frequência dos cinco segundos de captura, e suporta a hipótese que o sinal capturado se

aproxima de um sinal sEMG saudável, pois as principais componentes de frequência se encontram entre 10Hz e 500Hz.

6.3 Separação de Sinais Conhecidos

Ao propor um sistema para decompor sinais que são compostos por fontes desconhecidas, o pesquisador deve mostrar que o processo de decomposição funciona corretamente. Uma abordagem muito utilizada por pesquisadores para provar a eficiência do sistema de decomposição envolve a construção matemática de sinais, ou misturas, compostos por componentes de fontes conhecidas, no caso MUAPs, decompor esses sinais simulados nas constituintes MUAPs e, por fim, analisar a qualidade dos sinais separados (De Luca *et al*, 2006). A maior parte dos pesquisadores valida o sistema de decomposição de sinais sEMG utilizando um ambiente controlado de simulação de sinais sEMG (Farina *et al*, 2004b; Farina *et al*, 2004c; Gazzoni *et al*, 2004; Holobar e Zazula, 2004; Farina *et al*, 2008). Isso é alcançado através de modelos que simulam a geração e propagação de sinais sEMG, considerando as várias características não-lineares dos tecidos subcutâneos, que influenciam no efeito volume condutor e, conseqüentemente, nas características dos sinais sEMG simulados. Da mesma forma, esses modelos permitem a simulação de sinais sEMG considerando diferentes geometrias de eletrodos, o que também influencia nas características dos sinais gerados (Farina & Rainoldi, 1999; Farina & Merletti, 2001; Lowery *et al*, 2002; Farina *et al*, 2004a; Lowery *et al*, 2004; Mesin, 2008). A implementação de simuladores de sinais sEMG engloba uma linha de pesquisa extensa e complexa. Os modelos de simulação de sinais sEMG citados são de difícil aquisição, lembrando que não são comercializados e que têm uso restrito à área acadêmica. Logo, poucos grupos de pesquisa detêm o uso de tais modelos.

Apesar de utilizarem modelos de geração de sinais sEMG para validar o processo de decomposição de sinais sEMG, nenhum trabalho valida quantitativamente essa separação comparando os sinais originais com os sinais separados. LeFever e De Luca (LeFever & De Luca, 1982) utilizaram técnicas de *template matching* e análise visual da morfologia de MUAPs na validação dos sinais sEMG decompostos. McGill e colaboradores (McGill *et al*, 1985) validaram a decomposição de sinais sEMG analisando os limites gaussianos da variação da taxa de disparo

de UMs. Holobar e e Zazula (Holobar & Zazula, 2004) validaram a separação de sinais simulados utilizando um índice que considera a morfologia e a taxa de disparo de MUAPs. Nakamura e colaboradores (Nakamura *et al*, 2004) validaram a separação de sinais sEMG analisando a independência estatística através da análise da curtose de cada componente estimada via FastICA. Farina e colaboradores (Farina *et al*, 2004b) validaram a decomposição de sinais sEMG simulados comparando a relação sinal ruído entre os sinais originais e os sinais estimados. García e colaboradores (García *et al*, 2005) validaram a separação de sinais sEMG reais utilizando um índice que considera a morfologia de MUAPs e através da análise dos limites gaussianos da variação da taxa de disparo de UMs. O presente trabalho propõe quantificar a separação do sinal EMG por meio da SIR, propondo uma nova abordagem na validação de sistemas de decomposição de sinais EMG. Desta forma, torna-se possível quantificar a decomposição de sinais EMG, mesmo em modelos de simulação através da SIR entre os MUAPs simulados e os MUAPs separados.

Com o intuito de superar a carência de modelos de simulação de sinais sEMG, optou-se por capturar e separar sinais conhecidos que foram misturados previamente à captura. Desta forma, garante-se um ambiente controlado para a validação de ambos os sistemas, de captura e de separação de fontes, tornando possível a comparação entre as fontes originais, as misturas dessas fontes, e as fontes estimadas. Adicionalmente, com o conhecimento das fontes originais, foi possível utilizar a SIR para analisar os resultados.

As Figuras 5.7 a 5.12 mostram os resultados do processo de mistura, captura e separação de seis testes com sinais conhecidos. A configuração dos sinais misturados em cada teste pode ser visto na Tabela 4.1. Lembrando que foram realizadas cinco capturas em cada teste.

A Figura 5.7 mostra o resultado da separação dos sinais capturados durante o primeiro teste, que envolveu a mistura das fontes originais: senóide de 500Hz, ruído branco e a *Waveform*.

A SIR mostrada na Figura 5.7a demonstra que os três sinais capturados são misturas diferentes dos mesmos sinais, cumprindo um dos requisitos para separação de fontes, ou seja, o número de observações deve ser maior ou igual ao número de fontes. Nesse caso, tem-se três misturas de três fontes originais.

A Figura 5.7b mostra o resultado da separação de fontes para a primeira captura, ou seja, valor da SIR entre as fontes originais e as fontes estimadas referente à primeira captura do primeiro teste. Nota-se, em decorrência da separação de fontes, que em cada um dos resultados mostrados no gráfico (Resultado A, Resultado B e Resultado C), duas fontes originais foram atenuadas e uma fonte foi amplificada. Adicionalmente, cada resultado amplificou uma fonte diferente, atenuando as duas outras fontes. Em outras palavras: o Resultado A separou o ruído branco; o Resultado B separou a senóide de 500Hz; o Resultado C separou a *Waveform*.

A fim de confirmar esse resultado, a correlação entre o resultado e a respectiva fonte original foi calculada. Assim, apesar da SIR sugerir que o Resultado A separou o ruído branco, a correlação entre o Resultado A e a fonte do ruído branco original mostra que existe uma certa diferença entre os dois sinais. O mesmo não ocorreu para os Resultados B e C, onde a correlação entre eles e a senóide 500Hz e a *Waveform*, respectivamente, foi alta. A correlação entre o ruído branco estimado e o ruído branco original foi baixa muito provavelmente devido à existência de outras fontes de ruído no sistema. A ICA tem a limitação de não conseguir separar fontes gaussianas. Caso exista mais de uma fonte gaussiana entre fontes não-gaussianas, as fontes não-gaussianas são separadas, porém as gaussianas não. Como ruídos tendem a ter distribuição gaussiana, caso exista mais de uma fonte de ruído no sistema, a ICA não conseguirá separá-los.

A Figura 5.7c agrega a SIR entre as fontes originais e as fontes estimadas das cinco capturas do primeiro teste. É importante ressaltar que a Figura 5.7c mostra somente a SIR das fontes estimadas, ou seja, as duas fontes sobressalentes que foram atenuadas pelo processo de separação foram omitidas com o intuito de facilitar a visualização. Desta forma, nota-se que os resultados mostrados na Figura 5.7b são mostrados também na Figura 5.7c no espaço “Captura 1”. A Figura 5.7c mostra, portanto, que o sistema separou as fontes nas cinco capturas do primeiro teste.

A Figura 5.7d confirma a idéia que o sistema conseguiu separar as fontes nas cinco capturas do primeiro teste através do cálculo da média da correlação entre fontes originais e fontes estimadas. Nota-se que a correlação manteve-se alta para as estimativas da senóide 500Hz e para a *Waveform*, comprovando que essas duas fontes foram corretamente separadas.

A Figura 5.7e mostra a SIR e a correlação entre as fontes originais utilizadas no Teste 1, e permite inferir se uma fonte é correlacionada com outra ou se são semelhantes entre si. É possível notar que a *Waveform* não é correlacionada, tampouco semelhante, com nenhuma das outras duas fontes. Contudo, apesar da SIR entre a senóide 500Hz e o ruído branco ser baixo, eles possuem uma correlação de quase 85%. É importante notar que a situação onde duas fontes são correlacionadas apenas dificulta o processo de separação e, mesmo assim, o sistema foi capaz de separar essas duas fontes. A correlação entre esses dois sinais é elevada pois o ruído branco tem a frequência da senóide de 500Hz embutida no seu espectro de frequência. Outra hipótese menos provável é a ocorrência de *crosstalk* entre os canais de captura, ou seja, um sinal pode ter influenciado o outro no momento da captura. O circuito integrado utilizado no PGA desse projeto possui três canais. Eventualmente, um canal pode influenciar o outro, de forma que algumas componentes de frequência de um canal podem aparecer em outro, e vice-versa. Isso pode ser evitado se cada circuito de PGA tiver somente um canal, de forma que um canal de captura não sofra influência de nenhum outro.

As Figuras 5.8, 5.9, 5.10, 5.11 e 5.12 mostram o mesmo conjunto de gráficos para os testes 2, 3, 4, 5 e 6, respectivamente. Os resultados mostram que os sinais foram separados em todas as capturas de todos os testes, sendo que a correlação entre o ruído separado e o ruído estimado sempre foi baixa, suportando a hipótese da presença de outra(s) fonte(s) de ruído.

A Figura 5.8 mostra o resultado da separação dos sinais capturados durante o segundo teste, que envolveu a mistura das fontes originais: senóide de 500Hz, ruído branco e o *Burst*. Os sinais foram separados corretamente, mas pode-se notar, nas capturas 2 e 4, que o *Burst* apresentou uma SIR muito maior que nas capturas 1, 3 e 5 (Figura 5.8c). Porém, isso não influenciou na separação das outras fontes, tampouco na correlação entre as fontes originais e as fontes estimadas (Figura 5.8d). A Figura 5.8e mostra que a correlação entre as fontes originais senóide 500Hz e ruído branco também foi alta.

A Figura 5.9 mostra o resultado da separação dos sinais capturados durante o terceiro teste, que envolveu a mistura das fontes originais: senóide de 500Hz, senóide de 40Hz e ruído branco. Apesar de efetuar a separação das fontes nas cinco capturas, a SIR entre as fontes originais e as fontes estimadas oscilou muito (Figura 5.9c). Contudo, a correlação foi alta entre as

fontes originais e as fontes estimadas para as senóides de 40Hz e de 500Hz, mostrando que a separação foi bem sucedida (Figura 5.9d). Conforme esperado, as fontes originais senóide 40Hz e 500Hz apresentaram uma correlação elevada com ruído branco original, contudo isso não afetou a separação dos sinais (Figura 5.9e).

A Figura 5.10 mostra o resultado da separação dos sinais capturados durante o quarto teste, que envolveu a mistura das fontes originais: senóide de 500Hz, ruído branco e *User1*. A SIR entre a fonte original e a fonte estimada do *User1* foi menor que o encontrado em outras fontes (Figura 5.10c), contudo a correlação entre a fonte original e a estimada manteve-se elevada, confirmando que a separação foi bem sucedida (Figura 5.10d). Nenhuma fonte apresentou correlação significativa entre si (Figura 5.10e).

A Figura 5.11 mostra o resultado da separação dos sinais capturados durante o quinto teste, que envolveu a mistura das fontes originais: senóide de 500Hz, ruído branco e *User2*. A SIR para o *User2* oscilou em todas as capturas (Figura 5.11c), contudo a correlação entre a fonte original e a estimada manteve-se elevada, confirmando que a separação foi bem sucedida (Figura 5.10d). Nenhuma fonte apresentou correlação significativa entre si (Figura 5.11e).

A Figura 5.12 mostra o resultado da separação dos sinais capturados durante o sexto teste, que envolveu a mistura das fontes originais: senóide de 500Hz, ruído branco e *User3*. A SIR para o *User3* oscilou em todas as capturas, e foi muito baixo para as capturas 1 e 4 (Figura 5.11c). Contudo, as correlações entre as fontes originais e as estimadas mantiveram-se elevadas, confirmando que a separação foi bem sucedida (Figura 5.10d). Nenhuma fonte apresentou correlação significativa entre si (Figura 5.11e).

6.4 Separação de Sinais Eletromiográficos

Após mostrar que o sistema captura sinais sEMG e que o sistema é capaz de separar sinais conhecidos, podemos considerar uma situação hipotética onde os sinais EMG mostrados na Figura 4.18 foram capturados utilizando o sistema de captura apresentado nesse trabalho, resultando em uma mistura linear os sinais EMG. Esse cenário é apenas uma simplificação do problema fisiológico real, e gera um ambiente controlado para separação de fontes, sendo que o

número de fontes, ou MUAPs, é, nesse caso, conhecido e controlado. Em sinais sEMG reais, esse controle não existe, e é muito difícil limitar a quantidade de UMs recrutadas durante uma contração. Isso prejudica o processo de separação de fontes. Apesar de misturar linearmente sinais EMG intramusculares provenientes de diferentes sujeitos, essa etapa de validação tem como objetivo principal uma análise inicial do comportamento da ICA na separação de sinais com as características de sinais EMG. Adicionalmente, criou-se um cenário crítico, que simula a captura de um sinal sEMG composto por MUAPs provenientes de diferentes UMs, que inclui um sinal saudável, um miopático, um neuropático e um ruído branco. Mesmo em tal cenário, o ICA conseguiu separar os sinais de forma confiável.

Gerou-se cinco misturas diferentes envolvendo os sinais da Figura 4.18. Cada mistura representa um teste. Desta forma, cinco testes foram realizados, e as Figuras 5.15 a 5.19 mostram os resultados da separação dos sinais EMG para os testes 1, 2, 3, 4 e 5, respectivamente. Em todos os testes, um resultado acentuou uma fonte e atenuou as outras. Por exemplo, a Figura 5.15 mostra a SIR entre as fontes originais e as estimadas. O Resultado A separou o sinal EMG com Neuropatia, o Resultado B separou o sinal EMG Saudável, o Resultado C separou o sinal EMG com Miopatia, e o Resultado D separou o ruído branco. O mesmo ocorreu para todos os testes.

A SIR foi relativamente baixa para as fontes estimadas Saudável e Miopatia em todos os testes, porém as correlações com as respectivas fontes originais foram sempre altas. Nesses testes, é interessante notar que a correlação entre o ruído branco original e o estimado é alta, pois não existe nenhuma outra fonte de ruído, suportando a hipótese da presença de outras fontes de ruídos nos testes de Separação de Sinais Conhecidos.

6.5 Considerações Gerais e Trabalhos Futuros

A decomposição de sinais EMG em seus constituintes MUAPs engloba uma linha de pesquisa extensa e necessita do estudo e desenvolvimento de vários módulos.

Inicialmente, é necessário desenvolver um transdutor de força capaz de medir, em tempo real, a intensidade de contração do sujeito. Desta forma, pode-se relacionar a intensidade de

força de contração com a contração máxima voluntária (*e.g.*, 20%, 30% da contração máxima voluntária). Com isso, tem-se o controle da intensidade de contração e, indiretamente, o número de UMs recrutadas para sustentar a contração. Claro que o controle exato do número de UMs recrutadas durante uma contração voluntária é praticamente impossível, mas a presença de uma mesa de força tem se mostrado extremamente útil nesse processo (LeFever & De Luca, 1982; Farina *et al.*, 2004b; García *et al.*, 2005).

O eletrodo, ou a matriz de eletrodos, é a primeira etapa no processo de captura de sinais sEMG. Logo, ruídos e artefatos gerados nessa etapa são propagados para o restante do sistema. Além disso, deve-se garantir uma área de captura menor que as encontradas em eletrodos comerciais. Com isso, é necessário o desenvolvimento de matrizes de eletrodos com dimensões reduzidas e confiáveis. É interessante dar preferência a eletrodos de Ag-AgCl, pois são os mais indicados para captura de biopotenciais.

Os resultados mostram que os sinais sEMG capturados neste trabalho com eletrodos comerciais são limpos e bons, mostrando que o sistema é apto a capturar sinais sEMG de qualidade. Contudo, o mesmo não foi visto com sinais sEMG capturados pela matriz de eletrodos, com resultados bem ruidosos. Portanto, é necessário desenvolver uma matriz de eletrodos com uma interface Ag-AgCl mais estável. Adicionalmente, deve-se ter o maior número possível de eletrodos, uma vez que as UMs são organizadas de tal modo que as fibras musculares se entrelaçam. Logo, uma pequena área na superfície da pele pode culminar na captura da atividade elétrica de inúmeras UMs. Ainda, o processo de BSS exige que o número de misturas seja maior ou igual ao número de fontes a serem separadas e que o músculo possui uma quantidade enorme de UMs.

Esse tópico implica também no desenvolvimento de um sistema de captura que suporte uma quantidade elevada de canais. Logo, deve-se construir um sistema de captura dedicado, com quantidade de canais suficiente para suportar matrizes de eletrodos com muitos pontos de captura. Adicionalmente, seria interessante desenvolver um sistema de captura dedicado, sem a utilização do TWR-S08MM128 e também garantir que o sistema capture sinais sEMG desconectado do PC, como um *data logger*. Isso auxiliaria a garantir níveis de ruído do sistema inferiores ao apresentado nesse projeto.

Além dos filtros digitais utilizados nesse trabalho, outros pré-processamentos podem ser estudados a fim de auxiliar no processo de decomposição dos sinais EMG. Em particular, dois métodos podem ser considerados. O primeiro, chamado de filtro de zona morta (*dead zone filter*) visa diminuir o nível de ruído do sinal capturado, bem como eliminar pequenos potenciais de ação de UMs que somente tornariam a decomposição mais difícil (García *et al*, 2005). O segundo processamento é conhecido como filtro passa-baixa diferencial (*low-pass differential filter*), que desloca a componente média de frequência para frequências maiores, eliminando componentes lentas e tornando os PAs mais visíveis (Usui & Amidror, 1982; McGill *et al*, 1985).

A fim de tornar o processo de validação do sistema de separação de sinais EMG proposto mais robusto, é interessante utilizar simuladores de sinais sEMG. Tais modelos são extremamente complexos, e levam em consideração o tamanho de fibras, velocidade de condução, não-linearidade do meio, composição do tecido subcutâneo, geometria das fibras e dos eletrodos. Contudo, esses simuladores não são de fácil acesso, e seu desenvolvimento é demorado.

Por fim, existe uma gama enorme de métodos de BSS que podem ser estudados para decomposição de sinais EMG. A investigação desses métodos é crucial para atingir resultados relevantes. Seria interessante a decomposição de sinais EMG por técnicas de BSS de segunda ordem. Tais técnicas consideram informações temporais dos sinais, o que pode ser relevante na separação. Apesar do método JADE ser considerado um método de separação baseado em independência estatística, ele é visto como um método mais robusto e pode ser utilizado no lugar da FastICA. Uma última técnica que seria interessante investigar é a SCA, que considera que as fontes assumem valor nulo a maior parte do tempo e, principalmente, pode ser utilizada em um sistema sub-dimensionado, ou seja, com número de observações menor que o número de fontes. Isso é de grande valia na eletromiografia de superfície, tendo em vista que é difícil garantir que a quantidade de UMs recrutadas durante uma contração fique limitada à quantidade de canais de captura de sinais eletromiográficos.

Capítulo 7

Conclusão

ESTE projeto visou desenvolver um sistema capaz de capturar sinais eletromiográficos de superfície e analisar a viabilidade da separação de sinais eletromiográficos intramusculares misturados linearmente, utilizando análise de componentes independentes.

O sistema desenvolvido capturou vários sinais eletromiográficos de superfícies fidedignos utilizando uma matriz de eletrodos desenvolvida no Laboratório de Reabilitação Sensório-Motora do CEB/UNICAMP, gerando um ambiente propício para a utilização da análise de componentes independentes na decomposição de sinais eletromiográficos em suas constituintes componentes. Adicionalmente, realizou-se uma análise inicial da viabilidade da utilização da análise de componentes independentes na decomposição de sinais com as características dos sinais eletromiográficos através de um cenário controlado ao misturar linearmente sinais eletromiográficos intramusculares provenientes de um banco de dados.

Referências Bibliográficas

- BASMAJIAN, J. V. & DE LUCA, C. J. (1985). *Muscles Alive – Their Functions Revealed by Electromyography*. 5th Edition, Williams & Wilkins
- CARDOSO, J. & SOULOUMIAC, A. (1993). *Blind Beamforming for Non Gaussian Signals*. IEEE Proceedings-F Vol. 140, n. 6, pp. 362–370
- COBBOLD, R. S. C. (1974). *Transducer for Biomedical Measurements*. John Wiley & Sons
- COVER T. M. & THOMAS J. A. (1991). *Chapter 2: Entropy, Relative Entropy and Mutual Information*, in Elements of Information Theory. John Wiley & Sons
- DE LUCA, C. J. (1997). *The Use of Surface Electromyography in Biomechanics*. Journal of Applied Biomechanics, 13 (2), pp. 135–163
- DE LUCA C. J., ADAM A., WOTIZ R., GILMORE L. D. & NAWAB S. H. (2006). *Decomposition of Surface EMG Signals*. J. Neurophysiol 96, pp. 1646–1657
- DE LUCA, C. J. (2006). *Electromyography*, in Encyclopedia of Medical Devices and Instrumentation, 2nd Edition, Volume 3, Edited by John G. Webster, A John Wiley & Sons, pp. 98-109.
- DROST, G., BLOK, J. H., STEGEMAN, D. F., VAN DIJK, J. P., VAN ENGELEN, B. G. M. & ZWARTS, M. J. (2001). *Propagation Disturbance of Motor Unit Action Potentials During Transient Paresis in Generalized Myotonia*. Brain 124, pp. 352–360.
- DUARTE, L. T. (2006). *Um Estudo sobre Separação Cega de Fontes e Contribuições ao Caso de Misturas Não-lineares*. Dissertação de Mestrado, Departamento de Comunicações, Faculdade de Engenharia Elétrica e de Computação, Unicamp, Campinas, SP, Brasil.

- FARINA, D. & RAINOLDI, A. (1999). *Compensation of the Effect of Sub-cutaneous Tissue Layers on Surface EMG: a Simulation Study*. *Medical Engineering & Physics* 21, pp. 487–496
- FARINA, D. & MERLETTI R. (2001). *A Novel Approach for Precise Simulation of the EMG Signal Detected by Surface Electrodes*. *IEEE Transactions on Biomedical Engineering*, Vol. BME–48, No. 6, pp. 637–646
- FARINA D., COLOMBO R., MERLETTI R. & OLSEN, H. B. (2001). *Evaluation of intra-muscular EMG signal decomposition algorithms*. *J. Electromyography and Kinesiology*, vol. 11, pp. 175–187
- FARINA, D., MESIN, L., MARTINA, S. & MERLETTI, R. (2004a). *A Surface EMG Generation Model With Multilayer Cylindrical Description of the Volume Conductor*. *IEEE Transactions on Biomedical Engineering*, Vol. BME–51, No. 3, pp. 415–426
- FARINA, D., FÉVOTTE, C., DONCARLI, C. & MERLETTI, R. (2004b). *Blind Separation of Linear Instantaneous Mixtures of Nonstationary Surface Myoelectric Signals*. *IEEE Transactions on Biomedical Engineering*, Vol. BME–51, No. 9, pp. 1555–1567
- FARINA, D., MERLETTI, R. & ENOKA, R. M. (2004c). *The Extraction of Neural Strategies from the Surface EMG*. *J Appl Physiol*, 96, pp. 1486–1495
- FARINA, D., LUCAS, M. & DONCARLI, C. (2008). *Optimized Wavelets for Blind Separation of Nonstationary Surface Myoelectric Signals*. *IEEE Transactions on Biomedical Engineering*, Vol. BME–55, No. 1, pp. 78–86
- FELICI, F. & SBRICCOLI, P. (2006). *Muscle, Skeletal*, in *Wiley Encyclopedia of Biomedical Engineering*, Edited by Metin Akay, A John Wiley & Sons, pp. 2438 – 2445
- FREESCALE (2010a). Disponível em http://cache.freescale.com/files/32bit/doc/quick_ref_guide/S08MM128QSG.pdf, acessado em 23 de fevereiro de 2012
- FREESCALE (2010b). Disponível em http://cache.freescale.com/files/32bit/doc/user_guide/TWR-S08MMUG.pdf, acessado em 23 de fevereiro de 2012

- FREESCALE (2010c). Disponível em http://www.arrow.nac.com/services-tools/design-tools/arrowedge/parts/2010-2/pdf/09_factsheet_MC9S08MM.pdf, acessado em 23 de fevereiro de 2012
- GARCÍA, A. G., OKUNO, R. & AKAZAWA, K. (2005). *A Decomposition Algorithm for Surface Electrode-Array Electromyogram*. IEEE Engineering in Medicine and Biology Magazine, July/August 2005, Technological Developments in Japan, pp. 63–72
- GAZZONI, M., FARINA, D. & MERLETTI, R. (2004). *A New Method for the Extraction and Classification of Single Motor Unit Action Potentials from Surface EMG Signals*. Journal of Neuroscience Methods, Vol. 136, pp. 165–177
- GRAUPE, D., & CLINE, W. K. (1975). *Functional Separation of EMG Signals via ARMA Identification Methods for Prosthesis Control Purposes*. IEEE Transactions on Systems, Man, and Cybernetics, Vol. SMC-5, no. 2, pp. 252–259
- HIRAIWA A., SHIMOHARA K. & TOKUNAGA Y. (1989). *EMG Pattern Analysis and Classification by Neural Network*. IEEE International Conference on Systems, Man and Cybernetics, pp. 1113–1115
- HOLOBAR, A. & ZAZULA, D. (2004). *Correlation-based Decomposition of Surface Electromyograms at Low Contraction Forces*. Medical & Biological Engineering & Computing, vol. 42, pp. 487–495
- HYVÄRINEN, A., & OJA, E. (1997). *A Fast Fixed-point Algorithm for Independent Component Analysis*. Neural Computation, 9(7), pp. 1483–1492
- HYVÄRINEN, A., & OJA, E. (2000). *Independent Component Analysis: Algorithms and Applications*. Neural Networks, 13 (4-5), 411-430
- HYVÄRINEN, A., KARHUNEN, J. & OJA, E. (2001). *Independent Component Analysis*. John Wiley & Sons
- KARLSSON, J. S., ROELEVELD, K., GRÖNLUND, C., HOLTERMANN, A. & ÖSTLUND, N. (2008). *Signal processing of the surface electromyogram to gain insight into neuromuscular physiology*. Philosophical Transactions of the Royal Society A, Mathematical, Physical & Engineering Sciences, Vol. 367, pp. 337–356

- KELLY, M. F., PARKER, P. A. & SCOTT, R. N. (1990). *Myoelectric Signal Analysis Using Neural Networks*. IEEE Engineering in Medicine and Biology Magazine, pp. 61–64
- KLEINE, B. U., BLOK, J. H., OOSTENVELD, R., PRAAMSTRA, P. & STEGEMAN, D. F. (2000). *Magnetic Stimulation-induced Modulations of Motor Unit Firings Extracted from Multi-channel Surface EMG*. John Wiley & Sons, Inc. Muscle Nerve, 23, pp. 1005–1015
- KLEINE, B. U., VAN DIJK, J. P. , LAPATKI, B. G., ZWARTS, M. J. & STEGEMAN, D. F. (2007). *Using Two-dimensional Spatial Information in Decomposition of Surface EMG Signals*. J. Electromyography and Kinesiology, vol. 17, pp. 535–548
- LEFEVER, R & DE LUCA C. J. (1982). *A Procedure for Decomposing the Myoelectric Signal Into its Constituent Action Potentials – Part I – Technique Theory and Implementation*. IEEE Transactions on Biomedical Engineering, Vol. 29, No. 3, pp. 149–157
- LOEB, G. E. & GHEZ, C. (2000). *The Motor Unit and Muscle Action*, in Principles of Neural Science, 4th Edition, Editors Eric R. Kandel, James H. Schwartz, Thomas M. Jessell, The McGraw-Hill Companies, Chapter 34, pp. 675–696
- LOWERY, M. M., STOYKOV, N. S., TAFLOVE, A. & KUIKEN T. A. (2002). *A Multiple-Layer Finite-Element Model of the Surface EMG Signal*. IEEE Transactions on Biomedical Engineering, Vol. BME-49, No. 5, pp. 446–454
- LOWERY, M. M., STOYKOV, N. S., DEWALD, J. P. A. & KUIKEN T. A. (2004). *Volume Conduction in an Anatomically Based Surface EMG Model*. IEEE Transactions on Biomedical Engineering, Vol. BME-51, No. 12, pp. 2138–2147
- MCGILL, K. C., CUMMINS, K. L. & DORFMAN, L. J. (1985). *Automatic Decomposition of the Clinical Electromyogram*. IEEE Transactions on Biomedical Engineering, Vol. BME-32, No. 7, pp. 470–477
- MERLETTI, R., HOLOBAR, A. & FARINA, D. (2008). *Analysis of Motor Units with High-density Surface Electromyography*. Journal of Electromyography and Kinesiology, 18, pp. 879–890

- MESIN, L. (2008). *Simulation of Surface EMG Signals for a Multilayer Volume Conductor With a Superficial Bone or Blood Vessel*. IEEE Transactions on Biomedical Engineering, Vol. BME-55, No. 6, pp. 1647–1657
- NAGEL, J. H. (2000). *Biopotential Amplifiers*, in The Biomedical Engineering Handbook. 2nd Edition, Editor Joseph D. Bronzino, CRC Press LLC
- NAKAMURA, H., YOSHIDA, M., KOTANI, M., AKAZAWA, K. & MORITANI, T. (2004a). *The Application of Independent Component Analysis to the Multi-channel Surface Electromyographic Signals for Separation of Motor Unit Action Potential Trains: Part I–Measuring Techniques*. J Electromyogr Kinesiol 14, pp. 423–432
- NAKAMURA, H., YOSHIDA, M., KOTANI, M., AKAZAWA, K. & MORITANI, T. (2004a). *The Application of Independent Component Analysis to the Multi-channel Surface Electromyographic Signals for Separation of Motor Unit Action Potential Trains: Part II–Modelling Interpretation*. J Electromyogr Kinesiol 14, pp. 433–441
- NATIONAL SEMICONDUCTOR (1994). LM1973 μ Pot™ 3-Channel 76dB Audio Attenuator with Mute. Datasheet disponível em <http://www.ti.com/lit/ds/symlink/lm1973.pdf>
- PHYSIOBANK (2011). Disponível em <http://www.physionet.org/physiobank/database/emgdb/>, acessado em 07 de outubro de 2011
- POZZO, M., FARINA, D. & MERLETTI, R. (2004a). *Electromyography: Detection, Processing and Applications*, in Biomedical Technology and Devices Handbook. Edited by James Moore and George Zouridakis, CRC Press
- POZZO, M., BOTTIN, A., FERRABONE, R. & MERLETTI, R. (2004b). *Sixty-four Channel Wearable Acquisition System for Long-term Surface Electromyogram Recording with Electrode Arrays*. Med. Biol. Eng. Comput., 42, pp. 455–466
- QUEVEDO, A. A. F. (1993). *Desenvolvimento de um Sistema de Análise Digital de Sinais EMG*. Dissertação de Mestrado, Faculdade de Engenharia Elétrica e de Computação, Unicamp, Campinas, SP, Brasil

- REAZ, M. B. I., HUSSAIN, M. S. & MOHD-YASIN, F. (2006). *Techniques of EMG Signal Analysis: Detection, Processing, Classification and Applications*. *Biological Procedures Online*, 8(1), pp. 11–35
- ROMANO, J. M. T., ATTUX, R. R. F., CAVALCANTE, C. C. & SUYAMA, R. (2011). *Unsupervised Signal Processing - Channel Equalization and Source Separation*. CRC Press
- SAMPAIO, A. C. (1998). *Eletromiógrafo de Doze Canais para Uso em Laboratório de Pesquisa*. Dissertação de Mestrado, Faculdade de Engenharia Elétrica e de Computação, Unicamp, Campinas, SP, Brasil
- SEMMLow, J. L. & YUAN, W. (2002). *Adaptive Modification of Disparity Vergence Components: An Independent Component Analysis Study*, *Investigative Ophthalmology & Visual Science*, Vol. 43, No. 7, pp. 2189–2195
- SUYAMA, R. (2007). *Proposta de Métodos de Separação Cega de Fontes para Misturas Convolutivas e Não-lineares*. Dissertação de Doutorado, Departamento de Comunicações, Faculdade de Engenharia Elétrica e de Computação, Unicamp, Campinas, SP, Brasil
- SCHOBEN, D., TORKKOLA, K., SMARAGDIS, P. (1999). *Evaluation of Blind Signal Separation Methods*. *Proceedings of the 1st International Workshop on Independent Components Analysis and Blind Source Separation, ICA'99*.
- STONE, J. V. (2004). *Independent Component Analysis – A Tutorial Introduction*. The MIT Press
- TALLGREN, P., VANHATALO, S., KAILA, K. & VOIPIO, J. (2005). *Evaluation of commercially available electrodes and gels for recording of slow EEG potentials*. *Clinical Neurophysiology*, 116, pp. 799–806
- TEXAS INSTRUMENTS (2005). *INA128, INA129 - Precision, Low Power Instrumentation Amplifiers*. Datasheet disponível em <http://www.ti.com/lit/ds/symlink/ina128.pdf>
- USUI, S. & AMIDROR, I. (1982). *Digital Low-Pass Differentiation for Biological Signal Processing*. *IEEE Transactions on Biomedical Engineering*, Vol. BME-29, No. 10, pp. 686–693

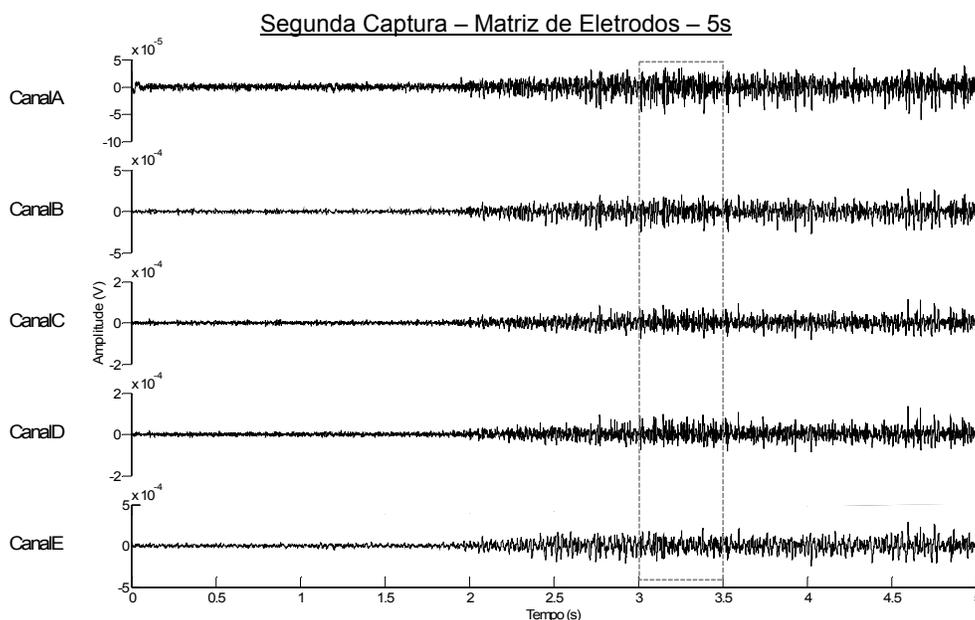
- WON, D. K. (2012). *Muscle & Peripheral Nervous System*. Notas de aula, Physiology – Human Physiology 1, Prof. Dr. Dean K. Won, Pasadena City College, Disponível em <http://faculty.pasadena.edu/dkwon/lectures.htm>, acessado em 19 de abril de 2012
- WOOD, S. M., JARRATT, J.A., BARKER, A.T. & BROWN B.H. (2001). *Surface Electromyography Using Electrode Arrays: a Study of Motor Neuron Disease*. John Wiley & Sons, Inc. *Muscle Nerve*, 24, pp. 223–230
- ZWARTS M.J. & STEGEMAN, D.F. (2003). *Multichannel Surface EMG: Basic Aspects and Clinical Utility*. *Muscle & Nerve*, 28, pp. 1–17.

Apêndice A

Continuação dos Resultados

Este apêndice apresenta resultados atingidos com esse trabalho que, por questão de praticidade, resolveu-se omitir do texto principal.

As Figuras A1 a A5 mostram, cada uma, os três gráficos referentes à segunda, terceira, quarta, quinta e sexta captura de sinais sEMG com a matriz de eletrodos, respectivamente. O primeiro gráfico de cada Figura mostra os cinco segundos de captura do sinal sEMG. O segundo permite a visualização do sinal capturado em maior detalhe, capturado entre 3 segundos e 3,5 segundos. O terceiro mostra as componentes de frequência dos cinco segundos de captura.



a)

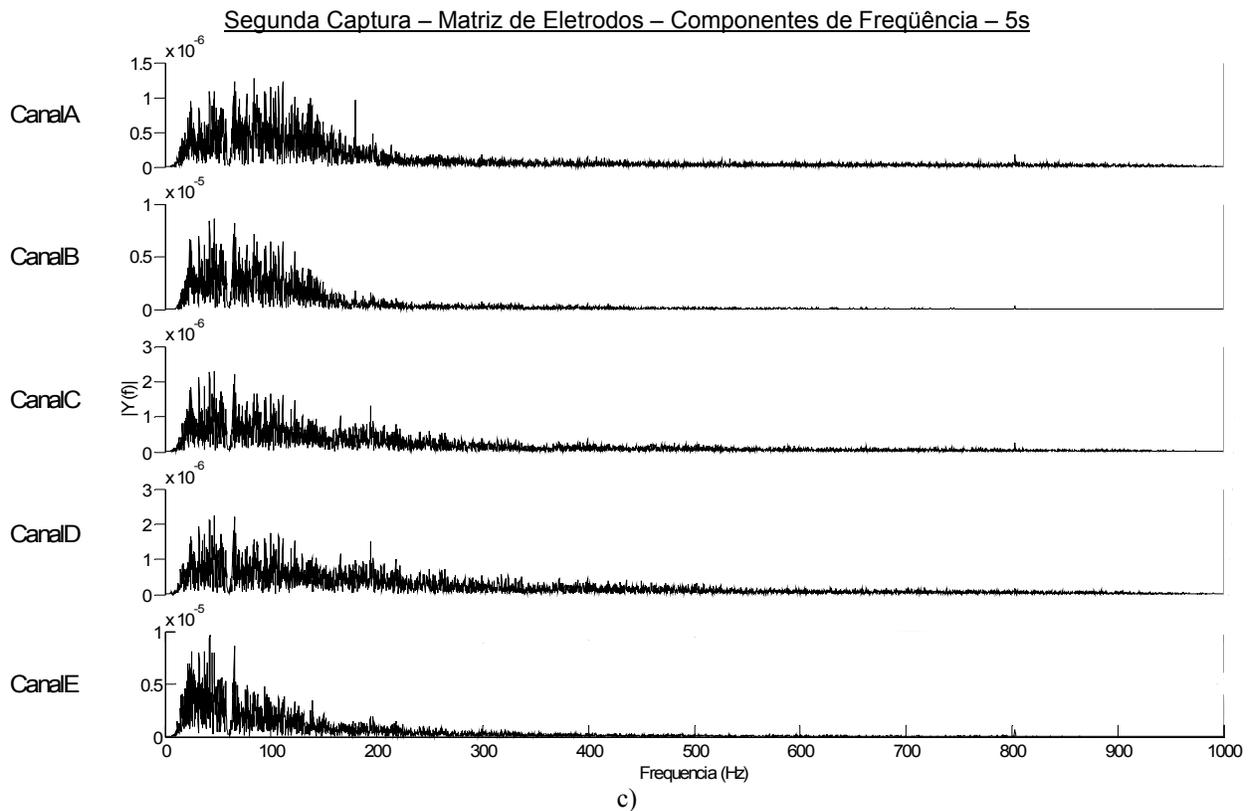
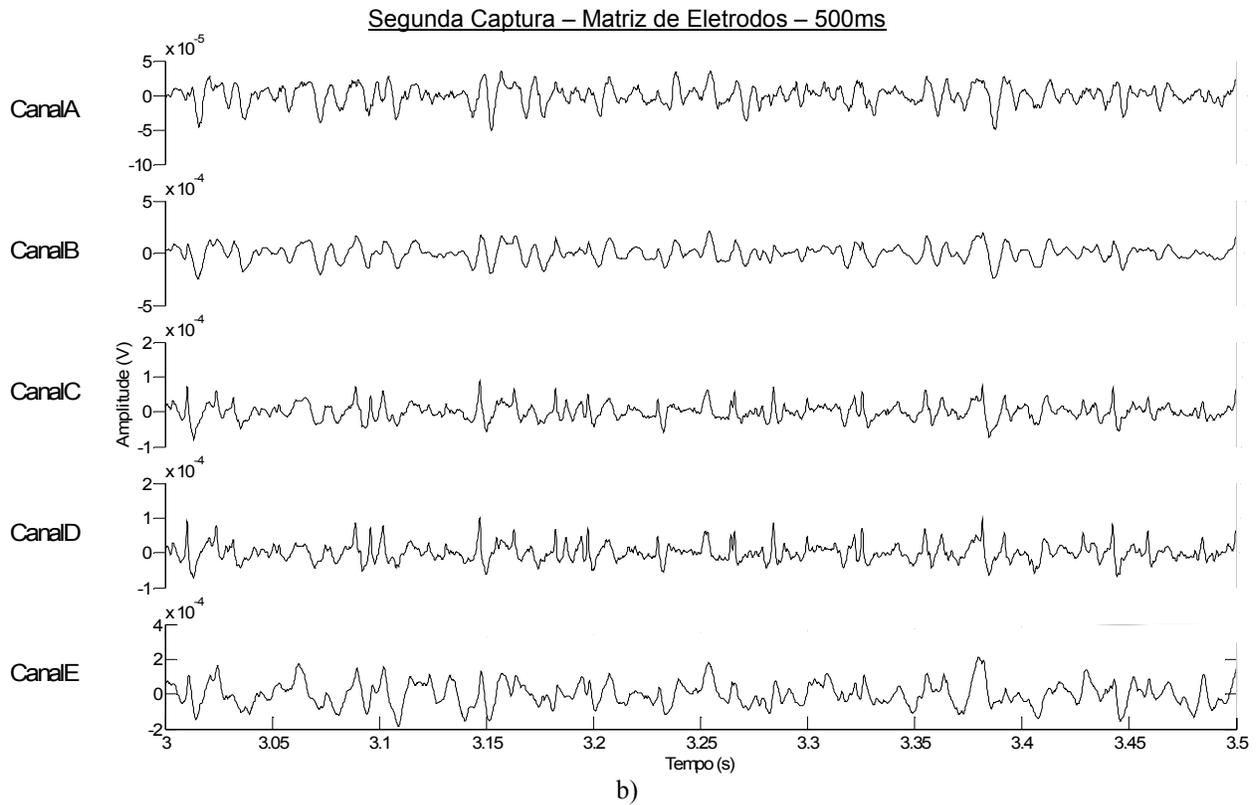
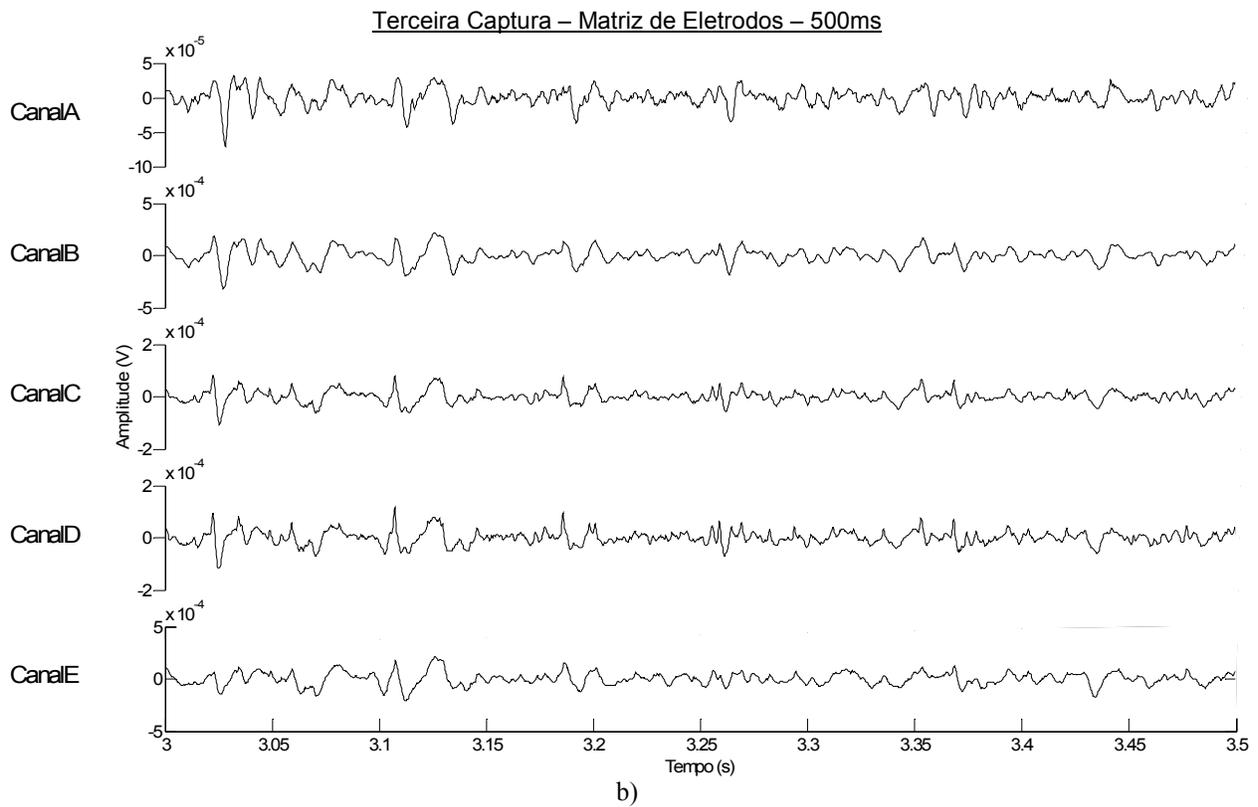
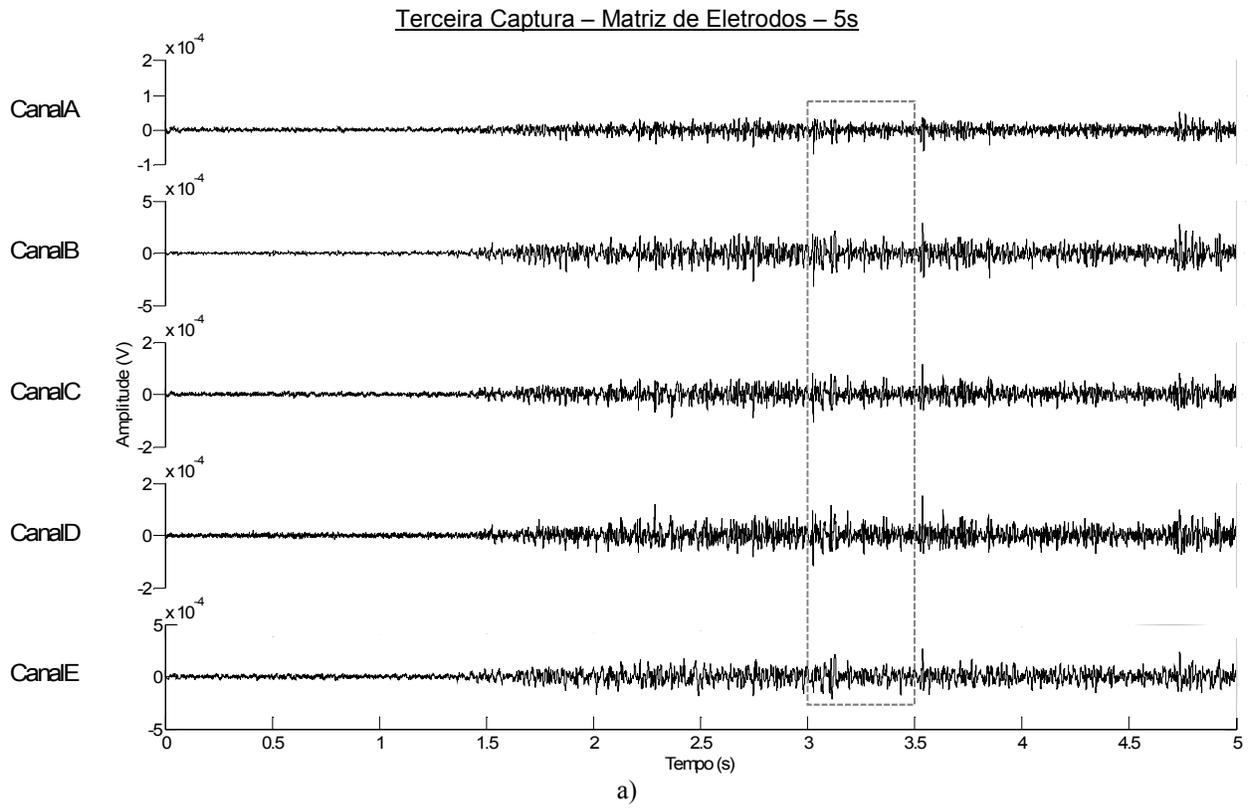


Figura A1 – Segunda captura de sinal sEMG com a matriz de eletrodos: a) 5s do sinal sEMG na segunda captura. b) Detalhe de 500ms sinal sEMG na segunda captura. c) Análise espectral dos 5s do sinal sEMG na segunda captura.



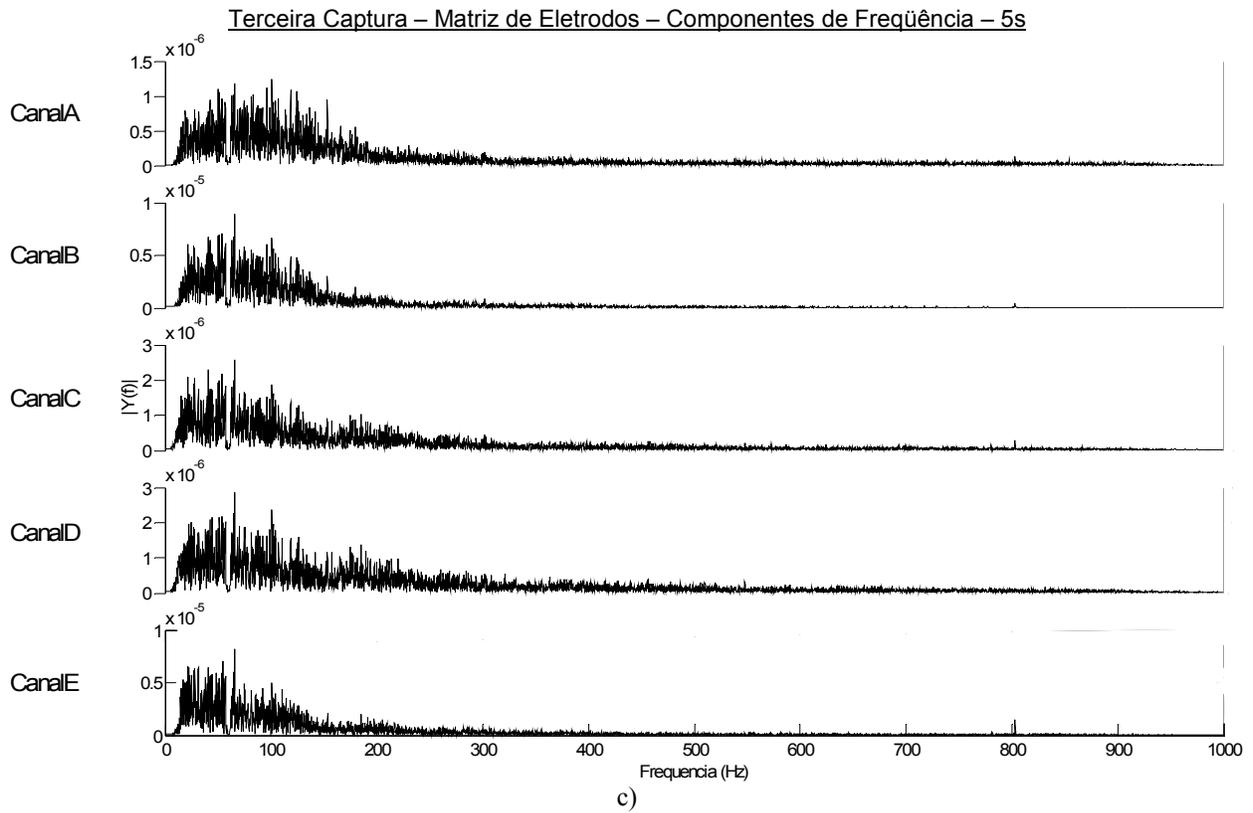
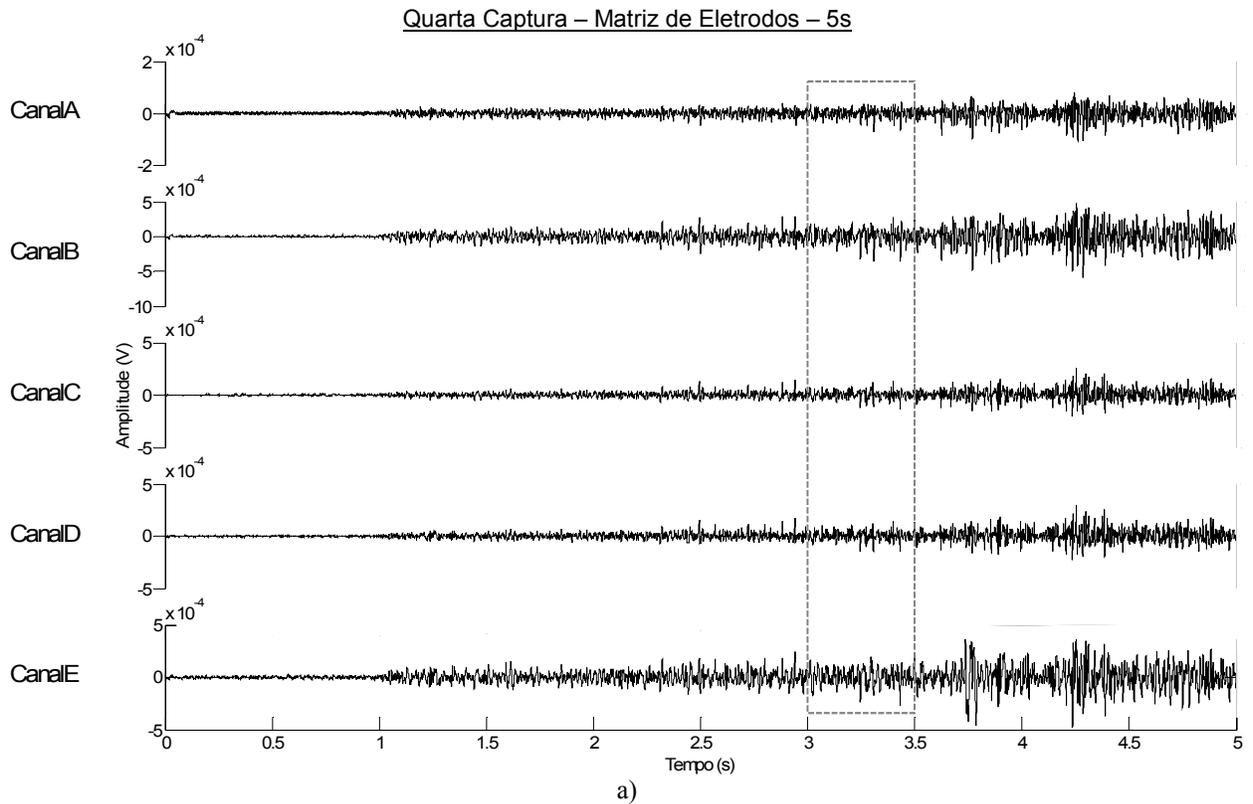


Figura A2 - Terceira captura de sinal sEMG com a matriz de eletrodos: a) 5s do sinal sEMG na terceira captura. b) Detalhe de 500ms sinal sEMG na terceira captura. c) Análise espectral dos 5s do sinal sEMG na terceira captura.



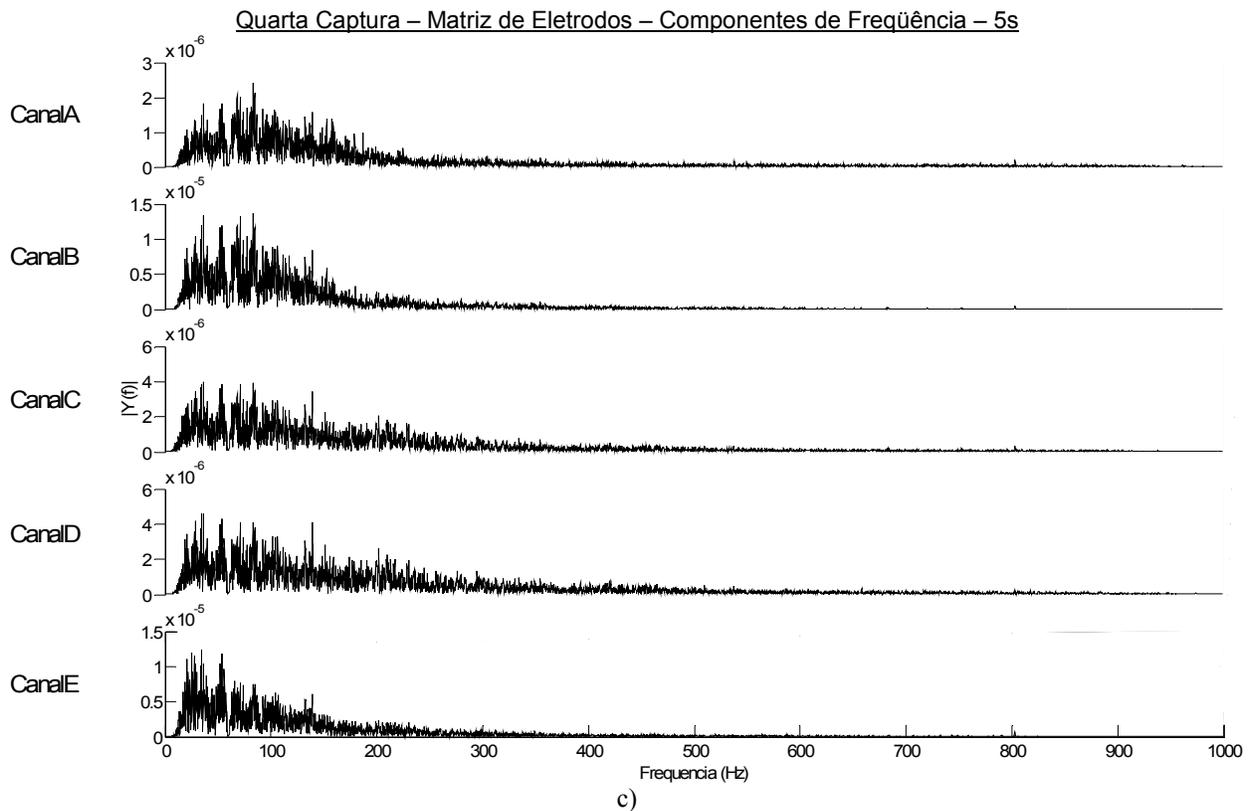
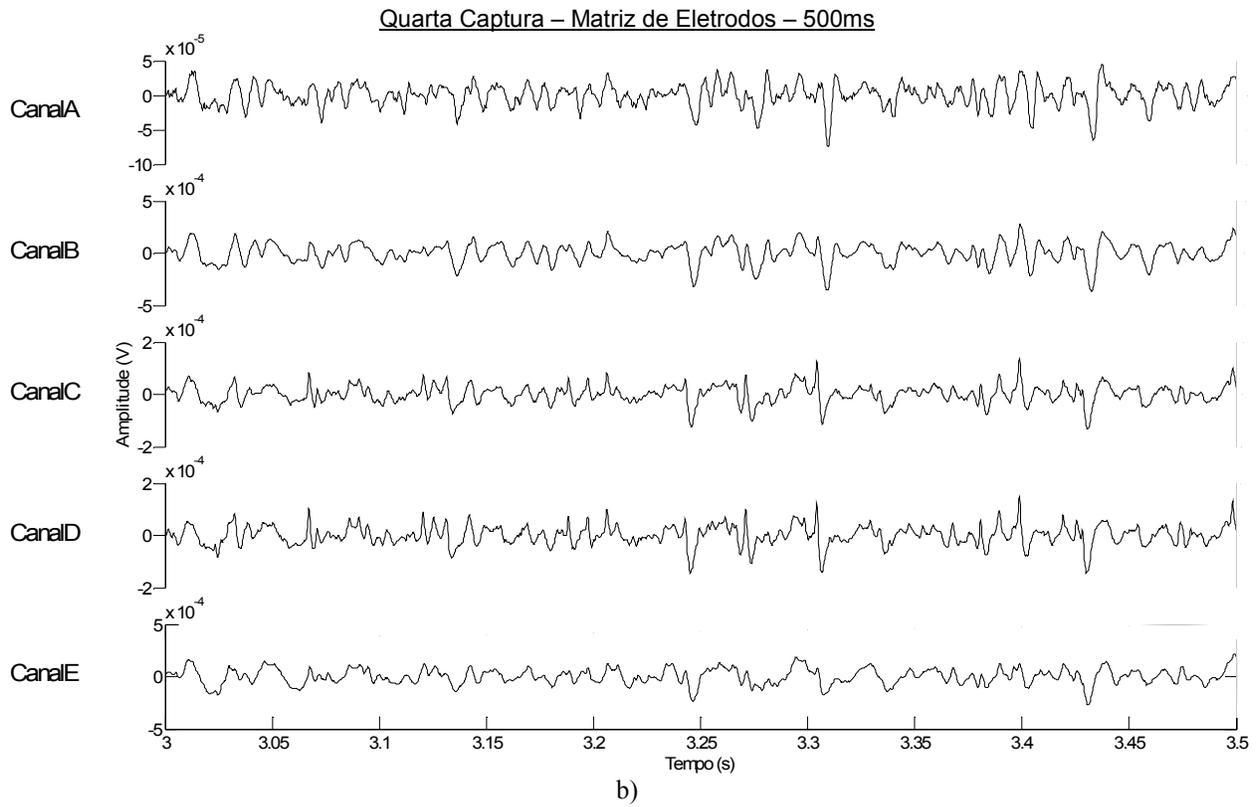
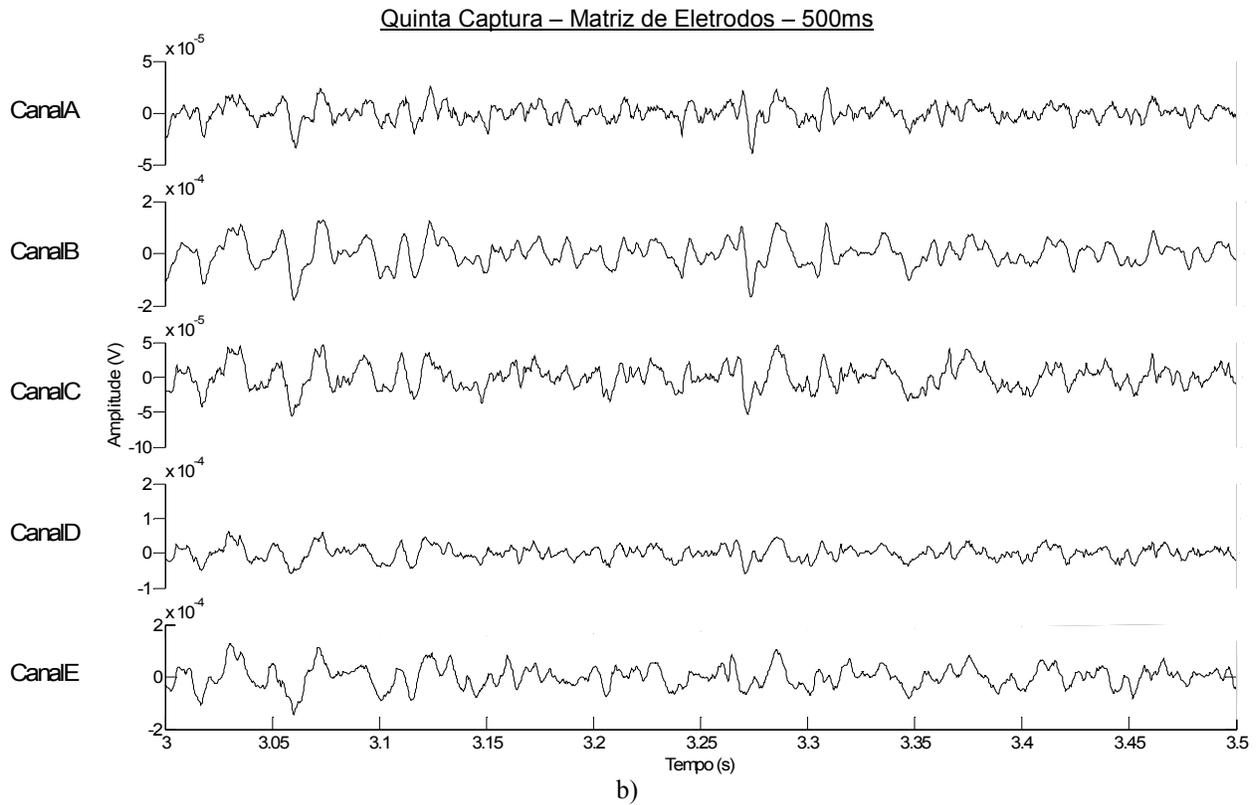
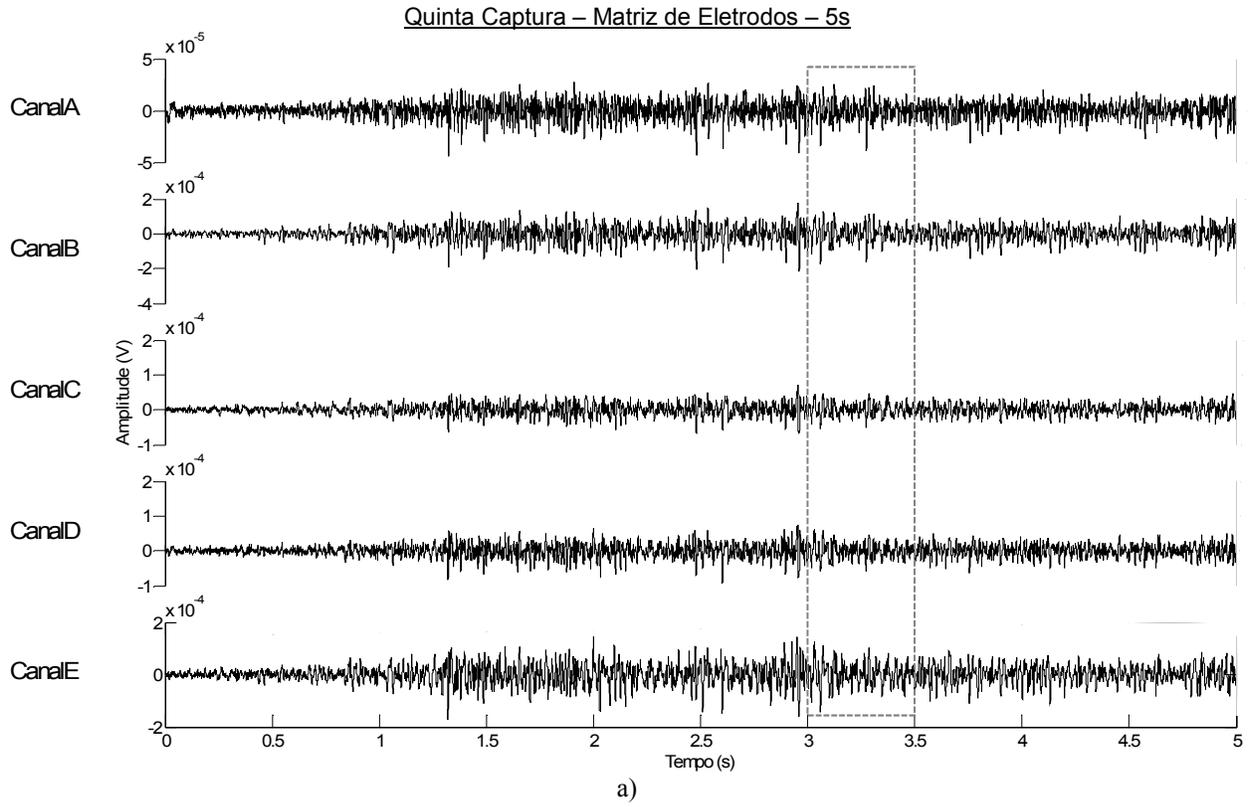


Figura A3 – Quarta captura de sinal sEMG com a matriz de eletrodos: a) 5s do sinal sEMG na quarta captura. b) Detalhe de 500ms sinal sEMG na quarta captura. c) Análise espectral dos 5s do sinal sEMG na quarta captura.



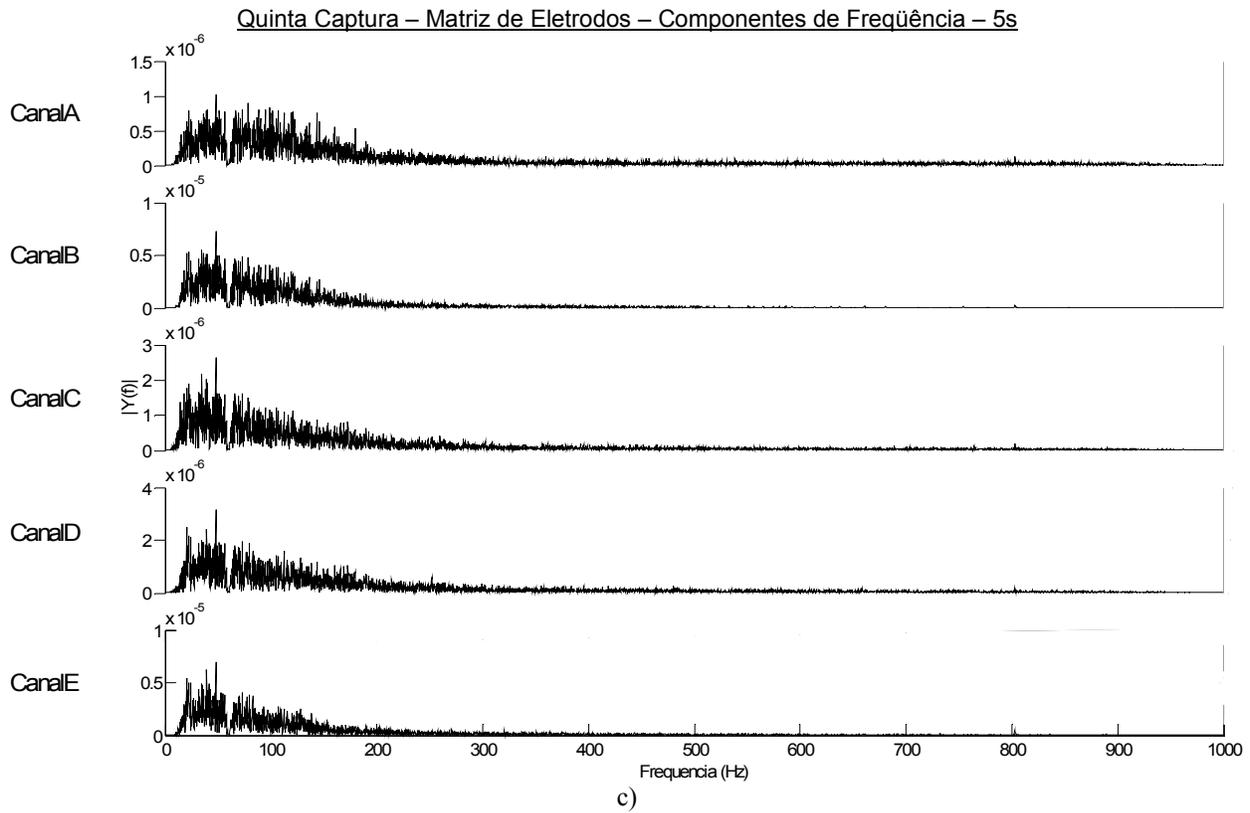
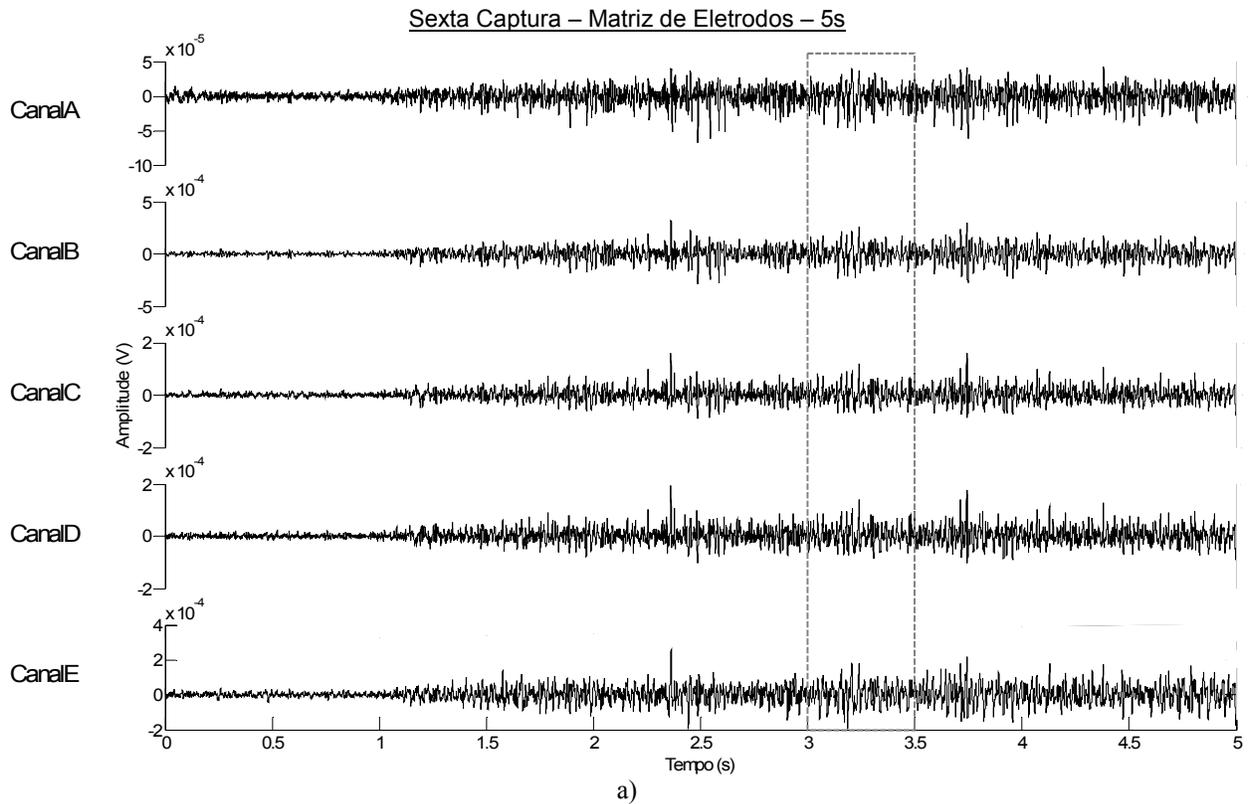


Figura A4 – Quinta captura de sinal sEMG com a matriz de eletrodos: a) 5s do sinal sEMG na quinta captura. b) Detalhe de 500ms sinal sEMG na quinta captura. c) Análise espectral dos 5s do sinal sEMG na quinta captura.



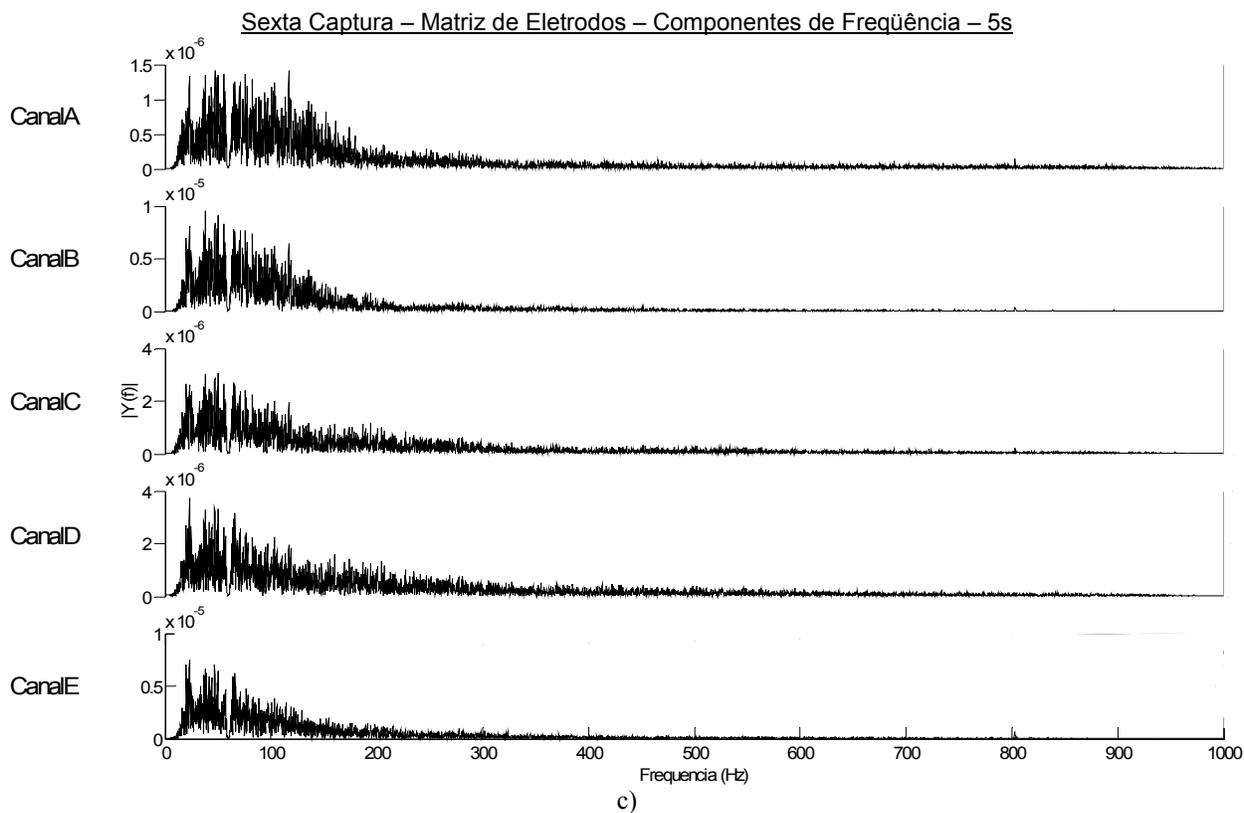
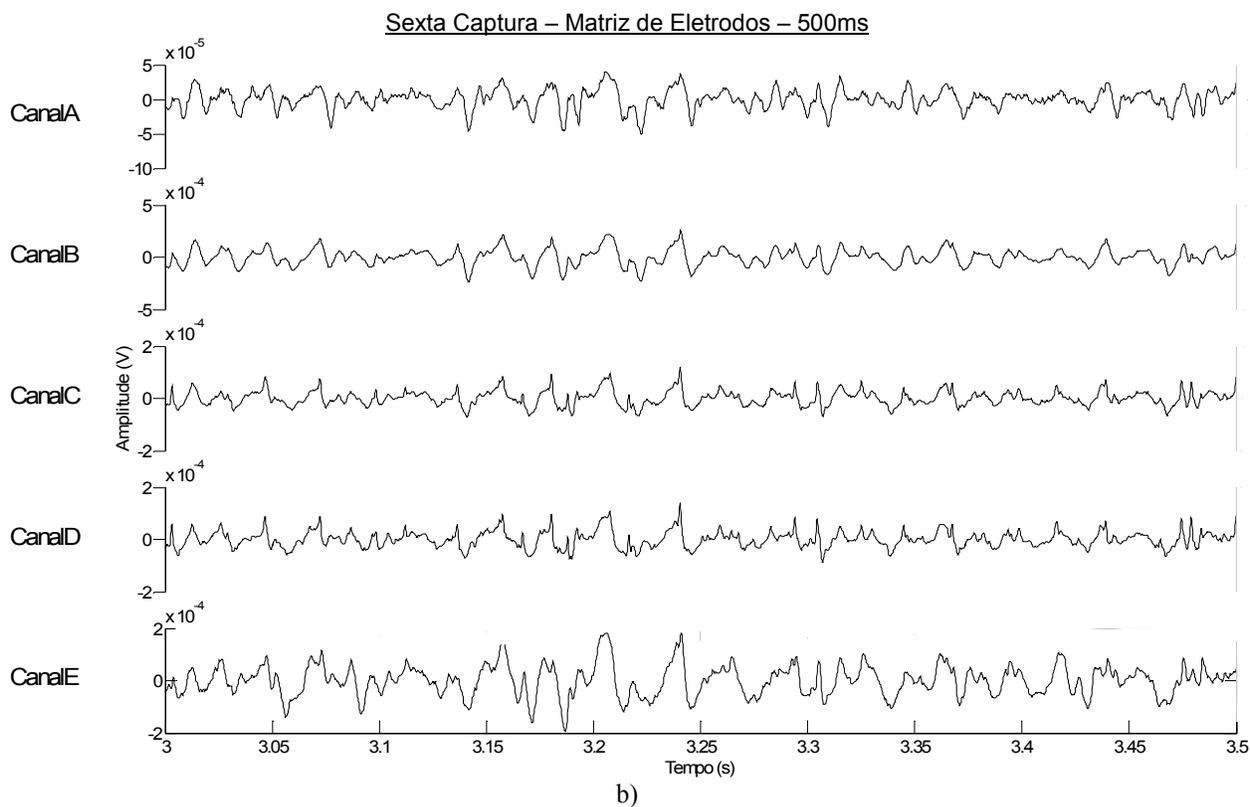


Figura A5 – Sexta captura de sinal sEMG com a matriz de eletrodos: a) 5s do sinal sEMG na sexta captura. b) Detalhe de 500ms sinal sEMG na sexta captura. c) Análise espectral dos 5s do sinal sEMG na sexta captura.

As Figuras A6 a A38 mostram os resultados do processo de mistura e separação dos sinais conhecidos. No texto principal, foram mostradas apenas as primeiras capturas dos seis testes. As Figuras A6 a A38 mostram as outras quatro capturas para cada um dos testes. As Figuras mostram dois gráficos: o gráfico à esquerda mostra o valor da SIR entre as fontes originais e os sinais misturados; o gráfico à direita mostra o resultado da separação de fontes, ou seja, valor da SIR entre as fontes originais e as fontes estimadas, além de mostrar o valor da correlação entre as fontes originais e fontes estimadas.

As Figuras A6 a A9 mostram os resultados das capturas 2 a 4, respectivamente, da separação dos sinais capturados durante o primeiro teste, que engloba as fontes *waveform*, senoíde de 500Hz e ruído branco.

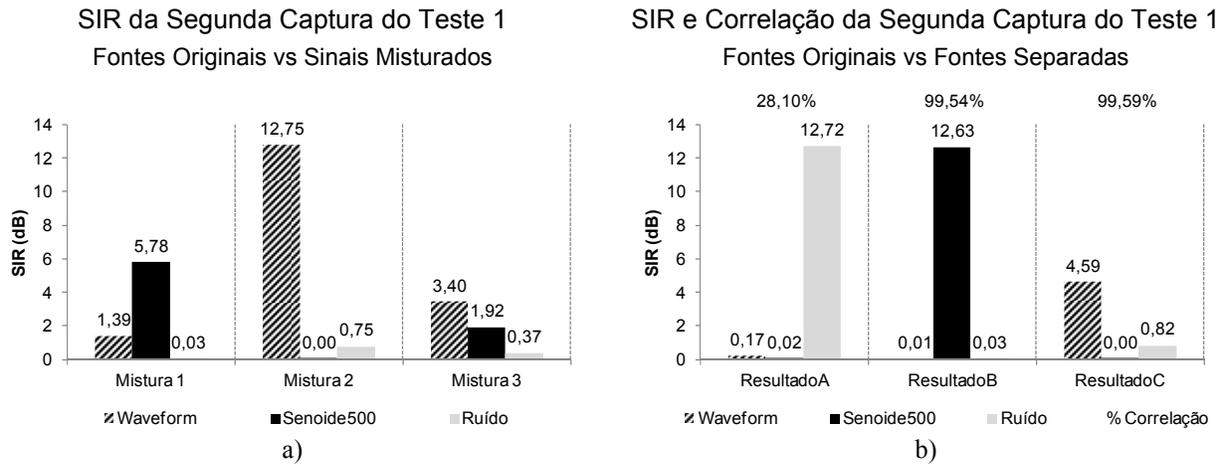


Figura A6 – Resultados da separação de sinais conhecidos para a captura 2 do Teste 1. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

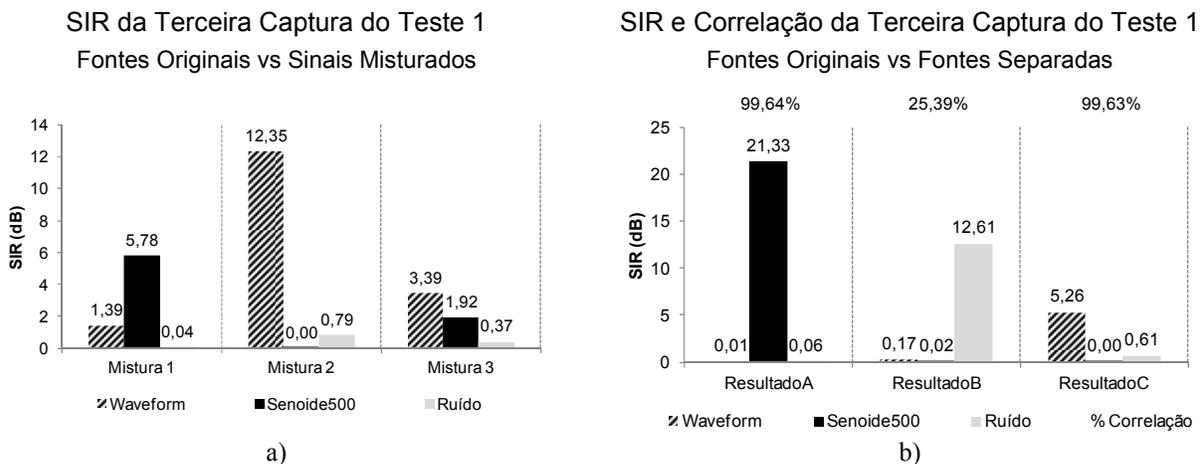


Figura A7 – Resultados da separação de sinais conhecidos para a captura 3 do Teste 1. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

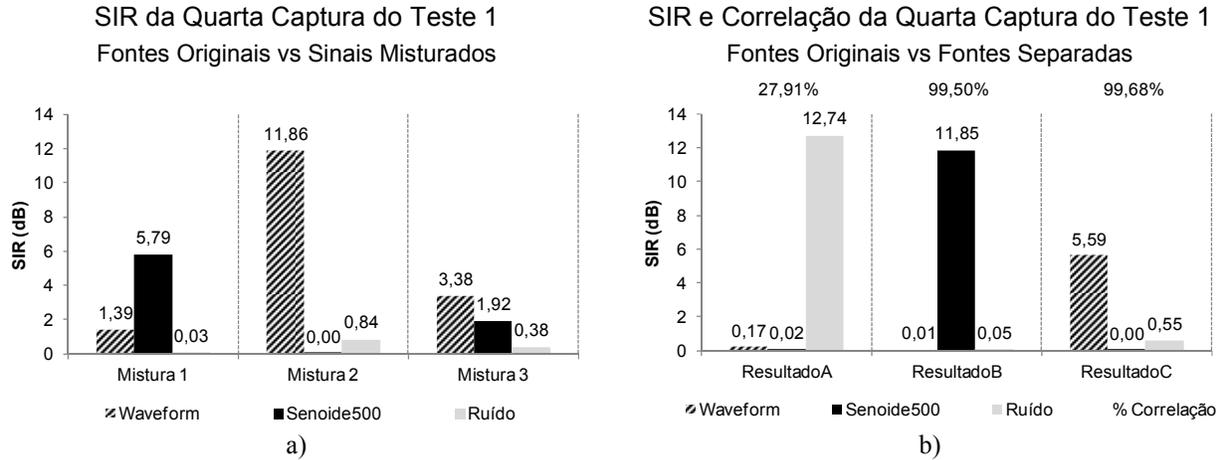


Figura A8 – Resultados da separação de sinais conhecidos para a captura 4 do Teste 1. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

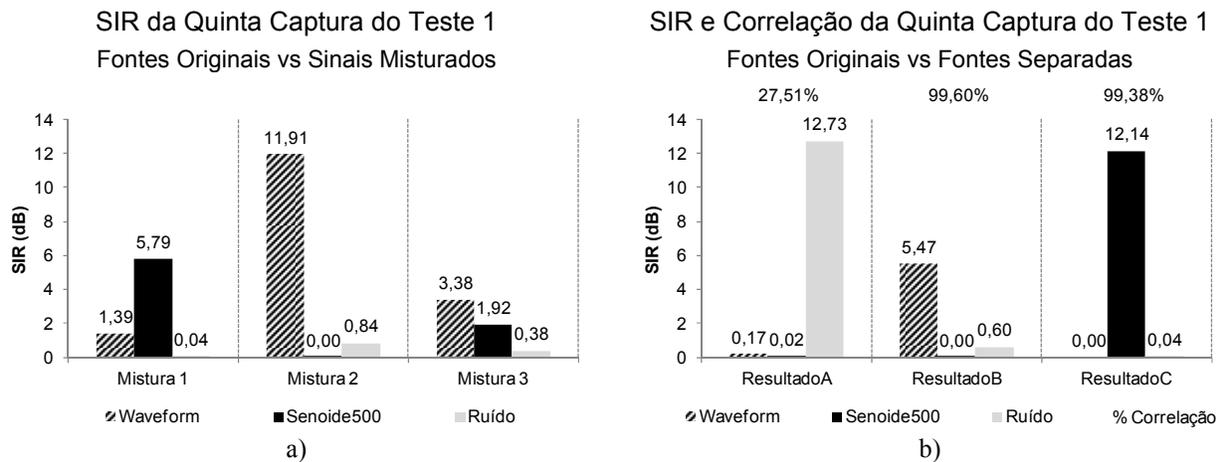
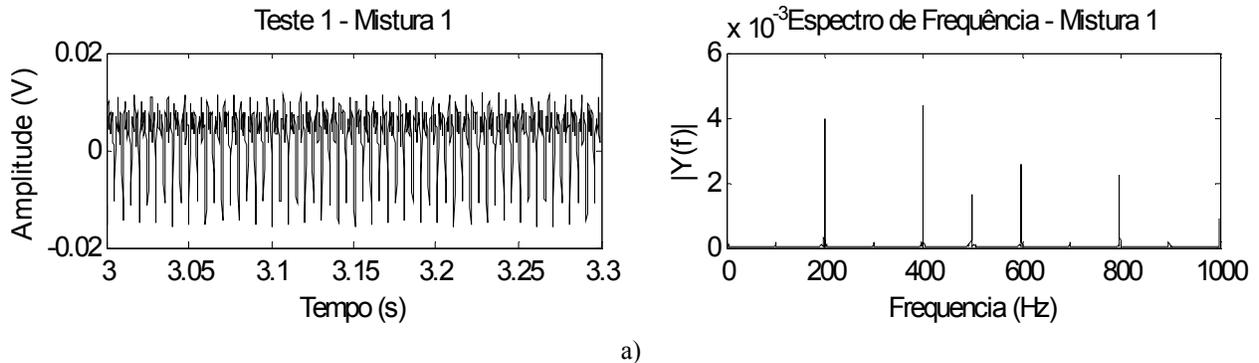


Figura A9 – Resultados da separação de sinais conhecidos para a captura 5 do Teste 1. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

As Figura A10 e A11 mostram, respectivamente, as três misturas capturadas e os três sinais estimados pelo processo de separação para primeira captura do Teste 1.



a)

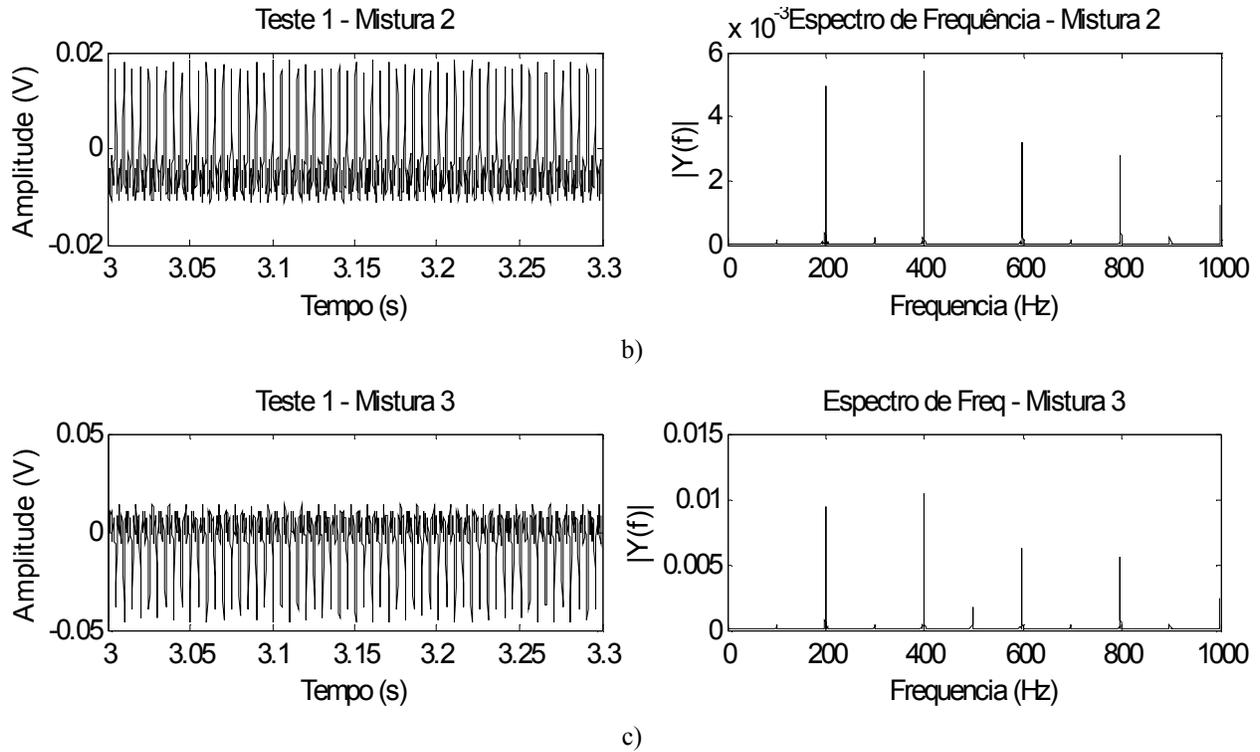
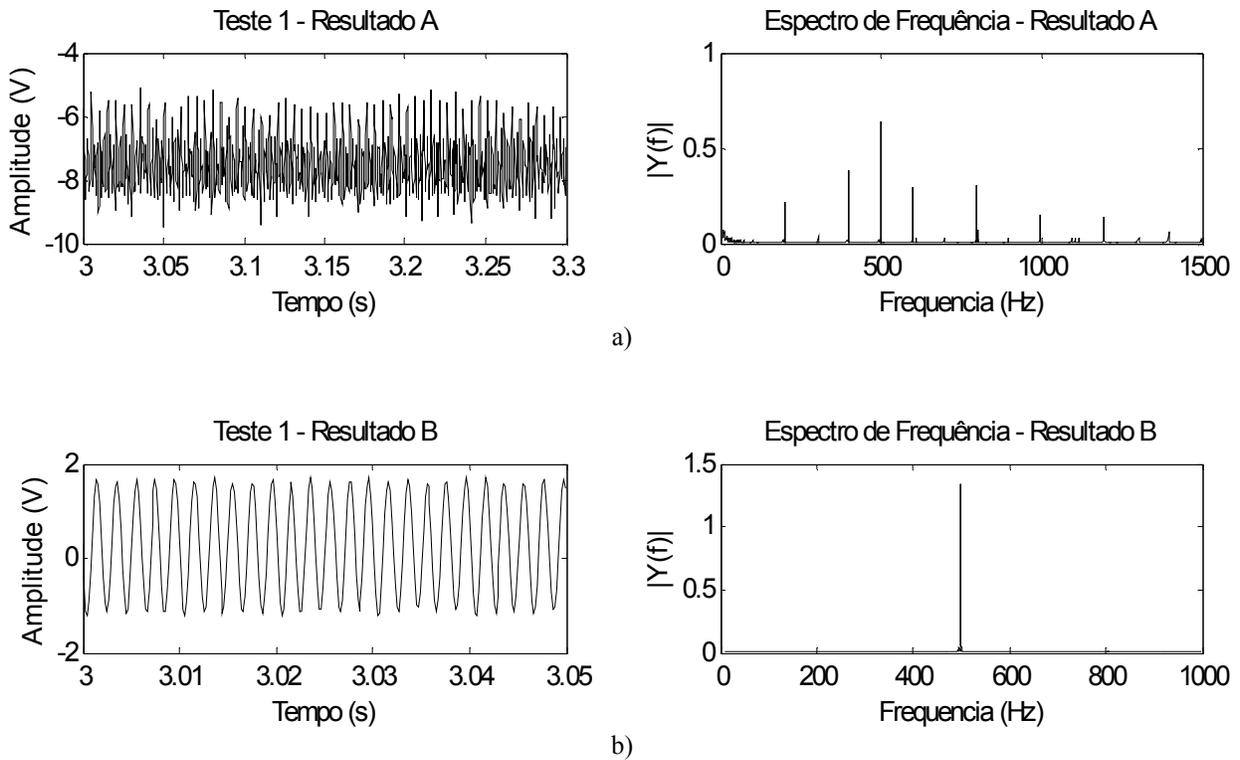
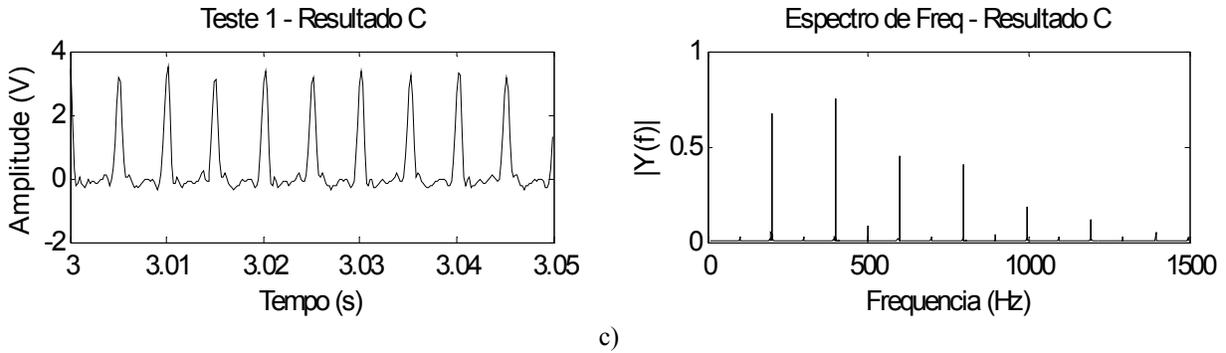


Figura A10 – Três misturas da primeira captura do Teste 1, no domínio do tempo e da frequência, que engloba as fontes originais *waveform*, senóide de 500Hz e ruído branco. a) Mistura 1. b) Mistura 2. c) Mistura 3.





c)

Figura A11 – Três sinais estimados pelo processo de separação para a primeira captura do Teste 1, no domínio do tempo e da frequência, que engloba as fontes originais *waveform*, senóide de 500Hz e ruído branco. a) Resultado A separou o ruído. b) Resultado B separou a senóide de 500Hz. c) Resultado C separou a *waveform*.

As Figuras A12 a A15 mostram os resultados das capturas 2 a 4, respectivamente, da separação dos sinais capturados durante o segundo teste, que envolveu a mistura das fontes originais: senóide de 500Hz, ruído branco e o *Burst*.

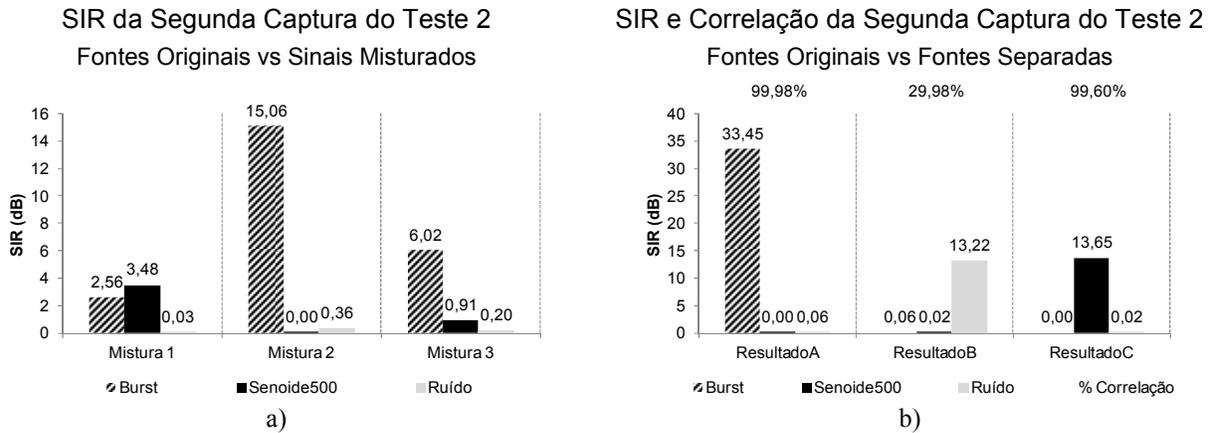


Figura A12 – Resultados da separação de sinais conhecidos para a captura 2 do Teste 2. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

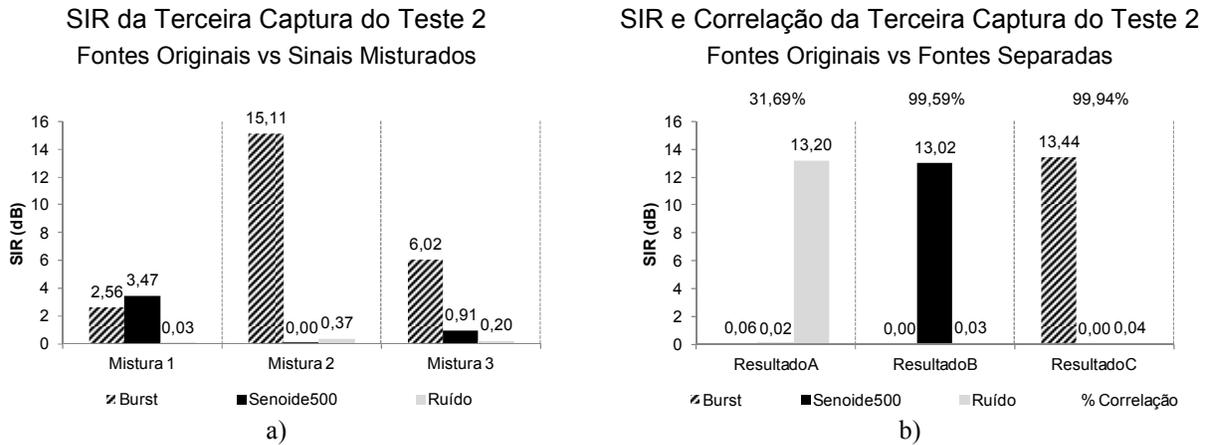


Figura A13 – Resultados da separação de sinais conhecidos para a captura 3 do Teste 2. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

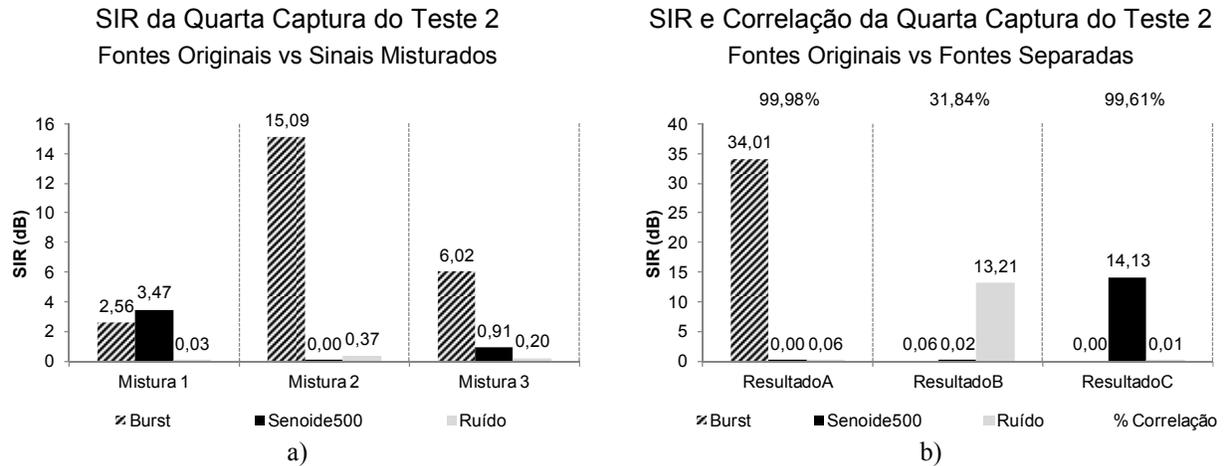


Figura A14 – Resultados da separação de sinais conhecidos para a captura 4 do Teste 2. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

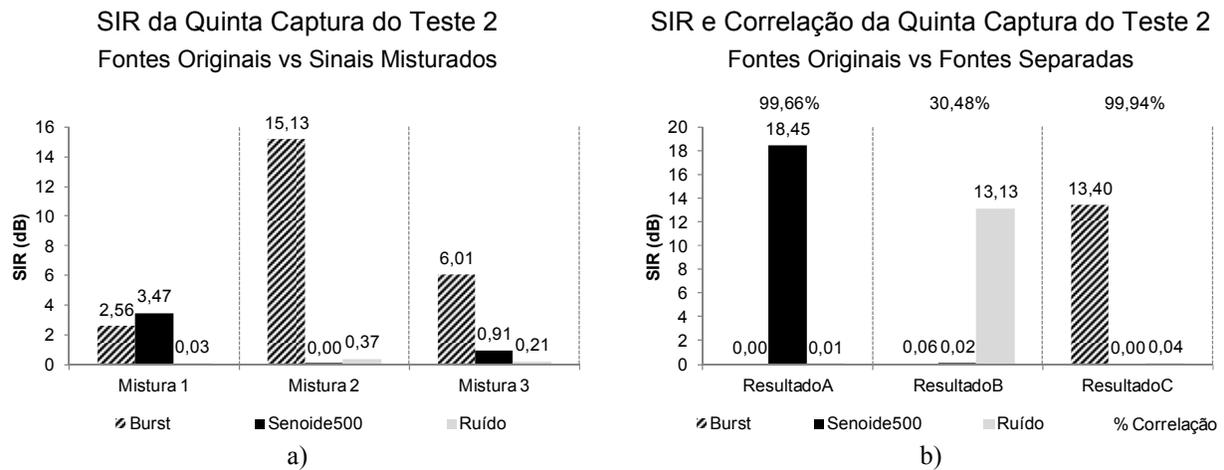


Figura A15 – Resultados da separação de sinais conhecidos para a captura 5 do Teste 2. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

As Figuras A16 a A19 mostram os resultados das capturas 2 a 4, respectivamente, da separação dos sinais capturados durante o terceiro teste, que engloba as fontes senóide de 40Hz, senóide de 500Hz e ruído branco.

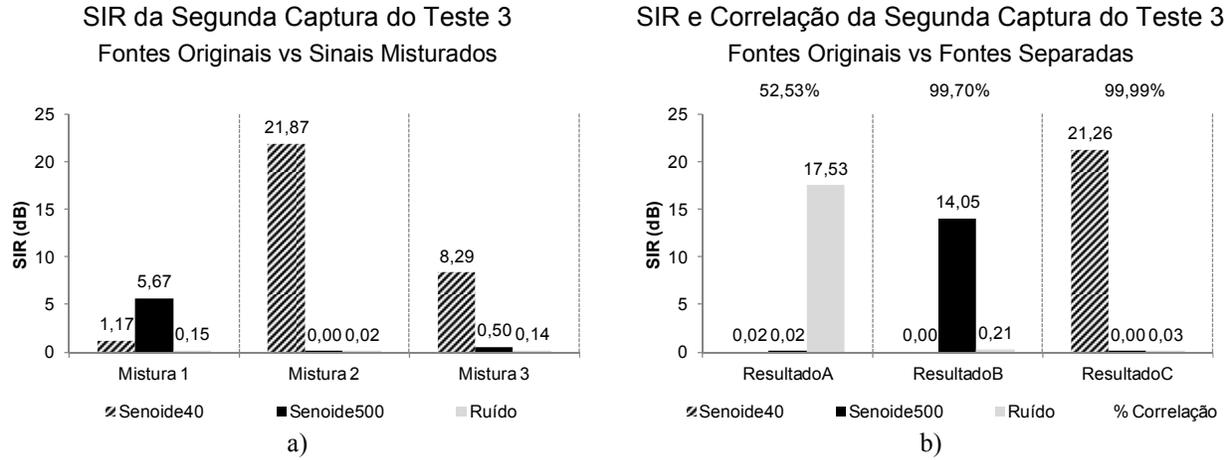


Figura A16 – Resultados da separação de sinais conhecidos para a captura 2 do Teste 3. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

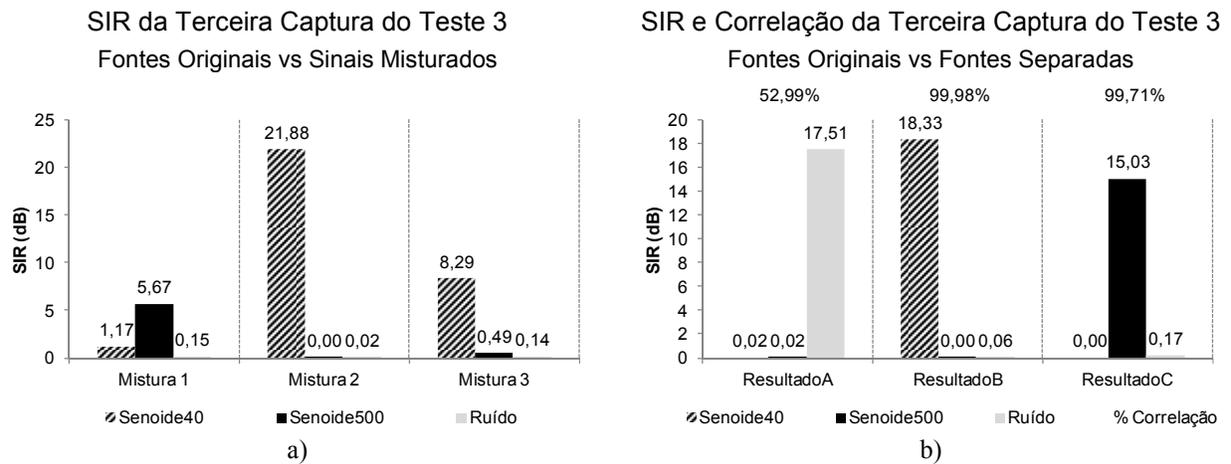


Figura A17 – Resultados da separação de sinais conhecidos para a captura 3 do Teste 3. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

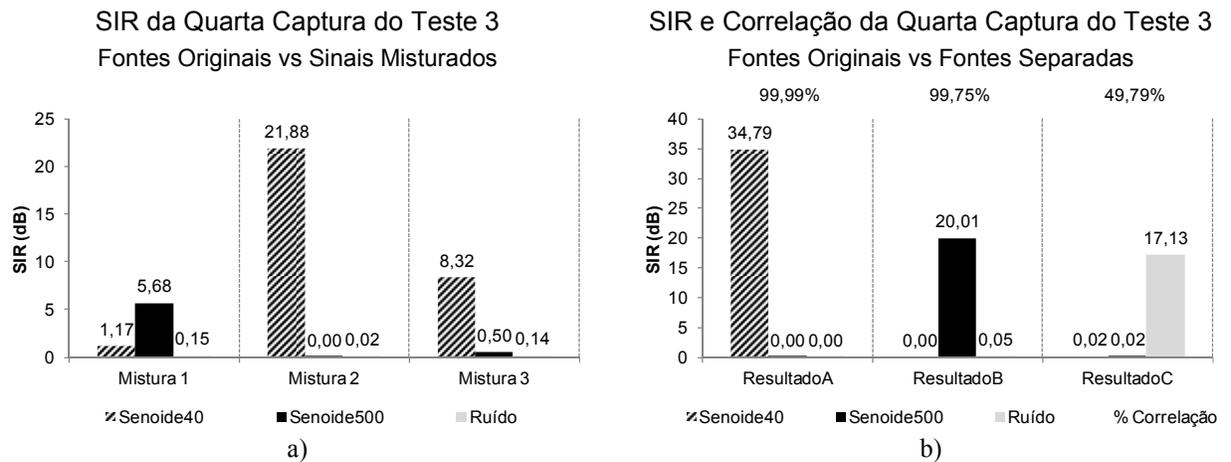


Figura A18 – Resultados da separação de sinais conhecidos para a captura 4 do Teste 3. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

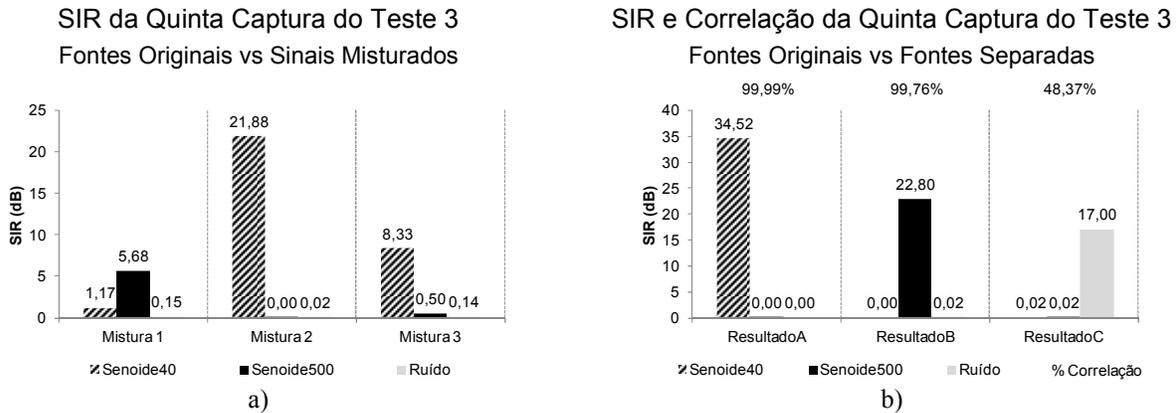


Figura A19 – Resultados da separação de sinais conhecidos para a captura 5 do Teste 3. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

As Figura A20 e A21 mostram, respectivamente, as três misturas capturadas e os três sinais estimados pelo processo de separação para primeira captura do Teste 3.

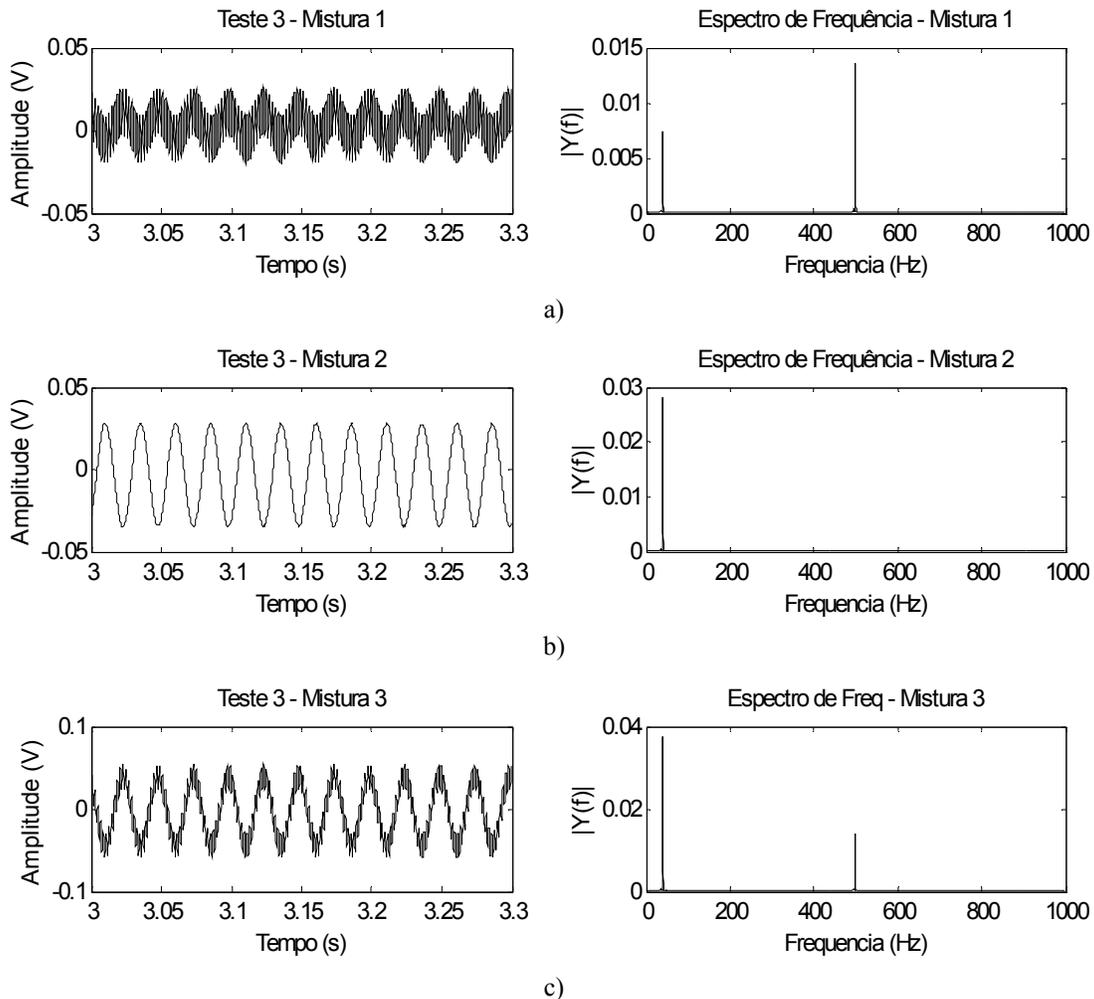


Figura A20 – Três misturas da primeira captura do Teste 3, no domínio do tempo e da frequência, que engloba as fontes originais senóide de 40Hz, senóide de 500Hz e ruído branco. a) Mistura 1. b) Mistura 2. c) Mistura 3.

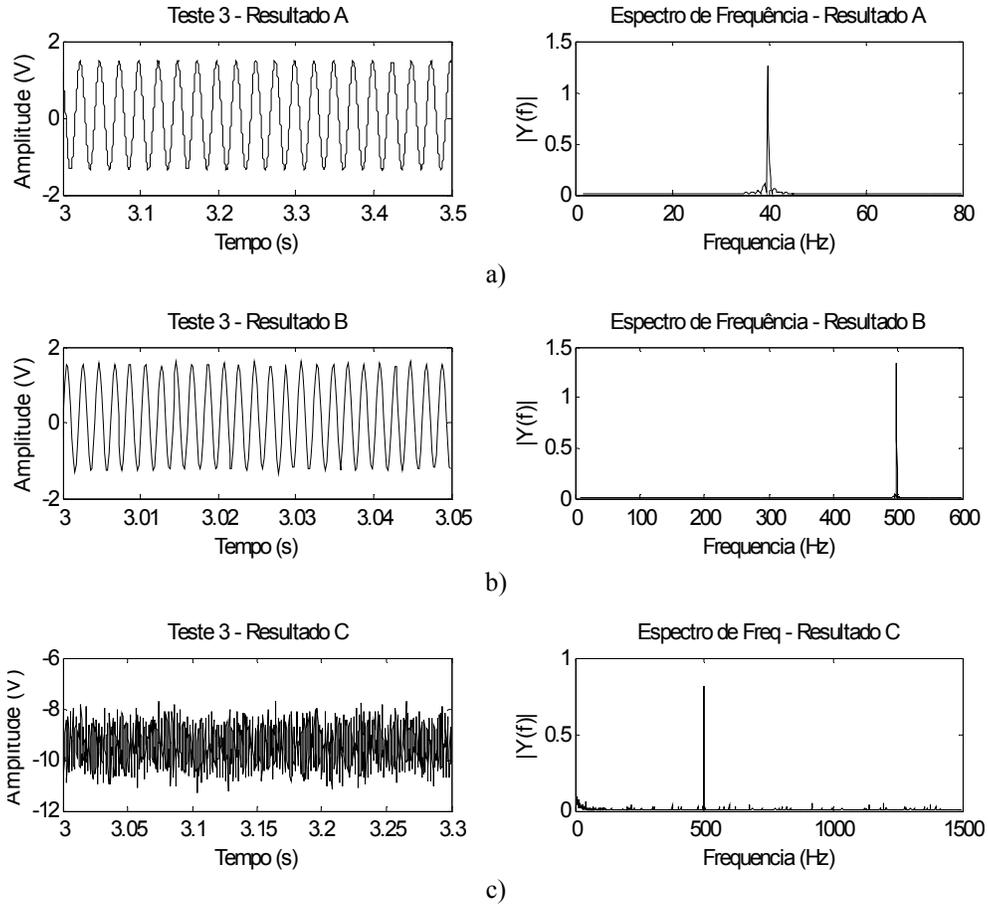


Figura A21 – Três sinais estimados pelo processo de separação para a primeira captura do Teste 3, no domínio do tempo e da frequência, que engloba as fontes originais senóide de 40Hz, senóide de 500Hz e ruído branco. a) Resultado A separou a senóide de 40Hz. b) Resultado B separou a senóide de 500Hz. c) Resultado C separou o ruído.

As Figuras A22 a A25 mostram os resultados das capturas 2 a 4, respectivamente, da separação dos sinais capturados durante o quarto teste, que engloba as fontes *user1*, senóide de 500Hz e ruído branco.

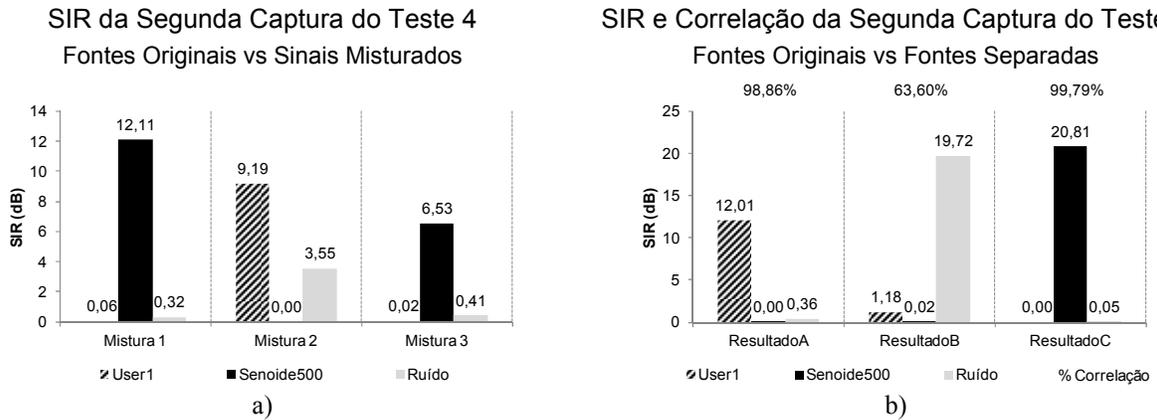


Figura A22 – Resultados da separação de sinais conhecidos para a captura 2 do Teste 4. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

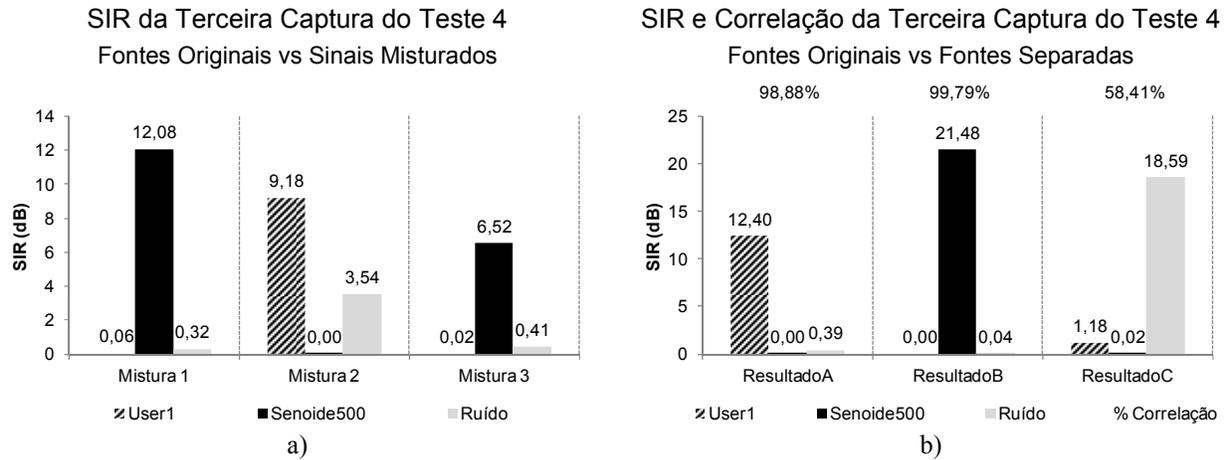


Figura A23 – Resultados da separação de sinais conhecidos para a captura 3 do Teste 4. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

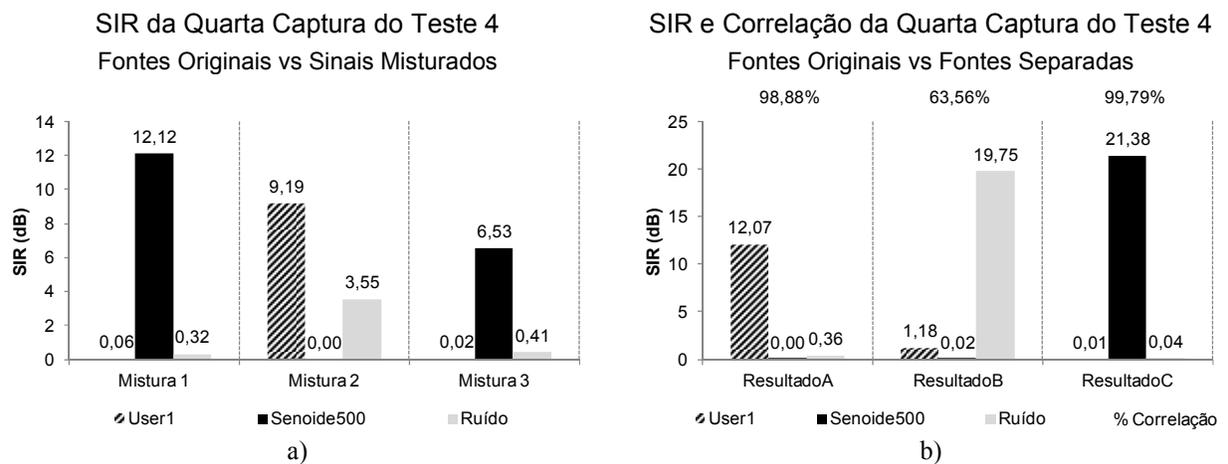


Figura A24 – Resultados da separação de sinais conhecidos para a captura 4 do Teste 4. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

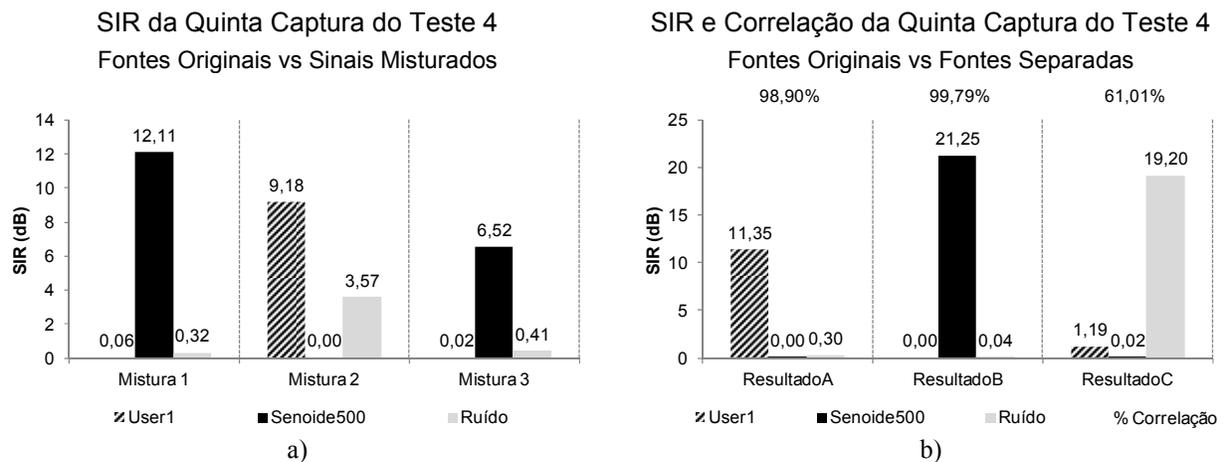


Figura A25 – Resultados da separação de sinais conhecidos para a captura 5 do Teste 4. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

As Figura A26 e A27 mostram, respectivamente, as três misturas capturadas e os três sinais estimados pelo processo de separação para primeira captura do Teste 4.

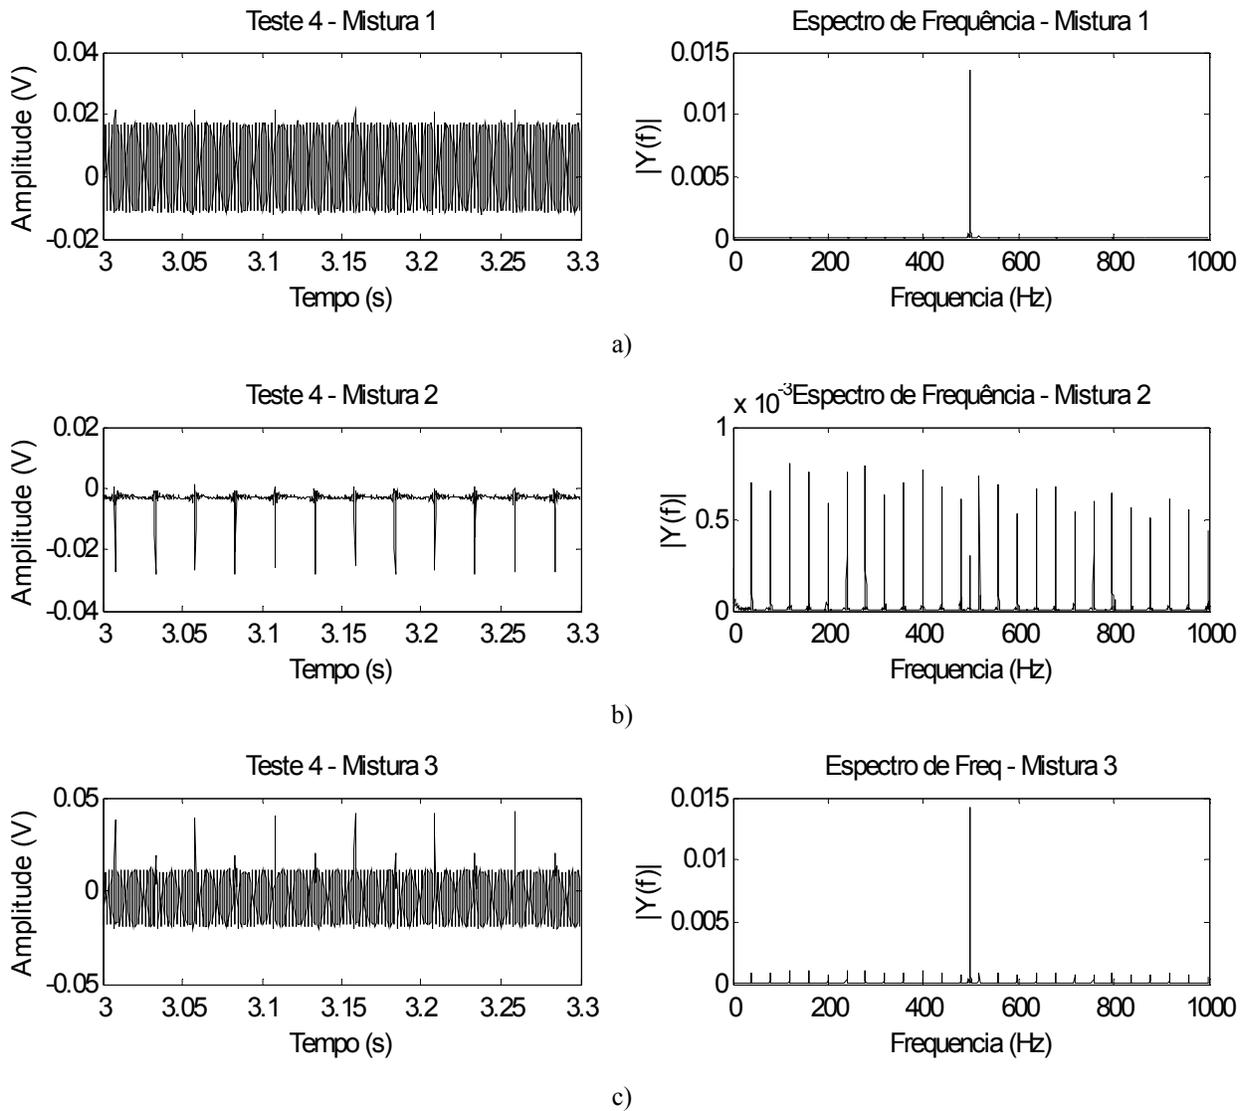
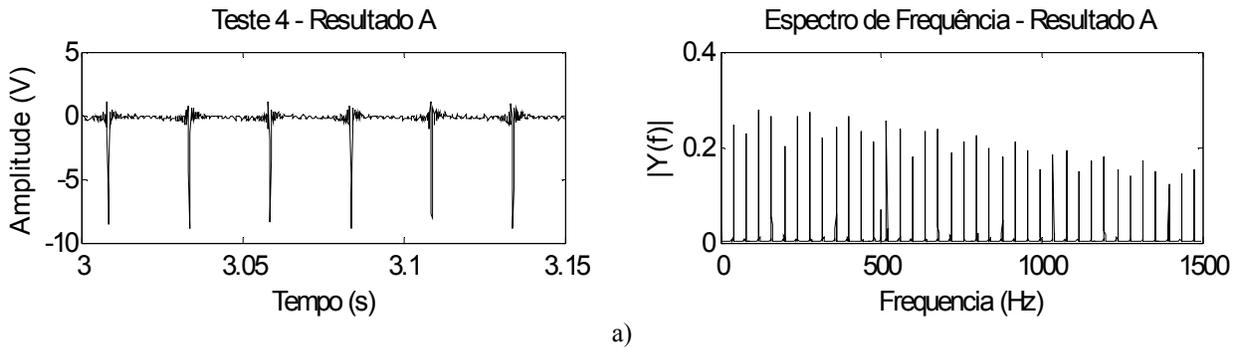


Figura A26 – Três misturas da primeira captura do Teste 4, no domínio do tempo e da frequência, que engloba as fontes originais *user1*, senóide de 500Hz e ruído branco. a) Mistura 1. b) Mistura 2. c) Mistura 3.



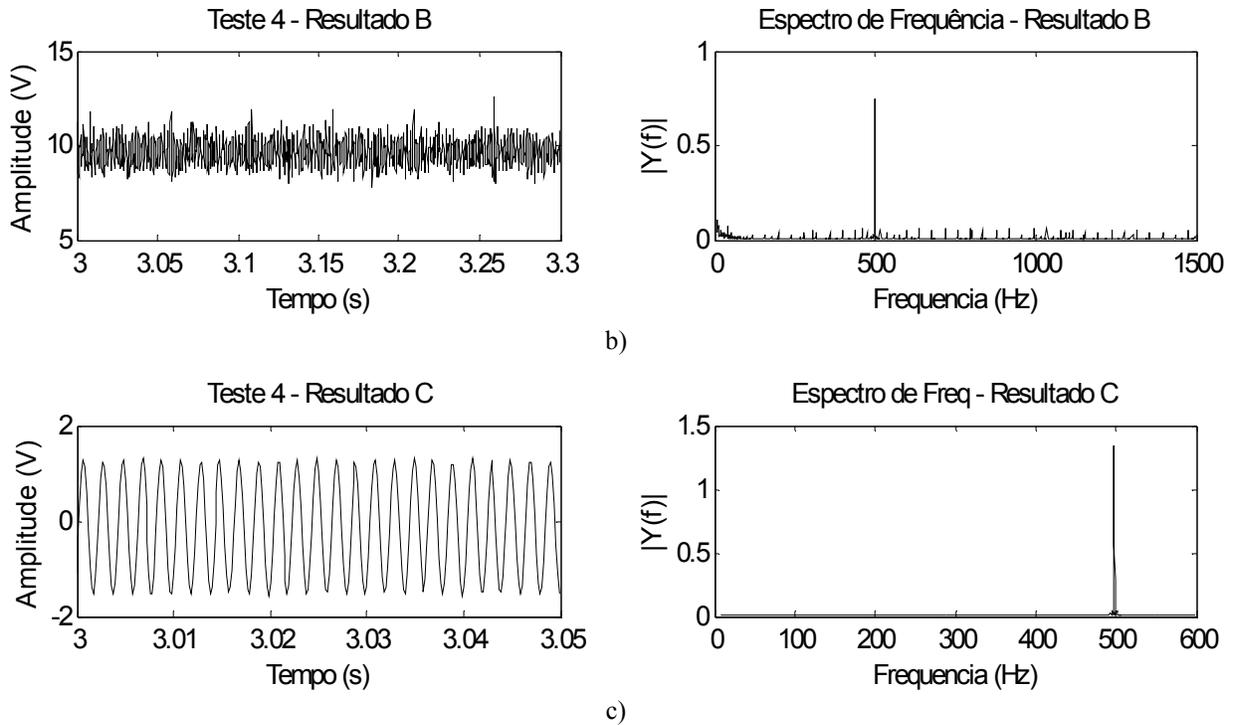


Figura A27 – Três sinais estimados pelo processo de separação para a primeira captura do Teste 4, no domínio do tempo e da frequência, que engloba as fontes originais *user1*, senóide de 500Hz e ruído branco. a) Resultado A separou a *user1*. b) Resultado B separou o ruído. c) Resultado C separou a senóide de 500Hz.

As Figuras A28 a A31 mostram os resultados das capturas 2 a 4, respectivamente, da separação dos sinais capturados durante o quinto teste, que engloba as fontes *user2*, senóide de 500Hz e ruído branco.

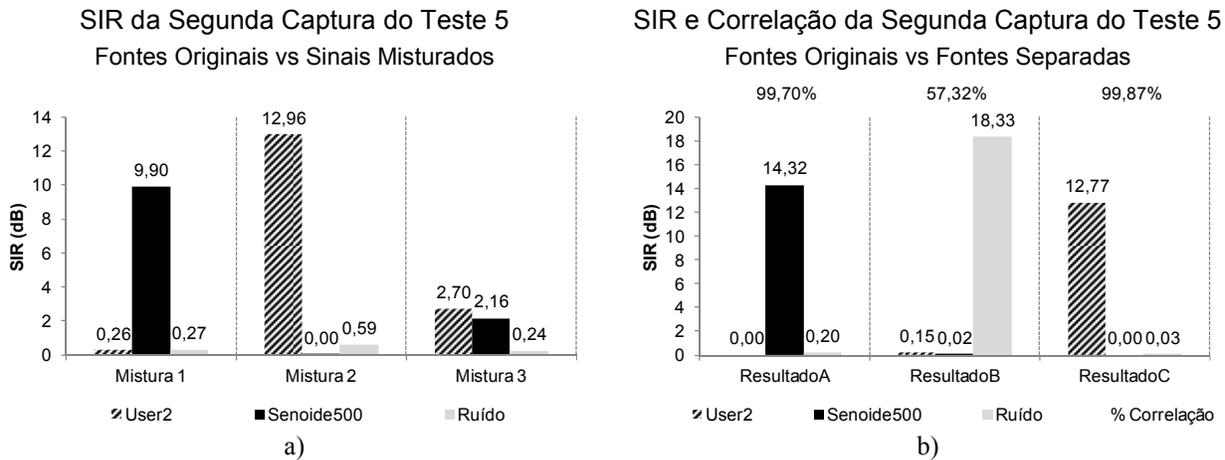


Figura A28 – Resultados da separação de sinais conhecidos para a captura 2 do Teste 5. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

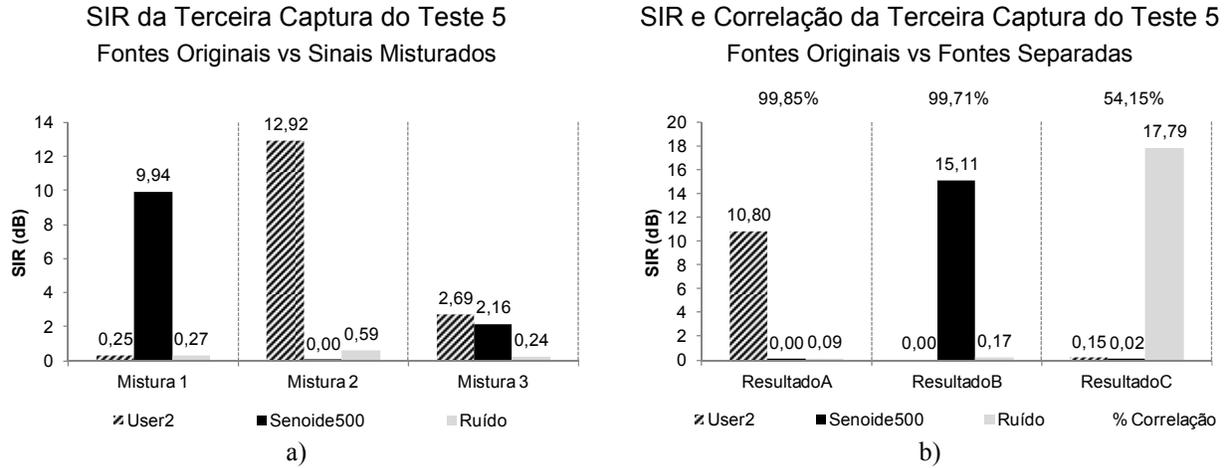


Figura A29 – Resultados da separação de sinais conhecidos para a captura 3 do Teste 5. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

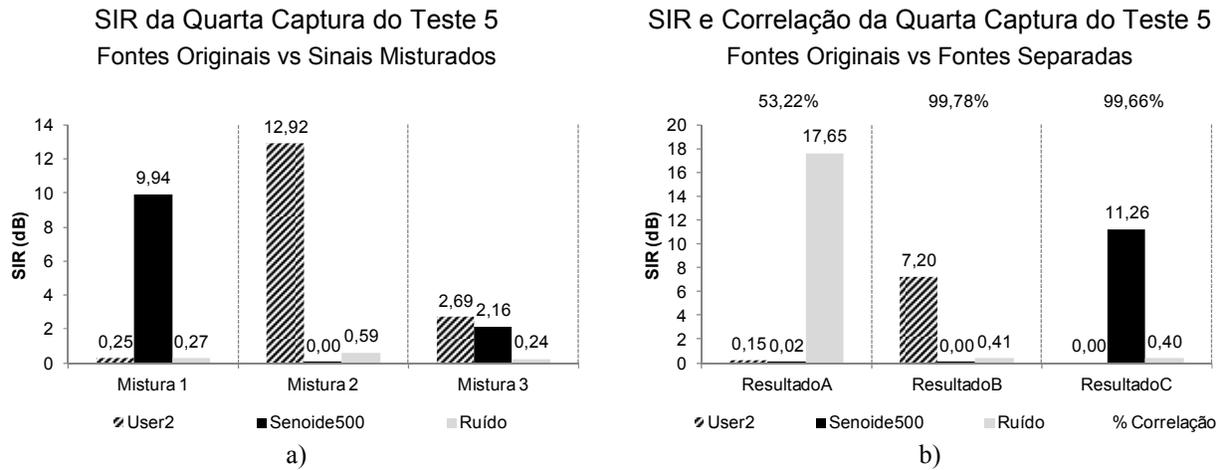


Figura A30 – Resultados da separação de sinais conhecidos para a captura 4 do Teste 5. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

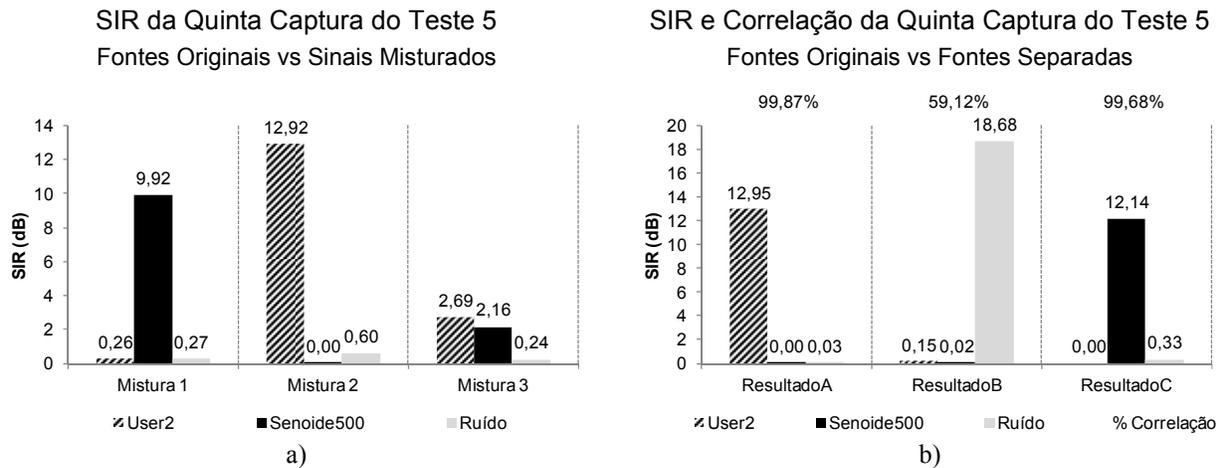


Figura A31 – Resultados da separação de sinais conhecidos para a captura 5 do Teste 5. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

As Figura A32 e A33 mostram, respectivamente, as três misturas capturadas e os três sinais estimados pelo processo de separação para primeira captura do Teste 5.

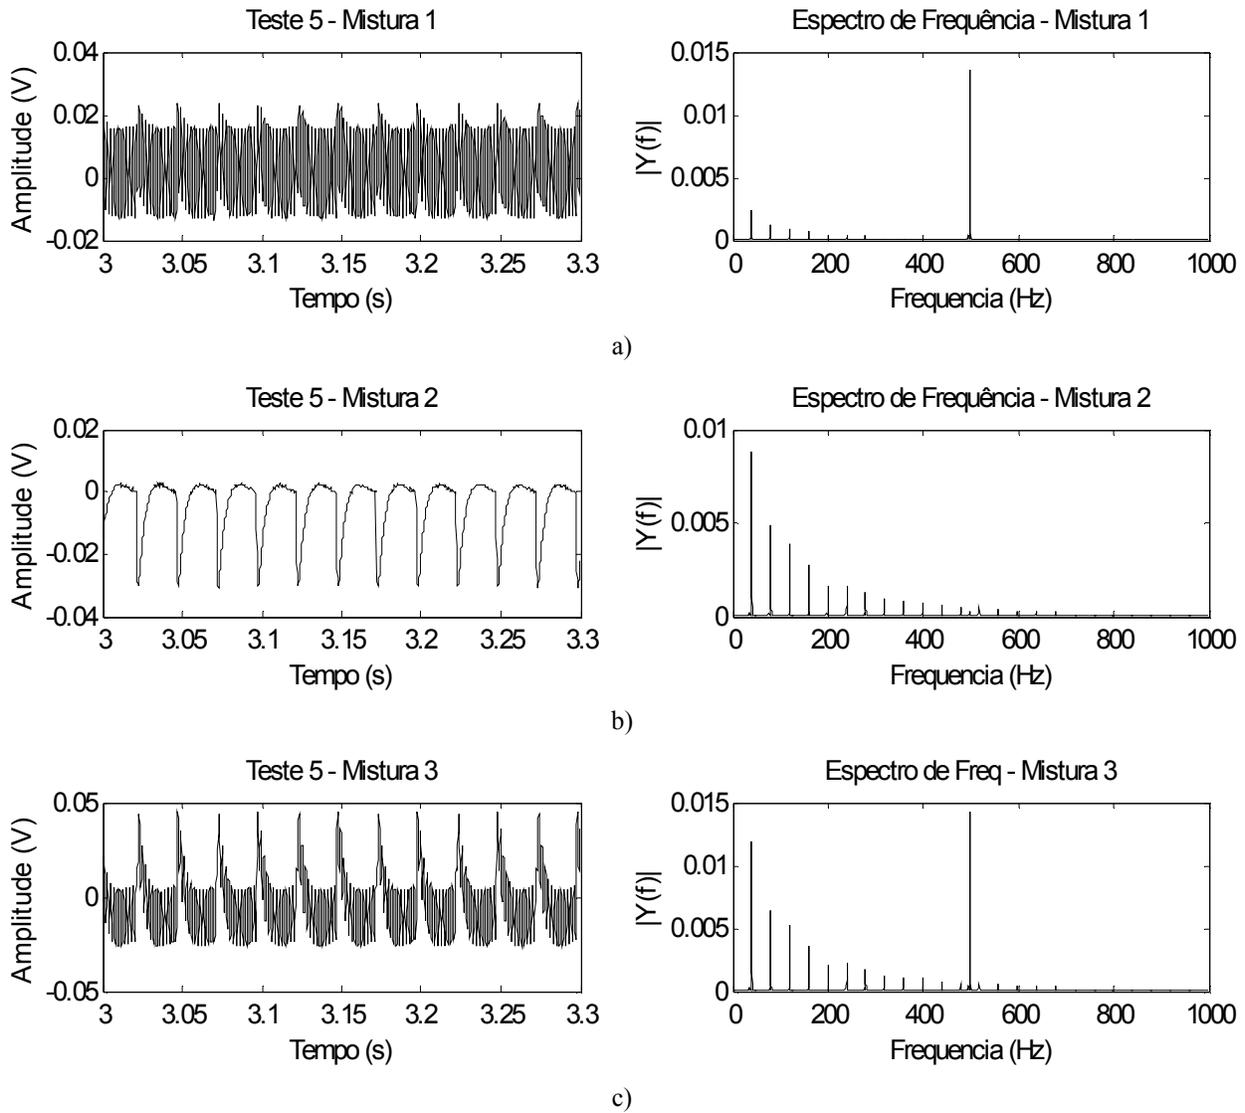
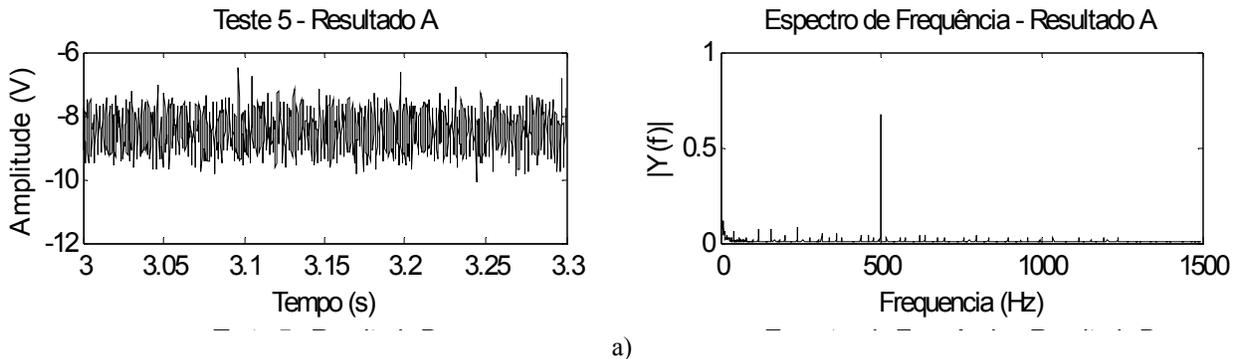


Figura A32 – Três misturas capturadas para o Teste 5, no domínio do tempo e da frequência, que engloba as fontes originais *user2*, senóide de 500Hz e ruído branco. a) Mistura 1. b) Mistura 2. c) Mistura 3.



a)

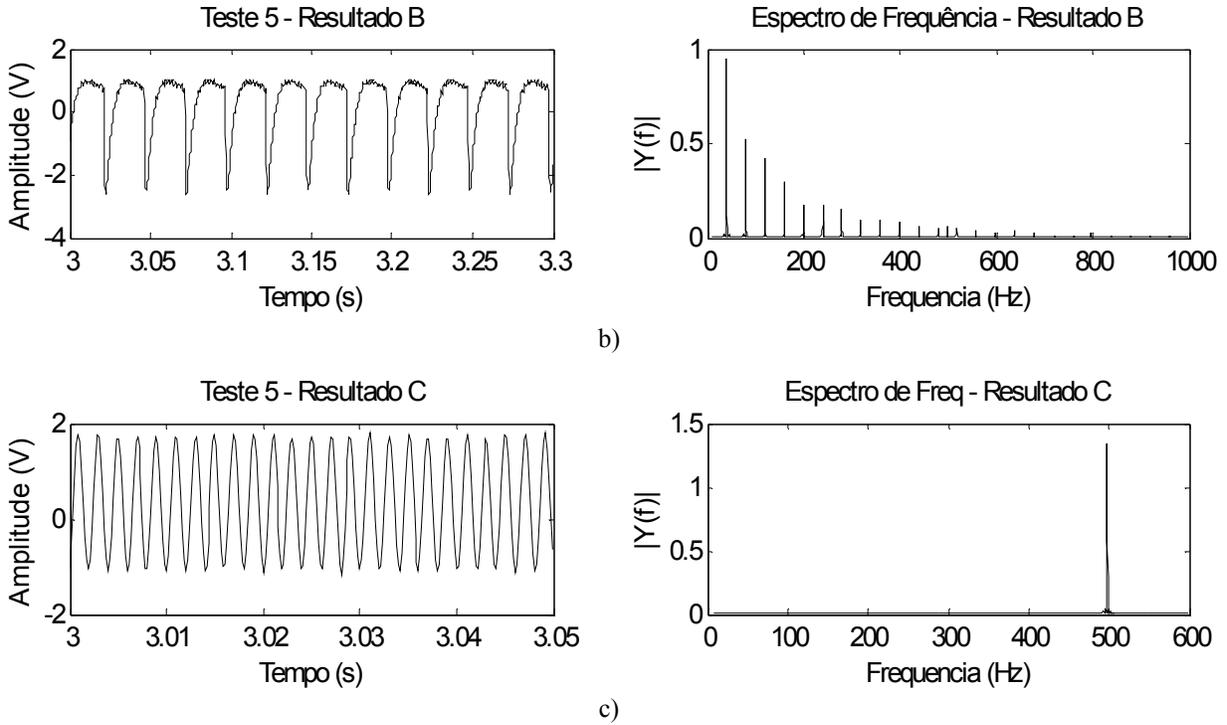


Figura A33 – Três sinais estimados pelo processo de separação para a primeira captura do Teste 5, no domínio do tempo e da frequência, que engloba as fontes originais *user1*, senóide de 500Hz e ruído branco. a) Resultado A separou o ruído. b) Resultado B separou a *user2*. c) Resultado C separou a senóide de 500Hz.

As Figuras A33 a A36 mostram os resultados das capturas 2 a 4, respectivamente, da separação dos sinais capturados durante o sexto teste, que engloba as fontes *user3*, senóide de 500Hz e ruído branco.

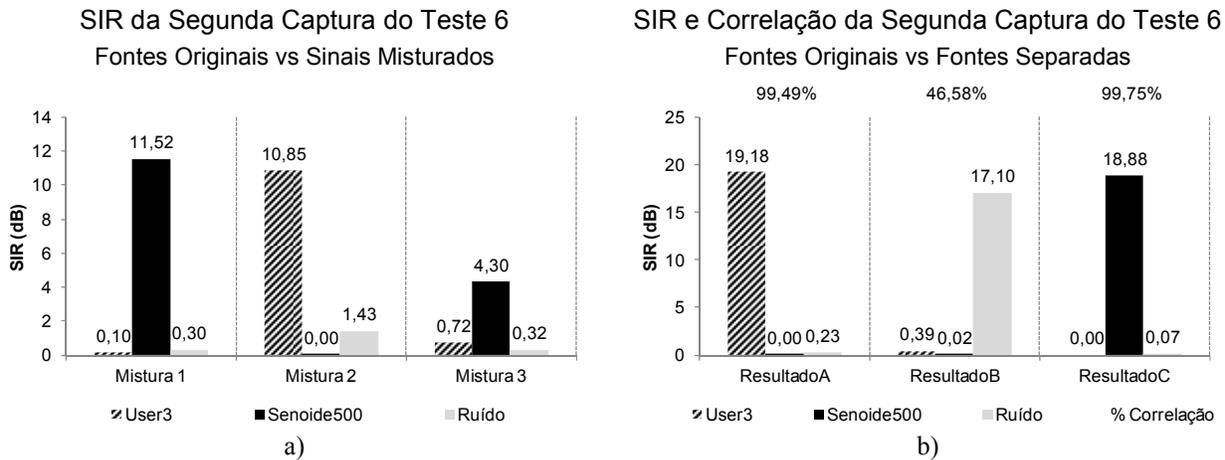


Figura A33 – Resultados da separação de sinais conhecidos para a captura 2 do Teste 6. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

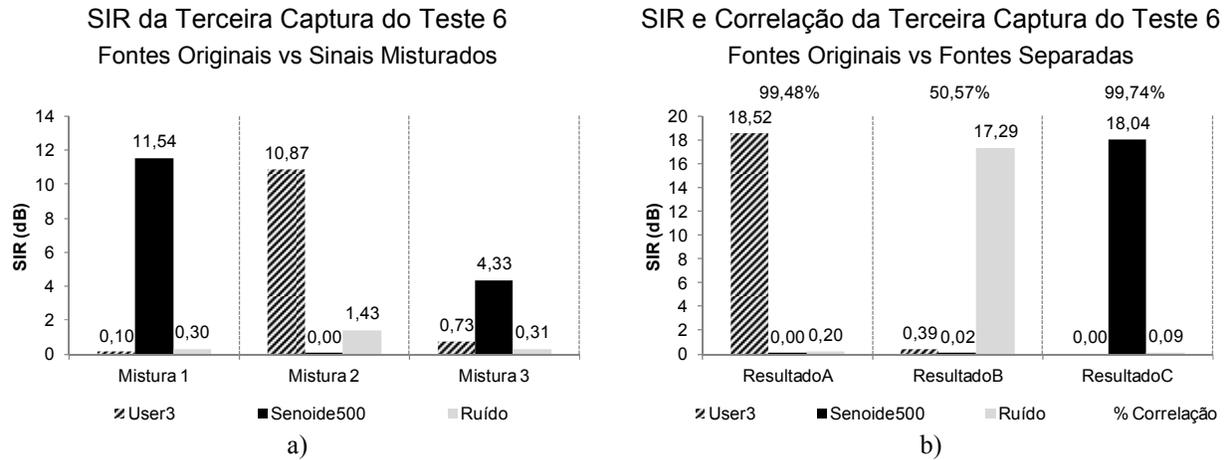


Figura A34 – Resultados da separação de sinais conhecidos para a captura 3 do Teste 6. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

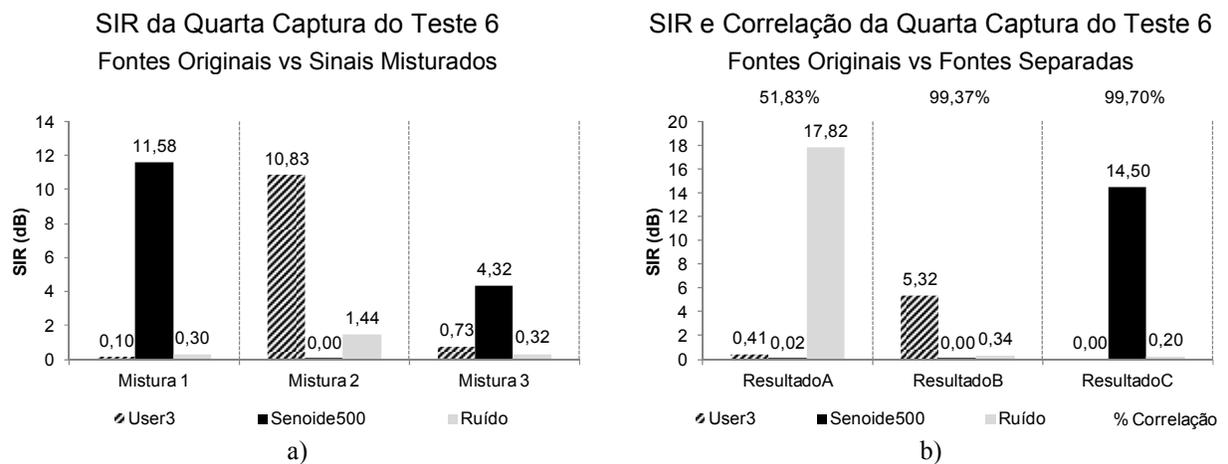


Figura A35 – Resultados da separação de sinais conhecidos para a captura 4 do Teste 6. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

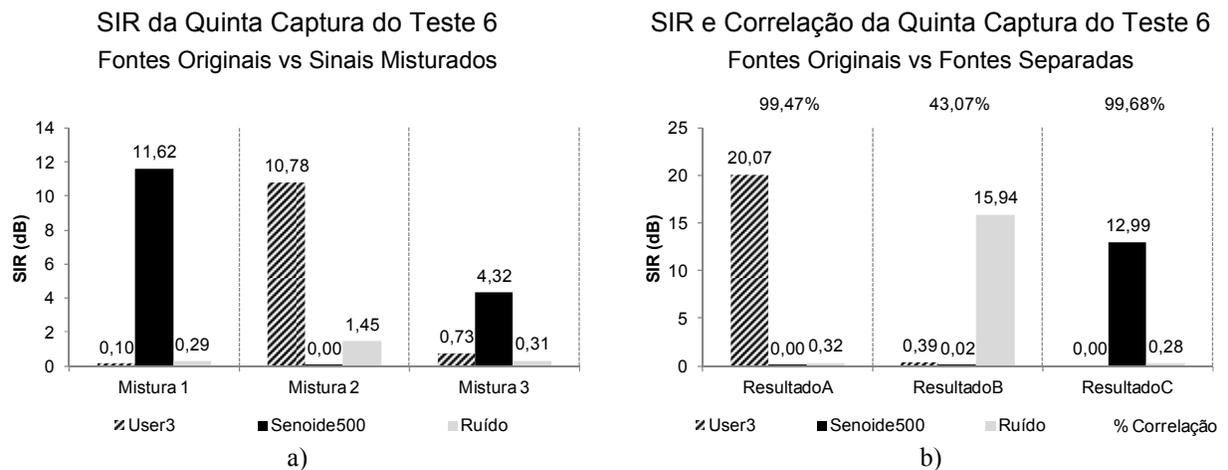


Figura A36 – Resultados da separação de sinais conhecidos para a captura 5 do Teste 6. a) SIR entre fontes conhecidas e misturas. b) SIR e Correlação entre fontes conhecidas e fontes separadas.

As Figura A37 e A38 mostram, respectivamente, as três misturas capturadas e os três sinais estimados pelo processo de separação para primeira captura do Teste 6.

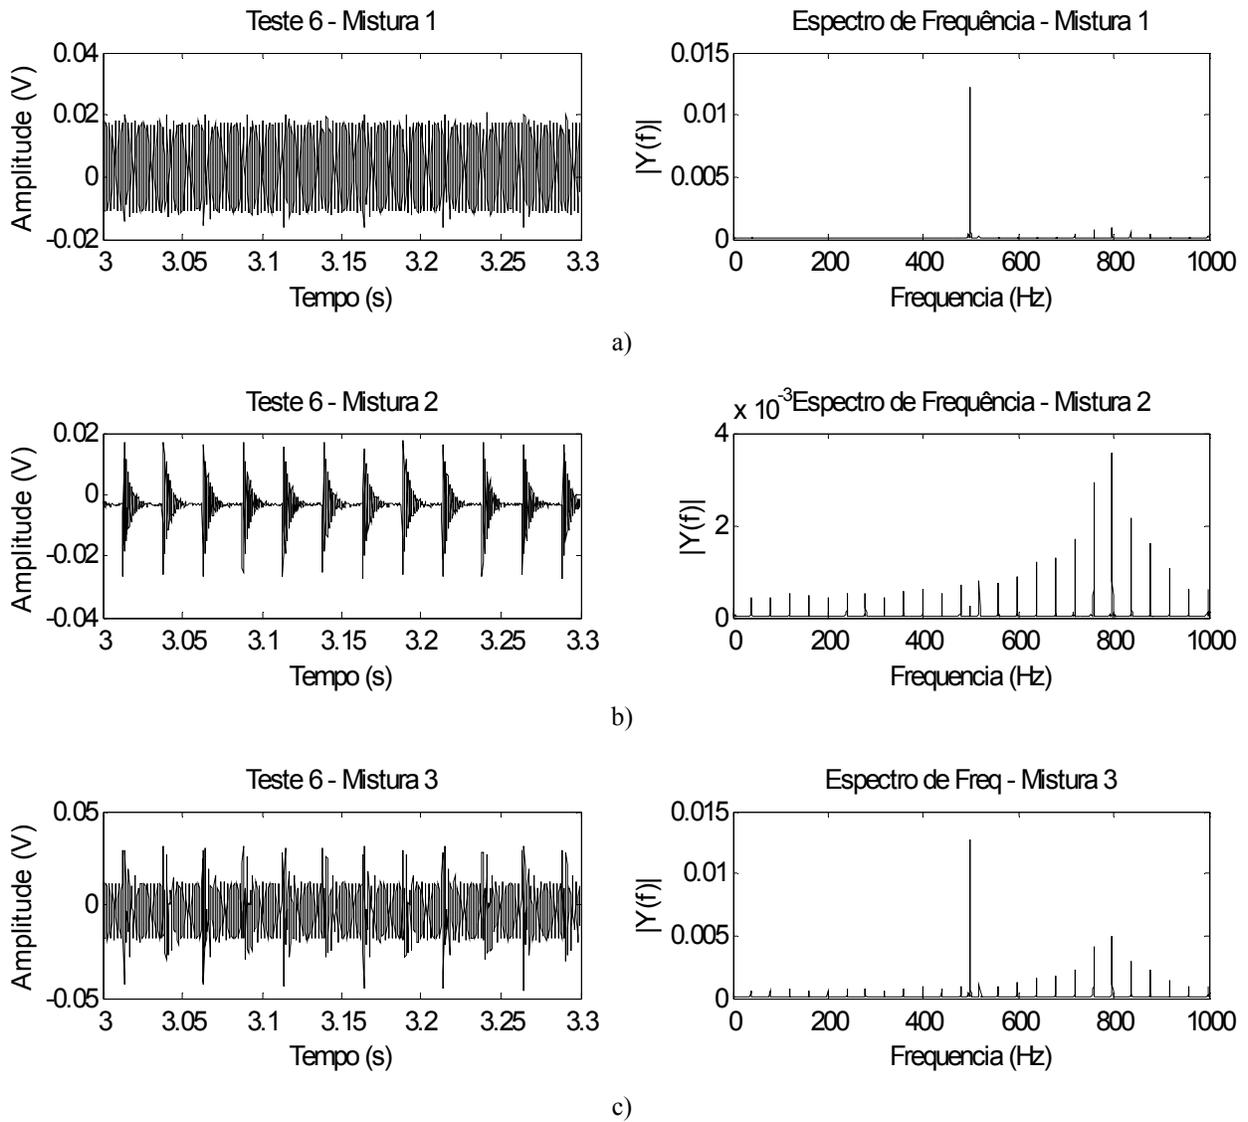
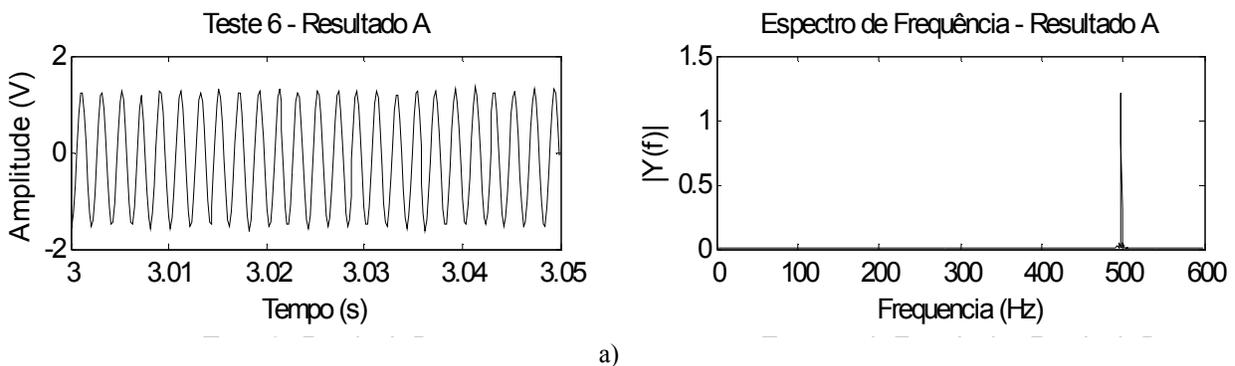


Figura A37 – Três misturas capturadas para o Teste 6, no domínio do tempo e da frequência, que engloba as fontes originais *user3*, senoíde de 500Hz e ruído branco. a) Mistura 1. b) Mistura 2. c) Mistura 3.



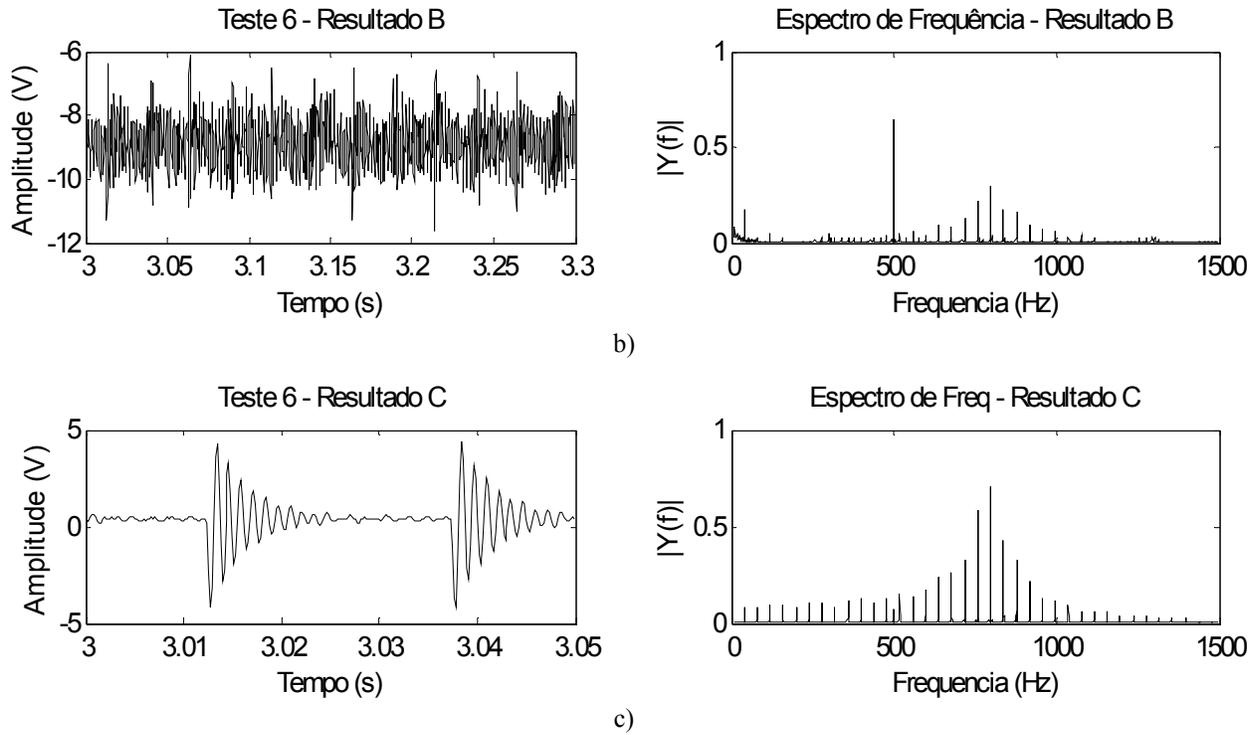
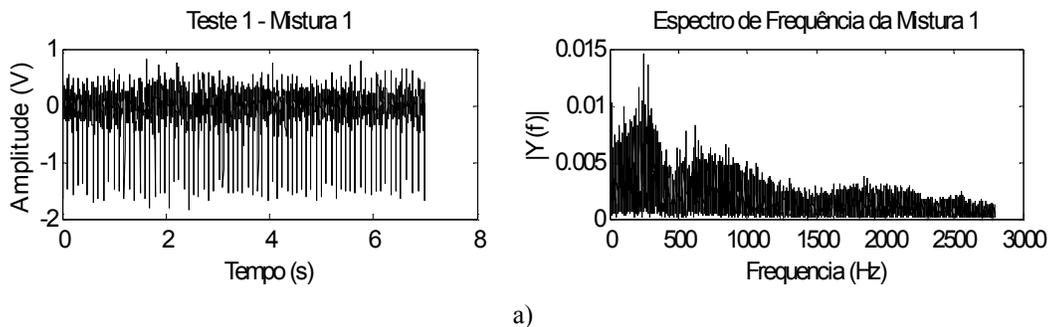


Figura A38 – Três sinais estimados pelo processo de separação para a primeira captura do Teste 6, no domínio do tempo e da frequência, que engloba as fontes originais *user3*, senóide de 500Hz e ruído branco. a) Resultado A separou a senóide de 500Hz. b) Resultado B separou o ruído. c) Resultado C separou a *user3*.

As Figuras A39 a A46 mostram os resultados do processo de mistura e separação dos sinais EMG no domínio do tempo e frequência. No texto principal, foram mostrados os sinais no domínio do tempo e frequência do segundo teste. As Figuras A39 a A46 mostram os sinais para os outros quatro testes. As Figuras mostram dois gráficos: o gráfico à esquerda mostra o valor da SIR entre as fontes originais e os sinais misturados; o gráfico à direita mostra o resultado da separação de fontes, ou seja, valor da SIR entre as fontes originais e as fontes estimadas, além de mostrar o valor da correlação entre as fontes originais e fontes estimadas.

As Figura A39 e A40 mostram, respectivamente, as quatro misturas geradas e os quatro sinais EMG estimados pelo processo de separação para o Teste 1 da separação de sinais EMG.



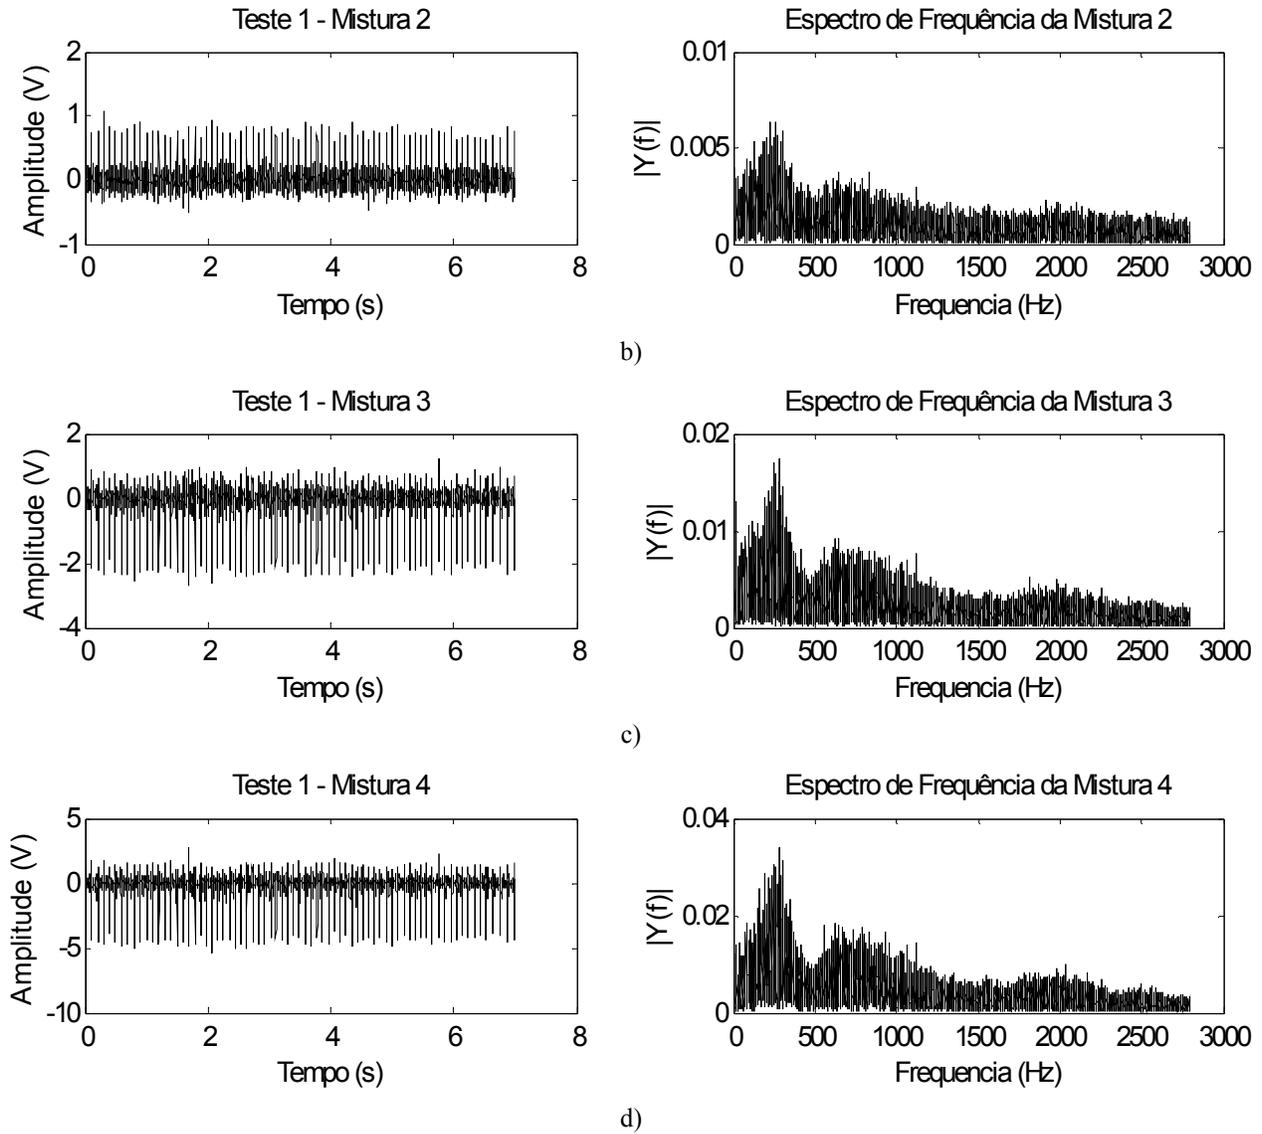
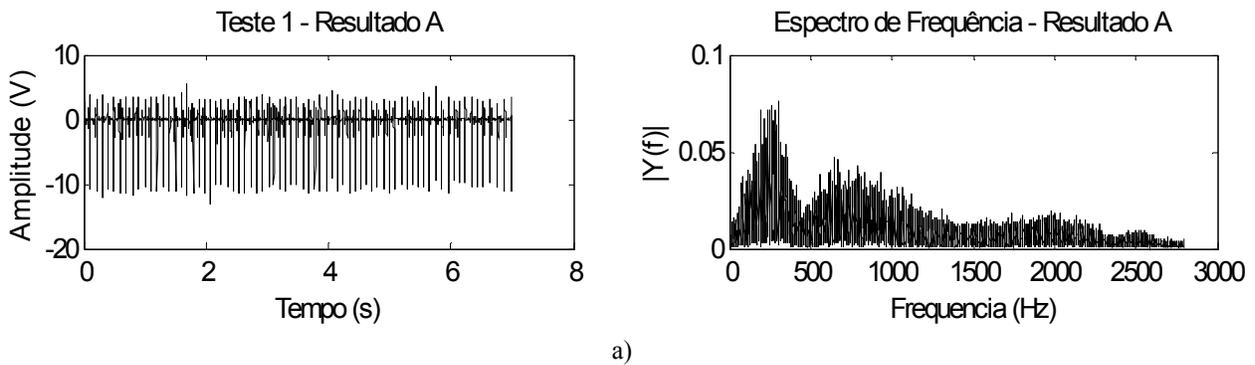


Figura A39 – Quatro misturas geradas com os sinais mostrados na Figura 4.18 para o primeiro teste da separação de sinais EMG, no domínio do tempo e da frequência. a) Mistura 1. b) Mistura 2. c) Mistura 3. d) Mistura 4.



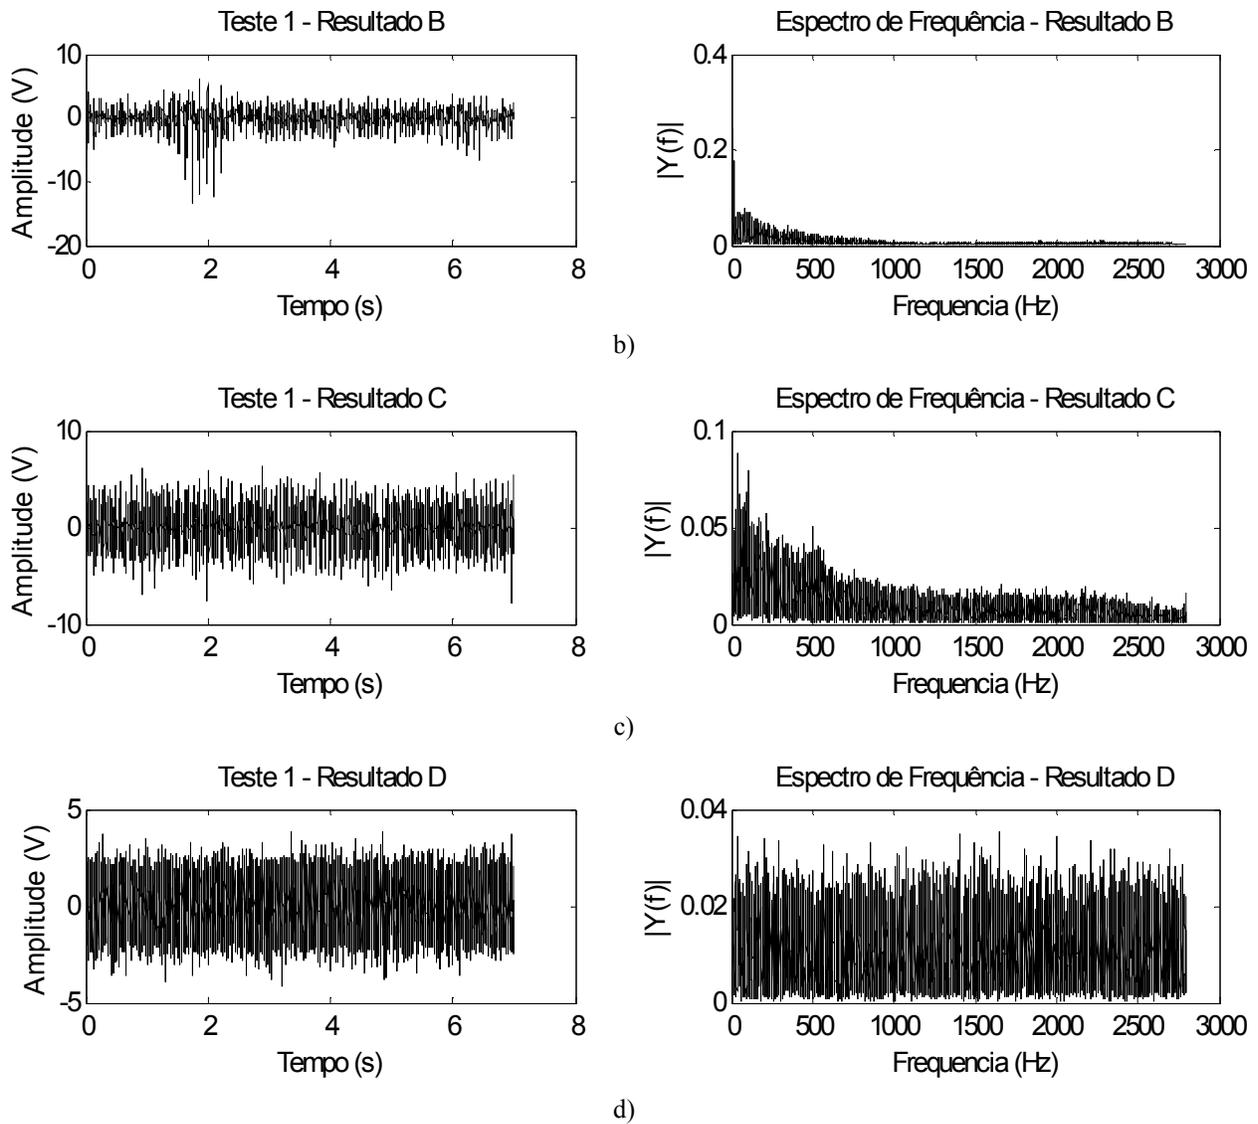
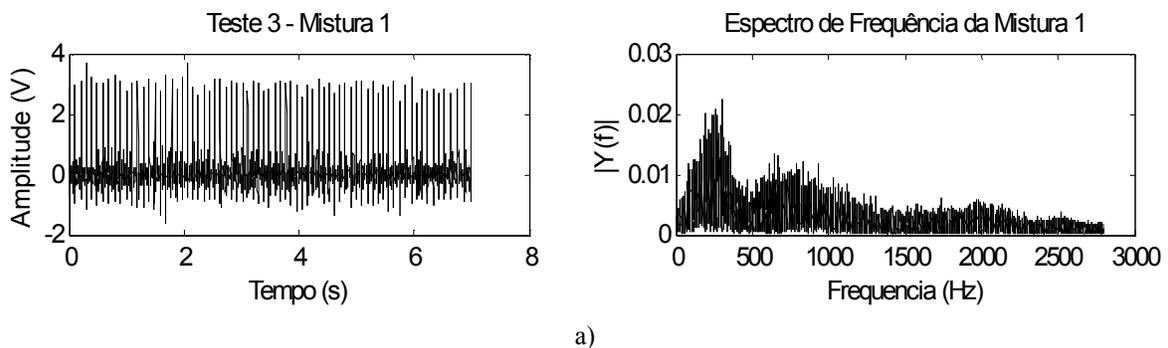


Figura A40 – Quatro sinais EMG estimados para o primeiro teste da separação de sinais EMG, no domínio do tempo e da frequência. a) Resultado A separou o sinal EMG com neuropatia. b) Resultado B separou o sinal EMG saudável. c) Resultado C separou o sinal EMG com miopatia. d) Resultado D separou ruído branco.

As Figura A41 e A42 mostram, respectivamente, as quatro misturas geradas e os quatro sinais EMG estimados pelo processo de separação para o Teste 3 da separação de sinais EMG.



a)

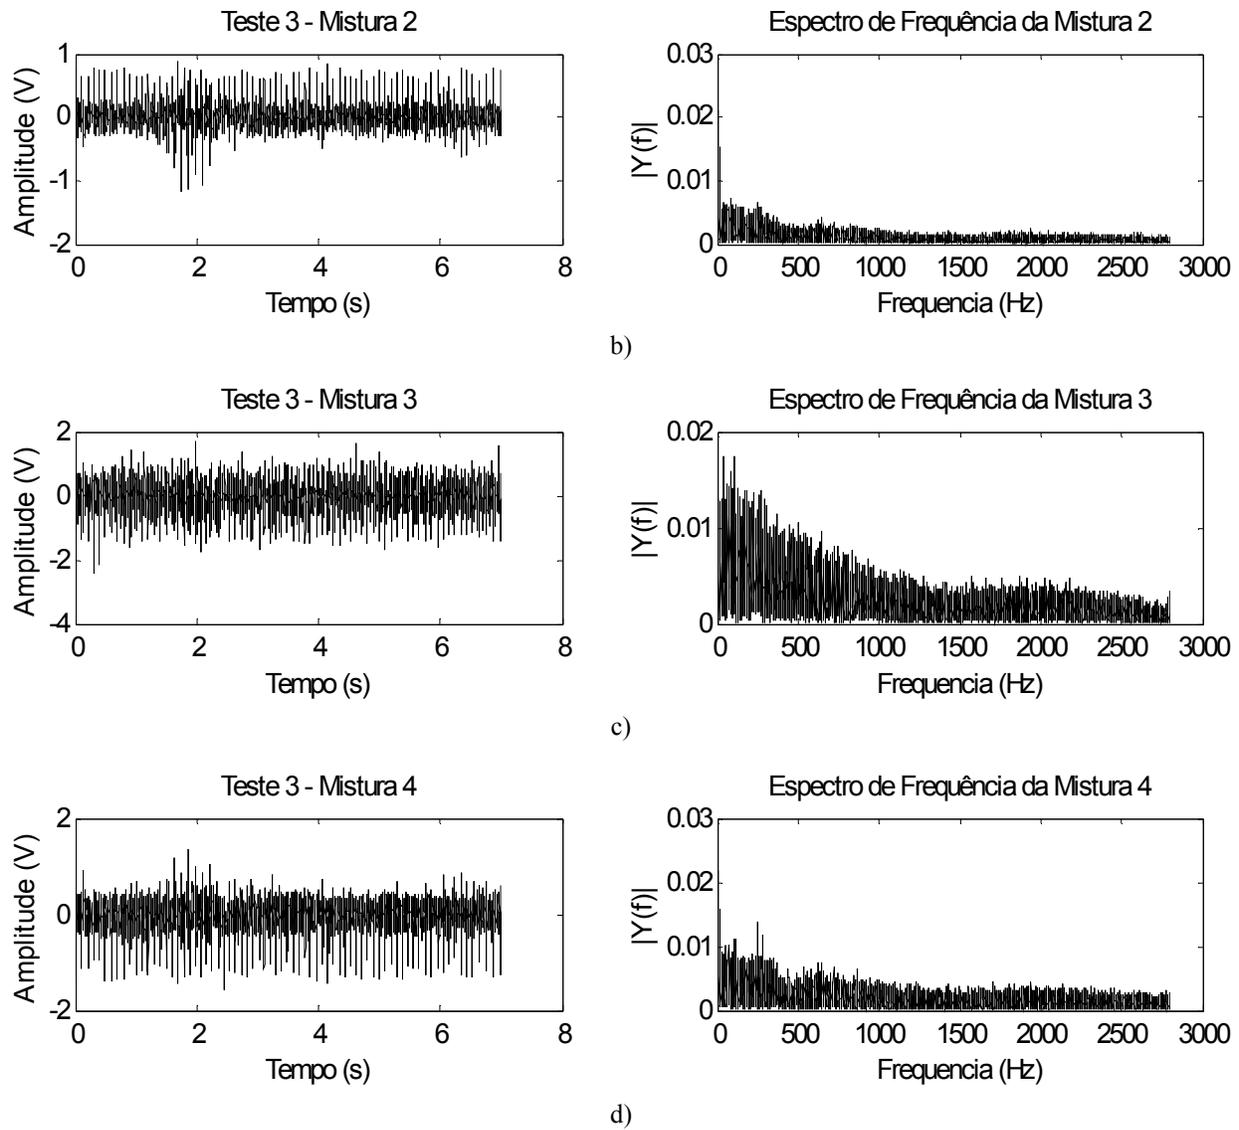
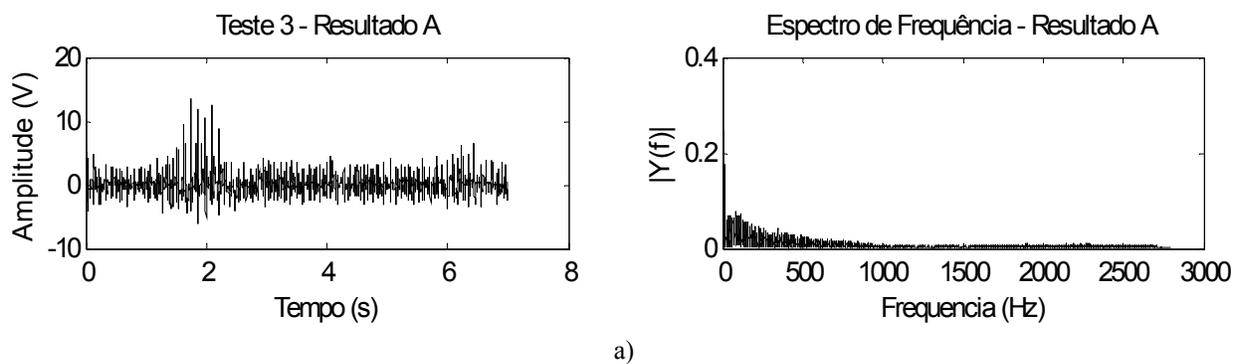


Figura A41 – Quatro misturas geradas com os sinais mostrados na Figura 4.18 para o terceiro teste da separação de sinais EMG, no domínio do tempo e da frequência. a) Mistura 1. b) Mistura 2. c) Mistura 3. d) Mistura 4.



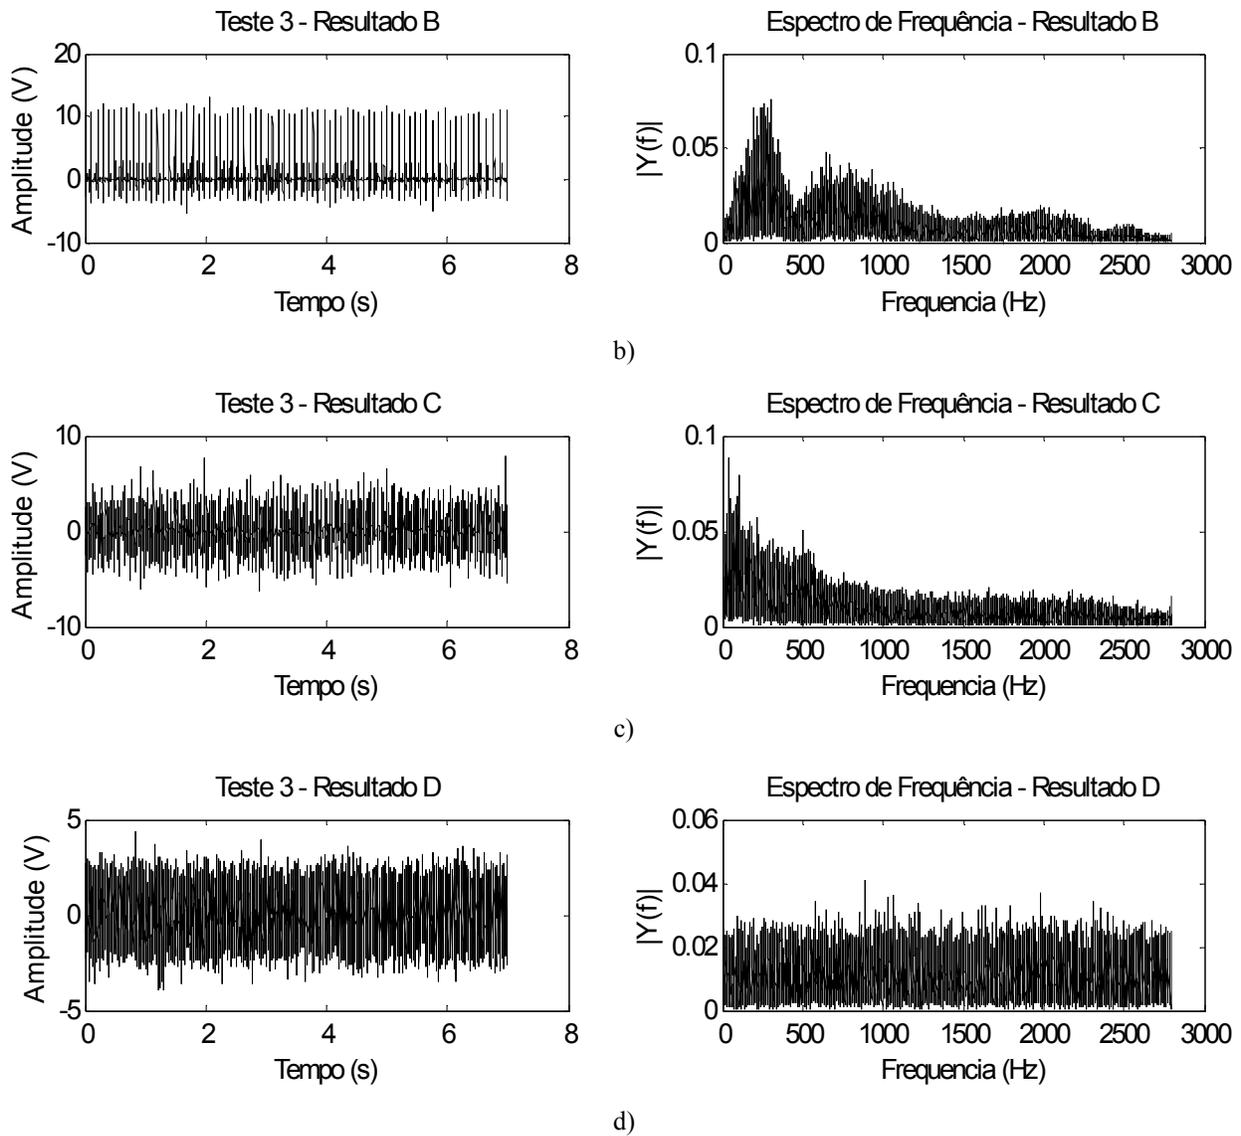
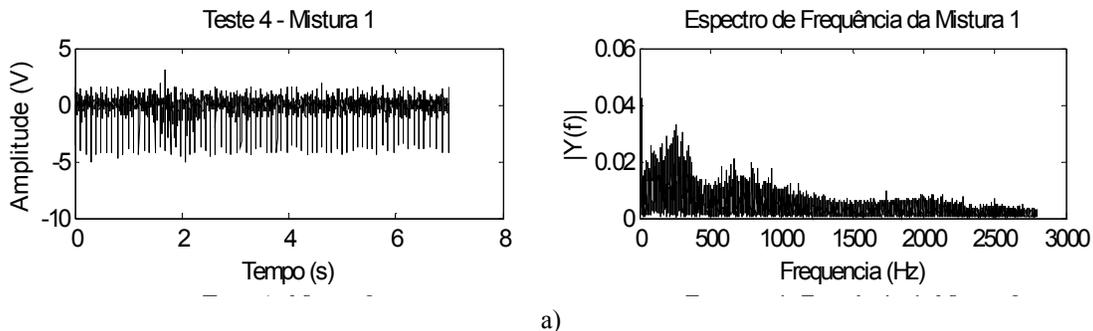
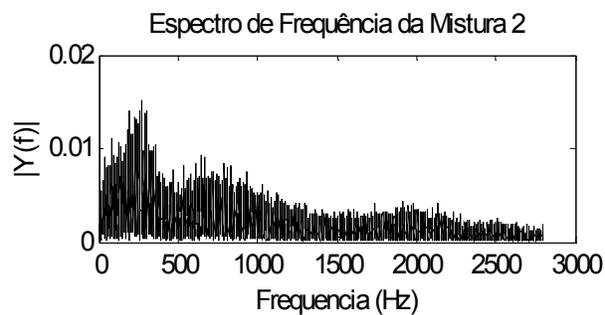
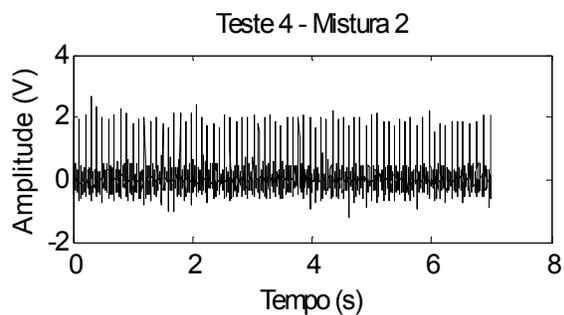


Figura A42 – Quatro sinais EMG estimados para o terceiro teste da separação de sinais EMG, no domínio do tempo e da frequência. a) Resultado A separou o sinal EMG saudável. b) Resultado B separou o sinal EMG com neuropatia. c) Resultado C separou o sinal EMG com miopatia. d) Resultado D separou ruído branco.

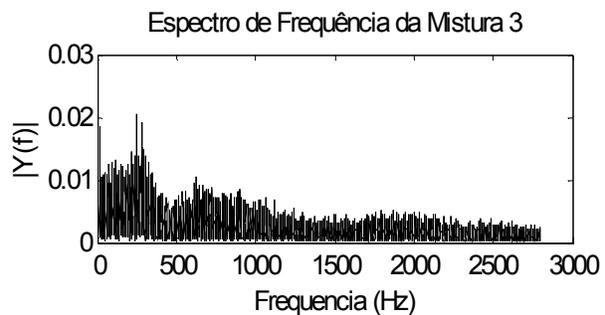
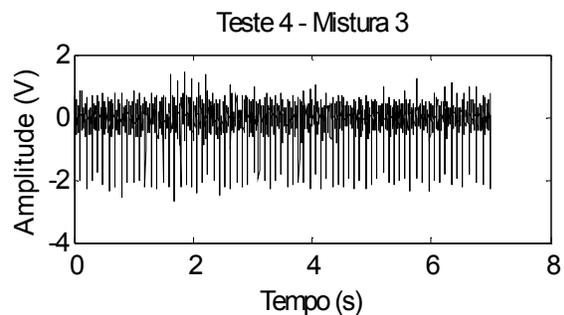
As Figura A43 e A44 mostram, respectivamente, as quatro misturas geradas e os quatro sinais EMG estimados pelo processo de separação para o Teste 4 da separação de sinais EMG.



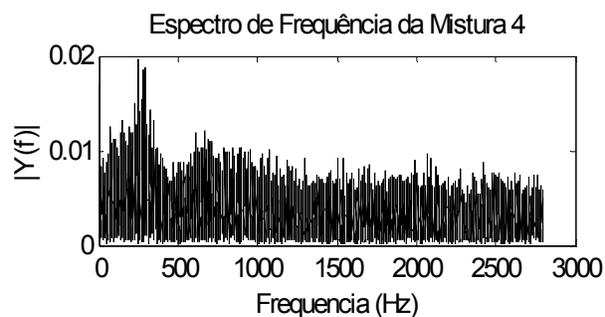
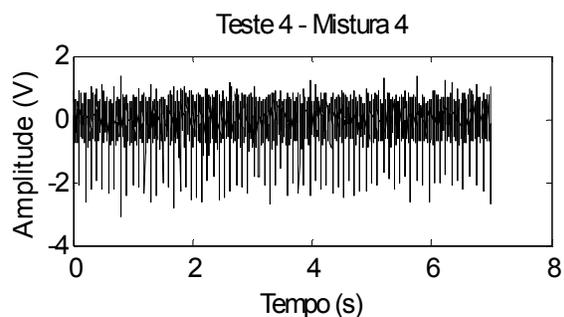
a)



b)

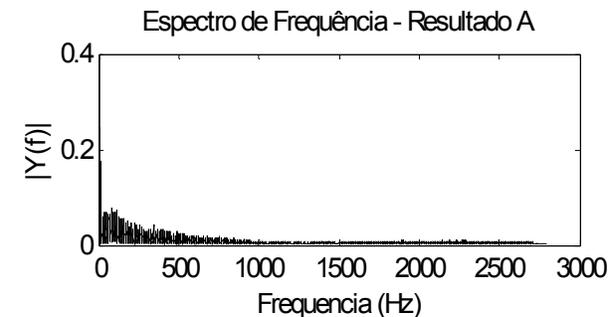
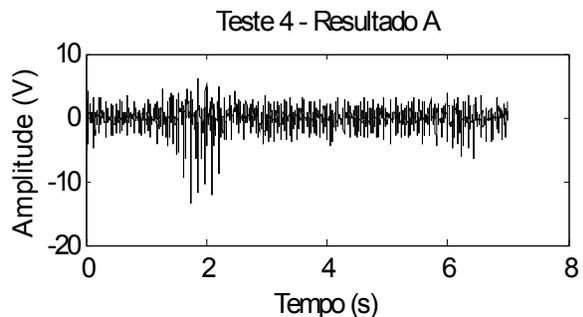


c)



d)

Figura A43 – Quatro misturas geradas com os sinais mostrados na Figura 4.18 para o quarto teste da separação de sinais EMG, no domínio do tempo e da frequência. a) Mistura 1. b) Mistura 2. c) Mistura 3. d) Mistura 4.



a)

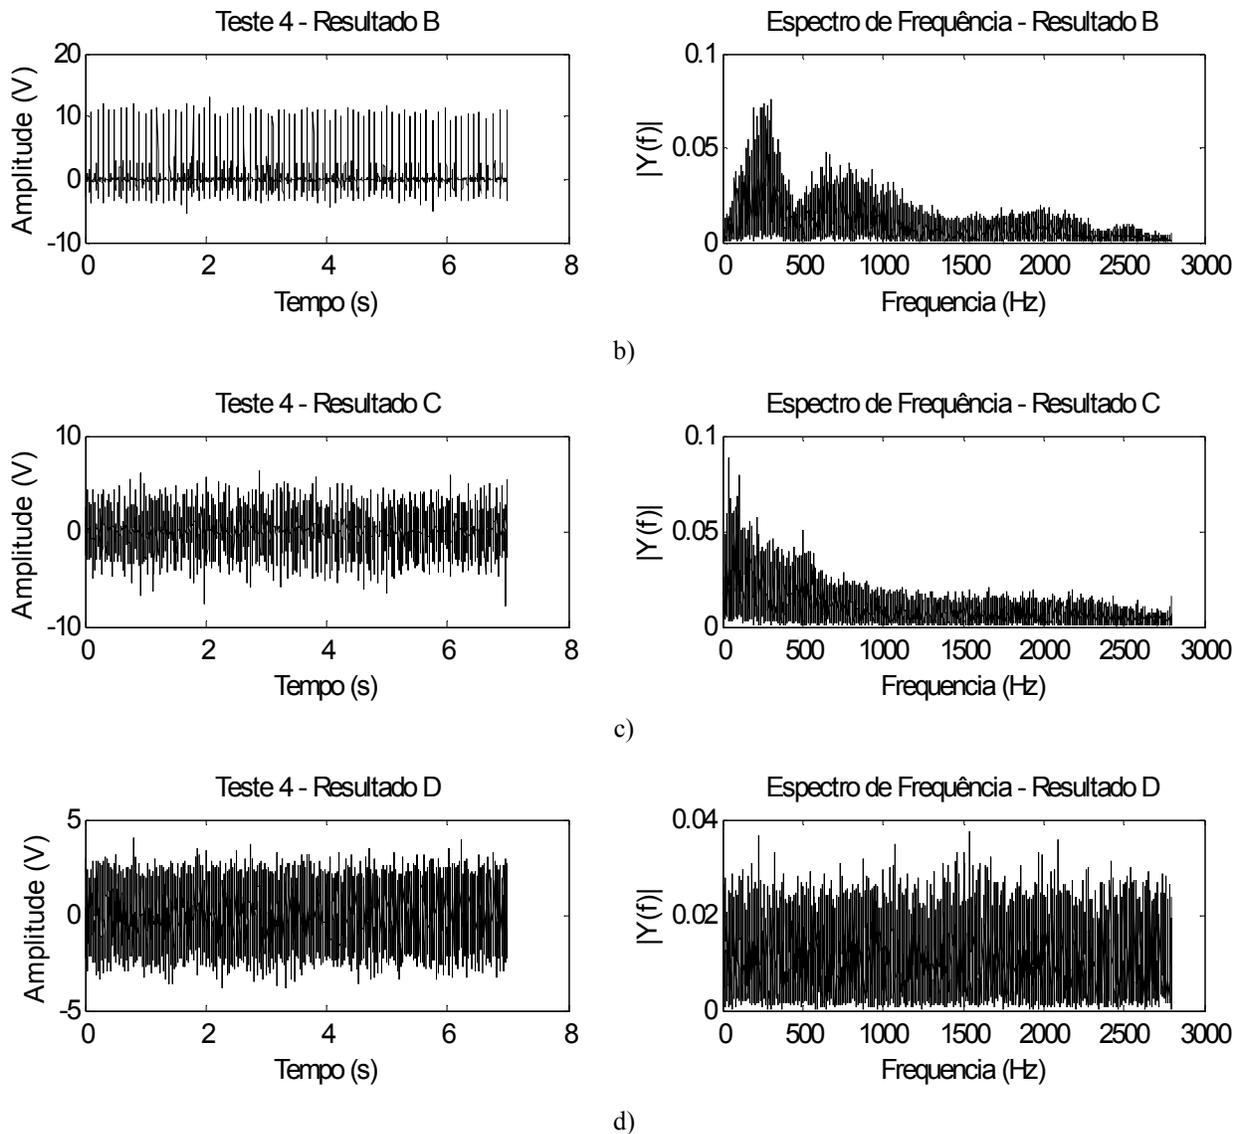
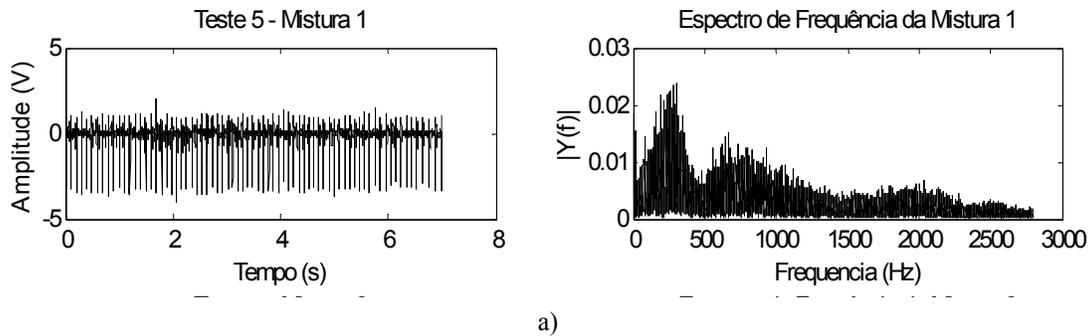
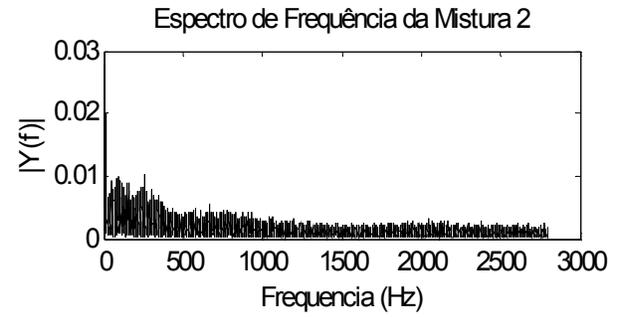
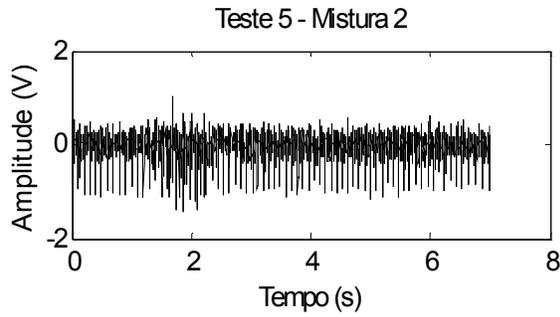


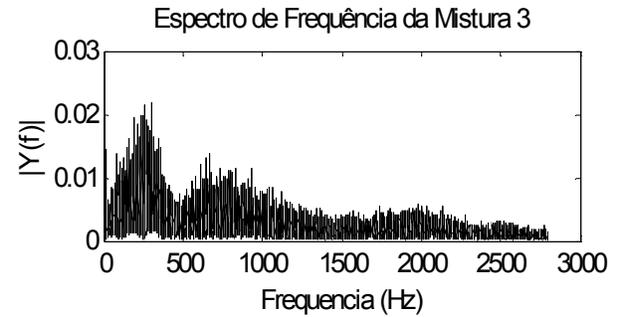
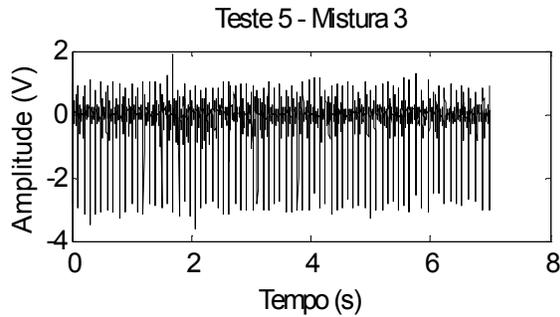
Figura A44 – Quatro sinais EMG estimados para o quarto teste da separação de sinais EMG, no domínio do tempo e da frequência. a) Resultado A separou o sinal EMG saudável. b) Resultado B separou o sinal EMG com neuropatia. c) Resultado C separou o sinal EMG com miopatia. d) Resultado D separou ruído branco.

As Figura A45 e A46 mostram, respectivamente, as quatro misturas geradas e os quatro sinais EMG estimados pelo processo de separação para o Teste 5 da separação de sinais EMG.

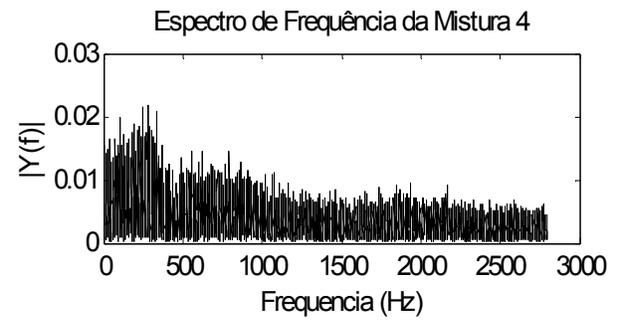
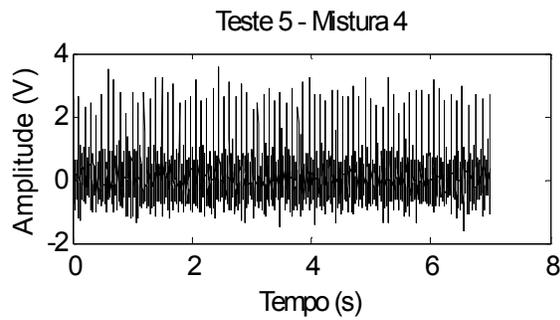




b)

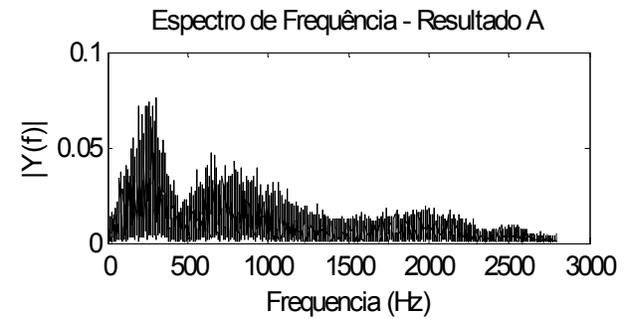
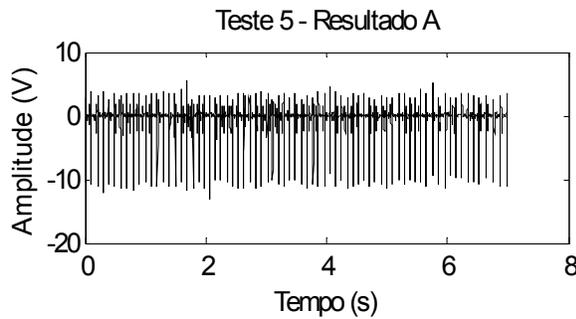


c)



d)

Figura A45 – Quatro misturas geradas com os sinais mostrados na Figura 4.18 para o quinto teste da separação de sinais EMG, no domínio do tempo e da frequência. a) Mistura 1. b) Mistura 2. c) Mistura 3. d) Mistura 4.



a)

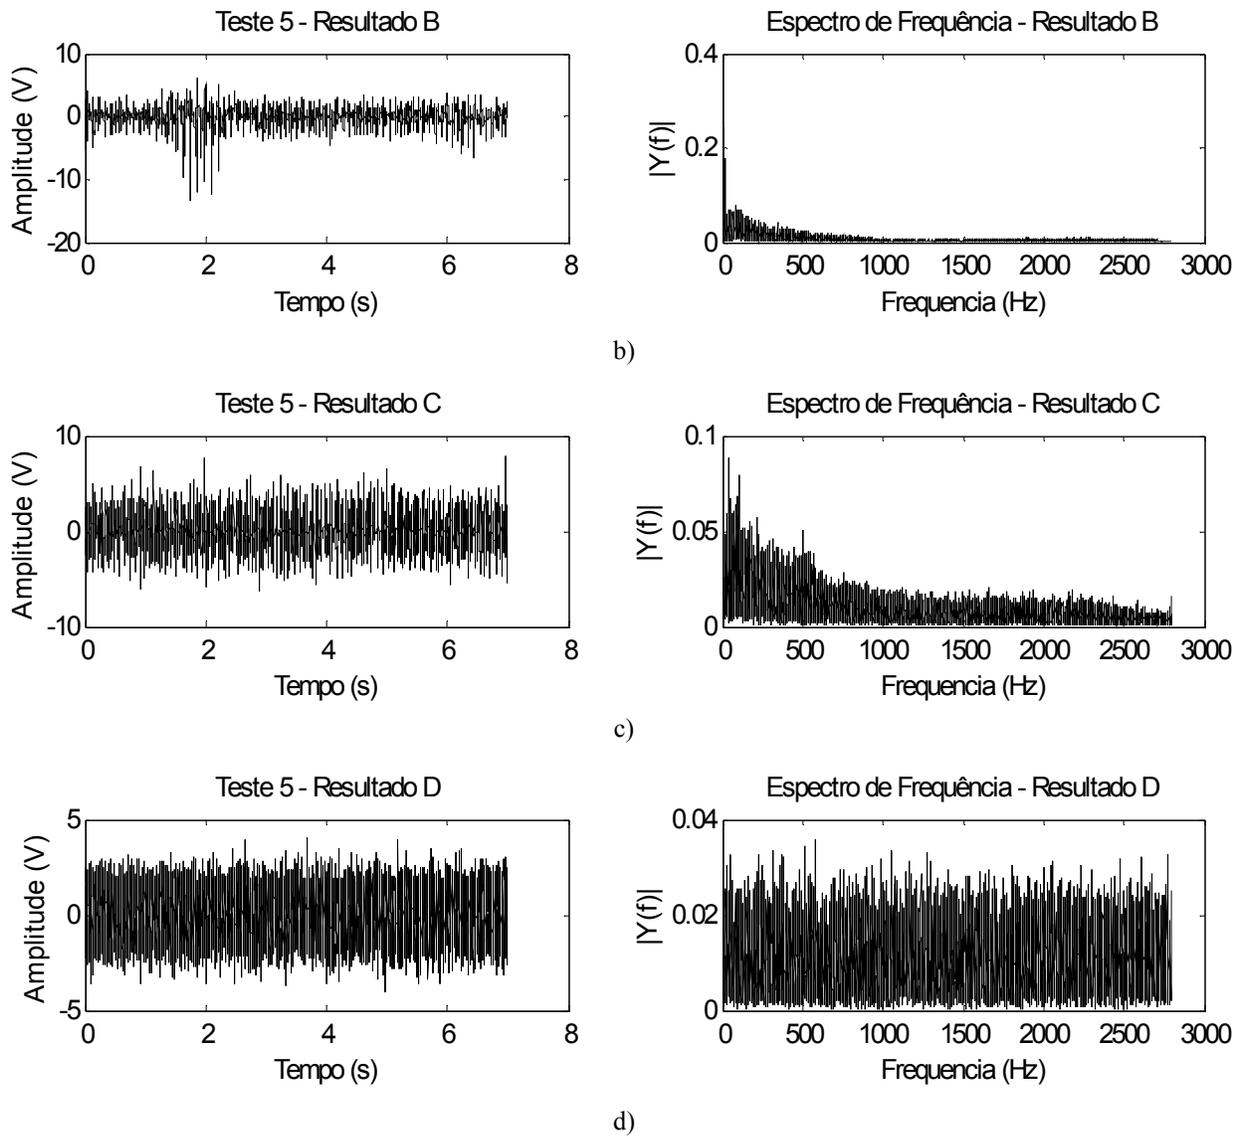


Figura A46 – Quatro sinais EMG estimados para o quinto teste da separação de sinais EMG, no domínio do tempo e da frequência. a) Resultado A separou o sinal EMG com neuropatia. b) Resultado B separou o sinal EMG saudável. c) Resultado C separou o sinal EMG com miopatia. d) Resultado D separou ruído branco.