Marcelo Antônio Alves Lima

# Uma Nova Metodologia para Análise da Qualidade da Energia Elétrica sob Condições de Ocorrência de Múltiplos Distúrbios

Tese apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Doutor em Ciências pelo Programa de Engenharia Elétrica.

Área de Concentração: Sistemas Elétricos de Potência
Orientador: Prof. Tit. Denis Vinicius Coury

Co-orientador: Prof. Dr. Augusto Santiago Cerqueira

São Carlos
2013

**Trata-se da versão corrigida da tese. A versão original se encontra disponível na EESC/USP que aloja o Programa de Pós-Graduação de Engenharia Elétrica.**

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Lima, Marcelo Antônio Alves
L732u Uma nova metodologia para análise da qualidade da energia elétrica sob condições de ocorrência de múltiplos distúrbios / Marcelo Antônio Alves Lima; orientador Denis Vinicius Coury; coorientador Augusto Santiago Cerqueira. São Carlos, 2013.

Tese (Doutorado) - Programa de Pós-Graduação em Engenharia Elétrica e Área de Concentração em Sistemas Elétricos de Potência -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2013.

1. Qualidade da energia elétrica. 2. Múltiplos distúrbios. 3. Separação cega de fontes. 4. Análise de componentes independentes. 5. Filtragem adaptativa. 6. Redes neurais artificiais. I. Título.

## FOLHA DE JULGAMENTO

Candidato: Engenheiro **MARCELO ANTÔNIO ALVES LIMA.**

Título da tese: "Uma nova metodologia para análise da qualidade da energia elétrica sob condições de ocorrência de múltiplos distúrbios".

Data da defesa: 14/10/2013

| **Comissão Julgadora:** | **Resultado:** |
|---|---|
| Prof. Titular **Denis Vinicius Coury (Orientador)**<br>(Escola de Engenharia de São Carlos/EESC) | APROVADO |
| Prof. Dr. **Augusto Santiago Cerqueira**<br>(Universidade Federal de Juiz de Fora) | APROVADO |
| Prof. Dr. **Antônio Padilha Feltrin**<br>(Universidade Estadual Paulista "Júlio de Mesquita Filho"/UNESP-Ilha Solteira) | APROVADO |
| Prof. Titular **Nelson Kagan**<br>(Escola Politécnica/USP) | APROVADO |
| Prof. Dr. **Washington Luiz Araújo Neves**<br>(Universidade Federal de Campina Grande) | APROVADO |

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica e Presidente da Comissão de Pós-Graduação:
Prof. Titular **Denis Vinicius Coury**

# Dedicatória

Dedico este trabalho ao meu avô Raimundo Feliciano Alves (*in memoriam*), com quem aprendi que as coisas simples da vida são as que trazem a verdadeira felicidade.

# Agradecimentos

A Deus, por ter me proporcionado força, dedicação, respeito e sabedoria para realizar este trabalho.

À minha esposa Tatiana, pelo amor, apoio, carinho e bons conselhos.

A meus pais, Márcio e Eva, por todo o amor incondicional, apoio, carinho e educação.

Ao meu orientador, Prof. Denis Vinicius Coury, e ao meu co-orientador, Prof. Augusto Santiago Cerqueira, por confiarem no meu trabalho e na minha dedicação.

Ao Laboratório de Sistemas de Energia Elétrica (LSEE), pela acomodação e infra-estrutura disponibilizados no desenvolvimento deste trabalho.

A todos os amigos do LSEE, pela amizade, troca de experiências e momentos de descontração. Em especial, a Daniel Motter, Etienne, Hermes, Janison, Sérgio Pitombo e Ulisses.

Ao Departamento de Engenharia Elétrica e de Computação da Escola de Engenharia de São Carlos, Universidade de São Paulo.

Ao CNPq, pelo suporte financeiro proporcionado para o desenvolvimento deste trabalho.

# Sumário

**Lista de Siglas** **ix**

**Lista de Tabelas** **xiii**

**Lista de Figuras** **xv**

**Resumo** **xxv**

**Abstract** **xxvii**

**1 Introdução** **1**

1.1 Objetivos e contribuições . . . . . 6

1.2 Organização do documento . . . . . 9

**2 Análise de distúrbios na Qualidade da Energia Elétrica** **11**

2.1 Tipos de distúrbios em Qualidade da Energia Elétrica (QEE) . . . . . 11

2.1.1 Transitórios . . . . . 14

2.1.2 Variações de tensão de curta duração . . . . . 16

2.1.3 Variações de tensão de longa duração . . . . . 17

2.1.4 Desequilíbrios . . . . . 18

2.1.5 Distorções da forma de onda . . . . . 18

2.1.6 Flutuações de tensão . . . . . 21

2.1.7 Variações na frequência fundamental . . . . . 21

2.2 Revisão sobre análise de distúrbios de QEE empregando técnicas de Processamento Digital de Sinais (PDS) . . . . . 22

2.2.1 Variações e eventos . . . . . 24

2.2.2 Métodos de PDS para detecção e segmentação de eventos . . . . . 26

2.2.3 Métodos de PDS para caracterizar segmentos de dados de QEE . . . . . 27

2.2.4 Métodos de PDS para classificação de distúrbios de QEE . . . . . 31

2.3 Distúrbios de QEE isolados e múltiplos: Uma formulação do problema . . . . . 35

2.4 Considerações finais do capítulo . . . . . 41

**3 Ferramentas Computacionais Utilizadas 43**

3.1 Análise de Componentes Independentes . . . . . 43

3.1.1 Motivação . . . . . 43

3.1.2 Definição da *Independent Component Analysis* (ICA) . . . . . 44

3.1.3 Restrições da ICA . . . . . 45

3.1.4 Indeterminações da ICA . . . . . 47

3.1.5 Aplicações de técnicas baseadas em estatísticas de segunda ordem à ICA como etapa de pré-processamento . . . . . 48

3.1.6 Funções objetivo utilizadas como medida de independência estatística . . 50

3.1.7 Aplicações da ICA em Sistema Elétrico de Potência (SEP) e QEE . . . . 56

3.2 Redes Neurais Artificiais . . . . . 58

3.2.1 O neurônio artificial . . . . . 59

3.2.2 Arquiteturas de Rede Neural Artificials (RNAs) . . . . . 61

3.2.3 *Perceptron* de múltiplas camadas . . . . . 61

3.3 Considerações finais do capítulo . . . . . 65

**4 Métodos de aplicação da ICA para canal único 67**

4.1 Introdução . . . . . 67

4.2 Método Filtros-ICA (FICA) . . . . . 68

4.2.1 Projeto do banco de filtros para gerar os sinais de observação . . . . . 73

4.2.2 Estimação das escalas dos componentes independentes . . . . . 74

4.2.3 Filtros adaptativos resultantes da aplicação do método FICA . . . . . 79

4.2.4 Exemplo de aplicação . . . . . 82

4.3 Método *Single Channel Independent Component Analysis* (SCICA) . . . . . 90

4.3.1 Exemplo de aplicação . . . . . 103

4.4 Considerações finais do capítulo . . . . . 107

**5 Decomposição de sinais contendo múltiplos distúrbios de QEE utilizando-se os métodos FICA e SCICA 109**

5.1 Sistema proposto empregando o método FICA . . . . . 109

5.1.1 Filtro *Notch* . . . . . 110

5.1.2 Projeto do banco de filtros fixos do método FICA . . . . . 112

5.2 Sistema proposto empregando o método SCICA . . . . . 114

5.2.1 Projeto do sistema . . . . . 115

5.3 Aplicação dos sistemas propostos na decomposição de sinais contendo múltiplos distúrbios de QEE . . . . . 117

5.3.1 Geração de dados sintéticos . . . . . 117
5.3.2 Aplicação das metodologias de decomposição propostas em dados sintéticos 124
5.3.3 Aplicação das metodologias propostas em dados reais . . . . . 172
5.4 Considerações finais do capítulo . . . . . 179

**6 Classificação de múltiplos distúrbios de QEE 181**

6.1 Sistema para classificação de distúrbios decompostos pela metodologia baseada no método FICA . . . . . 182
6.1.1 Classificador do distúrbio do sinal $f[n]$ . . . . . 183
6.1.2 Classificador dos distúrbios do sinal $x[n]$ . . . . . 189
6.2 Sistema para classificação de distúrbios decompostos pela metodologia baseada no método SCICA . . . . . 191
6.2.1 Classificador do distúrbio do sinal $f[n]$ . . . . . 192
6.2.2 Classificador dos distúrbios do sinal $x[n]$ . . . . . 192
6.3 Geração dos dados . . . . . 193
6.3.1 Geração dos padrões para treinamento e teste do classificador de distúrbios do componente fundamental . . . . . 194
6.3.2 Geração dos padrões para treinamento e teste do classificador de distúrbios do sinal de erro . . . . . 196
6.4 Projeto, treinamento e teste das RNAs dos classificadores . . . . . 207
6.4.1 RNA responsável pela classificação dos distúrbios do componente fundamental . . . . . 207
6.4.2 RNA responsável pela classificação dos distúrbios do sinal de erro - metodologia baseada no método FICA . . . . . 212
6.4.3 RNA responsável pela classificação dos distúrbios do sinal de erro - metodologia baseada no método SCICA . . . . . 215
6.5 Considerações finais do capítulo . . . . . 221

**7 Conclusões 223**

7.1 Propostas de continuidade da pesquisa . . . . . 228

**Referências Bibliográficas 239**

**A Produção científica relacionada a esta pesquisa 241**

A.1 Artigos publicados em periódicos internacionais . . . . . 241
A.2 Artigos publicados em congressos internacionais . . . . . 241
A.3 Artigos publicados em congressos nacionais . . . . . 242

# Lista de Siglas

**ANEEL** Agência Nacional de Energia Elétrica

**BSS** *Blind Source Separation*

**CA** Corrente Alternada

**CAD** Conversor Analógico Digital

**CC** Corrente Contínua

**DFT** *Discrete Fourier Transform*

**DSP** *Digital Signal Processor*

**EEG** *Electroencephalogram*

**EMD** Empirical-Mode Decomposition

**EQM** Erro Quadrático Médio

**FastICA** *Fast Fixed-point Algorithm for Independent Component Analysis*

**FDR** *Fisher Discriminant Ratio*

**FFT** *Fast Fourier Transform*

**FICA** Filtros-ICA

**FIR** *Finite-duration Impulse Response*

**FP** Fator de Potência

**GD** Geração Distribuída

**HOS** *Higher Order Statistics*

**IA** Inteligência Artificial

**ICA** *Independent Component Analysis*

**IEEE** *Institute of Electrical and Electronics Engineers*

**IIR** *Infinite-duration Impulse Response*

**LF** Lógica *Fuzzy*

**LMS** *Least Mean Square*

**LS** *Least Squares*

**LSEE** Laboratório de Sistemas de Energia Elétrica

**MICA** *Multi-dimensional Independent Component Analysis*

**MUSIC** *Multiple Signal Classification*

**PCA** *Principal Component Analysis*

**PDS** Processamento Digital de Sinais

**PMC** *Perceptron* de Múltiplas Camadas

**PRODIST** Procedimentos de Distribuição

**PSO** *Particle Swarm Optimization*

**QEE** Qualidade da Energia Elétrica

**RBDT** *Rule-based Decision Tree*

**RMS** *Root Mean Square*

**RNA** Rede Neural Artificial

**RRMSE** *Relative Root Mean Square Error*

**SCICA** *Single Channel Independent Component Analysis*

**SEP** Sistema Elétrico de Potência

**SF** Sistema *Fuzzy*

**SNR** *Signal-to-Noise Ratio*

**STFT** *Short Time Fourier Transform*

**SVM** *Support Vector Machine*

**THD** *Total Harmonic Distortion*

**TWD** Transformada *Wavelet* Discreta

# Lista de Tabelas

2.1 Categorias e características típicas de fenômenos eletromagnéticos em SEPs. . . . 13

6.1 Tipos e quantidades de sinais gerados para treinamento e teste do sistema de classificação para cada tipo de distúrbio isolado. . . . . 194

6.2 Tipos e quantidades de sinais gerados para treinamento e teste do sistema de classificação para cada combinação de distúrbios múltiplos. . . . . 194

6.3 Codificação das classes de saída do classificador de distúrbios do componente fundamental. . . . . 197

6.4 Faixas de frequências para o cálculo das energias a comporem o vetor de características a ser fornecido como entrada para o módulo classificador. . . . . 198

6.5 Codificação das classes de saída do classificador de distúrbios do sinal de erro. . . 201

6.6 Taxa de classificação e eficiência global obtidas pelo classificador de distúrbios do componente fundamental, para o conjunto de teste. . . . . 212

6.7 Taxa de classificação e eficiência global (%) obtidas pelos classificadores de distúrbios no sinal de erro, para o conjunto de teste. . . . . 220

# Lista de Figuras


2.1 Papel do processamento de sinais na extração de informação a partir dos dados de QEE. . . . . 24

2.2 Exemplo de ocorrência de múltiplos distúrbios; (a) Sinal de corrente monitorado $u[n]$, (b) Componente fundamental estimado $f[n]$ e, (c) sinal de erro $x[n] = u[n] - f[n]$. . . . . 38

3.1 Diagrama de blocos da *Blind Source Separation* (BSS). . . . . 45

3.2 Processo de mistura e separação da ICA. . . . . 51

3.3 Modelo do neurônio artificial. . . . . 59

3.4 Exemplo de rede *Perceptron* de Múltiplas Camadas (PMC). . . . . 62

4.1 Diagrama de blocos do sistema proposto para geração dos sinais de observação para a ICA. . . . . 69

4.2 Representação de um sistema de fase linear como uma cascata de um filtro de amplitude e um deslocamento no tempo. . . . . 72

4.3 Diagrama de blocos do combinador linear adaptativo para estimação das escalas dos componentes independentes. . . . . 75

4.4 Diagrama de blocos do algoritmo FICA completo. . . . . 78

4.5 Diagrama de blocos do filtro linear adaptativo que obtém o $p$-ésimo sinal de saída a partir do sinal de entrada $x[n]$. . . . . 80

4.6 Diagrama de blocos do banco de filtros lineares adaptativos que obtém o $P$ sinais de saída e reconstrói o sinal de entrada. . . . . 81

4.7 Formas de onda das fontes e do sinal de mistura; (a) fonte $s_1[n]$, (b) fonte $s_2[n]$ e, (c) mistura $x[n]$. . . . . 83

4.8 Módulos das respostas em frequência dos filtros $h_1[n]$ e $h_2[n]$, e módulo da transformada de Fourier do sinal $x[n]$. . . . . 83

4.9 Fases das respostas em frequência dos filtros $h_1[n]$ e $h_2[n]$ em (a), e, em (b) seus respectivos atrasos de grupo. . . . . 84

4.10 Sinais de observação $x_1[n]$ e $x_2[n]$ obtidos a partir da filtragem do sinal $x[n]$ através dos filtros $h_1[n]$ e $h_2[n]$; (a) $x_1[n]$ e, (b) $x_2[n]$. . . . . 85

4.11 Componentes independentes $y_1[n]$ e $y_2[n]$ estimados pela ICA; (a) $y_1[n]$ e, (b) $y_2[n]$. 86

4.12 Comportamento do erro quadrático médio em função das épocas de ajuste. . . . 87

4.13 Componentes independentes com suas escalas estimadas pelo combinador linear adaptativo; (a) $y_{\mathrm{rec}_1}[n]$ e, (b) $y_{\mathrm{rec}_2}[n]$. . . . . 88

4.14 Comparação entre o sinal reconstruído $g[n]$ e o sinal original $x[n]$. . . . . 88

4.15 Módulos das respostas em frequência dos filtros $f_1[n]$ e $f_2[n]$; (a) $|F_1(e^{j\omega})|$ e, (b) $|F_2(e^{j\omega})|$. . . . . 89

4.16 Representação em diagrama de blocos do esquema de construção da matriz de observações $\mathbf{X}$. . . . . 92

4.17 Diagrama de blocos do filtro linear adaptativo que obtém o $p$-ésimo sinal de saída a partir do sinal de entrada $x[n]$, considerando-se $\tau = 1$. . . . . 94

4.18 Diagrama de blocos do banco de filtros lineares adaptativos que obtém o $P$ sinais de saída a partir do sinal de entrada $x[n]$. . . . . 95

4.19 Diagrama de blocos do filtro linear adaptativo que obtém o sinal $y_s^{(p)}[n]$ a partir do sinal $y_p[n]$. . . . . 96

4.20 Diagrama de blocos do banco de filtros lineares adaptativos que obtém os $P$ sinais de saída a partir do sinal de entrada $x[n]$. . . . . 97

4.21 Diagrama de blocos da etapa de agrupamento dos componentes independentes relacionados a cada uma das fontes. . . . . 102

4.22 Diagrama de blocos do algoritmo SCICA completo. . . . . 103

4.23 Estimativas de componentes independentes com escalas recuperadas. . . . . 104

4.24 Vetores de energias calculados para as estimativas de componentes independentes, com o respectivo agrupamento pelo algoritmo *k-means* baseado em suas similaridades espectrais. . . . . 105

4.25 Componentes separados e reconstruídos utilizando-se o método SCICA; (a) $y_{\mathrm{rec}_1}[n]$ e, (b) $y_{\mathrm{rec}_2}[n]$. . . . . 106

4.26 Módulos das respostas em frequência dos filtros adaptativos resultantes da operação do método SCICA, e espectro de frequências do sinal $x[n]$. . . . . 107

5.1 Diagrama de blocos do sistema proposto baseado no método FICA. . . . . 110

5.2 Diagrama de blocos do filtro *notch*. . . . . 111

5.3 Diagrama de blocos do sistema proposto baseado no método SCICA. . . . . 114

5.4 Sinal de tensão sintético modelando a ocorrência de transitório oscilatório; (a) sinal gerado, (b) componente fundamental e, (c) sinal de distúrbio. . . . . 120

5.5 Sinal de tensão sintético modelando a ocorrência de transitório impulsivo; (a) sinal gerado, (b) componente fundamental e, (c) sinal de distúrbio. . . . . 121

5.6 Sinal de tensão sintético modelando a ocorrência de *notchings*; (a) sinal gerado, (b) componente fundamental e, (c) sinal de distúrbio. . . . . 122

5.7 Sinais de tensão sintéticos modelando variações de tensão; (a) afundamento, (b) elevação e, (c) interrupção. . . . . 124

5.8 Sinal de tensão sintético modelando a ocorrência de harmônicos; (a) sinal gerado, (b) componente fundamental e, (c) sinal de distúrbio. . . . . 125

5.9 Sinal de tensão sintético modelando a ocorrência simultânea de harmônicos e *notchings*; (a) Sinal de tensão monitorado $u[n]$, (b) Estimativa do componente fundamental $f[n]$ e, (c) sinal de erro $x[n] = u[n] - f[n]$. . . . . 126

5.10 Espectros de frequências dos distúrbios originais e do sinal $x[n]$; (a) *notchings* - fonte $s_1[n]$, (b) harmônicos - fonte $s_2[n]$ e, (c) sinal de erro - mistura $x[n]$. . . . . 127

5.11 Módulos das respostas em frequência dos filtros $h_1[n]$ e $h_2[n]$, e espectro de frequências do sinal $x[n]$: *notchings* e harmônicos. . . . . 128

5.12 Estimativas de componentes independentes obtidas pelo método FICA; (a) *notchings* originais, (b) $y_{\mathrm{rec}_1}[n]$, (c) harmônicos originais e, (d) $y_{\mathrm{rec}_2}[n]$. . . . . 129

5.13 Módulos das respostas em frequência dos filtros adaptativos resultantes da operação do método FICA, e espectro de frequências do sinal $x[n]$: *notchings* e harmônicos. . . . . 130

5.14 Coeficiente de correlação entre os distúrbios originais e suas estimativas, em função: (a) da frequência de corte de $h_2[n]$ e, (b) da ordem dos filtros, para o sinal contendo *notchings* e harmônicos. . . . . 131

5.15 Estimativas de componentes independentes obtidas pelo método FICA, quando utilizados $M = 3$ filtros; (a) $y_{\text{rec}_1}[n]$, (b) $y_{\text{rec}_2}[n]$ e, (c) $y_{\text{rec}_3}[n]$. . . . . 133

5.16 Estimativas de componentes independentes com escalas recuperadas: *notchings* e harmônicos. . . . . 134

5.17 Vetores de energias calculados para as estimativas de componentes independentes, com o respectivo agrupamento pelo algoritmo *k-means* baseado em suas similaridades espectrais: *notchings* e harmônicos. . . . . 135

5.18 Componentes separados e reconstruídos utilizando-se o método SCICA; (a) *notchings* originais, (b) $y_{\text{rec}_1}[n]$, (c) harmônicos originais e, (d) $y_{\text{rec}_2}[n]$. . . . . 136

5.19 Módulos das respostas em frequência dos filtros adaptativos resultantes da operação do método SCICA, e espectro de frequências do sinal $x[n]$: *notchings* e harmônicos. . . . . 137

5.20 Coeficiente de correlação entre os distúrbios originais e suas estimativas, em função do número de sinais de observação $M$ gerados pelo método SCICA: *notchings* e harmônicos. . . . . 137

5.21 Componentes separados e reconstruídos utilizando-se o método SCICA, para $C = 3$ *clusters*; (a) $y_{\text{rec}_1}[n]$, (b) $y_{\text{rec}_2}[n]$ e, (c) $y_{\text{rec}_3}[n]$. . . . . 139

5.22 Sinal de tensão sintético modelando a ocorrência simultânea de transitório oscilatório e harmônicos; (a) Sinal de tensão monitorado $u[n]$, (b) Estimativa do componente fundamental $f[n]$ e, (c) sinal de erro $x[n] = u[n] - f[n]$. . . . . 140

5.23 Espectros de frequências dos distúrbios originais e do sinal $x[n]$; (a) transitório oscilatório - fonte $s_1[n]$, (b) harmônicos - fonte $s_2[n]$ e, (c) sinal de erro - mistura $x[n]$. . . . . 140

5.24 Módulos das respostas em frequência dos filtros $h_1[n]$ e $h_2[n]$, e espectro de frequências do sinal $x[n]$: transitório oscilatório e harmônicos. . . . . 142

5.25 Estimativas de componentes independentes obtidas pelo método FICA; (a) transitório oscilatório original, (b) $y_{\text{rec}_1}[n]$, (c) harmônicos originais e, (d) $y_{\text{rec}_2}[n]$. . . 142

5.26 Módulos das respostas em frequência dos filtros adaptativos resultantes da operação do método FICA, e espectro de frequências do sinal $x[n]$: transitório oscilatório e harmônicos. . . . . 143

5.27 Coeficiente de correlação entre os distúrbios originais e suas estimativas, em função: (a) da frequência de corte de $h_2[n]$ e, (b) da ordem dos filtros, para o sinal contendo transitório oscilatório e harmônicos. . . . . 144

5.28 Estimativas de componentes independentes obtidas pelo método FICA, quando utilizados 3 filtros fixos; (a) $y_{\text{rec}_1}[n]$, (b) $y_{\text{rec}_2}[n]$ e, (d) $y_{\text{rec}_3}[n]$. . . . . 145

5.29 Estimativas de componentes independentes com escalas recuperadas: transitório oscilatório e harmônicos. . . . . 146

5.30 Vetores de energias calculados para as estimativas de componentes independentes, com o respectivo agrupamento pelo algoritmo *k-means* baseado em suas similaridades espectrais: transitório oscilatório e harmônicos. . . . . 147

5.31 Componentes separados e reconstruídos utilizando-se o método SCICA; (a) transitório oscilatório original, (b) $y_{\text{rec}_2}[n]$, (c) harmônicos originais e, (d) $y_{\text{rec}_1}[n]$. . . 148

5.32 Módulos das respostas em frequência dos filtros adaptativos resultantes da operação do método SCICA, e espectro de frequências do sinal $x[n]$: transitório oscilatório e harmônicos. . . . . 149

5.33 Coeficiente de correlação entre os distúrbios originais e suas estimativas, em função do número de observações $M$: transitório oscilatório e harmônicos. . . . . 150

5.34 Componentes separados e reconstruídos utilizando-se o método SCICA, para $C = 3$ *clusters*; (a) $y_{\text{rec}_1}[n]$, (b) $y_{\text{rec}_2}[n]$ e, (c) $y_{\text{rec}_3}[n]$. . . . . 150

5.35 Sinal de tensão sintético modelando a ocorrência simultânea de transitório oscilatório, *notchings* e harmônicos; (a) Sinal de tensão monitorado $u[n]$, (b) Estimativa do componente fundamental $f[n]$ e, (c) sinal de erro $x[n] = u[n] - f[n]$. . . . . 152

5.36 Espectros de frequências dos distúrbios originais; (a) transitório oscilatório - fonte $s_1[n]$, (b) *notchings* - fonte $s_2[n]$, (c) harmônicos - fonte $s_3[n]$ e, (d) sinal de erro - mistura $x[n]$. . . . . 152

5.37 Módulos das respostas em frequência dos filtros $h_1[n]$, $h_2[n]$ e $h_3[n]$, e espectro de frequências do sinal $x[n]$: transitório oscilatório, *notchings* e harmônicos. . . . . 153

5.38 Estimativas de componentes independentes obtidas pelo método FICA; (a) transitório oscilatório original, (b) $y_{\mathrm{rec}_3}[n]$, (c) *notchings* originais, (d) $y_{\mathrm{rec}_2}[n]$, (e) harmônicos originais e, (f) $y_{\mathrm{rec}_1}[n]$. . . . . 155

5.39 Módulos das respostas em frequência dos filtros adaptativos resultantes da operação do método FICA, e espectro de frequências do sinal $x[n]$: transitório oscilatório, *notchings* e harmônicos. . . . . 156

5.40 Estimativas de componentes independentes obtidas pelo método FICA, quando utilizados somente 2 filtros fixos; (a) $y_{\mathrm{rec}_1}[n]$ e, (b) $y_{\mathrm{rec}_2}[n]$. . . . . 156

5.41 Estimativas de componentes independentes com escalas recuperadas: transitório oscilatório, *notchings* e harmônicos. . . . . 157

5.42 Vetores de energias calculados para as estimativas de componentes independentes, com o respectivo agrupamento pelo algoritmo *k-means* baseado em suas similaridades espectrais: transitório oscilatório, *notchings* e harmônicos. . . . . 158

5.43 Componentes separados e reconstruídos utilizando-se o método SCICA; (a) transitório oscilatório original, (b) $y_{\mathrm{rec}_3}[n]$, (c) *notchings* originais, (d) $y_{\mathrm{rec}_2}[n]$, (e) harmônicos originais e, (f) $y_{\mathrm{rec}_1}[n]$. . . . . 159

5.44 Módulos das respostas em frequência dos filtros adaptativos resultantes da operação do método SCICA, e espectro de frequências do sinal $x[n]$: transitório oscilatório, *notchings* e harmônicos. . . . . 160

5.45 Componentes separados e reconstruídos utilizando-se o método SCICA, para $C = 2$ *clusters*; (a) $y_{\mathrm{rec}_1}[n]$, (b) $y_{\mathrm{rec}_2}[n]$ e, (c) $y_{\mathrm{rec}_3}[n]$. . . . . 161

5.46 Decomposição de um sinal contendo harmônicos e um transitório impulsivo; (a) sinal de entrada, (b) e (c) resultados obtidos pelo método FICA e, (d) e (e) resultados obtidos pelo método SCICA. . . . . 163

5.47 Decomposição de um sinal contendo *notchings* e transitório impulsivo; (a) sinal de entrada, (b) e (c) resultados obtidos pelo método FICA e, (d) e (e) resultados obtidos pelo método SCICA. . . . . 164

5.48 Decomposição de um sinal contendo transitórios oscilatório e impulsivo; (a) sinal de entrada, (b) e (c) resultados obtidos pelo método FICA e, (d) e (e) resultados obtidos pelo método SCICA. . . . . 165

5.49 Coeficientes de correlação para decomposições de sinais contendo *notchings* e harmônicos; (a) método FICA, (b) método SCICA e, (c) sem decomposição. . . . 166

5.50 Coeficientes de correlação para decomposições de sinais contendo transitório oscilatório e harmônicos; (a) método FICA, (b) método SCICA e, (c) sem decomposição. 167

5.51 Coeficientes de correlação para decomposições de sinais contendo transitório impulsivo e harmônicos; (a) método FICA, (b) método SCICA e (c) sem decomposição. 168

5.52 Coeficientes de correlação para decomposições de sinais contendo transitórios oscilatório e impulsivo; (a) método FICA, (b) método SCICA e, (c) sem decomposição. 169

5.53 Coeficientes de correlação para decomposições de sinais contendo *notchings* e transitório impulsivo; (a) método FICA, (b) método SCICA e, (c) sem decomposição. 170

5.54 Coeficientes de correlação para decomposições de sinais contendo transitório oscilatório e *notchings*; (a) método FICA, (b) método SCICA e, (c) sem decomposição. 171

5.55 Sinal de tensão real medido na entrada de um retificador trifásico de seis pulsos; (a) sinal de entrada $u[n]$ (tensão da fase $A$), (b) estimativa do componente fundamental $f[n]$ e, (c) sinal de erro $x[n] = u[n] - f[n]$. . . . . 173

5.56 Comparação das decomposições do sinal $x[n]$ obtidas pelos métodos FICA e SCICA; (a) e (b) sinais de saída do método FICA, (c) e (d) sinais de saída do método SCICA. . . . . 173

5.57 Comparação dos módulos das respostas em frequência dos filtros adaptativos de decomposição obtidos pelos métodos FICA e SCICA; (a) método FICA e, (b) método SCICA. . . . . 174

5.58 Sinal de corrente real; (a) sinal de entrada $u[n]$, (b) estimativa do componente fundamental $f[n]$ e, (c) sinal de erro $x[n] = u[n] - f[n]$. . . . . 176

5.59 Comparação das decomposições do sinal $x[n]$ obtidas pelos métodos FICA e SCICA; (a), (b) e (c) sinais de saída do método FICA; (d), (e) e (f) sinais de saída do método SCICA. . . . . 177

5.60 Comparação dos módulos das respostas em frequência dos filtros de decomposição adaptativos obtidos pelos métodos FICA e SCICA; (a) método FICA e, (b) método SCICA. . . . . 178

6.1 Diagrama de blocos generalizado do sistema proposto para classificação de distúrbios decompostos pela metodologia baseada no método FICA. . . . . 183

6.2 Estimação do componente fundamental e janelamento de um sinal de tensão apresentando afundamento. . . . . 186

6.3 Diagrama de blocos da etapa de extração de características da estimativa do componente fundamental . . . . . 187

6.4 Diagrama de blocos da etapa de classificação do distúrbio presente no sinal de estimativa do componente fundamental. . . . . 188

6.5 Diagrama de blocos da etapa de extração de características dos sinais resultantes da decomposição realizada pelo método FICA. . . . . 189

6.6 Diagrama de blocos da etapa de classificação de distúrbios nos sinais resultantes da decomposição realizada pelo método FICA. . . . . 191

6.7 Diagrama de blocos generalizado do sistema proposto para classificação de distúrbios decompostos pela metodologia baseada no método SCICA. . . . . 191

6.8 Diagrama de blocos da etapa de extração de características dos sinais resultantes da decomposição realizada pelo método SCICA. . . . . 193

6.9 Distribuição dos padrões de entrada para treinamento do classificador de distúrbios do componente fundamental. . . . . 196

6.10 Distribuição das saídas desejadas para treinamento do classificador de distúrbios do componente fundamental. . . . . 197

6.11 Distribuição dos padrões de entrada para treinamento do classificador de distúrbios do sinal de erro isolados. . . . . 199

6.12 Distribuição de energia para o sinal de erro obtido a partir de um sinal de tensão contendo afundamento. . . . . 200

6.13 Distribuição das saídas desejadas para treinamento do classificador de distúrbios do sinal de erro isolados. . . . . 202

6.14 Fluxograma do esquema de ordenação das estimativas de componentes independentes em relação às fontes originais. . . . . 204

6.15 Distribuição dos padrões de entrada para treinamento do classificador de distúrbios do sinal de erro separados pelo método FICA. . . . . 206

6.16 Distribuição dos padrões de entrada para treinamento do classificador de distúrbios do sinal de erro separados pelo método SCICA. . . . . 208

6.17 Distribuição das saídas desejadas para treinamento do classificador de distúrbios do sinal de erro separados pelo método FICA ou pelo método SCICA. . . . . 209

6.18 Topologia da RNA utilizada para classificar os distúrbios do componente fundamental. . . . . 210

6.19 Gráfico de treinamento da RNA especializada na identificação do distúrbio presente no componente fundamental. . . . . 210

6.20 Resultado de teste da RNA especializada na identificação dos distúrbios presentes no componente fundamental. . . . . 211

6.21 Topologia da RNA utilizada para classificar os distúrbios do sinal de erro. . . . . 213

6.22 Gráfico de treinamento da RNA especializada na identificação do distúrbio presente no sinal de erro - método FICA. . . . . 214

6.23 Resultado de teste da RNA especializada na identificação dos distúrbios presentes no sinal de erro, para a metodologia baseada no método FICA - distúrbios isolados. 215

6.24 Resultado de teste da RNA especializada na identificação dos distúrbios presentes no sinal de erro, para a metodologia baseada no método FICA - distúrbios múltiplos decompostos. . . . . 216

6.25 Gráfico de treinamento da RNA especializada na identificação do distúrbio presente no sinal de erro - método SCICA. . . . . 217

6.26 Resultado de validação da RNA especializada na identificação dos distúrbios presentes no sinal de erro, para a metodologia baseada no método SCICA - distúrbios isolados. . . . . 218

6.27 Resultado de validação da RNA especializada na identificação dos distúrbios presentes no sinal de erro, para a metodologia baseada no método SCICA - distúrbios decompostos. . . . . 219

# Resumo

Lima, M. A. A. **Uma Nova Metodologia para Análise da Qualidade da Energia Elétrica sob Condições de Ocorrência de Múltiplos Distúrbios**. 242 p. Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, 2013.

Um Sistema Elétrico de Potência (SEP) está susceptível à presença de diversas fontes de distúrbios que prejudicam a Qualidade da Energia Elétrica (QEE). Desta forma, as suas tensões e/ou correntes podem conter múltiplos distúrbios com ocorrência simultânea. Este trabalho apresenta uma metodologia para decomposição do sinal medido em componentes que estimem as formas de onda dos distúrbios individuais quando da ocorrência de múltiplos distúrbios, com o posterior reconhecimento de cada um deles. A Análise de Componentes Independentes (ICA) é utilizada como principal ferramenta na etapa de decomposição dos distúrbios. A ICA é originalmente uma técnica aplicada em análise multivariada de dados, o que significa que ela necessita de medições realizadas por múltiplos sensores dispostos em diferentes posições de um sistema. No entanto, este trabalho propõe a sua aplicação tendo disponível apenas um sinal medido. Para tanto, são propostos dois métodos para produzir a diversidade necessária para a técnica funcionar adequadamente. É demonstrado que ambos os métodos equivalem a um banco de filtros lineares adaptativos capaz de realizar a separação não-supervisionada de múltiplos distúrbios independentes e que sejam espectralmente disjuntos. Por fim, é proposto um sistema de classificação que utiliza Redes Neurais Artificiais (RNAs) para identificar os distúrbios decompostos pela etapa anterior. A metodologia completa é avaliada por meio de testes utilizando dados sintéticos e reais, alcançando resultados altamente satisfatórios para decomposição de sinais contendo múltiplos distúrbios e taxas de acerto globais dos classificadores superiores a 97%.

Palavras-chave: Qualidade da Energia Elétrica, Múltiplos Distúrbios, Separação Cega de Fontes, Análise de Componentes Independentes, Filtragem Adaptativa, Redes Neurais Artificiais.

# Abstract

Lima, M. A. A. **A New Methodology for Power Quality Analysis under Multiple Disturbance Occurrence**. 242 p. Ph.D. Thesis – São Carlos School of Engineering, University of São Paulo, 2013.

*The power system is susceptible to the presence of several sources of disturbances that harm the power quality. In this sense, its voltages and/or currents may contain multiple disturbances with simultaneous occurrence. This work presents a methodology that decomposes the measured signal in components which estimate the waveforms of the individual disturbances followed by their recognition when a multiple disturbance situation occurs. The Independent Component Analysis (ICA) is the main tool in the disturbance decomposition stage. The ICA is originally a technique applied in multivariate data analysis, which means that it requires measurements from multiple sensors allocated in different positions of the system. However, this work proposes its application for a single measured signal available. For this, two methods were developed in order to provide the required diversity to the ICA technique. It is demonstrated that both methods are equivalent to an adaptive linear filter bank capable to perform an unsupervised separation of multiple independent disturbances, if they are spectrally disjoint. A classification system based on artificial neural networks is proposed to identify the disturbances decomposed by the previous stage. The complete system is tested using synthetic and actual data, presenting highly satisfactory results for the decomposition of signals containing multiple disturbances, and precision for the classification task above 97%.*

*Keywords: Power Quality, Multiple Disturbance, Blind Source Separation, Independent Component Analysis, Adaptive Filtering, Artificial Neural Networks.*

# Capítulo 1

# Introdução

O termo Qualidade da Energia Elétrica (QEE) refere-se a uma ampla variedade de fenômenos eletromagnéticos que caracterizam a tensão e a corrente em um determinado instante de tempo e em uma determinada localização do Sistema Elétrico de Potência (SEP) (IEEE Std. 1159, 2009). Segundo Dugan *et al.* (2004), um distúrbio de QEE pode ser definido como sendo qualquer problema manifestado na tensão, corrente ou desvio de frequência, que resulte em falha ou má operação dos equipamentos de consumidores.

O tema QEE tem se tornado um assunto de extrema importância no mercado atual de energia elétrica, constituindo um fator crucial para a competitividade de praticamente todos os setores industriais e de serviços, já que uma deficiente QEE resulta em mau-funcionamento, instabilidade e diminuição da vida útil dos equipamentos elétricos. Sendo assim, é esperado que um SEP forneça tensões senoidais com valores nominais e sem distorções, e correntes ininterruptas e com frequência nominal aos consumidores finais. Entretanto, a crescente penetração no SEP de cargas que utilizam controladores baseados na eletrônica de potência, e da conexão de elementos de Geração Distribuída (GD) de pequena escala (por exemplo, energia eólica e solar) têm levado a uma demanda mais rígida na QEE fornecida aos consumidores (Arrillaga *et al.*, 2000). Tais elementos podem tanto causar distúrbios eletromagnéticos quanto ser sensíveis a estes fenômenos. Por exemplo, o crescimento na GD pode causar variações na amplitude da tensão e introduzir níveis de amplitude de tensão adicionais que divergem do valor nominal. A energia eólica pode levar a um aumento da severidade das flutuações de tensão e consequentemente do efeito de cintilação luminosa (*flicker*), e a energia solar e as formas mais avançadas de conexão da energia eólica levam a um aumento dos níveis de distorção harmônica (Arrillaga *et al.*, 2000).

A crescente utilização dos elementos citados acima tem trazido diversas vantagens técnicas e econômicas a nível residencial, comercial e industrial, mas tem também introduzido novos desafios aos engenheiros da área de energia elétrica. Sendo assim, nas últimas três décadas, o interesse na área de QEE se espalhou significativamente devido às razões já apontadas anteriormente e também a diversas outras, que podem ser resumidas como segue (Saxena *et al.*, 2010):

- Os equipamentos elétricos modernos são equipados com dispositivos baseados na eletrônica de potência e controlados por microcontroladores/microprocessadores. Como exemplo de tais dispositivos, estão incluídas as fontes de energia chaveadas, os *dimmers*, os reatores eletrônicos para iluminação, e os inversores associados à GD, como os utilizados nos sistemas fotovoltáicos. Tais equipamentos tanto introduzem diversos tipos de problemas de QEE quanto também são mais sensíveis aos distúrbios de QEE no SEP.

- Os equipamentos industriais de alta eficiência energética, os controladores eletrônicos de velocidade de motores e os capacitores em derivação (*shunt*) para melhoramento do Fator de Potência (FP) têm sido extensivamente utilizados. Portanto, a complexidade dos processos industriais resulta em altas perdas econômicas se os equipamentos falharem ou apresentarem funcionamento defeituoso.

- A complexa interconexão de sistemas, resultando em consequências mais severas se qualquer um dos componentes falhar. Além disso, diversos equipamentos sofisticados de eletrônica de potência, que são muito sensíveis aos problemas de QEE, são utilizados para melhorar a estabilidade, a operação e a eficiência do sistema.

- A introdução de mercados de energia competitivos dá direito aos consumidores de exigirem alta qualidade de fornecimento, tornando a preocupação com a confiabilidade e o bom funcionamento do sistema elétrico um compromisso não apenas das concessionárias, mas também dos consumidores, que cada vez mais apresentam menor tolerância a problemas de fornecimento de energia.

O novo cenário previsto para as redes inteligentes (*Smart Grids*) (Santacana *et al.*, 2010) reforça ainda mais o crescimento da área de QEE para as próximas décadas, e as principais razões são:

- O crescente aumento e diversificação dos sistemas de GD, o que, como dito anteriormente,

cria novos problemas de QEE.

- As novas formas de utilização previstas para os SEPs (por exemplo, estações de recarga para veículos elétricos, expansão de ferrovias de trens elétricos de alta-velocidade, etc), o que tanto pode introduzir novos tipos de problemas de QEE quanto pode ser susceptível aos problemas de QEE gerados por outros elementos do sistema.

- A crescente demanda no monitoramento, operação e controle automáticos do SEP, o que leva à necessidade de novas técnicas de análise e diagnóstico de QEE.

- A participação mais ativa do consumidor no setor de energia, que poderá utilizar a eletricidade gerada através de suas próprias fontes ou até mesmo vender energia para a rede durante os períodos de pico de consumo, aumentando assim a eficiência energética e adiando investimentos em redes de transmissão e distribuição.

Desta forma, uma QEE adequada garante a compatibilidade necessária entre todos os equipamentos conectados na rede. Ela é, portanto, um importante aspecto para a operação eficiente e bem sucedida tanto das redes elétricas existentes quanto das futuras. Entretanto, a QEE não deve formar uma barreira desnecessária contra o desenvolvimento das redes inteligentes ou a introdução de fontes renováveis de energia. Ao invés disso, as propriedades "inteligentes" das redes do futuro devem ser um desafio para novas abordagens no gerenciamento eficiente da QEE (Bollen *et al.*, 2010).

As novas redes inteligentes devem incluir: o monitoramento da rede elétrica de forma a melhorar a sua confiabilidade; o monitoramento dos equipamentos de forma a melhorar a sua manutenção; e o monitoramento do seu produto (energia) de forma a melhorar a QEE oferecida. Para alcançar estes objetivos, a nova infraestrutura dos sistemas de distribuição (especialmente os medidores inteligentes e os dispositivos eletrônicos inteligentes remotos) deve ser utilizada para adquirir o máximo de informação possível relacionada à rede elétrica, aos seus equipamentos e à energia fornecida e consumida, de forma a melhorar a QEE como um todo (Bollen *et al.*, 2010).

Entretanto, o diagnóstico de problemas de QEE requer um elevado nível de conhecimento especialista. Além da dificuldade no diagnóstico correto de problemas, o conhecimento especialista necessário não está compreendido somente em uma área, mas em diversas áreas da engenharia elétrica, como por exemplo: acionamentos elétricos, sensores, máquinas rotativas, transformadores, eletrônica de potência, fontes de energia, chaveamento de capacitores, proteção, faltas em sistemas de potência, harmônicos, análise de sinais, instrumentos de medição, e operação dos

sistemas de potência de uma maneira geral (Ibrahim e Morcos, 2002).

No SEP, a tensão tem seus parâmetros bem definidos em estado permanente e para condições normais de operação. Desta forma, os principais problemas e definições da QEE estão relacionados à tensão, uma vez que os distúrbios na forma de onda da corrente estão relacionados, em sua maioria, ao tipo de carga inserida no SEP. Considerando a forma de onda da tensão, podem ser encontrados diversos tipos de distúrbios, tais como *notchings*, presença de harmônicos, faltas, elevações (*swells*), afundamentos (*sags*), flutuações, transitórios impulsivos e de chaveamento, etc (Dugan *et al.*, 2004). Estes distúrbios podem ter duração desde 50 ns, como os transitórios impulsivos, até vários minutos, como as subtensões. Sendo assim, quando tais eventos são monitorados por oscilógrafos, geram arquivos de dados de grande extensão que, além de serem difíceis de armazenar, trazem muitas vezes informações desnecessárias para a avaliação da QEE.

Um importante passo para diagnosticar problemas na QEE, e assim ser capaz de melhorá-la, é extrair informações suficientes a respeito dos distúrbios. Tal requerimento pode envolver a utilização de técnicas sofisticadas de processamento que fazem uso de decomposição de sinais, modelagem, estimação de parâmetros, e algoritmos de identificação (Bollen *et al.*, 2009).

Desta forma, diversas ferramentas utilizando técnicas de Processamento Digital de Sinais (PDS) e Inteligência Artificial (IA) têm sido propostas para analisar e diagnosticar problemas em QEE, tais como em detecção e classificação de distúrbios, estimação de parâmetros de distúrbios, compressão de dados de distúrbios, diagnóstico e localização de faltas, etc. De acordo com Bollen *et al.* (2009), técnicas tipicamente utilizadas para extrair informações úteis são a transformada de tempo curto de Fourier (*Short Time Fourier Transform* (STFT)), a Transformada *Wavelet* Discreta (TWD) e a Transformada-$S$. As técnicas tipicamente utilizadas para identificar os distúrbios e/ou suas causas são as Redes Neurais Artificiais (RNAs), os Sistemas *Fuzzy* (SFs), a árvore de decisão (*Rule-based Decision Tree* (RBDT)) e a máquina de vetores de suporte (*Support Vector Machine* (SVM)).

Contudo, além de haver alguns problemas com soluções em aberto, estão surgindo novos desafios envolvendo o cenário de redes inteligentes, o que favorece o desenvolvimento de novos métodos e ferramentas para análise de QEE. Por exemplo, identificar e localizar fontes geradoras de distúrbios de QEE é um problema que não foi completamente resolvido até então, especialmente quando os distúrbios são não-estacionários (Bentley *et al.*, 2010).

Outro desafio ainda pouco explorado é a análise de QEE respeitando a possibilidade de

diferentes distúrbios ocorrerem em sequência ou simultaneamente dentro de um mesmo intervalo de tempo do sinal monitorado. A maioria dos métodos existentes geralmente considera um evento de QEE como contendo um único distúrbio. Na prática, entretanto, um evento de QEE pode consistir de diversos tipos de distúrbios ao mesmo tempo, já que o SEP está susceptível à presença de diversas fontes de distúrbios (Lu *et al.*, 2008). Portanto, os desempenhos desses métodos podem ser limitados para aplicações em SEPs reais, já que eles não foram projetados para lidar com tal situação (Lu *et al.*, 2008; Ribeiro e Pereira, 2007). De fato, somente alguns trabalhos mais recentes consideram a ocorrência de combinações de múltiplos distúrbios em sinais adquiridos dos SEPs, o que naturalmente leva ao desenvolvimento de métodos mais complexos quando comparados aos métodos desenvolvidos para análise de distúrbios simples ou isolados.

Dentre os recentes métodos que lidam com a ocorrência de múltiplos distúrbios, a maioria tem como objetivo resolver o problema de classificação (Zhang *et al.*, 2011; Kapoor e Saini, 2011; Hooshmand e Enshaee, 2010; Faisal e Mohamed, 2009; Biswal *et al.*, 2009). Tais métodos geralmente têm em comum uma etapa de pré-processamento, que extrai alguns parâmetros representativos para fornecer informações que possam distinguir entre os diferentes distúrbios, e uma etapa de classificação, que utiliza um método inteligente para realizar tal distinção. Entretanto, nenhum desses métodos é dedicado à decomposição do sinal contendo múltiplos distúrbios, levando à separação e recuperação das formas de onda dos distúrbios individuais que estejam ocorrendo em multiplicidade. Se esta tarefa pudesse ser realizada, seria possível realizar um processamento e um diagnóstico mais precisos e detalhados a respeito de cada distúrbio individual.

A TWD (Mitra, 2006) tem sido amplamente utilizada para análise de QEE devido a sua capacidade de representação tempo-frequência, o que permite separar diferentes componentes de frequência de um sinal preservando a sua informação temporal (Oleskovicz *et al.*, 2009). Apesar da grande aplicabilidade da TWD para análise de QEE, esta técnica pode apresentar resultados imprecisos na decomposição de um sinal (forma de onda de tensão ou corrente) que contenha múltiplos distúrbios, se o objetivo for decompô-lo em versões que possam representar individualmente cada distúrbio. Isto ocorre porque a TWD é composta de um banco de filtros pré-definidos e fixos, que não dependem ou se adaptam de acordo com a característica do sinal de entrada.

De forma a buscar uma solução eficiente para este problema, em Lima (2009) foi inicialmente proposta uma abordagem para a separação de múltiplos distúrbios de QEE baseada na análise de

componentes independentes (*Independent Component Analysis* (ICA)) (Hyvärinen *et al.*, 2001). Ao invés de procurar por diferenças no tempo e/ou na frequência, a ICA busca a independência estatística entre componentes que estejam ocorrendo simultaneamente.

A abordagem visa identificar, em um cenário de múltiplos distúrbios, componentes independentes que estejam ocorrendo durante o mesmo intervalo de tempo, a partir de um determinado modelo de mistura de distúrbios isolados. Sendo a ICA uma das técnicas mais utilizadas em separação cega de fontes (*Blind Source Separation* (BSS)), o método é capaz de recuperar as formas de onda de alguns tipos de distúrbios isolados sem o conhecimento prévio de quais distúrbios estejam envolvidos e de como eles se encontram misturados.

A ICA é uma técnica originalmente aplicada em análise multivariada de dados, sendo esses dados mutuamente adquiridos de sensores alocados em diferentes posições de um sistema (Hyvärinen *et al.*, 2001). No contexto de QEE, tal situação corresponderia à alocação de diversos medidores sincronizados em diferentes posições do SEP para a obtenção dos dados. Entretanto, o método proposto em Lima (2009) é capaz de processar os dados obtidos de um único sensor. Para que isto seja possível, o método propõe um estágio de pré-processamento utilizando um banco de filtros fixos pré-definidos para gerar múltiplos sinais observáveis a partir de um único sinal medido, permitindo a leitura a partir de um único medidor de QEE. Esta situação é mais comum e mais interessante, uma vez que equipamentos de medição ligados em pontos distantes da rede elétrica iriam registrar diferentes distúrbios, e mais econômica, já que não há a necessidade da utilização de dois ou mais equipamentos de medição próximos e sincronizados.

## 1.1 Objetivos e contribuições

Esta tese de doutorado apresenta a continuação e o avanço da pesquisa iniciada em Lima (2009). Sendo que o desenvolvimento de métodos para a análise de QEE considerando-se a possibilidade de ocorrência de múltiplos distúrbios em um evento tende a ser mais complexo do que considerando-se a possibilidade de ocorrência de um único distúrbio, este trabalho fundamenta-se no *Princípio de Dividir para Conquistar* para decompor os sinais elétricos em *componentes primitivos*, que são componentes dos quais padrões primitivos podem ser independentemente extraídos. A razão por trás disso é que cada componente primitivo está associado a um conjunto reduzido e disjunto de distúrbios. Este princípio inspirou a técnica de detecção de distúrbios introduzida em Duque *et al.* (2005) e a técnica de classificação de distúrbios introduzida em Ribeiro

e Pereira (2007).

Desta forma, o objetivo principal deste trabalho é decompor o sinal elétrico (tensão ou corrente) em componentes primitivos que possam expressar melhor as informações individuais dos distúrbios. Para tanto, será proposta uma metodologia para decomposição do sinal elétrico em seu componente fundamental e nos componentes independentes do sinal de erro, sendo este último representado pela diferença entre o sinal de entrada e o componente fundamental. O estágio principal do algoritmo é a associação do banco de filtros fixos de pré-processamento com a ICA proposta em Lima (2009), que será chamado de método Filtros-ICA (FICA). O sinal de erro é fornecido como entrada ao método FICA, que estima os seus componentes independentes.

As condições de separabilidade para que as estimativas de componentes independentes sejam capazes de corresponder aos componentes primitivos do sinal de entrada do método FICA serão definidas e apresentadas neste trabalho. Um desenvolvimento matemático mostrará que, desde que essas condições de separabilidade sejam ao menos aproximadamente alcançadas, a estrutura completa do método FICA resulta em um banco de filtros lineares adaptativos, capazes de separar de maneira não-supervisionada os distúrbios independentes do sinal de entrada que sejam espectralmente distintos. Além disso, será proposto um procedimento simples baseado no algoritmo *Least Mean Square* (LMS) (Haykin, 2002) para estimar as escalas (amplitude e fase) dos componentes independentes, superando uma indeterminação intrínseca do modelo da ICA, devido ao fato da mesma não possuir o conhecimento prévio de quais componentes independentes estejam envolvidos e nem de como eles se encontram relacionados entre si.

No entanto, uma possível dificuldade na utilização do método FICA é a necessidade de projeto inicial da etapa de pré-processamento, que consiste do projeto do banco de filtros fixos para gerar os sinais de entrada para a ICA. Em Ferreira *et al.* (2012) e Ferreira (2010), foi proposto um outro método baseado na ICA para separar múltiplos distúrbios de QEE a partir de um único sinal medido. Tal método gera os múltiplos sinais de observação para a ICA por meio da aplicação de sucessivos atrasos temporais no sinal medido. Desta forma, esta abordagem não necessita de projeto inicial, por parte do usuário, da etapa de pré-processamento da ICA.

Além das contribuições já reportadas, neste trabalho também será proposto um algoritmo baseado no método *Single Channel Independent Component Analysis* (SCICA), o qual foi originalmente proposto por Davies e James (2007) com aplicações em análise de sinais biomédicos, e que também aplica sucessivos atrasos temporais no sinal medido para gerar os múltiplos sinais de entrada para a ICA. O algoritmo SCICA é um caso especial da ICA multidimensional aplicada

a vetores de amostras atrasadas de um mesmo sinal. Isto implica que múltiplos componentes estimados pela ICA podem ser associados a uma única fonte independente.

Desta forma, diferentemente de Ferreira *et al.* (2012) e Ferreira (2010), este trabalho propõe uma etapa de agrupamento de estimativas de componentes independentes associados a uma mesma fonte, baseado em suas similaridades espectrais. Além disso, assim como no método FICA, as escalas dos componentes independentes serão recuperadas. Um desenvolvimento matemático mostrará que a estrutura global do método SCICA também resulta em um banco de filtros lineares adaptativos que, diferentemente do método FICA, possui coeficientes os quais são totalmente determinados de maneira não-supervisionada apenas pela operação da ICA. Diversos resultados de comparação entre os métodos FICA e SCICA serão apresentados, de forma a destacar as diferenças, vantagens e desvantagens de cada um.

Por fim, será proposta neste trabalho uma metodologia para classificação automática dos sinais obtidos pela etapa anterior de decomposição do sinal de entrada, com o objetivo de identificar os distúrbios presentes no mesmo. Com base no *princípio de dividir para conquistar*, a classificação realizada a partir dos componentes primitivos, ao invés de ser diretamente realizada a partir do sinal de entrada, pode ser mais simples e mais precisa. Uma vez que os múltiplos distúrbios sejam bem separados e recuperados pela etapa anterior de decomposição, o sistema de classificação pode ser relativamente simples, podendo o mesmo ser composto por ferramentas mais básicas de PDS. De fato, o classificador proposto neste trabalho consiste de ferramentas básicas, tais como o cálculo do valor eficaz (*Root Mean Square* (RMS)) e da transformada discreta de Fourier (*Discrete Fourier Transform* (DFT)) para a extração de parâmetros, e da utilização de RNAs para o reconhecimento/classificação de padrões.

Será visto que os parâmetros extraídos a partir do cálculo do valor RMS levam à distinção, por parte de uma RNA, das classes de distúrbios do componente fundamental. Já os parâmetros extraídos através da aplicação da DFT nos componentes independentes estimados pelo método FICA ou pelo método SCICA promovem a distinção das classes de distúrbios do sinal de erro por parte de uma outra RNA, uma vez que tais métodos são capazes de separar distúrbios independentes disjuntos no domínio da frequência.

## 1.2 Organização do documento

No Capítulo 2, será realizada inicialmente uma breve descrição dos tipos de distúrbios de QEE que podem ocorrer nos sinais de tensões e/ou correntes nos SEPs. Em seguida, será apresentada uma revisão sobre técnicas de PDS normalmente empregadas em análise de QEE. Por fim, será apresentada uma formulação matemática do problema de múltiplos distúrbios como sendo uma contribuição aditiva de diversos tipos de fenômenos, dando vistas de como o *princípio de dividir para conquistar* poderia ser utilizado para decompor um problema complexo em diversas soluções mais simples.

O Capítulo 3 apresenta inicialmente os fundamentos da ICA, técnica amplamente utilizada para resolver o problema de BSS. A ICA é a principal etapa da metodologia proposta neste trabalho para decomposição de sinais contendo múltiplos distúrbios de QEE. Em seguida, será realizada uma breve descrição sobre os fundamentos de RNAs, já que esta importante ferramenta computacional de IA será utilizada neste trabalho na etapa de classificação de distúrbios de QEE.

O Capítulo 4 apresenta o desenvolvimento matemático dos dois métodos propostos para realizar a BSS através da ICA tendo-se disponível apenas um sinal de mistura das fontes (canal único). Além disso, serão mostradas quais as condições para que os métodos consigam recuperar corretamente as fontes independentes.

O Capítulo 5 apresenta uma metodologia baseada no *princípio de dividir para conquistar*, sendo o seu objetivo decompor o sinal analisado em seus componentes primitivos. A principal ferramenta desta metodologia é um dos dois métodos de separação propostos no Capítulo 4. As estruturas propostas com base nesses dois métodos serão avaliadas em detalhes utilizando-se dados sintéticos gerados no *software* Matlab. Elas também serão testadas utilizando-se dados reais.

O Capítulo 6 apresenta uma metodologia proposta para classificação de distúrbios de QEE, tendo sido o sinal de entrada previamente decomposto pelas estruturas propostas no Capítulo 5.

O Capítulo 7 apresenta as conclusões obtidas com relação ao desenvolvimento deste trabalho, e aponta propostas para trabalhos futuros.

# Capítulo 2

# Análise de distúrbios na Qualidade da Energia Elétrica

Este capítulo inicialmente descreve, de forma resumida, os tipos de distúrbios de QEE mais encontrados em SEPs. Em seguida, é apresentada uma revisão sobre técnicas de PDS normalmente empregadas para análise de distúrbios de QEE. Por fim, é apresentada uma formulação matemática do problema de múltiplos distúrbios, na qual este trabalho se baseia.

## 2.1 Tipos de distúrbios em QEE

De acordo com IEEE Std. 1159 (2009); Dugan *et al.* (2004), os diferentes tipos de distúrbios podem ser divididos em 7 categorias principais: transitórios, variações de curta duração, variações de longa duração, desequilíbrios, distorções de forma de onda, flutuações de tensão e variações na frequência do sistema.

No Brasil, os Procedimentos de Distribuição (PRODIST) (ANEEL, 2012) são documentos elaborados pela Agência Nacional de Energia Elétrica (ANEEL) que normatizam e padronizam as atividades técnicas relacionadas ao funcionamento e desempenho dos sistemas de distribuição de energia elétrica. O PRODIST contém 9 Módulos, sendo que o Módulo 8 trata especificamente da Qualidade da Energia Elétrica. O Módulo 8 trata da qualidade do produto, ou seja, da energia elétrica fornecida, e da qualidade do serviço, que estabelece os procedimentos relativos aos indicadores de continuidade de fornecimento da energia elétrica e dos tempos de atendimento das concessionárias. Com relação à qualidade do produto, o PRODIST define a terminologia, carac-

teriza os fenômenos e estabelece os parâmetros e valores de referência relativos à conformidade de tensão em regime permanente e às perturbações na forma de onda de tensão.

Os aspectos considerados da qualidade do produto em regime permanente ou transitório são: tensão em regime permanente, fator de potência, harmônicos, desequilíbrio de tensão, flutuação de tensão, variações de tensão de curta duração e variação de frequência.

Os distúrbios podem ser encontrados tanto em sistemas de transmissão quanto de distribuição de energia elétrica. Cada tipo de distúrbio apresenta características próprias e, por isso, pode causar diferentes falhas nos equipamentos conectados à rede elétrica. Deve-se ressaltar que estas características são, ainda, uma importante referência para o processo de identificação do distúrbio. Neste capítulo, algumas características importantes para a análise de distúrbios de QEE serão apresentadas, tais como: conteúdos espectrais típicos, durações típicas, amplitudes típicas, possíveis causas e os possíveis danos causados às cargas sujeitas a tais distúrbios. A Tabela 2.1, extraída de IEEE Std. 1159 (2009), mostra algumas destas características para cada uma das categorias de distúrbios de QEE.

Os fenômenos listados na Tabela 2.1 podem ser identificados e descritos através de uma série de atributos apropriados (IEEE Std. 1159, 2009). Para fenômenos de regime permanente, os seguintes atributos podem ser utilizados:

- Amplitude
- Frequência
- Espectro
- Modulação
- Impedância da fonte
- Profundidade do *notch*
- Área do *notch*

Para fenômenos que não sejam de regime permanente, outros atributos podem ser necessários:

- Tempo de subida
- Amplitude

- Duração
- Espectro
- Frequência
- Taxa de ocorrência
- Energia
- Impedância da fonte

As categorias da Tabela 2.1, quando utilizadas com os atributos mencionados acima, fornecem meios de descrever claramente um distúrbio eletromagnético. As categorias e suas descrições são importantes para classificar resultados provenientes de medições e para descrever fenômenos

Tabela 2.1: Categorias e características típicas de fenômenos eletromagnéticos em SEPs.

| Categoria | Conteúdo espectral | Duração típica | Amplitude típica |
|---|---|---|---|
| 1. Transitórios | | | |
| Transitório Impulsivo | Tempo de subida entre 5 ns e 0,1 ms | $< 1$ ms | |
| Transitório Oscilatório | Até 5 MHz | 5 $\mu$s - 50 ms | 0 - 8 pu |
| 2. Variações de curta duração | | | |
| Afundamento (*sag*) | | 0,5 ciclo - 1 min. | 0,1 - 0,9 pu |
| Elevação (*swell*) | | 0,5 ciclo - 1 min. | 1,1 - 1,8 pu |
| Interrupção | | $< 1$ min. | $< 0{,}1$ pu |
| 3. Variações de longa duração | | | |
| Subtensão | | $> 1$ min. | 0,8-0,9 pu |
| Sobretensão | | $> 1$ min. | 1,1-1,2 pu |
| Interrupção sustentada | | $> 1$ min. | 0,0 pu |
| 4. Desequilíbrios | | | |
| Tensão | | Regime permanente | 0,5-2% |
| Corrente | | Regime permanente | 1,0-30% |
| 5. Distorções da forma de onda | | | |
| Nível CC | | Regime permanente | 0-0,1% |
| Harmônicos | 0-9 kHz | Regime permanente | 0-20% |
| Inter-harmônicos | 0-9 kHz | Regime permanente | 0-2% |
| *Notching* | | Regime permanente | |
| Ruído | Toda banda | Regime permanente | 0-1% |
| 6. Flutuações de tensão (*flicker*) | $< 25$ Hz | Intermitente | 0,1-7% |
| 7. Variações na frequência fundamental | | $< 10$ s | $\pm 0,10$ Hz |

eletromagnéticos que possam causar problemas de QEE. Uma das principais razões para classificar os fenômenos é que há diferentes formas de resolver problemas de QEE dependendo do tipo de distúrbio ocorrido. Deve ser notado que a maioria dos fenômenos descritos na Tabela 2.1 se aplica a tensões, visto que da operação do sistema como um todo, tem-se o controle apenas da tensão e não das correntes que as cargas particulares venham a produzir. Entretanto, às vezes um fenômeno pode se manifestar na corrente. A seguir, serão descritas cada uma das categorias de distúrbios mostradas na Tabela 2.1.

### 2.1.1 Transitórios

O termo transitório é utilizado para caracterizar manifestações ou respostas elétricas locais ou nas adjacências, oriundas de alterações súbitas nas condições operacionais de um SEP. Muitos transitórios são decorrentes de variações instantâneas na corrente, as quais interagem com a impedância do sistema, resultando em elevadas tensões instantâneas. Transitórios podem ser consequência de cargas com operação intermitente, chaveamento de bancos de capacitores, faltas a terra, operação de dispositivos semicondutores, falhas em condutores e descargas atmosféricas (IEEE Std. 1159, 2009).

Geralmente, a duração de um transitório é muito pequena, mas de grande importância, uma vez que os equipamentos presentes nos sistemas elétricos estarão submetidos a grandes solicitações de tensão e/ou corrente. Normalmente, os fenômenos transitórios de interesse para a QEE são classificados em duas categorias: *impulsivos*, normalmente causados por descargas atmosféricas, e *oscilatórios*, normalmente causados por chaveamentos. Estes termos refletem a forma de onda do transitório de tensão ou corrente.

#### Transitório impulsivo

Um transitório impulsivo pode ser definido como uma alteração repentina nas condições de estado permanente da tensão, corrente ou ambas, caracterizando-se por apresentar impulsos unidirecionais em polaridade (positivo ou negativo) e frequências bem diferenciadas em relação à frequência fundamental do SEP. Suas principais causas são descargas atmosféricas (IEEE Std. 1159, 2009).

Um transitório impulsivo é normalmente caracterizado por seus tempos de subida e descida. Por exemplo, quando um transitório impulsivo de tensão é descrito como tendo uma forma

de onda 1,2/50, o valor 1,2 expressa uma medida do tempo de subida em microssegundos e o valor 50 expressa uma medida do tempo de descida em microssegundos (IEEE Std. 1159, 2009). Classificam-se ainda os transitórios impulsivos de acordo com seus tempos de duração, em nanossegundos (duração típica menor que 50 ns e tempo de subida de 5 ns), microssegundos (duração típica entre 50 ns e 1 ms e tempo de subida de 1 $\mu$s), e milissegundos (duração típica maior que 1 ms e tempo de subida de 0,1 ms). Estes fenômenos podem também ser revelados por seus conteúdos espectrais. Devido as altas frequências envolvidas, transitórios impulsivos são amortecidos rapidamente pelos elementos resistivos do circuito, não sendo conduzidos a pontos distantes do seu local de incidência. Transitórios impulsivos podem também excitar os elementos ressonantes do SEP e produzir assim transitórios oscilatórios (IEEE Std. 1159, 2009).

**Transitório oscilatório**

Um transitório oscilatório é caracterizado como uma alteração repentina nas condições de regime permanente da tensão e/ou corrente, com valores instantâneos alternando em polaridade a uma frequência diferente da frequência fundamental, e que apresenta um decaimento com o tempo (IEEE Std. 1159, 2009). Ele é descrito por seu conteúdo espectral (frequência predominante), duração e amplitude. Tais fenômenos são decorrentes de energização de linhas, corte de carga indutiva, eliminação de faltas, chaveamento de bancos de capacitores e transformadores.

De acordo com o conteúdo espectral, os transitórios oscilatórios podem ser subdivididos em três classes: baixa frequência (conteúdo espectral <5 kHz e duração típica de 0,3-50 ms), média frequência (conteúdo espectral de 5-500 kHz e duração típica de 20 $\mu$s) e alta frequência (conteúdo espectral de 0,5-5 MHz e duração típica de 5 $\mu$s). Os transitórios oscilatórios de baixa frequência são frequentemente encontrados em sistemas de subtransmissão e distribuição, e são causados por diversos eventos. O mais frequente é a energização de bancos de capacitores, o qual geralmente resulta em oscilações de tensão com frequência entre 300 Hz e 900 Hz, com amplitude máxima de 2,0 p.u, sendo valores típicos de 1,3 a 1,5 p.u com duração entre 0,5 e 3 ciclos do componente fundamental, dependendo das características de amortecimento do sistema.

Com relação aos transitórios oscilatórios de média frequência, estes podem ser causados também por energização de capacitores, resultando em correntes transitórias de dezenas de kHz, e por chaveamento de disjuntores para eliminação de faltas. Já os transitórios oscilatórios de alta frequência são geralmente o resultado de uma resposta do sistema a um transitório impulsivo. Isto é, podem ser causados por descargas atmosféricas ou por chaveamento de circuitos

indutivos (IEEE Std. 1159, 2009).

### 2.1.2 Variações de tensão de curta duração

Cada tipo de variação de curta duração pode ser classificado como instantâneo, momentâneo ou temporário, dependendo de sua duração. Geralmente são provocadas por condições de falta, energização de grandes cargas que solicitam altas correntes de partida ou por intermitentes falhas nas conexões dos cabos do SEP (IEEE Std. 1159, 2009). Dependendo da sua localização e das condições do sistema, a falta pode provocar afundamento de tensão, elevação de tensão ou uma completa perda da tensão (interrupção).

#### Afundamento (*Sag*)

Afundamento é a redução da amplitude do componente fundamental da tensão entre 0,1 e 0,9 pu, com duração entre 0,5 ciclo e 1 minuto (IEEE Std. 1159, 2009). Os afundamentos podem ser classificados como instantâneos (duração entre 0,5 e 30 ciclos), momentâneos (duração entre 30 ciclos e 3 seg) ou temporários (duração entre 3 seg e 1 min). As principais causas de afundamentos estão geralmente associadas a faltas no sistema, chaveamento de grandes cargas, partida de grandes motores ou energização de transformadores.

#### Elevação (*Swell*)

Elevação é o aumento da amplitude do componente fundamental da tensão entre 1,1 e 1,8 pu, com duração entre 0,5 ciclo e 1 minuto (IEEE Std. 1159, 2009). Assim como afundamentos, são também classificadas entre instantâneas (duração entre 0,5 e 30 ciclos e amplitude entre 1,1 e 1,8 pu), momentâneas (duração entre 30 ciclos e 3 seg e amplitude entre 1,1 e 1,4 pu) ou temporárias (duração entre 3 seg e 1 min e amplitude entre 1,1 e 1,2 pu). Elevações são também associadas a condições de faltas no sistema, porém são muito menos comuns do que afundamentos. Uma elevação pode ocorrer devido a uma falta fase-terra, resultando em elevação da tensão nas fases não-faltosas. Também pode ser causada por desligamento de uma grande carga ou chaveamento de um grande banco de capacitores.

#### Interrupção

Uma interrupção de curta duração ocorre quando a tensão ou corrente decresce a menos de 0,1 pu por um período de tempo não excedente a 1 min (IEEE Std. 1159, 2009). Interrupções podem ser resultantes de faltas no SEP, falhas de equipamentos e mal funcionamento de sistemas de controle (IEEE Std. 1159, 2009). A duração de uma interrupção, devido a uma falta no sistema da concessionária, é determinada pelo tempo de operação dos dispositivos de proteção e do evento particular que está causando a falta.

### 2.1.3 Variações de tensão de longa duração

Variações de longa duração compreendem desvios no valor eficaz da tensão na frequência fundamental do sistema, por um período maior que 1 min (IEEE Std. 1159, 2009). São classificadas em sobretensão, subtensão ou interrupção sustentada, dependendo da causa da variação. Sobretensões e subtensões geralmente não são resultantes de faltas no sistema, sendo causadas normalmente por variações de carga e operações de chaveamento no sistema.

#### Sobretensão

Uma sobretensão é caracterizada por um aumento no valor eficaz da tensão acima de 1,1 pu (valores típicos entre 1,1 e 1,2 pu), considerando-se a frequência do sistema, por um período de duração maior que 1 minuto (IEEE Std. 1159, 2009). Além de ser causada pela saída de grandes grupos de cargas da rede, também é causada por deficiências na regulação da tensão por bancos de capacitores e o incorreto uso de *taps* em transformadores.

#### Subtensão

Uma subtensão é caracterizada por um decréscimo no valor eficaz da tensão a valores menores que 0,9 pu, considerando-se a frequência do sistema, e com período de duração maior que 1 minuto (IEEE Std. 1159, 2009). Suas principais causas são entrada de grandes grupos de cargas na rede e saída de bancos de capacitores reguladores de tensão.

**Interrupção sustentada**

Uma interrupção sustentada é caracterizada por um decréscimo da tensão a menos de 10% do seu valor nominal por um período de tempo superior a 1 minuto. É frequentemente permanente e requer a intervenção da concessionária para reparar o sistema e restaurar o fornecimento de energia (IEEE Std. 1159, 2009).

As interrupções sustentadas podem ocorrer devido à manutenção programada ou não. A maioria delas ocorre de forma não programada e as principais causas são falhas nos disjuntores, queima de fusíveis, falhas de componentes de circuito alimentador, etc. Já o outro caso de interrupção sustentada ocorre geralmente para executar a manutenção da rede, ou seja, serviços como troca de cabos e postes, mudança do *tap* do transformador, alteração dos ajustes de equipamentos de proteção, etc (Arruda, 2003).

### 2.1.4 Desequilíbrios

Desequilíbrio (ou desbalanceamento) é definido como a razão entre as amplitudes do componente de sequência negativa e do componente de sequência positiva da tensão ou corrente (IEEE Std. 1159, 2009). O componente de sequência negativa da tensão em um SEP geralmente surge devido a cargas desbalanceadas que causam o fluxo de correntes de sequência negativa.

O desequilíbrio de tensão em um circuito trifásico pode ser estimado como o máximo desvio da média das três tensões, dividido pela média das três tensões, sendo expresso em percentagem (IEEE Std. 1159, 2009). Por exemplo, se as tensões entre fases em um determinado instante forem iguais a 230 V, 232 V e 225 V, a média é 229 V. O máximo desvio da média entre as 3 leituras é 4 V. A percentagem de desequilíbrio será então igual a $100 \cdot 4/229 = 1,7\%$. Valores típicos de desequilíbrios de tensão estão entre 0,5 e 2%.

As principais fontes de desequilíbrios de tensão são alocações mal dimensionadas de cargas monofásicas nos circuitos de alimentação trifásicos. Podem também ser resultantes da queima de fusíveis em uma das fases de um banco de capacitores trifásico.

### 2.1.5 Distorções da forma de onda

Distorção de forma de onda é definida como um desvio, em regime permanente, da forma de onda idealmente senoidal na frequência do sistema. É caracterizada principalmente pelo

conteúdo espectral do desvio. Os principais tipos de distorção de forma de onda são (IEEE Std. 1159, 2009):

- Nível de Corrente Contínua (CC)
- Harmônicos
- Inter-harmônicos
- *Notching*
- Ruído

**Nível CC**

A presença de tensão ou corrente CC em um sistema de Corrente Alternada (CA) também é chamada de *offset*. É normalmente causada por distúrbios geomagnéticos ou devido ao efeito de retificação de meia onda. O nível CC em redes CA pode levar à saturação de transformadores, resultando em aquecimento adicional e redução da vida útil do equipamento. Pode também causar corrosão eletrolítica de eletrodos de aterramento e outros conectores. Valores típicos da amplitude destes fenômenos se encontram abaixo de 0,001 pu (Dugan *et al.*, 2004).

**Harmônicos**

Harmônicos são tensões ou correntes senoidais contendo frequências que são múltiplos inteiros da frequência nominal do SEP. Estes harmônicos distorcem as formas de onda da tensão e corrente e ocorrem devido a características não-lineares de equipamentos e cargas alimentados pelo SEP (IEEE Std. 1159, 2009), tais como retificadores, inversores e diversos outros equipamentos advindos da eletrônica de potência.

Estes equipamentos podem ser modelados como fontes de corrente que injetam correntes harmônicas no SEP. Surgem também distorções harmônicas na tensão, já que as correntes harmônicas causam queda de tensão não-senoidal na impedância do sistema. A amplitude típica de harmônicos no SEP encontra-se em valores menores que 0,2 pu (Dugan *et al.*, 2004).

### Inter-harmônicos

Tensões ou correntes contendo componentes de frequência que não são múltiplos inteiros da frequência fundamental são chamadas de inter-harmônicos. Podem aparecer como frequências discretas ou como uma ampla faixa espectral. Normalmente, a amplitude desses fenômenos se encontra abaixo de 0,02 pu. As principais causas de distorção inter-harmônica são conversores estáticos de frequência, cicloconversores, fornos de indução e equipamentos a arco, especialmente aqueles cujo controle não é sincronizado com a frequência do sistema (IEEE Std. 1159, 2009).

### *Notching*

*Notching* é um distúrbio periódico de tensão causado pela operação normal de dispositivos de eletrônica de potência quando a corrente é comutada de uma fase para outra. Durante este período, há um curto circuito momentâneo entre duas fases, devido à comutação não-instantânea entre as chaves estáticas. Conversores trifásicos que produzem corrente CC são a principal causa de *notchings* de tensão. *Notchings* representam um caso especial que se situa entre transitórios e distorção harmônica. Desde que *notchings* ocorrem continuamente (regime permanente), eles podem ser caracterizados por meio do espectro harmônico da tensão afetada. Entretanto, os componentes de frequência associados com *notchings* são de alta ordem e podem não ser caracterizados por meio de equipamentos de medida normalmente utilizados para análise harmônica (IEEE Std. 1159, 2009).

### Ruído

Ruídos são definidos como sinais elétricos indesejáveis com larga faixa espectral, com frequências tipicamente menores que 200 kHz e que são superpostos às tensões ou correntes de fase, ou encontrados em condutores de neutro. Valores típicos de amplitude se encontram em torno de 1% da amplitude da tensão (IEEE Std. 1159, 2009)..

Ruídos em SEP podem ser causados por dispositivos de eletrônica de potência, circuitos de controle, equipamentos a arco, cargas contendo retificadores de estado sólido e fontes chaveadas. Ruídos são normalmente associados a aterramentos impróprios. Basicamente, ruídos consistem em distorções indesejáveis que não podem ser classificadas nem como distorção harmônica nem como transitório.

### 2.1.6 Flutuações de tensão

Flutuações de tensão correspondem a variações sistemáticas ou aleatórias do valor eficaz da tensão, e que são compreendidas na faixa de 0,95 a 1,05 pu (IEEE Std. 1159, 2009). Normalmente são causadas por cargas industriais que apresentam variações cíclicas significativas de corrente, especialmente do componente reativo. Fornos a arco ligados a sistemas de transmissão e distribuição são as fontes mais comuns de geração de flutuações de tensão.

Flutuações de tensão geralmente se apresentam como uma modulação do componente fundamental da tensão (semelhante à modulação AM em um sinal de rádio). Tipicamente, o fenômeno de *flicker* é perceptível ao olho humano se a frequência de modulação situa-se na faixa de 6 a 8 Hz. Geralmente o termo *flicker* é usado erroneamente para descrever flutuações de tensão. Na verdade, ele corresponde ao fenômeno de cintilação luminosa observado em algumas lâmpadas, e que é provocado por flutuações de tensão. Este tema merece especial atenção, uma vez que o desconforto visual associado à perceptibilidade do olho humano às variações da intensidade luminosa é indesejável.

### 2.1.7 Variações na frequência fundamental

Variações na frequência do sistema são definidas como o desvio da frequência fundamental do sistema elétrico em relação ao seu valor nominal. No Brasil, a frequência fundamental nominal é de 60 Hz. A frequência do sistema está diretamente relacionada à velocidade de rotação dos geradores que alimentam o sistema. O fenômeno de variação de frequência ocorre quando há um desbalanço entre a potência solicitada por um sistema de cargas e a potência disponibilizada pelo gerador. Desvios típicos na frequência fundamental se situam na faixa de $60 \pm 0,5$ Hz. A amplitude da variação e sua duração dependem das características da carga e da resposta do regulador de velocidade instalado no sistema de geração.

Variações de frequência que ultrapassam os limites para operação normal em regime permanente podem ser causadas por faltas em sistemas de transmissão, saída de um grande bloco de carga ou pela saída de operação de uma grande fonte de geração (IEEE Std. 1159, 2009). Tais variações são mais propensas em sistemas isolados, como é o caso da geração própria nas indústrias.

## 2.2 Revisão sobre análise de distúrbios de QEE empregando técnicas de PDS

Os avanços nas tecnologias de PDS, microprocessadores e dispositivos de armazenamento mudaram a maneira na qual as medições de QEE são realizadas, processadas e como são apresentados seus resultados ao usuário. As tecnologias mais antigas não tinham a velocidade, a capacidade de armazenamento e a habilidade computacional para realizar cálculos e analisar automaticamente distúrbios de QEE em tempo real. Além da capacidade de analisar os dados coletados, a capacidade de armazenar informação também tem aumentado. Os monitores de QEE mais antigos ofereciam uma baixa taxa amostral, tipicamente de 16 amostras por ciclo da frequência fundamental. Com uma limitada resolução espectral, detalhes das variações na forma de onda eram difíceis de serem capturados. Em 2001, taxas de amostragem de 640 amostras por ciclo já eram disponibilizadas (Khan, 2001). A alta taxa de amostragem, aliada à qualidade e ao nível de desempenho dos Conversores Analógico Digital (CADs), ajudam a determinar a resolução e a precisão da forma de onda digitalizada.

Há uma relação direta entre a evolução da tecnologia empregada e o mercado que a utiliza. Na década de 1970, eram utilizados os voltímetros e as medições eram registradas em fitas de papel, e quem utilizava esses equipamentos eram apenas os engenheiros de campo. Na década de 1980, começaram a ser utilizados os osciloscópios e os dispositivos gráficos, sendo que além dos engenheiros de campo, grupos de qualidade de energia dentro das concessionárias de energia começaram a utilizar esses instrumentos. Na década de 1990, além do início da utilização de técnicas de PDS, surgiram também a integração dos medidores a computadores, o armazenamento de dados e a comunicação em rede (*ethernet*). A partir daí, as concessionárias de energia de uma maneira mais abrangente, as indústrias e os engenheiros de consultoria passaram a utilizar os equipamentos de monitoramento de QEE (Khan, 2001). Já no início do século XXI, técnicas de reconhecimento de padrões, mineração de dados, tomada de decisões e comunicação via internet foram incorporadas aos dispositivos de monitoramento. A partir daí, agências reguladoras passaram a incluir índices de QEE no desempenho econômico dos SEPs (Flores, 2002).

Com o aumento da quantidade de dados medidos a partir de monitores de QEE, tornou-se desejável que a análise, caracterização, classificação e compressão dos dados fossem realizadas de maneira automática. Além disso, tornou-se desejável também encontrar a causa de cada

distúrbio, por exemplo, se um afundamento de tensão é causado por uma falta ou por alguma outra razão, tal como a partida de um motor ou a energização de um transformador. Com isso, diversas técnicas de PDS passaram a ser empregadas para essas e outras aplicações em QEE (Gu e Styvaktakis, 2003).

Muitas técnicas foram desenvolvidas para extrair parâmetros, caracterizar, utilizar de maneira adequada os dados provenientes das medições, e comprimir os dados registrados. Dentre as técnicas de processamento de sinais para extrair características a partir dos dados medidos, estão inclusas as transformadas de Fourier e *wavelet*, combinadas com RNAs, SFs, e métodos de reconhecimento de padrões (Santoso *et al.*, 2000; Gaouda *et al.*, 1999; Angrisani *et al.*, 2001; Dash *et al.*, 2000).

Para classificação e caracterização de medições de QEE, Santoso *et al.* (2000) e Chung *et al.* (2002) propuseram métodos utilizando a transformada *wavelet* combinada com RNAs, modelos ocultos de Markov e SFs. Para compressão de dados, é muito frequente a utilização de métodos também baseados na transformada *wavelet* (Santoso *et al.*, 1997; Littler e Marrow, 1999). Embora as técnicas citadas acima sejam muito bem conhecidas na comunidade de processamento de sinais, elas têm sido cada vez mais aplicadas para resolver problemas de QEE de forma bastante satisfatória, e têm fornecido novos rumos à análise de dados de QEE.

Segundo Bollen e Gu (2006), o processamento de dados de monitoramento de QEE pode ser resumido de uma maneira geral pelo diagrama de blocos da Figura 2.1. Os *dados* são disponibilizados como formas de onda amostradas de tensão e/ou corrente. Destas formas de onda, *informações* são extraídas, como por exemplo, a tensão remanescente e a duração de um afundamento de tensão. As ferramentas de PDS desempenham um papel essencial nesta etapa. Para extrair *conhecimento* da informação (por exemplo, o tipo e a localização da falta que causou o afundamento de tensão), as ferramentas de PDS e o conhecimento do SEP são necessários. Tendo-se conhecimento suficiente, isto irá no final levar à *compreensão*, por exemplo, de que afundamentos ocorrem com maior frequência durante o verão por causa das tempestades com relâmpagos, o que pode ajudar na elaboração de métodos de mitigação.

Na verdade, ainda segundo Bollen e Gu (2006), não há fronteiras bem definidas entre as diferentes etapas da Figura 2.1. A disponibilidade de grandes quantidades de dados e a habilidade de acessá-los pode muitas vezes levar a uma impressão errônea de que a compreensão foi alcançada. É importante deixar claro que cada etapa da Figura 2.1 é uma espécie de refinamento da etapa anterior. Pode-se dizer que o processamento de sinais extrai e realça a informação que

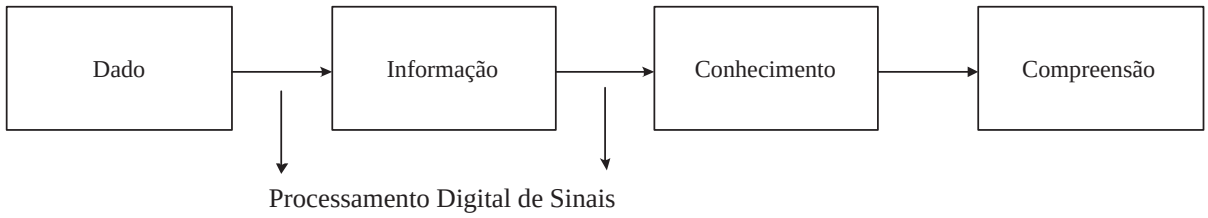


Figura 2.1: Papel do processamento de sinais na extração de informação a partir dos dados de QEE.

está muitas vezes escondida ou não está diretamente perceptível.

### 2.2.1 Variações e eventos

Uma importante divisão dos distúrbios de QEE é entre variações e eventos. Variações são distúrbios de regime estacionário ou de regime quase-estacionário que requerem (ou permitem) medições contínuas. Eventos são distúrbios abruptos com um início e um fim. Tal distinção é realizada em quase todas as publicações em QEE, mas a terminologia pode diferir. Com referência à engenharia elétrica de uma maneira mais clássica, a medição de variações é similar à medição de consumo de energia (contínua), e a medição de eventos é similar à atuação de um relé de proteção (disparada) (Bollen e Gu, 2006).

Um exemplo típico de variação é a variação da frequência do SEP. Seu valor nominal é 60 Hz, mas o seu valor real sempre se difere deste em até cerca de 1 Hz em um SEP real (Bollen e Gu, 2006). Em qualquer momento, a frequência pode ser medida e um valor ser obtido. Por exemplo, pode-se medir a frequência uma vez por segundo a partir do número de cruzamentos por zero da forma de onda da tensão. Desta maneira, a frequência média é obtida a cada segundo. Após uma semana, esta medição poderia ser utilizada para obter informações de sua distribuição de probabilidade, como a média e o desvio padrão. Outros distúrbios que podem ser enquadrados como variações são as variações de amplitude da tensão, as distorções de forma de onda, os desequilíbrios e as flutuações de tensão.

Um exemplo típico de evento é uma interrupção. Durante uma interrupção, a tensão no ponto de medição é nula. Para medir uma interrupção, deve-se esperar até a mesma acontecer. Isto é feito automaticamente na maioria dos monitores de QEE por meio da comparação da amplitude da tensão medida com um limiar (*threshold*). Quando a amplitude da tensão medida é menor do que o limiar por mais de um certo tempo, o monitor detecta o início de uma interrupção. O fim de uma interrupção é detectado quando a amplitude da tensão fica acima

do limiar novamente. A duração da interrupção é a diferença de tempo entre o início e o fim do evento. As estatísticas extraídas de medições de eventos são de natureza completamente diferente daquelas extraídas de variações (Bollen e Gu, 2006). Ao invés de uma distribuição de probabilidade, é obtida uma distribuição da duração da interrupção. Por exemplo, pode-se estar interessado em obter o número de interrupções com duração de até 1 min ou com duração de mais de 3 h. A duração média de uma interrupção, entretanto, não tem um significado direto. Outros exemplos de eventos são os afundamentos de tensão e os transitórios.

A distinção entre variações e eventos nem sempre é fácil de ser percebida. Se, por exemplo, considerar-se mudanças na amplitude da tensão como um distúrbio de QEE, pode-se considerar um afundamento de tensão como um caso extremo de uma variação de amplitude da tensão. A única maneira de definir eventos é pelo disparo que é necessário para iniciar a sua gravação. As variações não necessitam de disparo, os eventos sim (Bollen e Gu, 2006). A diferença entre um afundamento de tensão e uma variação de amplitude da tensão está no disparo. Um afundamento de tensão possui um instante específico de início e outro de fim.

Geralmente, as variações e os eventos requerem tipos diferentes de processamento. A maioria das variações são caracterizadas através do cálculo de parâmetros da forma de onda dentro de um intervalo de tempo predefinido. Por exemplo, as variações de amplitude da tensão normalmente são quantificadas pelo valor RMS calculado sobre uma janela, por exemplo, de 200 ms (10 ciclos da frequência fundamental para 50 Hz ou 12 ciclos para 60 Hz). Os desequilíbrios de tensão, as distorções da forma de onda e as flutuações de tensão também podem ser calculados dentro do mesmo intervalo de tempo. Para cada intervalo de tempo dos dados, os parâmetros calculados correspondem à variação de tensão, ao desequilíbrio, ou algum outro tipo de variação dentro do intervalo de tempo especificado. Os parâmetros calculados dentro de cada intervalo de tempo são então combinados para obter valores associados a um intervalo maior, por exemplo, uma semana ou até mesmo um ano (Bollen *et al.*, 2009).

A caracterização de eventos geralmente ocorre em dois estágios. O primeiro estágio é a detecção, que consiste em detectar o instante de tempo no qual o evento se inicia. Este estágio distingue entre um grande e um pequeno desvio em relação à forma de onda ideal da tensão. O segundo estágio é a caracterização propriamente dita, na qual a severidade e a duração de um evento individual são quantificadas.

Por exemplo, em um evento de afundamento de tensão, a amplitude da tensão é quantificada pelos valores RMS em função do tempo: cada valor RMS é calculado utilizando uma janela

de 1 ciclo da frequência fundamental do dado medido. O processo é repetido sucessivamente após deslocar à frente a janela de dados com uma sobreposição de meio ciclo. Uma vez que as amplitudes dos valores RMS assumam valores abaixo de um limiar predefinido (frequentemente ajustado como 90% da tensão nominal), um afundamento de tensão é detectado. Esta detecção frequentemente dispara operações adicionais (por exemplo, armazenamento da forma de onda com uma determinada duração de tempo). Quando o disparo de um evento é detectado, é uma prática normal registrar tanto as tensões quanto as correntes associadas com o evento, já que estas quantidades são muito correlacionadas (Bollen *et al.*, 2009).

### 2.2.2 Métodos de PDS para detecção e segmentação de eventos

A segmentação de um evento (Styvaktakis, 2002) consiste em quebrar um evento em segmentos de transição e segmentos de eventos. Em termos de processamento de sinais, a segmentação significa encontrar grupos de segmentos de dados que possuam propriedades similares. Sendo assim, a segmentação de eventos visa dividir o sinal em partes quase-estacionárias e não-estacionárias. Um segmento de transição é um segmento no qual o sinal é não-estacionário, por exemplo, onde há uma mudança na amplitude da tensão ou corrente entre dois estados distintos. O intervalo entre os dois segmentos de transição mais próximos é um segmento de evento, no qual o sinal é quase-estacionário. O segmento quase-estacionário antes do primeiro segmento de transição é um segmento pré-evento, enquanto que o segmento quase-estacionário após o último segmento de transição é um segmento pós-evento. Segmentos de transição são tipicamente relacionados à ocorrência de eventos ou ações no SEP, tais como o início de uma falta, a extinção de uma falta, a abertura ou o fechamento de chaves (chaveamento de linha, transformador, capacitor, etc).

Existem três abordagens básicas para detectar segmentos de transição (Bollen e Gu, 2006):

- A primeira abordagem, contendo os métodos mais simples, consiste em calcular a partir da forma de onda uma série de parâmetros em função do tempo, sendo tipicamente calculado o valor RMS das tensões e correntes ao longo do tempo. Os segmentos de transição são então detectados pela comparação do valor RMS com um limiar pré-determinado. Embora este seja um método simples, ele é considerado eficiente para a maioria das medições, sendo o método mais empregado para detectar afundamentos, elevações e interrupções de tensão por parte de instrumentos de medição.

- A segunda abordagem é utilizar filtros passa-altas ou passa-faixas, já que um evento frequentemente resulta em uma rápida alteração na tensão (ou corrente) e em oscilações de alta frequência. É muito comum a utilização dos filtros *wavelet* (Gu e Styvaktakis, 2003) para detectar rápidas alterações ou singularidades na forma de onda do sinal. Na prática, um filtro passa-altas analógico ou digital é tipicamente utilizado em instrumentos para detectar transitórios.

- A terceira abordagem faz uso de métodos paramétricos, onde um modelo do sinal (por exemplo, um modelo senoidal amortecido ou um modelo auto-regressivo) é utilizado. Dependendo do algoritmo utilizado, a sequência de dados gravados pode ser dividida em blocos, e os parâmetros do modelo podem ser estimados em cada bloco. Isto pode ser realizado estimando-se parâmetros do sinal utilizando-se modelos auto-regressivos (Gu *et al.*, 2000). Alternativamente, algoritmos iterativos podem ser usados sem dividir os dados em blocos, por exemplo, os filtros de Kalman (Gu e Styvaktakis, 2003; Styvaktakis, 2002). Então, os resíduos, que indicam o desvio entre a forma de onda original e a forma de onda gerada pelo modelo estimado, são calculados. Enquanto o sinal for quase-estacionário, o resíduo é pequeno; entretanto, para uma rápida mudança no sinal, por exemplo, um transitório, o resíduo se torna grande. Os valores do resíduo podem, portanto, ser utilizados para detectar segmentos de transição.

### 2.2.3 Métodos de PDS para caracterizar segmentos de dados de QEE

Os métodos utilizados para caracterizar formas de onda em segmentos de eventos podem ser utilizados também para quantificar variações, já que ambos os tipos de sinais são quase-estacionários, e os mesmos princípios de processamento de sinais podem ser aplicados.

#### Filtros para remoção do componente fundamental

Este pré-processamento é frequentemente necessário antes de iniciar a análise e caracterização do sinal. Na análise de distúrbios, a frequência dominante é a fundamental (50 Hz ou 60 Hz), que poderia ser considerada como um forte ruído (frequentemente ele é 10 dB mais forte que o restante da informação contida no sinal). Isto poderia afetar a exatidão na análise dos outros componentes do sinal para frequências próximas da frequência fundamental. O filtro mais frequentemente utilizado para remover o componente fundamental é o filtro *notch* (Ribeiro e Pereira, 2007) ajustado na frequência fundamental.

**Decomposição tempo-frequência do sinal utilizando transformadas e bancos de filtros**

A decomposição de um sinal de uma variável (tempo) em componentes de duas variáveis (tempo-frequência) permite observar as alterações nos componentes individuais em função do tempo. Sendo assim, uma futura caracterização da dinâmica dos componentes é possível; por exemplo, o monitoramento das alterações nos componentes harmônicos ao longo do tempo ou a detecção do início e fim de um evento.

Enquanto a DFT (Mitra, 2006) é uma ferramenta muito utilizada para representação de sinais estacionários no domínio da frequência, a análise tempo-frequência deve ser empregada para sinais não-estacionários, onde o uso da DFT se torna inadequado. Há diversos métodos de filtragem baseados em transformadas tempo-frequência e em filtros de sub-bandas que podem ser empregados; por exemplo, a STFT (Oppenheim e Schafer, 1998) e a TWD.

A decomposição de sinais através da STFT equivale a aplicar um conjunto de filtros passa-faixas com larguras de banda iguais. Os parâmetros essenciais necessários, que devem ser ajustados corretamente para aplicações em SEPs, são as frequências centrais e a largura de banda dos filtros passa-faixas. As frequências centrais dos filtros passa-faixas equivalentes devem ser ajustadas nas frequências harmônicas. A largura de banda é determinada pelo tamanho da janela de dados analisada. É essencial que a passagem de apenas um ou alguns poucos harmônicos seja permitida por cada filtro (Bollen *et al.*, 2009). Há um compromisso, entretanto, entre a resolução de tempo dos filtros de sub-bandas e o número de harmônicos permitidos em cada banda de passagem, isto é, a largura de banda dos filtros. A resolução conjunta tempo-frequência é governada, assim como nos outros métodos de análise tempo-frequência, pelo princípio da incerteza $\Delta_\omega \Delta_t \leq 2\pi$, onde $\Delta_t$ é a resolução no tempo e $\Delta_\omega$ a resolução na frequência. A STFT possui a desvantagem de possuir a mesma resolução de frequência sobre a faixa inteira de frequências.

A TWD também decompõe sinais em componentes dependentes da frequência. Sua ação é equivalente a aplicar um banco de filtros de sub-bandas com uma relação de largura de banda em escala logarítmica, mais precisamente em oitavas (Mitra, 2006). A TWD é uma excelente ferramenta para detectar automaticamente singularidades em diferentes escalas de um sinal. Isto é particularmente útil para detectar os instantes iniciais e finais de eventos. Deve ser mencionado que a TWD não é adequada para análise de distúrbios relacionados a harmônicos (Gu e Bollen, 2000). Devido à relação em oitavas entre as larguras de banda dos filtros *wavelet*, implicando na passagem de mais componentes harmônicos em uma banda de frequência superior, o

número de harmônicos em cada banda de passagem não pode ser livremente ajustado. Ou seja, as frequências centrais dos filtros associados com as *wavelets* não podem ser livremente ajustadas nas frequências fundamental e harmônicas. Há muitas aplicações em SEP que utilizam a TWD (Chen e Zhu, 2007). A escolha entre a STFT ou a TWD depende das aplicações. Para análise de harmônicos, a STFT é mais adequada. Para a detecção de eventos, a TWD é mais efetiva (Santoso *et al.*, 2000; Gu e Bollen, 2000).

Outras transformadas ou filtros de sub-banda são também utilizados para decomposição de sinais de QEE. Como exemplo, pode-se citar a Transformada-$S$ (Stockwell *et al.*, 1996) para análise de eventos (Dash *et al.*, 2003). A Transformada-$S$ mais simples pode ser vista como um banco de filtros de duas bandas relacionado à transformada *wavelet* utilizando a função Haar como *wavelet* mãe, onde as saídas dos dois filtros são relacionadas à soma e à diferença das amostras dos dois sinais vizinhos, respectivamente.

**Métodos para analisar eventos**

Um problema comum em análise de eventos é a estimação de algumas quantidades de interesse. Em termos de análise de distorções harmônicas e inter-harmônicas, os parâmetros de interesse são o número de harmônicos/inter-harmônicos dominantes, suas frequências e amplitudes, a severidade de cada componente em função do tempo, e o instante inicial assim como a duração da distorção. Isto está relacionado a estimar, em função do tempo, as frequências, amplitudes, fases e fatores de atenuação, e alguns índices, tais como a distorção harmônica total (*Total Harmonic Distortion* (THD)). Em termos de afundamentos e elevações, os parâmetros de interesse incluem os instantes de início e fim do evento e a percentagem de afundamento ou elevação da tensão durante o evento. Outros parâmetros relevantes, dependendo da aplicação, seriam as localizações das fontes de distorção (Bollen *et al.*, 2009).

Dentre os métodos para analisar eventos, pode-se citar:

1. *Métodos básicos*:

   (a) O método RMS dependente do tempo, usado para estimar o valor RMS da forma de onda da tensão/corrente em função do tempo. Embora uma curva RMS seja muito básica e simples, ela é normalmente utilizada como uma base de comparação para outros métodos.

   (b) A transformada rápida de Fourier (*Fast Fourier Transform* (FFT)) aplicada a uma

janela de tamanho relativamente grande contendo o dado de interesse, para estimar o espectro do sinal e usá-lo para detectar harmônicos dominantes, inter-harmônicos, e suas amplitudes. Embora seja também um método básico e simples, seu resultado é muito utilizado como referência para outros métodos.

2. *Métodos não-paramétricos*: Métodos não-paramétricos podem ser usados para estimar a amplitude e a fase dos componentes fundamental, harmônicos e inter-harmônicos do sinal. Exemplos de métodos não-paramétricos são a STFT, a TWD e filtros de sub-bandas (Santoso *et al.*, 2000; Duque *et al.*, 2008). Entretanto, as formas de onda dos harmônicos individuais podem ser obtidas apenas quando a largura de banda do filtro é suficientemente estreita. Para inter-harmônicos dentro da largura de banda do sinal, o número possível de frequências é infinito. Portanto, estes métodos geralmente não são adequados para a análise de inter-harmônicos.

3. *Métodos paramétricos baseados em modelos senoidais amortecidos*: Métodos paramétricos podem ser usados para analisar tanto componentes harmônicos quanto inter-harmônicos. Uma vez que um modelo correto para o sinal seja encontrado, uma resolução de frequência muito maior pode ser alcançada comparando-se aos métodos não-paramétricos. Para análise de harmônicos/inter-harmônicos, um modelo senoidal amortecido é apropriado para modelar alguns tipos de transitórios e distúrbios, especialmente aqueles envolvendo o chaveamento de elementos capacitivos ou outras operações que têm o mesmo impacto nestes elementos (por exemplo, a extinção de uma falta). Para estimar os parâmetros do modelo, um processo consistindo de duas etapas é geralmente aplicado: primeiro, as frequências e fatores de amortecimendo são estimados. Então, o método de mínimos quadrados (*Least Squares* (LS)) é usado para estimar as amplitudes e fases iniciais das senóides. A vantagem do método é que qualquer frequência pode ser localizada, incluindo harmônicos e inter-harmônicos. Isto é especialmente útil na análise de inter-harmônicos. Sua desvantagem é que o número de senóides deve ser especificado antes de executar o algoritmo, quando na realidade isto é geralmente desconhecido. Em Bollen *et al.* (2005), é utilizado o modelo senoidal amortecido para caracterizar transitórios provocados por chaveamentos de capacitores. Em Gu e Bollen (2008), para analisar inter-harmônicos em um ambiente não-estacionário, é utilizado um método baseado no modelo senoidal amortecido, no qual a sequência de dados é dividida em blocos sobrepostos e o método é aplicado a cada bloco utilizando-se janelas deslizantes.

4. *Métodos paramétricos baseados em modelos de espaço de estado*: Uma outra forma para análise de harmônicos/inter-harmônicos consiste em usar modelos de espaço de estado e filtros de Kalman. Os filtros de Kalman têm sido amplamente utilizados em aplicações em SEP (Ma e Girgis, 1996; Yu *et al.*, 2005). Se for assumido que as frequências dos harmônicos são conhecidas, então a tarefa é estimar dinamicamente os componentes do sinal em função do tempo (ou amplitudes e fases iniciais) de acordo com um modelo de soma de $K$ senóides com frequências pré-definidas. Então, é formulado um modelo de espaço de estados, sendo as variáveis de estado definidas como a parte real e imaginária das $K$ senóides. A partir das variáveis de estado, as amplitudes e fases iniciais de cada componente são calculadas.

### 2.2.4 Métodos de PDS para classificação de distúrbios de QEE

Um passo geralmente utilizado após quantificar e caracterizar os dados é classificar, diagnosticar, e mitigar os distúrbios. Ferramentas apropriadas para alcançá-lo incluem técnicas de aprendizagem de máquinas e de classificação automática ou reconhecimento de padrões. Os métodos de classificação utilizam parâmetros (ou atributos ou características) dos dados como entradas e a designação desses dados em classes ou grupos como saídas. Um processo de classificação geralmente consiste das etapas de extração de parâmetros e otimização, projeto do classificador por meio da busca de uma função de mapeamento entre o espaço de características e o espaço de decisão, aprendizagem de máquina supervisionado ou não-supervisionado, validação e teste (Bollen e Gu, 2006).

Uma numerosa quantidade de trabalhos tem sido publicada propondo classificação automática de distúrbios de tensão nos últimos anos. Esses trabalhos podem ser divididos em dois grupos (Bollen *et al.*, 2009):

1. Classificação de formas de onda de distúrbios, com classes típicas incluindo "afundamentos", "elevações", "interrupções" e "transitórios". Este tipo de trabalho é importante para o desenvolvimento de ferramentas de classificação, mas possui um limitado valor prático.

2. Classificação de eventos baseada em suas origens, com classes típicas incluindo "faltas", "energização de transformador" e "energização de capacitor". Este tipo de trabalho possui um enorme valor prático.

Os métodos de classificação utilizados e sob desenvolvimento podem ser divididos dentre os

três grupos a seguir (Bollen *et al.*, 2009):

- *Inspeção visual*: Especialistas em SEP frequentemente utilizam este método na prática para classificar as origens dos distúrbios.

- *Sistemas baseados em regras*: Estes sistemas são frequentemente implementados como sistemas especialistas que sejam capazes de distinguir entre diferentes classes de distúrbios baseando-se em suas origens. Um exemplo é um sistema especialista para classificação de afundamentos e interrupções de tensão baseado em suas origens (Styvaktakis *et al.*, 2002). O sistema é capaz de distinguir entre nove classes e tem sido aplicado a uma larga quantidade de gravações medidas em um sistema de distribuição de média tensão. A vantagem de sistemas especialistas é que eles não necessitam de dados de treinamento para o classificador, já que eles utilizam regras desenvolvidas por especialistas humanos. Portanto, se houver uma quantidade limitada de dados de treinamento disponível, um sistema especialista é uma boa escolha. A principal desvantagem de sistemas especialistas é que eles geralmente requerem um conjunto de limiares fixos para aplicar uma decisão binária (sim ou não) após aplicar as regras.

- *Métodos baseados em estatística*: Estes métodos utilizam diversas técnicas de PDS e/ou IA avançadas. As RNAs, frequentemente combinadas com a extração de características a partir de um conjunto de filtros *wavelet*, são de uma forma geral as técnicas mais encontradas na literatura. A classificação utilizando RNAs tem se mostrado ser uma boa alternativa quando é disponível uma grande quantidade de dados de treinamento. Exemplos de aplicação de RNAs incluem um sistema de classificação baseado em formas de onda (Gaing, 2004) e um sistema que distingue entre energização de transformador e partida de motor (Zhu *et al.*, 2004). Outro sistema baseado em RNAs para identificar as origens de distúrbios foi apresentado em Santoso *et al.* (2000). Mais recentemente, técnicas da teoria de aprendizagem estatística, como SVMs, têm sido utilizadas também para classificação de distúrbios (Axelberg *et al.*, 2007). Sistemas de classificação baseados em múltiplos testes de hipóteses, abordagens orientadas a clientes e outros métodos híbridos também têm sido propostos na literatura (Duque *et al.*, 2005; Gu *et al.*, 2004; van Casteren *et al.*, 2005; Barros e Perez, 2006).

A classificação de distúrbios de QEE, assim como em outras áreas, inclui basicamente as etapas de seleção das características adequadas e representativas do sinal e o projeto do classifi-

cador. A grosso modo, a definição das características a serem utilizadas é altamente dependente do conhecimento especialista em SEP e QEE, enquanto que a extração adequada das características definidas e o projeto de bons classificadores demandam principalmente a especialidade em processamento de sinais e reconhecimento de padrões.

A definição e a extração de características bem representativas é uma etapa essencial para se obter uma classificação de distúrbios bem sucedida. Isto geralmente requer um excelente conhecimento de SEPs. As características são às vezes extraídas sem se levar em conta a natureza específica dos sinais de distúrbio, por exemplo: 1) usando as saídas de transformadas e filtros de sub-bandas, incluindo a DFT, a STFT, a TWD e outros métodos de decomposição tempo-frequência do sinal, e 2) usando estatísticas de segunda ordem e de ordem superior tais como valor RMS, energia e cumulantes. Mas sem um processamento adicional, por exemplo, utilizando-se a forma da curva RMS, os pontos de início e fim do evento ou a variação da energia em certas faixas de frequência, estas características oferecem pouco potencial para esclarecer os fenômenos ocultos.

Os atributos selecionados pelo especialista muitas vezes podem ser parcialmente correlacionados. Há muitos métodos eficientes em reconhecimento de padrões para descorrelacionar e reduzir a dimensão dos dados, como por exemplo a análise de componentes principais (*Principal Component Analysis* (PCA)) (Hyvärinen *et al.*, 2001). Uma alta dimensionalidade dos vetores de características geralmente requer mais dados de treinamento e leva a um sistema de classificação mais complexo, além de que pode levar a um baixo desempenho na generalização do classificador quando aplicado aos dados de teste.

Sabe-se que os SEPs estão sujeitos à ocorrência de diversos tipos de distúrbios, provocados por diferentes fontes, e esses distúrbios podem aparecer tanto nas formas de onda da tensão quanto nas formas de onda da corrente de maneira isolada ou simultaneamente (Lu *et al.*, 2008). Para a classificação de distúrbios isolados, várias soluções já foram propostas na literatura, incluindo aquelas já citadas nesta seção. Entretanto, o mesmo não acontece quando o problema se trata de múltiplos distúrbios.

A classificação de múltiplos distúrbios é um problema ainda em aberto e, portanto, demanda novas investigações para uma correta caracterização. Isto resultaria, por exemplo, em uma maior confiabilidade na identificação das fontes geradoras dos diferente distúrbios. Neste contexto, em Gaouda *et al.* (2002), Abdel-Galil *et al.* (2004), He e Starzyk (2006), Zhao e Yang (2007) e Mishra *et al.* (2008) foram propostos classificadores que abordam, além do problema de distúrbios

isolados, também o problema de múltiplos distúrbios, embora apenas para as classes combinadas de "harmônicos com afundamento de tensão" e "harmônicos com elevação de tensão".

Os trabalhos de Chuang *et al.* (2005a,b) e Lu *et al.* (2008) propõem um classificador que consiste de diversos componentes de processamento dispostos em cascata, compreendendo: um estimador de amplitude do componente fundamental, para o reconhecimento de afundamentos, elevações ou interrupções; a TWD, para a extração de características dos componentes restantes; um detector seguido por um filtro de transitórios impulsivos, e; RNAs, para o reconhecimento dos demais distúrbios considerados na abordagem (harmônicos e flutuação de tensão (*flicker*)). Com esta metodologia, consegue-se abordar até três tipos de distúrbios simultâneos.

Em Faisal e Mohamed (2009), é proposto um método para classificação de distúrbios isolados e múltiplos utilizando a Transformada-$S$ para extração de características seguida de um sistema classificador baseado em regras. O método proposto pode classificar também até três distúrbios simultâneos: "afundamento, harmônicos e *notchings*" e "elevação, harmônicos e *notchings*".

Em Hooshmand e Enshaee (2010), foi proposta a detecção e classificação de distúrbios isolados e múltiplos utilizando Lógica *Fuzzy* (LF) e otimização por enxame de partículas (*Particle Swarm Optimization* (PSO)). Nesse método, primeiramente são extraídos parâmetros adequados da forma de onda do sinal contendo distúrbio de QEE. Então, o SF classifica o tipo de distúrbio baseado nesses parâmetros. O algoritmo PSO é utilizado para determinar os parâmetros das funções de pertinência para o SF. Nesse artigo, oito classes de distúrbios isolados (impulso, interrupção, elevação, afundamento, *notching*, transitório, harmônicos e *flicker*) e oito classes de distúrbios múltiplos são consideradas. Entretanto, os distúrbios múltiplos envolvem somente as combinações de afundamento ou elevação com apenas mais um tipo dentre os demais tipos de distúrbios.

Em Zhang *et al.* (2011), foi proposto um método de classificação em tempo real de distúrbios de QEE. O método utiliza o cálculo do valor RMS e da DFT na etapa de extração de parâmetros. Na etapa de reconhecimento de padrões, é utilizada a RBDT. De acordo com os autores, nove tipos de distúrbios (sendo dois deles combinações de harmônicos com afundamento ou harmônicos com elevação) podem ser reconhecidos facilmente sem a necessidade de classificadores mais complexos. O tempo gasto pelo *hardware* para a classificação do distúrbio é de 0,09 até 0,12 s em média. Em Kapoor e Saini (2011), é proposto um método que utiliza conceitos de demodulação de amplitude e frequência para separar vários padrões de distúrbios isolados e múltiplos a serem classificados utilizando-se SF. Esse método classifica as combinações de afundamento com

harmônicos ou elevação com harmônicos, bem como a combinação de afundamento, transitório e harmônicos.

Uma abordagem interessante do problema de múltiplos distúrbios foi proposta em Ribeiro e Pereira (2007), na qual um sinal de tensão/corrente pode ser considerado como uma soma de diversos componentes primitivos. Sendo assim, foi proposta a decomposição do sinal de tensão monitorado $x[n]$ nos sinais $f[n]$, $h[n]$ e $u[n]$, onde tais sinais representam, respectivamente, as estimativas do componente fundamental, dos harmônicos e, por último, da soma dos componentes inter-harmônicos, transitórios e ruídos de fundo. Desta forma, cada um destes sinais está restrito à ocorrência de um grupo reduzido de distúrbios. Esta é uma forma de utilização do princípio de *dividir para conquistar*, no qual um problema mais complexo é dividido em sub-problemas mais simples. A próxima seção descreve a abordagem apresentada em Ribeiro e Pereira (2007), na qual este trabalho também se baseia.

## 2.3 Distúrbios de QEE isolados e múltiplos: Uma formulação do problema

A versão de tempo discreto de sinais elétricos de tensão/corrente monitorados pode ser dividida em janelas não superpostas de $N$ amostras. Baseado no modelo proposto em Duque *et al.* (2005) e Ribeiro e Pereira (2007), a sequência de tempo discreto $\{u[n]\}$ compreendida em uma janela de dados será expressa como uma contribuição aditiva de diversos tipos de fenômenos, da seguinte forma:

$$u[n] = u(t)|_{t=nT_S} = f[n] + h[n] + i[n] + t[n] + \nu[n], \tag{2.1}$$

onde $n = 0, \ldots, N-1$, $T_S = 1/f_S$ é o período de amostragem, $f_S$ é a frequência de amostragem, e $u[n]$ é a versão de tempo discreto do sinal contínuo $u(t)$ amostrado no instante $nT_S$. As sequências $\{f[n]\}$, $\{h[n]\}$, $\{i[n]\}$, $\{t[n]\}$, e $\{\nu[n]\}$ correspondem, respectivamente, ao componente fundamental, harmônicos, inter-harmônicos, transitórios e ruído de fundo. Cada um destes sinais é definido como segue:

$$f[n] = A_1[n]\text{sen}\left(2\pi f_1[n]nT_S + \delta_1[n]\right), \tag{2.2}$$

$$h[n] = \sum_{k=2}^{K} A_k[n]\text{sen}\left(2\pi k f_1[n] n T_S + \delta_k[n]\right), \tag{2.3}$$

$$i[n] = \sum_{j=1}^{J} A_{I,j}[n]\text{sen}\left(2\pi f_{I,j}[n] n T_S + \delta_{I,j}[n]\right), \tag{2.4}$$

$$t[n] = t_{\text{imp}}[n] + t_{\text{not}}[n] + t_{\text{osc}}[n] + t_{\text{dec}}[n], \tag{2.5}$$

e $\nu[n]$ é um ruído branco gaussiano $\mathcal{N}\left(0, \sigma_\nu^2\right)$ independente de $f[n]$, $h[n]$, $i[n]$, e $t[n]$.

Em (2.2), $A_1[n]$, $f_1[n]$, e $\delta_1[n]$ se referem à amplitude, frequência fundamental, e ângulo de fase do sinal da fonte de energia, respectivamente. A partir da sequência $\{f[n]\}$, os distúrbios que são principalmente relacionados ao componente fundamental podem ser diagnosticados. Estes distúrbios são: afundamento, elevação, interrupção, interrupção sustentada, subtensão e sobretensão.

Em (2.3), $A_k[n]$ é a amplitude e $\delta_k[n]$ é o ângulo de fase do $k$-ésimo componente harmônico. A partir da sequência $\{h[n]\}$, a ocorrência de distorção harmônica gerada por fontes que são principalmente cargas não-lineares conectadas ao SEP pode ser diagnosticada.

Em (2.4), $A_{I,j}[n]$, $f_{I,j}[n]$, e $\delta_{I,j}[n]$ são a amplitude, frequência e ângulo de fase do $j$-ésimo inter-harmônico, respectivamente. Estes componentes surgem devido à presença de alguns dispositivos de eletrônica de potência e cargas variantes no tempo que exigem grandes solicitações de corrente, como fornos a arco. Desta forma, tanto as flutuações de tensão quanto os inter-harmônicos podem ser diagnosticados a partir da sequência $\{i[n]\}$.

Em (2.5), $t_{\text{imp}}[n]$ e $t_{\text{not}}[n]$ representam transitórios impulsivos e *notchings*, respectivamente; $t_{\text{osc}}[n]$ se refere aos transitórios oscilatórios, e $t_{\text{dec}}[n]$ representa os decaimentos exponenciais. Estes transitórios podem ser expressos por:

$$t_{\text{imp}}[n] = \sum_{i=1}^{N_{\text{imp}}} t_{\text{imp},i}[n], \tag{2.6}$$

$$t_{\text{not}}[n] = \sum_{i=1}^{N_{\text{not}}} t_{\text{not},i}[n], \tag{2.7}$$

$$t_{\text{osc}}[n] = \sum_{i=1}^{N_{\text{osc}}} A_{\text{osc},i}[n] \exp\left(-\alpha_{\text{osc},i}[n]\, n T_S\right) \text{sen}\left(\omega_{\text{osc},i}[n] n T_S + \delta_{\text{osc,i}}[n]\right), \tag{2.8}$$

$$t_{\text{dec}}[n] = \sum_{i=1}^{N_{\text{dec}}} A_{\text{dec},i}[n] \exp\left(-\alpha_{\text{dec},i}[n]\, nT_S\right), \tag{2.9}$$

onde $t_{\text{imp},i}[n]$ e $t_{\text{not},i}[n]$ são a $n$-ésima amostra do $i$-ésimo transitório impulsivo ou *notching*, respectivamente. Deve ser mencionado que (2.8) se refere a chaveamentos, assim como a sinais resultantes de formas de onda faltosas. A equação (2.9) define o decaimento exponencial, assim como os componentes CC ($\alpha_{\text{dec}} = 0$) originados devido a distúrbios geomagnéticos ou à assimetria de conversores de eletrônica de potência (Dugan *et al.*, 2004).

O uso direto de $u[n]$ para análise de QEE normalmente leva a soluções com alta complexidade computacional. Além disso, a maioria das técnicas de análise de distúrbios de QEE desenvolvidas até então (por exemplo, para detecção e classificação) assumem a ocorrência de um único distúrbio dentro de uma janela de dados (Santoso *et al.*, 2000; Janik e Lobos, 2006; Yu e Wang, 2009). Essas técnicas apresentam alto desempenho com relação à detecção e classificação, às vezes muito próximo de 100%. Contudo, deve ser ressaltado que a incidência de múltiplos distúrbios, dentro de uma mesma janela de dados, é uma situação factível devido à presença de várias fontes de distúrbios nos SEPs. É importante mencionar que a análise de distúrbios de QEE leva em conta uma janela de dados não-superposta possuindo um determinado comprimento, normalmente especificado no projeto. Portanto, distúrbios múltiplos são definidos aqui como sendo aqueles que ocorrem dentro da mesma janela de dados.

O sinal apresentado na Figura 2.2(a), obtido na página de internet da força-tarefa P1159.3 do IEEE (IEEE P1159.3 Task Force, 2013), ilustra a ocorrência de múltiplos distúrbios dentro de uma janela de dados. A Figura 2.2(a) mostra o sinal de corrente medido $u[n]$, a Figura 2.2(b) mostra a estimativa do componente fundamental $f[n]$, obtida por um filtro *notch* com frequência de corte igual a 60 Hz, e a Figura 2.2(c) mostra a sequência $x[n] = u[n] - f[n]$, chamada aqui de sinal de erro. Aparentemente, o sinal de erro consiste de harmônicos, de um transitório que pode a princípio ser assumido como sendo um transitório oscilatório, e talvez de outros distúrbios que sejam mais difíceis de serem visualmente reconhecidos.

Pressupondo que os sinais elétricos de tensão e corrente possam ser representados por (2.1), quando uma situação de múltiplos distúrbios ocorre, a sequência $u[n]$ pode ser decomposta em seus componentes primitivos, de tal forma que cada componente primitivo forneça informações mais específicas do que o próprio sinal $u[n]$, a respeito de cada distúrbio que esteja ocorrendo dentro da mesma janela de dados.

De fato, se um método de análise de distúrbios de QEE (por exemplo, detecção, classificação,

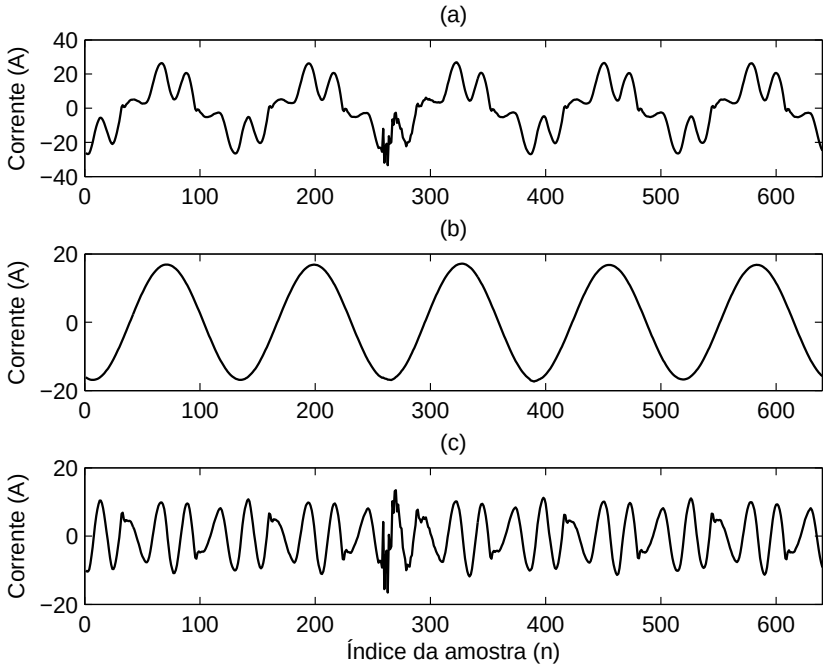


Figura 2.2: Exemplo de ocorrência de múltiplos distúrbios; (a) Sinal de corrente monitorado $u[n]$, (b) Componente fundamental estimado $f[n]$ e, (c) sinal de erro $x[n] = u[n] - f[n]$.

identificação) é modelado considerando a existência de um único distúrbio dentro da janela de dados, e se uma situação de múltiplos distúrbios ocorrer, o desempenho de tal método seria reduzido devido à maior complexidade das fronteiras que separam as características que diferem os distúrbios (Ribeiro e Pereira, 2007). Isto é devido ao fato de que, no paradigma padrão, o vetor de características $\mathbf{p}_u$ é extraído diretamente da sequência $u[n]$, a qual consiste de diversos componentes, que são associados a conjuntos de distúrbios distintos.

Como resultado, o projeto de técnicas de análise, especialmente para classificação de múltiplos distúrbios, é uma tarefa muito difícil de ser realizada (Wang e Mamishev, 2004; Wang *et al.*, 2004), já que os sinais elétricos são, na maioria dos casos, compostos por complexos padrões que são formados por múltiplos padrões primitivos. Portanto, as superfícies entre as regiões de classificação que são associadas a diferentes tipos de distúrbios isolados e múltiplos no espaço do vetor de características, podem ser muito complexas e difíceis de serem obtidas, mesmo se poderosas técnicas de extração de características e classificação forem aplicadas. Como resultado, o projeto de técnicas de reconhecimento de padrões oferece baixo desempenho se (2.1) for composto por múltiplos distúrbios.

De forma a superar as limitações do paradigma padrão e abrir novas possibilidades e desafios

para a análise da QEE, um paradigma baseado no *princípio de dividir para conquistar* é utilizado neste trabalho. Em tal paradigma, a sequência $u[n]$ poderia ser decomposta em seus componentes primitivos, fornecendo assim informações mais específicas a respeito dos distúrbios individuais e, como consequência, os padrões primitivos poderiam ser classificados mais facilmente. Os componentes primitivos são os vetores formados a partir das amostras dos sinais definidos por (2.2), (2.3), (2.4), e (2.5), para $n = 0$ até $N - 1$.

A idéia principal é decompor ou quebrar os sinais medidos no SEP, que são assumidos complexos, em diversos componentes primitivos, que são assumidos mais simples, para os quais técnicas mais simples de reconhecimento de padrões possam ser projetadas e aplicadas. De fato, cada um dos vetores $\mathbf{f}$, $\mathbf{h}$, $\mathbf{i}$, $\mathbf{t}_{\text{imp}}$, $\mathbf{t}_{\text{not}}$, $\mathbf{t}_{\text{osc}}$ e $\mathbf{t}_{\text{dec}}$ são relacionados a classes disjuntas e independentes de distúrbios, e o reconhecimento delas em paralelo poderia ser realizado mais facilmente.

De uma perspectiva da QEE, as vantagens e oportunidades oferecidas por este paradigma são promissoras para caracterizar de forma completa o comportamento dos sinais elétricos não apenas para propósitos de detecção e classificação, mas também para diversos outros propósitos passíveis de serem implementados nas novas redes inteligentes, tais como estimação de parâmetros dos distúrbios individuais, identificação e localização das fontes dos distúrbios, compressão de dados dos distúrbios, etc. Para que essa estratégia seja executada com sucesso, deve-se desenvolver e aplicar técnicas de PDS capazes de decompor o vetor $\mathbf{u}$ nos vetores $\mathbf{f}$, $\mathbf{h}$, $\mathbf{i}$, $\mathbf{t}_{\text{imp}}$, $\mathbf{t}_{\text{not}}$, $\mathbf{t}_{\text{osc}}$ e $\mathbf{t}_{\text{dec}}$, de forma a permitir a utilização posterior de técnicas mais simples dedicadas à extração de características individuais de cada componente primitivo e sua classificação.

Uma vez que as formas de onda de tensão e/ou corrente tenham sido corretamente adquiridas, digitalizadas e armazenadas na memória do dispositivo de monitoramento, e em seguida o sinal tenha sido decomposto em seus componentes primitivos, diversos parâmetros úteis podem ser calculados a partir de cada componente primitivo utilizando-se os algoritmos apropriados. Por exemplo, a partir do componente fundamental, podem ser calculados e apresentados pelo medidor ao usuário: sua frequência, amplitude e valor RMS em função do tempo, ou a duração de afundamentos, elevações e interrupções. A partir dos harmônicos, podem ser calculados e apresentados o espectro harmônico e a THD. A partir dos inter-harmônicos, podem ser estimados o espectro de frequências, suas frequências inter-harmônicas, ou alguns parâmetros relacionados ao *flicker*, tais como a variação da amplitude da tensão, a frequência de ocorrência e a frequência de modulação. A partir do transitório impulsivo, podem ser estimados a amplitude do seu

valor de pico, seu tempo de subida e sua duração. A partir do transitório oscilatório, podem ser estimados sua amplitude de pico, sua frequência de oscilação, seu decaimento exponencial, etc.

Os instrumentos projetados especificamente para monitoramento da QEE em sistemas de distribuição ou em pontos de acoplamento de cargas no SEP geralmente possuem quatro estágios de funcionalidade (IEEE Std. 1159, 2009). O primeiro estágio do processo é a aquisição de dados. Tipicamente, este estágio inclui redes de divisores de tensão utilizando resistores de alta impedância e possivelmente optoacopladores para as entradas de tensão e inclui conversores corrente/tensão para as entradas de corrente. Estes sinais são digitalizados por meio de CADs e processados pelo *hardware* de aquisição e/ou pelo *firmware* do dispositivo. O próximo estágio é o gerenciamento da base de dados das formas de onda e o cálculo de parâmetros pelo microprocessador, incluindo a determinação de quais informações devem ser armazenadas e quando o devem ser. Análises e caracterizações adicionais geralmente são realizadas neste estágio. Estas informações são estão transmitidas pelo estágio de comunicação como saída para o estágio de visualização, que pode consistir de um *display* local para visualização do usuário ou de ferramentas de visualização remotas, como por exemplo um navegador de *internet*.

O desenvolvimento constante dos microprocessadores tem permitido a aplicação de ferramentas de PDS cada vez mais poderosas, com o objetivo de extrair um maior número de características relevantes dos sinais de tensão e corrente registrados pelos monitores de QEE. Cabe ressaltar que a implementação das técnicas propostas para o processamento dos sinais de distúrbios, bem como as técnicas de análise da QEE em *software* embarcado em processador digital de sinais (*Digital Signal Processor* (DSP)) exige esforços consideráveis de projeto e verificação (Stranneby, 2001). Por outro lado, há a possibilidade de implementação, com um esforço menor, em uma plataforma construída para aplicações de *softwares* embarcados que dependam de aquisição de dados confiáveis em ambientes extremos, tal como a plataforma PC/104 (PC/104 Consortium, 2013). Além de características que provêm robustez à plataforma PC/104, esta permite o uso de sistemas operacionais convencionais, flexibilizando sua aplicação. Também é possível a utilização de sistemas operacionais de tempo real para suprir a necessidade de aplicações que têm requisitos de tempo. Tais características fazem da plataforma PC/104 uma excelente base para desenvolvimentos futuros de aplicações de PDS no contexto das redes elétricas inteligentes, pois une robustez com flexibilidade.

## 2.4 Considerações finais do capítulo

Este capítulo descreveu os tipos de distúrbios de QEE mais encontrados em SEPs, apresentou uma revisão sobre as técnicas de PDS mais empregadas para análise de distúrbios de QEE e apresentou a formulação matemática do problema de múltiplos distúrbios na qual este trabalho se baseia. O próximo capítulo descreverá a técnica ICA, amplamente utilizada para resolver o problema de separação cega de fontes. A ICA será utilizada neste trabalho como principal ferramenta de uma metodologia para decompor de maneira não-supervisionada (não necessitando de dados ou sequência de treinamento) o sinal de entrada em seus componentes independentes, utilizando-se o modelo do sinal de entrada como sendo uma soma de componentes primitivos, modelo o qual foi apresentado neste capítulo. O próximo capítulo também fará uma breve revisão dos conceitos básicos de RNAs, pois esta ferramenta será posteriormente utilizada para classificar os distúrbios separados pela etapa de decomposição.

# Capítulo 3

# Ferramentas Computacionais Utilizadas

Este capítulo apresenta os conceitos básicos das principais ferramentas computacionais que serão utilizadas neste trabalho.

## 3.1 Análise de Componentes Independentes

### 3.1.1 Motivação

Considere uma situação em que se tem um número de fontes emitindo sinais que estão interferindo uns com os outros. Algumas situações familiares em que isto ocorre são: uma sala cheia com muitas pessoas falando ao mesmo tempo, ondas eletromagnéticas de diferentes telefones móveis se interferindo, ou a interferência entre ondas cerebrais emitidas de diferentes áreas do cérebro. Em cada uma dessas situações, os sinais misturados são às vezes incompreensíveis, e seria interessante separar os sinais individuais. Este é o objetivo da BSS.

Um problema clássico em BSS é o problema da festa de coquetel (*cocktail party problem*) (Hyvärinen *et al.*, 2001; Haykin, 2008). O objetivo é amostrar uma mistura de vozes com um dado número de microfones (observações), e então separar cada voz individual em um canal separado (fontes). Na verdade, o próprio cérebro humano possui uma habilidade notável para se concentrar em um locutor dentro de um ambiente ruidoso de uma festa de coquetel, apesar de o sinal de voz originário daquele locutor estar envolvido por um fundo extremamente ruidoso devido à interferência de outras conversas na sala. Pode-se dizer que a BSS se inspira nessa

capacidade do cérebro humano. Na BSS, a palavra *blind* (cega) se refere ao fato de que não se tem conhecimento de como os sinais foram misturados ou de como eles foram gerados. Desta forma, a princípio a separação parece impossível. Entretanto, satisfazendo-se algumas restrições relativamente indiretas e gerais, o termo BSS se mantém válido e a separação é realizada sujeito a essas restrições.

A ICA é uma técnica estatística, talvez a mais utilizada, para resolver o problema de BSS (Hyvärinen *et al.*, 2001). A ICA é essencialmente um método para extrair sinais individuais a partir de misturas. Sua capacidade reside em hipóteses físicas de que diferentes processos físicos geram sinais não-relacionados. A natureza simples e genérica destas hipóteses permite à ICA ser aplicada com sucesso em uma faixa diversa de aplicações em diferentes áreas do conhecimento, tais como em processamento de sinais biomédicos, telecomunicações, economia, processamento de sinais de áudio e processamento de imagens (Hyvärinen *et al.*, 2001).

### 3.1.2 Definição da ICA

Segundo Comon (1994), a ICA de um vetor aleatório $\mathbf{x} = [x_1, x_2, \ldots, x_M]^T$ consiste na determinação de uma transformação linear $\mathbf{y} = \mathbf{W} \cdot \mathbf{x}$ que minimiza a dependência estatística entre os elementos do vetor aleatório $\mathbf{y} = [y_1, y_2, \ldots, y_P]^T$.

Assumindo-se que os elementos do vetor aleatório $\mathbf{x}$ sejam modelados como combinações lineares dos elementos do vetor aleatório $\mathbf{s} = [s_1, s_2, \ldots, s_P]^T$, pode-se escrever na forma matricial:

$$\mathbf{x} = \mathbf{A} \cdot \mathbf{s}, \tag{3.1}$$

onde os elementos de $\mathbf{s}$ são estatisticamente independentes entre si, e $\mathbf{A}$ corresponde a uma matriz de coeficientes de mistura de dimensão $M \times P$.

Este é o modelo básico da ICA. Ele é chamado modelo generativo, que significa que ele descreve como os dados observados $x_i$ são formados a partir de um processo de mistura dos componentes $s_j$. Os componentes independentes $s_j$ são variáveis latentes, significando que eles não podem ser diretamente observados. Também, os coeficientes da matriz $\mathbf{A}$ são assumidos desconhecidos. Tem-se conhecimento apenas das variáveis aleatórias $x_i$, e deve-se estimar tanto os coeficientes da matriz $\mathbf{A}$ quanto os componentes independentes $s_j$, a partir apenas do vetor aleatório $\mathbf{x}$.

Um aspecto fundamental do processo de mistura é que os sensores que obtêm os sinais observados $x_i$ devem ser separados no espaço (por exemplo, microfones que são espacialmente distribuídos dentro de uma sala) de tal forma que cada sensor registre uma mistura diferente das fontes $s_j$.

O diagrama de blocos da Figura 3.1 ilustra ambos os processos de mistura e separação envolvidos na BSS. As fontes independentes são misturadas pela matriz **A** (que é desconhecida). A ICA busca obter um vetor **y** que aproxima o vetor **s** estimando a matriz de separação **W** por meio de um algoritmo de aprendizagem adaptativo. Se a estimativa da matriz de separação possui boa exatidão, então obtém-se uma boa aproximação das fontes. O modelo descrito é o modelo mais simples da ICA, já que ele ignora os ruídos e qualquer atraso de tempo nos sinais registrados pelos sensores.

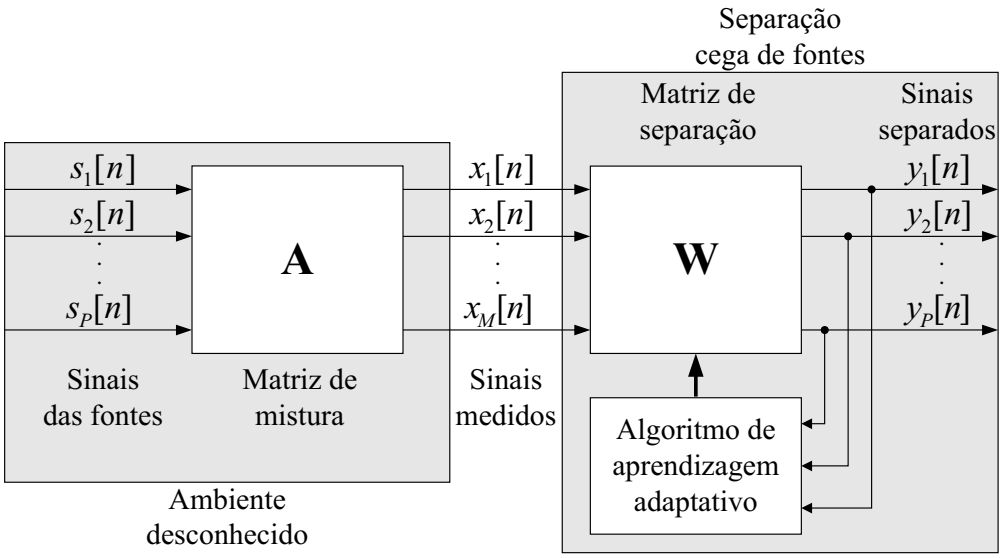


Figura 3.1: Diagrama de blocos da BSS.

### 3.1.3 Restrições da ICA

Para assegurar que o modelo básico da ICA possa ser estimado corretamente, as seguintes restrições devem ser satisfeitas.

1. As fontes devem ser estatisticamente independentes entre si.

2. No máximo uma fonte deve apresentar distribuição gaussiana.

3. A matriz de mistura deve ser invertível.

A primeira restrição constitui o fundamento da ICA. As variáveis aleatórias $s_1, s_2, \ldots, s_P$ são ditas estatisticamente independentes se a informação do valor de $s_i$ não fornece qualquer informação a respeito do valor de $s_j$, para $i \neq j$. Essas variáveis poderiam ser, por exemplo, obtidas de processos físicos diferentes que não são relacionados uns com os outros. No contexto deste trabalho, essas variáveis poderiam estar relacionadas a fontes distintas e independentes de distúrbios de QEE ocorrendo em um mesmo SEP. Tais fontes de distúrbios poderiam ser, por exemplo, uma carga não-linear injetando harmônicos em um determinado ponto do SEP e o transitório oscilatório oriundo de um evento de chaveamento de banco de capacitores em uma outra posição do mesmo SEP. Matematicamente, a independência estatística das variáveis aleatórias $s_1, s_2, \ldots, s_P$ ocorre quando a seguinte condição é estabelecida (Papoulis e Pillai, 2002):

$$p_{s_1,s_2,\ldots,s_P}(s_1, s_2, \ldots, s_P) = p_1(s_1)p_2(s_2)\ldots p_P(s_P) \tag{3.2}$$

onde $p_{s_1,\ldots,s_P}(s_1, \ldots, s_P)$ corresponde à função densidade de probabilidade conjunta das variáveis envolvidas e $p_i(s_i)$ representa a função densidade de probabilidade marginal de $s_i$.

A segunda restrição com relação às fontes é que elas devem possuir distribuições não-gaussianas. Como será visto na seção 3.1.6, as funções objetivo utilizadas nos algoritmos de estimação de ICA são baseadas em estatísticas de ordem superior (*Higher Order Statistics* (HOS)). Entretanto, para distribuições gaussianas, as HOS são nulas ou contêm informação redundante. Também, a distribuição de probabilidade conjunta de variáveis gaussianas é rotacionalmente simétrica a uma transformação ortogonal, se os dados forem branqueados (Hyvärinen *et al.*, 2001). Este é o resultado de que variáveis gaussianas descorrelacionadas são necessariamente independentes (Papoulis e Pillai, 2002). Portanto, apenas uma única variável gaussiana pode ser estimada. Na prática, a maioria das fontes de interesse são não-gaussianas (Hyvärinen *et al.*, 2001), incluindo aquelas fontes de distúrbios de QEE a serem analisados neste trabalho.

A terceira restrição é direta. Se a matriz de mistura não for invertível, então claramente a matriz de separação não existe. Esta restrição requer que a matriz de mistura possua posto (*rank*) completo, indicando que o número de sinais observáveis deve ser maior ou igual ao número de fontes, e que todos os sinais observáveis sejam linearmente independentes entre si. No contexto de QEE, tal situação corresponderia à alocação de diversos monitores sincronizados alocados em diferentes posições do SEP para a obtenção dos dados. No entanto, no Capítulo 4 serão propostos dois métodos para utilização da ICA tendo-se disponível dados obtidos a partir

de apenas um dispositivo de monitoramento.

Se essas três restrições são satisfeitas, então é possível estimar os componentes independentes a menos de algumas indeterminações. Essas restrições não deixam de justificar a aplicação da ICA, já que na prática necessita-se de muito pouca informação a respeito do processo de mistura e das fontes.

### 3.1.4 Indeterminações da ICA

Há duas indeterminações ou ambiguidades na estimação do modelo da ICA dado por (3.1). Essas indeterminações ocorrem devido ao fato de tanto as fontes $\mathbf{s}$ quanto a matriz de misturas $\mathbf{A}$ serem desconhecidas. A estimação da ICA não recupera a ordem das fontes e nem seus ganhos de escala. De certo modo, essa limitação é bem intuitiva, pois a independência estatística entre os elementos de um vetor aleatório não é alterada por permutações e escalas (Papoulis e Pillai, 2002).

#### Indeterminação dos ganhos de escala das fontes

A razão é que, sendo ambos $\mathbf{s}$ e $\mathbf{A}$ desconhecidos, qualquer constante escalar multiplicada por uma das fontes $s_j$ pode sempre ser cancelada pela divisão da respectiva coluna $\mathbf{a}_j$ de $\mathbf{A}$ pelo mesmo escalar, digamos $\alpha_j$, como em (3.3).

$$\mathbf{x} = \sum_{j=1}^{P} \left( \frac{1}{\alpha_j} \mathbf{a}_j \right) (\alpha_j s_j) \tag{3.3}$$

Felizmente, na maioria das aplicações esta ambiguidade é insignificante. A solução natural para isto é utilizar a hipótese de que cada fonte possui variância unitária, ou seja, $E\{s_j^2\} = 1$. Então, a matriz $\mathbf{A}$ é adaptada na solução do algoritmo ICA para levar em conta esta hipótese. Ainda assim, permanece a indeterminação no sinal das fontes, pois pode-se multiplicar um componente por -1 sem afetar o modelo e a estimação. Esta indeterminação é irrelevante na maioria dos casos.

#### Indeterminação da ordem das fontes

Novamente, como ambos $\mathbf{s}$ e $\mathbf{A}$ são desconhecidos, pode-se estimar os componentes independentes em qualquer ordem. Formalmente, uma matriz de permutação $\mathbf{P}$ e sua inversa podem

ser multiplicadas em (3.1), ou seja, $\mathbf{x} = \mathbf{A}\mathbf{P}^{-1}\mathbf{P}\mathbf{s}$. Os elementos de $\mathbf{P}\mathbf{s}$ são as fontes originais, porém, em uma ordem diferente. A matriz $\mathbf{A}\mathbf{P}^{-1}$ é uma outra matriz de mistura desconhecida que será encontrada pelo algoritmo de ICA.

### 3.1.5 Aplicações de técnicas baseadas em estatísticas de segunda ordem à ICA como etapa de pré-processamento

O problema BSS/ICA pode ser resolvido baseado na independência estatística das fontes, ou seja, através de HOS, já que a independência é caracterizada pelo conhecimento das densidades de probabilidade, e, consequentemente, de todas as estatísticas de uma variável aleatória. Portanto, as estatísticas de segunda ordem não são suficientes para resolver o problema por completo. Entretanto, será visto que estas estatísticas podem contribuir significativamente como etapa de pré-processamento na resolução dos algoritmos de ICA. Uma consagrada técnica baseada em estatísticas de segunda ordem, e muito utilizada no pré-processamento da ICA, é a PCA.

#### Análise de Componentes Principais

A PCA (Hyvärinen *et al.*, 2001), conhecida também como transformada discreta de Karhunen-Loève ou transformada de Hotelling, é uma técnica clássica em análise estatística de dados, extração de parâmetros e compressão de dados. A PCA emprega a correlação como medida de redundância entre os componentes, diferentemente da ICA, que emprega a independência estatística. Utilizando apenas correlação, a PCA pode ser calculada através de estatísticas de segunda ordem. Sendo assim, a PCA é uma medida "mais fraca" de informação se comparada à ICA, não sendo suficiente para explorar toda a redundância entre variáveis aleatórias. Entretanto, ela desempenha uma importante etapa de pré-processamento no cálculo da ICA, reduzindo o número de parâmetros a serem estimados.

Seja um vetor aleatório $\mathbf{x} = [x_1, \ldots, x_M]^T$, sendo que há informação redundante entre os elementos desse vetor. Portanto, os elementos desse vetor são mutuamente correlacionados. Inicialmente, é removida a média do vetor $\mathbf{x}$ através de:

$$\mathbf{x} \leftarrow \mathbf{x} - E\{\mathbf{x}\}. \tag{3.4}$$

Na prática, a média é estimada a partir das amostras temporais $\mathbf{x}[1], \ldots, \mathbf{x}[N]$. Em seguida, a PCA realiza uma transformação linear que, aplicada ao vetor $\mathbf{x}$, resulta em um vetor alea-

tório $\mathbf{y} = [y_1, \ldots, y_P]^T$ $(P \leq M)$, cujos elementos, denominados componentes principais, são descorrelacionados entre si.

Portanto, a redundância promovida pela correlação é removida pela PCA, tornando possível a redução da dimensão de $\mathbf{x}$. Ao mesmo tempo, as variâncias das projeções dos elementos de $\mathbf{x}$ em $\mathbf{y}$ são maximizadas, de tal forma que o primeiro eixo corresponde à máxima variância, o segundo eixo corresponde à máxima variância na direção ortogonal ao primeiro eixo, e assim por diante. A variância está relacionada à quantidade de informação que o componente pode oferecer. Sendo assim, o primeiro componente principal de $\mathbf{y}$ concentra a maior quantidade de informação a respeito de $\mathbf{x}$, o segundo componente principal concentra a maior quantidade de informação na direção ortogonal ao primeiro, e assim por diante.

A PCA é muito útil para reduzir a dimensão dos dados na situação em que $M > P$, ou seja, em que o número de misturas é maior que o número de fontes.

**Branqueamento**

Não há redução da dimensão dos dados através da PCA na situação em que $M = P$. Entretanto, este procedimento ainda permite a determinação de uma transformação sobre $\mathbf{x}$ que resulte em um vetor aleatório descorrelacionado, que como será visto a seguir, reduz consideravelmente o número de parâmetros a serem estimados pela ICA.

O branqueamento é uma transformação linear do vetor observado $\mathbf{x}$, que produz um novo vetor $\mathbf{z}$ que é branco, isto é, seus componentes são descorrelacionados e com variâncias unitárias. Em outras palavras, a matriz de covariância de $\mathbf{z}$ é igual à matriz identidade:

$$E\{\mathbf{z}\mathbf{z}^T\} = \mathbf{I}. \tag{3.5}$$

Devido ao fato do branqueamento ser essencialmente descorrelação seguida por normalização da variância do vetor $\mathbf{x}$, ele pode ser calculado através da PCA.

Dado um vetor aleatório $\mathbf{x}$ contendo $M$ elementos, o branqueamento de $\mathbf{x}$ é realizado a partir da transformação linear

$$\mathbf{z} = \mathbf{V}\mathbf{x}. \tag{3.6}$$

Seja $\mathbf{E} = [\mathbf{e}_1 \quad \ldots \quad \mathbf{e}_M]$ uma matriz cujas colunas são os autovetores de norma unitária da matriz de covariância $\mathbf{C_x} = E\{\mathbf{x}\mathbf{x}^T\}$ e $\mathbf{D} = \text{diag}(d_1 \quad \ldots \quad d_M)$ uma matriz diagonal contendo os autovalores de $\mathbf{C_x}$. Então uma matriz de branqueamento é dada por (Hyvärinen *et al.*, 2001):

$$\mathbf{V} = \mathbf{E}\mathbf{D}^{-1/2}\mathbf{E}^T. \tag{3.7}$$

A partir de (3.1), (3.6) e (3.7), pode-se escrever:

$$\mathbf{z} = \mathbf{V}\mathbf{x} = \mathbf{E}\mathbf{D}^{-1/2}\mathbf{E}^T\mathbf{A}\mathbf{s} = \tilde{\mathbf{A}}\mathbf{s}. \tag{3.8}$$

A utilidade do branqueamento reside no fato de que a nova matriz $\tilde{\mathbf{A}}$ é ortogonal. Sendo assumido que as fontes que compõem o vetor $\mathbf{s}$ são independentes, elas são necessariamente descorrelacionadas. Então:

$$E\{\mathbf{z}\mathbf{z}^T\} = \tilde{\mathbf{A}}E\{\mathbf{s}\mathbf{s}^T\}\tilde{\mathbf{A}}^T = \tilde{\mathbf{A}}\tilde{\mathbf{A}}^T = \mathbf{I}. \tag{3.9}$$

Aqui, pode-se observar que o branqueamento reduz o número de parâmetros a se estimar. Ao invés de ter que estimar os $M^2$ parâmetros, que são os elementos da matriz original $\mathbf{A}$, tem-se apenas que estimar a nova matriz de mistura ortogonal $\tilde{\mathbf{A}}$. Uma matriz ortogonal de dimensão $M^2$ contém $M(M-1)/2$ graus de liberdade (Hyvärinen *et al.*, 2001). Por exemplo, em duas dimensões, uma matriz ortogonal é determinada apenas por um ângulo. Em dimensões maiores, uma matriz ortogonal contém cerca de metade do número de parâmetros da matriz original. Sendo assim, pode-se dizer que o branqueamento resolve metade do problema da ICA. Sendo o branqueamento uma operação simples, muito mais simples do que qualquer algoritmo de ICA, ele é uma boa escolha para reduzir a complexidade do problema.

### 3.1.6 Funções objetivo utilizadas como medida de independência estatística

A essência da técnica de análise de componentes independentes, conforme discutido nas seções anteriores, consiste em determinar uma estrutura para separação de fontes de forma a obter estimativas independentes entre si, o que garante a recuperação das fontes independentes caso não haja mais do que uma fonte gaussiana.

O processo de mistura e separação da ICA é mostrado na Figura 3.2. O branqueamento é

utilizado como pré-processamento das misturas observadas. Os algoritmos de ICA funcionam sem esta etapa, mas ela simplifica a estimação e por isso é empregada na maioria dos casos. A estimação da matriz de separação **W** é um processo iterativo baseado na otimização de uma função objetivo.

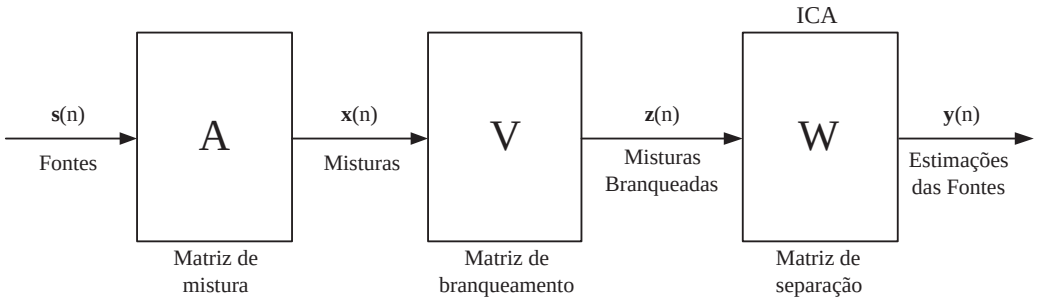


Figura 3.2: Processo de mistura e separação da ICA.

As funções objetivo desenvolvidas para ICA exploram, direta ou indiretamente, as hipóteses de independência estatística e *não-gaussianidade* das fontes. Nesta seção, serão apresentadas as principais abordagens desenvolvidas nesse contexto.

### Informação mútua

A informação mútua pode ser utilizada como uma medida de independência estatística pela ICA (Comon, 1994). A informação mútua é minimizada por meio da determinação de uma matriz **W** que minimiza a dependência entre os componentes do vetor **y**. A informação mútua $I(y_1, y_2, \ldots, y_P)$ de $P$ variáveis aleatórias $y_1, y_2, \ldots, y_P$ pode ser definida como:

$$I(y_1, y_2, \ldots, y_P) = \sum_{j=1}^{P} H(y_j) - H(\mathbf{y}). \tag{3.10}$$

Em (3.10), $H(y_j)$ é a entropia marginal de $y_j$ e $H(\mathbf{y})$ é a entropia conjunta do vetor **y** incluindo todas as variáveis $y_j$. $H(y_j)$ e $H(\mathbf{y})$ são definidos como:

$$\begin{aligned} H(y_j) &= -\int p_{y_j}(y_j) \log p_{y_j}(y_j) dy_j, \\ H(\mathbf{y}) &= -\int p_{\mathbf{y}}(\mathbf{y}) \log p_{\mathbf{y}}(\mathbf{y}) d\mathbf{y}. \end{aligned} \tag{3.11}$$

A entropia[1] de uma variável aleatória fornece uma idéia da incerteza sobre o valor que esta

[1] A quantidade $H(y)$ também pode ser definida para variáveis discretas. Neste caso, $H(y) = -\sum_j p_j \log p_j$, e apresenta propriedades semelhantes à entropia para variáveis contínuas.

variável assume (Cavalcante, 2004). Pode-se mostrar que a distribuição gaussiana apresenta a maior entropia dentre todas as distribuições com mesma variância.

A informação mútua pode ser escrita em termos da divergência de *Kullback-Leibler* (Comon, 1994). Matematicamente, a divergência de *Kullback-Leibler* entre duas funções multidimensionais $f(\mathbf{r})$ e $g(\mathbf{r})$ é dada por:

$$D\left(f(\mathbf{r}), g(\mathbf{r})\right) = \int f(\mathbf{r}) \log \frac{f(\mathbf{r})}{g(\mathbf{r})} d\mathbf{r}. \tag{3.12}$$

Um importante caso particular dessa medida ocorre quando uma das funções corresponde à densidade de probabilidade conjunta do vetor aleatório $\mathbf{y}$ e a outra denota o produto das densidades marginais dos elementos desse vetor. Matematicamente, este caso é expresso do seguinte modo:

$$D\left(p_{\mathbf{y}}(\mathbf{y}), p_{y_1}(y_1)p_{y_2}(y_2)\ldots p_{y_P}(y_P)\right) = \int p_{\mathbf{y}}(\mathbf{y}) \log \frac{p_{\mathbf{y}}(\mathbf{y})}{p_{y_1}(y_1)p_{y_2}(y_2)\ldots p_{y_P}(y_P)} d\mathbf{y}. \tag{3.13}$$

Esta medida sempre assume valores não-negativos e é igual a zero se e somente se as duas funções em questão forem iguais. A partir de (3.2), esta condição ocorre quando os elementos de $\mathbf{y}$ forem independentes.

Após um simples desenvolvimento, pode-se constatar que (3.13) é equivalente a (3.10), ou seja:

$$I(y_1, y_2, \ldots, y_P) = \int p_{\mathbf{y}}(\mathbf{y}) \log \frac{p_{\mathbf{y}}(\mathbf{y})}{p_{y_1}(y_1)p_{y_2}(y_2)\ldots p_{y_P}(y_P)} d\mathbf{y}. \tag{3.14}$$

Portanto, como era de se esperar, a informação mútua entre os elementos de um vetor aleatório é nula quando eles são independentes. Dessa forma, a minimização da informação mútua configura-se como uma função objetivo para a otimização da estrutura de separação.

### Maximização da *não-gaussianidade*

A idéia principal deste critério é o ajuste do sistema separador de modo que as densidades de probabilidade de cada uma das estimativas das fontes sejam, em algum sentido, as mais distantes possível de uma variável gaussiana. Portanto, a estratégia consiste em adaptar a

matriz de separação de forma a maximizar a *não-gaussianidade* dos sinais estimados. Embora não seja evidente, o princípio leva à estimação de sinais independentes entre si, mostrando-se um método apropriado para a ICA. Um dos principais benefícios desta estratégia é a possibilidade de recuperação individual das fontes. Um dos algoritmos mais conhecidos para resolução da ICA é o *Fast Fixed-point Algorithm for Independent Component Analysis* (FastICA) (Hyvärinen, 1999; Hyvärinen *et al.*, 2001), que foi desenvolvido com base neste critério.

A idéia chave presente na abordagem via maximização da *não-gaussianidade* está associada ao Teorema do Limite Central (Papoulis e Pillai, 2002). Em linhas gerais, o teorema estabelece que o resultado da soma de um conjunto de variáveis aleatórias independentes resulta em uma variável mais próxima de uma gaussiana do que qualquer uma pertencente a este conjunto. Portanto, baseado neste teorema, as misturas são mais gaussianas do que qualquer uma das fontes.

Logo, uma tentativa de ajustar $\mathbf{W}$ fundamenta-se na recuperação da *não-gaussianidade* das estimativas das fontes. No modelo de (3.1), suponha que se esteja interessado em recuperar apenas uma das fontes e, para isto, utiliza-se um vetor de separação $\mathbf{w}_1$:

$$y_1 = \mathbf{w}_1^T \mathbf{x} = \mathbf{q}^T \mathbf{s} = \sum_{j=1}^{P} q_j s_j, \tag{3.15}$$

onde $\mathbf{q} = \mathbf{w}_1^T \mathbf{A}$ representa o efeito conjunto dos sistemas misturador e separador. Nota-se que $y_1$, uma estimativa da fonte original, é uma combinação linear do vetor de fontes $\mathbf{s}$. Assim, para que se tenha uma estimativa da fonte original, basta que $\mathbf{q}$ seja um vetor com apenas um elemento não-nulo.

Como a estimativa $y_1 = \mathbf{q}^T \mathbf{s}$ é uma soma ponderada das fontes, pode-se dizer que a sua distribuição será mais gaussiana do que qualquer uma das distribuições das fontes $s_j$. Portanto, pensando de forma inversa, $y_1$ será o menos gaussiano possível quando sua distribuição for igual à de qualquer uma das fontes $s_j$, ou seja, quando $\mathbf{q}$ possuir apenas um elemento não-nulo. Dessa forma, obter o vetor $\mathbf{w}_1$ que maximize a *não-gaussianidade* de $\mathbf{w}_1^T \mathbf{x}$ configura-se como uma possível estratégia para a recuperação da fonte.

Para extrair $k$ fontes ($k = 1, \ldots, P$), se faz necessária alguma regra que evite que o algoritmo convirja para um mesmo ponto de máxima *não-gaussianidade*, o que representaria a recuperação da mesma fonte. Caso a matriz de mistura seja previamente branqueada, as suas linhas são ortogonais. Portanto, uma estratégia viável seria inserir alguma etapa no algoritmo que garanta

a ortogonalidade dos vetores estimados.

Uma forma clássica de medir a *gaussianidade*, e consequentemente a *não-gaussianidade* de variáveis aleatórias, é através da *kurtosis* (Papoulis e Pillai, 2002), ou cumulante de quarta ordem, cuja definição para uma variável aleatória de média zero, $y$, é dada por:

$$\kappa_4(y) = E\left\{y^4\right\} - 3\left[E\left\{y^2\right\}\right]^2. \tag{3.16}$$

Uma interessante propriedade da *kurtosis* é que esta medida é não-nula para a grande maioria das variáveis aleatórias, sendo a gaussiana uma das poucas exceções desta regra. De fato, é usual classificar as distribuições com relação aos valores de suas *kurtosis*: caso $\kappa_4(y) = 0$, diz-se que $y$ possui distribuição *gaussiana*; caso $\kappa_4(y) < 0$, diz-se que $y$ possui distribuição *sub-gaussiana*; caso $\kappa_4(y) > 0$, diz-se que $y$ possui distribuição *super-gaussiana*. Deste modo, um critério para maximizar a *não-gaussianidade* pode ser obtido através da maximização do valor absoluto da *kurtosis* do sinal estimado, ou seja:

$$\max_{\mathbf{w}} |\kappa_4(y_j)|, \tag{3.17}$$

tendo como principal atrativo sua simplicidade.

Na prática, para se encontrar a matriz de separação $\mathbf{W}$ que fornecerá o vetor de componentes independentes $\mathbf{y}[n]$, tal que $\mathbf{y}[n] = \mathbf{W} \cdot \mathbf{x}[n]$, com base na medida das *kurtosis* das estimativas, deve-se, como descrito em Hyvärinen *et al.* (2001):

1. Branquear o vetor de sinais observados $\mathbf{x}[n]$, de forma a obter $\mathbf{z}[n]$;
2. Inicializar $\mathbf{W}$ com um valor aleatório;
3. Calcular a direção em que a *kurtosis* do $j$-ésimo componente $y_j[n]$ está crescendo (ou decrescendo) mais fortemente;
4. Baseado nas medidas disponíveis $\mathbf{x}[n]$, utilizar um método de gradiente ou equivalente, para encontrar um novo vetor $\mathbf{w}$;
5. As etapas 3 e 4 continuam até que todas as fontes sejam estimadas.

Há uma outra opção de medida de *não-gaussianidade* chamada *negentropia*, que é baseada na teoria da informação. Um dos principais resultados desta área afirma que, no conjunto de

todas as variáveis aleatórias de mesma variância, a variável gaussiana é aquela que possui a maior entropia (Cover e Thomas, 1991). Logo, uma possível estratégia de maximização da *não-gaussianidade* seria buscar a minimização das entropias marginais das estimativas das fontes.

A *negentropia* de uma variável aleatória $y$ é definida como:

$$J_{\text{Negentropia}}(y) = H(y_{\text{gauss}}) - H(y), \tag{3.18}$$

onde $y_{\text{gauss}}$ representa uma variável aleatória com distribuição gaussiana e mesma média e variância de $y$.

Uma vez que a entropia de uma variável aleatória é máxima para a distribuição gaussiana, a *negentropia* sempre assumirá valores não-negativos, sendo nula somente quando $y$ possuir distribuição gaussiana. Dessa forma, a *negentropia* fornece uma idéia da distância entre a distribuição de $y$ e aquela da variável gaussiana. A maximização da *não-gaussianidade* é alcançada através da maximização da *negentropia*. O conceito pode ser estendido diretamente para um vetor $\mathbf{y}$ de variáveis aleatórias, sendo $J_{\text{Negentropia}}(\mathbf{y}) = H(\mathbf{y}_{\text{gauss}}) - H(\mathbf{y})$, onde $\mathbf{y}_{\text{gauss}}$ representa um vetor aleatório com distribuição gaussiana e matriz de covariância igual à de $\mathbf{y}$. A *negentropia* possui a interessante propriedade de ser invariante a transformações lineares inversíveis (Hyvärinen *et al.*, 2001).

A *negentropia* é uma medida eficiente da *não-gaussianidade*. Entretanto, ela é difícil de ser calculada porque requer uma estimativa da função densidade de probabilidade. Sendo assim, aproximações mais simples da *negentropia* se fazem necessárias. Uma dessas aproximações é por meio de cumulantes de ordem superior (Hyvärinen, 1999):

$$J_{\text{Negentropia}}(y) \cong \frac{1}{12}\kappa_3^2(y) + \frac{1}{48}\kappa_4^2(y), \tag{3.19}$$

onde $\kappa_3$ e $\kappa_4$ são, respectivamente, os cumulantes de terceira e quarta ordem de uma variável aleatória $y$ com média nula e variância unitária. A partir desta aproximação obtém-se meios simples para estimação da *negentropia*, sem a necessidade de se efetuar a integração de funções, conforme a própria definição de entropia em (3.11).

Outras aproximações podem ser encontradas na literatura. Por exemplo, em Hyvärinen (1999) é proposta uma aproximação não-polinomial para a *negentropia* de uma variável aleatória, dada por:

$$J_{\text{Negentropia}}(y) = \alpha \left( E\{G(y)\} - E\{G(v)\} \right)^2 , \tag{3.20}$$

onde $G(.)$ é uma função não-linear e não-quadrática, $\alpha$ é uma constante e $v$ é uma variável aleatória gaussiana de média zero e variância unitária. Como consequência da utilização de uma gaussiana normalizada neste caso, é necessário restringir, durante a etapa de adaptação, a potência de cada uma das estimativas das fontes, assumindo por exemplo que $E\{|y_j|^2\} = E\{|\mathbf{w}_j^T \mathbf{x}|^2\} = 1$. A precisão da aproximação, no entanto, depende da escolha adequada da função não-linear $G(.)$.

### 3.1.7 Aplicações da ICA em SEP e QEE

Nesta seção, é apresentada uma breve revisão sobre algumas publicações envolvendo aplicações da ICA nas áreas de SEP e QEE. Podem ser facilmente encontradas várias publicações envolvendo a ICA nas áreas de separação de áudio, separação de imagens, telecomunicações e análise de sinais biomédicos. Entretanto, ainda não há muitos trabalhos que a utilizam nas áreas de SEP e QEE, embora tem sido crescente a sua aplicação nestas áreas ao longo dos últimos anos.

Há uma quantidade razoável de trabalhos que utilizam diferentes tipos de algoritmos de ICA para estimação de correntes harmônicas (Gursoy e Niebur, 2005, 2009; Supriya e Nambiar, 2011). De uma maneira geral, se as correntes harmônicas são estatisticamente independentes, a ICA é capaz de estimar essas correntes a partir de um número limitado de medidores de tensões harmônicas alocados em diferentes localizações em um SEP, sem qualquer conhecimento da topologia do SEP. Em Supriya e Nambiar (2012), é realizado um estudo que seleciona o melhor algoritmo de ICA baseado no desempenho em regime permanente para estimação de estado harmônico, sendo os resultados de estimação de diferentes algoritmos ICA processados por um filtro de Kalman, que funciona como um estimador ótimo de estado em uma frequência harmônica particular.

Em Farhoodnea *et al.* (2010), é proposta uma técnica para localização de fontes harmônicas em SEPs baseada na ICA, sendo esta aplicada para estimar os perfis das correntes harmônicas injetadas no sistema e produzidas por cargas não-lineares. Através da utilização da ICA, a reconstrução das correntes harmônicas é realizada a partir apenas das tensões harmônicas que são obtidas pelos medidores alocados nos barramentos, sem o conhecimento a respeito dos

componentes do sistema. A partir dos perfis de correntes harmônicas reconstruídos, a teoria da informação mútua é aplicada para determinar a localização exata das fontes harmônicas por meio do cálculo da informação mútua entre a tendência das correntes extraídas e as tensões dos barramentos. O método foi utilizado para determinar a localização provável de fontes harmônicas em sistemas radiais e malhados do instituto de engenheiros eletricistas e eletrônicos (*Institute of Electrical and Electronics Engineers* (IEEE)), com um erro quadrático médio menor que 0,00035.

Ai e Zhang (2013) modelam o problema de separação de harmônicos como um problema de BSS, e utilizam a ICA em conjunto com o método de mínimos quadrados (*Least Squares* (LS)) para resolver o problema. A ICA é utilizada inicialmente para determinar as ordens harmônicas através da construção de um número apropriado de sinais de observação virtuais. Então, o método LS é utilizado para determinar as amplitudes e as fases dos componentes harmônicos contidos no sinal de mistura. Segundo os autores, o método apresentado possui rápida velocidade de obtenção dos resultados e alta precisão dos mesmos. Em Liquan e Yanfei (2010), é utilizada a ICA para estimação das amplitudes, fases e frequências de inter-harmônicos, sendo utilizada uma variação do algoritmo para sinais complexos. Os resultados de simulação mostram que o algoritmo possui melhor resolução e exatidão do que o algoritmo *Multiple Signal Classification* (MUSIC) para estimação das frequências inter-harmônicas.

Em Liao e Niebur (2003), a ICA é utilizada para estimar perfis de cargas utilizando um pequeno conjunto de medições de fluxo de potência ativa, sem qualquer informação a respeito da topologia ou dos parâmetros do modelo da rede elétrica. É realizada uma técnica de pré-processamento utilizando um filtro de média móvel para assegurar a independência estatística das cargas. A influência do ruído de medida e da não-linearidade do modelo de fluxo de potência são também investigados. O método proposto é avaliado através da simulação de um sistema de cinco barras e do sistema de 30 barras do IEEE.

Em Han *et al.* (2005), a ICA é utilizada para a extração de sinais provenientes de fontes de vibração em máquinas elétricas rotativas a partir de medições ruidosas. A presença de ruído interfere na classificação de defeitos em máquinas, podendo levar a resultados incorretos. O método proposto aplica a ICA em conjunto com filtros de sub-bandas para a extração de informações das fontes relacionadas à rotação da máquina. Os resultados experimentais de testes de rolamento mostram que o método fornece informações mais precisas do que métodos convencionais, na análise de defeitos de rolamento na máquina a partir de dados corrompidos

por ruídos de fundo e interferência.

Em Dubey *et al.* (2011), é proposto um detector de faltas em SEP com vistas à aplicação em relés digitais baseado na ICA. Métodos tradicionais de detecção de faltas envolvem a comparação entre os valores das amostras de corrente para dois ciclos consecutivos, com a falta sendo detectada se os valores da diferença forem maiores do que um certo limiar. Entretanto, esses métodos possuem limitações devido às dificuldades em modelar a resistência de falta. Outras abordagens envolvem a aplicação de filtro de Kalman ou da transformada *wavelet* para detectar as alterações abruptas no sinal. Entretanto, esse métodos são sensíveis a desvios na frequência e também à presença de ruídos e harmônicos. Desta forma, é proposta a detecção da alteração abrupta no sinal devido à falta a partir dos componentes independentes das amostras do sinal de corrente, sendo definido um índice para a detecção da falta a partir do resultado encontrado pela ICA.

A partir da revisão realizada, percebe-se que há potenciais aplicações para a ICA nas áreas de SEP e QEE. Na próxima seção, será realizada uma revisão sucinta sobre RNAs, utilizadas neste trabalho para o propósito de classificação de distúrbios de QEE.

## 3.2 Redes Neurais Artificiais

A presente seção apresenta as RNAs como uma importante ferramenta para a classificação de padrões. Serão abordados os neurônios artificiais denominados *perceptrons*, bem como suas interconexões de forma a caracterizar uma rede *Perceptron* de Múltiplas Camadas (PMC).

De uma maneira geral, as RNAs são modelos matemáticos computacionais inspirados no sistema nervoso de seres vivos. Possuem a capacidade de aquisição e manutenção do conhecimento (baseado em informações) e podem ser definidas como um conjunto de unidades básicas de processamento (neurônios artificiais), os quais são interligados por um grande número de interconexões (sinapses artificiais), sendo estas representadas por vetores/matrizes de pesos sinápticos (da Silva *et al.*, 2010).

As RNAs possuem como principais características a capacidade de aprender por meio de exemplos e a generalização das informações aprendidas. As adaptações dos pesos sinápticos são ajustadas a partir da apresentação sucessiva de exemplos (padrões, amostras, medidas) relacionados ao comportamento do processo, possibilitando a aquisição do conhecimento por experimentação. Por intermédio da aplicação de um método de treinamento ou algoritmo de

aprendizagem, a RNA consegue extrair o relacionamento existente entre as diversas variáveis que compõem o processo. Após o processo de treinamento, a RNA é capaz de generalizar o conhecimento adquirido, possibilitando estimar soluções que eram até então desconhecidas. Outras características como tolerância a falhas, auto-organização e capacidade de agrupar ou organizar dados também podem ser observadas em algumas arquiteturas de RNAs.

### 3.2.1 O neurônio artificial

A unidade básica de processamento presente nas RNAs é o neurônio artificial. Os neurônios artificiais utilizados nos modelos de RNAs são não-lineares, fornecem saídas tipicamente contínuas, e realizam funções simples, como coletar os sinais existentes em suas entradas, agregá-los de acordo com uma função operacional e produzir uma resposta, levando em consideração sua função de ativação inerente (da Silva *et al.*, 2010). O diagrama de blocos da Figura 3.3 apresenta o modelo mais simples de um neurônio artificial, proposto por McCulloch e Pitts (1943), e que engloba as principais características de uma rede neural biológica, sendo o modelo mais utilizado nas diferentes arquiteturas de RNAs.

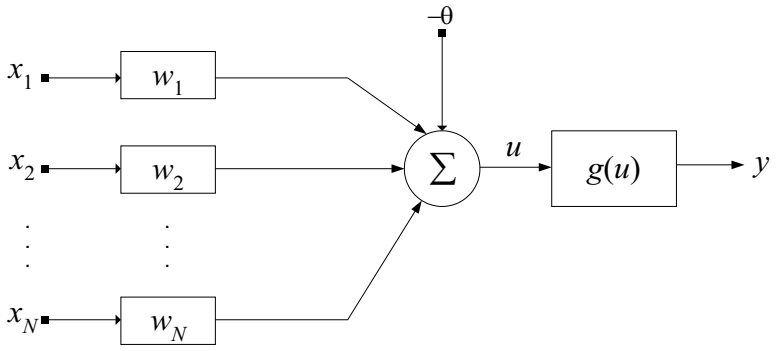


Figura 3.3: Modelo do neurônio artificial.

Nesta representação, os diversos sinais de entrada $x_1, x_2, \ldots, x_N$ advindos do meio externo (aplicação) são análogos aos impulsos elétricos captados pelos dendritos nos neurônios biológicos (da Silva *et al.*, 2010). Os sinais de entrada são usualmente normalizados visando incrementar a eficiência computacional dos algoritmos de aprendizagem.

As ponderações exercidas pelas junções sinápticas do modelo biológico são representadas no neurônio artificial pelo conjunto de pesos sinápticos $w_1, w_2, \ldots, w_N$. De forma análoga, a relevância de cada uma das entradas $x_i$ do neurônio é então quantificada por meio de suas multiplicações pelos respectivos pesos sinápticos $w_i$, ponderando-se, portanto, todas as informações

externas que chegam ao neurônio. Assim, torna-se possível verificar que a saída do corpo celular artificial, denotada por $u$ e denominada potencial de ativação, é a soma ponderada das entradas do neurônio.

A variável $\theta$ é denominada limiar de ativação, e especifica qual será o patamar apropriado para que o resultado da soma ponderada possa gerar um valor de disparo em direção à saída do neurônio. A função de ativação $g(.)$ tem por objetivo limitar a saída do neurônio dentro de um intervalo de valores razoáveis a serem assumidos pela sua própria imagem funcional. Tipicamente, a saída do neurônio é limitada dentro do intervalo $[0, 1]$ ou dentro do intervalo $[-1, 1]$. Finalmente, o sinal de saída $y$ consiste do valor final produzido pelo neurônio em relação a um determinado conjunto de sinais de entrada, podendo ser também utilizado por outros neurônios que estejam sequencialmente interligados.

Matematicamente, o modelo de neurônio artificial apresentado na Figura 3.3 pode ser sintetizado através das duas expressões seguintes:

$$u = \sum_{i=1}^{N} w_i x_i - \theta, \tag{3.21}$$

$$y = g(u). \tag{3.22}$$

As funções de ativação podem ser divididas em dois grupos principais, considerando-se todo o domínio de definição das mesmas. São elas: funções parcialmente diferenciáveis e funções totalmente diferenciáveis. As funções de ativação parcialmente diferenciáveis são aquelas que possuem pontos cujas derivadas de primeira ordem são inexistentes. As três principais funções desse grupo são: função degrau, função degrau bipolar e função rampa simétrica (da Silva *et al.*, 2010). As funções de ativação totalmente diferenciáveis são aquelas cujas derivadas de primeira ordem existem e são conhecidas em todos os pontos de seu domínio de definição. As quatro principais funções pertencentes a este grupo, e que podem ser empregadas em RNAs, são a função logística (sigmóide), a tangente hiperbólica, a gaussiana e a função linear (da Silva *et al.*, 2010).

### 3.2.2 Arquiteturas de RNAs

A arquitetura de uma RNA define a forma como os seus diversos neurônios estão arranjados, ou dispostos, uns em relação aos outros. O treinamento ou algoritmo de aprendizagem de uma arquitetura específica consiste da aplicação de um conjunto de passos ordenados com o intuito de ajustar os pesos e os limiares de ativação dos seus neurônios, visando sintonizar a rede para que as suas respostas estejam próximas dos valores desejados.

Basicamente, uma RNA pode ser dividida em três partes, denominadas de camadas, as quais são nomeadas da seguinte forma:

1. *Camada de entrada*: é a camada responsável pelo recebimento de dados advindos do meio externo, sendo que tais dados (amostras ou padrões) são geralmente normalizados em relação às faixas de variações dinâmicas produzidas pelas funções de ativação.

2. *Camadas neurais escondidas ou intermediárias*: são camadas compostas de neurônios que possuem a responsabilidade de extrair as características associadas ao processo ou sistema a ser inferido.

3. *Camada neural de saída*: é uma camada também constituída de neurônios, sendo responsável pela produção e apresentação dos resultados finais da rede, os quais são advindos dos processamentos efetuados pelos neurônios das camadas anteriores.

As principais arquiteturas de RNAs, considerando-se a disposição de seus neurônios, assim como suas formas de interligação entre si e a constituição de suas camadas, podem ser divididas em: redes *feedfoward* (alimentação à frente) de camada simples, redes *feedforward* de camadas múltiplas, redes recorrentes, e redes reticuladas (da Silva *et al.*, 2010).

Na próxima seção, serão analisados os principais aspectos inerentes à arquitetura *feedforward* da rede PMC, a qual será empregada neste trabalho para a tarefa de classificação de distúrbios de QEE.

### 3.2.3 *Perceptron* de múltiplas camadas

O PMC é um tipo de RNA composta pela camada de entrada, uma ou mais camadas neurais intermediárias e a camada neural de saída. Por utilizar a arquitetura *feedforward*, o fluxo de dados do PMC se propaga adiante, camada por camada, partindo-se da camada de entrada,

que irá receber um vetor contendo os sinais provenientes do sistema, passando pelos neurônios das camadas neurais intermediárias, que irão processar a informação, até alcançar a camada neural de saída, que fornecerá o resultado final da rede. As redes PMC são empregadas na solução de diversos tipos de problemas, tais como aqueles relacionados à aproximação de funções, classificação de padrões, identificação de sistemas, otimização, etc.

De forma meramente ilustrativa e sem perda de generalização, apresentar-se-á na Figura 3.4 uma rede PMC contendo apenas uma camada neural intermediária. Cada círculo representa um neurônio básico da Figura 3.3, onde o limiar e a função de ativação estão implícitos.

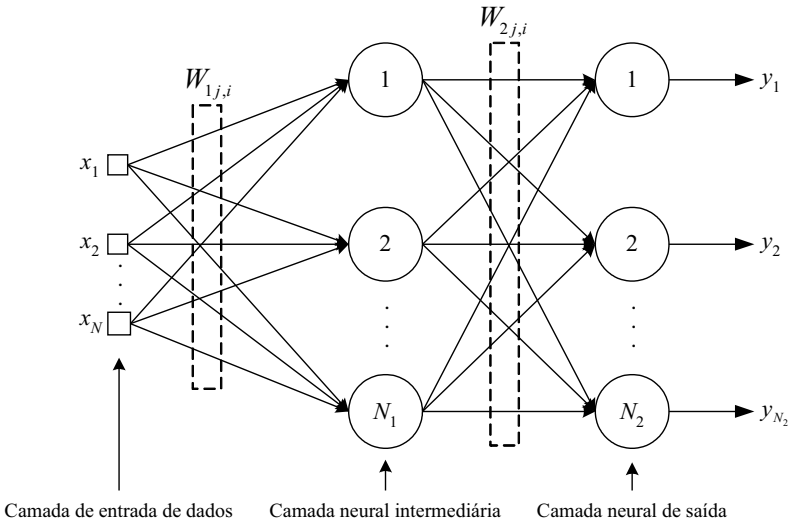


Figura 3.4: Exemplo de rede PMC.

A partir da Figura 3.4, pode ser visualizado que em redes PMC os neurônios de cada camada são conectados apenas aos neurônios da camada imediatamente superior, não existindo qualquer outro tipo de conexão. Todo o conhecimento obtido pelo processamento dos neurônios das camadas neurais intermediária e de saída será armazenado na forma de matrizes de pesos sinápticos, representadas respectivamente por $W_{1j,i}$ e $W_{2j,i}$. Cada linha $j$ dessas matrizes representa um neurônio da respectiva camada, e cada coluna $i$ representa uma entrada do $j$-ésimo neurônio.

Ainda a partir da Figura 3.4, é possível abstrair que a quantidade de neurônios que compõem a camada neural intermediária é normalmente diferente do número de sinais que compõem a camada de entrada de dados da rede. De fato, o número de camadas intermediárias e de seus respectivos neurônios constituintes depende, sobretudo, do tipo e da complexidade do problema a ser mapeado pela rede, assim como da quantidade e da qualidade dos dados disponíveis sobre o problema. Normalmente, as escolhas de tais parâmetros não seguem uma regra e são deter-

minadas de forma experimental. Entretanto, a quantidade de sinais de saída da rede sempre coincidirá com o número de neurônios da camada neural de saída (da Silva *et al.*, 2010).

Tipicamente, o treinamento da rede PMC é realizado de forma supervisionada através de um algoritmo que se baseia na regra de aprendizagem por correção de erro, sendo este método conhecido como algoritmo de retropropagação de erro (*backpropagation*) (Haykin, 2008). O treinamento é aplicado em problemas que dispõem de um conjunto de entradas $x_1[k], \ldots, x_N[k]$ com um conjunto de saídas desejadas $d_1[k], \ldots, d_{N_2}[k]$ associado. A rede aprende, ou seja, é treinada, ajustando suas matrizes de pesos sinápticos, de forma que, se apresentado um padrão $k$ na sua entrada, então $y_j[k]$ deve ser o mais próximo possível de $d_j[k]$ ($j = 1, \ldots, N_2$). O processo de treinamento de redes PMC utilizando o algoritmo *backpropagation*, conhecido também como regra Delta generalizada, é comumente realizado mediante as aplicações sucessivas de duas fases bem específicas.

A primeira fase a ser aplicada é denominada de "propagação adiante" (*forward*), na qual os sinais $x_1, \ldots, x_N$ de uma amostra do conjunto de treinamento são inseridos nas entradas da rede e são propagados camada a camada até a produção das respectivas saídas. Portanto, a aplicação desta fase visa tão somente obter as respostas da rede, levando-se em consideração apenas os valores atuais dos pesos sinápticos e limiares de ativação de seus neurônios, os quais permanecerão inalterados durante cada execução desta fase.

Logo em seguida, as respostas produzidas pelas saídas da rede são comparadas com as respectivas respostas desejadas que estejam disponíveis, pois, conforme mencionado anteriormente, trata-se de um processo de aprendizado supervisionado. Para ressaltar, considerando-se uma rede PMC constituída de $N_2$ neurônios em sua camada neural de saída, os respectivos $N_2$ desvios (erros) entre as respostas desejadas e aquelas produzidas pelos neurônios de saída são então calculados, os quais serão subsequentemente utilizados para ajustar os pesos e limiares de ativação de todos os neurônios da rede.

Assim, em função desses valores de erros, aplica-se, em seguida, a segunda fase do algoritmo *backpropagation*, denominada de "propagação reversa" (*backward*). Diferentemente da anterior, as alterações (ajustes) dos pesos sinápticos e limiares de ativação de todos os neurônios da rede são executadas no decorrer desta fase. O processo de ajuste dos pesos é realizado através do gradiente do erro quadrático apresentado pela rede, em relação aos pesos sinápticos, ou seja:

$$\epsilon[k] = \frac{1}{2}\sum_{j=1}^{N_2}\left[d_j[k] - y_j[k]\right]^2. \tag{3.23}$$

Dada a utilização do gradiente, as funções de ativação devem ser totalmente diferenciáveis. Dentre as funções utilizadas, destacar-se-á a função tangente hiperbólica, dada por:

$$g(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}}, \tag{3.24}$$

onde $\beta$ é uma constante real associada ao nível de inclinação da função tangente hiperbólica em relação ao seu ponto de inflexão. O resultado de saída de tal função sempre assume valores reais entre -1 e 1, de tal forma que se $u$ tende a $-\infty$, então $g(u)$ tende a -1, e se $u$ tende a $\infty$, então $g(u)$ tende a 1. Quanto maior for o valor do parâmetro $\beta$, mais inclinada estará a função tangente hiperbólica, sendo que esta se aproximará da função degrau bipolar quando o valor de $\beta$ for muito elevado.

Tratando-se do processo de ajuste de pesos, uma equação geral para o peso que realiza a conexão sináptica do neurônio $j$ da camada neural corrente à sua entrada $i$ pode ser escrita como:

$$w_{ji}[t+1] = w_{ji}[t] + \eta\delta_j y_i, \tag{3.25}$$

onde $\eta$ é a taxa de aprendizagem do algoritmo *backpropagation*, $\delta_j$ é definido como o gradiente local do erro em relação ao $j$-ésimo neurônio, $w_{ji}[t+1]$ é o peso ajustado e $w_{ji}[t]$ é o peso no passo anterior.

Em suma, as aplicações sucessivas das fases *forward* e *backward* fazem com que os pesos sinápticos e limiares de ativação dos neurônios de todas as camadas neurais se ajustem automaticamente em cada iteração, implicando na gradativa diminuição da soma dos erros quadráticos produzidos pelas respostas da rede frente àquelas desejadas (da Silva *et al.*, 2010).

Diversas variações do método *backpropagation* já foram propostas como o objetivo de tornar o processo de convergência mais eficiente. Dentre tais aperfeiçoamentos, tem-se o método de inserção do termo de *momentum*, o método *resilient-propagation* e o método de Levenberg-Marquardt (Haykin, 2008; da Silva *et al.*, 2010).

Dentre as técnicas de otimização citadas acima, pode-se destacar o algoritmo de Levenberg-

Marquardt. O algoritmo *backpropagation* convencional é um método de descida do gradiente da função erro quadrático médio a fim de minimizá-la. Entretanto, além deste método não ser considerado o mais favorável para a localização do ótimo global, ainda requer um grande esforço computacional. O algoritmo de Levenberg-Marquardt, o qual é um método gradiente de segunda ordem baseado no método de mínimos quadrados para modelos não-lineares, destaca-se por apresentar uma convergência mais rápida, por ser uma aproximação do método de Newton (da Silva *et al.*, 2010). Com a atualização dos pesos sinápticos tem-se uma nova etapa *backward*, que como comprovado por Hagan e Menhaj (1994), apresenta um melhor ajuste dos pesos e um aumento na velocidade de convergência quando comparado ao algoritmo *backpropagation* convencional.

## 3.3 Considerações finais do capítulo

Neste capítulo, foi realizada uma abordagem rápida e sucinta das principais ferramentas computacionais empregadas nos métodos propostos neste tese. A ICA foi abordada inicialmente, sendo que ela é utilizada no próximo capítulo como a principal etapa dos dois métodos propostos para realizar a separação cega (não-supervisionada) de sinais a partir de apenas um sinal de mistura observado (canal único). Também foram tratadas as principais características e fundamentos das RNAs, ferramenta esta que será utilizada para realizar a classificação de distúrbios múltiplos e isolados presentes em sinais de QEE.

# Capítulo 4

# Métodos de aplicação da ICA para canal único

## 4.1 Introdução

Em monitoramento multicanais, por exemplo em eletroencefalograma (*Electroencephalogram* (EEG)), o problema de BSS pode ser eficientemente resolvido utilizando-se a ICA para decompor os sinais medidos pelos múltiplos sensores em suas múltiplas fontes mutuamente independentes (Jung *et al.*, 2000). Como apresentado no Capítulo 3, a ICA é uma técnica que originalmente extrai as fontes estatisticamente independentes quando o número de sensores (canais) é no mínimo igual ao número de fontes. Neste trabalho, é considerado somente um único dispositivo de monitoramento (canal único), o que é um cenário mais realístico para análise de QEE. Sendo assim, alguma etapa de pré-processamento deve ser realizada antes da etapa que calcula a ICA, de forma a fornecer um número suficiente de sinais de observação para a operação correta do algoritmo, a partir de um único sinal medido.

Neste capítulo, serão apresentados dois métodos para utilização da ICA quando está disponível apenas um sinal de entrada. O primeiro método, proposto originalmente nesta pesquisa, será chamado FICA. Tal método utiliza um banco de filtros fixos para gerar os sinais a serem fornecidos como entrada para a ICA a partir de um único sinal medido. Além disso, será proposto um simples procedimento baseado no algoritmo LMS (Haykin, 2002) para estimar as escalas dos componentes independentes, superando assim a indeterminação dos ganhos de escala das fontes apresentada na Seção 3.1.4. Também será demonstrado que a estrutura completa do

método FICA resulta em um banco de filtros lineares adaptativos capaz de separar de maneira não-supervisionada fontes independentes não-sobrepostas na frequência, dado que o projeto do banco de filtros fixos de pré-processamento atenda a certos pré-requisitos.

O segundo método, baseado no método originalmente proposto por Davies e James (2007), será chamado ICA de canal único (*Single Channel Independent Component Analysis* (SCICA)). Tal método gera os sinais de entrada para a ICA por meio da aplicação de sucessivos atrasos temporais no sinal medido. Desta forma, no método SCICA não há a necessidade de projeto de um banco de filtros para gerar os sinais de observação para a ICA. Devido ao fato de no método SCICA os sinais de entrada da ICA serem versões atrasadas de um mesmo sinal, múltiplas estimativas de componentes independentes podem estar associadas a uma mesma fonte no caso de um número de sinais de observação maior do que o número de fontes independentes.

Desta forma, será proposto um estágio de pós-processamento no domínio da frequência utilizando o algoritmo de $k$-médias, ou *k-means* (Haykin, 2008), para agrupar de maneira não-supervisionada as estimativas de componentes independentes obtidas pela ICA que sejam associadas a uma mesma fonte. Será demonstrado que, assim como para o método FICA, a aplicação do método SCICA também resulta em um banco de filtros lineares adaptativos capaz de separar de maneira não-supervisionada fontes independentes não-sobrepostas na frequência, mas neste caso os coeficientes desses filtros são totalmente associados às matrizes de mistura $\mathbf{A}$ e de separação $\mathbf{W}$ estimadas pela ICA, não dependendo dos coeficientes de filtros externos.

## 4.2 Método FICA

Este método gera os sinais de observação por meio da passagem de um sinal $x[n]$ através de um banco de filtros, sendo cada filtro responsável por fornecer um sinal de observação diferente para a ICA. A Figura 4.1 mostra o diagrama de blocos do sistema proposto, o qual é composto por $M$ filtros.

Definindo-se $x[n]$ como sendo uma mistura linear, instantânea e ponderada de $P$ fontes $s_1[n], \ldots, s_P[n]$ estatisticamente independentes entre si, tem-se:

$$x[n] = a_1 s_1[n] + a_2 s_2[n] + \cdots + a_P s_P[n], \tag{4.1}$$

onde $a_1, a_2, \ldots, a_P$ são coeficientes relacionados às distâncias entre as fontes e o ponto onde $x[n]$

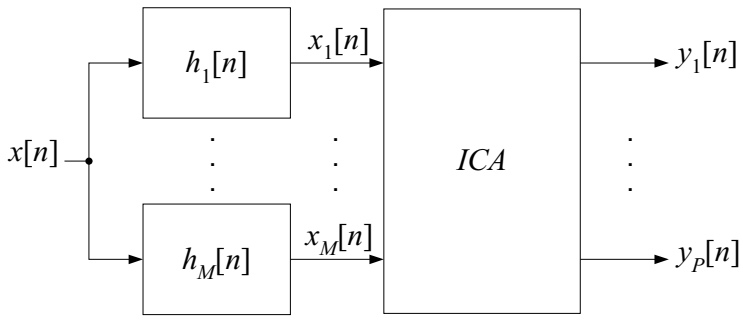


Figura 4.1: Diagrama de blocos do sistema proposto para geração dos sinais de observação para a ICA.

é medido.

O objetivo inicial é encontrar a relação entre $y_1[n], \ldots, y_P[n]$ e $s_1[n], \ldots, s_P[n]$, e posteriormente buscar uma forma de recuperar $s_1[n], \ldots, s_P[n]$ a partir de $y_1[n], \ldots, y_P[n]$, sendo que a única informação disponível a respeito das $P$ fontes é o sinal $x[n]$. Desta forma, não há conhecimento a respeito das fontes e nem de como elas foram misturadas, se configurando, portanto, como um problema de BSS.

Suponha que os filtros $h_1[n], \ldots, h_M[n]$ na Figura 4.1 sejam todos de resposta ao impulso de comprimento finito (*Finite-duration Impulse Response* (FIR)) (Mitra, 2006). Tais filtros serão utilizados devido ao fato de serem inerentemente estáveis. Ao contrário, os filtros de resposta ao impulso de comprimento infinito (*Infinite-duration Impulse Response* (IIR)) podem apresentar instabilidade em sua resposta. Em particular, é possível um filtro IIR se tornar instável (ou seja, apresentar oscilação permanente em sua saída), a menos que seja tomada precaução especial na escolha dos seus coeficientes de realimentação (Mitra, 2006). A saída do $m$-ésimo filtro FIR na Figura 4.1 é dada por:

$$x_m[n] = \sum_{k=0}^{K} h_m[k]x[n-k], \tag{4.2}$$

sendo $m = 1, \ldots, M$ e $\{h_m[k]\}$ a sequência que contém os $K+1$ coeficientes de resposta ao impulso do filtro. Então, um vetor $\mathbf{x}[n]$ é construído como sendo um conjunto de observações, tal como segue:

$$\mathbf{x}[n] = [x_1[n] \quad x_2[n] \quad \ldots \quad x_M[n]]^T. \tag{4.3}$$

Sendo $N$ o comprimento dos sinais de observação, um algoritmo padrão de ICA (tal como o

FastICA) é aplicado à matriz de observações,

$$\mathbf{X} = [\mathbf{x}[1] \quad \mathbf{x}[2] \quad \dots \quad \mathbf{x}[N]]\,,$$

para estimar as matrizes de mistura e separação, $\mathbf{A}$ e $\mathbf{W}$, respectivamente.

Sendo que a ICA realiza a transformação $\mathbf{Y} = \mathbf{WX}$, então $y_p[n] = \sum_{m=1}^{M} w_{pm} x_m[n]$, onde $w_{pm}$ é o $p$-ésimo coeficiente da $m$-ésima coluna de $\mathbf{W}$. Sendo assim, para $M$ filtros $h_m[n]$ contendo cada um $K$ atrasos, obtém-se:

$$y_p[n] = a_1 \sum_{k=0}^{K} \sum_{m=1}^{M} (w_{pm} h_m[k])\, s_1[n-k] + \cdots + a_P \sum_{k=0}^{K} \sum_{m=1}^{M} (w_{pm} h_m[k])\, s_P[n-k], \tag{4.4}$$

para $p = 1, \dots, P$. Observa-se em (4.4) que a estimativa $y_p[n]$ fornecida pela ICA é equivalente à soma das filtragens de todas as fontes $s_p$ misturadas no sinal de entrada $x[n]$ através de um mesmo filtro. Isto indica que as fontes não devem apresentar sobreposição espectral entre si para que $y_p[n]$ possa vir a ser a recuperação individual de uma delas. Este filtro também é do tipo FIR e possui novos coeficientes de resposta ao impulso, os quais são determinados pelo produto entre a $p$-ésima linha da matriz de separação $\mathbf{W}$ e a matriz que contém os coeficientes de resposta ao impulso dos filtros originais $h_1[n], \dots, h_M[n]$.

Escrevendo (4.4) na forma matricial para a estimação simultânea de todas as $P$ fontes no instante $n$, e utilizando o asterisco para denotar as operações de convolução (Mitra, 2006), obtém-se:

$$\begin{bmatrix} y_1[n] \\ \vdots \\ y_P[n] \end{bmatrix} = \begin{bmatrix} w_{11} & \cdots & w_{1M} \\ \vdots & \ddots & \vdots \\ w_{P1} & \cdots & w_{PM} \end{bmatrix} \begin{bmatrix} a_1 h_1[n] * s_1[n] + \cdots + a_P h_1[n] * s_P[n] \\ \vdots \\ a_1 h_M[n] * s_1[n] + \cdots + a_P h_M[n] * s_P[n] \end{bmatrix}. \tag{4.5}$$

A questão agora é: Como devem ser projetados os filtros $h_1[n], \dots, h_M[n]$ para que $y_1, \dots, y_P$ possam recuperar as fontes independentes $s_1, \dots, s_P$?

Considere a situação ideal em que todas as operações de convolução em (4.5) possam ser representadas pela seguinte aproximação:

$$h_m[n] * s_p[n] \simeq \alpha_{mp} s_p[n - n_m], \tag{4.6}$$

onde $\alpha_{mp}$ é o ganho e $n_m$ é o atraso aplicados pelo filtro $h_m[n]$ na fonte $s_p[n]$. Se todos os filtros possuírem o mesmo atraso constante, $n_d$, então (4.5) pode ser aproximada da seguinte forma:

$$\begin{bmatrix} y_1[n] \\ \vdots \\ y_P[n] \end{bmatrix} \simeq \begin{bmatrix} w_{11} & \cdots & w_{1M} \\ \vdots & \ddots & \vdots \\ w_{P1} & \cdots & w_{PM} \end{bmatrix} \begin{bmatrix} \alpha_{11} & \cdots & \alpha_{1P} \\ \vdots & \ddots & \vdots \\ \alpha_{M1} & \cdots & \alpha_{MP} \end{bmatrix} \begin{bmatrix} a_1 s_1[n - n_d] \\ \vdots \\ a_P s_P[n - n_d] \end{bmatrix}. \tag{4.7}$$

Desta forma, (4.7) sugere que se as condições dadas por (4.6) forem satisfeitas para todos os filtros $h_m[n]$, e se todos eles possuírem o mesmo atraso constante $n_d$, então, a menos desse atraso e dos coeficientes relacionados às distâncias entre as fontes e o sinal medido, é possível aproximar as fontes estatisticamente independentes e disjuntas espectralmente $s_p[n]$ a partir das estimativas $y_p[n]$, para $p = 1, \ldots, P$, se a ICA for capaz de ajustar a matriz de separação $\mathbf{W}$ de tal forma que:

$$\mathbf{W}^{-1} = \begin{bmatrix} \alpha_{11} & \cdots & \alpha_{1P} \\ \vdots & \ddots & \vdots \\ \alpha_{M1} & \cdots & \alpha_{MP} \end{bmatrix}. \tag{4.8}$$

A relação descrita por (4.6) sugere que os filtros $h_m[n]$ devam aproximadamente aplicar ganhos e atrasos constantes dentro de toda a faixa de frequências de cada uma das fontes $s_p[n]$, e os coeficientes $\alpha_{mp}$ devem ser tais que a matriz em (4.8) seja invertível. Uma matriz quadrada é invertível se as suas linhas são linearmente independentes. Desta forma, os filtros $h_m[n]$ devem também gerar sinais de observação linearmente independentes.

Sendo essas restrições obedecidas, a matriz de separação $\mathbf{W}$ pode ser a inversa da matriz de misturas gerada artificialmente pelos filtros $h_m[n]$, já que estes filtros estão apenas aplicando diferentes escalas nas fontes $s_p[n]$, e a independência estatística das fontes não é afetada por fatores de escala (Papoulis e Pillai, 2002).

Além de apresentar respostas em frequência linearmente independentes e com amplitudes aproximadamente constantes dentro da faixa de frequências de cada fonte, os filtros $h_m[n]$ devem também possuir respostas em frequência com fase linear, sendo este último requisito alcançado através da utilização de filtros FIR apropriados, como será visto a seguir. Na prática, as condições

em (4.6) serão satisfeitas apenas aproximadamente, resultando em alguma distorção nos sinais recuperados.

Uma medida conveniente da linearidade da fase de um filtro é o atraso de grupo (Oppenheim e Schafer, 1998). O atraso de grupo é definido como:

$$\tau(\omega) = -\frac{d\theta(\omega)}{d\omega}, \tag{4.9}$$

onde $\theta(\omega)$ é a resposta de fase do filtro. Uma forma geral de representar uma resposta em frequência com fase linear é:

$$H(e^{j\omega}) = |H(e^{j\omega})|e^{-j\omega n_d}, \qquad |\omega| \leq \pi. \tag{4.10}$$

A equação (4.10) sugere a interpretação da Figura 4.2. O sinal $s[n]$ é filtrado pela resposta em frequência de fase zero $|H(e^{j\omega})|$, e a saída filtrada é então deslocada no tempo pela quantidade $n_d$. O atraso de grupo para esse sistema é $\tau(\omega) = n_d$, significando que ele é constante para qualquer frequência angular $\omega$ tal que $|\omega| \leq \pi$.

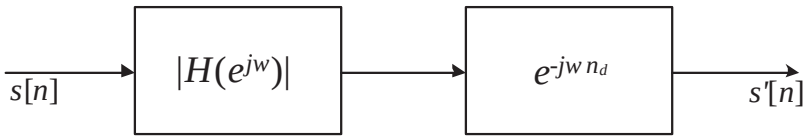


Figura 4.2: Representação de um sistema de fase linear como uma cascata de um filtro de amplitude e um deslocamento no tempo.

Na Figura 4.2, $s'[n] = h[n] * s[n]$. Aplicando-se a transformada de Fourier, obtém-se:

$$S'(e^{j\omega}) = H(e^{j\omega})S(e^{j\omega}) \tag{4.11}$$

$$S'(e^{j\omega}) = |H(e^{j\omega})|e^{-j\omega n_d}S(e^{j\omega}) \tag{4.12}$$

Assumindo que a resposta de fase zero $|H(e^{j\omega})|$ seja constante para a faixa de frequências de $S(e^{j\omega})$, ou seja, $|H(e^{j\omega})| = \alpha$, então:

$$S'(e^{j\omega}) = \alpha e^{-j\omega n_d}S(e^{j\omega}) \tag{4.13}$$

Aplicando-se a transformada inversa de Fourier, obtém-se:

$$s'[n] = \alpha s[n - n_d], \tag{4.14}$$

o que prova (4.6).

### 4.2.1 Projeto do banco de filtros para gerar os sinais de observação

Conforme descrito anteriormente, o método FICA utiliza filtros FIR com respostas em frequência que apresentam fases lineares e atrasos de grupo constantes para gerar os sinais de observação a serem fornecidos para a ICA. Para este processo, se todos os $M$ filtros possuírem o mesmo atraso, será mantido assim o sincronismo entre os sinais que serão fornecidos para a ICA. Os filtros utilizados neste trabalho são FIR Tipo 1 (Mitra, 2006), cuja resposta em frequência é da forma:

$$H(e^{j\omega}) = |H(e^{j\omega})|e^{-jK\omega/2}, \tag{4.15}$$

sendo $K$ a ordem do filtro e $K + 1$ o seu comprimento. Comparando-se (4.15) com (4.10), conclui-se que o atraso de grupo proporcionado por este tipo de filtro é $\tau(\omega) = K/2$.

Portanto, é concluído que se todos os filtros são FIR Tipo 1 e possuem a mesma ordem $K$, então todos eles possuem o mesmo atraso de grupo $\tau(\omega) = K/2$, constante para todo valor de $\omega$ tal que $|\omega| \leq \pi$. Este é um dos requisitos para que seja possível aproximar (4.5) por meio de (4.7). O outro requisito para que tal aproximação seja possível é que todos os filtros apliquem ganhos linearmente independentes e aproximadamente constantes dentro das bandas de frequência de cada uma das fontes presentes em $x[n]$, e que obviamente essas fontes não apresentem sobreposição espectral. Uma solução fácil para que um dos filtros sempre cumpra esse requisito, independentemente da composição espectral de $x[n]$, é que este filtro seja do tipo passa-todas. Baseado nesta solução, salvo quando for explicitamente informada outra configuração, o filtro $h_1[n]$ na Figura 4.1 será um filtro passa-todas com resposta em frequência dada por:

$$H_1(e^{jw}) = e^{-jK\omega/2}. \tag{4.16}$$

Portanto,

$$|H_1(e^{j\omega})| = 1$$

e

$$\tau_1(\omega) = K/2.$$

Assim, o filtro $h_1[n]$ apenas atrasa o sinal $x[n]$ em $K/2$ amostras sem alterar sua amplitude, ou equivalentemente, $x_1[n] = x[n - K/2]$, para $n = K/2, \ldots, N-1$. Portanto, o filtro passa-todas aqui tem como objetivo gerar uma observação ($x_1[n]$) que mantenha a máxima informação a respeito dos pesos originais das diferentes fontes misturadas em $x[n]$, apenas introduzindo um atraso equivalente ao que será imposto pelos demais filtros.

O filtro $h_1[n]$ possui ordem par $K$ e seus coeficientes de resposta ao impulso são dados por:

$$\begin{cases} h_1[n] = 1, & \text{para} \quad n = \frac{K}{2} + 1 \\ h_1[n] = 0, & \text{caso contrário.} \end{cases} \tag{4.17}$$

Os filtros $h_2[n], \ldots, h_M[n]$ devem ser projetados de forma a melhorar a diversidade dos sinais fornecidos por eles. Neste sentido, eles devem possuir respostas em frequência diferentes, já que todos eles recebem o mesmo sinal de entrada ($x[n]$). A diversidade mencionada deve ser levada em conta por causa da restrição imposta pela ICA que diz que as misturas devem ser linearmente independentes uma da outra e o número de misturas deve ser no mínimo igual ao número de fontes, para que a matriz de mistura seja invertível, e assim a ICA possa encontrar todas as fontes independentes presentes mutuamente nesses sinais de mistura. Sendo assim, o propósito de cada filtro $h_2[n], \ldots, h_M[n]$ é aplicar pesos linearmente independentes nas mesmas bandas de frequência, de forma a gerar misturas linearmente independentes, como já foi argumentado anteriormente.

### 4.2.2 Estimação das escalas dos componentes independentes

Como comentado na Seção 3.1.4, a ICA não preserva as amplitudes e pode inverter o sinal de uma ou mais fontes independentes estimadas. Isto ocorre porque a ICA não tem nenhum conhecimento prévio a respeito nem da matriz de misturas $\mathbf{A}$ nem do vetor de fontes $\mathbf{s}$. Entretanto, as escalas dos componentes independentes podem revelar informações importantes a

respeito das fontes que estão misturadas em $x[n]$. Sendo assim, nesta seção será proposta uma etapa para estimar as escalas dos componentes independentes obtidos pela ICA utilizando-se o combinador linear adaptativo (Widrow e Winter, 1988) proposto na Figura 4.3.

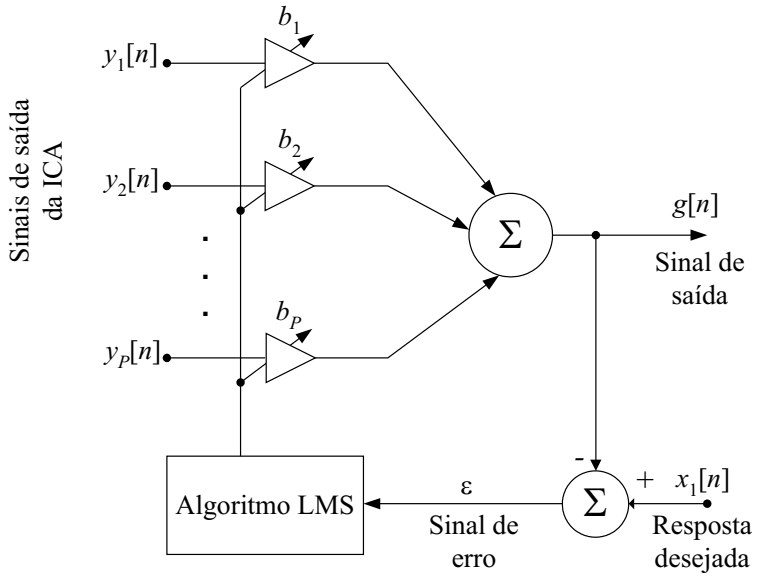


Figura 4.3: Diagrama de blocos do combinador linear adaptativo para estimação das escalas dos componentes independentes.

Considerando-se o sinal $x_1[n]$, os $P$ componentes independentes $(y_1[n], y_2[n], \ldots, y_P[n])$ e os pesos $b_1, b_2, \ldots, b_P$, o algoritmo adaptativo busca ajustar os melhores pesos de tal forma que $g[n]$ em (4.18) se aproxime de $x_1[n]$. O sinal $x_1[n]$ foi o alvo escolhido para $g[n]$ porque $x_1[n]$ preserva os pesos originais de todas as fontes, desde que seja obtido a partir de $x[n]$ utilizando-se um filtro passa-todas.

$$g[n] = b_1 y_1[n] + b_2 y_2[n] + \cdots + b_P y_P[n] = \sum_{p=1}^{P} b_p y_p[n] \tag{4.18}$$

O processo de ajuste dos pesos é baseado no algoritmo de aprendizado denominado de regra Delta, ou regra de aprendizado de Widrow-Hoff, conhecido também como algoritmo LMS (da Silva *et al.*, 2010).

A idéia básica envolvida com a aplicação do algoritmo LMS objetivando ajustar os pesos está em minimizar a diferença entre a saída desejada $(x_1[n])$ e a resposta do combinador linear $(g[n])$, considerando-se para tanto todas as $N$ amostras de ambos os sinais. Mais especificamente, utiliza-se a minimização do erro quadrático entre $g[n]$ e $x_1[n]$ com o intuito de ajustar o vetor de pesos $\mathbf{b} = [b_1, b_2, \cdots, b_P]^T$ do combinador linear adaptativo. Em resumo, o objetivo consiste

em obter um vetor $\mathbf{b}^*$ ótimo tal que o erro quadrático $E(\mathbf{b}^*)$ sobre todo o conjunto de amostras seja o mínimo possível. A função erro quadrático em relação às $N$ amostras de $x_1[n]$ e $g[n]$ é definida por:

$$E\left(\mathbf{b}\right) = \frac{1}{2}\sum_{n=1}^{N}\left(x_1[n] - g[n]\right)^2. \tag{4.19}$$

Substituindo o resultado de (4.18) em (4.19), obtém-se:

$$E(\mathbf{b}) = \frac{1}{2}\sum_{n=1}^{N}\left(x_1[n] - \sum_{p=1}^{P} b_p y_p[n]\right)^2 = \frac{1}{2}\sum_{n=1}^{N}\left(x_1[n] - \mathbf{b}^T\mathbf{y}[n]\right)^2, \tag{4.20}$$

sendo $\mathbf{y}[n] = [y_1[n], y_2[n], \cdots, y_P[n]]^T$.

O próximo passo consiste na aplicação do operador gradiente em relação ao vetor $\mathbf{b}$, tendo-se como objetivo a busca do valor ótimo para o erro quadrático dado em (4.20), ou seja:

$$\nabla E(\mathbf{b}) = \frac{\partial E(\mathbf{b})}{\partial \mathbf{b}} \tag{4.21}$$

Considerando o resultado de (4.20) em (4.21), obtém-se:

$$\nabla E(\mathbf{b}) = \sum_{n=1}^{N}\left(x_1[n] - \mathbf{b}^T\mathbf{y}[n]\right)\cdot\left(-\mathbf{y}[n]\right) \tag{4.22}$$

Retornando o valor de (4.18) em (4.22), obtém-se:

$$\nabla E(\mathbf{b}) = -\sum_{n=1}^{N}\left(x_1[n] - g[n]\right)\cdot\mathbf{y}[n] \tag{4.23}$$

Finalmente, os passos de adaptação do vetor de pesos devem ser efetuados na direção oposta àquela do gradiente, pois o objetivo da otimização é minimizar o erro quadrático. Nesta condição, a variação $\Delta\mathbf{b}$ a ser efetivada no vetor de pesos do combinador linear adaptativo é dada por:

$$\Delta\mathbf{b} = -\eta\cdot\nabla E(\mathbf{b}) \tag{4.24}$$

Inserindo o resultado de (4.23) em (4.24), obtém-se:

$$\Delta \mathbf{b} = \eta \cdot \sum_{n=1}^{N} (x_1[n] - g[n]) \cdot \mathbf{y}[n] \tag{4.25}$$

De forma complementar, pode-se expressar (4.25) por:

$$\mathbf{b}^{\text{atual}} = \mathbf{b}^{\text{anterior}} + \eta \cdot \sum_{n=1}^{N} (x_1[n] - g[n]) \cdot \mathbf{y}[n] \tag{4.26}$$

Alternativamente, por razões de simplificação, a atualização de $\mathbf{b}$ pode ser também realizada discretamente após a apresentação de cada $n$-ésima amostra, ou seja:

$$\mathbf{b}^{\text{atual}} = \mathbf{b}^{\text{anterior}} + \eta \cdot (x_1[n] - g[n]) \cdot \mathbf{y}[n], \quad \text{onde} \quad n = 1, \ldots, N \tag{4.27}$$

Em notação algorítmica, a expressão anterior equivale a:

$$\mathbf{b} \leftarrow \mathbf{b} + \eta \cdot (x_1[n] - g[n]) \cdot \mathbf{y}[n] \tag{4.28}$$

A constante $\eta$ define a taxa de aprendizagem do algoritmo LMS. Ela exprime o quão rápido o processo de ajuste dos pesos estará indo em direção ao ponto de minimização da função erro quadrático dada em (4.19), sendo que normalmente se adotam valores pertencentes ao intervalo compreendido em $0 < \eta < 1$.

O critério de parada do algoritmo é estipulado em função do erro quadrático médio ($E_{\text{qm}}(\mathbf{b})$) em relação a todas as $N$ amostras, sendo definido por:

$$E_{\text{qm}}(\mathbf{b}) = \frac{1}{N} \sum_{n=1}^{N} (x_1[n] - g[n])^2 \tag{4.29}$$

O algoritmo converge quando o erro quadrático médio entre duas épocas sucessivas de ajuste for suficientemente pequeno, ou seja:

$$|E_{\text{qm}}(\mathbf{b}^{\text{atual}}) - E_{\text{qm}}(\mathbf{b}^{\text{anterior}})| \leq \varepsilon, \tag{4.30}$$

onde $\varepsilon$ é a precisão requerida para o processo de convergência. Vale mencionar que cada época significa cada vez que é apresentado o conjunto inteiro das $N$ amostras de $x_1[n]$ ao algoritmo LMS visando o ajuste do vetor de pesos $\mathbf{b}$.

Após o ajuste do vetor de pesos **b** através de (4.28), as escalas dos componentes independentes podem ser aproximadas utilizando-se a relação:

$$\begin{bmatrix} y_{\mathrm{rec}_1}[n] \\ y_{\mathrm{rec}_2}[n] \\ \vdots \\ y_{\mathrm{rec}_P}[n] \end{bmatrix} = \begin{bmatrix} b_1 & 0 & \cdots & 0 \\ 0 & b_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & b_P \end{bmatrix} \begin{bmatrix} y_1[n] \\ y_2[n] \\ \vdots \\ y_P[n] \end{bmatrix}, \tag{4.31}$$

onde $[y_{\mathrm{rec}_1}[n], y_{\mathrm{rec}_2}[n], \ldots, y_{\mathrm{rec}_P}[n]]^T$ é o vetor contendo os componentes independentes estimados com as suas escalas recuperadas. Voltando à Figura 4.3, conclui-se que:

$$g[n] = \sum_{p=1}^{P} y_{\mathrm{rec}_p}[n] \tag{4.32}$$

Supondo-se que o algoritmo LMS conseguiu encontrar um vetor de pesos **b** que minimize o erro quadrático médio entre $x_1[n]$ e $g[n]$, pode-se assumir que:

$$g[n] \cong x_1[n] \Rightarrow g[n] \cong x[n - K/2], \tag{4.33}$$

ou seja, o sinal $g[n]$ conseguiu aproximar o sinal $x[n]$, a menos de um atraso de $K/2$ amostras.

A Figura 4.4 mostra o diagrama de blocos completo do método FICA, sendo fornecido como entrada o sinal $x[n]$ e obtido como saídas os sinais $y_{\mathrm{rec}_1}[n], y_{\mathrm{rec}_2}[n], \ldots, y_{\mathrm{rec}_P}[n]$.

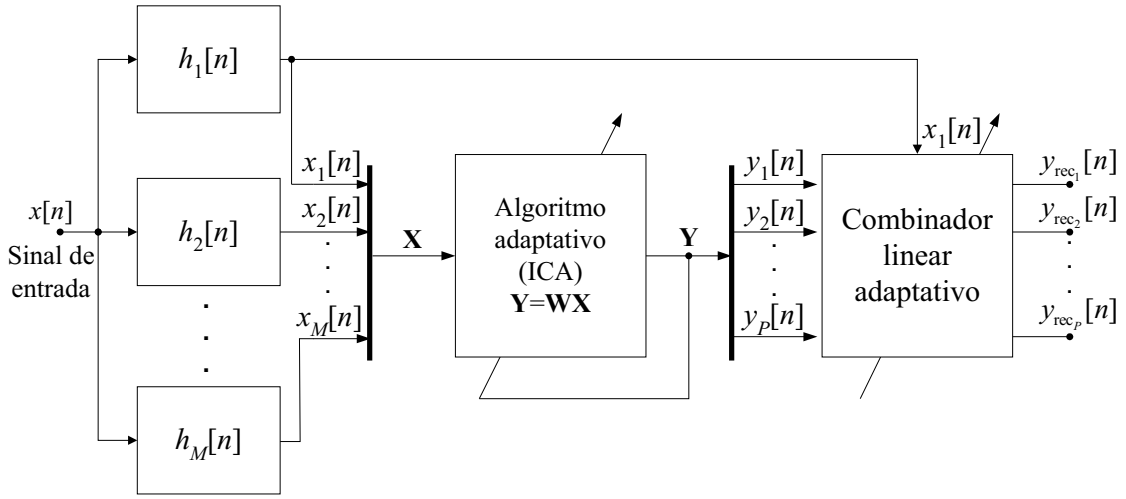


Figura 4.4: Diagrama de blocos do algoritmo FICA completo.

### 4.2.3 Filtros adaptativos resultantes da aplicação do método FICA

Nesta seção, será mostrada a equivalência do método FICA com um banco de filtros adaptativos, cujos coeficientes são ajustados de maneira não-supervisionada pelo próprio método.

Agrupando-se (4.5) e (4.31), e assumindo-se que $x[n] = a_1 s_1[n] + a_2 s_2[n] + \ldots + a_P s_P[n]$, obtém-se:

$$\begin{bmatrix} y_{\mathrm{rec}_1}[n] \\ y_{\mathrm{rec}_2}[n] \\ \vdots \\ y_{\mathrm{rec}_P}[n] \end{bmatrix} = \begin{bmatrix} b_1 & 0 & \cdots & 0 \\ 0 & b_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & b_P \end{bmatrix} \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1M} \\ w_{21} & w_{22} & \cdots & w_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ w_{P1} & w_{P2} & \cdots & w_{PM} \end{bmatrix} \times$$
$$\times \begin{bmatrix} h_1[0] & h_1[1] & \cdots & h_1[K] \\ h_2[0] & h_2[1] & \cdots & h_2[K] \\ \vdots & \vdots & \ddots & \vdots \\ h_M[0] & h_M[1] & \cdots & h_M[K] \end{bmatrix} \begin{bmatrix} x[n] \\ x[n-1] \\ \vdots \\ x[n-K] \end{bmatrix}. \tag{4.34}$$

O produto das três primeiras matrizes do lado direito de (4.34) resulta em uma matriz de dimensão $P \times (K+1)$ que será chamada de $\mathbf{F}$, na qual cada linha $p$ contém uma sequência de coeficientes de resposta ao impulso de um filtro FIR adaptativo, sendo que esta sequência, ao ser convoluída com o sinal $x[n]$, resulta no sinal $y_{\mathrm{rec}_p}[n]$. Redefinindo-se os coeficientes da matriz $\mathbf{F}$ da forma apresentada em (4.35),

$$\mathbf{F} = \begin{bmatrix} f_1[0] & f_1[1] & \cdots & f_1[K] \\ f_2[0] & f_2[1] & \cdots & f_2[K] \\ \vdots & \vdots & \ddots & \vdots \\ f_P[0] & f_P[1] & \cdots & f_P[K] \end{bmatrix}, \tag{4.35}$$

então cada sinal de saída $y_{\mathrm{rec}_p}[n]$ pode ser obtido pela seguinte operação de filtragem:

$$y_{\mathrm{rec}_p}[n] = \sum_{k=0}^{K} f_p[k] x[n-k]. \tag{4.36}$$

A Figura 4.5 ilustra a aplicação do $p$-ésimo filtro FIR adaptativo responsável por obter $y_{\text{rec}_p}[n]$ a partir de $x[n]$, sendo os coeficientes desse filtro obtidos através da aplicação do método FICA em $x[n]$.

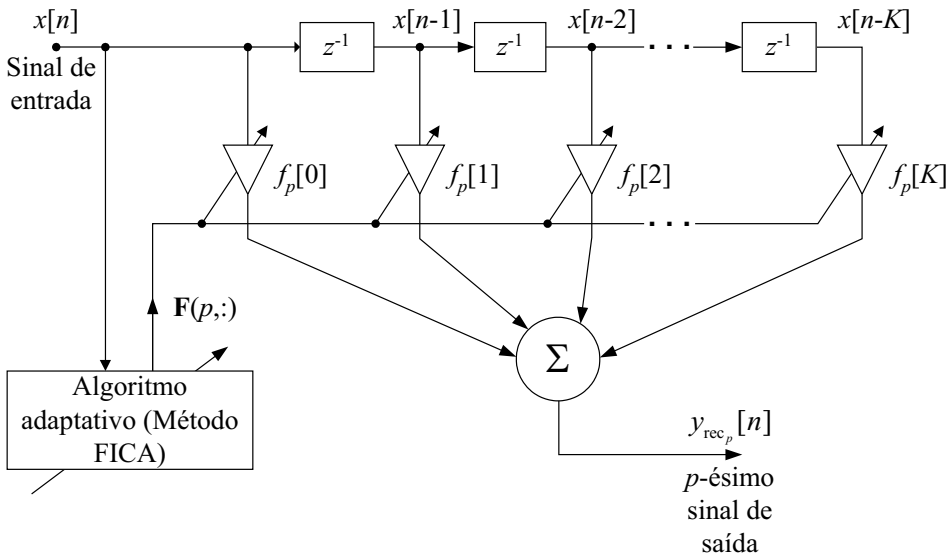


Figura 4.5: Diagrama de blocos do filtro linear adaptativo que obtém o $p$-ésimo sinal de saída a partir do sinal de entrada $x[n]$.

A Figura 4.6 mostra o diagrama de blocos do banco de filtros composto por todos os $P$ filtros adaptativos, e a reconstrução do sinal $g[n]$ a partir da combinação linear dos sinais de saída desses filtros.

Como dito na Seção 4.2.1, os filtros fixos $h_1[n], \ldots, h_M[n]$ devem apresentar respostas em frequência capazes de fornecer sinais de observação linearmente independentes ao algoritmo que calcula a ICA. Além disso, se cada um desses filtros aplicar ganhos aproximadamente constantes nas bandas de frequências de cada uma das fontes presentes em $x[n]$, e assumindo-se que as fontes $s_1[n], \ldots, s_P[n]$ sejam independentes e não-sobrepostas espectralmente, então (4.34) poderia ser aproximada da seguinte forma:

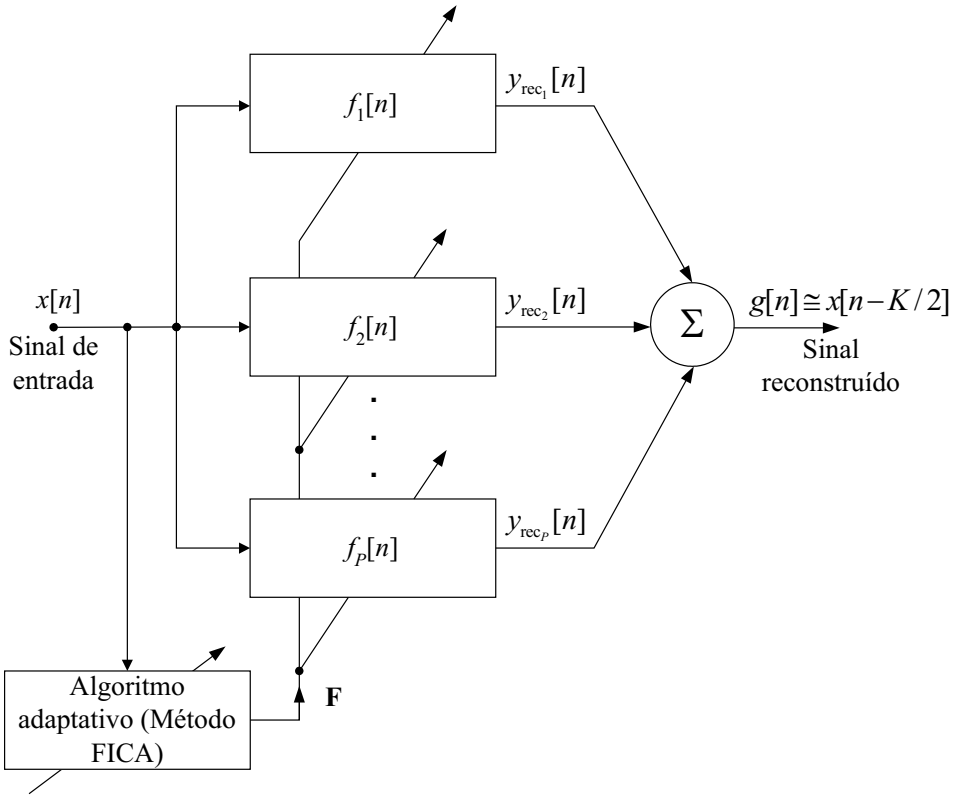


Figura 4.6: Diagrama de blocos do banco de filtros lineares adaptativos que obtém o $P$ sinais de saída e reconstrói o sinal de entrada.

$$\begin{bmatrix} y_{\text{rec}_1}[n] \\ \vdots \\ y_{\text{rec}_P}[n] \end{bmatrix} \simeq \begin{bmatrix} b_1 w_{11} & \cdots & b_1 w_{1M} \\ \vdots & \ddots & \vdots \\ b_P w_{P1} & \cdots & b_P w_{PM} \end{bmatrix} \times$$
$$\times \begin{bmatrix} \alpha_{11} & \cdots & \alpha_{1P} \\ \vdots & \ddots & \vdots \\ \alpha_{M1} & \cdots & \alpha_{MP} \end{bmatrix} \begin{bmatrix} a_1 s_1[n-K/2] \\ \vdots \\ a_P s_P[n-K/2] \end{bmatrix}, \tag{4.37}$$

sendo $\alpha_{mp}$ o ganho aplicado pelo filtro $h_m[n]$ na fonte $s_p[n]$. Sendo assim, $[y_{\text{rec}_1}[n], \ldots, y_{\text{rec}_P}[n]]^T$ seria capaz de aproximar $[a_1 s_1[n-K/2], \ldots, a_P s_P[n-K/2]]^T$ se a parte adaptativa do método (ICA e combinador linear adaptativo) ajustar uma matriz resultante que seja capaz de inverter a matriz de pesos atribuídos pelo banco de filtros fixos às fontes presentes em $x[n]$.

### 4.2.4 Exemplo de aplicação

Como um simples exemplo de aplicação do método FICA, considerar-se-á duas fontes $s_1[n]$ e $s_2[n]$ tais que:

$$s_1[n] = \text{sen}(\omega_1 n T_S)$$

e

$$s_2[n] = \text{sen}(\omega_2 n T_S),$$

sendo que $\omega_1 \neq \omega_2$ e $T_S$ é o período de amostragem dos sinais. Fazendo $x[n] = s_1[n] + s_2[n]$ e escolhendo-se dois filtros com respostas ao impulso $h_1[n]$ e $h_2[n]$ para gerar respectivamente as misturas $x_1[n]$ e $x_2[n]$, obtém-se:

$$x_1[n] = h_1[n] * \text{sen}(\omega_1 n T_S) + h_1[n] * \text{sen}(\omega_2 n T_S) \tag{4.38}$$

$$x_2[n] = h_2[n] * \text{sen}(\omega_1 n T_S) + h_2[n] * \text{sen}(\omega_2 n T_S) \tag{4.39}$$

Se as respostas ao impulso $h_1[n]$ e $h_2[n]$ forem tais que a aproximação dada por (4.6) possa ser utilizada, então:

$$\begin{bmatrix} x_1[n] \\ x_2[n] \end{bmatrix} \simeq \begin{bmatrix} \alpha_{11} & \alpha_{12} \\ \alpha_{21} & \alpha_{22} \end{bmatrix} \begin{bmatrix} \text{sen}(\omega_1[n-n_d]T_S) \\ \text{sen}(\omega_2[n-n_d]T_S) \end{bmatrix}. \tag{4.40}$$

Escolhendo-se $f_1 = 60$ Hz e $f_2 = 120$ Hz, sendo $f_1$ e $f_2$ as frequências das fontes $s_1[n]$ e $s_2[n]$, respectivamente, e sendo $f_S = 1/T_S = 1800$ Hz a frequência de amostragem, e $N = 300$ amostras o comprimento dos sinais, a Figura 4.7(a) mostra a forma de onda da fonte $s_1[n]$, a Figura 4.7(b) mostra a forma de onda da fonte $s_2[n]$ e a Figura 4.7(c) mostra a forma de onda da mistura $x[n]$.

Os filtros $h_1[n]$ e $h_2[n]$ escolhidos são FIR Tipo 1, tal como proposto na Seção 4.2.1. Para este exemplo, ambos os filtros escolhidos possuem ordem $K = 20$, ou seja, a resposta ao impulso de cada um deles possui 21 coeficientes. O filtro $h_1[n]$ é do tipo passa-todas, e o filtro $h_2[n]$ é do tipo passa-altas, com frequência de corte $f_{C2} = 90$ Hz. A Figura 4.8 mostra os módulos das respostas em frequência dos filtros $h_1[n]$ e $h_2[n]$, $|H_1(e^{j\omega})|$ e $|H_2(e^{j\omega})|$ respectivamente, além do módulo da transformada de Fourier $|X(e^{j\omega})|$ do sinal $x[n]$.

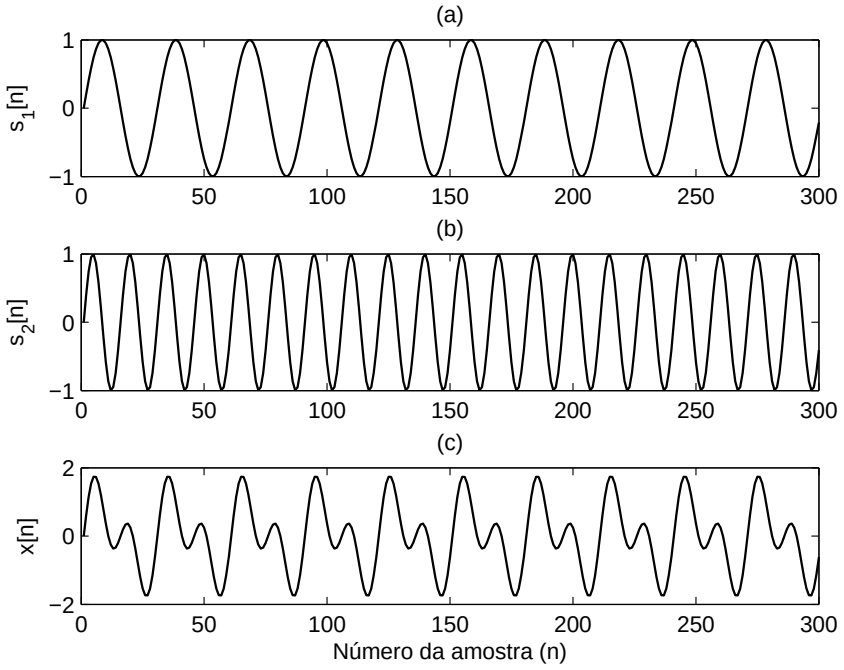


Figura 4.7: Formas de onda das fontes e do sinal de mistura; (a) fonte $s_1[n]$, (b) fonte $s_2[n]$ e, (c) mistura $x[n]$.

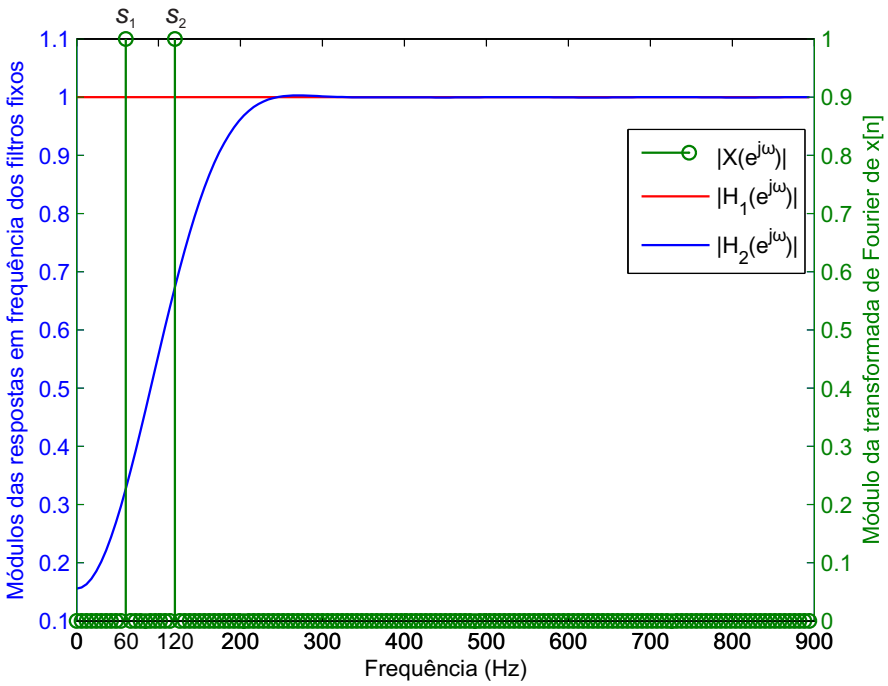


Figura 4.8: Módulos das respostas em frequência dos filtros $h_1[n]$ e $h_2[n]$, e módulo da transformada de Fourier do sinal $x[n]$.

A Figura 4.9(a) mostra as fases das respostas em frequência dos filtros $h_1[n]$ e $h_2[n]$, e a Figura 4.9(b) mostra os atrasos de grupo dos respectivos filtros. Como pode ser observado, tais filtros possuem respostas de fase linear e consequentemente atrasos de grupo constantes para toda a faixa de frequência em que $|\omega| \leq \pi$ ($|f| \leq 900$ Hz), sendo $\tau_1(\omega) = \tau_2(\omega) = n_d = 10$ amostras. Portanto, ambas as fontes $s_1[n]$ e $s_2[n]$ serão atrasados por 10 amostras nos sinais de observação $x_1[n]$ e $x_2[n]$ fornecidos como saídas do banco de filtros fixos.

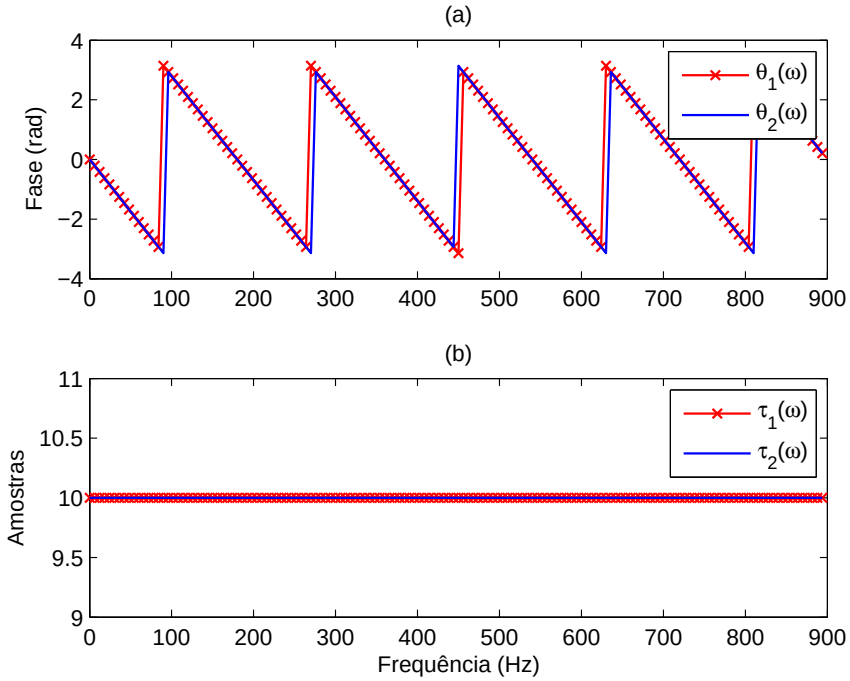


Figura 4.9: Fases das respostas em frequência dos filtros $h_1[n]$ e $h_2[n]$ em (a), e, em (b) seus respectivos atrasos de grupo.

Observando na Figura 4.8 que os únicos componentes de frequência de $X(e^{j\omega})$ que apresentam energia são justamente aqueles relacionados a $s_1[n]$ e $s_2[n]$, ou seja, $\omega_1$ e $\omega_2$, obtém-se:

$$\begin{bmatrix} x_1[n] \\ x_2[n] \end{bmatrix} \simeq \begin{bmatrix} 1 & 1 \\ 0,3269 & 0,6735 \end{bmatrix} \begin{bmatrix} \text{sen}(\omega_1[n-10]T_S) \\ \text{sen}(\omega_2[n-10]T_S) \end{bmatrix}, \tag{4.41}$$

que é da forma de (4.40), sendo $\alpha = \begin{bmatrix} 1 & 1 \\ 0,3269 & 0,6735 \end{bmatrix}$.

A Figura 4.10 mostra os sinais $x_1[n]$ e $x_2[n]$, obtidos pela filtragem do sinal $x[n]$ por meio das operações de convolução dadas por (4.38) e (4.39), respectivamente. Como os sinais $s_1[n]$ e $s_2[n]$ neste exemplo são muito simples e possuem um único componente de frequência cada ($\omega_1$ e

$\omega_2$, respectivamente), o resultado da aplicação dos filtros $h_1[n]$ e $h_2[n]$ é aproximadamente igual a (4.41), como foi mostrado acima. Entretanto, deve ser observado nos sinais $x_1[n]$ e $x_2[n]$ a presença dos transitórios iniciais dos filtros, que como pode ser observado em (4.41), duram até a amostra $n = n_d = 10$. Além disso, após alcançado o regime permanente, as saídas filtradas estão atrasadas no tempo de $n_d$ amostras em relação à mistura $x[n]$.

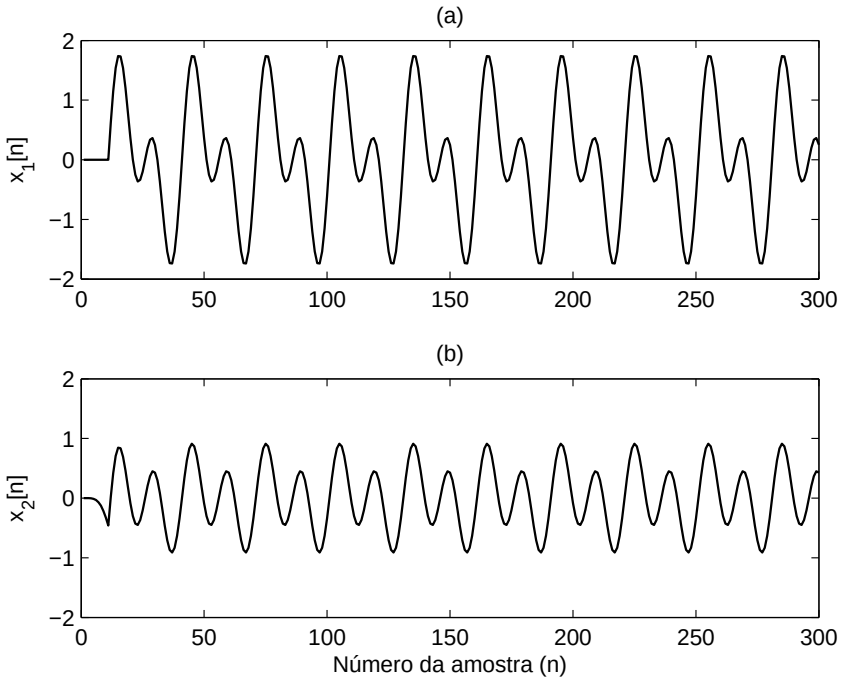


Figura 4.10: Sinais de observação $x_1[n]$ e $x_2[n]$ obtidos a partir da filtragem do sinal $x[n]$ através dos filtros $h_1[n]$ e $h_2[n]$; (a) $x_1[n]$ e, (b) $x_2[n]$.

O próximo passo será fornecer os sinais $x_1[n]$ e $x_2[n]$ para o algoritmo FastICA[1], para que ele calcule a ICA. Após encontrar sua convergência, o algoritmo fornece uma matriz de separação $\mathbf{W}$, que será utilizada para encontrar $y_1[n]$ e $y_2[n]$ a partir de $x_1[n]$ e $x_2[n]$, ou seja:

$$\begin{bmatrix} y_1[n] \\ y_2[n] \end{bmatrix} = \begin{bmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \end{bmatrix} \begin{bmatrix} x_1[n] \\ x_2[n] \end{bmatrix}. \tag{4.42}$$

A Figura 4.11 mostra os sinais $y_1[n]$ e $y_2[n]$ estimados pelo algoritmo FastICA. Analisando-se os sinais $y_1[n]$ e $y_2[n]$, observa-se que $y_1[n]$ é uma estimativa da fonte $s_2[n]$ mostrada na Figura 4.7(b), e o sinal $y_2[n]$ é uma estimativa da fonte $s_1[n]$ mostrada na Figura 4.7(a), levando-se em conta as indeterminações de ganhos de escala e ordem de estimação características da ICA,

[1]Neste trabalho, será utilizado um pacote gratuito de funções que executam o algoritmo em ambiente MATLAB, e que pode ser encontrado no endereço `http://www.cis.hut.fi/projects/ica/fastica/`

além dos atrasos proporcionados pelos filtros $h_1[n]$ e $h_2[n]$. Pode ser observado nitidamente o efeito dos transitórios iniciais dos filtros $h_1[n]$ e $h_2[n]$ no início de $y_1[n]$ e $y_2[n]$. A matriz $\mathbf{W}$ encontrada pelo algoritmo FastICA para esta separação foi:

$$\mathbf{W} = \begin{bmatrix} -1,2653 & 4,0032 \\ -2,7425 & 4,0558 \end{bmatrix}. \tag{4.43}$$

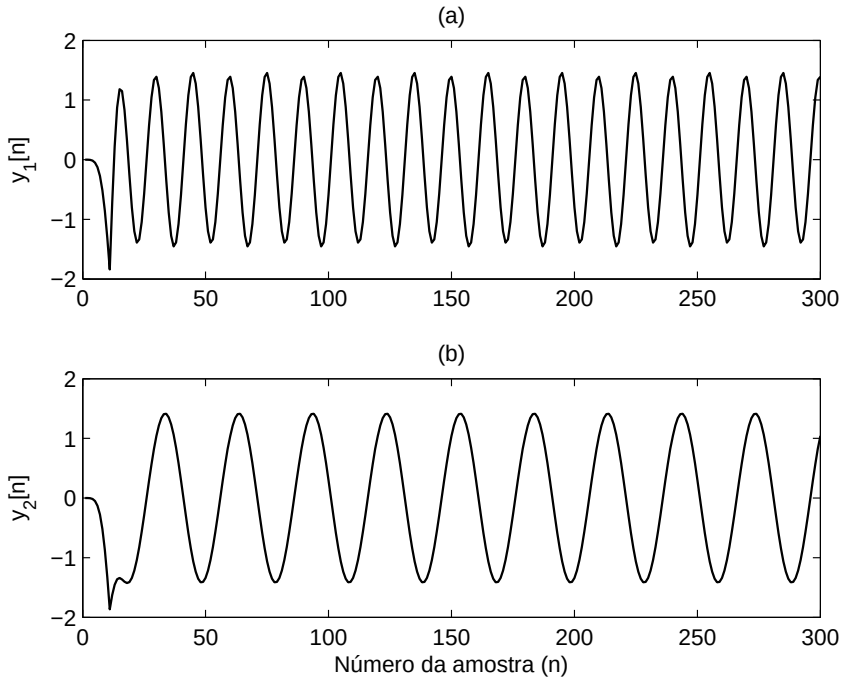


Figura 4.11: Componentes independentes $y_1[n]$ e $y_2[n]$ estimados pela ICA; (a) $y_1[n]$ e, (b) $y_2[n]$.

O último passo é fornecer os sinais $y_1[n]$ e $y_2[n]$ como entradas, e o sinal $x_1[n]$ como saída desejada, ao combinador linear adaptativo proposto na Figura 4.3, com o objetivo de estimar as escalas originais das fontes. Para a etapa de ajuste dos pesos $b_1$ e $b_2$ através do algoritmo LMS, escolheu-se $\eta = 0,01$ e $\varepsilon = 1,0 \times 10^{-7}$. O algoritmo LMS convergiu em apenas quatro épocas de ajuste, sendo a evolução do valor do $E_{\text{qm}}(\mathbf{b})$, em função do número da época, mostrada na Figura 4.12. Os valores finais encontrados para os pesos foram $b_1 = 0,6936$ e $b_2 = -0,6846$. O sinal negativo de $b_2$ mostra que $y_2[n]$ foi invertido em relação a $s_1[n]$. Os valores menores que 1 para ambos os pesos mostram que $y_1[n]$ e $y_2[n]$ possuem amplitudes maiores do que as fontes originais, como pode ser observado na Figura 4.11.

Após o ajuste dos pesos, a relação descrita em (4.31) deve ser utilizada para encontrar $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_2}[n]$ a partir de $y_1[n]$ e $y_2[n]$, respectivamente. A Figura 4.13 mostra os sinais obtidos. Como

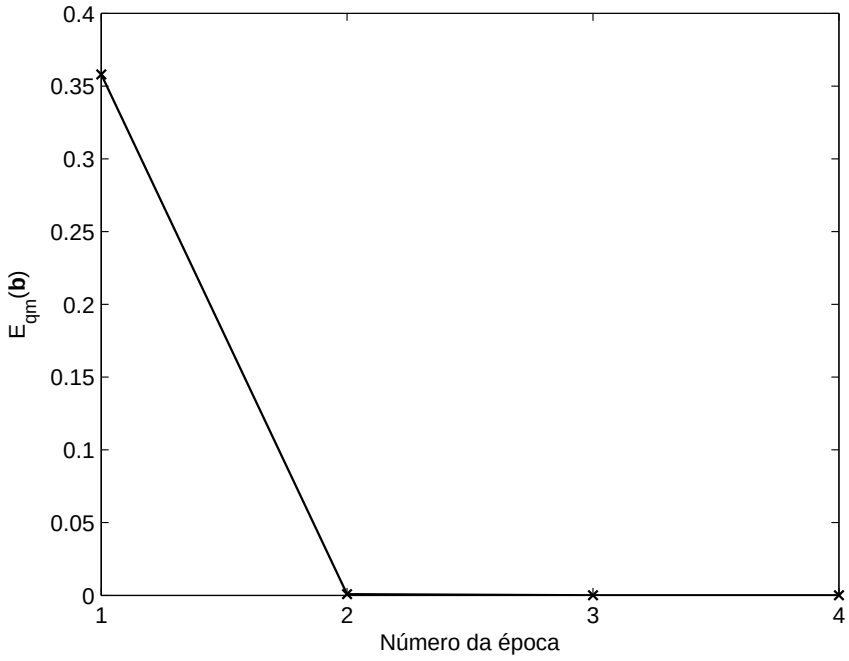


Figura 4.12: Comportamento do erro quadrático médio em função das épocas de ajuste.

pode ser observado, ambos os componentes possuem agora amplitude igual a 1, que é o valor das amplitudes das fontes originais. Além disso, $y_{\text{rec}_2}[n]$ possui fase invertida em relação a $y_2[n]$, recuperando assim o sinal da fonte $s_1[n]$ (vide Figura 4.7(a)).

A Figura 4.14 mostra o sinal $g[n]$ reconstruído comparado ao sinal de entrada $x[n]$, na qual percebe-se que o sinal reconstruído é uma recuperação do sinal original contendo um atraso de $n_d = 10$ amostras, o que está de acordo com (4.33).

Adaptando-se (4.34) para este exemplo, e relembrando que os filtros $h_1[n]$ e $h_2[n]$ possuem ordem $K = 20$, obtém-se:

$$\begin{bmatrix} y_{\text{rec}_1}[n] \\ y_{\text{rec}_2}[n] \end{bmatrix} = \begin{bmatrix} b_1 w_{11} & b_1 w_{12} \\ b_2 w_{21} & b_2 w_{22} \end{bmatrix} \begin{bmatrix} h_1[0] & h_1[1] & \cdots & h_1[20] \\ h_2[0] & h_2[1] & \cdots & h_2[20] \end{bmatrix} \begin{bmatrix} x[n] \\ x[n-1] \\ \vdots \\ x[n-20] \end{bmatrix}. \tag{4.44}$$

Chamando de $\mathbf{F}$ a matriz resultante do produto das duas primeiras matrizes do lado direito de (4.44), cada linha de $\mathbf{F}$ corresponderá a novas respostas ao impulso que, quando convoluídas com o sinal $x[n]$, resultarão nos sinais $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_2}[n]$. Sendo assim, cada linha de $\mathbf{F}$ será

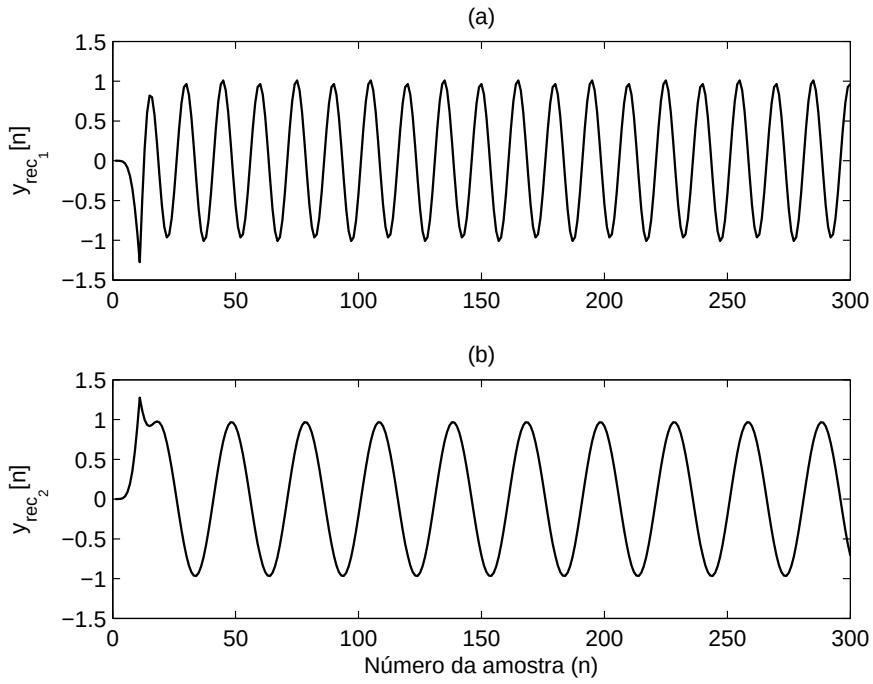


Figura 4.13: Componentes independentes com suas escalas estimadas pelo combinador linear adaptativo; (a) $y_{\mathrm{rec}_1}[n]$ e, (b) $y_{\mathrm{rec}_2}[n]$.

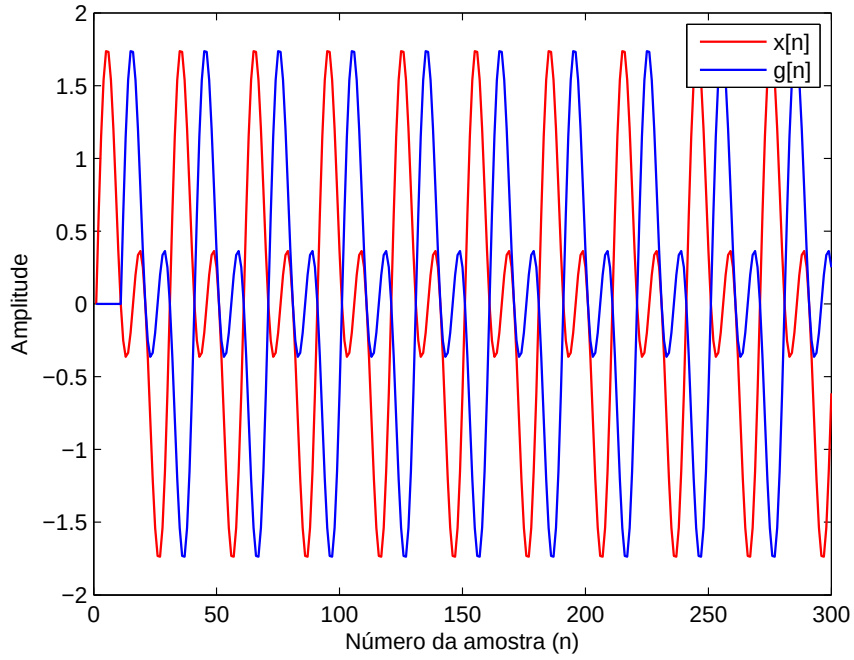


Figura 4.14: Comparação entre o sinal reconstruído $g[n]$ e o sinal original $x[n]$.

um filtro FIR adaptativo ($f_1[n]$ e $f_2[n]$). A Figura 4.15 mostra os módulos das respostas em frequência desses filtros. Pode-se observar que o filtro $f_1[n]$ atenua fortemente o componente

de 60 Hz ($s_1$) e deixa passar o componente de 120 Hz ($s_2$) com ganho unitário, e o filtro $f_2[n]$ atenua fortemente o componente de 120 Hz e deixa passar o componente de 60 Hz com ganho unitário, o que de fato foi observado na Figura 4.13.

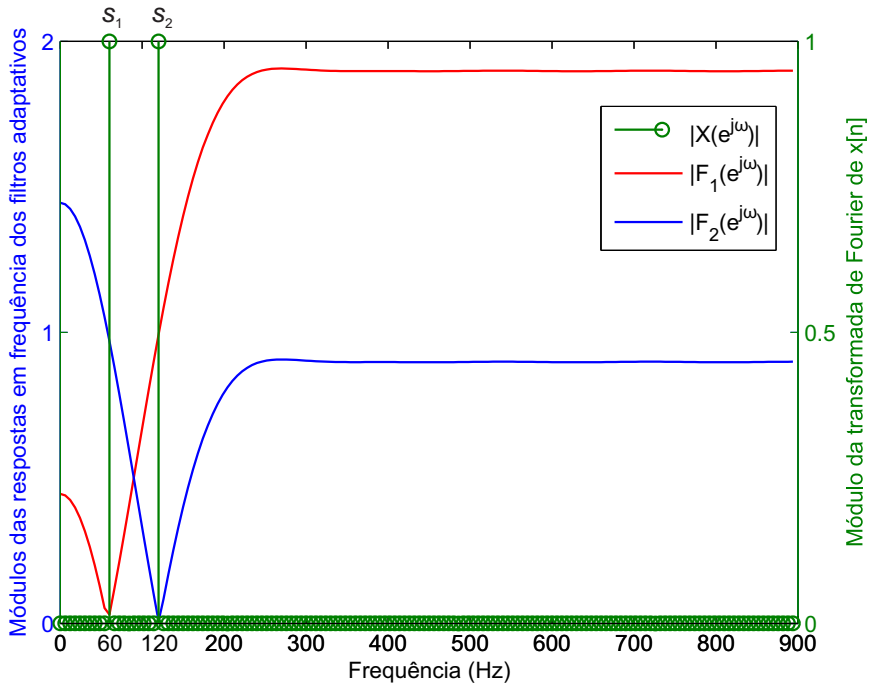


Figura 4.15: Módulos das respostas em frequência dos filtros $f_1[n]$ e $f_2[n]$; (a) $|F_1(e^{j\omega})|$ e, (b) $|F_2(e^{j\omega})|$.

Utilizando-se a aproximação dada por (4.37) e substituindo-se os valores encontrados para $\mathbf{b}$, $\mathbf{W}$ e $\alpha$ neste exemplo, obtém-se:

$$\begin{bmatrix} y_{\text{rec}_1}[n] \\ y_{\text{rec}_2}[n] \end{bmatrix} \simeq \begin{bmatrix} -0,8777 & 2,7768 \\ 1,8776 & -2,7768 \end{bmatrix} \begin{bmatrix} 1 & 1 \\ 0,3269 & 0,6735 \end{bmatrix} \begin{bmatrix} \text{sen}(\omega_1[n-10]T_S) \\ \text{sen}(\omega_2[n-10]T_S) \end{bmatrix}, \quad (4.45)$$

sendo os pesos da primeira matriz do lado direito da equação determinados pela etapa adaptativa (ICA e combinador linear adaptativo), e os pesos da segunda matriz do lado direito da equação determinados pelos filtros fixos. Multiplicando-se essas duas matrizes, obtém-se a relação abaixo:

$$\begin{bmatrix} y_{\text{rec}_1}[n] \\ y_{\text{rec}_2}[n] \end{bmatrix} \simeq \begin{bmatrix} 0,0300 & 0,9925 \\ 0,9699 & 0,0074 \end{bmatrix} \begin{bmatrix} \text{sen}(\omega_1[n-10]T_S) \\ \text{sen}(\omega_2[n-10]T_S) \end{bmatrix}, \quad (4.46)$$

que mostra que $y_{\text{rec}_1}[n]$ possui uma pequena presença de $s_1[n]$ (0,0300) e uma grande presença de

$s_2[n]$ (0,9925), e $y_{\text{rec}_2}[n]$ possui uma grande presença de $s_1[n]$ (0,9699) e uma pequena presença de $s_2[n]$ (0,0074). Estes resultados estão de acordo com aqueles apresentados nas Figuras 4.13 e 4.15.

Na próxima seção, será apresentado e descrito detalhadamente um outro método proposto para separação cega de fontes utilizando-se também a ICA para recuperar as fontes a partir de um único sinal de mistura.

## 4.3 Método SCICA

O método FICA é capaz de recuperar adequadamente as fontes independentes presentes simultaneamente em um sinal se as seguintes restrições são obedecidas:

1. As fontes não possuem sobreposição espectral.
2. Os filtros fixos aplicam ganhos constantes (ao menos aproximadamente) e atrasos constantes nas bandas de frequência de cada fonte.
3. Os filtros fixos produzem saídas linearmente independentes.

Assumindo-se que as fontes não possuam subreposição espectral, a maior dificuldade na utilização do método FICA é o projeto adequado do banco de filtros fixos de forma que as outras duas restrições sejam obedecidas. Isto porque pode ser necessário um conhecimento prévio das composições espectrais das fontes para o projeto desses filtros. Nesta seção é apresentado o método SCICA, o qual é um método alternativo ao método FICA para realizar a mesma função. Ao invés de gerar os sinais de observação a serem fornecidos como entrada para a ICA utilizando-se um banco de filtros, o método SCICA gera esses sinais através da aplicação de sucessivos atrasos temporais no sinal $x[n]$.

A SCICA é um caso especial da ICA multidimensional (*Multi-dimensional Independent Component Analysis* (MICA)) (Castells *et al.*, 2004) aplicada a sinais que são versões atrasadas de um mesmo sinal. Isto implica que múltiplos componentes estimados pela ICA podem ser associados a uma mesma fonte independente e, sendo assim, alguma forma de pós-processamento se torna necessária para agrupar tais componentes juntos.

Assim como para o método FICA, a estrutura do método SCICA também é obtida através do mapeamento de uma série temporal em um modelo multi-dimensional, implicando que as fontes

podem ser separadas e identificadas corretamente pela ICA somente se elas não apresentam sobreposição espectral entre si.

O algoritmo SCICA inicialmente quebra o sinal de entrada $x[n]$, cujo comprimento total é de $N$ amostras, em uma sequência de $M$ blocos contíguos $\mathbf{x}'[m]$, cada um tendo comprimento $L = N - M\tau + 1$ amostras, sendo $m = 1, 2, \ldots, M$ o índice de cada bloco e $\tau$ um atraso de tempo (em número de amostras). Cada bloco é definido como segue:

$$\mathbf{x}'[m] = [x[m\tau] \quad x[m\tau + 1] \quad \cdots \quad x[m\tau + L - 1]]\,. \tag{4.47}$$

De forma a manter o comprimento original de $N$ amostras do sinal de entrada, são inseridos $M\tau - 1$ zeros antes do primeiro elemento de cada bloco $\mathbf{x}'[m]$, dando origem ao bloco $\mathbf{x}[m]$. Desta forma, obtém-se:

$$\mathbf{x}[m] = \begin{bmatrix} \overbrace{0 \quad 0 \quad \cdots \quad 0}^{M\tau-1 \quad \text{zeros}} & \mathbf{x}'[m] \end{bmatrix}^T . \tag{4.48}$$

O diagrama de blocos da Figura 4.16 representa o resultado equivalente da aplicação em sequência das operações descritas por (4.47) e (4.48), válido a partir da amostra $n = M\tau$ (por causa da inserção de prévios $M\tau - 1$ zeros). Como pode ser observado, a observação $\mathbf{x}[1]$ é o próprio sinal $x[n]$ atrasado por $M\tau - 1$ amostras. A observação $\mathbf{x}[2]$ é o próprio sinal $x[n]$ atrasado por $M\tau - 2$ amostras, e assim por diante, até a observação $\mathbf{x}[M]$, que não possui atraso em relação ao sinal $x[n]$. Este diagrama deixa claro que os sinais de observação são simplesmente versões atrasadas do próprio sinal de entrada.

Então, uma matriz $\mathbf{X}$ é construída como sendo um conjunto de observações $\mathbf{x}[m]$, tal como segue:

$$\mathbf{X} = [\mathbf{x}[1] \quad \mathbf{x}[2] \quad \cdots \quad \mathbf{x}[M]]^T . \tag{4.49}$$

Cada linha da matriz $\mathbf{X}$ corresponderá a um diferente sinal de observação a ser fornecido como entrada para a ICA. Expandindo-se a matriz $\mathbf{X}$, obtém-se:

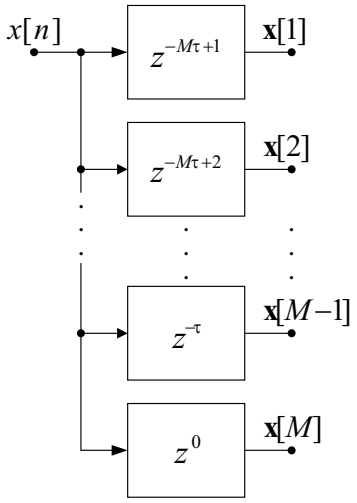


Figura 4.16: Representação em diagrama de blocos do esquema de construção da matriz de observações $\mathbf{X}$.

$$\mathbf{X} = \begin{bmatrix} \overbrace{0 \quad 0 \quad \cdots \quad 0}^{M\tau-1 \quad \text{zeros}} & x[\tau] & x[\tau+1] & \cdots & x[\tau+L-1] \\ 0 \quad 0 \quad \cdots \quad 0 & x[2\tau] & x[2\tau+1] & \cdots & x[2\tau+L-1] \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 \quad 0 \quad \cdots \quad 0 & x[M\tau] & x[M\tau+1] & \cdots & x[M\tau+L-1] \end{bmatrix}. \tag{4.50}$$

Desta forma, a matriz $\mathbf{X}$ possui dimensão $M \times N$.

Então, um algoritmo padrão de ICA (tal como o FastICA) é aplicado à matriz $\mathbf{X}$ para estimar as matrizes de mistura e separação, $\mathbf{A}$ e $\mathbf{W}$, respectivamente. As dimensões das matrizes $\mathbf{A}$ e $\mathbf{W}$ são, respectivamente, $M \times P$ e $P \times M$, sendo $P$ o número de componentes independentes estimados pela ICA. Sendo que a ICA realiza a transformação linear $\mathbf{Y} = \mathbf{WX}$, obtém-se:

$$\mathbf{Y} = \begin{bmatrix} \overbrace{0 \quad \cdots \quad 0}^{M\tau-1 \quad \text{zeros}} & \sum_{m=1}^{M} w_{1m} x[m\tau] & \sum_{m=1}^{M} w_{1m} x[m\tau+1] & \cdots & \sum_{m=1}^{M} w_{1m} x[m\tau+L-1] \\ 0 \quad \cdots \quad 0 & \sum_{m=1}^{M} w_{2m} x[m\tau] & \sum_{m=1}^{M} w_{2m} x[m\tau+1] & \cdots & \sum_{m=1}^{M} w_{2m} x[m\tau+L-1] \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 \quad \cdots \quad 0 & \sum_{m=1}^{M} w_{Pm} x[m\tau] & \sum_{m=1}^{M} w_{Pm} x[m\tau+1] & \cdots & \sum_{m=1}^{M} w_{Pm} x[m\tau+L-1] \end{bmatrix},$$

onde as $M\tau - 1$ primeiras colunas são também constituídas de elementos nulos. Sendo assim, a dimensão da matriz $\mathbf{Y}$ é $P \times N$. Definindo-se $k = 0, 1, \ldots, L-1$, cada coluna não-nula (ou seja,

para $n = M\tau, M\tau + 1, \ldots, M\tau + L - 1)$ da matriz $\mathbf{Y}$ pode ser representada como:

$$\mathbf{y}\left[M\tau + k\right] = \begin{bmatrix} \sum_{m=1}^{M} \mathbf{W}_{(1,m)} x[m\tau + k] \\ \sum_{m=1}^{M} \mathbf{W}_{(2,m)} x[m\tau + k] \\ \vdots \\ \sum_{m=1}^{M} \mathbf{W}_{(P,m)} x[m\tau + k] \end{bmatrix}. \tag{4.51}$$

Substituindo $n = M\tau + k$, obtém-se:

$$\mathbf{y}\left[n\right] = \begin{bmatrix} \sum_{m=0}^{M-1} \mathbf{W}_{(1,M-m)} x[n - m\tau] \\ \sum_{m=0}^{M-1} \mathbf{W}_{(2,M-m)} x[n - m\tau] \\ \vdots \\ \sum_{m=0}^{M-1} \mathbf{W}_{(P,M-m)} x[n - m\tau] \end{bmatrix}, \tag{4.52}$$

onde $\mathbf{y}[n] = [y_1[n], y_2[n], \ldots, y_P[n]]^T$. Sendo assim, para $\tau = 1$ em (4.52), cada estimativa de componente independente $y_p[n]$ será obtida através da soma de convolução:

$$y_p[n] = \sum_{m=0}^{M-1} \mathbf{W}_{(p,M-m)} x[n - m]. \tag{4.53}$$

Portanto, por esta abordagem, cada linha da matriz de separação $\mathbf{W}$ corresponde aos coeficientes de resposta ao impulso de um filtro FIR (Mitra, 2006), sendo $y_p[n]$ equivalente a uma versão filtrada de $x[n]$, onde $y_p[n] = w_p[-n] * x[n]$ e $w_p[-n]$ é um filtro associado ao vetor linha $\mathbf{W}_{(p,:)}$. A sequência $w_p[-n]$ é representada com o índice negativo porque, como pode ser observado em (4.53), $x[n]$ é multiplicado por $\mathbf{W}_{(p,M)}$, $x[n-1]$ é multiplicado por $\mathbf{W}_{(p,M-1)}$, e assim por diante, até $x[n - M + 1]$ ser multiplicado por $\mathbf{W}_{(p,1)}$. A Figura 4.17 mostra o diagrama de blocos desse filtro, no qual pode-se observar que os coeficientes da $p$-ésima linha da matriz de separação estimada pela ICA são utilizados para obter $y_p[n]$ a partir de $x[n]$.

A Figura 4.18 mostra o diagrama de blocos do banco de filtros de decomposição relacionado à matriz $\mathbf{W}$ completa, para obter todos os $P$ componentes independentes a partir da matriz $\mathbf{X}$. A ilustração deixa claro que a ICA adapta os coeficientes de todos os filtros FIR de separação por meio do ajuste da matriz $\mathbf{W}$, sendo que o critério de atualização desses coeficientes é a

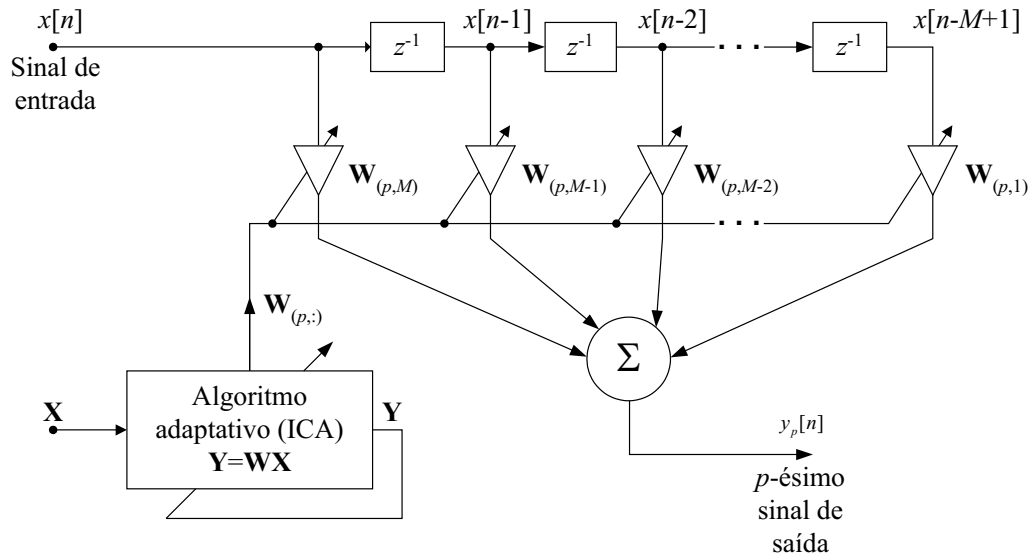


Figura 4.17: Diagrama de blocos do filtro linear adaptativo que obtém o $p$-ésimo sinal de saída a partir do sinal de entrada $x[n]$, considerando-se $\tau = 1$.

maximização da independência estatística entre as linhas da matriz $\mathbf{Y}$, ou seja, os sinais $y_p[n]$. De uma forma geral, pode-se dizer que a matriz $\mathbf{W}$ obtida pela ICA contém os coeficientes de um banco de filtros de análise (Mitra, 2006), os quais decompõem o sinal $x[n]$ em $P$ sinais $y_p[n]$, cada qual ocupando uma sub-banda de frequência do sinal original.

Entretanto, como a ICA não recupera os ganhos de escala das fontes independentes, se faz necessário utilizar algum mecanismo para mapear os sinais separados de volta ao domínio original dos sinais de observação. Para isto, um banco de filtros de síntese é necessário para reconstruir o sinal $x[n]$ a partir dos $P$ sinais de sub-bandas $y_p[n]$, combinando essas sub-bandas para formar uma saída.

Em uma aplicação padrão da ICA, os sinais separados podem ser mapeados de volta ao domínio dos sinais de observação através da aplicação de um par de transformações de mistura e separação da seguinte forma (Davies e James, 2007):

$$\mathbf{y}_s^{(p)} = \mathbf{A}_{(:,p)}\mathbf{W}_{(p,:)}\mathbf{x}, \tag{4.54}$$

sendo, portanto, o vetor $\mathbf{y}_s^{(p)}$ de dimensão $M \times 1$. Cada linha $m$ do vetor $\mathbf{y}_s^{(p)}$, para $m = 1, 2, \ldots, M$, representa o peso original do $p$-ésimo sinal separado no $m$-ésimo sinal de observação. Para sinais temporais, (4.54) se torna:

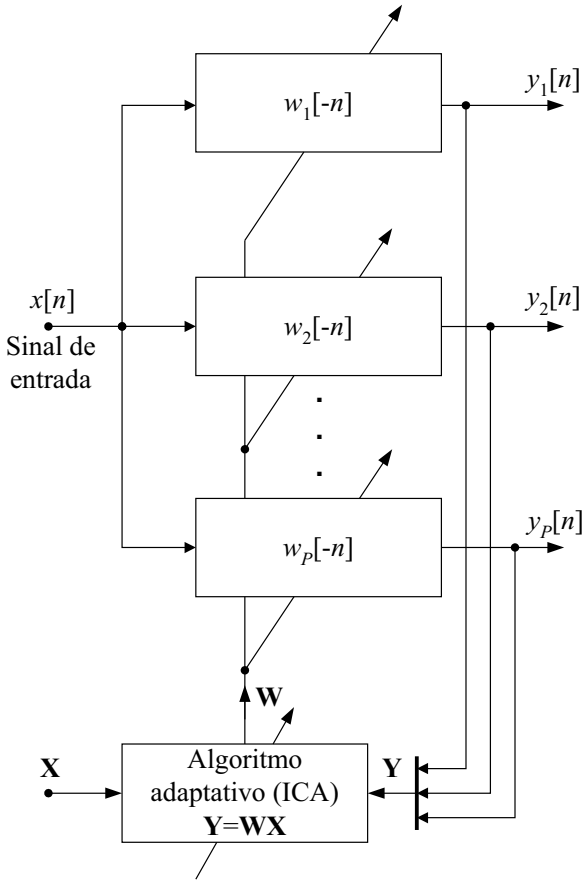


Figura 4.18: Diagrama de blocos do banco de filtros lineares adaptativos que obtém o $P$ sinais de saída a partir do sinal de entrada $x[n]$.

$$\mathbf{y}_s^{(p)}[n] = \mathbf{A}_{(:,p)}\mathbf{W}_{(p,:)}\mathbf{x}[n]. \tag{4.55}$$

Sendo que $y_p[n] = \mathbf{W}_{(p,:)}\mathbf{x}[n]$, então:

$$\mathbf{y}_s^{(p)}[n] = \mathbf{A}_{(:,p)}y_p[n]. \tag{4.56}$$

Substituindo (4.53) em (4.56), obtém-se:

$$\mathbf{y}_s^{(p)}[n] = \mathbf{A}_{(:,p)}\sum_{m=0}^{M-1}\mathbf{W}_{(p,M-m)}x[n-m]. \tag{4.57}$$

Cada linha do vetor $\mathbf{y}_s^{(p)}[n]$ representa o peso da $p$-ésima fonte no $m$-ésimo sinal de observação no instante $n$. Mas, no caso da SCICA, cada sinal de observação $\mathbf{x}[m]$, para $m = 2, \ldots, M$, é

simplesmente uma versão do sinal de observação $\mathbf{x}[m-1]$ transladado à esquerda por $\tau$ amostras (vide Eq. (4.50)). Em suma, os sinais de observação são versões transladadas do sinal de entrada. Sendo assim, poder-se-á deduzir que o peso da $p$-ésima fonte seria o mesmo nos $M$ sinais de observação. Entretanto, as estimativas das fontes reconstruídas são dependentes do alinhamento de cada sinal de observação com o sinal de entrada (Davies e James, 2007). No caso do método FICA, não há esse problema, pois todos os sinais de observação possuem o mesmo atraso em relação ao sinal de entrada. Para obter uma completa invariância à translação do sinal de entrada provocada pelo processo de construção da matriz $\mathbf{X}$ no método SCICA, Davies e James (2007) propõem o uso da técnica *cycle-spinning* (Coifman e Donoho, 1995).

Implementando a técnica *cycle-spinning* considerando-se $\tau = 1$, para cada linha $m$ do vetor $\mathbf{y}_s^{(p)}[n]$ em (4.56), o sinal $y_p[n]$ é transladado pelo deslocamento de uma amostra à direita $j$, sendo $j = 0, 1, \ldots, M-1$, e a média simples das $M$ estimativas obtidas por esta operação é calculada para obter o escalar $y_s^{(p)}[n]$, ou seja:

$$y_s^{(p)}[n] = \frac{1}{M} \sum_{j=0}^{M-1} A_{(j+1,p)} y_p[n-j]. \tag{4.58}$$

Sendo assim, a operação acima reverte o efeito de translação à esquerda provocado pelo esquema de construção da matriz $\mathbf{X}$ no método SCICA. A Figura 4.19 mostra o diagrama de blocos que descreve (4.58), no qual se observa que a aplicação da técnica *cycle-spinning* resulta em um filtro FIR, cujos coeficientes de resposta ao impulso são associados ao vetor coluna $\mathbf{A}_{(:,p)}$.

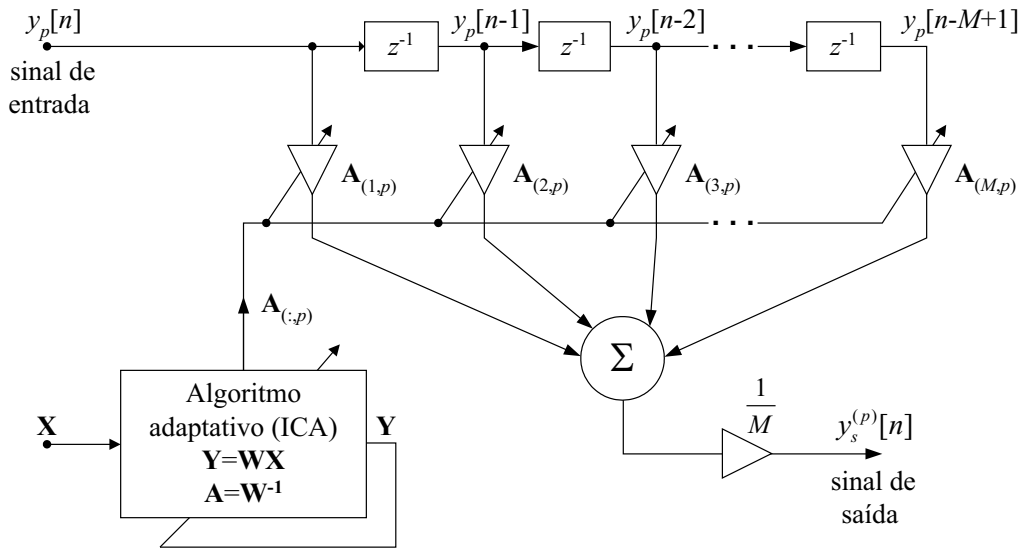


Figura 4.19: Diagrama de blocos do filtro linear adaptativo que obtém o sinal $y_s^{(p)}[n]$ a partir do sinal $y_p[n]$.

Substituindo (4.53) em (4.58), obtém-se:

$$
\begin{aligned}
y_s^{(p)}[n] &= \frac{1}{M}\sum_{j=0}^{M-1}\mathbf{A}_{(j+1,p)}\sum_{m=0}^{M-1}\mathbf{W}_{(p,M-m)}x[n-m-j] \\
&= \frac{1}{M}a_p[n] * w_p[-n] * x[n], \qquad (4.59)
\end{aligned}
$$

onde $a_p[n]$ representa o filtro FIR associado ao vetor coluna $\mathbf{A}_{(:,p)}$. Pode-se observar que a estimativa $y_s^{(p)}[n]$ é uma versão filtrada de $x[n]$ obtida pela configuração em cascata dos filtros $a_p[n]$ e $w_p[-n]$, cujos coeficientes de resposta ao impulso foram estimados pela ICA de maneira adaptativa e não-supervisionada. A Figura 4.20 mostra o diagrama de blocos da estrutura completa representando os bancos de filtros de análise e síntese responsáveis por obter os sinais $y_s^{(1)}[n], \ldots, y_s^{(P)}[n]$ a partir de $x[n]$.

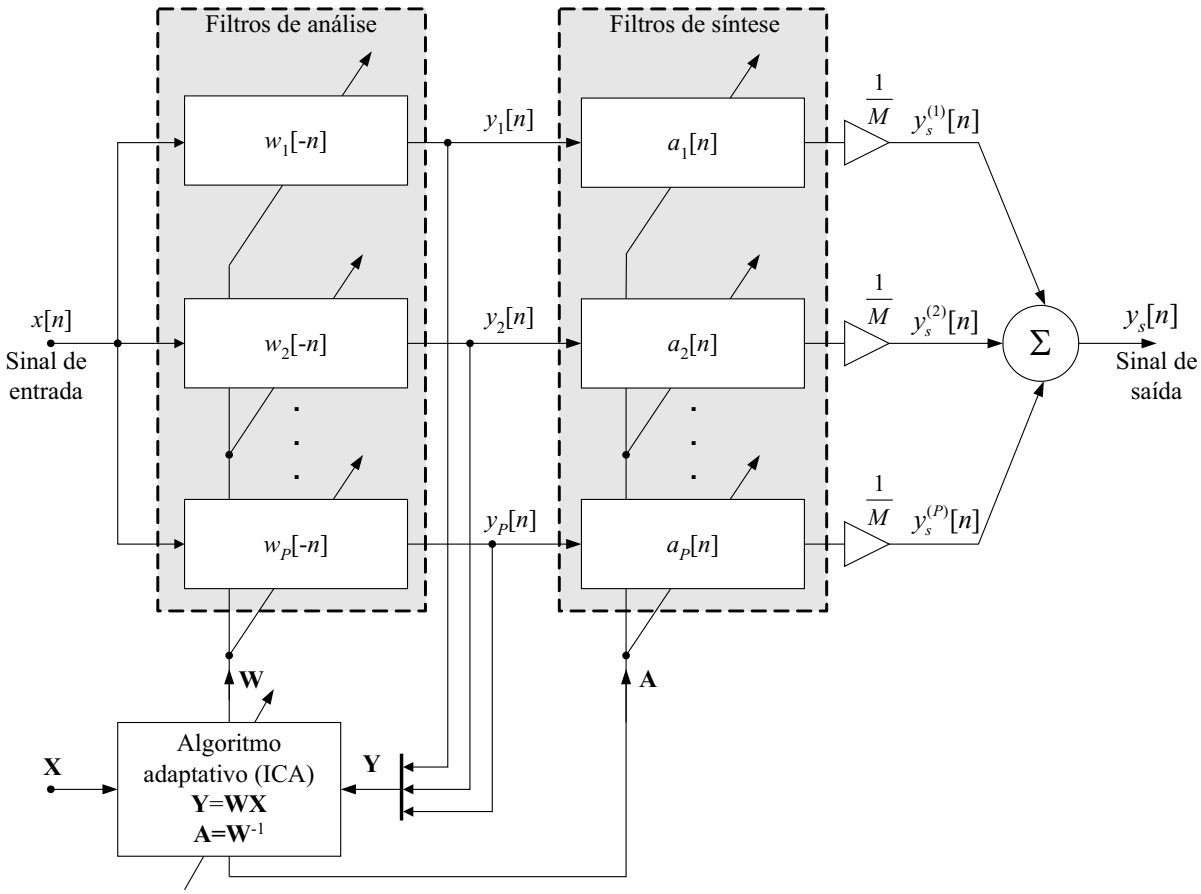


Figura 4.20: Diagrama de blocos do banco de filtros lineares adaptativos que obtém os $P$ sinais de saída a partir do sinal de entrada $x[n]$.

Devido ao fato da matriz $\mathbf{X}$ ser branqueada na etapa de pré-processamento da ICA (vide Seção 3.1.5), as matrizes $\mathbf{A}$ e $\mathbf{W}$ são ortogonais. Por causa disso, os filtros resultantes da cascata dos filtros $a_p[n]$ e $w_p[-n]$ possuem fase zero. Desta forma, o atraso evidenciado nos sinais $y_s^{(p)}[n]$ em relação a $x[n]$ é devido apenas à inserção de $M\tau - 1$ zeros no início dos sinais de observação.

Uma importante propriedade ao mapear os componentes independentes de volta ao domínio dos sinais de observação é que se alcança uma reconstrução perfeita de $\mathbf{x}$ (Davies e James, 2007), isto é:

$$\mathbf{x} = \sum_{p=1}^{P} \mathbf{y}_s^{(p)}. \tag{4.60}$$

Considerando-se sinais temporais, tem-se na Figura 4.20 que:

$$y_s[n] = \sum_{p=1}^{P} y_s^{(p)}[n] = x[n - M + 1]. \tag{4.61}$$

Suponha que o sinal de entrada $x[n]$ tenha sido decomposto pela estrutura da Figura 4.20 e tenham sido obtidos os sinais $y_s^{(p)}[n]$, para $p = 1, \ldots, P$. Geralmente, o número de sinais de observação no método SCICA deve ser maior do que o número de fontes, para se alcançar filtros com comprimentos suficientes para conseguir filtrá-las. O comprimento, tanto dos filtros FIR de análise quanto dos filtros FIR de síntese, é exatamente igual ao número $M$ de sinais de observação. Como consequência do número de sinais de observação ser maior do que o número de fontes, mais de um componente independente pode estar associado a uma mesma fonte, sendo necessário identificar quais componentes (e quantos) são associados a cada fonte.

Suponha agora que o sinal de saída $y_s[n]$ da Figura 4.20 admita uma decomposição dada por uma soma de $C$ processos estocásticos mutuamente independentes $y_{\mathrm{rec}_c}[n]$, ou seja:

$$y_s[n] = \sum_{c=1}^{C} y_{\mathrm{rec}_c}[n]. \tag{4.62}$$

Cada processo estocástico $y_{\mathrm{rec}_c}[n]$, para $c = 1, \ldots, C$, pode ser decomposto pela ICA em vetores base $\mathbf{a}_p$ os quais podem ser agrupados em um mesmo subconjunto $\gamma_c$, de tal forma que se $p \in \gamma_c$, então $\mathbf{a}_p$ se encontra em um mesmo sub-espaço $E_c$ no espaço $\mathbb{R}^M$ (Davies e James, 2007). Além disso, sendo que esses vetores base tendem a ser aproximações transladadas de um mesmo filtro ótimo $\mathbf{h}_c$, todos os vetores base associados a um mesmo subconjunto $\gamma_c$ geralmente

possuem suportes espectrais similares. Portanto, tal característica pode ser útil para identificar os componentes independentes associados a uma mesma fonte. Dependendo da largura de banda de $\mathbf{h}_c$, haverá um número diferente de versões transladadas de um mesmo filtro. Geralmente, as fontes que possuem espectros mais amplos são associadas a um número maior de componentes independentes do que aquelas que possuem espectros mais estreitos.

Se os sub-espaços $E_1, \ldots, E_C$ são linearmente independentes, então cada processo estocástico $y_{\mathrm{rec}_c}[n]$ pode ser corretamente identificado (Davies e James, 2007). Para que esses sub-espaços sejam linearmente independentes, os processos estocásticos $y_{\mathrm{rec}_c}[n]$ devem possuir suporte espectral disjunto, ou seja, devem ocorrer em bandas de frequência distintas. Esta é também uma condição para separar fontes através de filtros lineares invariantes no tempo. Entretanto, com a utilização da ICA, obtém-se filtros lineares adaptativos.

Seguindo o modelo proposto neste trabalho, os componentes $y_s^{(p)}[n]$ associados a uma mesma fonte deverão possuir semelhanças espectrais. Por outro lado, aqueles componentes associados a diferentes fontes deverão possuir espectros disjuntos, desde que, obviamente, tais fontes não sejam sobrepostas na frequência. Agrupando-se em cada subconjunto $\gamma_c$ os componentes $y_s^{(p)}[n]$ que possuem similaridades espectrais entre si, obtém-se:

$$y_{\mathrm{rec}_c}[n] = \sum_{p \in \gamma_c} y_s^{(p)}[n], \tag{4.63}$$

sendo esta operação realizada de tal forma que cada componente $y_s^{(p)}[n]$ seja atribuído a apenas um subconjunto $\gamma_c$ dentro do universo $\gamma_1, \ldots, \gamma_C$.

Neste trabalho, é proposto o agrupamento dos componentes $y_s^{(p)}[n]$ associados a uma mesma fonte baseado em suas similaridades no domínio da frequência. O objetivo é indexar aqueles componentes mais similares entre si dentro de um mesmo grupo, sendo definido um total de $C$ grupos distintos. Componentes que apresentem pouca ou nenhuma similaridade espectral entre si devem ser indexados dentro de grupos distintos.

O algoritmo de agrupamento utilizado neste trabalho é o algoritmo de $k$-médias, ou *k-means* (da Silva *et al.*, 2010). O algoritmo *k-means* é um dos métodos mais simples de aprendizagem não-supervisionada para a resolução do problema de agrupamento de dados. O procedimento classifica um determinado conjunto de dados através de um número pré-estabelecido de *clusters* (no caso deste trabalho, $C$ *clusters*). A principal idéia seria então definir $C$ centróides, um para cada *cluster*. A posição inicial escolhida para os centróides afeta diretamente o resultado

final, de forma que diferentes posicionamentos iniciais podem levar a diferentes posicionamentos finais, para um mesmo conjunto de dados. Sendo assim, a melhor escolha é posicioná-los inicialmente o mais distante possível uns dos outros. A próxima etapa é associar cada amostra do conjunto de dados ao centróide mais próximo. Quando nenhuma amostra estiver pendente, esta etapa terá sido completa e um agrupamento inicial estará pronto. Então, é necessário recalcular $C$ novos centróides como sendo baricentros dos *clusters* resultantes da etapa anterior. Após serem obtidos esses $C$ novos centróides, uma nova associação deve ser feita entre cada amostra do conjunto de dados e os novos centróides mais próximos. Assim, os $C$ centróides mudam suas localizações passo a passo até que não haja mais alterações. Resumindo, o algoritmo é composto pelas seguintes etapas:

1. Inicializar $C$ pontos no espaço representado pelas amostras de dados que estão sendo agrupadas. Estes pontos representam os centróides iniciais de cada *cluster*.

2. Atribuir cada amostra ao *cluster* que possui o centróide mais próximo.

3. Quando todas as amostras tiverem sido atribuídas, recalcular as posições dos $C$ centróides.

4. Repetir as etapas 2 e 3 até que os centróides não mais se movam. Isso produz uma separação das amostras em grupos a partir da qual a métrica a ser minimizada pode ser calculada. Tipicamente, a métrica a ser minimizada é a distância euclidiana entre as amostras pertencentes a um mesmo *cluster*.

Como dito anteriormente, os componentes $y_s^{(p)}[n]$ serão agrupados com base nas suas similaridades no domínio da frequência, pois em tal domínio são mais evidentes as relações entre componentes associados a uma mesma fonte e as distinções entre componentes associados a fontes diferentes. Portanto, é necessária uma ferramenta para transformar os sinais $y_s^{(p)}[n]$ do domínio do tempo para o domínio da frequência. Devido a sua simplicidade, será utilizada a DFT (Mitra, 2006) para realizar tal propósito. Primeiramente, será então calculada a DFT de cada sinal $y_s^{(p)}[n]$, obtendo-se o sinal complexo $Y_s^{(p)}[k]$ correspondente.

Para a DFT, o teorema de Parseval (Mitra, 2006), dado um sinal de tempo discreto $y_s^{(p)}[n]$ de comprimento $N$ amostras e energia finita, pode ser matematicamente escrito da seguinte forma:

$$\sum_{n=0}^{N-1} |y_s^{(p)}[n]|^2 = \frac{1}{N} \sum_{k=0}^{N-1} |Y_s^{(p)}[k]|^2. \tag{4.64}$$

A interpretação desta versão do teorema diz que a energia total contida no sinal de tempo discreto $y_s^{(p)}[n]$ somada para todas as $N$ amostras é igual à energia total da DFT do mesmo sinal somada para todos os $N$ valores discretos de frequência, ou seja, a energia contida no sinal $y_s^{(p)}[n]$ se mantém ao se aplicar a DFT sobre o mesmo para mapeá-lo para o domínio da frequência. Sendo a DFT uma transformada simétrica em relação à frequência $\omega = \pi$ rad/s, necessita-se apenas calcular a energia para $k = 0$ até $k = \frac{N}{2} - 1$, e em seguida multiplicar o resultado por um fator $\frac{2}{N}$. Com isto, a relação descrita pelo teorema de Parseval pode ser reescrita da seguinte forma:

$$\sum_{n=0}^{N-1} |y_s^{(p)}[n]|^2 = \frac{2}{N} \sum_{k=0}^{\frac{N}{2}-1} |Y_s^{(p)}[k]|^2. \tag{4.65}$$

Chamando de $\mathbf{Y}_s^{(p)}$ o vetor obtido pela aplicação da DFT no sinal $y_s^{(p)}[n]$ seguida pela operação de módulo quadrático $|\cdot|^2$ e pela multiplicação pelo fator $\frac{2}{N}$, tem-se que:

$$\mathbf{Y}_s^{(p)} = \begin{bmatrix} \frac{2}{N}|Y_s^{(p)}[0]|^2 & \frac{2}{N}|Y_s^{(p)}[1]|^2 & \cdots & \frac{2}{N}|Y_s^{(p)}[N/2-1]|^2 \end{bmatrix}^T. \tag{4.66}$$

Observa-se, portanto, que os vetores $\mathbf{Y}_s^{(p)}$, para $p = 1, \ldots, P$, possuem comprimento igual a $N/2$ amostras. Tais vetores possuem dimensão ainda muito elevada para serem fornecidos como entrada para o algoritmo *k-means*, comprometendo o seu desempenho e exigindo um maior esforço computacional. Sendo assim, propõe-se fornecer como entrada para o algoritmo *k-means* os valores das energias acumuladas dentro de faixas pré-estabelecidas de frequência, ao invés dos valores das energias para todos os valores discretos de frequência. Para isto, inicialmente define-se $R$ faixas regulares de frequência, cada uma com largura $L = \frac{f_S}{2R}$ Hz, sendo $f_S$ a frequência de amostragem utilizada. Em seguida, a energia de cada faixa $r$ de frequência, para $r = 1, \ldots, R$, é calculada usando:

$$EY_s^{(p)}[r] = \sum_{f=(r-1)\cdot L}^{r\cdot L} \mathbf{Y}_s^{(p)}[f], \tag{4.67}$$

onde $f$ é um valor discreto de frequência diretamente relacionado ao índice $k$ por meio da relação $f = k \cdot \frac{f_S}{N}$, o que faz com que $f$ esteja compreendido na faixa $f = 0, \frac{f_S}{N}, \ldots, \left(\frac{N}{2} - 1\right) \cdot \frac{f_S}{N}$, para $k$ compreendido na faixa $k = 0, 1, \ldots, \frac{N}{2} - 1$. Após o cálculo das energias acumuladas dentro de cada uma das $R$ faixas de frequência, constrói-se então o vetor:

$$\mathbf{EY}_s^{(p)} = \left[ EY_s^{(p)}[1] \quad EY_s^{(p)}[2] \quad \cdots \quad EY_s^{(p)}[R] \right]. \tag{4.68}$$

Em seguida, os vetores $\mathbf{EY}_s^{(1)}, \mathbf{EY}_s^{(2)}, \ldots, \mathbf{EY}_s^{(P)}$ são fornecidos como entrada para o algoritmo *k-means*. Sendo assim, são fornecidos $P$ vetores como padrões de entrada para o algoritmo, cada um contendo $R$ amostras. Além disso, é fornecido também o número $C$ de *clusters* aos quais se deseja atribuir cada um dos padrões de entrada. Após alcançada a convergência do algoritmo *k-means*, cada um dos subconjuntos $\gamma_1, \gamma_2, \ldots, \gamma_C$ deverão ter associados a eles aqueles componentes independentes que apresentam similaridades entre si no domínio da frequência. A Figura 4.21 resume todos os blocos operacionais da etapa de agrupamento dos componentes independentes dentro de seus respectivos *clusters*.

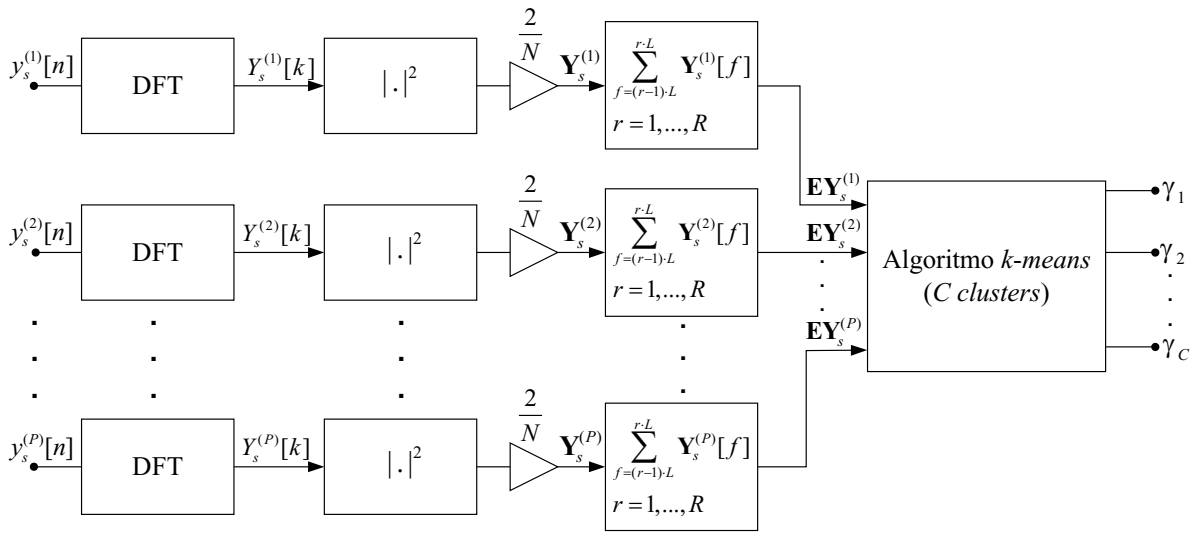


Figura 4.21: Diagrama de blocos da etapa de agrupamento dos componentes independentes relacionados a cada uma das fontes.

Após a operação de agrupamento ser concluída, os componentes independentes associados a cada *cluster* devem ser somados para reconstruir cada fonte $c$, para $c = 1, \ldots, C$, utilizando-se (4.63). Já os coeficientes dos filtros de separação/reconstrução para cada fonte $c$ podem ser obtidos através de:

$$f_c[n] = \frac{1}{M} \sum_{p \in \gamma_c} a_p[n] * w_p[-n], \tag{4.69}$$

sendo que $y_{\mathrm{rec}_c}[n] = f_c[n] * x[n]$.

A Figura 4.22 apresenta o diagrama de blocos do sistema completo, desde o recebimento do sinal de entrada $x[n]$ até o fornecimento das estimativas $y_{\mathrm{rec}_c}[n]$.

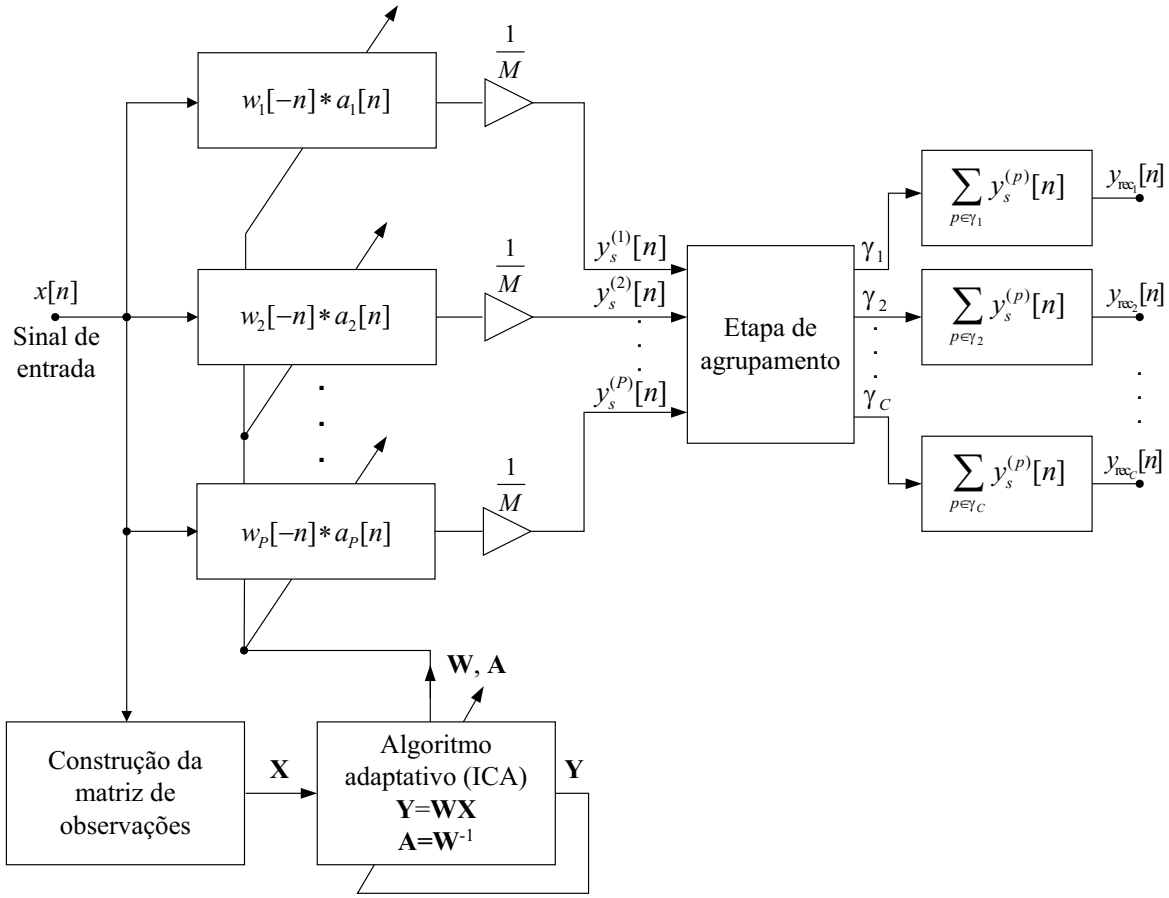


Figura 4.22: Diagrama de blocos do algoritmo SCICA completo.

### 4.3.1 Exemplo de aplicação

Nesta seção, será realizada a separação cega, pelo método SCICA, das fontes presentes no sinal $x[n]$ da Figura 4.7(c). Este mesmo sinal também foi decomposto anteriormente pelo método FICA, sendo o mesmo composto pela soma das senóides de 60 Hz e 120 Hz apresentadas, respectivamente, nas Figuras 4.7(a) e 4.7(b).

O primeiro passo do método SCICA, como pode ser visto na Figura 4.22, é construir a matriz de sinais de observação, $\mathbf{X}$. Essa matriz é construída utilizando-se (4.47), (4.48) e (4.49), ou de forma análoga, o esquema da Figura 4.16. No caso deste exemplo, adotou-se: $M = 12$ sinais de observação e $\tau = 1$ amostra de atraso. O próximo passo é aplicar o algoritmo que calcula a ICA (FastICA) à matriz $\mathbf{X}$, de forma a estimar as matrizes de separação $\mathbf{W}$ e de mistura

**A**. Em seguida, as matrizes obtidas são aplicadas em (4.59), para obter as $P$ estimativas dos componentes independentes $y_s^{(1)}[n], \ldots, y_s^{(P)}[n]$ a partir de $x[n]$.

As estimativas obtidas são mostradas na Figura 4.23. Como pode ser observado, há apenas $P = 4$ estimativas, embora tenham sido fornecidos à ICA $M = 12$ sinais de observação. Desta forma, a PCA, etapa interna ao algoritmo FastICA, reduziu a dimensão dos dados, por ter encontrado redundância nos mesmos (veja a Seção 3.1.5). Cada $p$-ésima estimativa de componente independente é uma versão filtrada de $x[n]$, sendo que, claramente, há múltiplas estimativas diretamente associadas a cada fonte presente nesse sinal. Mais precisamente, as estimativas $y_s^{(1)}[n]$ e $y_s^{(3)}[n]$ são associadas à fonte $s_1[n]$ (60 Hz), e as estimativas $y_s^{(2)}[n]$ e $y_s^{(4)}[n]$ são associadas à fonte $s_2[n]$ (120 Hz).

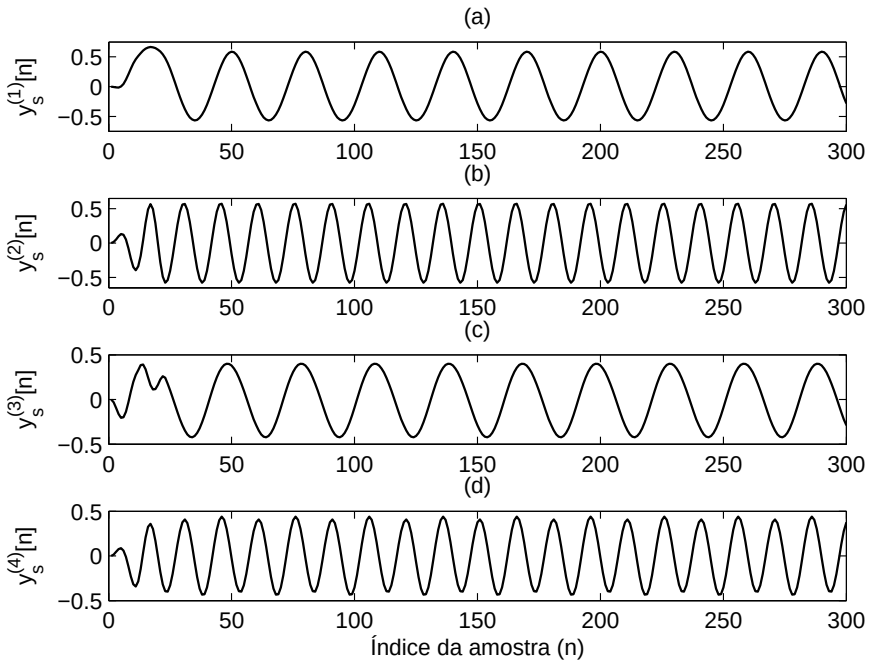


Figura 4.23: Estimativas de componentes independentes com escalas recuperadas.

Portanto, a etapa de agrupamento se faz necessária neste momento. Esta etapa é detalhada na Figura 4.21. Ela deve automaticamente identificar as estimativas associadas a uma mesma fonte e agrupá-las juntas dentro de um mesmo *cluster*. Como há duas fontes, adotou-se $C = 2$ *clusters* a serem estimados pelo algoritmo *k-means*. Para o cálculo dos vetores de energias a serem fornecidos como entradas para o algoritmo *k-means*, adotou-se $R = 15$ faixas de frequência, o que proporciona uma largura de banda $L = 60$ Hz para cada faixa de frequência, lembrando-se que a frequência de amostragem utilizada para a geração do sinal $x[n]$ foi $f_S = 1800$ Hz. Pode ser

evidenciada aqui a redução da dimensão dos dados a serem fornecidos para o algoritmo *k-means* por meio da técnica proposta, de um total de $N = 300$ amostras para apenas $R = 15$ amostras.

Desta forma, para cada estimativa, a faixa $r = 1$ contém a energia acumulada no intervalo de frequências $[0, 60)$ Hz. A faixa $r = 2$ contém a energia acumulada no intervalo de frequências $[60, 120)$ Hz. A faixa $r = 3$ contém a energia acumulada no intervalo de frequências $[120, 180)$ Hz, e assim por diante, até a faixa $r = 15$, que contém a energia acumulada na faixa de frequências $[840, 900)$ Hz. A Figura 4.24 mostra a distribuição dos valores de energia para cada componente $y_s^{(p)}[n]$ ao longo das 15 faixas de frequência, sendo tais valores armazenados no vetor correspondente $\mathbf{EY}_s^{(p)}$. Como o sinal $x[n]$ contém somente os componentes de 60 Hz e 120 Hz, apenas as faixas $r = 2$ e $r = 3$ apresentam energia.

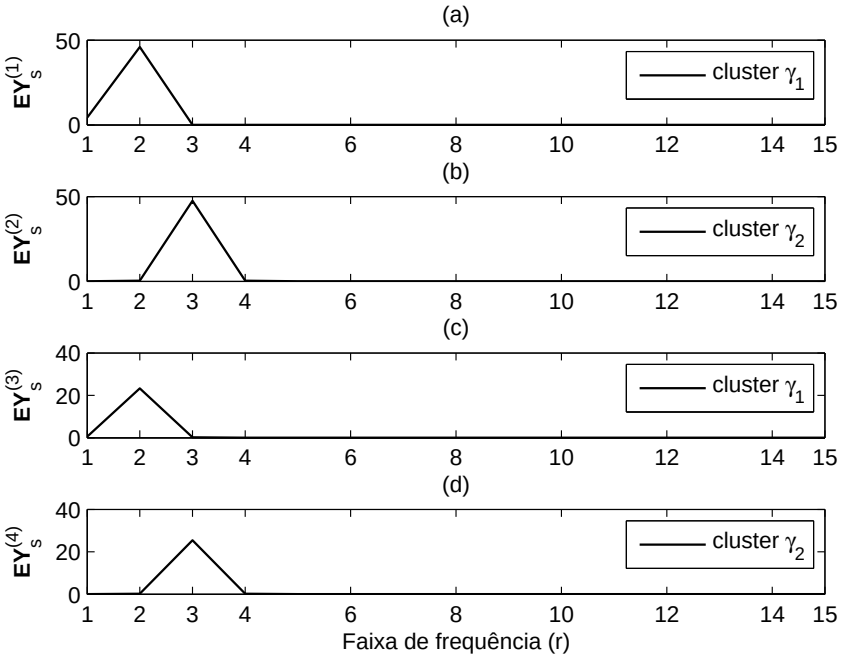


Figura 4.24: Vetores de energias calculados para as estimativas de componentes independentes, com o respectivo agrupamento pelo algoritmo *k-means* baseado em suas similaridades espectrais.

A Figura 4.24 também mostra, nas legendas, o resultado do agrupamento de cada vetor de energia dentro dos *clusters* $\gamma_1$ ou $\gamma_2$, alcançado pelo algoritmo *k-means*. O resultado revela que os vetores 1 e 3 foram agrupados dentro do *cluster* $\gamma_1$, e os vetores 2 e 4 foram agrupados dentro do *cluster* $\gamma_2$. De fato, voltando à análise da Figura 4.23, confirma-se que as estimativas $y_s^{(1)}[n]$ e $y_s^{(3)}[n]$ são associadas à fonte $s_1[n]$, e as estimativas $y_s^{(2)}[n]$ e $y_s^{(4)}[n]$ são associadas à fonte $s_2[n]$. Sendo assim, cada *cluster* engloba os componentes pertencentes a um diferente subespaço independente, cada qual dentro de uma diferente faixa de frequências do sinal de entrada

$x[n]$. O primeiro sub-espaço possui dimensão 2, e o segundo subespaço também possui dimensão 2. A dimensão de cada sub-espaço é função da largura de banda de cada fonte independente. Como ambas as fontes possuem somente um componente de frequência cada, os sub-espaços associados a ambas possuem a mesma dimensão.

O próximo passo, como pode ser visto na Figura 4.22, é somar os componentes independentes associados ao *cluster* $\gamma_1$, para obter $y_{\text{rec}_1}[n]$, e somar os componentes independentes associados ao *cluster* $\gamma_2$, para obter $y_{\text{rec}_2}[n]$. Os sinais obtidos através desta operação de reconstrução são mostrados na Figura 4.25, onde $y_{\text{rec}_1}[n]$ é uma estimativa da fonte $s_1[n]$ e $y_{\text{rec}_2}[n]$ é uma estimativa da fonte $s_2[n]$. Como pode ser observado, as escalas das fontes foram recuperadas. O atraso observado em cada estimativa em relação à sua respectiva fonte é igual a 11 amostras, provocado pela inserção de $M\tau - 1$ zeros durante o processo de construção da matriz de observações $\mathbf{X}$.

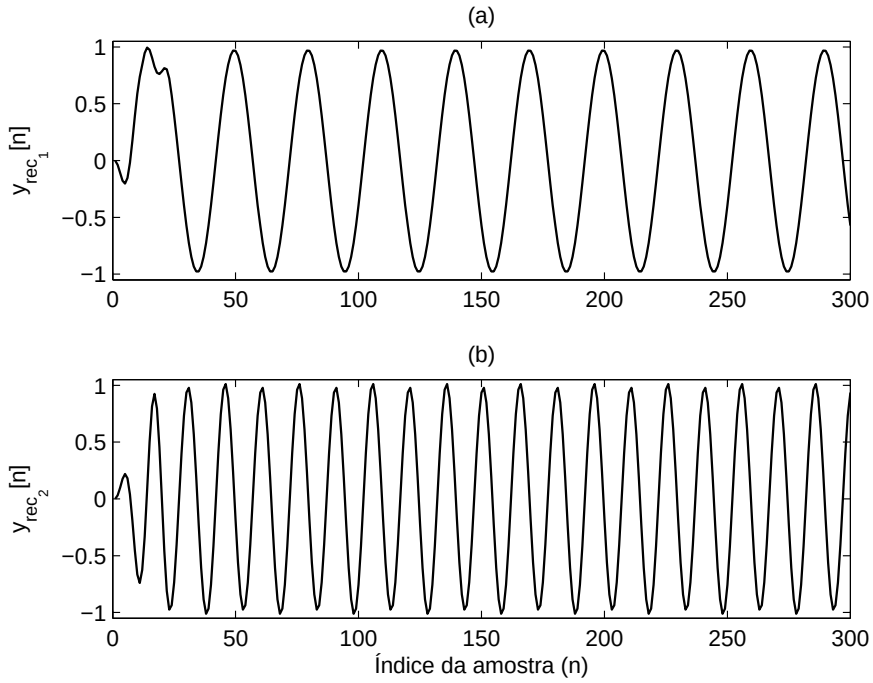


Figura 4.25: Componentes separados e reconstruídos utilizando-se o método SCICA; (a) $y_{\text{rec}_1}[n]$ e, (b) $y_{\text{rec}_2}[n]$.

De forma equivalente, os componentes $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_2}[n]$ também poderiam ser encontrados por meio da operação de filtragem do sinal de entrada $x[n]$ utilizando-se os filtros adaptativos $f_1[n]$ e $f_2[n]$, obtidos através de (4.69). A Figura 4.26 mostra os módulos das respostas em frequência desses filtros, além do espectro de frequências de $x[n]$. Pode ser observado que o filtro $f_1[n]$, responsável por obter $y_{\text{rec}_1}[n]$ por meio da filtragem de $x[n]$, atenua profundamente a frequência da fonte $s_2$ e passa com ganho unitário a frequência da fonte $s_1$. Por outro lado,

o filtro $f_2[n]$, responsável por obter $y_{\text{rec}_2}[n]$ por meio da filtragem de $x[n]$, atenua severamente a frequência da fonte $s_1$ e passa com ganho unitário a frequência da fonte $s_2$. Tais resultados estão de acordo com aqueles mostrados na Figura 4.25. A partir dos resultados obtidos para este exemplo, fica claro que o método SCICA separou de maneira totalmente adaptativa e cega (não-supervisionada) as fontes presentes no único sinal apresentado ao mesmo ($x[n]$).

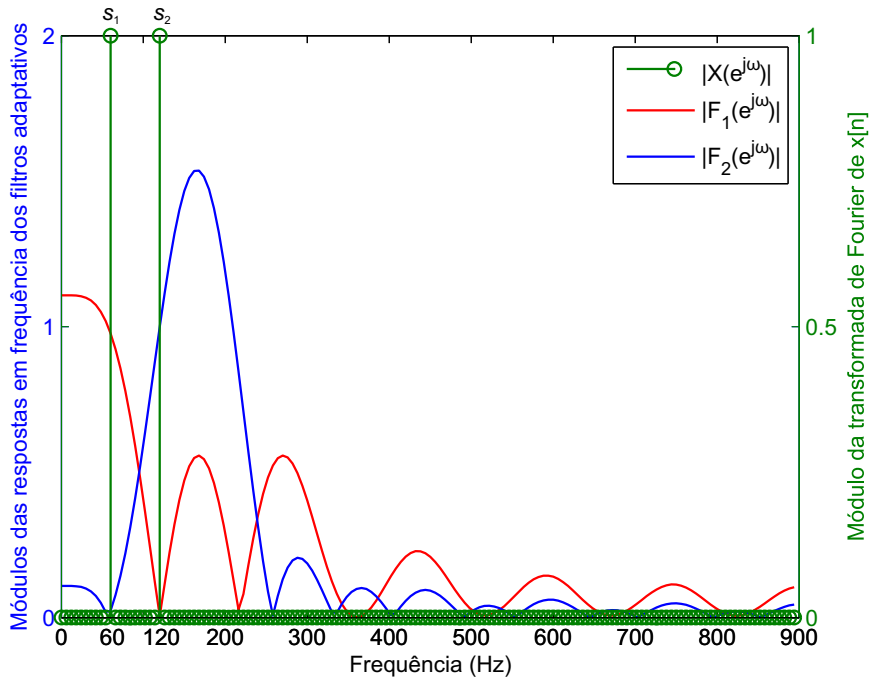


Figura 4.26: Módulos das respostas em frequência dos filtros adaptativos resultantes da operação do método SCICA, e espectro de frequências do sinal $x[n]$.

## 4.4 Considerações finais do capítulo

Este capítulo propôs dois métodos para separação cega de fontes utilizando-se a ICA, visando a sua aplicação tendo disponível apenas um sinal de mistura das fontes. O primeiro deles, o método FICA, utiliza um banco de filtros fixos para gerar artificialmente os múltiplos sinais de observação para a ICA. Conforme foi demonstrado, é possível este método recuperar as fontes independentes e espectralmente disjuntas presentes no sinal de mistura se o banco de filtros aplicar ganhos e atrasos constantes em cada uma das fontes, sendo que esses filtros devem também gerar sinais de observação linearmente independentes. Já o método SCICA gera artificialmente os sinais de observação por meio da aplicação de sucessivos atrasos temporais no sinal de mistura das fontes. Foi demonstrado que este método também consegue recuperar as

fontes independentes e espectralmente disjuntas presentes no sinal de mistura.

O método FICA, embora seja mais simples computacionalmente, exige o projeto inicial do banco de filtros, o que de certo modo faz com que a separação das fontes possa não ser de todo realmente cega, podendo exigir algum conhecimento inicial a seu respeito para que a sua separação seja adequada. Já o método SCICA não exige nenhum conhecimento a respeito das fontes, mas esta qualidade vem às custas de uma maior complexidade computacional, exigindo um número de sinais de observação geralmente bem maior do que o número de fontes para a separação das fontes ser adequada. Por causa disso, há múltiplas estimativas associadas a uma mesma fonte, exigindo também a etapa de agrupamento.

Diferentemente das aplicações tradicionais da ICA, que buscam pela independência espacial das fontes, ambos os métodos propostos buscam pela independência no plano tempo-frequência. Por causa disso, eles não conseguem separar fontes que possuam sobreposição espectral. Uma outra forma de visualizar esta limitação é que os resultados da aplicação de ambos os métodos são bancos de filtros lineares, porém adaptativos e não-supervisionados. O próximo capítulo apresenta uma metodologia que utiliza os métodos propostos neste capítulo, visando a separação e a recuperação das formas de onda de componentes primitivos quando da ocorrência de múltiplos distúrbios de QEE, a partir da medição de um único sinal de tensão e/ou corrente no SEP.

# Capítulo 5

# Decomposição de sinais contendo múltiplos distúrbios de QEE utilizando-se os métodos FICA e SCICA

O objetivo da metodologia proposta neste capítulo é decompor uma forma de onda de tensão ou corrente do SEP de maneira não-supervisionada utilizando-se a ICA, porém dispondo-se apenas de um único canal de monitoramento. Objetiva-se que a metodologia alcance estimativas que possam expressar melhor, do ponto de vista individual, cada componente primitivo presente no sinal medido, quando da presença de múltiplos distúrbios. Serão propostos dois sistemas, cujo bloco principal é o método FICA no primeiro e o método SCICA no segundo. A teoria referente aos dois métodos foi apresentada no capítulo anterior.

## 5.1 Sistema proposto empregando o método FICA

O sistema proposto para decompor um sinal de tensão ou corrente $u[n]$ utilizando-se o método FICA é dividido segundo os blocos mostrados na Figura 5.1. Como pode ser observado, o método FICA está incorporado na estrutura, sendo $x[n]$ o sinal aplicado em sua entrada e $y_{\mathrm{rec}_1}[n], \ldots, y_{\mathrm{rec}_P}[n]$ os seus sinais de saída. Ressalta-se que a estrutura interna do método FICA pode ser revista na Figura 4.4. A seguir será realizada a descrição dos componentes do sistema.

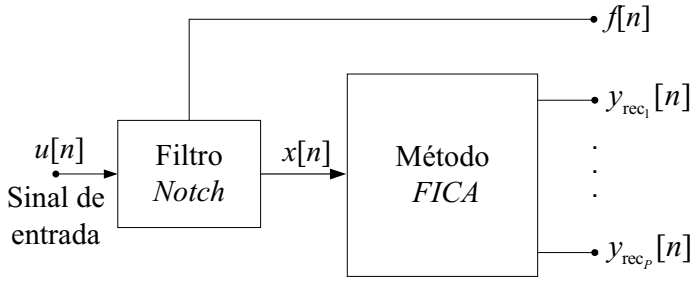


Figura 5.1: Diagrama de blocos do sistema proposto baseado no método FICA.

### 5.1.1 Filtro *Notch*

O objetivo da utilização do filtro *notch* é separar o componente fundamental do sinal de entrada. O componente fundamental é o que possui a maior energia contida neste sinal, podendo comprometer a separação dos demais componentes primitivos. Portanto, ele é previamente filtrado pelo filtro *notch*, sendo facilmente removido devido ao fato de ocorrer em uma única frequência, a qual é bem estabelecida (50 Hz ou 60 Hz). O sinal $f[n]$ fornece uma estimativa do componente fundamental, e $x[n] = u[n] - f[n]$ fornece uma estimativa da soma dos demais componentes primitivos que estejam ocorrendo no sinal $u[n]$.

De acordo com a modelagem que foi apresentada na Seção 2.3, a partir do sinal $f[n]$, distúrbios tais como afundamentos, elevações e interrupções poderiam ser diagnosticados de uma maneira bem direta. Isto porque tais distúrbios são todos caracterizados por variações de tensão fora das faixas normais de operação do SEP. Sendo assim, se um destes distúrbios ocorrer, então informações extraídas da variação de amplitude da estimativa do componente fundamental $f[n]$ poderiam ser utilizadas para detectá-lo.

O filtro *notch* proposto neste trabalho utiliza a DFT aplicada para extrair apenas um componente de frequência (componente fundamental) utilizando a formulação recursiva do algoritmo (Mitra, 2006). A equação da formulação recursiva da DFT para a extração apenas do componente fundamental, no instante de tempo $n$, é dada por:

$$U_1[n] = U_1[n-1] + (u[n] - u[n-J])e^{-j2\pi n/J}, \tag{5.1}$$

onde $J$ é o tamanho da janela deslizante para 1 ciclo fundamental, e $U_1[n]$ é uma função complexa de $n$, e que pode ser expressa na forma polar como:

$$U_1[n] = |U_1[n]|e^{j\phi[n]}, \tag{5.2}$$

onde a amplitude e a fase de $U_1[n]$ são calculadas, respectivamente, por:

$$|U_1[n]| = \sqrt{\mathrm{Re}\{U_1[n]\}^2 + \mathrm{Im}\{U_1[n]\}^2}, \tag{5.3}$$

$$\phi[n] = \tan^{-1}\left(\frac{\mathrm{Im}\{U_1[n]\}}{\mathrm{Re}\{U_1[n]\}}\right). \tag{5.4}$$

Para reconstruir a forma de onda do componente fundamental, é necessário calcular a DFT inversa do harmônico de interesse, ou seja, apenas do próprio componente fundamental. Sendo assim, a transformada inversa será dada por:

$$u_1[n] = \frac{2}{J}U_1[n]e^{j2\pi n/J}. \tag{5.5}$$

Sendo que o espectro de um sinal senoidal é simétrico em relação à frequência zero, o fator 2 é necessário em (5.5). Substituindo (5.2) em (5.5) e usando a Fórmula de Euler, o sinal desejado $f[n]$, o qual é a parte real de $u_1[n]$, pode ser reconstruído utilizando:

$$f[n] = \frac{2}{J}|U_1[n]|\cos\left(\phi[n] + \frac{2\pi n}{J}\right). \tag{5.6}$$

A Figura 5.2 mostra o diagrama de blocos do filtro *notch*, sendo que o bloco estimador de parâmetros executa (5.1), e o bloco gerador do componente fundamental executa (5.3), (5.4) e (5.6).

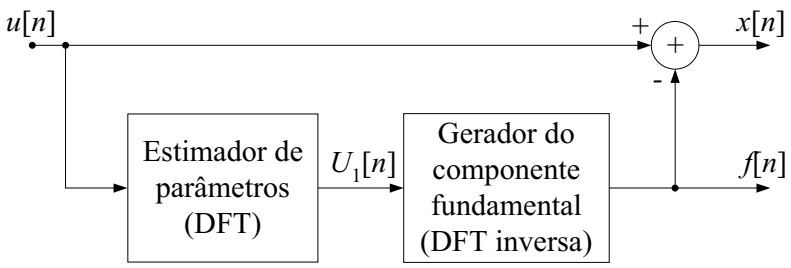


Figura 5.2: Diagrama de blocos do filtro *notch*.

### 5.1.2 Projeto do banco de filtros fixos do método FICA

Alguns parâmetros do método FICA devem ser pré-definidos, de forma a obter uma decomposição adequada do sinal de entrada. Mais precisamente, com relação à etapa de geração dos sinais de observação através do banco de filtros fixos, o número de filtros ($M$), a ordem desses filtros ($K$) e suas respostas em frequência devem ser definidos antes de sua utilização.

#### Número de filtros ($M$)

O número de filtros ($M$) está diretamente relacionado ao número de componentes independentes a serem estimados pela ICA. O sinal $x[n]$ é decomposto nas formas de onda de suas estimativas de componentes independentes. Portanto, em uma situação ideal de mistura de distúrbios que sejam independentes e não-sobrepostos espectralmente, o número de filtros fixos necessários deveria ser igual ao número de distúrbios presentes em $x[n]$. Para a situação ideal acima, caso o número de filtros seja maior do que o número de distúrbios, percebe-se que pelo menos um dos distúrbios será sub-decomposto em mais de uma estimativa de componente independente. Caso o número de filtros seja menor do que o número de distúrbios existentes, percebe-se que pelo menos um dos distúrbios nunca será totalmente separado, mantendo-se sobreposto junto a estimativas mais correlacionadas a outros distúrbios.

Na Seção 5.3.2, serão mostrados exemplos de aplicação do método FICA alterando-se o número de filtros fixos, onde poderá ser observado que ocorre o que foi descrito acima. Geralmente, dois ou três filtros fixos são suficientes para a maioria dos casos, já que a probabilidade de mais de três distúrbios ocorrerem simultaneamente em $x[n]$ seria pequena.

#### A ordem dos filtros ($K$)

Um importante requerimento é que todos os filtros possuam a mesma ordem, mantendo-se o sincronismo entre os sinais de observação obtidos por eles, como foi explicado na Seção 4.2.1. Dado que o filtro $h_1[n]$ seja um filtro passa-todas, deixando assim passar toda a informação contida no sinal $x[n]$, a respeito de todos os seus componentes primitivos, pode-se perceber que a ordem dos filtros não é um parâmetro crítico. Pode-se variar o seu valor dentro de uma faixa relativamente grande de valores sem se observar grandes alterações nos resultados da aplicação do método proposto. Contudo, a escolha de $K$ deve manter uma relação de compromisso entre, no mínimo, ser suficiente para gerar misturas linearmente independentes e, no máximo, não

provocar atrasos muito elevados e transitórios indesejados. Como será observado nos resultados da Seção 5.3.2, a escolha de $K = 20$ será suficiente para se obter desempenho adequado na decomposição dos tipos de sinais analisados neste trabalho.

### Respostas em frequência dos filtros

Como foi visto na Seção 4.2, os filtros $h_1[n], \ldots, h_M[n]$ devem apresentar respostas em frequência capazes de fornecer sinais de observação linearmente independentes para o algoritmo que calcula a ICA. Mais precisamente, tais filtros devem aplicar ganhos linearmente independentes nos componentes primitivos presentes em $x[n]$, de forma que a matriz de mistura $\mathbf{A}$ a ser estimada pela ICA seja invertível. Além disso, se cada um desses filtros aproximadamente aplicar ganhos e atrasos constantes nas bandas de frequência de cada um dos componentes primitivos, e se cada componente primitivo for uma fonte independente $s_1[n], \ldots, s_P[n]$ não sobreposta espectralmente às demais, então a aproximação dada por (4.37), repetida aqui por conveniência, é válida.

$$\begin{bmatrix} y_{\mathrm{rec}_1}[n] \\ \vdots \\ y_{\mathrm{rec}_P}[n] \end{bmatrix} \simeq \begin{bmatrix} b_1 w_{11} & \cdots & b_1 w_{1M} \\ \vdots & \ddots & \vdots \\ b_P w_{P1} & \cdots & b_P w_{PM} \end{bmatrix} \times$$
$$\times \begin{bmatrix} \alpha_{11} & \cdots & \alpha_{1P} \\ \vdots & \ddots & \vdots \\ \alpha_{M1} & \cdots & \alpha_{MP} \end{bmatrix} \begin{bmatrix} a_1 s_1[n - K/2] \\ \vdots \\ a_P s_P[n - K/2] \end{bmatrix}.$$

A aproximação acima revela que os sinais $[y_{\mathrm{rec}_1}[n], \ldots, y_{\mathrm{rec}_P}[n]]^T$ seriam capazes de estimar os sinais $[a_1 s_1[n-K/2], \ldots, a_P s_P[n-K/2]]^T$ se a parte adaptativa do método (ICA e combinador linear adaptativo) ajustasse uma matriz resultante que fosse capaz de inverter a matriz de pesos atribuídos pelo banco de filtros fixos às fontes presentes em $x[n]$.

Como já comentado anteriormente, para que todas as condições de separabilidade do método FICA sejam satisfeitas com um elevado nível de exatidão, talvez um grande conhecimento acerca dos espectros de frequência das fontes seria necessário, o que até poderia não justificar a aplicação deste método, tendo em vista que neste caso a aplicação de técnicas convencionais de filtragem linear resolveria o problema. No entanto, como será visto nos diversos resultados a

serem apresentados nas Seções 5.3.2 e 5.3.3, o método pode obter estimativas bem próximas das fontes originais mesmo para situações em que as condições de separabilidade sejam parcialmente satisfeitas.

Em um primeiro momento, o projeto dos filtros fixos pode ser realizado por tentativa e erro. Uma vez que o resultado seja satisfatório, pode ser percebido que na prática a mesma configuração pode vir a ser utilizada para a aplicação do método em diversos outros sinais. Mesmo que a situação ideal não seja alcançada, os resultados podem ser adequados, pois ainda assim as condições de separabilidade podem ser parcialmente cumpridas.

## 5.2 Sistema proposto empregando o método SCICA

A Figura 5.3 mostra o sistema proposto para decomposição baseado no método SCICA. O filtro *notch* tem a mesma função e é o mesmo utilizado no sistema baseado no método FICA. Externamente, a única diferença entre o método SCICA e o método FICA é a nomenclatura utilizada para os sinais de saída. Repare que no método SCICA há $C$ sinais de saída, sendo que cada um corresponde a um diferente *cluster* encontrado pelo algoritmo *k-means*. Já no método FICA, há $P$ sinais de saída, cada um correspondente a uma diferente estimativa de componente independente encontrada pela ICA. Os detalhes de projeto do sistema baseado no método SCICA serão descritos a seguir.

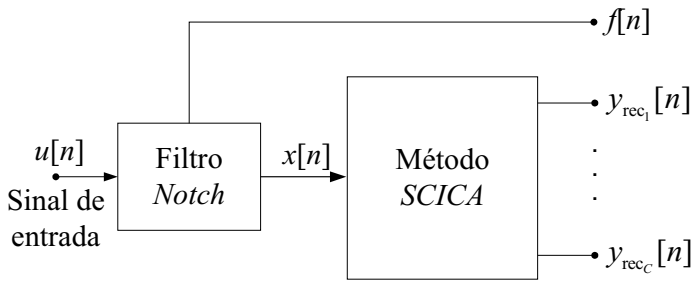


Figura 5.3: Diagrama de blocos do sistema proposto baseado no método SCICA.

Cabe comentar que há alguns trabalhos que utilizam uma estrutura semelhante à da Figura 5.3 para decompor sinais contendo múltiplos distúrbios de QEE (Ferreira *et al.*, 2012; Ruiz-Llata *et al.*, 2011; Ferreira, 2010; Ferreira *et al.*, 2009). No entanto, o algoritmo do método SCICA utilizado nestes trabalhos contém somente a etapa de geração dos sinais de observação e a própria ICA. Não há a recuperação das escalas dos componentes independentes, e nem o agrupamento dos componentes independentes associados a uma mesma fonte. Em função

disso, a qualidade dos resultados de separação de distúrbios alcançados nestes trabalhos é bastante prejudicada, não conseguindo recuperar com exatidão as formas de onda dos distúrbios independentes.

### 5.2.1 Projeto do sistema

Assim como no método FICA, alguns parâmetros do método SCICA também devem ser pré-definidos, de forma a obter uma decomposição adequada do sinal de entrada. Estes parâmetros são: o número de sinais de observação ($M$) gerados a partir do sinal de entrada e fornecidos como entradas à ICA, o número de *clusters* ($C$) a serem encontrados pela etapa de agrupamento de componentes independentes associados a uma mesma fonte, e o comprimento dos vetores de energia ($R$) a serem fornecidos como entrada para o algoritmo de agrupamento *k-means*. A seguir, cada um desses parâmetros será brevemente descrito.

#### Número de sinais de observação ($M$)

Este parâmetro diz respeito à quantidade de sinais a serem fornecidos como entrada à ICA, gerados a partir do sinal de entrada $x[n]$. Como pode ser observado em (4.59), os filtros adaptativos, cujos coeficientes são obtidos por meio da aplicação da ICA nos $M$ sinais de observação, possuem comprimento também igual a $M$ amostras. Sendo assim, este parâmetro interfere na resposta em frequência desses filtros e, quanto maior o seu valor, mais seletivos na frequência os filtros serão.

Entretanto, como será visto em algumas simulações realizadas na Seção 5.3.2, na prática o aumento indiscriminado do valor deste parâmetro nem sempre resulta em melhores resultados de separação entre os distúrbios. Adianta-se que quanto maior o valor de $M$, maior será a complexidade computacional para o algoritmo *k-means* agrupar estimativas de componentes independentes associadas a uma mesma fonte, podendo o mesmo agrupar estimativas associadas a uma mesma fonte em *clusters* diferentes, ou agrupar estimativas associadas a fontes diferentes em um mesmo *cluster*. Não há uma regra para uma escolha exata de $M$, mas será visto que a escolha de $M = 12$ leva a resultados satisfatórios para a aplicação do método SCICA na decomposição dos sinais contendo múltiplos distúrbios analisados neste trabalho.

### Número de *clusters* ($C$)

Este parâmetro diz respeito ao número de sinais de saída a serem disponibilizados pelo método SCICA. Deve ser enfatizado que, no caso do método SCICA, diferentemente do método FICA, o número de sinais de saída não é necessariamente igual ao número de componentes independentes estimados pela ICA. No método SCICA, geralmente há mais estimativas de componentes independentes do que fontes, podendo haver múltiplas estimativas associadas a uma mesma fonte. Sendo assim, a etapa de agrupamento é necessária para agrupar essas estimativas e levar à obtenção de apenas uma estimativa resultante para cada *cluster*.

Idealmente, o número de *clusters* seria igual ao número de distúrbios independentes misturados no sinal de entrada. Se esse número for maior, estimativas associadas a um mesmo distúrbio podem ser sub-decompostas em mais de um sinal de saída, e se for menor, estimativas associadas a diferentes distúrbios podem se manter sobrepostas em um mesmo sinal de saída. Geralmente dois ou três *clusters* são suficientes para a maioria dos casos, sendo a probabilidade de mais de três distúrbios ocorrerem simultaneamente no sinal de entrada pequena.

### Comprimento dos vetores de energia ($R$)

Este parâmetro diz respeito ao número de faixas de frequência para representação das distribuições de energia de cada estimativa de componente independente, para efetuar a composição dos vetores de entrada do algoritmo de agrupamento *k-means*. Em função do valor de $R$, determina-se a largura de banda $L$ de cada faixa de frequência, lembrando que $L = \frac{f_S}{2R}$. Desta forma, é desejável que a escolha de $R$ seja suficiente para que as distribuições de energia sejam capazes de expressar as diferenças espectrais entre estimativas de componentes independentes associadas a fontes distintas, e também sejam capazes de expressar as similaridades espectrais entre estimativas associadas a uma mesma fonte.

Por exemplo, se $R$ for muito pequeno, então $L$ pode ser muito largo, e as composições espectrais de estimativas de fontes distintas podem não ser separadas em faixas de frequência distintas, o que pode levar ao agrupamento errôneo dessas estimativas dentro de um mesmo *cluster*. Por outro lado, se $R$ for muito elevado, então a dimensão dos vetores de entrada do algoritmo *k-means* pode ser também elevada, levando a um alto esforço computacional e a uma maior possibilidade de geração de resultados incorretos por parte deste algoritmo. Neste trabalho, utilizar-se-á $R = 16$ faixas de frequência, o que resulta em resultados satisfatórios

para a aplicação do método SCICA na decomposição dos sinais contendo múltiplos distúrbios analisados. Sendo que os dados analisados possuem frequência de amostragem $f_S = 15360$ Hz, isto resulta em $L = 480$ Hz.

## 5.3 Aplicação dos sistemas propostos na decomposição de sinais contendo múltiplos distúrbios de QEE

Nesta seção, os sistemas propostos serão aplicados na decomposição de diversos sinais, de forma a demonstrar seus desempenhos com relação à estimação de componentes primitivos do sinal do SEP (tensão ou corrente). Os sistemas serão avaliados utilizando-se dados sintéticos e dados reais.

### 5.3.1 Geração de dados sintéticos

Nesta seção, os sinais a serem fornecidos como entrada para os sistemas propostos nas seções 5.1 e 5.2 serão obtidos de forma sintética, com base nos modelos matemáticos apresentados em Trindade (2005). É importante mencionar que, neste caso, os componentes primitivos do sinal gerado são todos conhecidos *a priori*. Portanto, as estimativas fornecidas pelos sistemas propostos poderão ser diretamente comparadas às fontes originais. Os distúrbios isolados abordados neste trabalho pertencem a oito diferentes classes, sendo elas: sinal normal (sinal sem distúrbio), afundamento (*sag*), elevação (*swell*), interrupção, harmônicos, transitório impulsivo, transitório oscilatório e *notchings*. Os distúrbios múltiplos a serem abordados tratam-se de possíveis combinações entre os distúrbios acima. A geração de cada tipo de distúrbio considera as características intrínsecas de cada um destes distúrbios apontadas na literatura, tendo sido essas características revisadas no Capítulo 2, de acordo com Dugan *et al.* (2004); IEEE Std. 1159 (2009); ANEEL (2012).

Os sinais serão gerados a uma taxa de amostragem de 256 amostras por ciclo do componente fundamental. Com isso, considerando-se o sistema elétrico brasileiro, o qual opera com frequência igual a 60 Hz, a frequência de amostragem será igual a 15360 Hz. Será utilizada uma janela de dados com tamanho fixo de $N = 1024$ amostras, englobando portanto quatro ciclos do componente fundamental, sendo comum para todos os sinais gerados sinteticamente. Todos os sinais serão gerados no *software* Matlab. O ambiente considerado para o sistema de geração de dados analisado prevê uma relação sinal ruído (*Signal-to-Noise Ratio* (SNR)) de 60 dB, sendo

este dado considerado constante e comum a todos os distúrbios simulados.

Com o objetivo de se atingir um elevado índice de generalização no processo de decomposição e, posteriormente, no processo de classificação de distúrbios a ser proposto no Capítulo 6, as características de cada distúrbio serão escolhidas de forma aleatória dentro de intervalos pré-estabelecidos, conforme apontado em Trindade (2005). Dentro desses intervalos, será considerado que as características dos distúrbios apresentem distribuição uniforme, de maneira a evitar a geração de um maior número de sinais com alguma característica semelhante.

Tomando como base a modelagem apresentada na Seção 2.3, o sinal de tempo discreto $u[n]$ será considerado como sendo uma contribuição aditiva de diversos tipos de componentes primitivos. Repetindo aqui (2.1) por conveniência, tem-se:

$$u[n] = u(t)|_{t=nT_S} = f[n] + h[n] + i[n] + t[n] + \nu[n],$$

onde as sequências $\{f[n]\}$, $\{h[n]\}$, $\{i[n]\}$, $\{t[n]\}$, e $\{\nu[n]\}$ correspondem, respectivamente, ao componente fundamental, harmônicos, inter-harmônicos, transitórios e ruído de fundo. Neste trabalho, a geração sintética do fenômeno inter-harmônicos não será abordada. Portanto, o termo $i[n]$ será considerado nulo. Ainda segundo a modelagem apresentada na Seção 2.3, o termo $t[n]$ pode ser desmembrado nos termos $t_{\text{imp}}[n]$, $t_{\text{not}}[n]$, $t_{\text{osc}}[n]$ e $t_{\text{dec}}[n]$, os quais representam, respectivamente, transitório impulsivo, *notchings*, transitório oscilatório e decaimento exponencial. Neste trabalho, também não será abordada a geração sintética do decaimento exponencial. Desta forma, considerando-se as classes de distúrbios sintéticos a serem analisadas, (2.1) poderia ser reescrita da seguinte forma:

$$u[n] = u(t)|_{t=nT_S} = f[n] + h[n] + t_{\text{imp}}[n] + t_{\text{not}}[n] + t_{\text{osc}}[n] + \nu[n], \tag{5.7}$$

sendo que qualquer uma dessas parcelas pode estar ou não presente no sinal de entrada, e ao mesmo tempo pode contribuir para a formação do sinal $u[n]$.

A seguir é apresentada uma breve descrição a respeito da modelagem dos tipos de distúrbios a comporem o banco de dados sintéticos, tomando como referência Trindade (2005).

**Transitório oscilatório**

De maneira usual, os transitórios oscilatórios estão relacionados com o chaveamento de bancos de capacitores, e sua frequência de oscilação e seu tempo de duração dependem das características de impedância do SEP. A amplitude do distúrbio é função da amplitude do componente fundamental no momento em que ocorre o chaveamento, considerando-se que o banco de capacitores não possui carga inicial no momento em que é conectado ao sistema, e que não há variação instantânea na tensão dos capacitores. Sendo assim, pode-se observar que este fenômeno faz a tensão no sistema elétrico tender a zero rapidamente no momento do chaveamento e, em seguida, a mesma apresenta uma breve oscilação na sua forma de onda, seguida pela extinção do distúrbio.

Os distúrbios causados pelo chaveamento de capacitores, em um instante de tempo $n$, onde o valor da amplitude da tensão do componente fundamental é próximo de zero, serão descartados da análise proposta, já que nestes casos, os mesmos não causam grandes perturbações no sistema. Sendo assim, de acordo com Trindade (2005), serão considerados os distúrbios que ocorrem quando o valor do módulo da amplitude do sinal monitorado é superior a 45% do seu valor de pico. A fase de ocorrência do distúrbio será selecionada de maneira aleatória dentro dos intervalos de tempo em que esta condição é verdadeira, seguindo uma distribuição uniforme.

O componente oscilatório do distúrbio é modelado como uma senóide amortecida, que tem como amplitude inicial o valor do componente fundamental no momento em que se inicia o distúrbio. Uma constante de amortecimento é sorteada, seguindo uma distribuição uniforme, dentro de um intervalo de valores que proporcionam uma duração do distúrbio entre 5 e 10 ms. A frequência de oscilação do distúrbio também é definida de forma aleatória dentro de um intervalo de valores com distribuição uniforme que varia de 500 a 2500 Hz.

Assim, a modelagem do distúrbio transitório oscilatório pode ser resumida por:

$$t_{\text{osc}}[n] = f[n_0]\text{sen}(\omega_{\text{osc}}(n - n_0)T_S)e^{-\alpha_{\text{osc}}(n-n_0)T_S}, \tag{5.8}$$

onde: $f[n]$ é o valor da amplitude do componente fundamental para a amostra $n$, $\omega_{\text{osc}}$ é a frequência angular de oscilação do distúrbio, $\alpha_{\text{osc}}$ é a constante de amortecimento do distúrbio, e $n_0$ é a amostra em que ocorre o início do distúrbio.

A Figura 5.4(a) mostra um sinal de tensão sintético contendo um transitório oscilatório, ge-

rado de acordo com a modelagem apresentada. A Figura 5.4(b) mostra a parcela correspondente ao componente fundamental e a Figura 5.4(c) mostra a parcela correspondente ao componente primitivo do distúrbio.

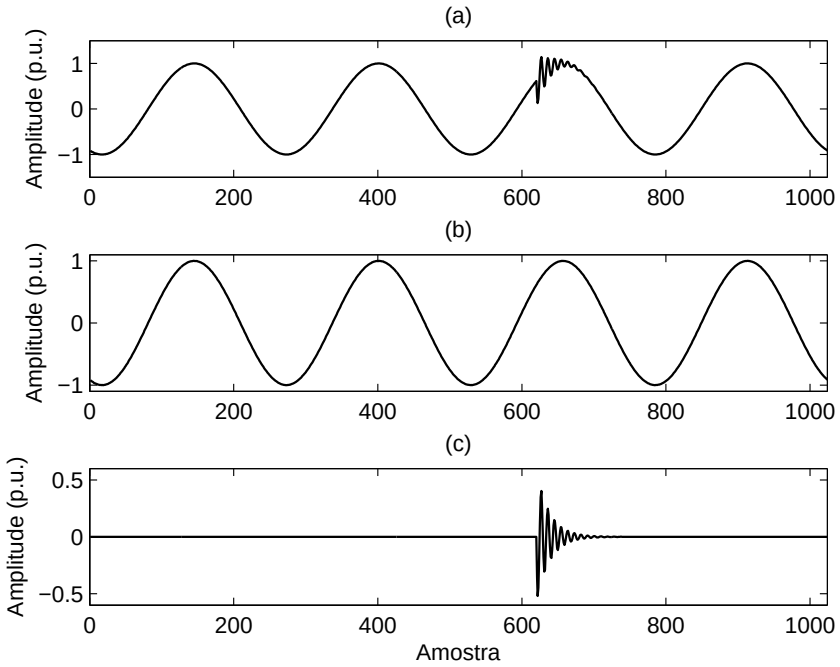


Figura 5.4: Sinal de tensão sintético modelando a ocorrência de transitório oscilatório; (a) sinal gerado, (b) componente fundamental e, (c) sinal de distúrbio.

### Transitório impulsivo

A modelagem adotada para este distúrbio considera que o mesmo ocorre apenas em instantes nos quais o módulo da amplitude do sinal seja superior a 60% do seu valor nominal, de maneira semelhante à adotada para a geração de transitórios oscilatórios. Também como na geração de transitórios oscilatórios, a amplitude do transitório impulsivo é função do valor da amplitude do componente fundamental no instante em que o distúrbio se inicia. Este valor é definido de forma empírica como sendo 60% do valor da amplitude do componente fundamental (Trindade, 2005).

A modelagem do distúrbio é feita de forma que haja uma elevação linear do módulo do valor da amplitude, distribuída em um intervalo de tempo considerado constante e igual a 0,26 ms, que corresponde a 4 amostras e, em seguida, uma redução também linear de mesma duração, que faz com que a amplitude do componente fundamental retorne ao seu valor nominal.

A Figura 5.5(a) mostra um sinal de tensão sintético contendo um transitório impulsivo, gerado de acordo com a modelagem apresentada. A Figura 5.5(b) mostra a parcela correspondente ao componente fundamental e a Figura 5.5(c) mostra a parcela correspondente ao componente primitivo do distúrbio.

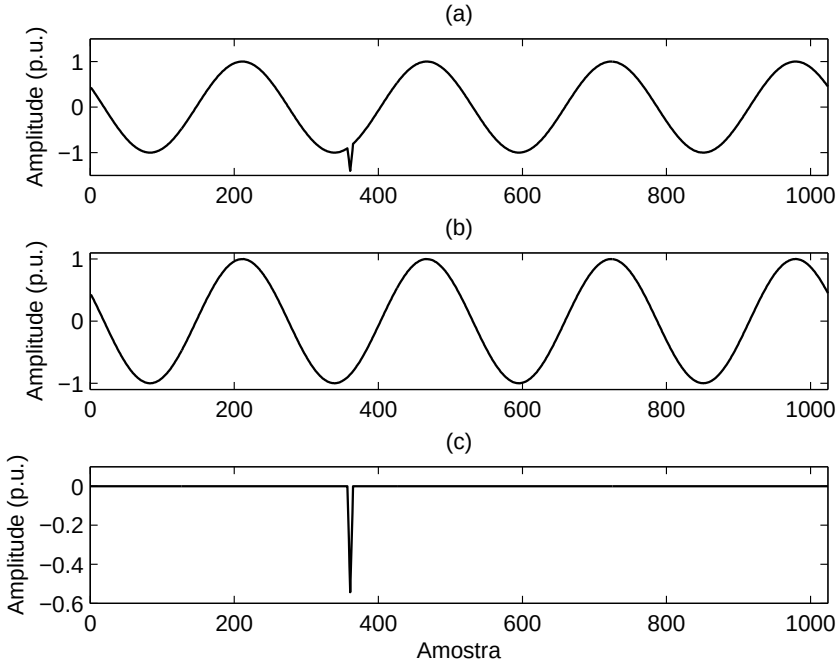


Figura 5.5: Sinal de tensão sintético modelando a ocorrência de transitório impulsivo; (a) sinal gerado, (b) componente fundamental e, (c) sinal de distúrbio.

### *Notchings*

A presença de *notchings* no SEP está relacionada com a operação normal de cargas eletrônicas chaveadas, como mencionado no Capítulo 2. A modelagem deste distúrbio é feita de forma semelhante à adotada para a geração dos transitórios oscilatórios. Os *notchings* são modelados como fenômenos oscilatórios de curta duração que ocorrem de maneira periódica no sistema elétrico. Mais uma vez, a amplitude do distúrbio depende da amplitude do componente fundamental. A duração de cada *notching* simulado é de 0,59 ms, que corresponde a 9 amostras do sinal gerado. Dentro desse intervalo de tempo, o distúrbio é modelado através de:

$$t_{\text{not}}[n] = -0,7f[n_0]\text{sen}(\omega_{\text{osc}}(n-n_0)T_S)e^{-\alpha_{\text{osc}}(n-n_0)T_S}. \tag{5.9}$$

O termo 0,7 em (5.9) tem a função de limitar a amplitude inicial do *notching* em 70% do valor

da amplitude do sinal do sistema no momento em que ocorre o distúrbio. O sinal negativo tem como objetivo fazer com que o início de cada *notching* sempre seja uma variação da tensão em direção a 0, já que cada *notching* ocorre devido ao curto-circuito momentâneo entre duas fases do sistema elétrico, o que tende sempre a diminuir momentaneamente o módulo da tensão entre as fases envolvidas. A frequência angular de oscilação $\omega_{\text{osc}}$ é correspondente a uma frequência de 3 kHz e é mantida fixa para todos os distúrbios gerados. A constante de amortecimento $\alpha_{\text{osc}}$ é definida de forma que cada *notching* ocorra em um período de tempo de 0,59 ms.

A amostra inicial do distúrbio ($n_0$) no caso dos *notchings* é dinamicamente alterada de forma a gerar um efeito periódico do distúrbio. Assim, pode-se definir o números de *notchings* por ciclo do componente fundamental do SEP. Neste trabalho, considerar-se-á sempre que ocorrem seis *notchings* por ciclo, que normalmente é resultante da operação de conversores trifásicos.

A Figura 5.6(a) mostra um sinal de tensão sintético contendo *notchings*, gerado de acordo com a modelagem apresentada. A Figura 5.6(b) mostra a parcela correspondente ao componente fundamental e a Figura 5.6(c) mostra a parcela correspondente ao componente primitivo do distúrbio.

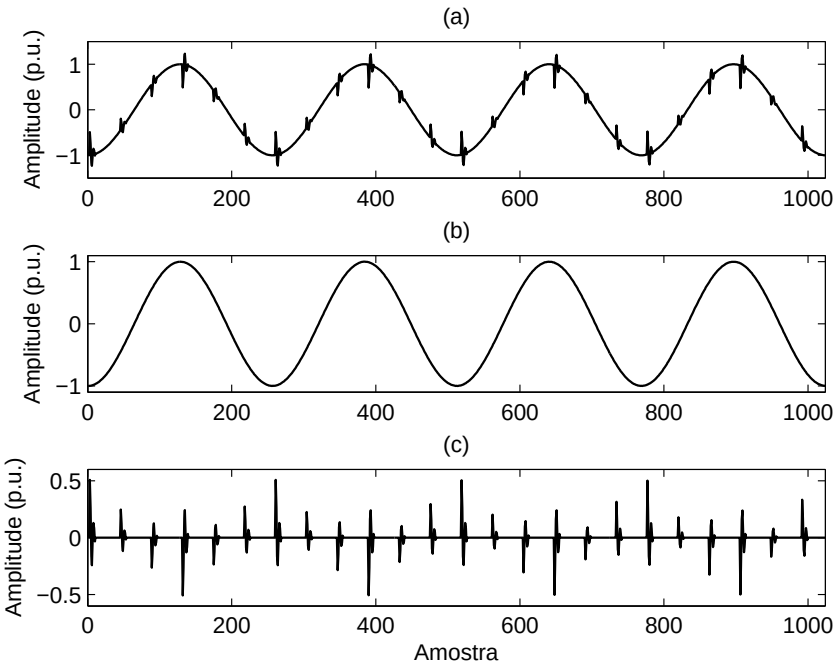


Figura 5.6: Sinal de tensão sintético modelando a ocorrência de *notchings*; (a) sinal gerado, (b) componente fundamental e, (c) sinal de distúrbio.

### Afundamento (*sag*), elevação (*swell*) e interrupção de tensão

Os distúrbios afundamento, elevação e interrupção de tensão são todos modelados de forma semelhante. Observando-se as características destes distúrbios apresentadas no Capítulo 2, foi definido que a variação da amplitude do componente fundamental pode ser de 10 a 90 % em relação ao seu valor nominal nos distúrbios de afundamento, de 110 a 180 % nas elevações e de 0 a 10 % nas interrupções. O valor da variação é, portanto, sorteado de maneira aleatória para cada distúrbio dentro dos intervalos acima, considerando que as distribuições estatísticas desses valores sejam uniformes dentro dos mesmos.

Neste trabalho, estes distúrbios são considerados como tendo duração entre meio ciclo e quatro ciclos, sendo quatro ciclos o tamanho total da janela de dados. Assim, a escolha da amostra do sinal onde se inicia o distúrbio é feita de maneira aleatória dentro dessa faixa, também considerando uma distribuição estatística uniforme. A transição do valor da amplitude nominal para o novo valor em virtude da ocorrência do distúrbio se dá de forma linear em um período considerado constante e igual a $\frac{1}{4}$ do período do componente fundamental, conforme (5.10).

$$\frac{\Delta V}{\Delta t} = \frac{\text{variação da amplitude}}{\frac{1}{4}\text{ do período fundamental}}. \tag{5.10}$$

A formação desses distúrbios é composta de apenas duas parcelas, sendo a primeira parcela referente ao ruído de fundo do sistema $\nu[n]$ e a segunda parcela referente ao componente fundamental $f[n]$, que tem sua amplitude alterada no momento em que ocorre o início do distúrbio. Um último ponto a ser considerado na geração desses distúrbios é que a fase em que eles ocorrem em relação ao componente fundamental é também escolhida de forma aleatória entre $-\pi$ e $\pi$, seguindo uma distribuição uniforme.

A Figura 5.7 mostra o resultado da geração dos três tipos de distúrbios de acordo com a modelagem apresentada. A Figura 5.7(a) mostra um sinal contendo afundamento de tensão, a Figura 5.7(b) mostra um sinal contendo elevação de tensão, e a Figura 5.7(c) mostra um sinal contendo interrupção de tensão.

### Harmônicos

A geração sintética de harmônicos neste trabalho se dá a partir da escolha, de forma aleatória, do valor da amplitude de cada componente harmônico ímpar desde o terceiro até o sétimo harmônico. Todas as amplitudes podem variar de maneira independente em um intervalo que vai

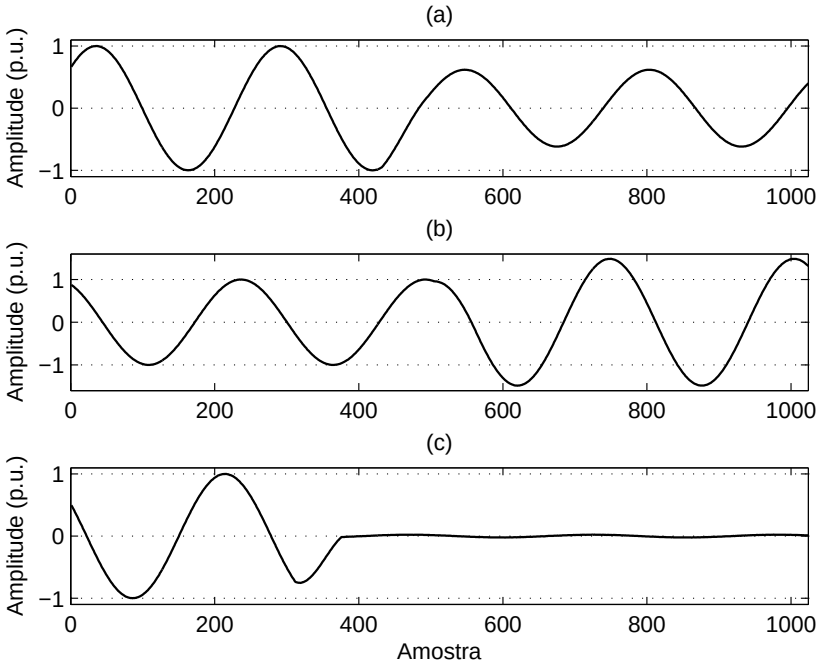


Figura 5.7: Sinais de tensão sintéticos modelando variações de tensão; (a) afundamento, (b) elevação e, (c) interrupção.

de 5 a 15% do valor do componente fundamental do sistema, sendo que este intervalo apresenta uma distribuição estatística uniforme. Além disso, a fase de cada componente harmônico é sorteada em um intervalo de $-\pi$ a $\pi$, também com distribuição uniforme. Em seguida, todos os componentes são adicionados simultaneamente para compor a forma de onda do distúrbio. Além das parcelas referentes aos componentes harmônicos e fundamental, soma-se também o ruído de fundo do sistema.

A Figura 5.8(a) mostra um sinal de tensão sintético contendo harmônicos, gerado de acordo com a modelagem apresentada. A Figura 5.8(b) mostra a parcela correspondente ao componente fundamental e a Figura 5.8(c) mostra a parcela correspondente ao componente primitivo do distúrbio.

### 5.3.2 Aplicação das metodologias de decomposição propostas em dados sintéticos

Ao gerar os sinais contendo os diferentes tipos de distúrbios de acordo com o procedimento descrito na Seção 5.3.1, obtém-se um grande volume de dados para cada tipo de distúrbio simulado.

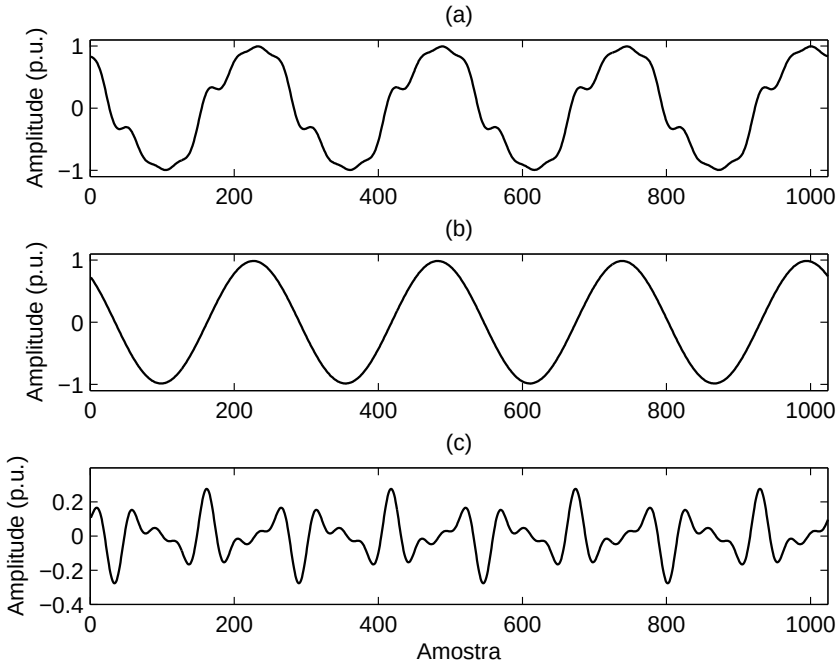


Figura 5.8: Sinal de tensão sintético modelando a ocorrência de harmônicos; (a) sinal gerado, (b) componente fundamental e, (c) sinal de distúrbio.

A seguir, serão apresentados os resultados e discussões a respeito da decomposição, pelos sistemas baseados nos métodos FICA e SCICA, de alguns sinais sintéticos modelando a ocorrência, de acordo com (2.1), de algumas combinações dos distúrbios individuais definidos anteriormente.

### *Notchings* e harmônicos

A Figura 5.9(a) mostra um sinal de tensão $u[n]$ com amplitude normalizada, o qual modela a ocorrência simultânea de harmônicos e de *notchings*. A Figura 5.9(b) mostra a estimativa do componente fundamental $f[n]$ fornecida pelo filtro *notch*, e a Figura 5.9(c) mostra o sinal de erro $x[n] = u[n] - f[n]$ resultante. Neste caso, o sinal $x[n]$ fornece a estimativa da soma dos componentes primitivos que caracterizam os harmônicos e os *notchings*.

A seguir, são mostrados os espectros de frequência do sinal $x[n]$ e dos distúrbios originais que compõem o sinal $u[n]$ (fontes $s_1[n]$ e $s_2[n]$), para que fique clara a influência das diferentes etapas dos métodos FICA e SCICA sobre as fontes. A Figura 5.10(a) mostra o espectro dos *notchings*, a Figura 5.10(b) mostra o espectro dos harmônicos, e a Figura 5.10(c) mostra o espectro de $x[n]$. Através da figura, pode ser observado que os *notchings* possuem energia espalhada por toda a faixa de frequências, enquanto que os harmônicos possuem energia limitada

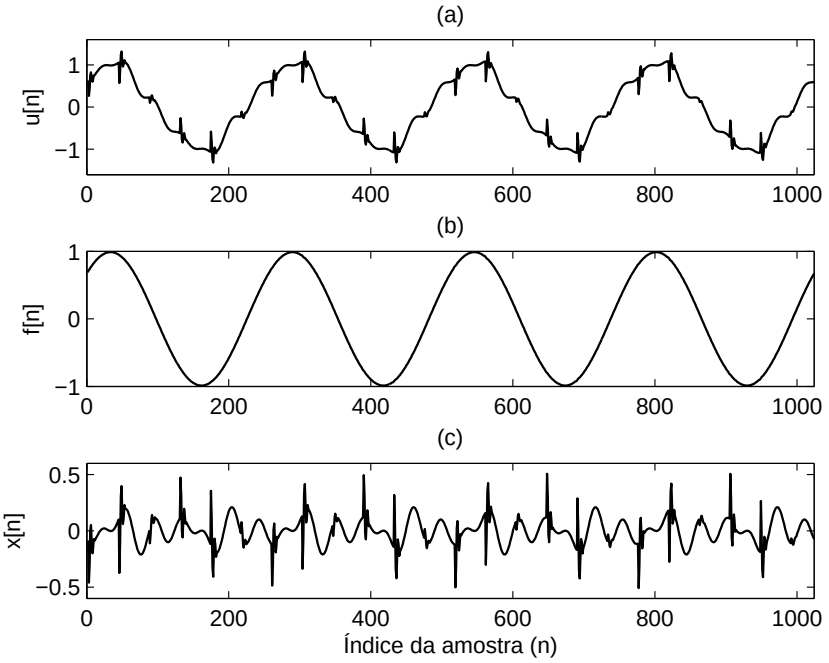


Figura 5.9: Sinal de tensão sintético modelando a ocorrência simultânea de harmônicos e *notchings*; (a) Sinal de tensão monitorado $u[n]$, (b) Estimativa do componente fundamental $f[n]$ e, (c) sinal de erro $x[n] = u[n] - f[n]$.

até a frequência de 420 Hz. Como pode ser observado no espectro do sinal $x[n]$, este compreende a combinação dos espectros de ambas as fontes, sendo que há uma pequena sobreposição entre suas energias. Entretanto, de certa forma, pode-se dizer que os dois distúrbios praticamente não possuem sobreposição espectral, já que os espectros de ambos podem ser bem reconhecidos na Figura 5.10(c). Deve ser lembrado que o desenvolvimento da teoria descritiva tanto do método FICA quanto do método SCICA, apresentada no Capítulo 4, assume que as fontes não possuem sobreposição espectral.

A seguir, serão apresentados os resultados e discussões a respeito da decomposição do sinal $x[n]$ utilizando-se, respectivamente, o método FICA e o método SCICA.

*Decomposição do sinal $x[n]$ utilizando o método FICA:*

Conforme pode ser revisto na Figura 4.4, o primeiro passo é submeter o sinal $x[n]$ ao banco de filtros fixos, de forma a gerar os sinais de observação a serem fornecidos para a ICA. Sendo que há dois componentes primitivos restantes em $x[n]$, será utilizado um banco de filtros com $M = 2$ filtros. Conforme explicado na Seção 4.2.1, o filtro $h_1[n]$ deve ser do tipo passa-todas. O

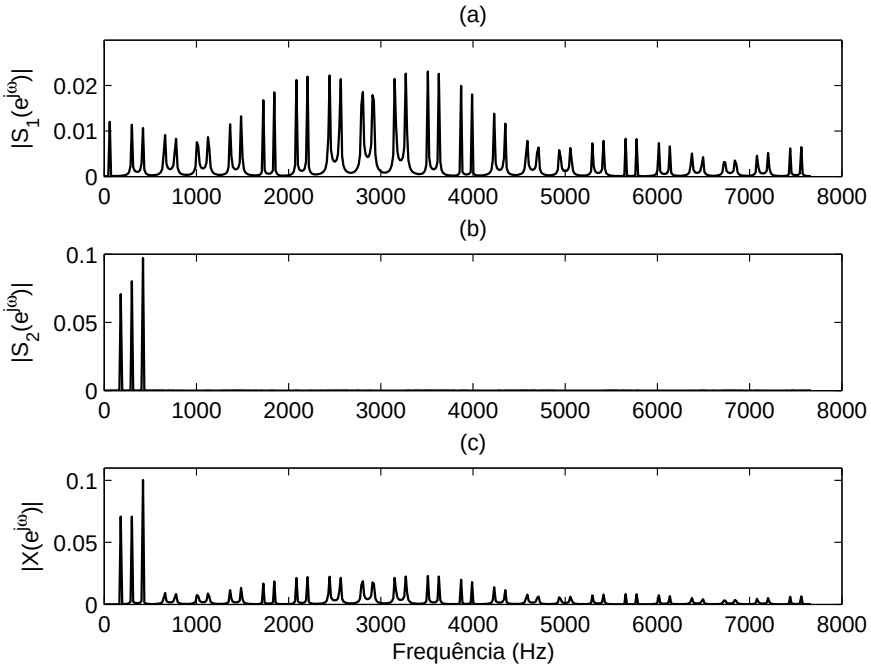


Figura 5.10: Espectros de frequências dos distúrbios originais e do sinal $x[n]$; (a) *notchings* - fonte $s_1[n]$, (b) harmônicos - fonte $s_2[n]$ e, (c) sinal de erro - mistura $x[n]$.

filtro $h_2[n]$ será do tipo passa-altas. Ambos os filtros possuirão ordem $K = 20$. Desta forma, os sinais de saída destes filtros apresentarão um atraso comum de 10 amostras quando comparados a $x[n]$. A frequência de corte adotada para o filtro passa-altas será $f_C = 300$ Hz.

A Figura 5.11 mostra os ganhos destes filtros (eixo vertical esquerdo), juntamente com o espectro de frequências de $x[n]$ (eixo vertical direito). Como pode ser observado, tais filtros apresentam respostas em frequência capazes de fornecer sinais de observação linearmente independentes ao algoritmo que vai calcular a ICA. Em outras palavras, tais filtros estão aplicando pesos linearmente independentes nas fontes, dando condições para que a matriz de mistura a ser estimada pela ICA seja invertível. Além disso, pode-se dizer que ambos os filtros estão aplicando pesos *aproximadamente* constantes em cada componente primitivo, dando assim condições para que a aproximação dada por (4.37) possa vir a ser satisfatoriamente alcançada. Como visto, o filtro $h_1[n]$ aplica ganhos unitários em ambos os componentes, e o filtro $h_2[n]$ aplica ganho entre 0,6 e 0,7 nos harmônicos e ganho unitário nas principais frequências dos *notchings*. Evidentemente, observa-se que informações de ambos os distúrbios se manterão presentes nas saídas de ambos os filtros. Reforça-se que o objetivo principal da aplicação destes filtros não é separar as fontes, o qual é o objetivo da aplicação da ICA.

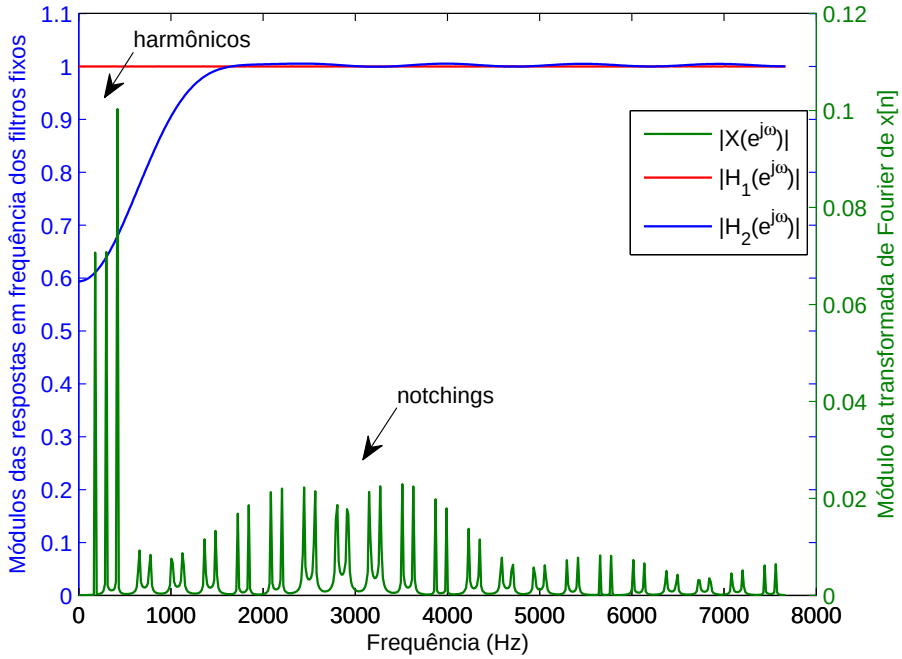


Figura 5.11: Módulos das respostas em frequência dos filtros $h_1[n]$ e $h_2[n]$, e espectro de frequências do sinal $x[n]$: *notchings* e harmônicos.

Observando-se novamente a Figura 4.4, o próximo passo é fornecer os sinais $x_1[n]$ e $x_2[n]$ ao algoritmo que calcula a ICA, que no caso deste trabalho, é o FastICA. É importante lembrar que os únicos dados fornecidos ao algoritmo FastICA são esses sinais de observação. Portanto, não há informação disponível ao algoritmo a respeito das fontes e nem de como elas se encontram misturadas. A ICA estima uma matriz de separação $\mathbf{W}$, que é utilizada para obter as estimativas de componentes independentes $y_1[n]$ e $y_2[n]$ a partir das observações $x_1[n]$ e $x_2[n]$.

Em seguida, fornece-se os sinais $x_1[n]$, $y_1[n]$ e $y_2[n]$ ao combinador linear adaptativo, para a obtenção dos sinais $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_2}[n]$. Os valores escolhidos para a taxa de aprendizagem e para a precisão requerida para o critério de parada do algoritmo LMS são, respectivamente, $\eta = 0,01$ e $\varepsilon = 1,0 \times 10^{-7}$. A convergência do algoritmo LMS foi alcançada em apenas duas épocas de treinamento. Ressalta-se de antemão que os valores escolhidos para os parâmetros do algoritmo LMS apresentados acima serão os mesmos para todas as demais aplicações neste trabalho, tendo sido visto que com tais valores são sempre obtidos resultados satisfatórios.

A Figura 5.12 mostra os sinais $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_2}[n]$ obtidos, comparados às formas de onda originais dos componentes primitivos, $s_1[n]$ e $s_2[n]$. Como pode ser visto, o método FICA, aplicado ao sinal $x[n]$, obteve estimativas que se aproximaram muito bem das formas de onda

originais dos distúrbios. O pequeno atraso observado nos sinais $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_2}[n]$ em relação às formas de onda originais dos distúrbios foi provocado pelo banco de filtros fixos (atraso de $\frac{K}{2} = 10$ amostras).

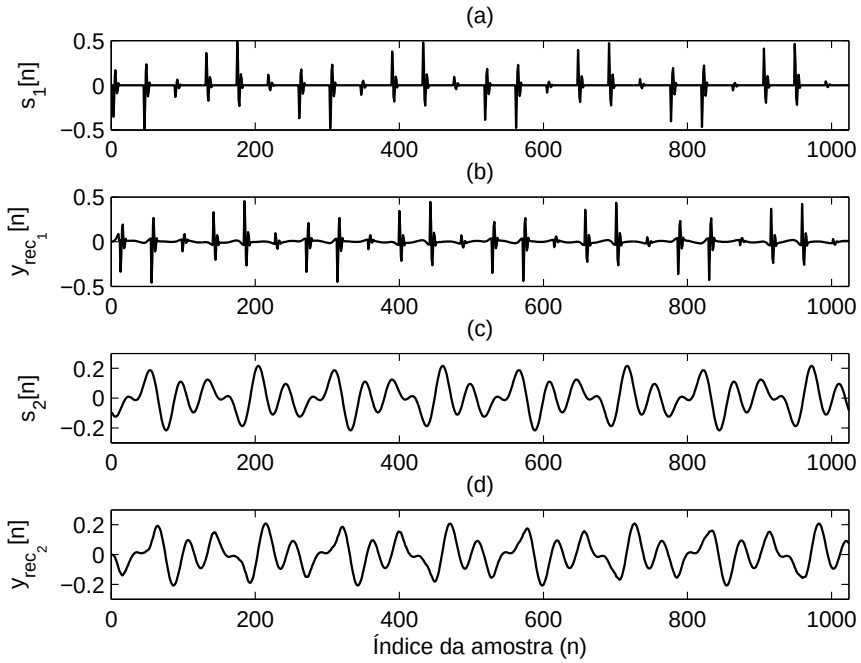


Figura 5.12: Estimativas de componentes independentes obtidas pelo método FICA; (a) *notchings* originais, (b) $y_{\text{rec}_1}[n]$, (c) harmônicos originais e, (d) $y_{\text{rec}_2}[n]$.

Adaptando-se (4.34) para o caso deste exemplo, ou seja, para $M = 2$, $P = 2$ e $K = 20$, tal equação expressa a relação entre as saídas $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_2}[n]$ e o sinal de entrada $x[n]$. Tal equação mostra que $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_2}[n]$ são obtidos por meio da filtragem de $x[n]$ utilizando-se filtros cujos coeficientes são determinados pelo produto das três primeiras matrizes do lado direito da igualdade, sendo que a primeira matriz contém os pesos do combinador linear adaptativo, a segunda matriz contém os pesos obtidos pela ICA e a terceira matriz contém os coeficientes dos filtros fixos $h_1[n]$ e $h_2[n]$. Os filtros resultantes de tal produto serão adaptativos, cujos coeficientes são expressos pela matriz em (4.35), onde cada linha representa os coeficientes de um diferente filtro.

Chamando-se de $f_1[n]$ e $f_2[n]$ esses filtros adaptativos, a Figura 5.13 mostra os módulos de suas respostas em frequência (eixo vertical esquerdo), juntamente com o espectro de frequências de $x[n]$ (eixo vertical direito). Como pode ser observado, o filtro $f_1[n]$, responsável por obter $y_{\text{rec}_1}[n]$ por meio da sua convolução com $x[n]$ (veja a Eq. (4.36) e a Figura 4.6), atenua as frequências dos harmônicos e passa com ganhos em torno de 1 a maior parte do espectro dos

*notchings*. Por outro lado, o filtro $f_2[n]$, responsável por obter $y_{\text{rec}_2}[n]$ a partir da sua convolução com $x[n]$, passa as frequências dos harmônicos com ganhos em torno de 1 e atenua fortemente as frequências mais importantes dos *notchings*. Tais resultados estão de acordo com aqueles encontrados nas Figuras 5.12(b) e (d).

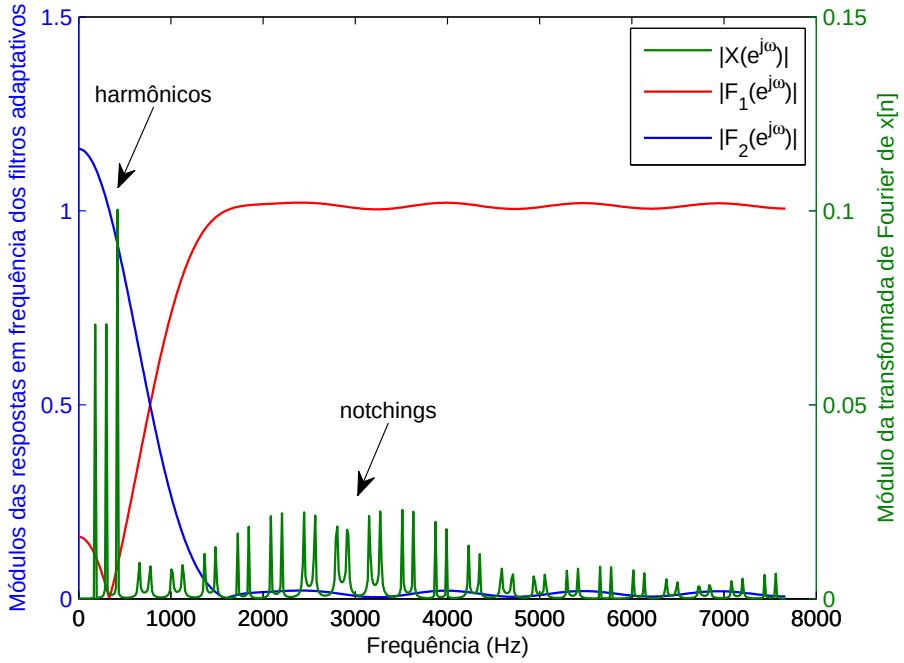


Figura 5.13: Módulos das respostas em frequência dos filtros adaptativos resultantes da operação do método FICA, e espectro de frequências do sinal $x[n]$: *notchings* e harmônicos.

A seguir, será realizada uma análise dos efeitos da variação da frequência de corte do filtro fixo $h_2[n]$ e da ordem dos filtros $h_1[n]$ e $h_2[n]$, nos resultados da decomposição do sinal $x[n]$ alcançados pelo método FICA. Para tanto, inicialmente serão calculados os coeficientes de correlação linear de Pearson (Papoulis e Pillai, 2002) entre as formas de onda dos distúrbios originais e as estimativas de componentes independentes encontradas, para cada valor de frequência de corte de $h_2[n]$ dentro de uma determinada faixa, mantendo-se a ordem dos filtros constante. Em seguida, serão calculados os coeficientes de correlação, também entre as formas de onda dos distúrbios originais e as estimativas de componentes independentes encontradas, porém desta vez variando-se a ordem dos filtros e mantendo-se a frequência de corte de $h_2[n]$ constante. Valores de coeficiente de correlação ($\rho$) próximos de 1 indicam que os componentes estimados são fortemente correlacionados aos componentes originais, e valores próximos de 0 indicam correlações fracas entre os componentes estimados e os originais.

Na Figura 5.14 são mostrados os resultados da aplicação do método FICA ao sinal $x[n]$ da

Figura 5.9(c). Para o experimento cujo resultado é mostrado na Figura 5.14(a), a frequência de corte $f_{C2}$ de $h_2[n]$ foi variada desde 100 até 4000 Hz em passos de 50 Hz, sendo tal filtro sempre um passa-altas com ordem $K = 20$. Para cada valor de frequência de corte de $h_2[n]$, o método FICA foi executado, e em seguida foram calculados os coeficientes de correlação entre as estimativas de componentes independentes encontradas e as formas de onda dos distúrbios originais.

Para o experimento cujo resultado é mostrado na Figura 5.14(b), a ordem dos filtros $h_1[n]$ e $h_2[n]$ foi variada desde 10 até 100 em passos de 2, mantendo-se a frequência de corte $f_{C2}$ de $h_2[n]$ sempre igual a 300 Hz. Para cada valor de ordem dos filtros, o método FICA foi executado, sendo calculados os coeficientes de correlação entre as estimativas de componentes independentes obtidas e as formas de onda dos distúrbios originais.

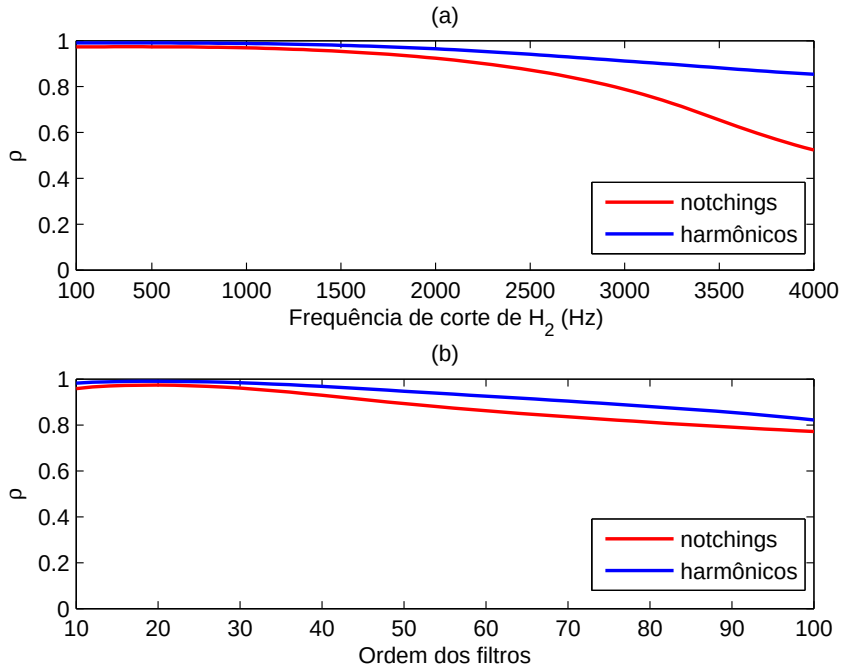


Figura 5.14: Coeficiente de correlação entre os distúrbios originais e suas estimativas, em função: (a) da frequência de corte de $h_2[n]$ e, (b) da ordem dos filtros, para o sinal contendo *notchings* e harmônicos.

Como pode ser observado na Figura 5.14(a), para as simulações entre $f_{C2} = 100$ Hz e $f_{C2} = 1000$ Hz, os valores de $\rho$ para as estimativas de ambos os distúrbios se mantiveram próximos de 1 e praticamente não se alteraram. Portanto, qualquer valor de $f_{C2}$ escolhido dentro desta faixa de frequências praticamente não alteraria o desempenho do método FICA com relação à obtenção de componentes que estimem bem as formas de onda dos distúrbios

individuais que se encontram misturados em $x[n]$. Cabe lembrar que as estimativas mostradas na Figura 5.12 foram obtidas para $f_{C2} = 300$ Hz.

À medida que $f_{C2}$ aumenta, o desempenho do método FICA vai diminuindo crescentemente. Isto ocorre porque, como pode ser observado na Figura 5.11, o filtro $h_2[n]$ irá rejeitar cada vez mais informações espectrais de ambos os distúrbios à medida que $f_{C2}$ for aumentando. Portanto, a mistura correspondente $x_2[n]$ carregará cada vez menos informação suficiente a respeito dos distúrbios envolvidos, de tal forma que a ICA será cada vez menos capaz de estimar uma matriz de separação $\mathbf{W}$ que separe os distúrbios mutuamente a partir dos sinais $x_1[n]$ e $x_2[n]$.

Já a partir do resultado mostrado na Figura 5.14(b), observa-se que para valores de ordem dos filtros situados entre $K = 10$ e $K = 30$, o desempenho da separação promovida pelo método FICA se mostrou excelente, sendo o melhor resultado alcançado para valores de $K$ em torno de 20, sendo justamente este o valor da ordem utilizada para a obtenção das estimativas mostradas na Figura 5.12. À medida que $K$ aumenta, a qualidade da separação entre os distúrbios vai diminuindo gradativamente, mas percebe-se que este parâmetro influencia menos os resultados do que a frequência de corte de $h_2[n]$. O aumento de $K$ resulta em filtros com um número maior de coeficientes, o que leva à diminuição da faixa de transição entre a faixa de bloqueio/atenuação e a faixa de passagem de $h_2[n]$ (passa-altas), ou seja, leva a faixas de transição mais abruptas. Inevitavelmente, este efeito pode resultar em filtros que cumpram cada vez menos as condições de separabilidade do método FICA, especialmente aquela que diz que os filtros fixos devem aplicar pesos aproximadamente constantes em cada fonte.

A Figura 5.15 mostra o resultado da decomposição pelo método FICA do sinal $x[n]$ da Figura 5.9(c), desta vez utilizando-se $M = 3$ filtros na etapa de geração dos sinais de observação. Desta forma, tem-se um número maior de filtros do que de fontes. Os dois primeiros filtros, $h_1[n]$ e $h_2[n]$, são os mesmos utilizados anteriormente, e o filtro $h_3[n]$ é um passa-baixas com $f_{C3} = 1000$ Hz, também com ordem $K = 20$. Como pode ser observado, os sinais $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_3}[n]$ são estimativas que expressam de maneira bem exclusiva os *notchings* e os harmônicos, respectivamente. Já o sinal $y_{\text{rec}_2}[n]$ é uma estimativa muito distorcida, que contém informações misturadas de ambos os distúrbios, não sendo, portanto, uma boa representação de nenhum deles isoladamente.

A seguir, será mostrada a decomposição do sinal $x[n]$ da Figura 5.9(c), desta vez utilizando o método SCICA.

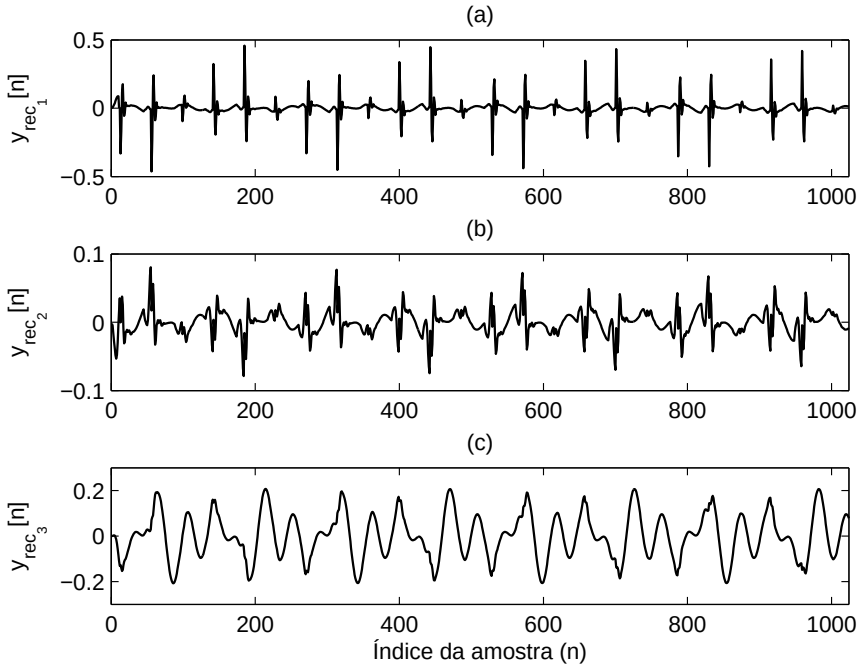


Figura 5.15: Estimativas de componentes independentes obtidas pelo método FICA, quando utilizados $M = 3$ filtros; (a) $y_{\mathrm{rec}_1}[n]$, (b) $y_{\mathrm{rec}_2}[n]$ e, (c) $y_{\mathrm{rec}_3}[n]$.

*Decomposição do sinal $x[n]$ utilizando o método SCICA:*

O primeiro passo do método SCICA, como pode ser revisto na Figura 4.22, é construir a matriz de sinais de observação $\mathbf{X}$. No caso deste exemplo, adotou-se: $M = 12$ sinais de observação e $\tau = 1$ amostra de atraso. O próximo passo é aplicar o algoritmo FastICA à matriz $\mathbf{X}$, de forma a estimar as matrizes de separação $\mathbf{W}$ e de mistura $\mathbf{A}$. Em seguida, tais matrizes são aplicadas em (4.59), para obter as estimativas dos componentes independentes a partir de $x[n]$. As estimativas obtidas são mostradas na Figura 5.16. Cada estimativa de componente independente é uma versão filtrada de $x[n]$, sendo que há múltiplas estimativas associadas a cada um dos distúrbios.

Com referência novamente à Figura 4.22, o próximo passo é fornecer as estimativas de componentes independentes encontradas, como entradas, à etapa de agrupamento. Tal etapa deve automaticamente identificar as estimativas associadas a uma mesma fonte e agrupá-las dentro de um mesmo *cluster*. Como há dois distúrbios, adotou-se $C = 2$ *clusters* a serem estimados pelo algoritmo *k-means*. Para o cálculo dos vetores de energias a serem fornecidos como entrada para o algoritmo *k-means*, adotou-se $R = 16$ faixas de frequência, o que proporciona uma largura de banda $L = 480$ Hz para cada faixa de frequência, lembrando-se que a frequência de amostragem

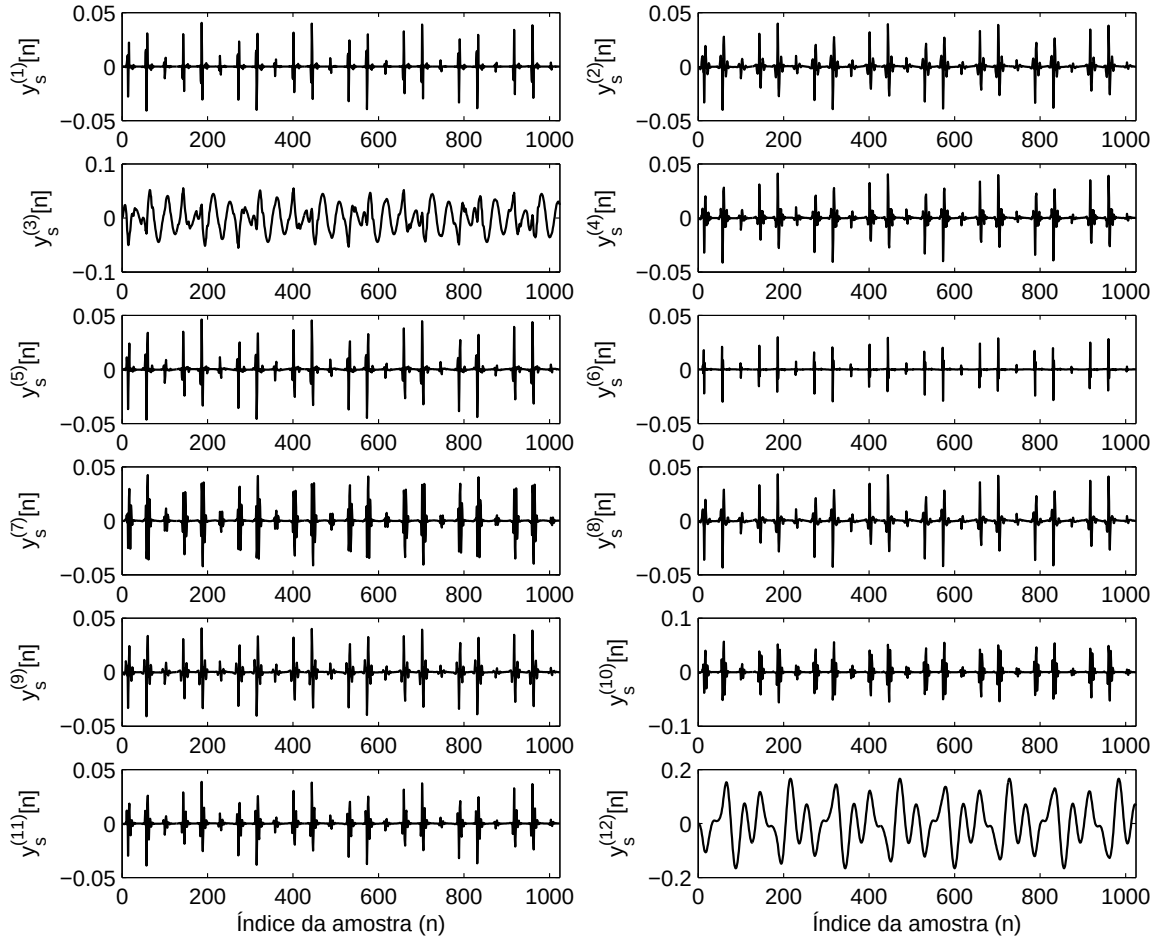


Figura 5.16: Estimativas de componentes independentes com escalas recuperadas: *notchings* e harmônicos.

adotada para a geração dos sinais sintéticos é $f_S = 15360$ Hz. A Figura 5.17 mostra a distribuição dos valores de energia para cada componente $y_s^{(p)}[n]$ ao longo das 16 faixas de frequência, sendo tais valores armazenados no vetor correspondente $\mathbf{EY}_s^{(p)}$.

A Figura 5.17 também mostra o resultado do agrupamento de cada vetor de energia dentro dos *clusters* $\gamma_1$ ou $\gamma_2$, realizado pelo algoritmo *k-means*. O resultado revela que os vetores 1, 2, 4, 5, 6, 7, 8, 9, 10 e 11 foram todos agrupados dentro do *cluster* $\gamma_1$, e os vetores 3 e 12 foram agrupados dentro do *cluster* $\gamma_2$. De fato, voltando-se à análise da Figura 5.16, observa-se que os componentes independentes 1, 2, 4, 5, 6, 7, 8, 9, 10 e 11 são mais associados aos *notchings*, e os componentes 3 e 12 são mais associados aos harmônicos. Sendo assim, cada *cluster* engloba os componentes pertencentes a um diferente sub-espaço independente, cada qual dentro de uma

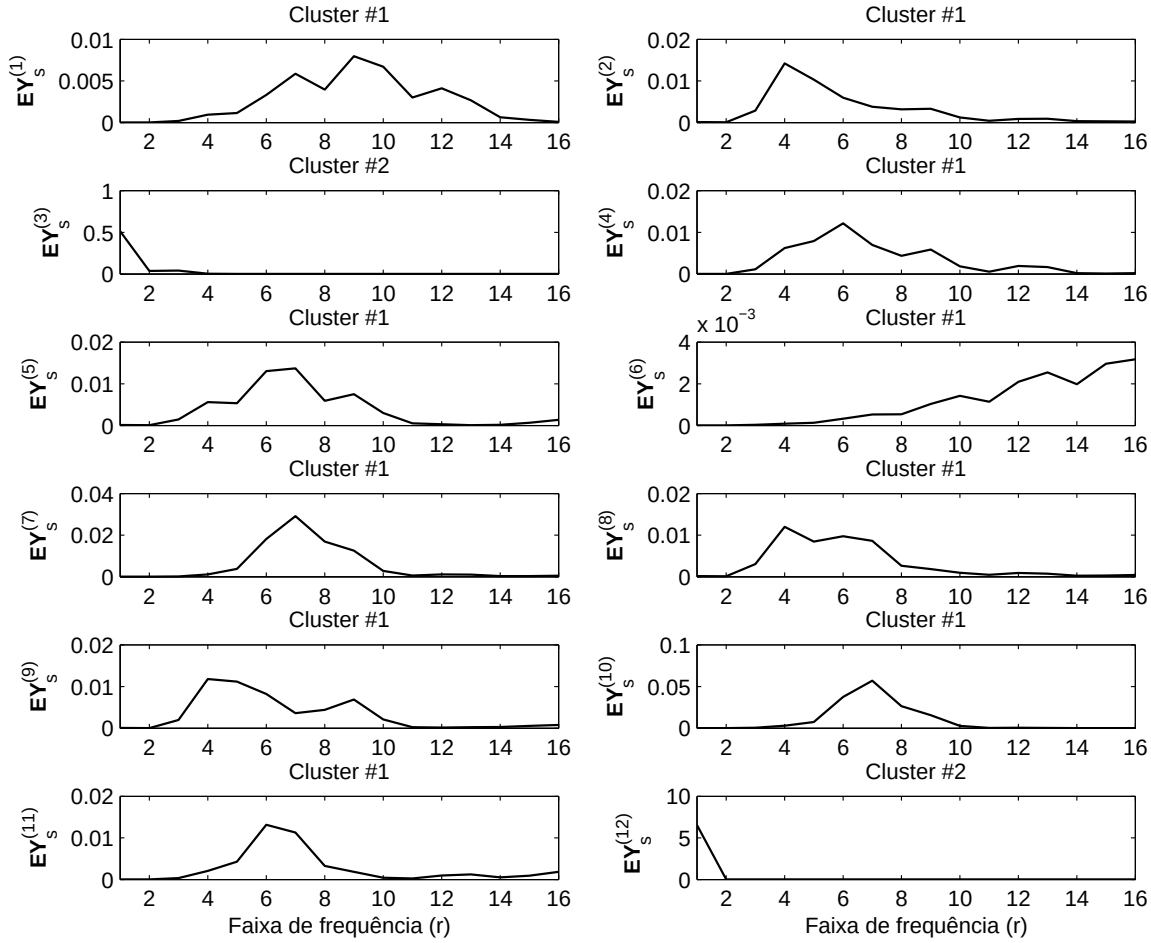


Figura 5.17: Vetores de energias calculados para as estimativas de componentes independentes, com o respectivo agrupamento pelo algoritmo *k-means* baseado em suas similaridades espectrais: *notchings* e harmônicos.

diferente faixa de frequências do sinal de entrada $x[n]$. O primeiro sub-espaço possui dimensão 10, e o segundo subespaço possui dimensão 2. A dimensão de cada sub-espaço é função da largura de banda de cada fonte independente. Como os *notchings* possuem banda de frequências mais ampla do que os harmônicos, o sub-espaço associado a eles possui dimensão maior.

O próximo passo, como pode ser revisto novamente na Figura 4.22, é somar todos os componentes independentes associados ao *cluster* $\gamma_1$, para se obter $y_{\text{rec}_1}[n]$, e somar todos os componentes independentes associados ao *cluster* $\gamma_2$, para se obter $y_{\text{rec}_2}[n]$. Os sinais obtidos através desta operação de reconstrução são mostrados na Figura 5.18, sendo comparados às formas de onda originais dos distúrbios, $s_1[n]$ e $s_2[n]$. O atraso observado em cada estimativa quando comparada à sua respectiva fonte é igual a $M - 1 = 11$ amostras, provocado pela inserção de

$M\tau - 1$ zeros durante o processo de construção da matriz de observações $\mathbf{X}$.

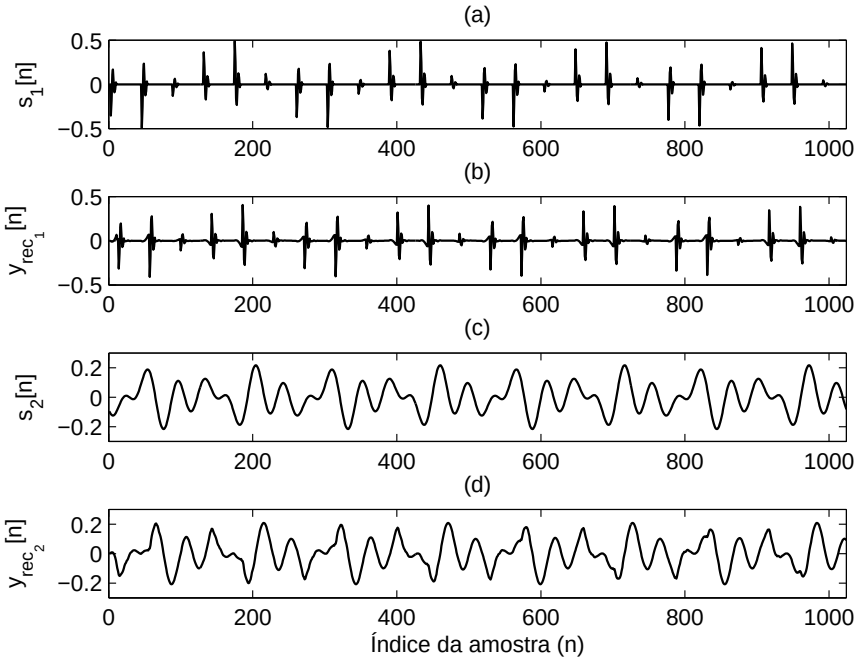


Figura 5.18: Componentes separados e reconstruídos utilizando-se o método SCICA; (a) *notchings* originais, (b) $y_{\text{rec}_1}[n]$, (c) harmônicos originais e, (d) $y_{\text{rec}_2}[n]$.

De forma equivalente, os componentes $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_2}[n]$ também poderiam ser encontrados por meio da operação de filtragem do sinal de entrada $x[n]$ utilizando-se os filtros adaptativos $f_1[n]$ e $f_2[n]$, obtidos através de (4.69). A Figura 5.19 mostra os módulos das respostas em frequência dos filtros $f_1[n]$ e $f_2[n]$ obtidos, juntamente com o espectro de frequências de $x[n]$. Pode ser observado que o filtro $f_1[n]$, responsável por obter $y_{\text{rec}_1}[n]$ por meio da filtragem de $x[n]$, atenua fortemente os harmônicos e passa com ganhos em torno de 1 as principais frequências dos *notchings*. Por outro lado, o filtro $f_2[n]$, responsável por obter $y_{\text{rec}_2}[n]$ por meio da filtragem de $x[n]$, atenua fortemente as principais frequências dos *notchings* e passa com ganhos próximos de 1 as frequências dos harmônicos. Tais resultados estão de acordo com aqueles mostrados na Figura 5.18. A partir dos resultados obtidos, fica claro que o método SCICA separou de maneira totalmente adaptativa e cega (não-supervisionada) os distúrbios presentes simultaneamente no sinal $x[n]$.

A próxima análise mostra o efeito da variação do número de sinais de observação $M$ a serem fornecidos como entrada à ICA. Para tanto, a Figura 5.20 mostra os coeficientes de correlação calculados entre os distúrbios originais e suas respectivas estimativas obtidas pelo método SCICA. Para cada valor de $M$, o método SCICA foi executado novamente, mantendo-

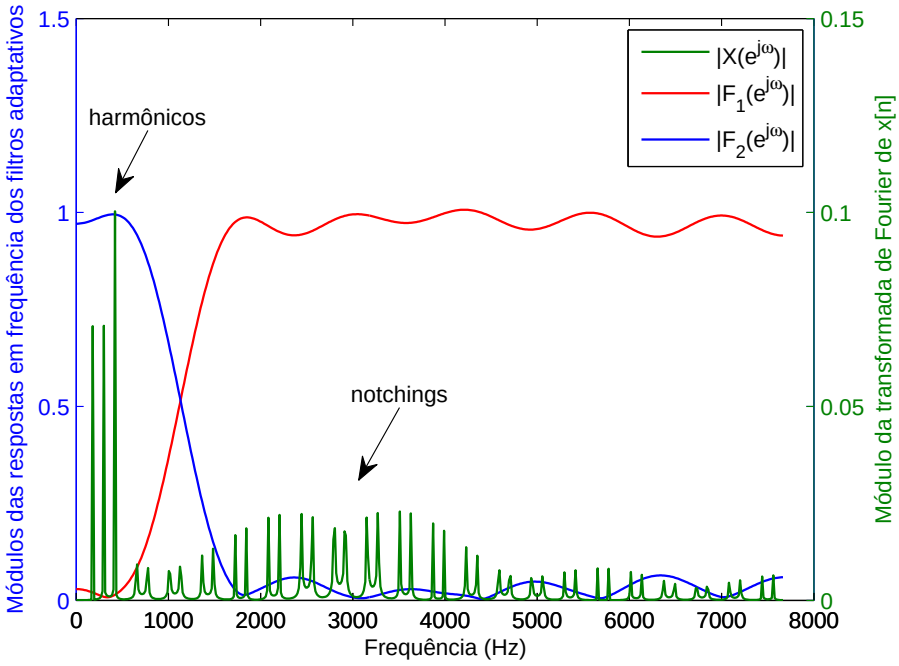


Figura 5.19: Módulos das respostas em frequência dos filtros adaptativos resultantes da operação do método SCICA, e espectro de frequências do sinal $x[n]$: *notchings* e harmônicos.

se os demais parâmetros inalterados.

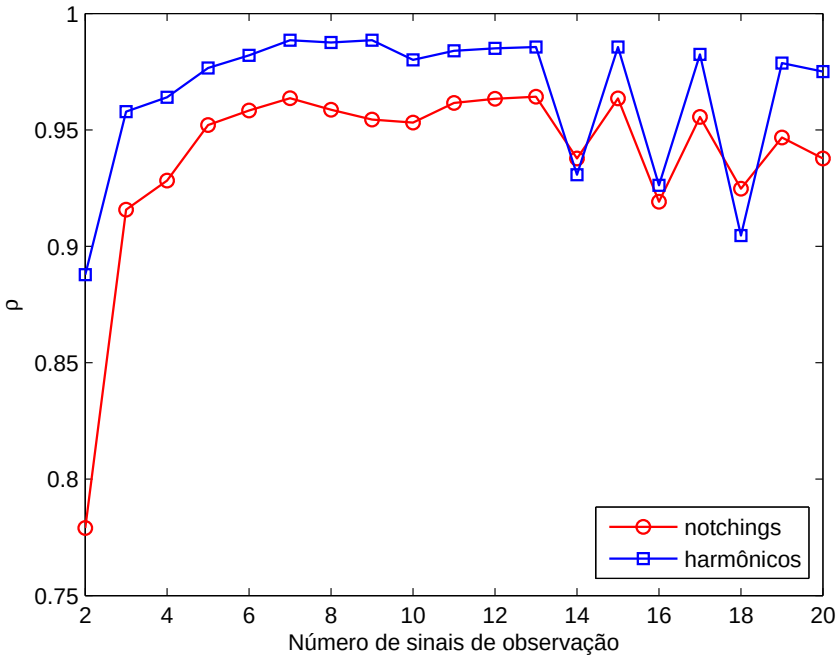


Figura 5.20: Coeficiente de correlação entre os distúrbios originais e suas estimativas, em função do número de sinais de observação $M$ gerados pelo método SCICA: *notchings* e harmônicos.

Como pode ser observado, à medida que se aumenta $M$, a qualidade das estimativas obtidas pelo método SCICA também aumenta, e se mantém praticamente uniforme para $M = 7$ até $M = 13$. Deve ser lembrado que para a decomposição realizada anteriormente, foi utilizado $M = 12$. O valor de $M$ determina o comprimento dos filtros adaptativos obtidos pelo método SCICA, portanto, teoricamente, quanto maior o seu valor, mais seletivos deveriam ser esses filtros. Entretanto, observa-se que a partir de $M = 14$, passa a ocorrer uma instabilidade na qualidade das estimativas obtidas. Este fenômeno é causado tanto pela possibilidade do algoritmo FastICA começar a obter estimativas de componentes independentes distorcidas quando se aumenta muito o valor de $M$, quanto pela possibilidade do algoritmo *k-means* começar a agrupar erroneamente os componentes independentes que teoricamente deveriam ser associados a um determinado sub-espaço independente. Portanto, observa-se que aumentar indiscriminadamente o valor de $M$ necessariamente não resultaria em melhores resultados de separação dos distúrbios.

A próxima análise mostra o resultado obtido para a decomposição do sinal $x[n]$ quando definidos $C = 3$ *clusters* a serem estimados pelo algoritmo *k-means*, mantendo-se $M = 12$ e $\tau = 1$. A Figura 5.21 mostra as estimativas obtidas pelo método SCICA para este caso, na qual observa-se que a estimativa $y_{\text{rec}_1}[n]$ é relacionada aos harmônicos, e as estimativas $y_{\text{rec}_2}[n]$ e $y_{\text{rec}_3}[n]$ são ambas relacionadas aos *notchings*.

Para esta simulação, os vetores de energia da Figura 5.17 foram automaticamente reagrupados pelo algoritmo *k-means* dentro dos três *clusters* mostrados abaixo:

$$\gamma_1 = \{\mathbf{EY}_s^{(3)}, \mathbf{EY}_s^{(12)}\},$$

$$\gamma_2 = \{\mathbf{EY}_s^{(1)}, \mathbf{EY}_s^{(6)}\},$$

$$\gamma_3 = \{\mathbf{EY}_s^{(2)}, \mathbf{EY}_s^{(4)}, \mathbf{EY}_s^{(5)}, \mathbf{EY}_s^{(7)}, \mathbf{EY}_s^{(8)}, \mathbf{EY}_s^{(9)}, \mathbf{EY}_s^{(10)}, \mathbf{EY}_s^{(11)}\}.$$

Consequentemente, observa-se que as respectivas estimativas de componentes independentes da Figura 5.16 associadas aos *clusters* $\gamma_2$ e $\gamma_3$ são todas relacionadas aos *notchings*, e as respectivas estimativas associadas ao *cluster* $\gamma_1$ são relacionadas aos harmônicos. Observou-se neste caso que, para $C$ maior do que o número de distúrbios independentes presentes em $x[n]$, aquele distúrbio que possui espectro de frequências mais amplo foi sub-decomposto em mais de um sub-espaço independente.

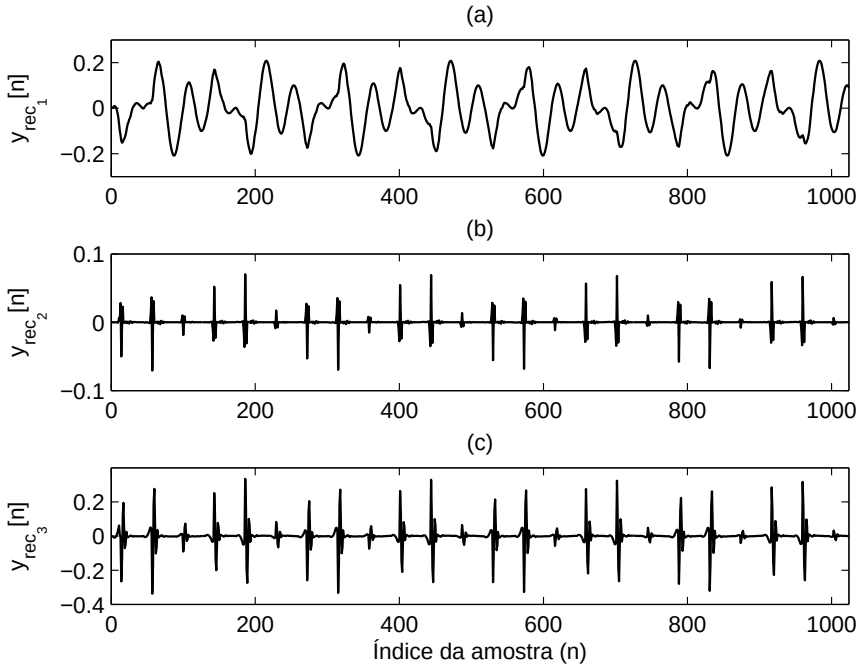


Figura 5.21: Componentes separados e reconstruídos utilizando-se o método SCICA, para $C = 3$ *clusters*; (a) $y_{\mathrm{rec}_1}[n]$, (b) $y_{\mathrm{rec}_2}[n]$ e, (c) $y_{\mathrm{rec}_3}[n]$.

A seguir, será apresentada a decomposição, pelos métodos FICA e SCICA, de um sinal contendo a presença simultânea de um transitório oscilatório e de harmônicos.

### Transitório oscilatório e harmônicos

A Figura 5.22(a) mostra um sinal de tensão $u[n]$ com amplitude normalizada, o qual modela a ocorrência simultânea de harmônicos e de um transitório oscilatório. A Figura 5.22(b) mostra a estimativa do componente fundamental $f[n]$ fornecida pelo filtro *notch*, e a Figura 5.22(c) mostra o sinal de erro resultante $x[n] = u[n] - f[n]$. Neste caso, o sinal $x[n]$ fornece a estimativa da soma dos componentes primitivos que caracterizam os harmônicos e o transitório oscilatório.

A Figura 5.23 mostra os espectros de frequência dos distúrbios originais e do sinal $x[n]$. A Figura 5.23(a) mostra o espectro do transitório oscilatório (fonte $s_1[n]$), a Figura 5.23(b) mostra o espectro dos harmônicos (fonte $s_2[n]$) e a Figura 5.23(c) mostra o espectro do sinal $x[n]$. Como pode ser observado, para esta combinação de múltiplos distúrbios, não há uma sobreposição acentuada de seus espectros, de forma que uma separação razoável poderia ser alcançada utilizando-se filtros fixos pré-projetados. Entretanto, a escolha adequada das respostas em frequência de tais filtros seria fundamental, e exigiria um conhecimento *a priori* dos espectros

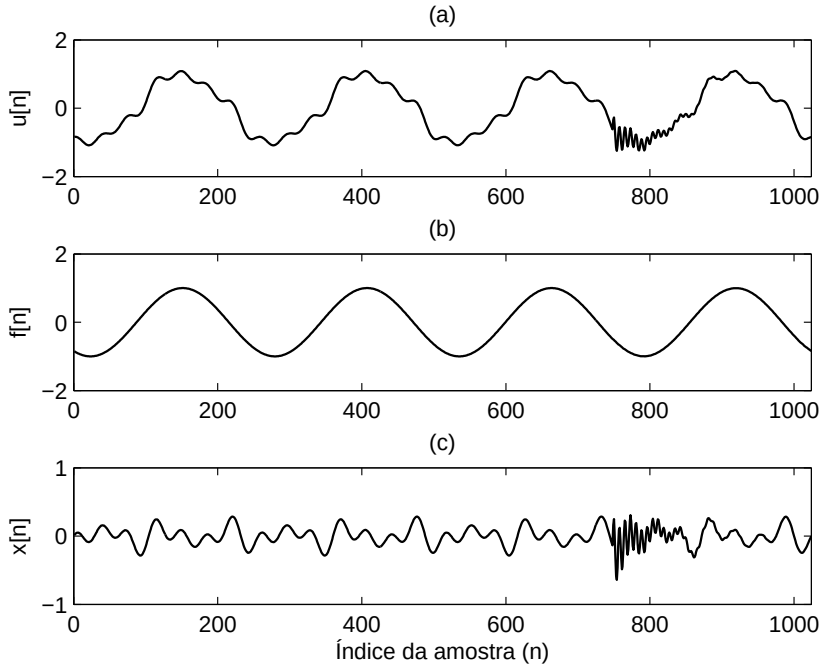


Figura 5.22: Sinal de tensão sintético modelando a ocorrência simultânea de transitório oscilatório e harmônicos; (a) Sinal de tensão monitorado $u[n]$, (b) Estimativa do componente fundamental $f[n]$ e, (c) sinal de erro $x[n] = u[n] - f[n]$.

de frequências de cada um dos distúrbios.

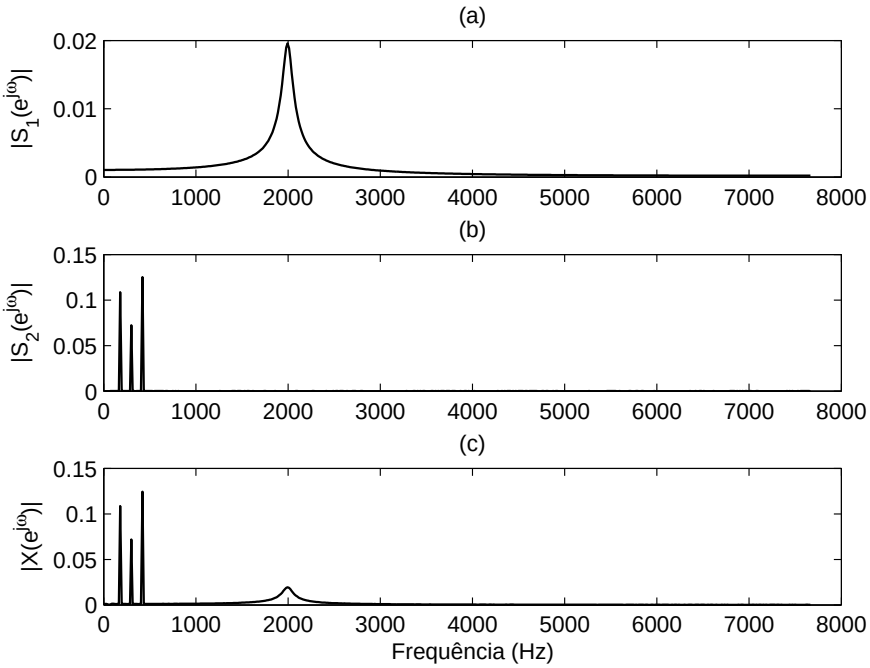


Figura 5.23: Espectros de frequências dos distúrbios originais e do sinal $x[n]$; (a) transitório oscilatório - fonte $s_1[n]$, (b) harmônicos - fonte $s_2[n]$ e, (c) sinal de erro - mistura $x[n]$.

A seguir, será realizada a decomposição adaptativa do sinal $x[n]$ utilizando-se o método FICA.

*Decomposição do sinal $x[n]$ utilizando o método FICA:*

De forma a observar como será o comportamento do método FICA para diferentes combinações de múltiplos distúrbios sem se alterar a configuração do banco de filtros fixos que geram os sinais de observação, utilizar-se-á aqui os mesmos filtros $h_1[n]$ e $h_2[n]$ utilizados anteriormente na decomposição de *notchings* e harmônicos. Portanto, o filtro $h_1[n]$ será um passa-todas e o filtro $h_2[n]$ será um passa-altas ($f_C = 300$ Hz), sendo ambos FIR Tipo 1 e com ordem $K = 20$. A Figura 5.24 mostra os módulos das respostas em frequência destes filtros, juntamente com o espectro de frequências do sinal $x[n]$. Como pode ser observado, o mesmo banco de filtros fixos utilizado na decomposição de *notchings* e harmônicos também aplica pesos linearmente independentes nos harmônicos e no transitório oscilatório deste exemplo. O filtro $h_1[n]$ aplica ganhos unitários em ambos os componentes. Já o filtro $h_2[n]$ aplica ganhos entre 0,6 e 0,7 nos harmônicos e ganho unitário nas principais frequências do transitório oscilatório. Desta forma, ambos os distúrbios continuarão presentes simultaneamente nos sinais de observação $x_1[n]$ e $x_2[n]$, sendo que, portanto, o banco de filtros fixos, por si só, não seria suficiente para separá-los.

O próximo passo é fornecer os sinais $x_1[n]$ e $x_2[n]$ como entradas para o algoritmo FastICA, para que ele realize o cálculo da ICA e estime uma matriz de separação $\mathbf{W}$ para a consequente obtenção de $y_1[n]$ e $y_2[n]$ a partir de $x_1[n]$ e $x_2[n]$. Em seguida, fornece-se os sinais $x_1[n]$, $y_1[n]$ e $y_2[n]$ ao algoritmo LMS, para a estimação dos pesos $b_1$ e $b_2$ do combinador linear adaptativo. Finalmente, os sinais $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_2}[n]$ são obtidos a partir de $b_1$, $b_2$, $y_1[n]$ e $y_2[n]$ utilizando-se (4.31), sendo neste caso $P = 2$. A Figura 5.25 mostra os sinais $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_2}[n]$ comparados às formas de onda dos distúrbios isolados originais. Como pode ser observado, o método FICA aplicado ao sinal $x[n]$ obteve estimativas que aproximaram muito bem as formas de onda das fontes originais.

Sendo $f_1[n]$ o filtro adaptativo que obtém $y_{\text{rec}_1}[n]$ e $f_2[n]$ o filtro adaptativo que obtém $y_{\text{rec}_2}[n]$, a Figura 5.26 mostra os módulos das respostas em frequência desses filtros resultantes da aplicação do método FICA ao sinal $x[n]$, cujo espectro de frequências é mostrado na mesma figura. Como pode ser observado, o filtro $f_1[n]$ atenua as frequências dos harmônicos e passa com ganhos próximos de 1 as frequências principais do transitório oscilatório. Já o filtro $f_2[n]$ passa as frequências dos harmônicos com ganhos em torno de 1 e rejeita bem as frequências

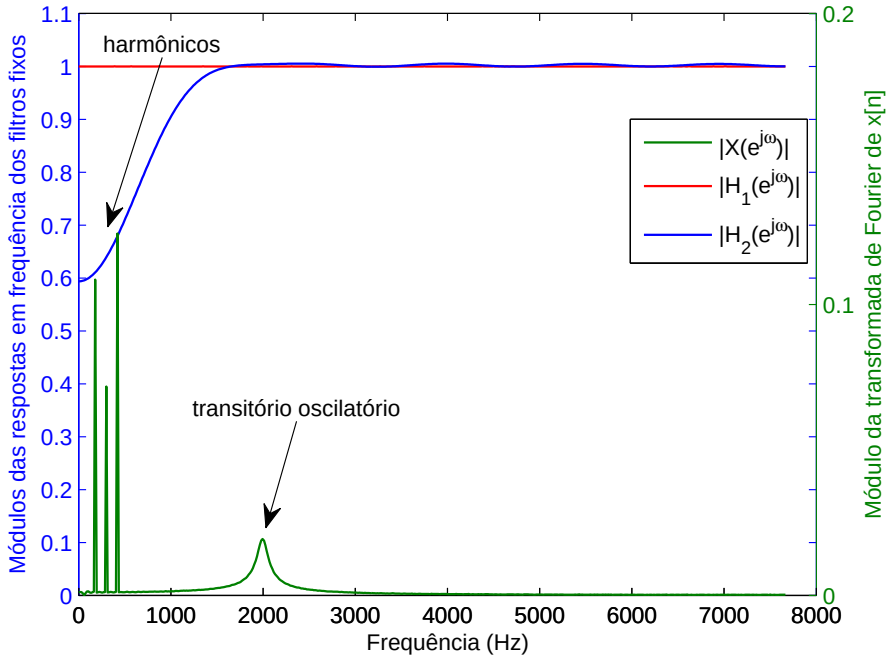


Figura 5.24: Módulos das respostas em frequência dos filtros $h_1[n]$ e $h_2[n]$, e espectro de frequências do sinal $x[n]$: transitório oscilatório e harmônicos.

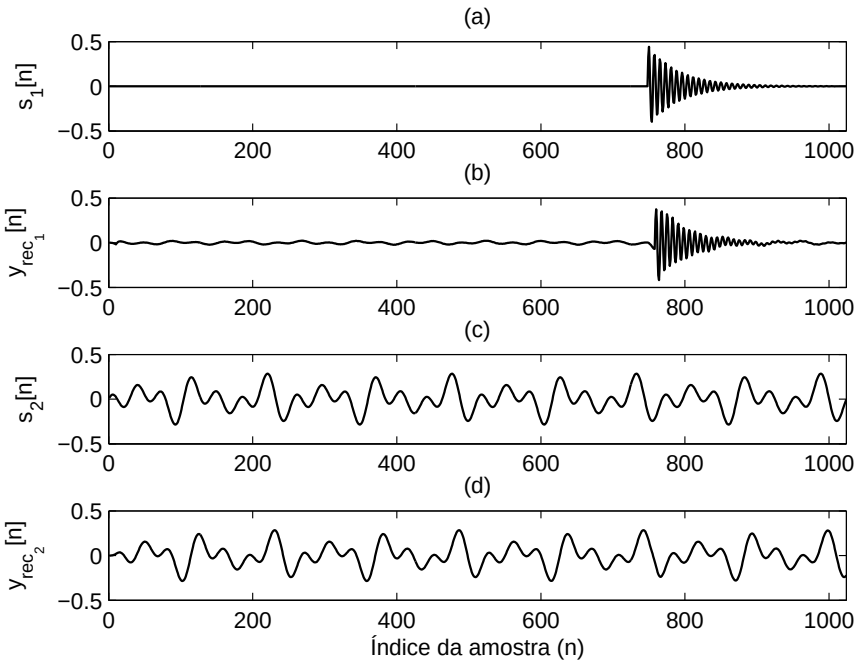


Figura 5.25: Estimativas de componentes independentes obtidas pelo método FICA; (a) transitório oscilatório original, (b) $y_{\text{rec}_1}[n]$, (c) harmônicos originais e, (d) $y_{\text{rec}_2}[n]$.

principais do transitório oscilatório, rejeitando completamente sua faixa de frequências de maior energia.

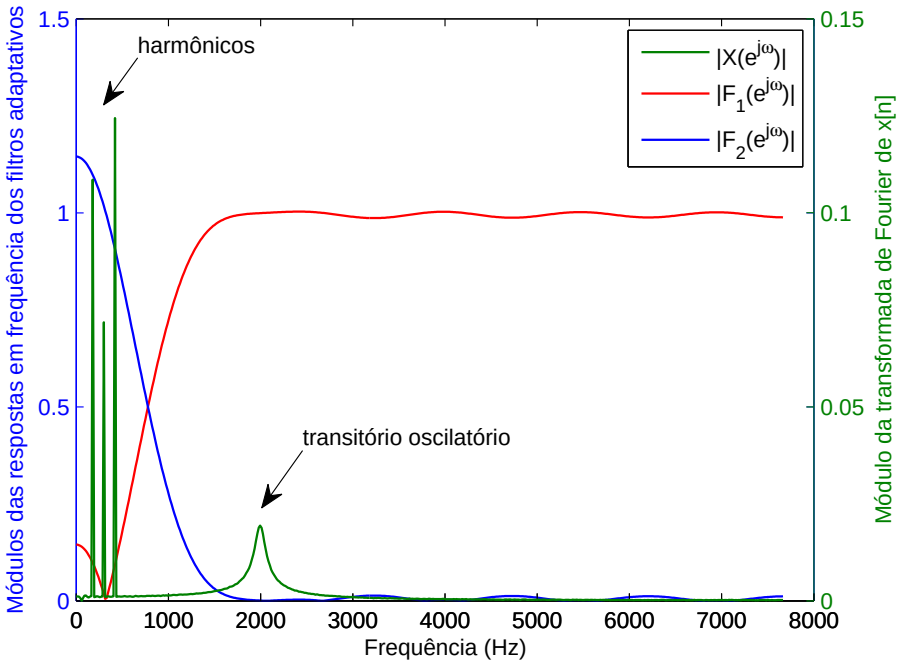


Figura 5.26: Módulos das respostas em frequência dos filtros adaptativos resultantes da operação do método FICA, e espectro de frequências do sinal $x[n]$: transitório oscilatório e harmônicos.

A Figura 5.27 mostra o resultado da simulação da variação da frequência de corte do filtro fixo $h_2[n]$ e da ordem de ambos os filtros $h_1[n]$ e $h_2[n]$. Para o experimento cujo resultado é mostrado na Figura 5.27(a), a frequência de corte $f_{C2}$ de $h_2[n]$ foi variada desde 100 até 3000 Hz em passos de 50 Hz, sendo tal filtro sempre um passa-altas com ordem $K = 20$. Para o experimento cujo resultado é mostrado na Figura 5.27(b), a ordem dos filtros $h_1[n]$ e $h_2[n]$ foi variada desde 10 até 60 em passos de 2, mantendo-se a frequência de corte $f_{C2}$ de $h_2[n]$ sempre igual a 300 Hz.

Como pode ser observado, esses resultados são semelhantes àqueles encontrados para a simulação de *notchings* e harmônicos e mostrados na Figura 5.14. Observa-se que os resultados de separação entre o transitório oscilatório e os harmônicos são excelentes para qualquer escolha de $f_{C2}$ desde 100 até 2000 Hz. A partir desta frequência, a qualidade das estimativas começa a cair gradativamente. Ao observar a Figura 5.24, percebe-se que o filtro $h_2[n]$ irá rejeitar cada vez mais informações espectrais de ambos os distúrbios à medida que $f_{C2}$ for aumentando, sendo que, após 2500 Hz, praticamente não há mais informação relevante de nenhum dos distúrbios.

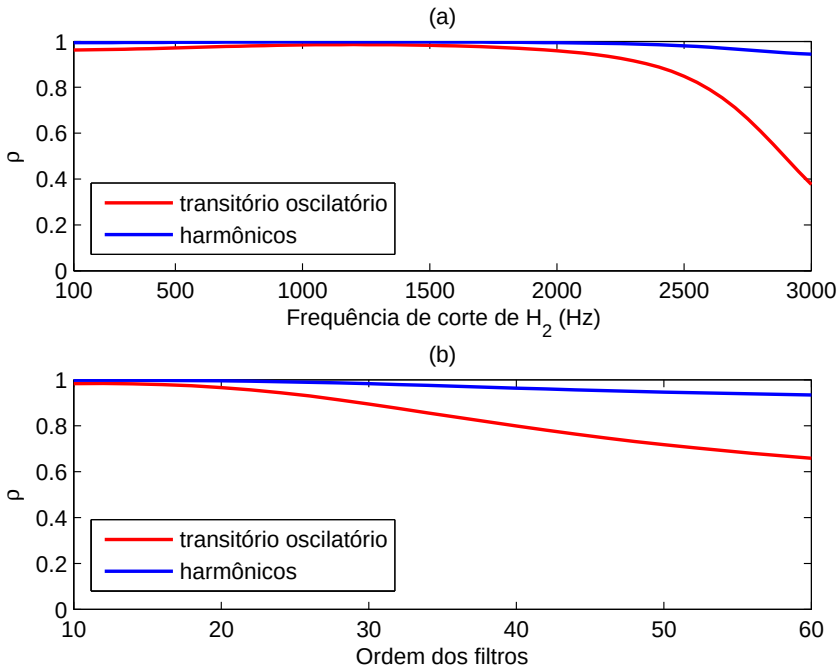


Figura 5.27: Coeficiente de correlação entre os distúrbios originais e suas estimativas, em função: (a) da frequência de corte de $h_2[n]$ e, (b) da ordem dos filtros, para o sinal contendo transitório oscilatório e harmônicos.

Portanto, à medida que $f_{C2}$ for aumentando, a observação correspondente $x_2[n]$ carregará cada vez menos informação suficiente a respeito dos distúrbios envolvidos, de tal forma que a ICA será cada vez menos capaz de estimar uma matriz de separação $\mathbf{W}$ que separe os distúrbios mutuamente presentes em $x_1[n]$ e $x_2[n]$. Deve ser observado que o valor de $\rho$ para as estimativas de harmônicos varia menos em função da variação de $f_{C2}$ do que para as estimativas de transitório oscilatório. Isto ocorre porque, sendo os harmônicos um tipo de distúrbio que ocorre ao longo de toda a janela de dados, e sendo o transitório oscilatório um distúrbio que ocorre apenas em uma parte da mesma, o cálculo do coeficiente de correlação para este último sofre muito mais os efeitos quando a estimativa do mesmo for distorcida.

Já com relação à simulação da variação da ordem dos filtros, o resultado da Figura 5.27(b) mostra que para $K = 10$ até $K = 20$, a qualidade da separação dos distúrbios se mantém praticamente inalterada. À medida que a ordem dos filtros aumenta demasiadamente, entretanto, a qualidade da separação vai diminuindo gradativamente, pelos mesmos motivos já comentados anteriormente para a simulação de separação entre *notchings* e harmônicos.

A Figura 5.28 mostra o resultado da decomposição do sinal $x[n]$, desta vez utilizando-se $M = 3$ filtros no banco de filtros fixos. Desta forma, tem-se mais filtros do que distúrbios. Os dois

primeiros filtros são os mesmos $h_1[n]$ e $h_2[n]$ utilizados anteriormente para $M = 2$, e o filtro $h_3[n]$ é um passa-baixas com $f_{C3} = 1000$ Hz, também com ordem $K = 20$. Como pode ser observado, os sinais $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_2}[n]$ são ambos estimativas mais associadas aos harmônicos, sendo mais precisamente sub-decomposições deste distúrbio. Já o sinal $y_{\text{rec}_3}[n]$ é uma estimativa apenas associada ao transitório oscilatório. Portanto, nesta simulação observou-se que, ao utilizar um número de filtros maior do que o número de distúrbios, um deles foi sub-decomposto em mais de um componente independente.

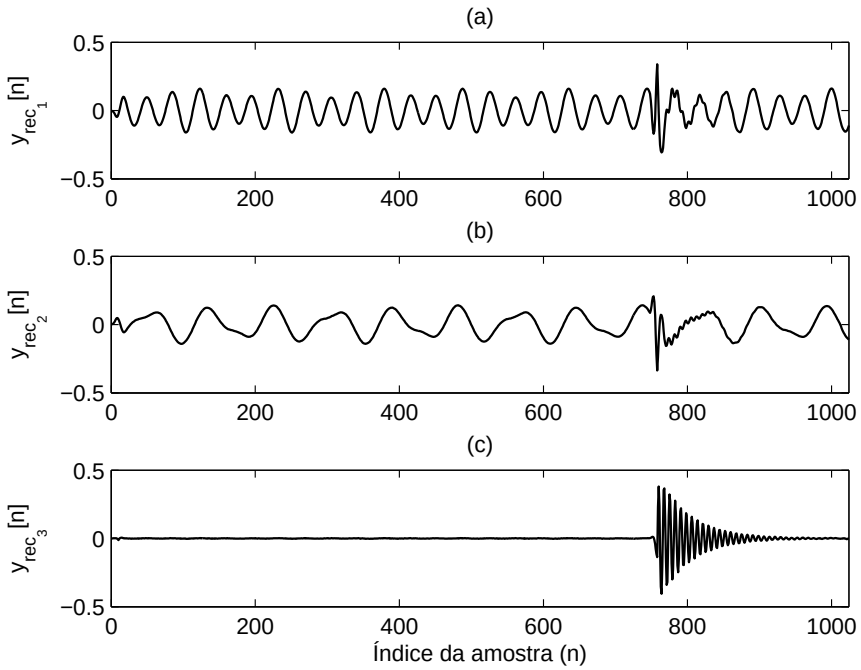


Figura 5.28: Estimativas de componentes independentes obtidas pelo método FICA, quando utilizados 3 filtros fixos; (a) $y_{\text{rec}_1}[n]$, (b) $y_{\text{rec}_2}[n]$ e, (d) $y_{\text{rec}_3}[n]$.

A seguir, serão apresentados os resultados da decomposição do sinal $x[n]$ da Figura 5.22(c), porém desta vez utilizando o método SCICA.

*Decomposição do sinal $x[n]$ utilizando o método SCICA:*

De forma a também analisar o funcionamento do método SCICA para diferentes combinações de múltiplos distúrbios sem se alterar seus parâmetros internos, a mesma configuração utilizada para decompor o sinal contendo *notchings* e harmônicos será novamente utilizada aqui. Neste caso, $M = 12$ sinais de observação e $\tau = 1$ amostra de atraso para o processo de construção da matriz de observações $\mathbf{X}$ a partir do sinal de entrada $x[n]$. Aplicando o algoritmo FastICA

à matriz $\mathbf{X}$, obteve-se as estimativas das matrizes $\mathbf{W}$ e $\mathbf{A}$, as quais foram utilizadas para obter as estimativas de componentes independentes mostradas na Figura 5.29. Novamente, observa-se que cada estimativa de componente independente é uma versão filtrada de $x[n]$, sendo que há múltiplas estimativas associadas a um mesmo tipo de distúrbio.

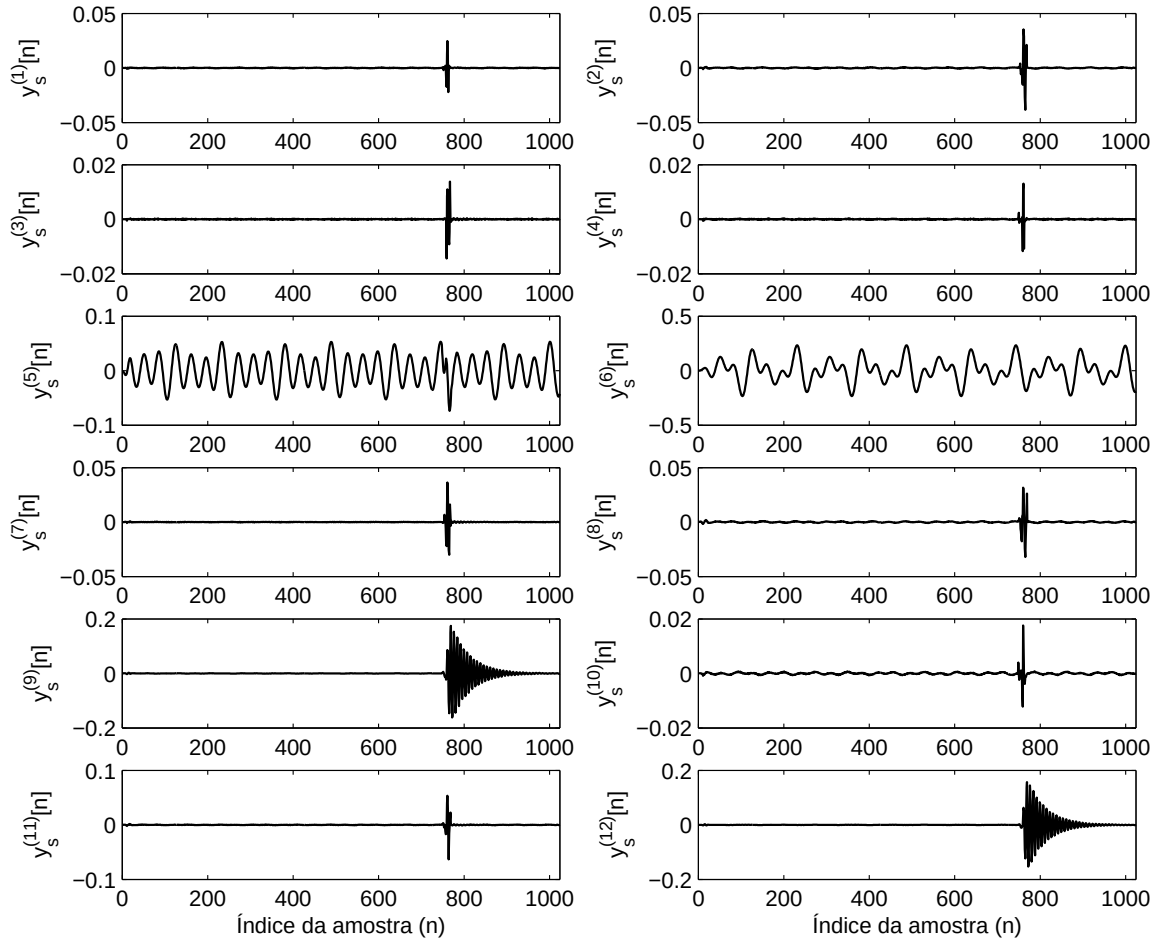


Figura 5.29: Estimativas de componentes independentes com escalas recuperadas: transitório oscilatório e harmônicos.

O próximo passo então é fornecer como entrada, à etapa de agrupamento, as estimativas de componentes independentes obtidas, para que tal etapa automaticamente identifique as estimativas associadas a uma mesma fonte e as agrupe juntas em um mesmo *cluster*. Novamente, como há duas fontes, adota-se nesta simulação $C = 2$ *clusters* a serem encontrados pelo algoritmo *k-means*. Para o cálculo dos vetores de energias a serem fornecidos como entrada para o algoritmo *k-means*, adotou-se novamente $R = 16$ faixas de frequência, o que proporciona uma largura de banda $L = 480$ Hz para cada faixa de frequência, lembrando-se que a frequência de

amostragem adotada para a geração dos sinais sintéticos é $f_S = 15360$ Hz. A Figura 5.30 mostra a distribuição dos valores de energia para cada componente $y_s^{(p)}[n]$, ao longo das 16 faixas de frequência, sendo tais valores armazenados no vetor correspondente $\mathbf{EY}_s^{(p)}$.

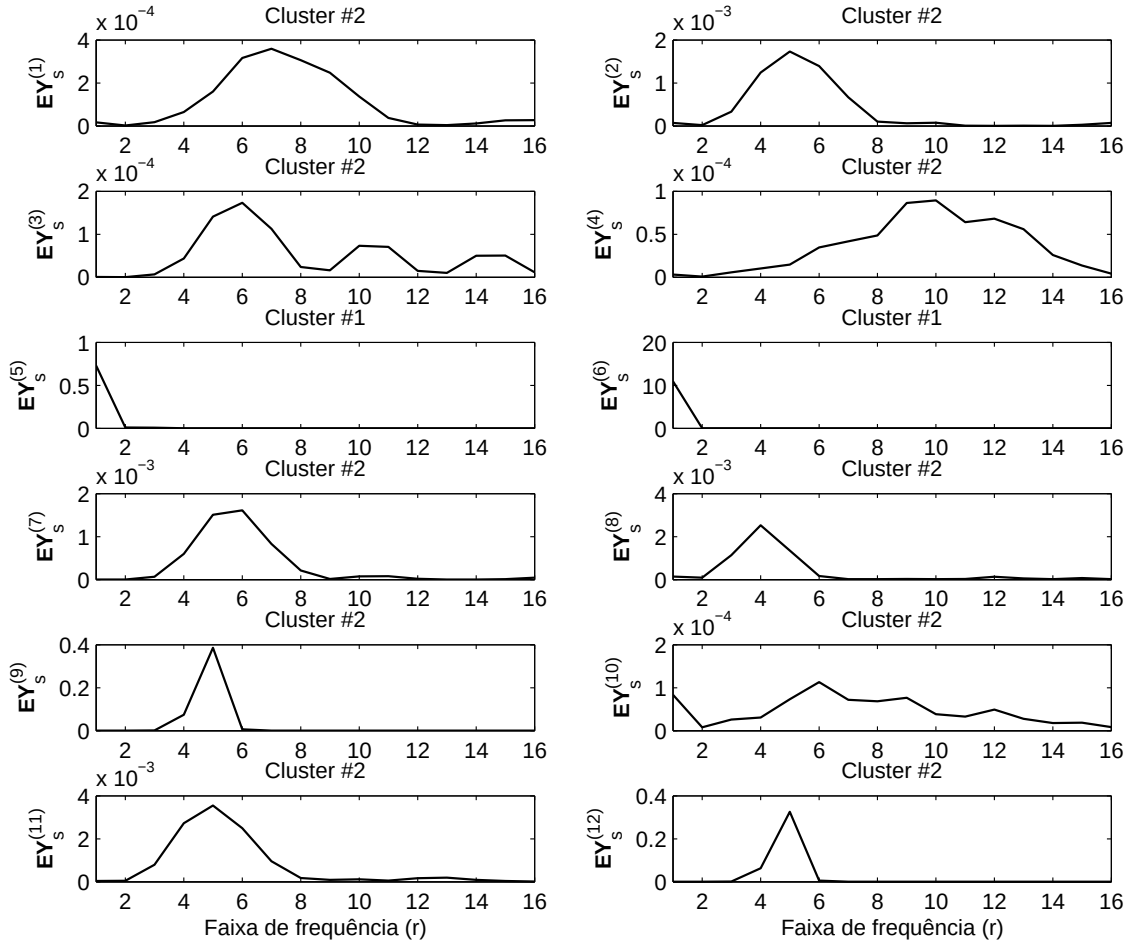


Figura 5.30: Vetores de energias calculados para as estimativas de componentes independentes, com o respectivo agrupamento pelo algoritmo *k-means* baseado em suas similaridades espectrais: transitório oscilatório e harmônicos.

A Figura 5.30 também mostra o resultado do agrupamento de cada vetor de energia pelo algoritmo *k-means* dentro dos *clusters* $\gamma_1$ e $\gamma_2$. O resultado revela que os vetores 1, 2, 3, 4, 7, 8, 9, 10, 11 e 12 foram todos agrupados dentro do *cluster* $\gamma_2$, e os vetores 5 e 6 foram agrupados dentro do *cluster* $\gamma_1$. Analisando-se a Figura 5.29, observa-se que os componentes independentes 1, 2, 3, 4, 7, 8, 9, 10, 11 e 12 são mais associados ao transitório oscilatório, e os componentes independentes 5 e 6 são mais associados aos harmônicos. Novamente, cada *cluster* engloba os componentes pertencentes a um diferente sub-espaço independente, cada qual dentro de uma

diferente faixa de frequências. O primeiro sub-espaço possui dimensão 10, e o segundo subespaço possui dimensão 2. Relembrando, a dimensão de cada sub-espaço é função da largura de banda de cada fonte independente.

O próximo passo é somar todos os componentes independentes associados ao *cluster* $\gamma_1$ para se obter $y_{\text{rec}_1}[n]$, e somar todos os componentes independentes associados ao *cluster* $\gamma_2$ para se obter $y_{\text{rec}_2}[n]$. Os sinais obtidos através desta operação são mostrados na Figura 5.31, sendo comparados às fontes originais $s_1[n]$ e $s_2[n]$. Observa-se que $y_{\text{rec}_2}[n]$ é uma estimativa do transitório oscilatório (fonte $s_1[n]$). Por outro lado, $y_{\text{rec}_1}[n]$ é uma estimativa dos harmônicos (fonte $s_2[n]$). Portanto, as estimativas não recuperaram a ordem correta das fontes originais. Repare na Figura 5.30 que as estimativas de componentes independentes associadas ao transitório oscilatório foram agrupadas dentro do *cluster* $\gamma_2$ e aquelas associadas aos harmônicos foram agrupadas dentro do *cluster* $\gamma_1$. Pelo fato do algoritmo *k-means* inicializar seus pesos de forma aleatória, consequentemente não há garantia que a ordem dos *clusters* siga a ordem das fontes originais.

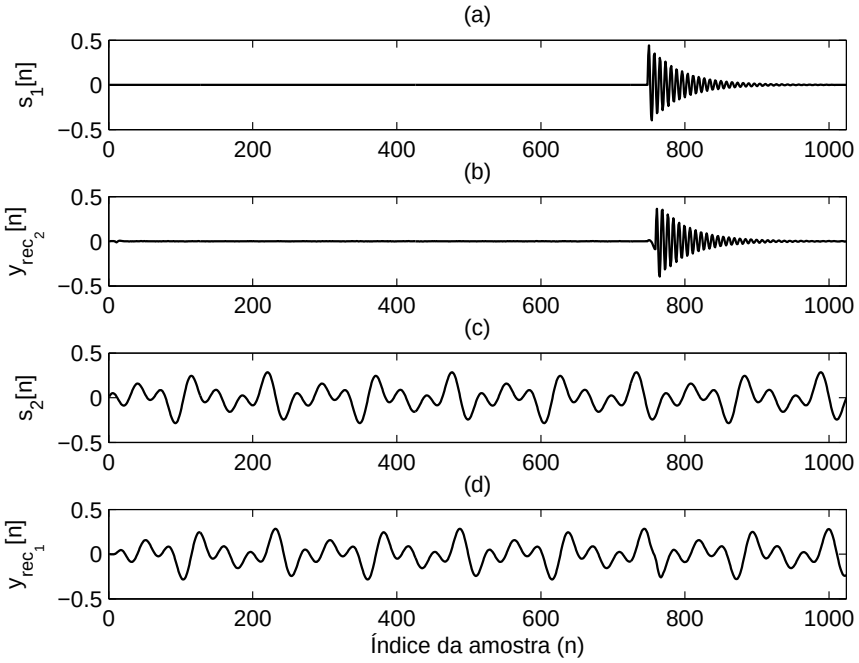


Figura 5.31: Componentes separados e reconstruídos utilizando-se o método SCICA; (a) transitório oscilatório original, (b) $y_{\text{rec}_2}[n]$, (c) harmônicos originais e, (d) $y_{\text{rec}_1}[n]$.

A Figura 5.32 mostra os módulos das respostas em frequência dos filtros adaptativos $f_1[n]$ e $f_2[n]$ obtidos pela aplicação do método SCICA ao sinal $x[n]$, juntamente com o espectro de frequências deste sinal. Pode ser observado que o filtro $f_1[n]$, responsável por obter $y_{\text{rec}_1}[n]$ por

meio da filtragem de $x[n]$, rejeita as principais frequências do transitório oscilatório, e passa com ganho unitário as frequências dos harmônicos. Por outro lado, o filtro $f_2[n]$, responsável por obter $y_{\text{rec}_2}[n]$ por meio da filtragem de $x[n]$, rejeita as frequências dos harmônicos, e passa com ganho unitário as principais frequências do transitório oscilatório. Tais resultados estão de acordo com aqueles mostrados na Figura 5.31.

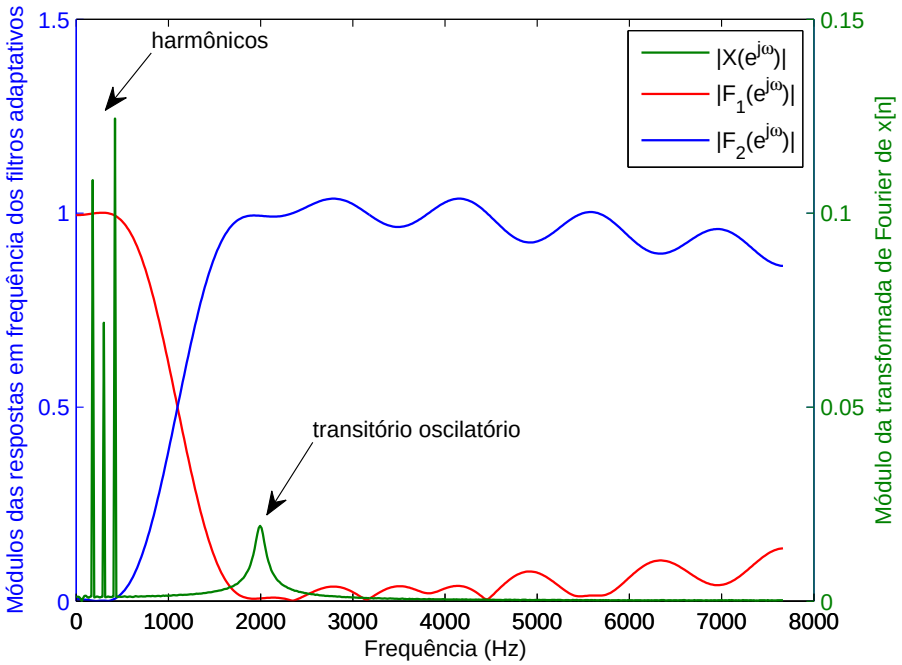


Figura 5.32: Módulos das respostas em frequência dos filtros adaptativos resultantes da operação do método SCICA, e espectro de frequências do sinal $x[n]$: transitório oscilatório e harmônicos.

A Figura 5.33 mostra o resultado da simulação da variação do número de sinais de observação $M$ a serem fornecidos para a ICA. Observa-se que à medida que se aumenta $M$, melhora-se a qualidade das estimativas, até não alcançar mais uma grande melhoria após $M = 12$, que foi o valor definido para tal parâmetro que levou aos resultados de separação mostrados na Figura 5.31.

A próxima análise mostra o resultado obtido para a decomposição do sinal $x[n]$ quando definidos $C = 3$ *clusters* a serem estimados pelo algoritmo *k-means*, mantendo-se $M = 12$ e $\tau = 1$. A Figura 5.34 mostra as estimativas obtidas pelo método SCICA para este caso, na qual observa-se que ambas as estimativas $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_2}[n]$ carregam informações associadas ao transitório oscilatório, e a estimativa $y_{\text{rec}_3}[n]$ carrega informações associadas aos harmônicos.

Para esta simulação, os vetores de energia da Figura 5.30 foram automaticamente reagrupa-

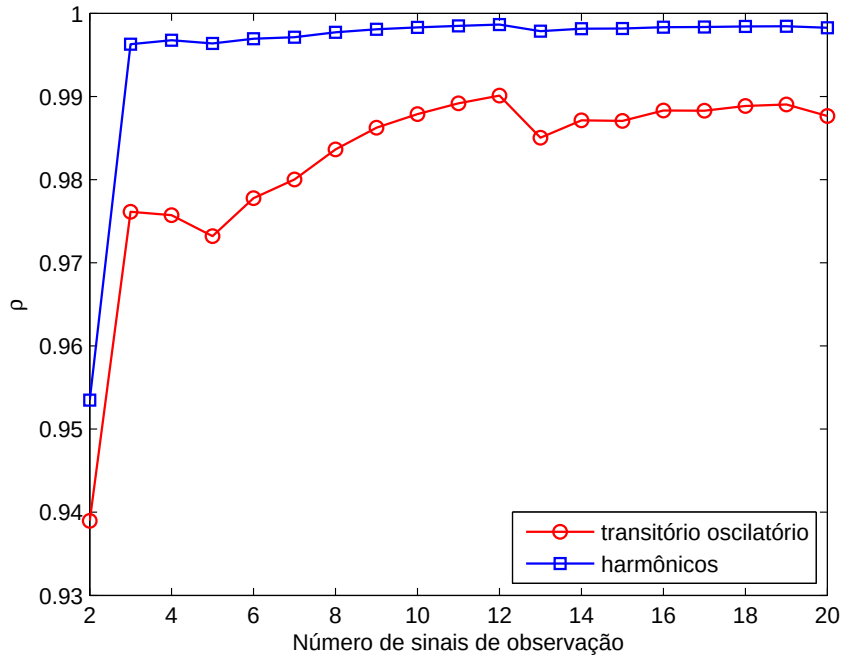


Figura 5.33: Coeficiente de correlação entre os distúrbios originais e suas estimativas, em função do número de observações $M$: transitório oscilatório e harmônicos.

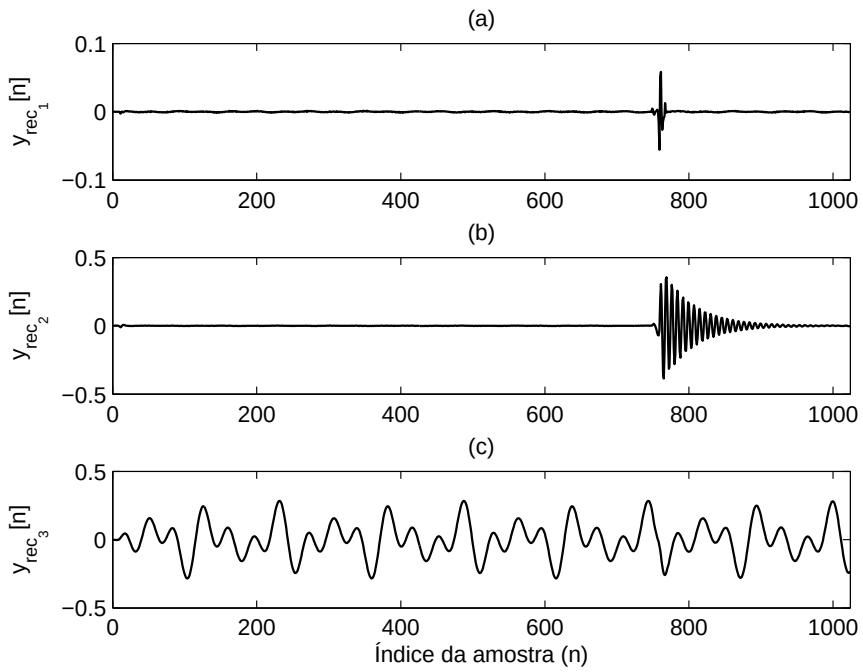


Figura 5.34: Componentes separados e reconstruídos utilizando-se o método SCICA, para $C = 3$ *clusters*; (a) $y_{\mathrm{rec}_1}[n]$, (b) $y_{\mathrm{rec}_2}[n]$ e, (c) $y_{\mathrm{rec}_3}[n]$.

dos pelo algoritmo *k-means* dentro dos três *clusters* mostrados abaixo:

$$\gamma_1 = \{\mathbf{EY}_s^{(1)}, \mathbf{EY}_s^{(3)}, \mathbf{EY}_s^{(4)}, \mathbf{EY}_s^{(10)}\},$$

$$\gamma_2 = \{\mathbf{EY}_s^{(2)}, \mathbf{EY}_s^{(7)}, \mathbf{EY}_s^{(8)}, \mathbf{EY}_s^{(9)}, \mathbf{EY}_s^{(11)}, \mathbf{EY}_s^{(12)}\},$$

$$\gamma_3 = \{\mathbf{EY}_s^{(5)}, \mathbf{EY}_s^{(6)}\}.$$

Consequentemente, observa-se que as respectivas estimativas de componentes independentes da Figura 5.29 associadas aos *clusters* $\gamma_1$ e $\gamma_2$ são todas relacionadas ao transitório oscilatório, e as respectivas estimativas associadas ao *cluster* $\gamma_3$ são relacionadas aos harmônicos. Observou-se mais uma vez que, para $C$ maior do que o número de distúrbios presentes em $x[n]$, aquele distúrbio que possui espectro de frequências mais amplo foi sub-decomposto em mais de um sub-espaço independente.

A seguir, será apresentada a decomposição, pelos métodos FICA e SCICA, de um sinal contendo a combinação de três distúrbios: transitório oscilatório, *notchings* e harmônicos.

**Transitório oscilatório, *notchings* e harmônicos**

Este exemplo mostra a aplicação, dos dois métodos propostos, em um sinal sintético modelando a ocorrência simultânea de transitório oscilatório, *notchings* e harmônicos. A Figura 5.35(a) mostra o sinal de entrada $u[n]$ contendo os três distúrbios simultaneamente dentro da mesma janela de dados. A Figura 5.35(b) mostra o componente fundamental $f[n]$ estimado pelo filtro *notch*, e a Figura 5.35(c) mostra o sinal de erro $x[n]$ resultante, que será em seguida fornecido como entrada aos métodos FICA e SCICA. As Figuras 5.36(a),(b), (c) e (d) mostram, respectivamente, os espectros de frequência do transitório oscilatório, dos *notchings*, dos harmônicos e do sinal $x[n]$.

A seguir, será apresentada a aplicação do método FICA para decompor o sinal $x[n]$.

*Decomposição do sinal $x[n]$ utilizando o método FICA:*

Como há três fontes misturadas no sinal $x[n]$, o banco de filtros projetado contém agora $M = 3$ filtros. Os filtros $h_1[n]$ e $h_2[n]$ serão os mesmos utilizados nas decomposições anteriores ($h_1[n]$ é um passa-todas e $h_2[n]$ é um passa-altas com $f_C = 300$ Hz, sendo ambos de ordem

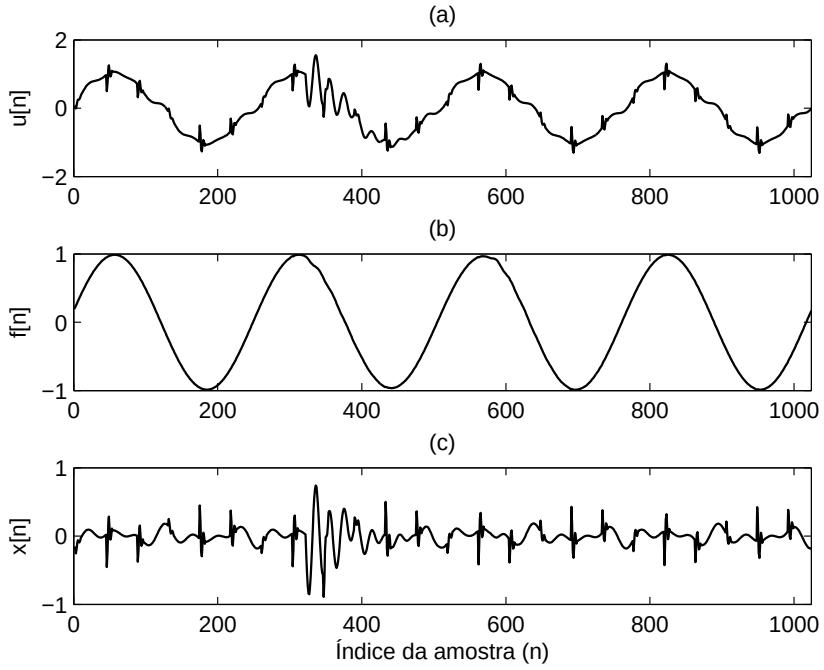


Figura 5.35: Sinal de tensão sintético modelando a ocorrência simultânea de transitório oscilatório, *notchings* e harmônicos; (a) Sinal de tensão monitorado $u[n]$, (b) Estimativa do componente fundamental $f[n]$ e, (c) sinal de erro $x[n] = u[n] - f[n]$.

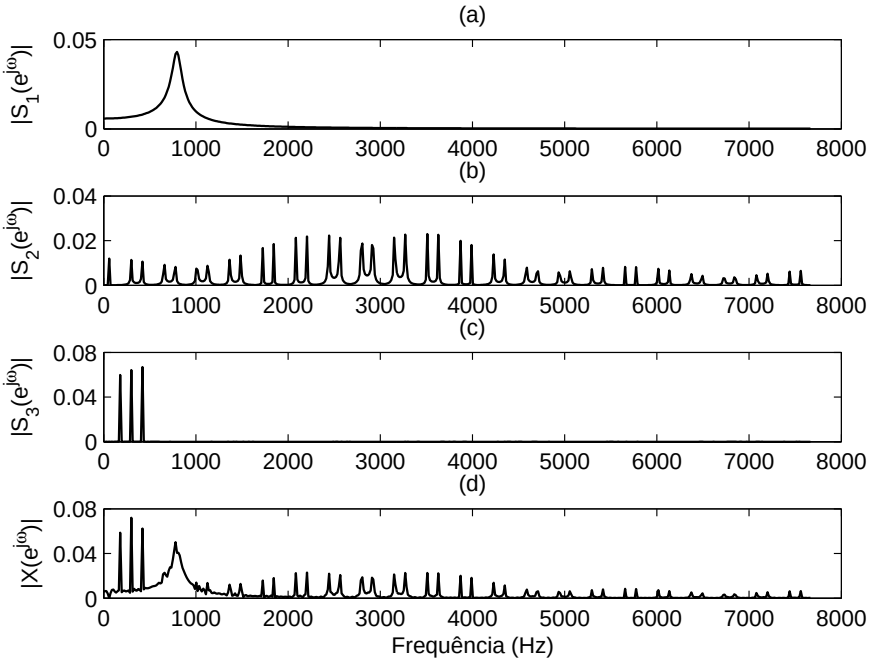


Figura 5.36: Espectros de frequências dos distúrbios originais; (a) transitório oscilatório - fonte $s_1[n]$, (b) *notchings* - fonte $s_2[n]$, (c) harmônicos - fonte $s_3[n]$ e, (d) sinal de erro - mistura $x[n]$.

$K = 20$). O filtro $h_3[n]$ será um passa-baixas com $f_C = 1000$ Hz e também ordem $K = 20$. A Figura 5.37 mostra os módulos das respostas em frequência destes filtros, além do espectro de frequências do sinal $x[n]$, o qual será fornecido a estes filtros fixos para que os mesmos originem, respectivamente, os sinais de observação $x_1[n]$, $x_2[n]$ e $x_3[n]$ para a ICA.

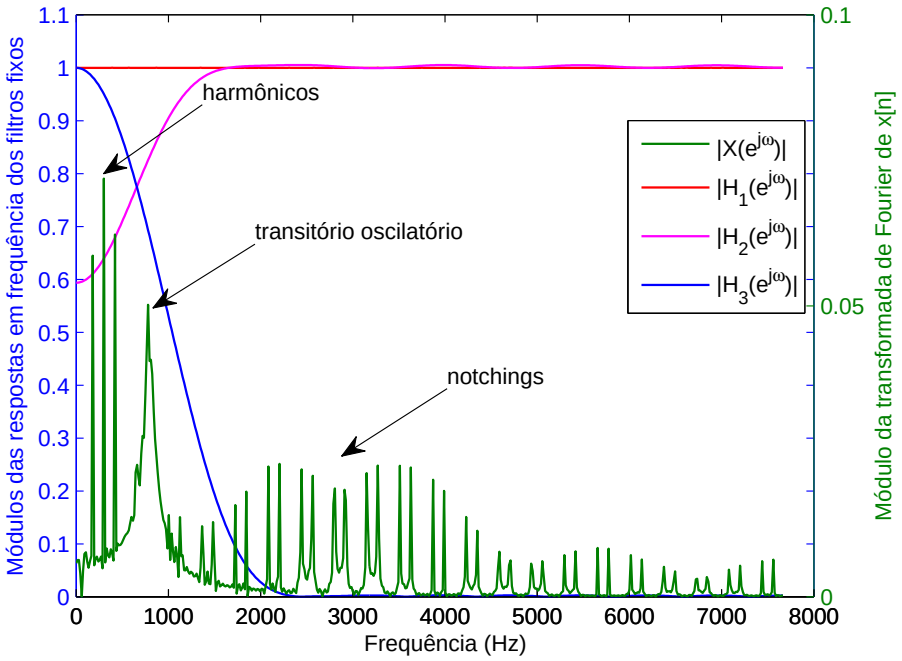


Figura 5.37: Módulos das respostas em frequência dos filtros $h_1[n]$, $h_2[n]$ e $h_3[n]$, e espectro de frequências do sinal $x[n]$: transitório oscilatório, *notchings* e harmônicos.

O filtro $h_1[n]$ aplica ganhos unitários nas frequências dos três distúrbios. O filtro $h_2[n]$ aplica ganhos entre 0,6 e 0,7 nas frequências dos harmônicos, ganhos em torno de 0,8 nas principais frequências do transitório oscilatório e ganhos em torno de 1 nas principais frequências dos *notchings*. O filtro $h_3[n]$ aplica ganhos entre 1 e 0,9 nas frequências dos harmônicos, ganhos em torno de 0,7 nas principais frequências do transitório oscilatório e ganho nulo nas principais frequências dos *notchings*. Desta forma, esses filtros aplicam pesos linearmente independentes nas fontes misturadas em $x[n]$, sendo esses pesos aproximadamente constantes.

Como pode ser observado no espectro de $x[n]$, os distúrbios não deixam de possuir sobreposição espectral, mas as frequências que contêm os maiores níveis de energia de cada um são razoavelmente distintas. Observa-se, portanto, que as condições de separabilidade do método FICA estão sendo todas aproximadamente satisfeitas. Sendo assim, se a ICA conseguir estimar uma matriz de separação que aproximadamente inverta a matriz de pesos aplicados pelos filtros fixos acima, as fontes podem ser aproximadamente recuperadas.

O próximo passo é fornecer os sinais $x_1[n]$, $x_2[n]$ e $x_3[n]$ ao algoritmo FastICA, que por sua vez deve estimar a matriz de separação $\mathbf{W}$ e os componentes independentes $y_1[n]$, $y_2[n]$ e $y_3[n]$. Em seguida, os sinais $x_1[n]$, $y_1[n]$, $y_2[n]$ e $y_3[n]$ são fornecidos ao algoritmo LMS, o qual estima os pesos $b_1$, $b_2$ e $b_3$ do combinador linear adaptativo, para finalmente obter $y_{\text{rec}_1}[n]$, $y_{\text{rec}_2}[n]$ e $y_{\text{rec}_3}[n]$.

A Figura 5.38 mostra os sinais $y_{\text{rec}_1}[n]$, $y_{\text{rec}_2}[n]$ e $y_{\text{rec}_3}[n]$ obtidos, comparados às formas de onda dos distúrbios originais. Como pode ser observado, neste exemplo, a ICA não recuperou a ordem das fontes, já que $y_{\text{rec}_3}[n]$ se aproxima mais de $s_1[n]$ e $y_{\text{rec}_1}[n]$ possui uma forma de onda mais correlacionada com $s_3[n]$.

A Figura 5.39 mostra os módulos das respostas em frequência dos filtros adaptativos $f_1[n]$, $f_2[n]$ e $f_3[n]$, responsáveis por obter, respectivamente, $y_{\text{rec}_1}[n]$, $y_{\text{rec}_2}[n]$ e $y_{\text{rec}_3}[n]$, por meio da filtragem de $x[n]$. Observando-se $|F_1(e^{j\omega})|$, percebe-se que $f_1[n]$ é um filtro que passa razoavelmente bem as frequências dos harmônicos, além de atenuar bem as frequências do transitório oscilatório e dos *notchings*. Com relação ao filtro $f_2[n]$, percebe-se que ele atenua bem as frequências dos harmônicos e do transitório oscilatório, além de passar as frequências principais dos *notchings* com ganhos próximos de 1. Já o filtro $f_3[n]$ atenua bem as frequências dos harmônicos e as frequências principais dos *notchings*, além de passar as frequências principais do transitório oscilatório com ganhos em torno de 1.

A Figura 5.40 mostra o resultado da decomposição de $x[n]$ pelo método FICA quando o banco de filtros fixos é composto apenas pelos filtros $h_1[n]$ e $h_2[n]$. Neste caso, há mais distúrbios do que filtros. Obviamente, tal configuração não foi suficiente para obter estimativas que separassem todos os distúrbios. A estimativa $y_{\text{rec}_1}[n]$ contém informações dos três distúrbios. A estimativa $y_{\text{rec}_2}[n]$ conseguiu filtrar os harmônicos, mas ainda contém uma mistura acentuada do transitório oscilatório e dos *notchings*.

A seguir, será apresentada a aplicação do método SCICA para decompor o mesmo sinal $x[n]$.

*Decomposição do sinal $x[n]$ utilizando o método SCICA:*

Utilizando-se a mesma configuração do método SCICA utilizada nos exemplos anteriores com relação à geração dos sinais de observação ($M = 12$ sinais de observação e $\tau = 1$ amostra de atraso), obteve-se as estimativas de componentes independentes mostradas na Figura 5.41. Observa-se, também neste exemplo, que as estimativas são versões filtradas de $x[n]$, sendo que

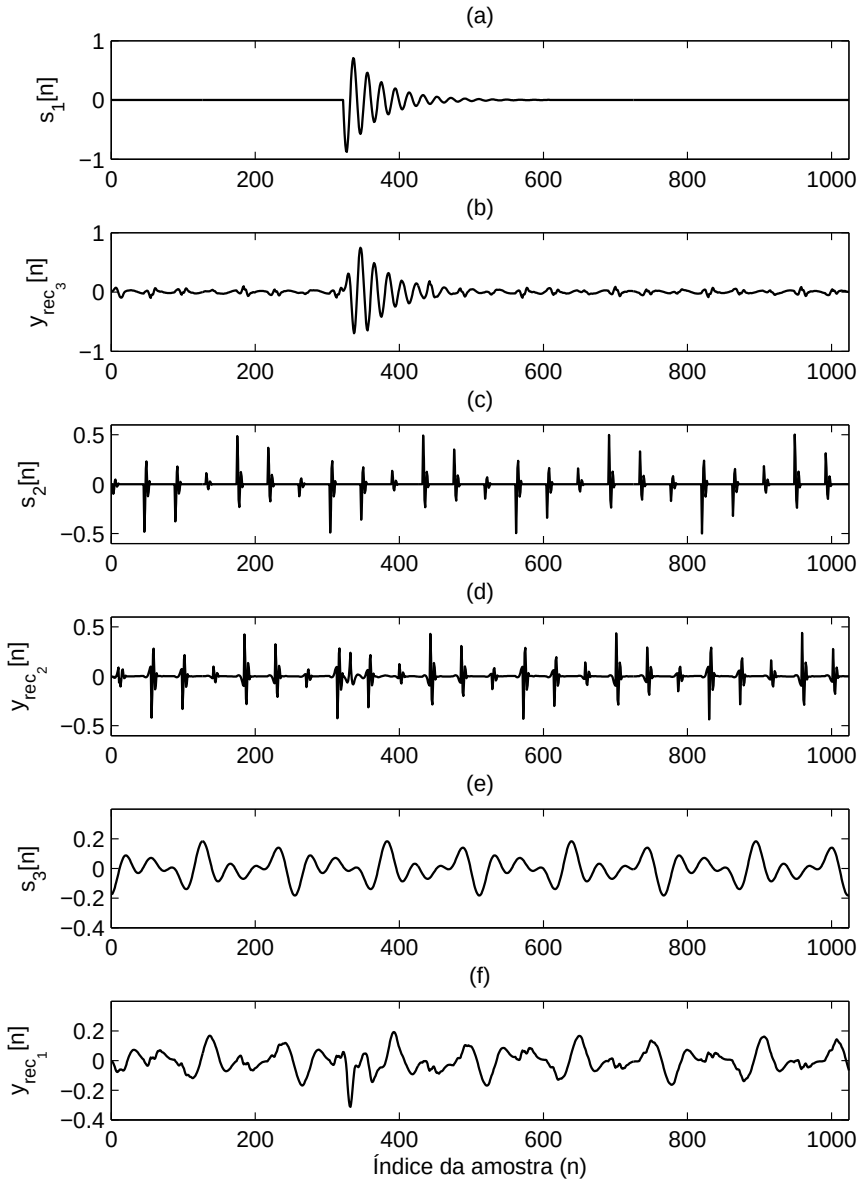


Figura 5.38: Estimativas de componentes independentes obtidas pelo método FICA; (a) transitório oscilatório original, (b) $y_{\mathrm{rec}_3}[n]$, (c) *notchings* originais, (d) $y_{\mathrm{rec}_2}[n]$, (e) harmônicos originais e, (f) $y_{\mathrm{rec}_1}[n]$.

há múltiplas estimativas associadas a um mesmo distúrbio.

Neste caso, como há três distúrbios, adota-se $C = 3$ *clusters* a serem estimados pelo algoritmo *k-means*. Para o cálculo dos vetores de energias a serem fornecidos como entrada para o algoritmo *k-means*, adotou-se novamente $R = 16$ faixas de frequência. A Figura 5.42 mostra a distribuição

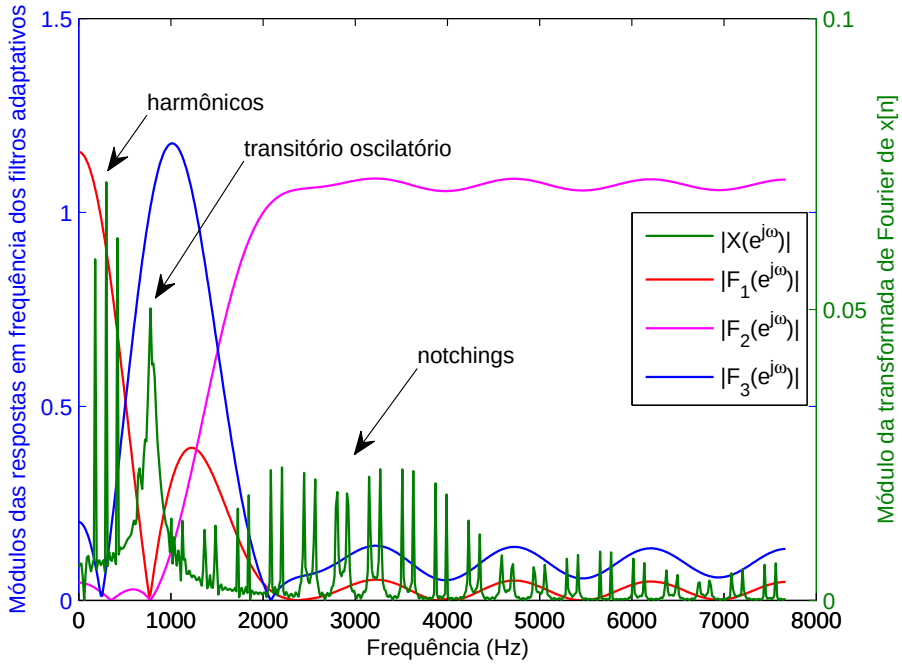


Figura 5.39: Módulos das respostas em frequência dos filtros adaptativos resultantes da operação do método FICA, e espectro de frequências do sinal $x[n]$: transitório oscilatório, *notchings* e harmônicos.

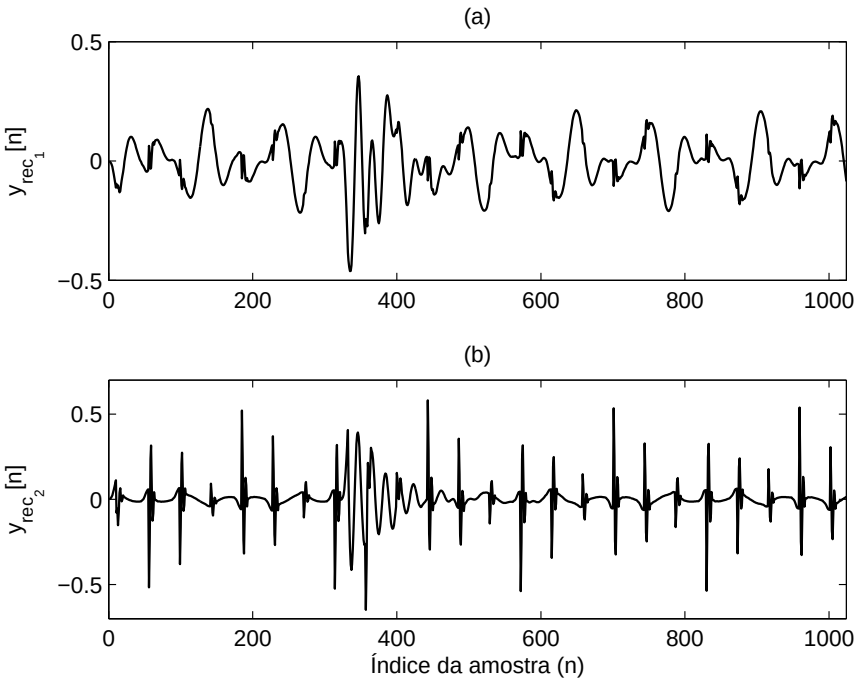


Figura 5.40: Estimativas de componentes independentes obtidas pelo método FICA, quando utilizados somente 2 filtros fixos; (a) $y_{\mathrm{rec}_1}[n]$ e, (b) $y_{\mathrm{rec}_2}[n]$.

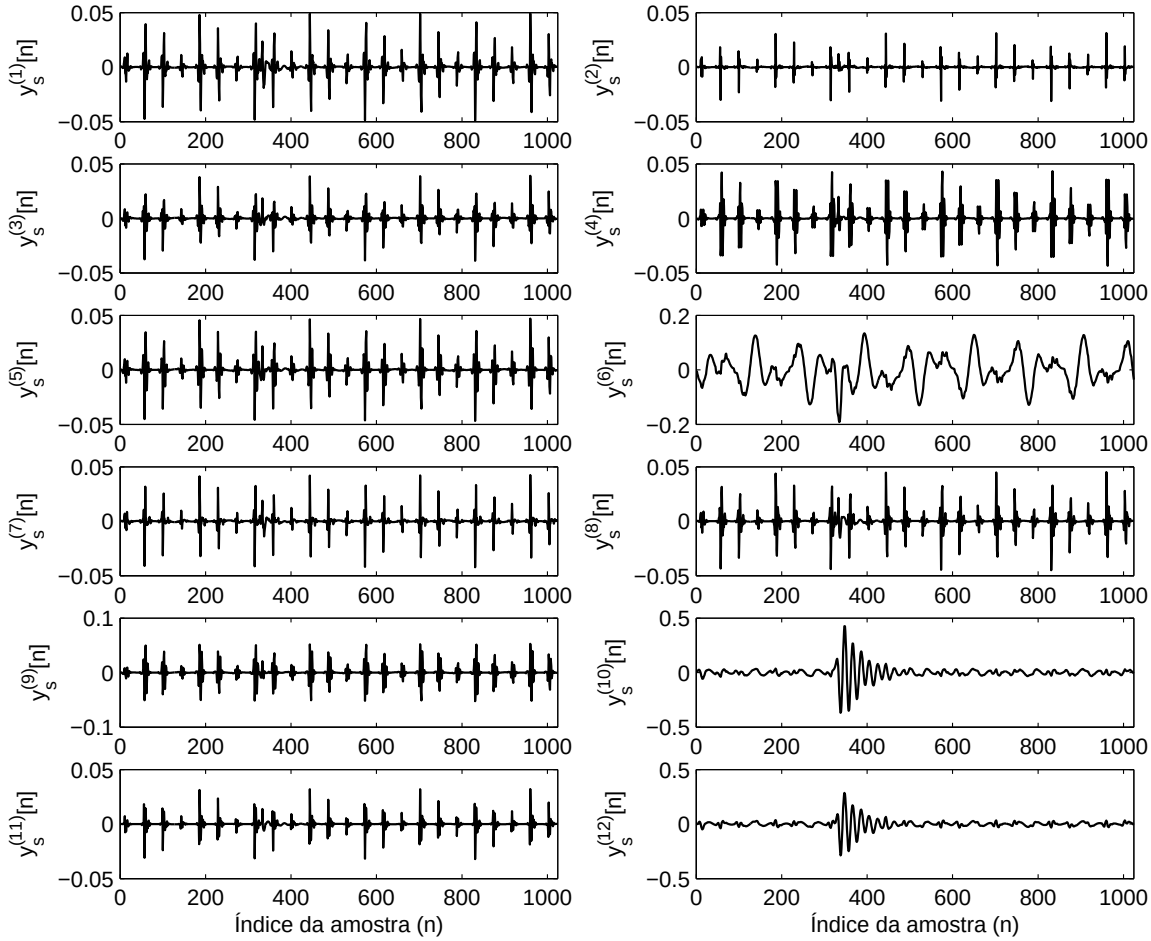


Figura 5.41: Estimativas de componentes independentes com escalas recuperadas: transitório oscilatório, *notchings* e harmônicos.

dos valores de energia ao longo das 16 faixas de frequência, calculados para cada estimativa $y_s^{(p)}[n]$.

A Figura 5.42 também mostra o resultado do agrupamento dos vetores de energias dentro dos *clusters* $\gamma_1$, $\gamma_2$ e $\gamma_3$. O resultado revela que os vetores associados aos componentes independentes $y_s^{(2)}[n]$ e $y_s^{(6)}[n]$ foram agrupados dentro do *cluster* $\gamma_1$, os vetores associados aos componentes independentes $y_s^{(10)}[n]$ e $y_s^{(12)}[n]$ foram agrupados dentro do *cluster* $\gamma_3$, e os vetores associados aos demais componentes independentes foram todos agrupados dentro do *cluster* $\gamma_2$.

De fato, voltando-se à análise da Figura 5.41, observa-se que as estimativas de componentes independentes $y_s^{(10)}[n]$ e $y_s^{(12)}[n]$ são mais associadas ao transitório oscilatório. Entretanto, visualmente, a estimativa $y_s^{(2)}[n]$ parece ser mais associada aos *notchings*, embora tenha sido

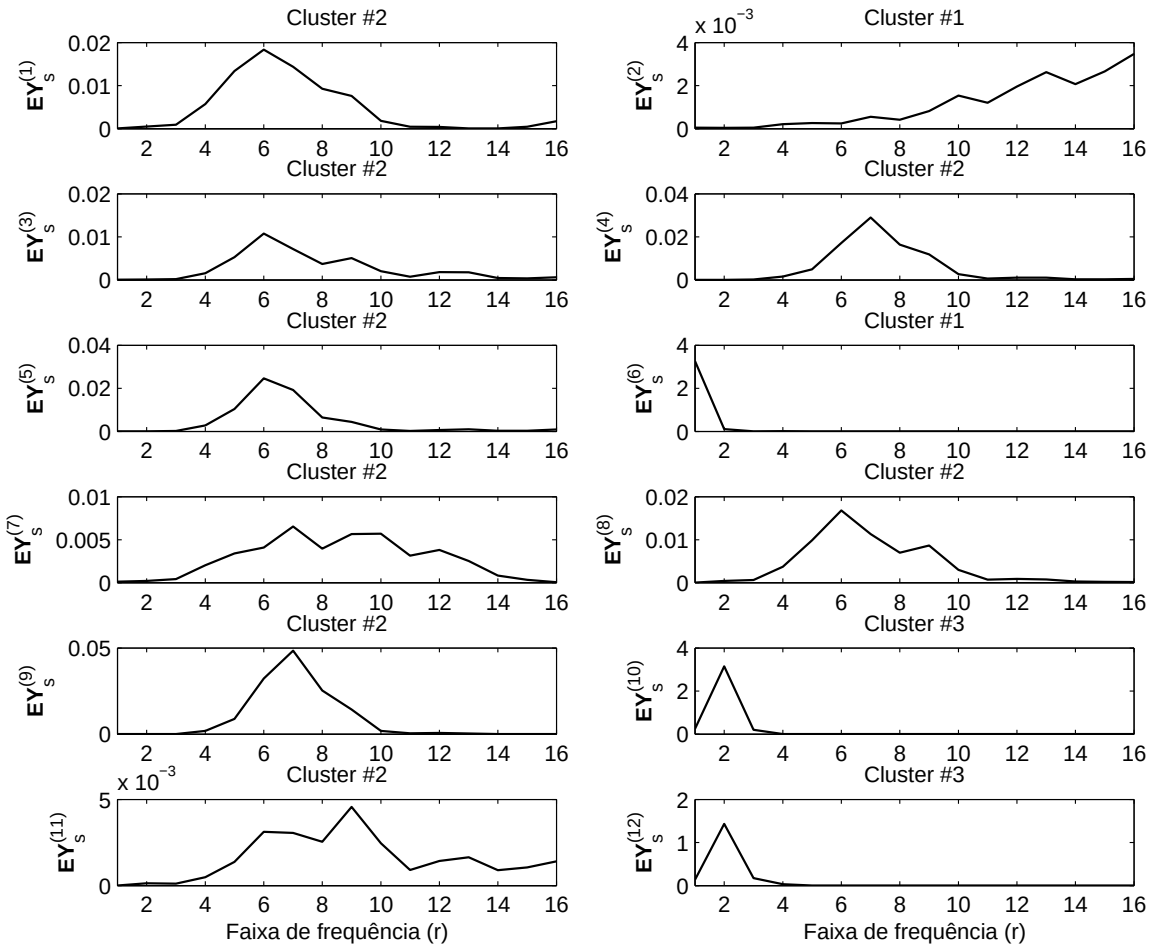


Figura 5.42: Vetores de energias calculados para as estimativas de componentes independentes, com o respectivo agrupamento pelo algoritmo *k-means* baseado em suas similaridades espectrais: transitório oscilatório, *notchings* e harmônicos.

agrupada junto com a estimativa $y_s^{(6)}[n]$, a qual é mais associada aos harmônicos. Visualmente, todas as demais estimativas de componentes independentes são mais associadas aos *notchings*, e foram todas agrupadas juntas. Ao observar o vetor de energias $\mathbf{EY}_s^{(2)}$ na Figura 5.42, percebe-se visualmente que não há similaridade espectral do mesmo com o vetor $\mathbf{EY}_s^{(6)}$. Na verdade, percebe-se que há uma maior similaridade do vetor $\mathbf{EY}_s^{(2)}$ com aqueles que foram agrupados dentro do *cluster* $\gamma_2$ (*notchings*). Sendo assim, a princípio, parece que o algoritmo *k-means* agrupou o componente $y_s^{(2)}[n]$ dentro do *cluster* errado. A seguir, serão vistos os resultados a que esse agrupamento originou.

O próximo passo é somar todos os componentes independentes associados a cada *cluster*, $\gamma_1$, $\gamma_2$ e $\gamma_3$, para obter, respectivamente, os sinais $y_{\mathrm{rec}_1}[n]$, $y_{\mathrm{rec}_2}[n]$ e $y_{\mathrm{rec}_3}[n]$. Os sinais obtidos através

desta operação são mostrados na Figura 5.43, sendo comparados às fontes originais $s_1[n]$, $s_2[n]$ e $s_3[n]$. Observa-se que $y_{\text{rec}_3}[n]$ é uma estimativa mais associada ao transitório oscilatório (fonte $s_1[n]$). Por outro lado, $y_{\text{rec}_2}[n]$ é uma estimativa mais associada aos *notchings* (fonte $s_2[n]$). Finalmente, $y_{\text{rec}_1}[n]$ é uma estimativa mais associada aos harmônicos (fonte $s_3[n]$). Entretanto, observa-se em $y_{\text{rec}_1}[n]$ uma certa contaminação de *notchings*, justamente porque o resultado do algoritmo *k-means* levou erroneamente à soma de $y_s^{(2)}[n]$ e $y_s^{(6)}[n]$, embora $y_s^{(2)}[n]$ seja uma estimativa mais associada aos *notchings*, como foi visto na Figura 5.41.

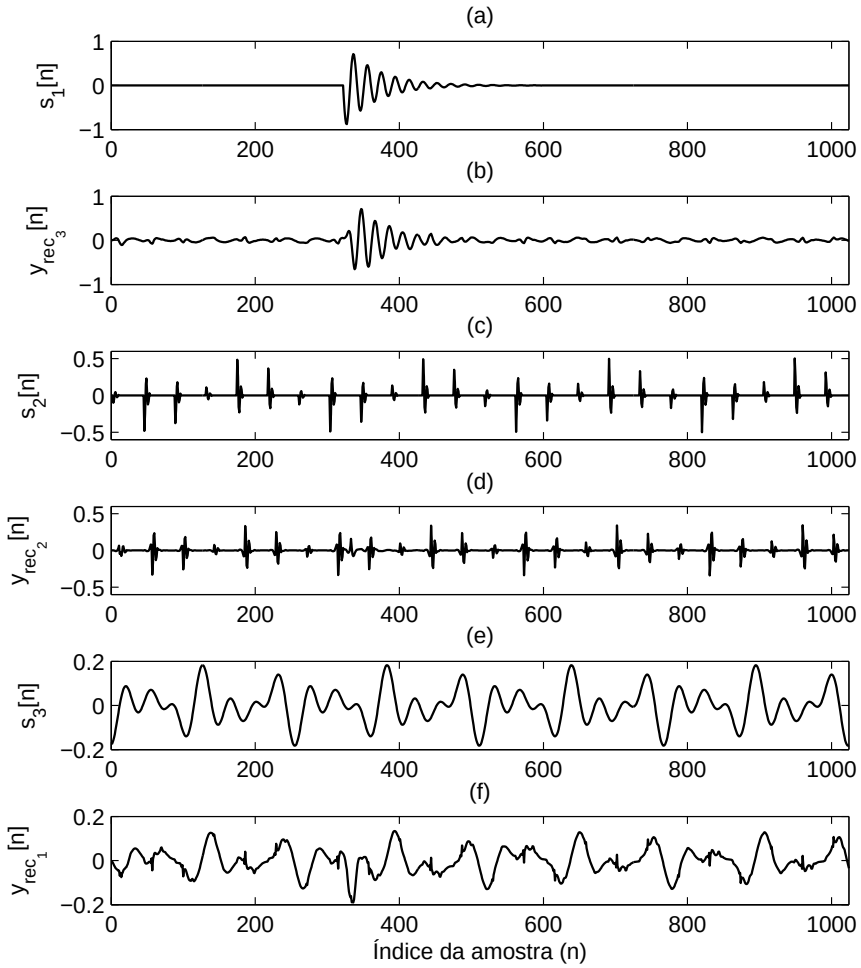


Figura 5.43: Componentes separados e reconstruídos utilizando-se o método SCICA; (a) transitório oscilatório original, (b) $y_{\text{rec}_3}[n]$, (c) *notchings* originais, (d) $y_{\text{rec}_2}[n]$, (e) harmônicos originais e, (f) $y_{\text{rec}_1}[n]$.

A Figura 5.44 mostra os módulos das respostas em frequência dos filtros adaptativos $f_1[n]$, $f_2[n]$ e $f_3[n]$, obtidos pela aplicação do método SCICA ao sinal $x[n]$. Pode ser observado que

o filtro $f_1[n]$, responsável por obter $y_{\text{rec}_1}[n]$ por meio da filtragem de $x[n]$, deixa passar razoavelmente bem todas as frequências dos harmônicos, e atenua bem as principais frequências do transitório oscilatório e dos *notchings*. A notável elevação no ganho desse filtro para as frequências mais altas dos *notchings* é responsável pela contaminação de $y_{\text{rec}_1}[n]$ por este distúrbio. Mais uma vez, este fato vem em consequência do erro cometido pelo algoritmo *k-means* durante a etapa de agrupamento. O filtro $f_2[n]$, responsável por obter $y_{\text{rec}_2}[n]$ por meio da filtragem de $x[n]$, atenua bem as frequências dos harmônicos e do transitório oscilatório, e passa com ganhos próximos de 1 as principais frequências dos *notchings*. Finalmente, o filtro $f_3[n]$, responsável por obter $y_{\text{rec}_3}[n]$ por meio da filtragem de $x[n]$, atenua razoavelmente bem as frequências dos harmônicos e atenua bem as principais frequências dos *notchings*, e passa com ganhos próximos de 1 as principais frequências do transitório oscilatório. Tais resultados estão de acordo com aqueles mostrados na Figura 5.43.

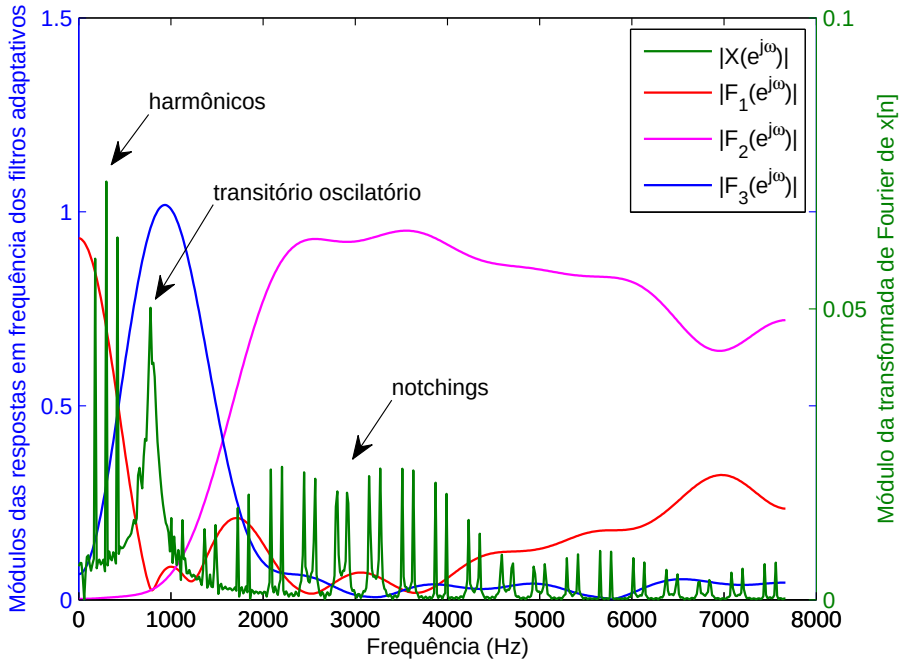


Figura 5.44: Módulos das respostas em frequência dos filtros adaptativos resultantes da operação do método SCICA, e espectro de frequências do sinal $x[n]$: transitório oscilatório, *notchings* e harmônicos.

A Figura 5.45 mostra o resultado obtido para a decomposição do sinal $x[n]$ quando definidos $C = 2$ *clusters* a serem estimados pelo algoritmo *k-means*, mantendo-se $M = 12$ e $\tau = 1$. Portanto, neste caso, tem-se menos estimativas obtidas do que distúrbios presentes em $x[n]$, estando mais de um distúrbio presente em uma mesma estimativa. Observa-se que a estimativa $y_{\text{rec}_1}[n]$

carrega mais intensamente informações simultâneas do transitório oscilatório e dos harmônicos, e a estimativa $y_{\text{rec}_2}[n]$ carrega informações mais associadas aos *notchings*.

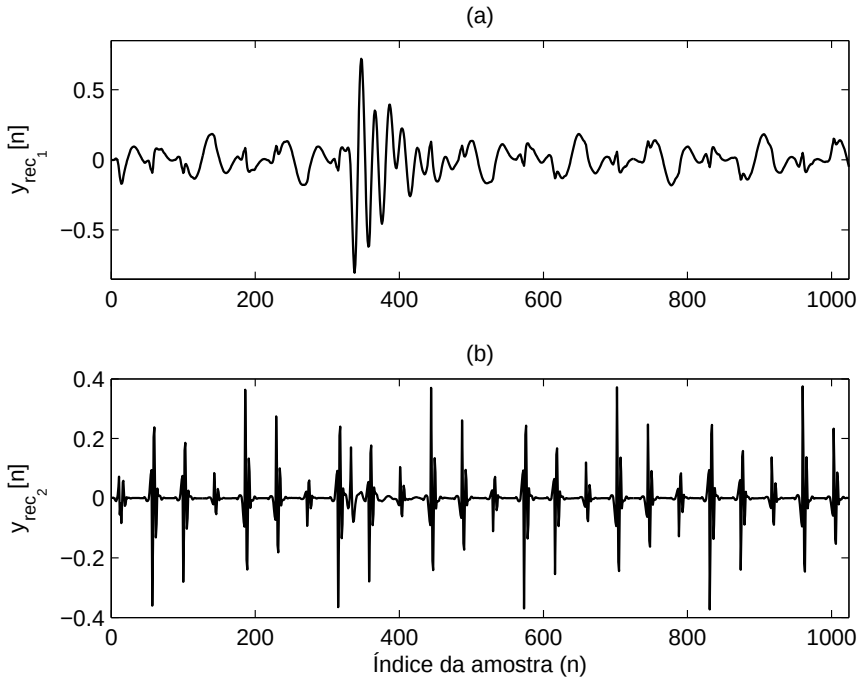


Figura 5.45: Componentes separados e reconstruídos utilizando-se o método SCICA, para $C = 2$ *clusters*; (a) $y_{\text{rec}_1}[n]$, (b) $y_{\text{rec}_2}[n]$ e, (c) $y_{\text{rec}_3}[n]$.

Para esta simulação, os vetores de energia da Figura 5.42 foram automaticamente reagrupados pelo algoritmo *k-means* dentro dos dois *clusters* mostrados abaixo:

$$\gamma_1 = \{\mathbf{EY}_s^{(6)}, \mathbf{EY}_s^{(10)}, \mathbf{EY}_s^{(12)}\},$$

$$\gamma_2 = \{\mathbf{EY}_s^{(1)}, \mathbf{EY}_s^{(2)}, \mathbf{EY}_s^{(3)}, \mathbf{EY}_s^{(4)}, \mathbf{EY}_s^{(5)}, \mathbf{EY}_s^{(7)}, \mathbf{EY}_s^{(8)}, \mathbf{EY}_s^{(9)}, \mathbf{EY}_s^{(11)}\}.$$

Consequentemente, observa-se que as respectivas estimativas de componentes independentes da Figura 5.41 associadas ao *cluster* $\gamma_1$ são relacionadas ao transitório oscilatório ou aos harmônicos, e as respectivas estimativas associadas ao *cluster* $\gamma_2$ são todas relacionadas aos *notchings*. Observou-se que, para $C$ menor do que o número de distúrbios presentes em $x[n]$, aqueles distúrbios que possuem espectros de frequências mais estreitos foram agrupados juntos dentro de um mesmo sub-espaço independente.

**Resultados alcançados para outras combinações de múltiplos distúrbios**

Os resultados de simulações realizadas até aqui mostraram de uma forma detalhada o funcionamento de todas as etapas internas de cada um dos métodos propostos, desde a aplicação do sinal de entrada até a obtenção dos sinais de saída. Nesta seção, serão apresentados, de uma forma sucinta e direta, os resultados de decomposição alcançados, por ambos os métodos, para outras combinações de múltiplos distúrbios.

Para os exemplos apresentados nesta seção, utilizar-se-á os mesmos parâmetros de entrada para os métodos FICA e SCICA utilizados anteriormente para as decomposições dos sinais contendo combinações de dois distúrbios, através de dois sinais de saída.

O primeiro exemplo trata-se da decomposição de um sinal de tensão contendo harmônicos e um transitório impulsivo. A Figura 5.46(a) mostra o referido sinal. As Figuras 5.46(b) e (c) mostram os sinais de saída obtidos pelo método FICA, e as Figuras 5.46(d) e (e) mostram os sinais de saída obtidos pelo método SCICA. As formas de onda reais dos distúrbios que compõem o sinal de entrada são também mostradas, para comparação com as estimativas obtidas. Observa-se que ambos os métodos conseguiram razoavelmente separar os distúrbios. Em ambos os métodos, a primeira estimativa expressa de forma mais acentuada o transitório impulsivo, e a segunda estimativa expressa de forma mais acentuada os harmônicos.

O próximo exemplo trata-se da decomposição de um sinal de tensão contendo *notchings* e um transitório impulsivo. A Figura 5.47(a) mostra o sinal de entrada, as Figuras 5.47(b) e (c) mostram os sinais de saída do método FICA, e as Figuras 5.47(d) e (e) mostram os sinais de saída do método SCICA. Como pode ser observado, para esta combinação de distúrbios, os resultados de separação obtidos por ambos os métodos são piores do que para todas as combinações já apresentadas até então. A estimativa obtida pelo método FICA mais correlacionada ao transitório impulsivo rejeita bem os *notchings*, mas também atenua bastante o próprio transitório impulsivo. Já a estimativa obtida também pelo método FICA que é mais correlacionada aos *notchings* recupera bem este distúrbio, mas também deixa passar o transitório impulsivo. Com relação às estimativas obtidas pelo método SCICA, observa-se que há uma maior sobreposição entre os dois distúrbios em ambas, mas a primeira estimativa realça mais os *notchings*, e a segunda estimativa realça mais o transitório impulsivo.

O próximo exemplo trata-se da decomposição de um sinal de tensão contendo ambos transitórios impulsivo e oscilatório. A Figura 5.48(a) mostra o sinal de entrada, as Figuras 5.48(b)

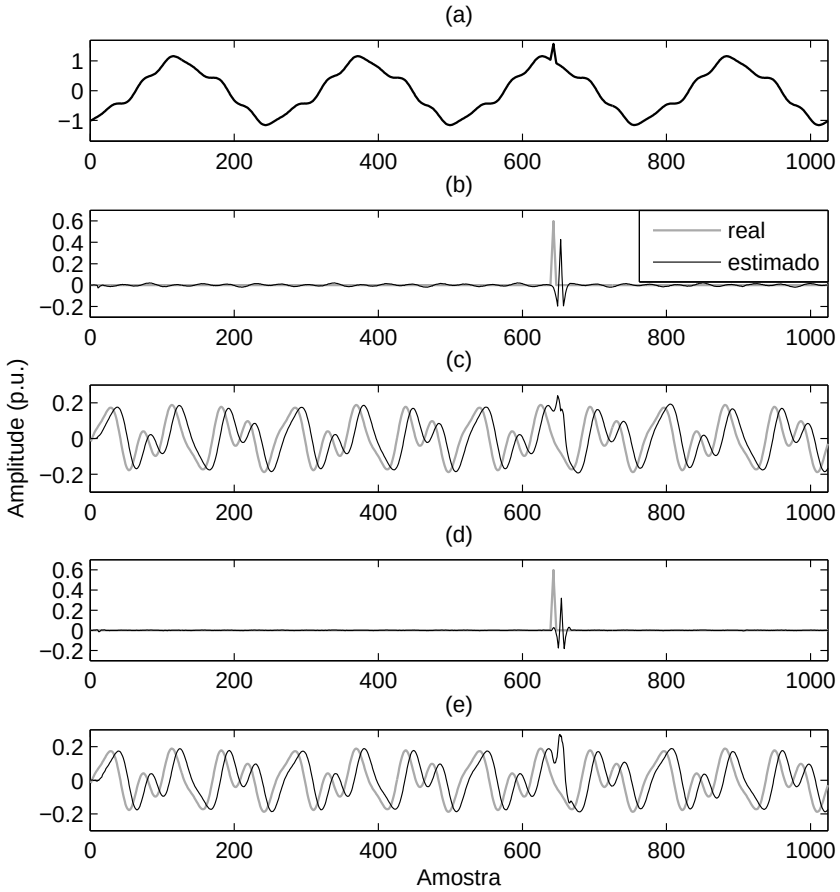


Figura 5.46: Decomposição de um sinal contendo harmônicos e um transitório impulsivo; (a) sinal de entrada, (b) e (c) resultados obtidos pelo método FICA e, (d) e (e) resultados obtidos pelo método SCICA.

e (c) mostram os sinais de saída do método FICA, e as Figuras 5.48(d) e (e) mostram os sinais de saída do método SCICA. Percebe-se que em ambos os métodos, a primeira estimativa obtida é mais correlacionada ao transitório oscilatório, e a segunda estimativa obtida é mais correlacionada ao transitório impulsivo, embora a separação não tenha sido perfeita.

### Análise quantitativa

A série de resultados de simulações apresentados até aqui mostrou uma análise qualitativa detalhada dos métodos FICA e SCICA, aplicados a diversos sinais contendo múltiplos distúrbios de QEE. A seguir, serão apresentados alguns resultados quantitativos de comparação entre os dois métodos. Os resultados serão também capazes de mostrar que, na maioria dos casos, a aplicação de qualquer um dos dois métodos resulta na obtenção de sinais que se aproximam mais das formas de onda dos distúrbios individuais do que o sinal de erro.

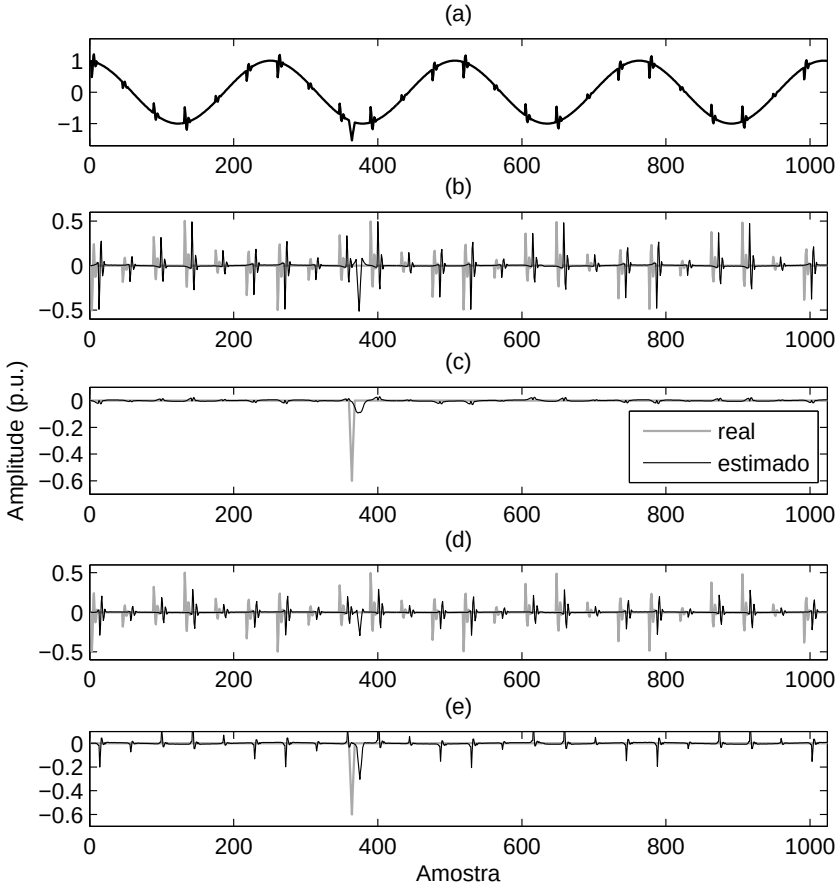


Figura 5.47: Decomposição de um sinal contendo *notchings* e transitório impulsivo; (a) sinal de entrada, (b) e (c) resultados obtidos pelo método FICA e, (d) e (e) resultados obtidos pelo método SCICA.

Para a obtenção dos resultados apresentados nesta seção, procedeu-se com a aplicação da seguinte metodologia:

1. Inicialmente, gerou-se 100 sinais diferentes de forma independente para cada combinação de distúrbios.

2. Realizou-se, em seguida, a decomposição desses sinais através das metodologias baseadas nos métodos FICA e SCICA.

3. Calculou-se os coeficientes de correlação entre as estimativas obtidas por ambos os métodos e as formas de onda originais dos distúrbios individuais.

4. Calculou-se o coeficiente de correlação entre o sinal de erro e as formas de onda originais dos distúrbios individuais.

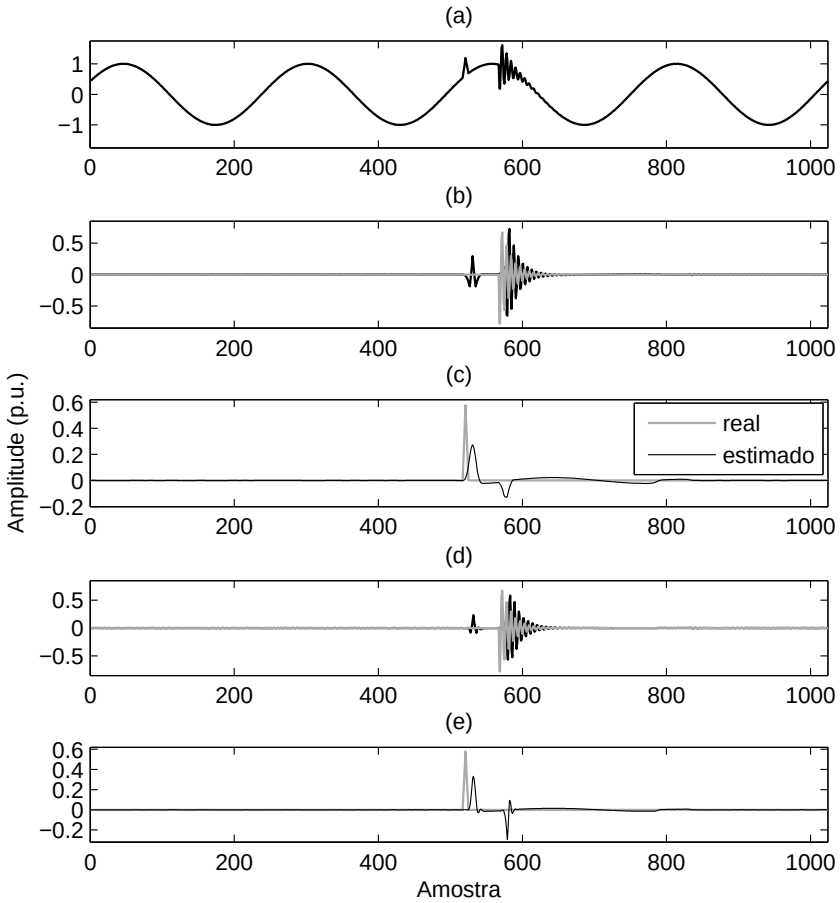


Figura 5.48: Decomposição de um sinal contendo transitórios oscilatório e impulsivo; (a) sinal de entrada, (b) e (c) resultados obtidos pelo método FICA e, (d) e (e) resultados obtidos pelo método SCICA.

A Figura 5.49 mostra os resultados obtidos para a decomposição de diferentes sinais contendo simultaneamente *notchings* e harmônicos. A Figura 5.49(a) mostra os valores dos coeficientes de correlação entre cada uma das parcelas originais dos distúrbios e suas respectivas estimativas, obtidas pelo método FICA. A Figura 5.49(b) mostra os mesmos resultados, porém para as estimativas obtidas pelo método SCICA. A Figura 5.49(c) mostra os valores dos coeficientes de correlação entre cada uma das parcelas originais dos distúrbios e o sinal de erro, o qual é o sinal imediatamente anterior à aplicação dos métodos FICA ou SCICA.

Primeiramente, observa-se que ambos os métodos obtiveram resultados muito bons para todos os sinais de entrada, mostrando que para diferentes sinais contendo a presença simultânea de harmônicos e *notchings*, ambos são sempre capazes de estimar adequadamente cada um dos distúrbios. Além disso, ambos os métodos foram capazes de obter estimativas mais próximas de cada um dos distúrbios originais do que o próprio sinal de erro, já que para ambos, os coe-

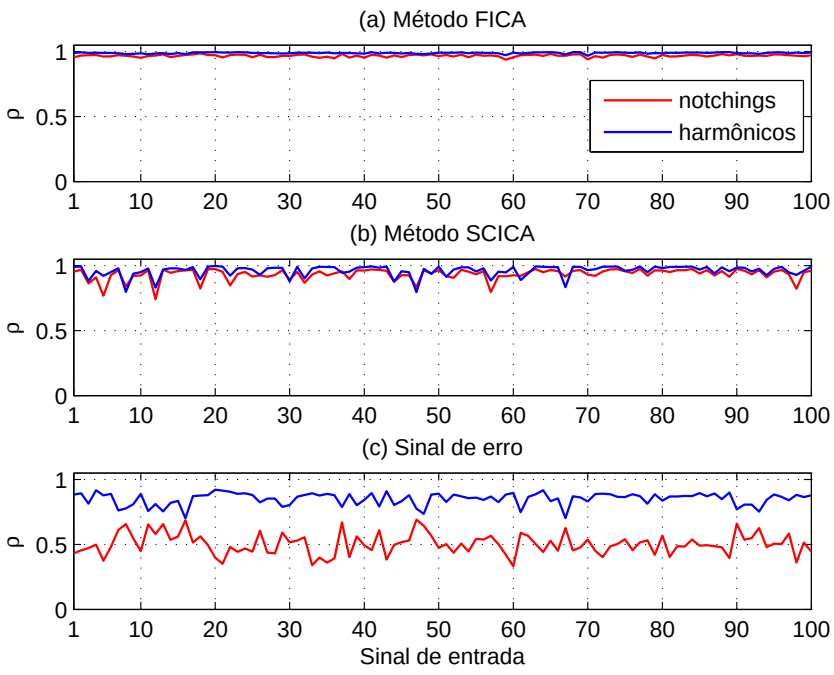


Figura 5.49: Coeficientes de correlação para decomposições de sinais contendo *notchings* e harmônicos; (a) método FICA, (b) método SCICA e, (c) sem decomposição.

ficientes de correlação obtidos foram maiores do que em relação ao sinal de erro. Isso mostra que a aplicação de qualquer um dos dois métodos leva à obtenção de sinais que se correlacionam melhor com as formas de onda dos distúrbios isolados originais do que o próprio sinal no qual esses distúrbios se encontram misturados. Finalmente, observa-se que para esta combinação de distúrbios, o método FICA obteve resultados de separação ligeiramente superiores ao método SCICA, já que os valores de $\rho$ para o primeiro método são mais próximos de 1. Mais precisamente, $\rho > 0,9$ para 100% dos sinais obtidos pelo método FICA, e $\rho > 0,9$ para 88,5% dos sinais obtidos pelo método SCICA.

A Figura 5.50 mostra os resultados obtidos para a decomposição de diferentes sinais contendo simultaneamente transitório oscilatório e harmônicos. A Figura 5.50(a) mostra os valores dos coeficientes de correlação entre cada uma das parcelas originais dos distúrbios e suas respectivas estimativas, obtidas pelo método FICA. A Figura 5.50(b) mostra os mesmos resultados, porém para as estimativas obtidas pelo método SCICA. A Figura 5.50(c) mostra os valores dos coeficientes de correlação entre cada uma das parcelas originais dos distúrbios e o sinal de erro.

Para esta combinação de distúrbios, observa-se também que ambos os métodos levam à obtenção de estimativas mais correlacionadas aos distúrbios originais do que o sinal de erro,

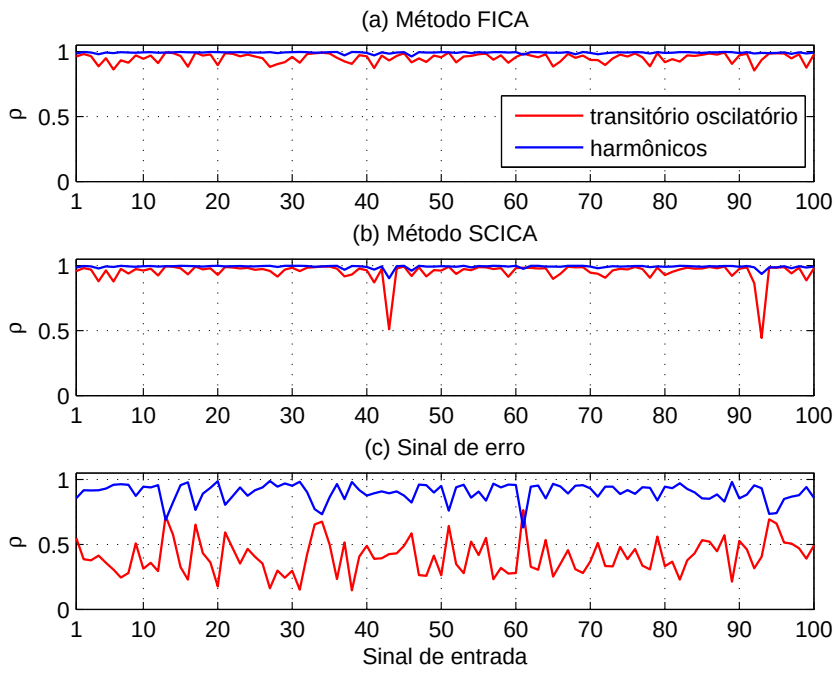


Figura 5.50: Coeficientes de correlação para decomposições de sinais contendo transitório oscilatório e harmônicos; (a) método FICA, (b) método SCICA e, (c) sem decomposição.

justificando assim as suas aplicações. Para 94,5% dos sinais estimados pelo método FICA, foi encontrado $\rho > 0,9$. Para 96% dos sinais estimados pelo método SCICA, foi encontrado $\rho > 0,9$. Embora de uma maneira geral os resultados alcançados pelo método SCICA tenham sido melhores, percebe-se que para dois sinais de entrada, as estimativas mais correlacionadas ao transitório oscilatório apresentaram $\rho$ em torno de 0,5. Este fato é resultado de agrupamentos errôneos realizados pelo algoritmo *k-means*, interno à etapa de agrupamento do método SCICA.

A Figura 5.51 mostra os resultados obtidos para a decomposição de diferentes sinais contendo simultaneamente transitório impulsivo e harmônicos. A Figura 5.51(a) mostra os valores dos coeficientes de correlação entre cada uma das parcelas originais dos distúrbios e suas respectivas estimativas, obtidas pelo método FICA. A Figura 5.51(b) mostra os mesmos resultados, porém para as estimativas obtidas pelo método SCICA. A Figura 5.51(c) mostra os valores dos coeficientes de correlação entre cada uma das parcelas originais dos distúrbios e o sinal de erro.

Para esta combinação de distúrbios, como pôde também ser observado nos resultados da Figura 5.46, as estimativas dos transitórios impulsivos possuem uma certa distorção em relação ao distúrbio real, para ambos os métodos. Por isso, os resultados de correlação para a estimação deste distúrbio são piores do que para aqueles que já foram apresentados até agora nesta

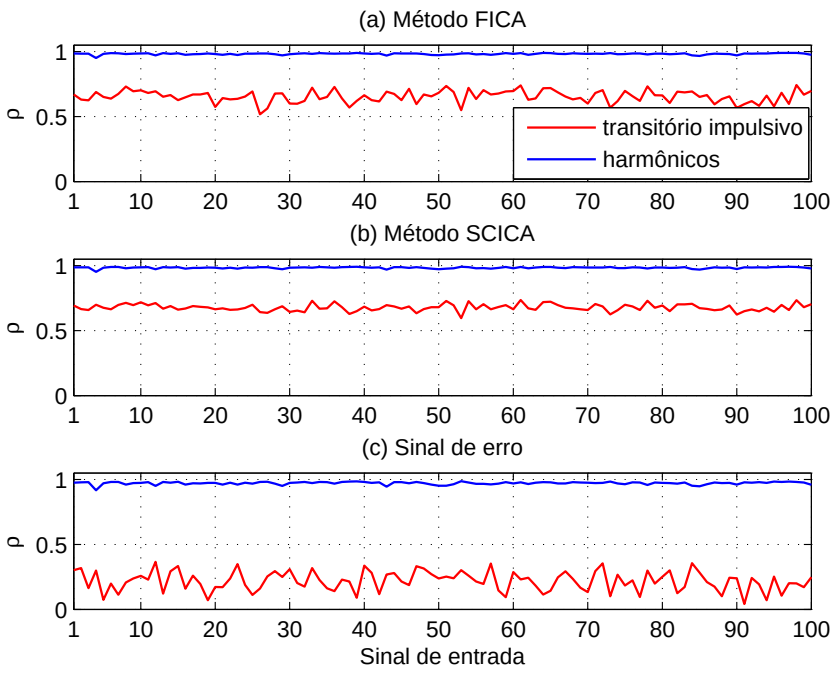


Figura 5.51: Coeficientes de correlação para decomposições de sinais contendo transitório impulsivo e harmônicos; (a) método FICA, (b) método SCICA e (c) sem decomposição.

seção. As estimativas de harmônicos sempre apresentam correlação alta com o distúrbio real porque, mesmo que não sejam totalmente separadas do transitório impulsivo, a grande maioria do sinal é composta por informações dos próprios harmônicos, como pôde ser observado nas Figuras 5.46(c) e (e). Mesmo assim, deve se chamar a atenção de que a aplicação dos métodos de decomposição nos sinais contendo esses dois distúrbios também é válida, pois como pode se observar na Figura 5.51, as correlações calculadas entre as estimativas de transitórios impulsivos e os distúrbios reais obtidas por ambos os métodos são maiores do que as correlações calculadas entre o sinal de erro e os distúrbios reais. Mais precisamente, $\rho > 0,5$ para todas as estimativas de transitório impulsivo obtidas por ambos os métodos, e $\rho < 0,5$ para todas as correlações entre este distúrbio e o sinal de erro.

A Figura 5.52 mostra os resultados obtidos para a decomposição de diferentes sinais contendo simultaneamente ambos transitórios impulsivo e oscilatório. A Figura 5.52(a) mostra os valores dos coeficientes de correlação entre cada uma das parcelas originais dos distúrbios e suas respectivas estimativas, obtidas pelo método FICA. A Figura 5.52(b) mostra os mesmos resultados, porém para as estimativas obtidas pelo método SCICA. A Figura 5.52(c) mostra os valores dos coeficientes de correlação entre cada uma das parcelas originais dos distúrbios e o sinal de erro.

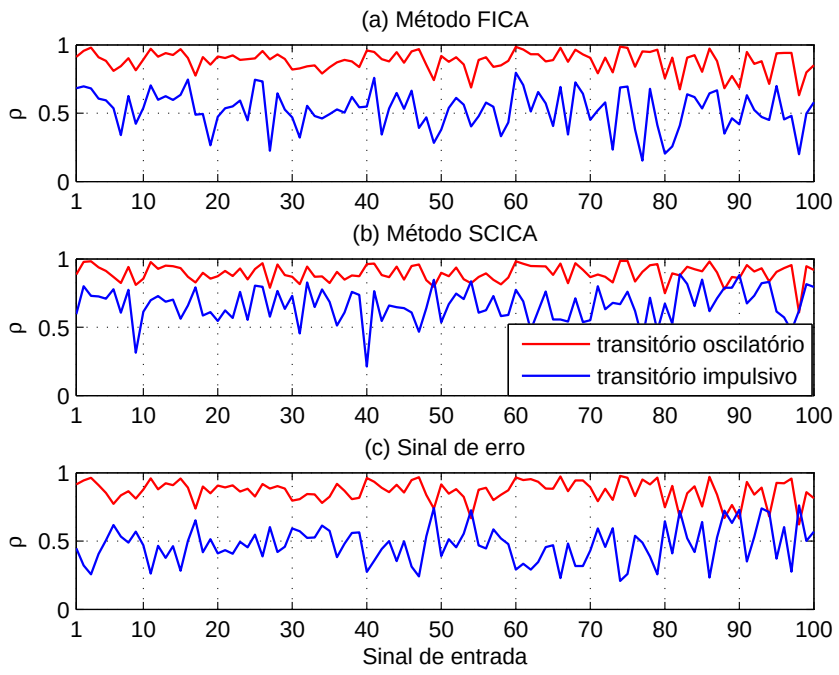


Figura 5.52: Coeficientes de correlação para decomposições de sinais contendo transitórios oscilatório e impulsivo; (a) método FICA, (b) método SCICA e, (c) sem decomposição.

Como pode ser observado, para esta combinação de distúrbios, há uma maior oscilação dos valores de $\rho$ para os diferentes sinais de entrada decompostos. Isto ocorre porque, sendo ambos os distúrbios do tipo transitórios, os erros de estimação que porventura possam ocorrer por parte dos métodos de decomposição afetam mais os valores de $\rho$. Observa-se este fato principalmente para as estimativas do transitório impulsivo, que é mais curto ainda que o transitório oscilatório. Embora o coeficiente de correlação seja uma métrica que talvez não seja muito adequada para expressar a qualidade da separação entre estes dois tipos de distúrbios, pôde ser visto nos resultados da Figura 5.48 que a aplicação dos métodos de decomposição pode obter estimativas que expressem cada distúrbio individual melhor do que o sinal de entrada e consequentemente o sinal de erro. Para as decomposições realizadas pelo método FICA, foi obtido $\rho > 0,5$ para 79,5% dos dados. Para as decomposições realizadas pelo método SCICA, foi obtido $\rho > 0,5$ para 96% dos dados. Já para o sinal de erro, foi obtido $\rho > 0,5$ para 71% dos dados. Desta forma, o método SCICA foi o que obteve melhores estimativas dos distúrbios isolados.

A Figura 5.53 mostra os resultados obtidos para a decomposição de diferentes sinais contendo simultaneamente transitório impulsivo e *notchings*. A Figura 5.53(a) mostra os valores dos coeficientes de correlação entre cada uma das parcelas originais dos distúrbios e suas respectivas estimativas, obtidas pelo método FICA. A Figura 5.53(b) mostra os mesmos resultados,

porém para as estimativas obtidas pelo método SCICA. A Figura 5.53(c) mostra os valores dos coeficientes de correlação entre cada uma das parcelas originais dos distúrbios e o sinal de erro.

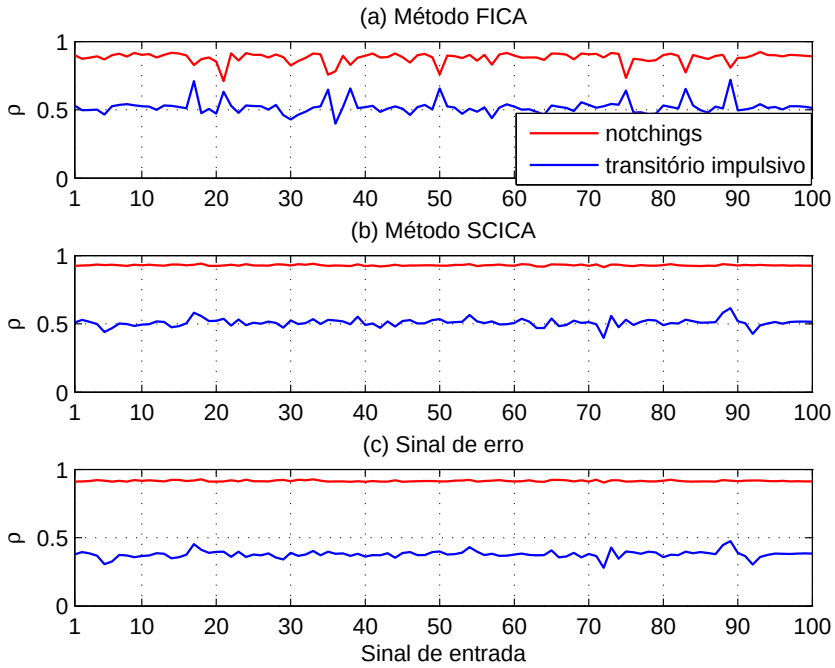


Figura 5.53: Coeficientes de correlação para decomposições de sinais contendo *notchings* e transitório impulsivo; (a) método FICA, (b) método SCICA e, (c) sem decomposição.

Percebe-se que os valores de $\rho$ são sempre maiores para as estimativas dos *notchings* do que para as estimativas dos transitórios impulsivos. Isto ocorre pelos mesmos motivos comentados para as separações entre transitórios impulsivos e os outros distúrbios já apresentadas. O transitório impulsivo, sendo um distúrbio muito curto, tem o cálculo do coeficiente de correlação prejudicado, por menor que seja a distorção em sua estimativa. Como pôde ser também visto nos resultados da Figura 5.47 para a decomposição de um sinal contendo os dois distúrbios, as estimativas mais correlacionadas ao transitório impulsivo não recuperam muito bem este distúrbio, mas ainda assim são capazes de certa forma de destacá-lo em relação ao outro distúrbio. Já as estimativas mais correlacionadas aos *notchings* sempre mantêm grande informação a seu respeito, levando sempre à obtenção de altos valores de $\rho$. Nos resultados da Figura 5.53, para as estimativas de transitório impulsivo obtidas pelo método FICA, foi encontrado $\rho > 0,5$ para 73% dos dados. Já para as estimativas de transitório impulsivo obtidas pelo método SCICA, $\rho > 0,5$ para 69% dos dados. Já para o sinal de erro, não houve nenhum sinal de entrada para o qual fosse obtido $\rho > 0,5$ em relação ao transitório impulsivo. Sendo assim, ambos os métodos obtiveram resultados semelhantes para esta combinação de distúrbios, discretamente melhores

do que o sinal de erro.

Finalmente, a Figura 5.54 mostra os resultados obtidos para a decomposição de diferentes sinais contendo simultaneamente transitório oscilatório e *notchings*. A Figura 5.54(a) mostra os valores dos coeficientes de correlação entre cada uma das parcelas originais dos distúrbios e suas respectivas estimativas, obtidas pelo método FICA. A Figura 5.54(b) mostra os mesmos resultados, porém para as estimativas obtidas pelo método SCICA. A Figura 5.54(c) mostra os valores dos coeficientes de correlação entre cada uma das parcelas originais dos distúrbios e o sinal de erro.

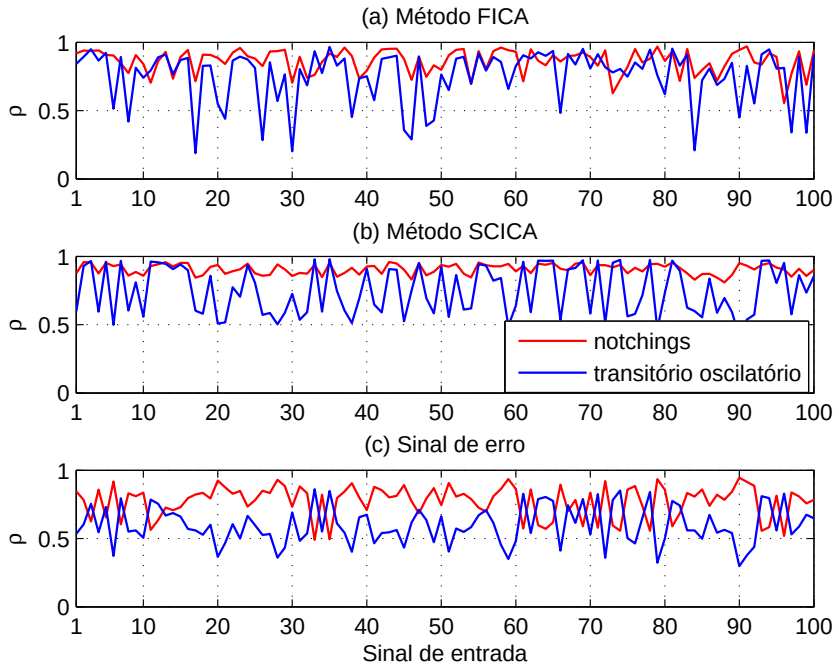


Figura 5.54: Coeficientes de correlação para decomposições de sinais contendo transitório oscilatório e *notchings*; (a) método FICA, (b) método SCICA e, (c) sem decomposição.

Percebe-se para esta combinação de distúrbios que há uma alternância grande entre estimativas dos transitórios oscilatórios bem correlacionadas com os distúrbios reais e estimativas não tão bem correlacionadas. Já para os *notchings*, as estimativas são sempre bem correlacionadas com os distúrbios reais, para ambos os métodos. No entanto, para as estimativas obtidas pelo método FICA, $\rho > 0,7$ para 85% dos sinais de entrada, e para as estimativas obtidas pelo método SCICA, $\rho > 0,7$ para 77% desses sinais. Já para o sinal de erro, $\rho > 0,7$ para apenas 50,05% dos mesmos sinais. Portanto, também para esta combinação de distúrbios, justifica-se a aplicação dos métodos de decomposição para obter estimativas que se correlacionem mais com os distúrbios isolados do que o próprio sinal no qual ambos se encontram misturados.

### 5.3.3 Aplicação das metodologias propostas em dados reais

Finalmente, esta seção apresenta a aplicação das metodologias de decomposição propostas em sinais reais.

A Figura 5.55(a) mostra um sinal de tensão real medido na entrada de um retificador trifásico de seis pulsos, obtido de Electrotek Concepts, Inc. (2013). O sinal foi medido na fase $A$ do retificador. Como pode ser observado, o sinal contém a presença de *notchings*, provocados pela comutação não instantânea de corrente entre os diodos do retificador, devido especialmente à impedância da linha de alimentação do circuito, a qual na prática é principalmente indutiva (Mohan *et al.*, 1995). Além disso, o sinal também contém a presença de harmônicos, devido à própria não-linearidade da carga. Esta carga faz circular correntes distorcidas através da impedância da linha de alimentação, consequentemente distorcendo também a tensão no seu ponto de conexão ao SEP.

O sinal medido foi amostrado com uma frequência $f_S = 20$ kHz, e o seu componente fundamental possui frequência $f_0 = 60$ Hz. A análise a seguir irá empregar as metodologias propostas para realizar a decomposição do referido sinal, e na sequência será realizada uma comparação entre as decomposições do sinal de erro $x[n]$ realizadas pelos métodos FICA e SCICA. A Figura 5.55(b) mostra a estimativa do componente fundamental $f[n]$ obtida pelo filtro *notch*, e a Figura 5.55(c) mostra o sinal de erro $x[n]$ resultante. Visualiza-se neste a presença simultânea dos harmônicos e dos *notchings*.

Visando analisar o comportamento dos métodos FICA e SCICA sem alterar seus parâmetros internos, as mesmas configurações utilizadas nos exemplos com dados sintéticos contendo dois distúrbios serão mantidas aqui para decompor o sinal $x[n]$. Deve-se lembrar que, para o método FICA, $M = 2$ filtros fixos, sendo o filtro $h_1[n]$ do tipo passa-todas e o filtro $h_2[n]$ do tipo passa-altas com $f_C = 300$ Hz, sendo ambos os filtros de ordem $K = 20$. Para o método SCICA, $M = 12$ sinais de observação, $\tau = 1$ amostra de atraso, $C = 2$ *clusters* e $R = 16$ faixas de frequência, o que proporciona uma largura de banda $L = 625$ Hz para cada faixa de frequência.

As Figuras 5.56(a) e (b) mostram, respectivamente, as estimativas $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_2}[n]$ obtidas pelo método FICA. As Figuras 5.56(c) e (d) mostram, respectivamente, as estimativas $y_{\text{rec}_1}[n]$ e $y_{\text{rec}_2}[n]$ obtidas pelo método SCICA.

A princípio, pode-se observar que ambos os métodos decompuseram satisfatoriamente o sinal $x[n]$ em componentes capazes de expressar cada um dos distúrbios de forma mais exclusiva do

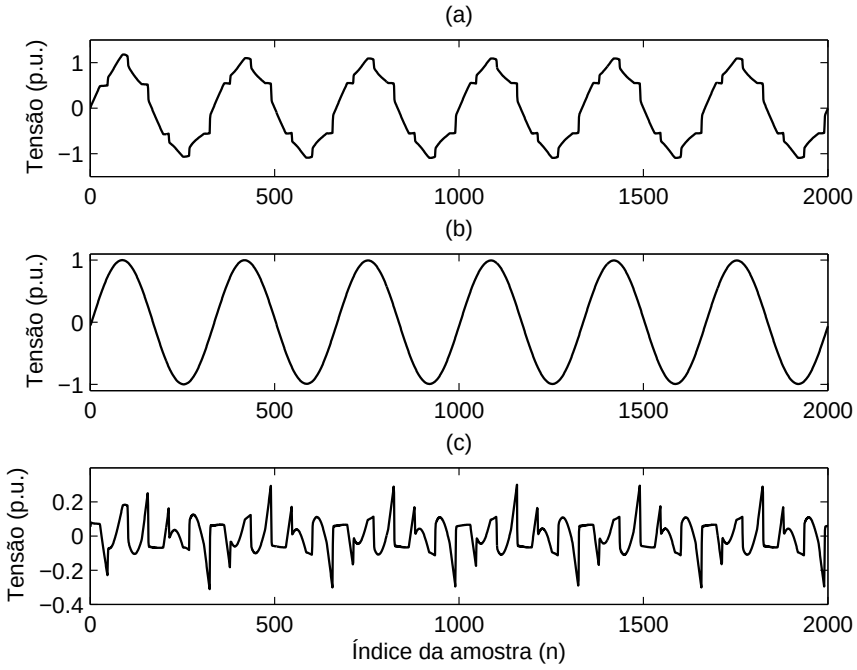


Figura 5.55: Sinal de tensão real medido na entrada de um retificador trifásico de seis pulsos; (a) sinal de entrada $u[n]$ (tensão da fase $A$), (b) estimativa do componente fundamental $f[n]$ e, (c) sinal de erro $x[n] = u[n] - f[n]$.

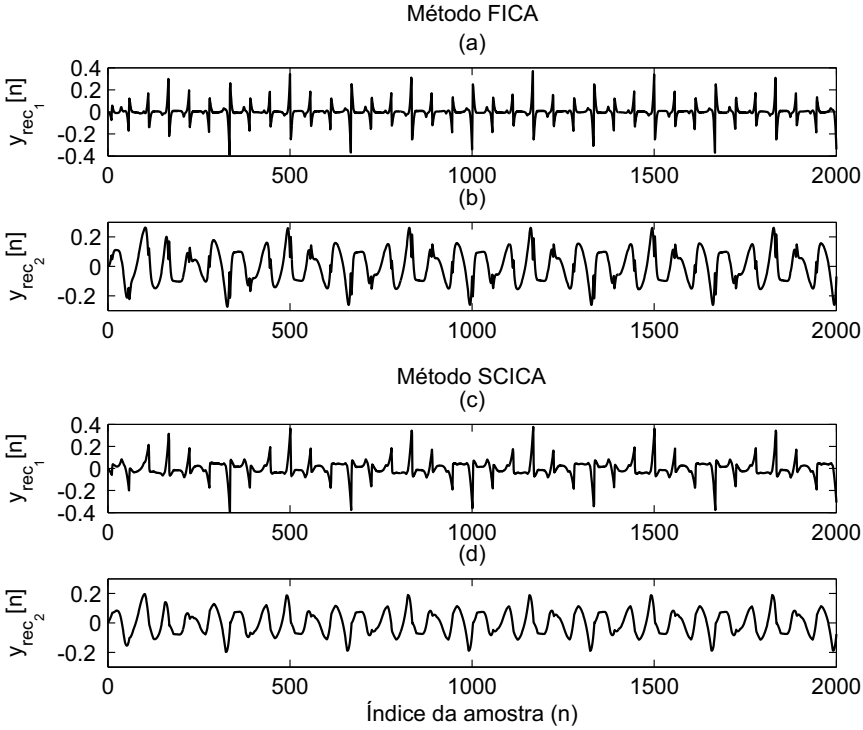


Figura 5.56: Comparação das decomposições do sinal $x[n]$ obtidas pelos métodos FICA e SCICA; (a) e (b) sinais de saída do método FICA, (c) e (d) sinais de saída do método SCICA.

que o próprio sinal $x[n]$. A estimativa $y_{\text{rec}_1}[n]$ para ambos os métodos explicita os *notchings*, e a estimativa $y_{\text{rec}_2}[n]$ também para ambos os métodos explicita os harmônicos.

A análise dos resultados alcançados pode ser melhor interpretada no domínio da frequência. Em um retificador trifásico de seis pulsos, os componentes harmônicos pares e múltiplos triplos do componente fundamental são nulos. As ordens harmônicas mais importantes que caracterizam o distúrbio são: 5ª, 7ª, 11ª e 13ª (Mohan *et al.*, 1995). De uma forma geral, as frequências acima de 2 kHz contêm muito pouca informação sobre este distúrbio (Dugan *et al.*, 2004). Já os componentes de frequência associados aos *notchings* são de ordens mais elevadas.

A Figura 5.57 compara as respostas em frequência dos filtros adaptativos de decomposição obtidos pelos dois métodos, sendo que a Figura 5.57(a) mostra os filtros obtidos pelo método FICA e a Figura 5.57(b) mostra os filtros obtidos pelo método SCICA.

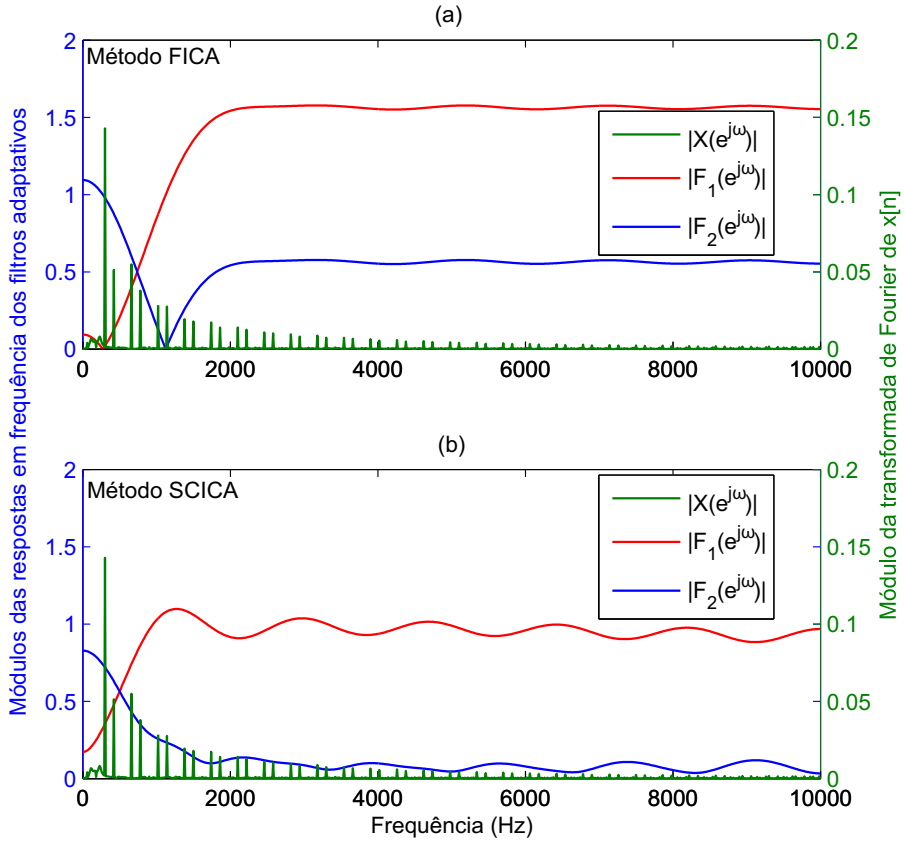


Figura 5.57: Comparação dos módulos das respostas em frequência dos filtros adaptativos de decomposição obtidos pelos métodos FICA e SCICA; (a) método FICA e, (b) método SCICA.

Como pode ser observado na Figura 5.57(a), o filtro $f_1[n]$, responsável por obter $y_{\text{rec}_1}[n]$ a partir da filtragem de $x[n]$, atenua as frequências mais importantes que caracterizam os harmônicos e amplifica as frequências acima de 2 kHz, onde basicamente há informação relevante apenas

dos *notchings*. Entretanto, o ideal seria que a faixa de passagem do filtro apresentasse ganho unitário, de forma a recuperar a amplitude correta do distúrbio. Já o filtro $f_2[n]$, responsável por obter $y_{\text{rec}_2}[n]$ a partir da filtragem de $x[n]$, passa a frequência de maior energia dos harmônicos (5º harmônico) com ganho unitário, e passa também as demais frequências que caracterizam este distúrbio, porém com ganhos menores que 1. Entretanto, percebe-se que para as altas frequências, as quais contém informação dos *notchings*, este filtro não as rejeita completamente, apresentando um ganho constante próximo a 0,5 para as mesmas. Por este motivo, observa-se na estimativa da Figura 5.56(b) a contaminação por informações dos *notchings*.

Por outro lado, como pode ser observado na Figura 5.57(b), o filtro $f_1[n]$ encontrado pelo método SCICA atenua bem, mas não completamente, as frequências que caracterizam os harmônicos. Porém, o mesmo filtro passa com ganhos em torno de 1 os componentes de altas frequências, onde se concentram as informações dos *notchings*. Já o filtro $f_2[n]$ encontrado pelo mesmo método atenua pouco as frequências dos harmônicos e atenua de maneira bem mais intensa as frequências dos *notchings*.

A comparação realizada mostra que ambos os métodos obtiveram resultados interessantes para a decomposição deste sinal real, mas de uma maneira geral, a separação alcançada pelo método SCICA se mostrou melhor, já que os filtros adaptativos obtidos pelo mesmo foram mais seletivos do que aqueles obtidos pelo método FICA.

O próximo exemplo apresenta a decomposição do sinal de corrente real já apresentado na Figura 2.2(a), tendo sido o mesmo obtido de IEEE P1159.3 Task Force (2013). A Figura 5.58(a) mostra o sinal novamente, que tem frequência fundamental igual a 60 Hz, e foi amostrado com uma frequência $f_S = 7680$ Hz. Pode ser visto que o sinal possui uma forte distorção harmônica, além de um transitório oscilatório. Realizando-se uma análise mais minuciosa, pode ser visto que o sinal também possui diversos transitórios impulsivos, que são repetidos periodicamente. As metodologias propostas são então aplicadas nesta forma de onda de forma a realizar a sua decomposição. A Figura 5.58(b) mostra a estimativa do componente fundamental encontrada pelo filtro *notch*, e a Figura 5.58(c) mostra o sinal de erro $x[n]$ resultante.

A partir da análise visual realizada no sinal de entrada $u[n]$, é assumido portanto que restam três distúrbios (harmônicos, transitório oscilatório e diversos transitórios impulsivos) no sinal de erro. Assim sendo, para o método FICA, o banco de filtros fixos será o mesmo utilizado para a decomposição dos sinais sintéticos usando $M = 3$: $h_1[n]$ é um filtro passa-todas, $h_2[n]$ é um filtro passa-altas com $f_C = 300$ Hz e $h_3[n]$ é um filtro passa-baixas com $f_C = 1000$ Hz, todos com a

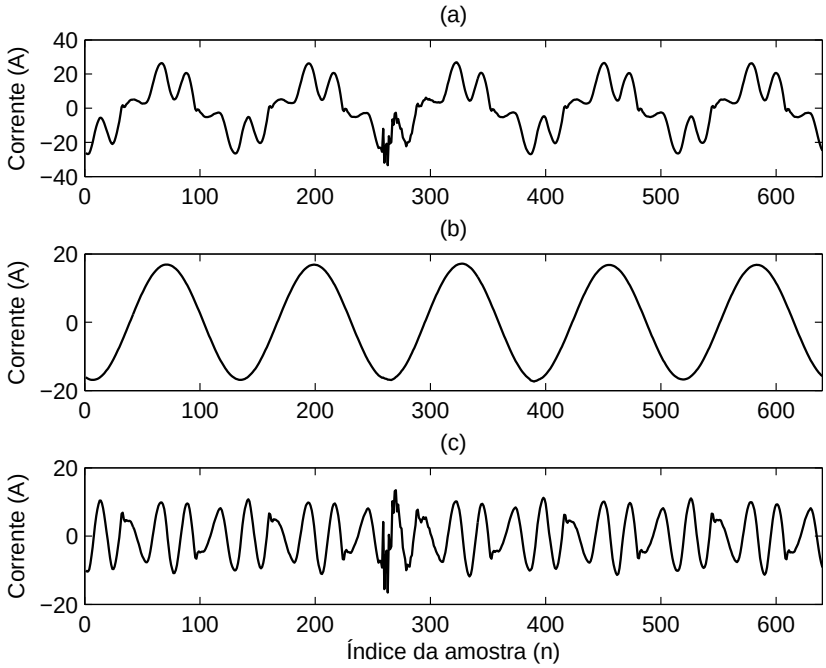


Figura 5.58: Sinal de corrente real; (a) sinal de entrada $u[n]$, (b) estimativa do componente fundamental $f[n]$ e, (c) sinal de erro $x[n] = u[n] - f[n]$.

mesma ordem $K = 20$. Para o método SCICA, $M = 12$ sinais de observação, $\tau = 1$ amostra de atraso, $C = 3$ *clusters* e $R = 16$ faixas de frequência, o que proporciona uma largura de banda $L = 240$ Hz para cada faixa de frequência.

As Figuras 5.59(a), (b) e (c) mostram as estimativas obtidas pelo método FICA, e as Figuras 5.59(d), (e) e (f) mostram as estimativas obtidas pelo método SCICA.

Observa-se que o componente $y_{\mathrm{rec}_1}[n]$ obtido tanto por um método quanto pelo outro é uma estimativa mais correlacionada com o transitório oscilatório, embora na estimativa obtida pelo método FICA haja uma pequena contaminação por parte dos transitórios impulsivos. Já o componente $y_{\mathrm{rec}_2}[n]$ obtido tanto por um método quanto pelo outro é uma estimativa mais correlacionada com os transitórios impulsivos, embora na estimativa obtida pelo método FICA haja uma sobreposição considerável de frequências dos harmônicos. Por outro lado, o componente $y_{\mathrm{rec}_3}[n]$ obtido tanto por um método quanto pelo outro é uma estimativa mais correlacionada com os harmônicos. A partir desta análise preliminar, observa-se que o método SCICA alcançou melhores resultados de separação também para este sinal real. A seguir, será realizada uma análise das respostas em frequência dos filtros de decomposição adaptativos encontrados por ambos os métodos.

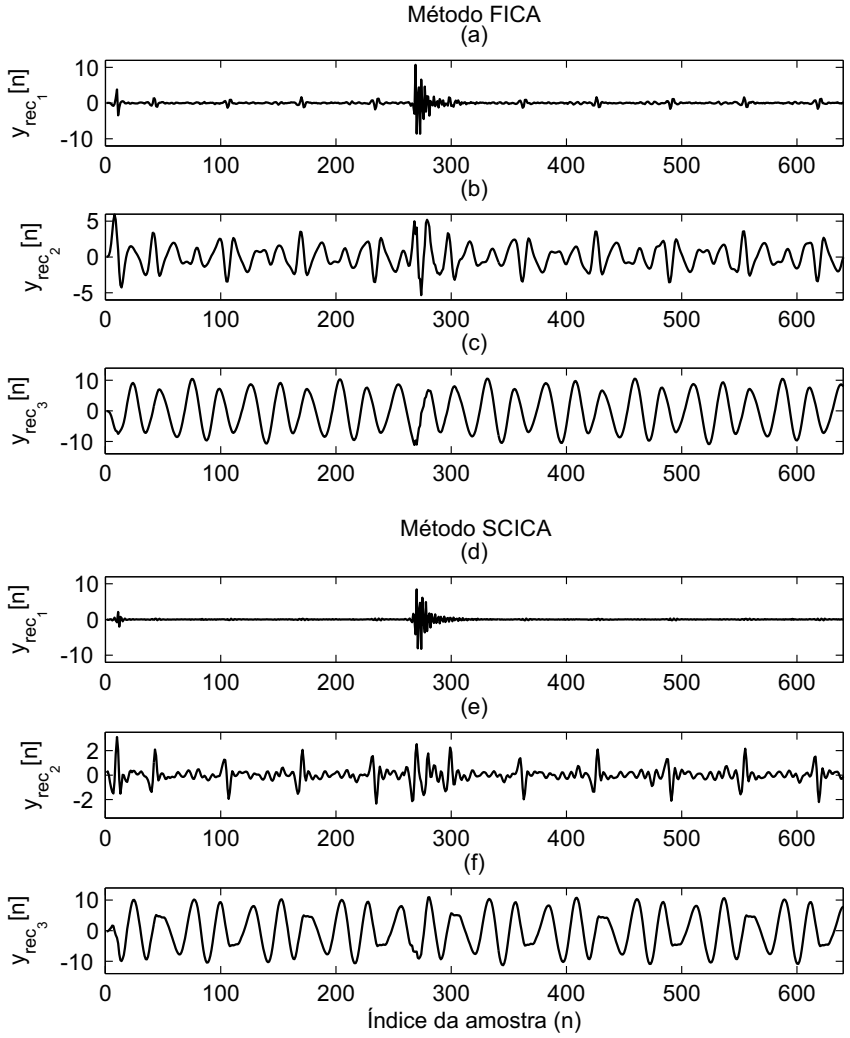


Figura 5.59: Comparação das decomposições do sinal $x[n]$ obtidas pelos métodos FICA e SCICA; (a), (b) e (c) sinais de saída do método FICA; (d), (e) e (f) sinais de saída do método SCICA.

A Figura 5.60(a) mostra os módulos das respostas em frequência dos filtros resultantes da aplicação do método FICA ao sinal de erro $x[n]$. Como pode ser observado, o filtro $f_1[n]$, responsável por obter $y_{\text{rec}_1}[n]$, rejeitou bem as baixas frequências, onde estão localizados os harmônicos (3ª, 5ª, 7ª e 9ª ordens), e também rejeitou parcialmente as frequências intermediárias, onde estão localizados os transitórios impulsivos. Além disso, este filtro passou com ganho unitário as altas frequências, onde se encontra o transitório oscilatório, cujas frequências principais estão localizadas um pouco antes de 3000 Hz. Já o filtro $f_2[n]$, responsável por obter $y_{\text{rec}_2}[n]$, atenuou as frequências dos harmônicos e do transitório oscilatório, e deixou passar as frequências do transitório impulsivo. Entretanto, percebe-se que este filtro não rejeita completamente as frequências dos harmônicos e do transitório oscilatório, o que justifica a presença de ambos os distúrbios na respectiva estimativa na Figura 5.59(b). Por fim, o filtro $f_3[n]$, responsável por

obter $y_{\text{rec}_3}[n]$, passa parcialmente as frequências dos harmônicos e atenua bem as frequências relacionadas aos demais distúrbios.

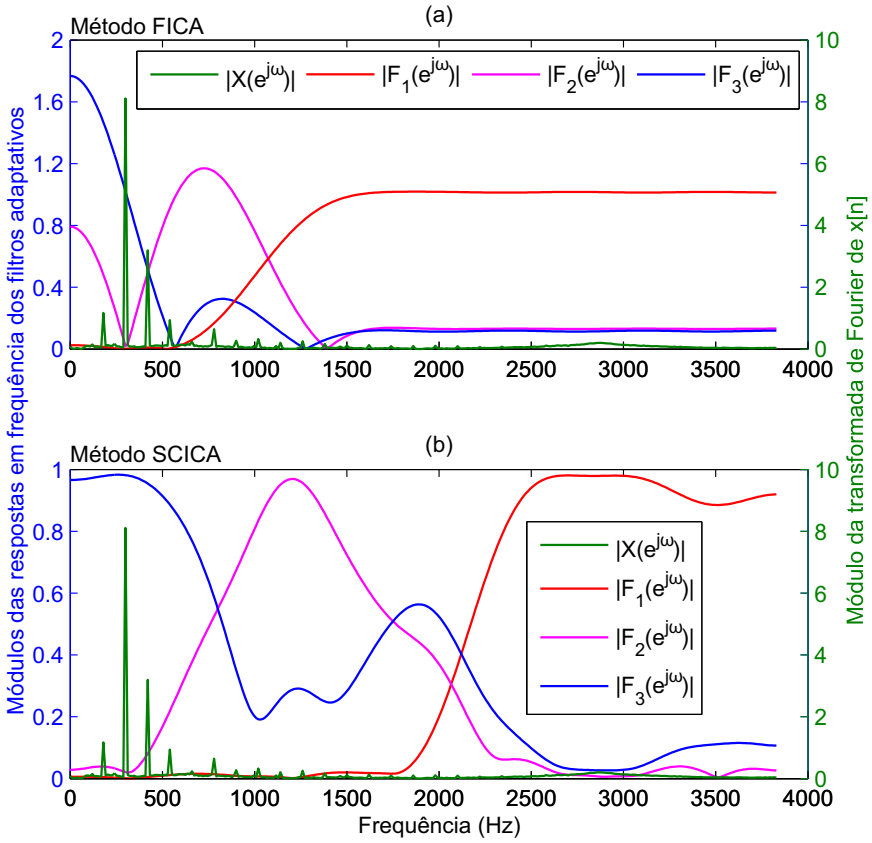


Figura 5.60: Comparação dos módulos das respostas em frequência dos filtros de decomposição adaptativos obtidos pelos métodos FICA e SCICA; (a) método FICA e, (b) método SCICA.

A Figura 5.60(b) mostra os módulos das respostas em frequência dos filtros resultantes da aplicação do método SCICA ao sinal de erro $x[n]$. Observa-se que o filtro $f_1[n]$ neste caso rejeita muito bem tanto as frequências dos harmônicos quanto dos transitórios impulsivos, e passa com ganhos próximos da unidade as frequências do transitório oscilatório. Já o filtro $f_2[n]$ atenua muito bem as frequências dos harmônicos e do transitório oscilatório, e passa com ganhos próximos de 1 as frequências dos transitórios impulsivos. Finalmente, o filtro $f_3[n]$ passa com ganhos próximos de 1 as frequências dos harmônicos, atenua razoavelmente bem as frequências dos transitórios impulsivos e atenua bem as frequências do transitório oscilatório.

De uma forma geral, pode-se concluir também para este sinal real que as decomposições realizadas por ambos os métodos propostos conseguiram fornecer resultados que evidenciaram melhor do ponto de vista individual cada um dos distúrbios contidos no sinal analisado, com um desempenho melhor de separação a favor do método SCICA, já que este gerou filtros adaptativos

de decomposição que separaram melhor as bandas de frequência dos diferentes distúrbios.

## 5.4 Considerações finais do capítulo

Este capítulo apresentou uma metodologia capaz de decompor uma forma de onda de tensão ou corrente do SEP de maneira não-supervisionada. O sistema inicialmente estima e separa o componente fundamental do sinal através de um filtro *notch*, e em seguida estima os componentes independentes do sinal de erro através do método FICA ou do método SCICA. A metodologia foi aplicada em sinais sintéticos e reais contendo múltiplos distúrbios de QEE, onde pôde ser observado que a mesma é capaz de separar e reconstruir com grande exatidão as formas de onda dos distúrbios individuais que não possuem sobreposição espectral. Entretanto, mesmo quando há sobreposição parcial dos espectros dos distúrbios, a metodologia é ainda capaz de obter estimativas que se aproximam mais das formas de onda dos distúrbios individuais do que o sinal de erro. Ambos os métodos FICA e SCICA obtiveram desempenhos bem semelhantes, com uma ligeira superioridade do método SCICA. O próximo capítulo propõe uma metodologia para classificação dos sinais resultantes da aplicação do sistema de decomposição proposto neste capítulo, sendo a sua função reconhecer automaticamente o tipo de distúrbio que cada estimativa obtida representa.

# Capítulo 6

# Classificação de múltiplos distúrbios de QEE

Neste capítulo, será proposta uma metodologia cujo objetivo é a classificação dos distúrbios presentes nos sinais decompostos pela metodologia apresentada no Capítulo 5, tanto utilizando o método FICA quanto o método SCICA. A idéia é utilizar em tal metodologia ferramentas mais simples do que as utilizadas pelos métodos convencionais de classificação de múltiplos distúrbios, já que se espera que a utilização da metodologia de decomposição proposta no Capítulo 5 leve a soluções mais simples do que aquelas que seriam necessárias se a classificação fosse realizada diretamente a partir de um sinal contendo múltiplos distúrbios.

Em geral, a etapa de classificação é precedida por uma etapa de extração de parâmetros ou características representativas que possam levar a uma distinção entre as diferentes classes a serem categorizadas. Os principais objetivos da extração de características para fins de classificação são:

1. Maximizar as fronteiras de separação entre as classes através da extração de parâmetros contendo informações importantes e restritas acerca de cada classe. Estas informações são geralmente extraídas por meio de transformações dos sinais de entrada para um domínio onde a distinção entre as diferentes classes seja mais pronunciada. Típicas ferramentas utilizadas são a DFT, a TWD, a Transformada-$S$, entre outras. Outra forma comum de se extrair informações dos sinais de entrada é utilizando-se estatísticas, tais como a média, a variância, o desvio padrão, o valor RMS, as HOS, etc.

2. Reduzir a dimensão dos dados a serem fornecidos como entrada para a etapa de classificação

de padrões, o que pode levar diretamente à diminuição da complexidade computacional do classificador. A redução da dimensão dos dados pode ser feita diretamente pela extração apenas dos parâmetros desejáveis, quando se tem um conhecimento suficiente sobre o problema, ou utilizando-se ferramentas de seleção de parâmetros, tal como o discriminante linear de Fisher (*Fisher Discriminant Ratio* (FDR)) (Theodoridis e Koutroumbas, 2003) ou a PCA. A aplicação de técnicas de seleção de parâmetros torna a escolha dos melhores parâmetros automática e menos dependente do conhecimento especialista do problema.

A seguir, será apresentado o sistema para classificação de distúrbios decompostos pela metodologia de decomposição baseada no método FICA. Após isto, também será apresentado o sistema para classificação de distúrbios decompostos pela metodologia baseada no método SCICA, sendo que este possui pequenas diferenças em relação ao primeiro sistema de classificação proposto.

## 6.1 Sistema para classificação de distúrbios decompostos pela metodologia baseada no método FICA

A Figura 6.1 apresenta o diagrama de blocos generalizado do sistema proposto para classificação de distúrbios decompostos pela metodologia baseada no método FICA. Como citado anteriormente, o filtro *notch* estima o componente fundamental $f[n]$ do sinal de entrada $u[n]$, e também obtém o sinal de erro $x[n] = u[n] - f[n]$. O sinal $f[n]$ carrega informações que podem distinguir diretamente as classes afundamento, elevação, interrupção e sinal normal (sem distúrbio). Sendo assim, haverá um subsistema dedicado exclusivamente à classificação do componente fundamental. Tal subsistema compreende as etapas: Extração de características 1 e Classificação de padrões 1.

Já o sinal $x[n]$ carrega informações diretas a respeito das demais classes abordadas nesta tese, ou seja, harmônicos, transitório impulsivo, transitório oscilatório e *notchings*. O classificador será projetado considerando-se que tais distúrbios possam ocorrer tanto isoladamente quanto simultaneamente. Desta forma, neste sistema será utilizado o método FICA para realizar a decomposição do sinal $x[n]$, com a consequente obtenção dos sinais $y_{\mathrm{rec}_1}[n], \ldots, y_{\mathrm{rec}_P}[n]$. Estes, por sua vez, serão fornecidos como entradas para o subsistema dedicado à classificação dos distúrbios do sinal $x[n]$, o qual compreenderá as seguintes etapas: Extração de características 2 e Classificação de padrões 2. A seguir, será detalhada cada uma das etapas do sistema de

classificação proposto.

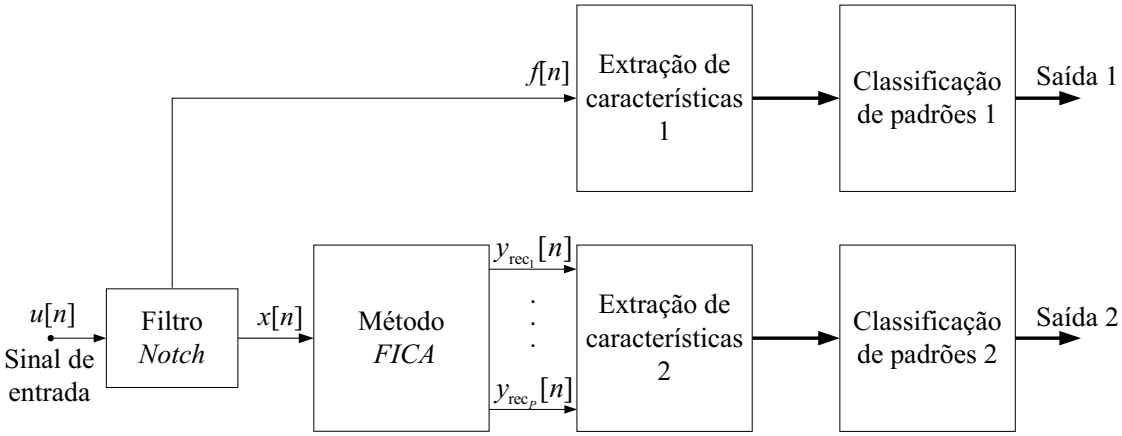


Figura 6.1: Diagrama de blocos generalizado do sistema proposto para classificação de distúrbios decompostos pela metodologia baseada no método FICA.

### 6.1.1 Classificador do distúrbio do sinal $f[n]$

A seguir, será descrito o subsistema responsável pela classificação do componente fundamental do sinal de entrada quanto aos possíveis tipos de distúrbios que o possam afetar, os quais são: afundamento, elevação ou interrupção. Além disso, tal subsistema também deve ser capaz de identificar se o componente fundamental está normal, ou seja, se não ocorreu nenhum dos três distúrbios acima.

#### Módulo Extração de características 1

Como foi visto nas definições dos diferentes tipos de distúrbios de QEE apresentadas no Capítulo 2, o afundamento é caracterizado pela redução da amplitude do componente fundamental da tensão entre 0,1 e 0,9 pu, com duração entre 0,5 ciclo e 1 minuto. Por sua vez, a elevação é caracterizada pelo aumento da amplitude do componente fundamental da tensão entre 1,1 e 1,8 pu, com a mesma faixa de duração do afundamento. Já a interrupção de curta duração ocorre quando a tensão decresce a menos de 0,1 pu por um período de tempo não excedente a 1 min. Por fim, se não há a ocorrência de nenhum dos três distúrbios, não há variação da amplitude do componente fundamental da tensão além da faixa de valores nominais, ou seja, abaixo de 0,9 pu ou acima de 1,1 pu.

Neste trabalho, os afundamentos, as elevações e as interrupções são modelados como variações de tensão de curta duração instantâneas, com duração entre 0,5 ciclo e 4 ciclos, sendo o

comprimento da janela de dados responsável por registrar o sinal de entrada também igual a 4 ciclos.

Assumindo que os tipos de distúrbios acima podem ser reconhecidos através do desvio da amplitude do componente fundamental do sinal de entrada em relação ao seu valor nominal, o valor RMS do mesmo pode vir a ser utilizado como uma estatística eficiente para o devido reconhecimento do tipo de distúrbio que esteja ocorrendo no mesmo.

A fórmula para o cálculo do valor RMS de um sinal de tempo discreto $f[n]$ de comprimento igual a $K$ amostras é (Wang e Bollen, 2004):

$$y_{\text{rms}} = \left( \frac{1}{K} \sum_{k=0}^{K-1} f^2[k] \right)^{\frac{1}{2}}. \tag{6.1}$$

Para um sinal puramente senoidal,

$$f[n] = A_1 \text{sen}(2\pi f_1 n T_S + \delta_1),$$

onde $A_1$ é a amplitude, $f_1$ é a frequência fundamental, $T_S = \frac{1}{f_S}$ é o período de amostragem, $f_S$ é a frequência de amostragem, e $\delta_1$ é o ângulo de fase inicial do sinal. Substituindo $f[n]$ em (6.1), e assumindo que o tamanho da janela $K$ seja múltiplo inteiro da metade do período de $f[n]$, obtém-se

$$y_{\text{rms}} = \frac{A_1}{\sqrt{2}}.$$

Portanto, multiplicando-se o lado direito de (6.1) por $\sqrt{2}$, obtém-se

$$y_{\text{rms}} = A_1,$$

o que expressa diretamente a amplitude do sinal $f[n]$, dentro da janela de $K$ amostras.

Se o tamanho da janela $K$ for múltiplo inteiro da metade do período de $f[n]$, e se o dobro da frequência do sinal $f[n]$ não for múltiplo inteiro da frequência de amostragem, então o erro no cálculo do valor RMS é nulo, independentemente do ângulo inicial $\delta_1$ (Wang e Bollen, 2004). A segunda condição acima é simplesmente uma reformulação do teorema da amostragem. Se ambas as condições acima forem satisfeitas, o cálculo RMS é idêntico à magnitude do componente fundamental e estável, independentemente do deslocamento da janela.

Considerando que as condições acima sejam satisfeitas, neste trabalho utilizar-se-á $J$ janelas

não-superpostas de comprimento $K$ para o cálculo do vetor de valores RMS, de tal forma que

$$J = \frac{N}{K},$$

sendo $N$ o comprimento total do sinal e $K$ um múltiplo inteiro da metade do período de $f[n]$, ou seja,

$$K = \frac{k \cdot f_S}{2f_1},$$

para $k$ sendo um número inteiro entre 1 e $J$. O $j$-ésimo elemento do vetor contendo os valores RMS para $J$ janelas não-superpostas de comprimento $K$ será calculado utilizando-se:

$$\mathbf{y}_{\text{rms}}[j] = \left( \frac{\sqrt{2}}{K} \sum_{n=(j-1)\cdot p_c}^{j\cdot p_c - 1} f^2[n] \right)^{\frac{1}{2}}, \tag{6.2}$$

onde $p_c = \frac{f_S}{2f_1}$ é o número de amostras por meio ciclo do sinal $f[n]$, e $j = 1, 2, \ldots, J$.

Como um exemplo, a Figura 6.2 mostra um sinal de tensão $u[n]$ que apresenta um afundamento e a sua estimativa de componente fundamental $f[n]$ obtida pelo filtro *notch*, sendo a frequência de amostragem $f_S = 15360$ Hz, a frequência fundamental $f_1 = 60$ Hz, e o comprimento total $N = 1024$ amostras. O sinal possui $\frac{f_S}{f_1} = 256$ amostras por ciclo. Escolhendo-se o tamanho da janela para cálculo do valor RMS igual à metade do período de $f[n]$, tem-se então $K = p_c = 128$ amostras, o que resulta em $J = 8$ janelas. Os retângulos na Figura 6.2 ilustram o janelamento do sinal $f[n]$ utilizando-se as oito janelas não-superpostas. Calculando (6.2) para cada janela, obtém-se:

$$\mathbf{y}_{\text{rms}} = [1,00 \quad 1,00 \quad 0,86 \quad 0,47 \quad 0,18 \quad 0,14 \quad 0,14 \quad 0,14].$$

Pode-se observar através dos valores encontrados e na Figura 6.2 que os dois primeiros semiciclos de $f[n]$ não apresentam desvio de amplitude em relação ao seu valor nominal. A partir do terceiro semiciclo, ocorre o distúrbio, o que se reflete na diminuição dos valores RMS até a sua estabilização em 0,14 pu, que se dá após a estabilização do filtro *notch*. De acordo com a definição, o afundamento é caracterizado pela redução da amplitude do componente fundamental da tensão entre 0,1 e 0,9 pu, com duração entre 0,5 ciclo e 1 minuto. Constata-se então, pelos

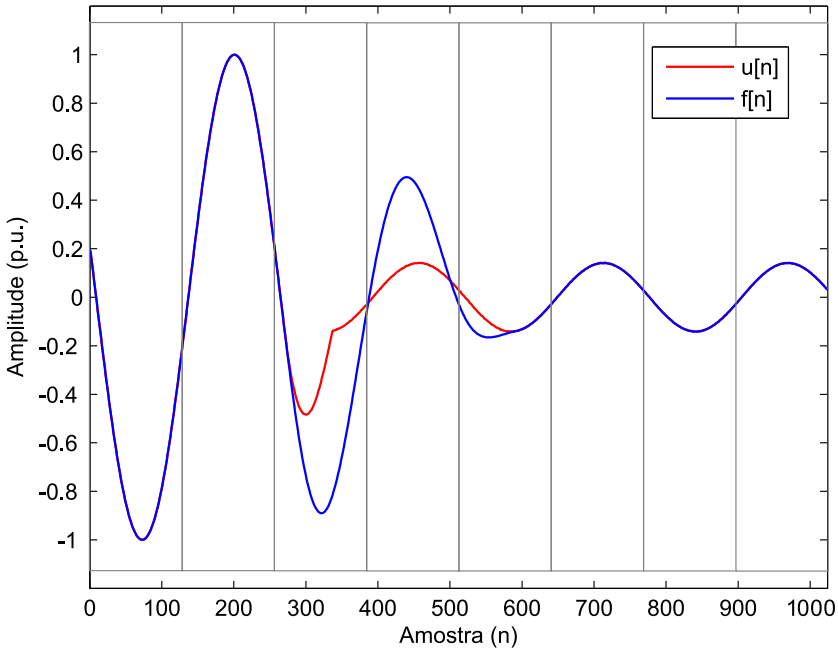


Figura 6.2: Estimação do componente fundamental e janelamento de um sinal de tensão apresentando afundamento.

valores RMS calculados, que ocorreu um afundamento a partir do terceiro semiciclo, com uma amplitude remanescente de 0,14 pu.

Deve-se chamar a atenção para o transitório do filtro *notch*, que pode ser evidenciado na Figura 6.2 através da divergência entre $u[n]$ e $f[n]$ desde o início do distúrbio até sua completa estabilização. Como será visto posteriormente, esse efeito transitório será útil para o reconhecimento da presença de variações de tensão de curta duração combinadas com outros tipos de distúrbios.

Tendo visto que o cálculo do valor RMS em janelas não-superpostas do sinal $f[n]$ pode ser utilizado como uma ferramenta para extrair as características tanto de amplitude remanescente quanto de duração das variações de tensão, será utilizado o sistema apresentado na Figura 6.3 para a extração de parâmetros representativos do sinal $f[n]$, para em seguida proceder ao reconhecimento automático, a partir de tais parâmetros, do tipo de distúrbio ocorrido.

O parâmetro $p_1$ representa o valor mínimo contido no vetor $\mathbf{y}_{\text{rms}}$. O parâmetro $p_2$ representa o seu valor máximo. O parâmetro $p_3$ representa o valor médio dos elementos do vetor e, por fim, o parâmetro $p_4$ representa o desvio padrão dos seus elementos. Para o exemplo anterior, $p_1 = 0,14$, $p_2 = 1,00$, $p_3 = 0,49$ e $p_4 = 0,40$. Desta forma, deve ser enfatizado que para um

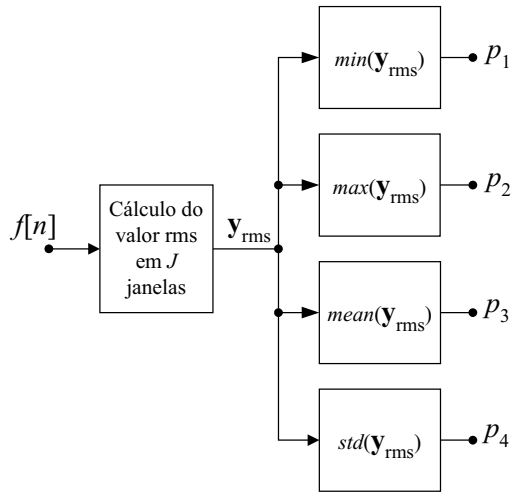


Figura 6.3: Diagrama de blocos da etapa de extração de características da estimativa do componente fundamental

sinal contendo um total de $N = 1024$ amostras, apenas quatro parâmetros serão utilizados para reconhecer o tipo de distúrbio que aconteceu em seu componente fundamental.

Como será visto posteriormente, o parâmetro $p_1$ auxilia principalmente na diferenciação entre um sinal com afundamento e um sinal com interrupção, e na diferenciação entre um sinal com afundamento e um sinal com componente fundamental normal. O parâmetro $p_2$ diferencia principalmente um sinal com componente fundamental normal de um sinal com elevação. Já os parâmetros $p_3$ e $p_4$ são estatísticas auxiliares para ajudar principalmente na quantificação do desvio do sinal em relação ao seu valor nominal.

### Módulo Classificação de padrões 1

Tendo sido obtido, pelo módulo de extração de características, o vetor $\mathbf{p} = [p_1 \quad p_2 \quad p_3 \quad p_4]^T$, o próximo passo é fornecer tal vetor como entrada ao módulo de classificação de padrões. A Figura 6.4 mostra o diagrama de blocos do módulo responsável pela classificação do distúrbio presente na estimativa do componente fundamental $f[n]$, utilizando-se uma RNA aplicada para a função de reconhecimento de padrões.

Como pode ser observado, os elementos do vetor de características $\mathbf{p}$ são inicialmente apresentados à etapa de normalização. Esta etapa é responsável por escalonar as respectivas amostras de entrada para a faixa de variação dinâmica das funções de ativação das camadas escondidas da RNA, com o intuito de evitar a saturação dos seus neurônios. Neste trabalho, as funções de ativação das camadas escondidas da RNA serão representadas pela função tangente hiperbólica.

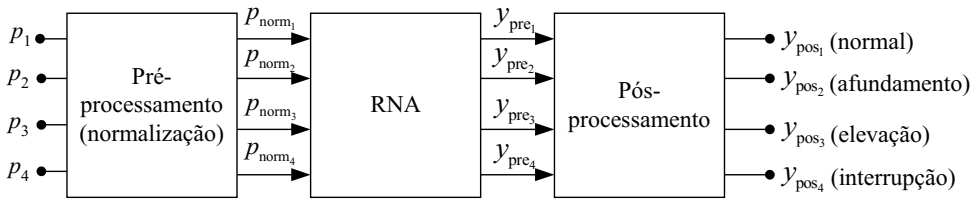


Figura 6.4: Diagrama de blocos da etapa de classificação do distúrbio presente no sinal de estimativa do componente fundamental.

Desta forma, os valores dos elementos de entrada e saída da RNA, tanto dos padrões de treinamento como dos padrões de validação e teste, devem ser escalonados levando-se em consideração a faixa de variação dinâmica da função de ativação tangente hiperbólica.

A técnica de escalonamento utilizada é baseada no princípio dos segmentos proporcionais (teorema de Tales) (da Silva *et al.*, 2010), onde um conjunto de valores definidos inicialmente num intervalo fechado entre $x^{\min}$ e $x^{\max}$, ou seja, $x \in \left[x^{\min}, x^{\max}\right]$, será convertido para um domínio proporcional entre -1 e 1, o qual está representando as próprias faixas de variações dinâmicas das entradas da função de ativação. Além disso, as saídas desejadas da RNA para os padrões de treinamento e teste também estarão compreendidas num intervalo $y \in [-1, 1]$.

Todas as variáveis de entrada da RNA $(p_{\text{norm}_1}, \ldots, p_{\text{norm}_4})$ precisam ser individualmente normalizadas, em relação aos seus respectivos valores mínimos e máximos, considerando também todos os dados disponíveis, e assegurando-se ainda que tais valores estejam contidos dentro do conjunto de treinamento. Caso contrário, os valores mínimos e máximos estarão no conjunto de teste, implicando então na redução dos domínios referentes às variáveis do conjunto de treinamento (da Silva *et al.*, 2010).

Como o problema se configura como um típico processo de classificação de padrões, a etapa de pós-processamento é responsável por mapear as saídas fornecidas pela RNA $(y_{\text{pre}_1}, \ldots, y_{\text{pre}_4})$, as quais são números reais, em números inteiros. Para tanto, é utilizado o critério de arredondamento simétrico apresentado a seguir:

$$y_{\text{pos}_j} = \begin{cases} 1, & \text{se} \quad y_{\text{pre}_j} \geq 0 \\ -1, & \text{se} \quad y_{\text{pre}_j} < 0 \end{cases}, \tag{6.3}$$

sendo esta operação realizada para cada neurônio $j$ da camada de saída da RNA $(j = 1, \ldots, 4)$. Desta forma, a saída do $j$-ésimo neurônio da camada de saída estará indicando a presença do

$j$-ésimo tipo de distúrbio no sinal $f[n]$ se $y_{\text{pos}_j} = 1$ e sua ausência se $y_{\text{pos}_j} = -1$.

### 6.1.2 Classificador dos distúrbios do sinal $x[n]$

A seguir, será descrito o subsistema responsável pela classificação dos distúrbios do sinal de erro $x[n]$. Este sinal é fornecido como entrada ao método FICA, e os sinais obtidos por este último são fornecidos como entradas ao módulo Extração de características 2 (vide Figura 6.1). Os possíveis tipos de distúrbios que podem estar presentes simultaneamente ou isoladamente no sinal de erro são: variação de tensão, harmônicos, transitório impulsivo, transitório oscilatório, *notchings*, ou sinal de erro sem distúrbio (normal).

#### Módulo Extração de características 2

Para a extração de características dos sinais resultantes da decomposição do sinal $x[n]$ pelo método FICA, será utilizado o sistema proposto na Figura 6.5. Como pode ser observado, o sistema é bem simples e intuitivo. O bloco multiplexador é responsável por apresentar um sinal $y_{\text{rec}_p}[n]$ de cada vez para a etapa de extração de características, para $p = 1, \ldots, P$. Partindo-se do pressuposto de que o método FICA tenha conseguido decompor o sinal $x[n]$ em estimativas $y_{\text{rec}_1}[n], \ldots, y_{\text{rec}_P}[n]$ distintas espectralmente entre si, será utilizada a DFT para transformar o sinal real $y_{\text{rec}_p}[n]$ para o domínio da frequência, obtendo o respectivo sinal complexo $Y_{\text{rec}_p}[k]$. Tal transformação é necessária porque as diferenças espectrais entre as estimativas podem ser diretamente acessadas no domínio da frequência.

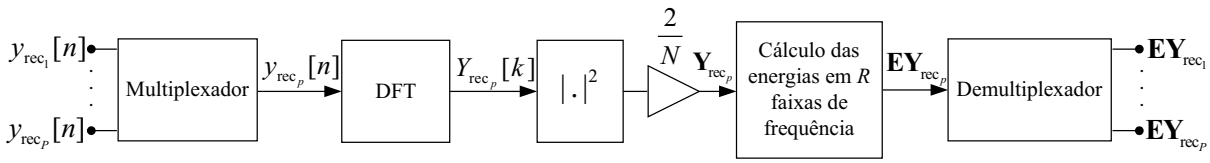


Figura 6.5: Diagrama de blocos da etapa de extração de características dos sinais resultantes da decomposição realizada pelo método FICA.

Em seguida, aplica-se o operador módulo quadrático no sinal complexo obtido pela operação anterior, e multiplica-se pelo fator de escala $2/N$, sendo $N$ o comprimento do sinal. Feito isto, obtém-se o vetor $\mathbf{Y}_{\text{rec}_p}$, de comprimento igual a $N$ amostras. Tal vetor contém as energias calculadas em $N$ frequências discretas, para a $p$-ésima estimativa de componente independente obtida pelo método FICA. Desta forma, o vetor ainda possui um comprimento muito elevado para ser diretamente submetido à etapa de classificação de padrões.

Sendo assim, o próximo bloco da etapa de extração de características calcula a energia acumulada em $R$ faixas de frequências discretas pré-definidas, sendo $R << N$, com a finalidade de minimizar redundâncias e reduzir a complexidade dimensional dos parâmetros de entrada do módulo classificador. Através desta operação, obtém-se o vetor $\mathbf{EY}_{\mathrm{rec}_p}$. Para o cálculo dos elementos deste vetor, o qual possuirá um total de $R$ elementos, a operação é realizada utilizando a seguinte expressão:

$$\mathbf{EY}_{\mathrm{rec}_p}[r] = \sum_{f \in \mathbf{f}_r} \mathbf{Y}_{\mathrm{rec}_p}[f], \tag{6.4}$$

onde $\mathbf{f}_r$ é o vetor contendo os valores discretos das frequências pertencentes a cada faixa $r$, para $r = 1, \ldots, R$. Por fim, o bloco demultiplexador simplesmente apresenta de forma paralela para a etapa de classificação de padrões todos os vetores $\mathbf{EY}_{\mathrm{rec}_1}, \ldots, \mathbf{EY}_{\mathrm{rec}_P}$ extraídos, respectivamente, dos sinais $y_{\mathrm{rec}_1}[n], \ldots, y_{\mathrm{rec}_P}[n]$. Pode ser reparado que a operação da etapa de extração de características proposta aqui é muito semelhante à etapa de agrupamento de múltiplos componentes independentes associados a uma mesma fonte no método SCICA.

**Módulo Classificação de padrões 2**

Tendo sido obtidos pelo módulo de extração de características os vetores $\mathbf{EY}_{\mathrm{rec}_1}, \ldots, \mathbf{EY}_{\mathrm{rec}_P}$ relacionados, respectivamente, às estimativas de componentes independentes $y_{\mathrm{rec}_1}[n], \ldots, y_{\mathrm{rec}_P}[n]$ encontradas pelo método FICA, o próximo passo é fornecer tais vetores como entradas ao módulo de classificação de padrões. A Figura 6.6 mostra o diagrama de blocos deste módulo. O bloco multiplexador tem como função fornecer de forma separada cada um dos $P$ vetores de características aos blocos subsequentes, para a realização do reconhecimento separado do tipo de distúrbio em cada uma das $P$ estimativas de componentes independentes.

Como pode ser observado, para a $p$-ésima estimativa de componente independente, o vetor de características $\mathbf{EY}_{\mathrm{rec}_p}$ é inicialmente apresentado à etapa de normalização. Todos os seus $R$ elementos são individualmente normalizados, o que resulta nos $R$ elementos de entrada da RNA $(x_1, \ldots, x_R)$. A normalização de cada um dos elementos é realizada em relação aos seus respectivos valores mínimos e máximos, considerando todos os dados disponíveis, e assegurando-se que tais valores estejam contidos dentro do conjunto de treinamento. A etapa de pós-processamento utiliza o critério de arredondamento simétrico dado por (6.3), sendo esta operação realizada para cada neurônio $j$ da camada de saída da RNA ($j = 1, \ldots, 6$). A saída do $j$-ésimo neurônio da

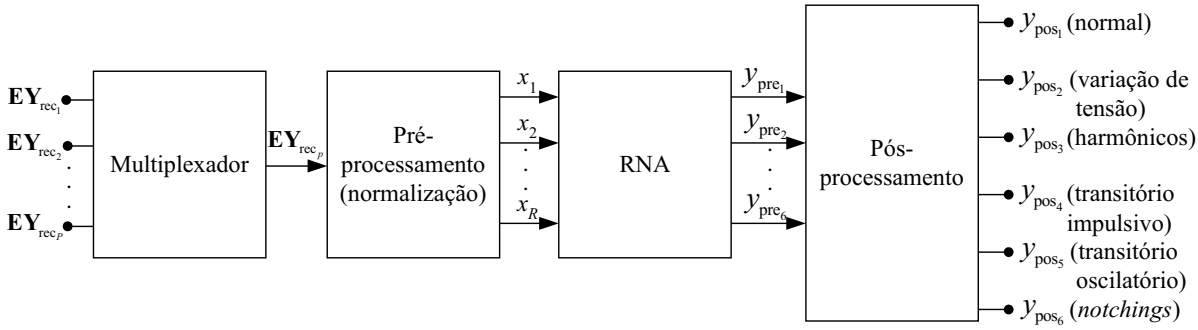


Figura 6.6: Diagrama de blocos da etapa de classificação de distúrbios nos sinais resultantes da decomposição realizada pelo método FICA.

camada de saída estará indicando a presença do $j$-ésimo tipo de distúrbio no $p$-ésimo sinal de entrada do módulo classificador se $y_{\text{pos}_j} = 1$ e sua ausência se $y_{\text{pos}_j} = -1$.

## 6.2 Sistema para classificação de distúrbios decompostos pela metodologia baseada no método SCICA

A Figura 6.7 apresenta o diagrama de blocos generalizado do sistema proposto para classificação de distúrbios decompostos pelo método SCICA. Este sistema possui poucas diferenças em relação ao sistema baseado no método FICA. A seguir, será descrito cada um dos seus blocos.

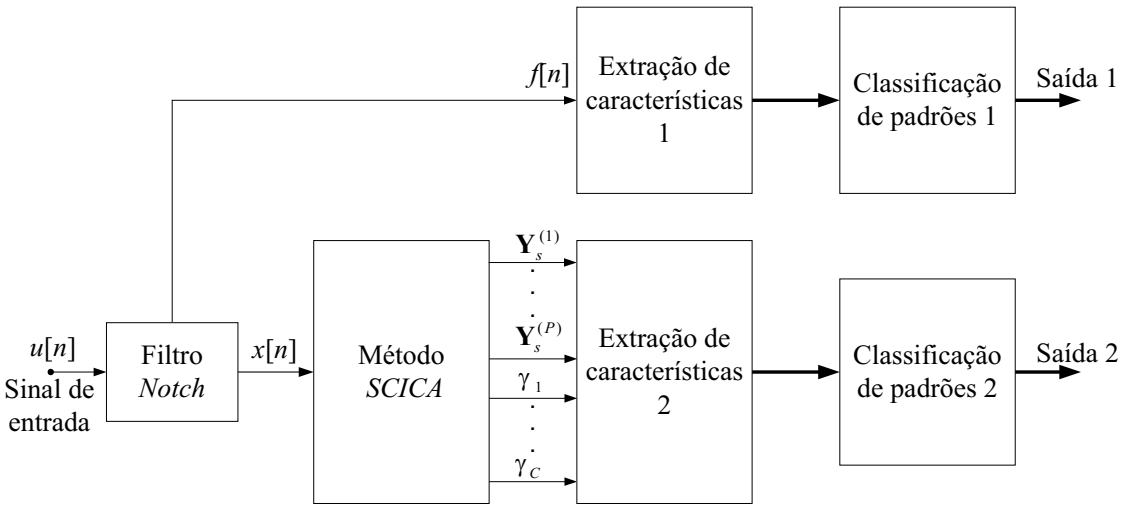


Figura 6.7: Diagrama de blocos generalizado do sistema proposto para classificação de distúrbios decompostos pela metodologia baseada no método SCICA.

### 6.2.1 Classificador do distúrbio do sinal $f[n]$

Neste subsistema, tanto a etapa de extração de características quanto a etapa de classificação de padrões são idênticas àquelas do sistema baseado no método FICA, apresentadas respectivamente nas Figuras 6.3 e 6.4.

### 6.2.2 Classificador dos distúrbios do sinal $x[n]$

A única diferença entre este subsistema, e aquele proposto para classificação dos distúrbios do sinal $x[n]$ quando decomposto pelo método FICA, está no bloco Extração de características 2. Como pode ser observado na Figura 6.7, os dados de entrada da etapa Extração de características 2 são os vetores de energia $\mathbf{Y}_s^{(1)}, \ldots, \mathbf{Y}_s^{(P)}$ e os vetores de subconjuntos $\gamma_1, \ldots, \gamma_C$, ao invés dos sinais $y_{\mathrm{rec}_1}[n], \ldots, y_{\mathrm{rec}_P}[n]$. Tal estratégia foi adotada porque o próprio método SCICA já calcula a DFT de cada estimativa de componente independente $y_s^{(p)}[n]$ internamente durante a sua etapa de agrupamento, bem como também realiza as operações módulo quadrático e multiplicação pelo fator $2/N$ para a obtenção dos valores de energia em $N$ frequências discretas e igualmente espaçadas, como pode ser revisto na Figura 4.21.

Desta forma, os vetores de energia $\mathbf{Y}_s^{(p)}$, para $p = 1, \ldots, P$, também podem ser agrupados de acordo com suas similaridades espectrais, tomando-se como base o próprio resultado já obtido anteriormente pelo algoritmo *k-means* e registrado nos vetores de subconjuntos $\gamma_c$ quando do agrupamento dos vetores de energia $\mathbf{EY}_s^{(p)}$ (vide Figura 4.21), obtendo-se com isto os vetores de energia $\mathbf{Y}_{\mathrm{rec}_c}$, da seguinte forma:

$$\mathbf{Y}_{\mathrm{rec}_c} = \sum_{p \in \gamma_c} \mathbf{Y}_s^{(p)}, \tag{6.5}$$

para $c = 1, \ldots, C$.

Estes vetores de energia, por sua vez, serão fornecidos para o cálculo das energias em $R$ faixas de frequência, exatamente da forma como foi proposto para o sistema que emprega o método FICA, levando à obtenção dos vetores de energia $\mathbf{EY}_{\mathrm{rec}_c}$. A Figura 6.8 resume as operações do módulo de extração de características proposto. Como antes, o bloco multiplexador apenas indica que cada vetor $\mathbf{Y}_{\mathrm{rec}_c}$, para $c = 1, \ldots, C$, é fornecido separadamente para o bloco que calcula as energias em $R$ faixas pré-definidas de frequência. Por sua vez, o bloco demultiplexador indica que todos os $C$ vetores de frequência $\mathbf{EY}_{\mathrm{rec}_1}, \ldots, \mathbf{EY}_{\mathrm{rec}_C}$ serão fornecidos de forma paralela

para a etapa Classificação de padrões 2, a qual também é idêntica àquela já proposta para a metodologia baseada no método FICA e apresentada na Figura 6.6.

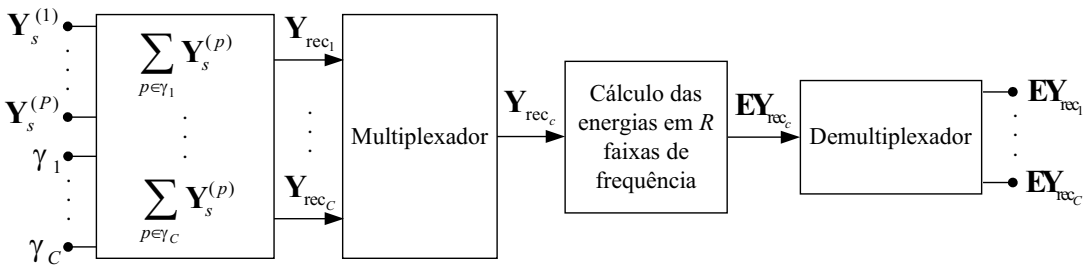


Figura 6.8: Diagrama de blocos da etapa de extração de características dos sinais resultantes da decomposição realizada pelo método SCICA.

Nas próximas seções, serão descritas as metodologias utilizadas para a geração de dados, bem como para o projeto, o treinamento e o teste dos classificadores propostos.

## 6.3 Geração dos dados

Os sinais sintéticos para treinamento e teste dos classificadores propostos serão gerados a uma taxa de amostragem de 256 amostras por ciclo do componente fundamental. Com isto, sendo a frequência fundamental igual a 60 Hz, a frequência de amostragem será igual a 15360 Hz. Será utilizada uma janela de dados com tamanho $N = 1024$ amostras comum para todos os sinais gerados, resultando no armazenamento de quatro ciclos do componente fundamental dentro da janela. Todos os sinais serão gerados no *software* Matlab, com base nos modelos matemáticos apresentados em Trindade (2005) e descritos na Seção 5.3.1. O ambiente considerado para a geração dos dados prevê uma SNR de 60 dB, sendo este dado considerado constante e comum a todos os distúrbios simulados.

A geração dos dados será dividida em dois subconjuntos: distúrbios isolados e distúrbios múltiplos. A Tabela 6.1 apresenta os tipos de distúrbios isolados gerados, os quais são divididos em oito classes. Para cada classe, são gerados 100 sinais para treinamento e outros 100 sinais para teste dos classificadores, perfazendo um total de 800 amostras para treinamento e outras 800 amostras para teste.

A Tabela 6.2 mostra os tipos de sinais gerados contendo múltiplos distúrbios e as respectivas quantidades, tanto para dados de treinamento quanto para dados de teste dos classificadores.

Na Tabela 6.2, com exceção das combinações de afundamento e harmônicos e das combinações

Tabela 6.1: Tipos e quantidades de sinais gerados para treinamento e teste do sistema de classificação para cada tipo de distúrbio isolado.

| Classe/Tipo de distúrbio isolado | Sinais de treinamento | Sinais de teste |
|---|---|---|
| $C_1$: Normal (sinal sem distúrbio) | 100 | 100 |
| $C_2$: Afundamento | 100 | 100 |
| $C_3$: Elevação | 100 | 100 |
| $C_4$: Interrupção | 100 | 100 |
| $C_5$: Harmônicos | 100 | 100 |
| $C_6$: Transitório impulsivo | 100 | 100 |
| $C_7$: Transitório oscilatório | 100 | 100 |
| $C_8$: *Notchings* | 100 | 100 |

Tabela 6.2: Tipos e quantidades de sinais gerados para treinamento e teste do sistema de classificação para cada combinação de distúrbios múltiplos.

| Classe/Combinação de distúrbios múltiplos | Sinais de treinamento | Sinais de teste |
|---|---|---|
| Afundamento e harmônicos | 100 | 100 |
| Elevação e harmônicos | 100 | 100 |
| Harmônicos e transitório impulsivo | 100 | 100 |
| Harmônicos e transitório oscilatório | 100 | 100 |
| Harmônicos e *notchings* | 100 | 100 |
| Transitório impulsivo e transitório oscilatório | 100 | 100 |
| Transitório impulsivo e *notchings* | 100 | 100 |
| Transitório oscilatório e *notchings* | 100 | 100 |

de elevação e harmônicos, todos os sinais de erro derivados dos demais sinais de entrada contendo múltiplos distúrbios serão apresentados aos métodos FICA e SCICA para decomposição, antes de serem fornecidos à etapa de classificação. De forma a aumentar a capacidade de generalização dos classificadores de distúrbios do sinal de erro, os sinais contendo apenas distúrbios isolados serão apresentados diretamente à etapa de classificação durante a sua fase de treinamento.

A geração dos padrões para treinamento e teste dos classificadores se divide na geração dos padrões extraídos do componente fundamental e na geração dos padrões extraídos do sinal de erro. Cada um destes procedimentos será descrito a seguir.

### 6.3.1 Geração dos padrões para treinamento e teste do classificador de distúrbios do componente fundamental

Para a geração dos vetores de características a serem fornecidos como padrões de entrada às etapas de treinamento e teste do classificador de distúrbios do componente fundamental, utilizar-

se-á a estrutura da Figura 6.3. Para cada sinal contido nos conjuntos de treinamento e teste da Tabela 6.1, além dos sinais dos conjuntos de treinamento e teste da Tabela 6.2 que contêm combinações de afundamento e harmônicos e de elevação e harmônicos, aplica-se o filtro *notch* para obter a estimativa do componente fundamental $f[n]$, para a partir deste sinal proceder à extração dos parâmetros que devem compor o vetor de características de entrada do módulo classificador da Figura 6.4.

A Figura 6.9 mostra a distribuição dos padrões que compõem o vetor de entrada do módulo classificador de distúrbios do componente fundamental, extraídos do conjunto de treinamento. Cada faixa, de 100 em 100 amostras, está associada à extração dos parâmetros de um sinal que contém o tipo de distúrbio descrito na parte superior da figura. Por exemplo, as amostras de 1 a 100 contêm parâmetros extraídos de sinais que não contêm distúrbio (normal), as amostras de 101 a 200 contêm parâmetros extraídos de sinais que contêm afundamento, e assim por diante.

Como pode ser observado na Figura 6.9, o parâmetro $p_1$ ($min(\mathbf{y}_{\text{rms}})$) auxilia na distinção entre sinais que contêm afundamento ou interrupção daqueles sinais que não contêm tais distúrbios. O parâmetro $p_1$ também auxilia na delimitação de uma fronteira de separação discreta entre afundamentos e interrupções. O parâmetro $p_2$ ($max(\mathbf{y}_{\text{rms}})$) auxilia na distinção entre os sinais que contêm elevação daqueles que não contêm. O parâmetro $p_3$ ($mean(\mathbf{y}_{\text{rms}})$) auxilia na distinção entre sinais que contêm distúrbios que afetam o componente fundamental daqueles sinais que contêm distúrbios que não o afetam. Por fim, o parâmetro $p_4$ ($std(\mathbf{y}_{\text{rms}})$) reforça a distinção promovida por $p_3$ e também reforça a distinção entre afundamento ou elevação de interrupção.

Tanto para a geração dos vetores de saídas desejadas do classificador de distúrbios do componente fundamental, com o propósito de ajustar os pesos sinápticos da RNA durante a fase de treinamento, quanto para a sua operação após ser treinada, procede-se com a aplicação da codificação apresentada na Tabela 6.3.

Na Tabela 6.3, a coluna $y_{d_j}$ ($j = 1, \ldots, 4$) corresponde à saída $j$ da RNA da Figura 6.4, sendo que: $y_{d_1} = 1$ acusa a presença de componente fundamental normal e $y_{d_1} = -1$ acusa a sua ausência, $y_{d_2} = 1$ acusa a presença de afundamento e $y_{d_2} = -1$ acusa a sua ausência, $y_{d_3} = 1$ acusa a presença de elevação e $y_{d_3} = -1$ acusa a sua ausência, e $y_{d_4} = 1$ acusa a presença de interrupção e $y_{d_4} = -1$ acusa a sua ausência.

A Figura 6.10 mostra a distribuição das amostras de saídas desejadas do módulo classificador a serem associadas às respectivas amostras de padrões de entrada de treinamento da Figura 6.9,

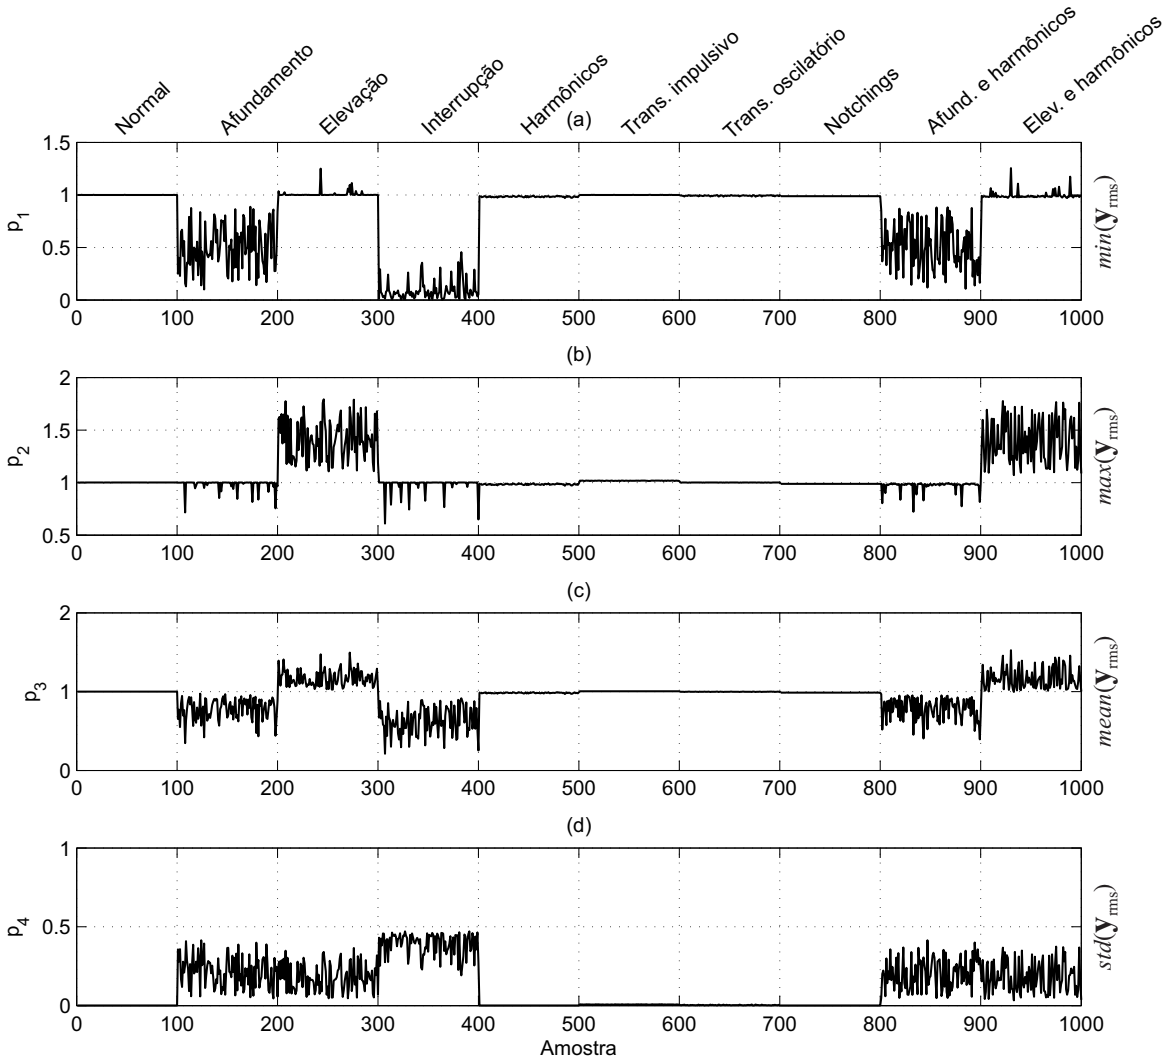


Figura 6.9: Distribuição dos padrões de entrada para treinamento do classificador de distúrbios do componente fundamental.

com o objetivo de treinar a RNA. Deve ser enfatizado que durante a fase de treinamento da RNA, as saídas desejadas serão aplicadas diretamente nas suas saídas, e não na saída do bloco de pós-processamento (vide Figura 6.4).

### 6.3.2 Geração dos padrões para treinamento e teste do classificador de distúrbios do sinal de erro

Para a geração dos vetores de características a serem fornecidos como padrões de entrada do classificador de distúrbios do sinal de erro, utilizar-se-á a estrutura da Figura 6.5, quando utilizado o método FICA como ferramenta de decomposição, e a estrutura apresentada na Figura 6.8, quando utilizado o método SCICA.

Tabela 6.3: Codificação das classes de saída do classificador de distúrbios do componente fundamental.

| $y_{d_1}$ | $y_{d_2}$ | $y_{d_3}$ | $y_{d_4}$ | Classe |
|---|---|---|---|---|
| 1 | -1 | -1 | -1 | Normal |
| -1 | 1 | -1 | -1 | Afundamento |
| -1 | -1 | 1 | -1 | Elevação |
| -1 | -1 | -1 | 1 | Interrupção |
| 1 | -1 | -1 | -1 | Harmônicos |
| 1 | -1 | -1 | -1 | Transitório impulsivo |
| 1 | -1 | -1 | -1 | Transitório oscilatório |
| 1 | -1 | -1 | -1 | *Notchings* |
| -1 | 1 | -1 | -1 | Afundamento e harmônicos |
| -1 | -1 | 1 | -1 | Elevação e harmônicos |

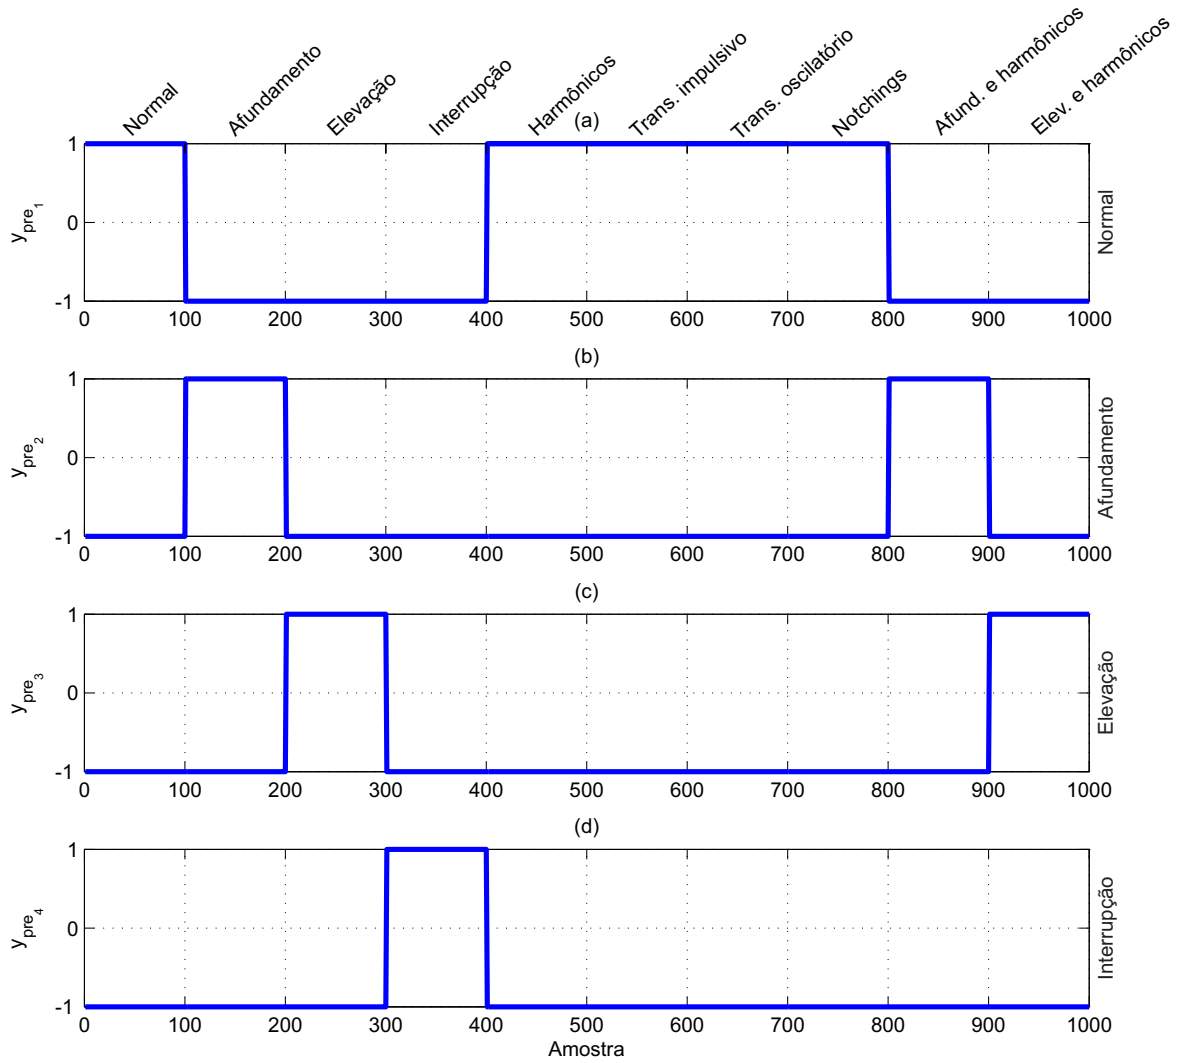


Figura 6.10: Distribuição das saídas desejadas para treinamento do classificador de distúrbios do componente fundamental.

A Tabela 6.4 mostra as $R = 5$ faixas de frequências escolhidas para o cálculo, através de (6.4), das energias acumuladas dentro de cada uma destas faixas. A partir da análise das distribuições dos padrões de entrada para treinamento do classificador de distúrbios do sinal de erro apresentada logo a seguir, será justificada a escolha desses intervalos de frequência para a composição dos vetores de características apresentados ao módulo de classificação.

Tabela 6.4: Faixas de frequências para o cálculo das energias a comporem o vetor de características a ser fornecido como entrada para o módulo classificador.

| Entrada | Faixa de frequências (Hz) |
|---|---|
| $\mathbf{EY}_{\mathrm{rec}_p}[1]$ | [0,180) |
| $\mathbf{EY}_{\mathrm{rec}_p}[2]$ | [180,480) |
| $\mathbf{EY}_{\mathrm{rec}_p}[3]$ | [480,960) |
| $\mathbf{EY}_{\mathrm{rec}_p}[4]$ | [960,2880) |
| $\mathbf{EY}_{\mathrm{rec}_p}[5]$ | [2880,7680) |

Como comentado anteriormente, de forma a aumentar a capacidade de generalização do classificador de distúrbios do sinal de erro, não apenas serão apresentados ao mesmo durante sua fase de treinamento os componentes independentes estimados pelo método FICA ou pelo método SCICA a partir de sinais contendo múltiplos distúrbios, mas também o sinal de erro obtido a partir de sinais contendo distúrbios isolados. Como foi visto nos resultados do Capítulo 5, as estimativas de componentes independentes não recuperam com exatidão as formas de onda dos distúrbios isolados para todas as combinações de distúrbios múltiplos. Desta forma, adotando a estratégia acima, o classificador de distúrbios do sinal de erro não apenas será capaz de reconhecer distúrbios múltiplos separados pelo método FICA ou pelo método SCICA, mas também distúrbios isolados.

Para tanto, os sinais de erro obtidos pelo filtro *notch* a partir dos sinais de entrada contendo distúrbios isolados pertencentes às classes da Tabela 6.1, além daqueles sinais de erro obtidos pelo filtro *notch* a partir dos sinais de entrada contendo combinações de afundamento e harmônicos e de elevação e harmônicos da Tabela 6.2, serão fornecidos diretamente como entrada à etapa de extração de características da Figura 6.5, sem passar antes pelo método FICA ou pelo método SCICA. Portanto, para os casos acima, o próprio sinal $x[n]$ será fornecido como entrada à etapa de extração de características, ao invés dos sinais $y_{\mathrm{rec}_1}[n], \ldots, y_{\mathrm{rec}_P}[n]$.

Cabe comentar neste momento que os sinais contendo combinações de afundamento e harmônicos e de elevação e harmônicos, apesar de conterem múltiplos distúrbios, não passam pelos métodos de decomposição FICA e SCICA, porque o sinal de erro obtido não conterá outro

distúrbio senão harmônicos.

A Figura 6.11 mostra a distribuição das amostras dos padrões de entrada do módulo classificador de distúrbios do sinal de erro, extraídos do conjunto de treinamento para distúrbios isolados. Como pode ser observado, o parâmetro $\mathbf{EY}_{\mathrm{rec}_p}[1]$, o qual representa a parcela de energia do sinal de erro contida dentro da faixa de frequências de 0 a 180 Hz, é útil na diferenciação entre os sinais que contêm distúrbios que afetam o componente fundamental e entre aqueles que não o afetam. Mais precisamente, esse parâmetro serve para informar que houve uma variação de tensão dentro da janela de dados analisada, a qual pode ser devido à ocorrência de um afundamento, uma elevação ou uma interrupção.

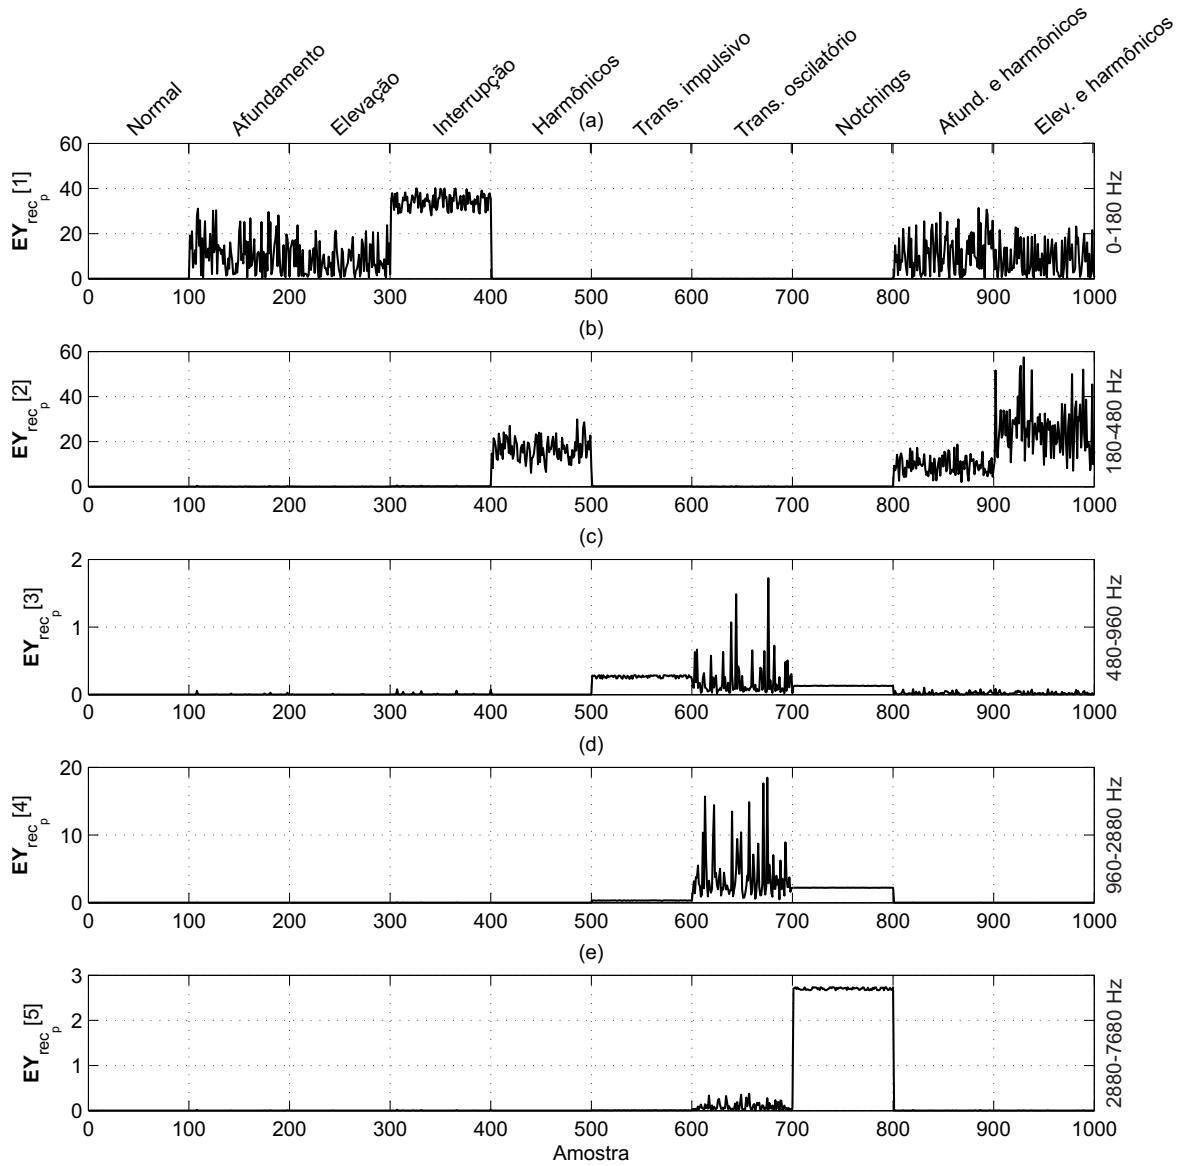


Figura 6.11: Distribuição dos padrões de entrada para treinamento do classificador de distúrbios do sinal de erro isolados.

Para ilustrar como uma variação de tensão ocorrida dentro da janela de dados pode ser diagnosticada por meio do parâmetro $\mathbf{EY}_{\mathrm{rec}_p}[1]$, a Figura 6.12(a) mostra um sinal de entrada $u[n]$ que sofreu um afundamento, a sua estimativa de componente fundamental $f[n]$ extraída pelo filtro *notch*, e o sinal de erro $x[n] = u[n] - f[n]$. Como pode ser observado, o sinal de erro apresenta um transitório de baixa frequência, desde o início do distúrbio até a estabilização do filtro *notch*. A Figura 6.12(b) mostra a distribuição de energias do sinal de erro no domínio da frequência, onde o detalhe mostra que o sinal possui energia totalmente compreendida dentro da faixa de frequências escolhida para o parâmetro $\mathbf{EY}_{\mathrm{rec}_p}[1]$. Como será comentado a seguir, essa delimitação de frequências de 0 a 180 Hz se mostra necessária para distinguir as variações de tensão dos harmônicos.

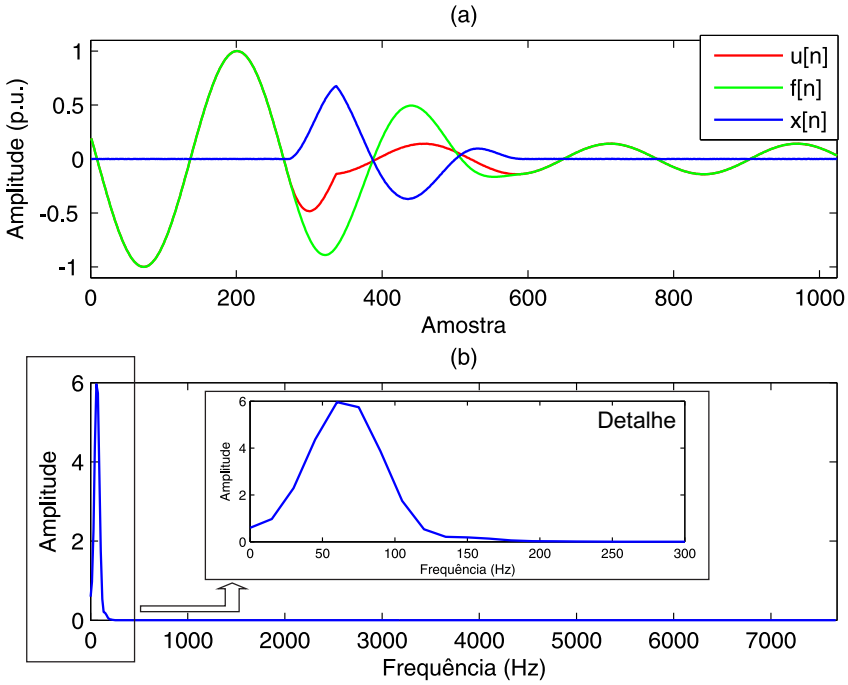


Figura 6.12: Distribuição de energia para o sinal de erro obtido a partir de um sinal de tensão contendo afundamento.

Voltando à análise da Figura 6.11, o parâmetro $\mathbf{EY}_{\mathrm{rec}_p}[2]$, o qual representa a parcela de energia do sinal de erro contida dentro da faixa de frequências de 180 a 480 Hz, é útil na distinção entre os sinais que contêm harmônicos e aqueles que não o contêm. Esta faixa de frequências compreende as ordens harmônicas mais importantes que caracterizam tal distúrbio, as quais são: 3º harmônico (180 Hz), 5º harmônico (300 Hz) e 7º harmônico (420 Hz) (Dugan *et al.*, 2004). Caso a faixa de frequências de $\mathbf{EY}_{\mathrm{rec}_p}[2]$ fosse definida de 0 a 480 Hz, seria bem mais difícil, senão impossível, a RNA distinguir entre harmônicos e variações de tensão.

O parâmetro $\mathbf{EY}_{\mathrm{rec}_p}[3]$, o qual representa a parcela de energia do sinal de erro contida dentro da faixa de frequências de 480 a 960 Hz, contém informações que auxiliam principalmente na distinção dos transitórios impulsivos, dos transitórios oscilatórios e dos *notchings* em relação aos demais tipos de distúrbios. O parâmetro $\mathbf{EY}_{\mathrm{rec}_p}[4]$, o qual representa a parcela de energia do sinal de erro contida dentro da faixa de frequências de 960 a 2880 Hz, auxilia na identificação de transitórios oscilatórios ou *notchings*. Por fim, o parâmetro $\mathbf{EY}_{\mathrm{rec}_p}[5]$, o qual representa a parcela de energia do sinal de erro contida dentro da faixa de frequências de 2880 a 7680 Hz, é útil principalmente na identificação dos *notchings*.

Tanto para a geração dos vetores de saídas desejadas do classificador de distúrbios do sinal de erro, com o propósito de ajuste dos pesos sinápticos da RNA durante a fase de treinamento, quanto para a sua operação após ser treinada, procede-se com a aplicação da codificação apresentada na Tabela 6.5.

Tabela 6.5: Codificação das classes de saída do classificador de distúrbios do sinal de erro.

| $y_{d_1}$ | $y_{d_2}$ | $y_{d_3}$ | $y_{d_4}$ | $y_{d_5}$ | $y_{d_6}$ | Classe |
|---|---|---|---|---|---|---|
| 1 | -1 | -1 | -1 | -1 | -1 | Normal |
| -1 | 1 | -1 | -1 | -1 | -1 | Afundamento |
| -1 | 1 | -1 | -1 | -1 | -1 | Elevação |
| -1 | 1 | -1 | -1 | -1 | -1 | Interrupção |
| -1 | -1 | 1 | -1 | -1 | -1 | Harmônicos |
| -1 | -1 | -1 | 1 | -1 | -1 | Transitório impulsivo |
| -1 | -1 | -1 | -1 | 1 | -1 | Transitório oscilatório |
| -1 | -1 | -1 | -1 | -1 | 1 | *Notchings* |
| -1 | 1 | 1 | -1 | -1 | -1 | Afundamento e harmônicos |
| -1 | 1 | 1 | -1 | -1 | -1 | Elevação e harmônicos |

Na Tabela 6.5, cada coluna $y_{d_j}$ $(j = 1, \ldots, 6)$ corresponde a cada saída $j$ da RNA da Figura 6.6, sendo que: $y_{d_1} = 1$ acusa a presença de sinal de erro normal (sem distúrbio) e $y_{d_1} = -1$ acusa a sua ausência, $y_{d_2} = 1$ acusa a presença de variação de tensão e $y_{d_2} = -1$ acusa a sua ausência, $y_{d_3} = 1$ acusa a presença de harmônicos e $y_{d_3} = -1$ acusa a sua ausência, $y_{d_4} = 1$ acusa a presença de transitório impulsivo e $y_{d_4} = -1$ acusa a sua ausência, $y_{d_5} = 1$ acusa a presença de transitório oscilatório e $y_{d_5} = -1$ acusa a sua ausência, e $y_{d_6} = 1$ acusa a presença de *notchings* e $y_{d_6} = -1$ acusa a sua ausência.

A Figura 6.13 mostra a distribuição das amostras de saídas desejadas do módulo classificador a serem associadas às respectivas amostras de padrões de entrada de treinamento da Figura 6.11. Assim como para o classificador de distúrbios do componente fundamental, durante a fase de

treinamento desta RNA, as saídas desejadas serão aplicadas diretamente na suas saídas, e não nas saídas do bloco de pós-processamento.

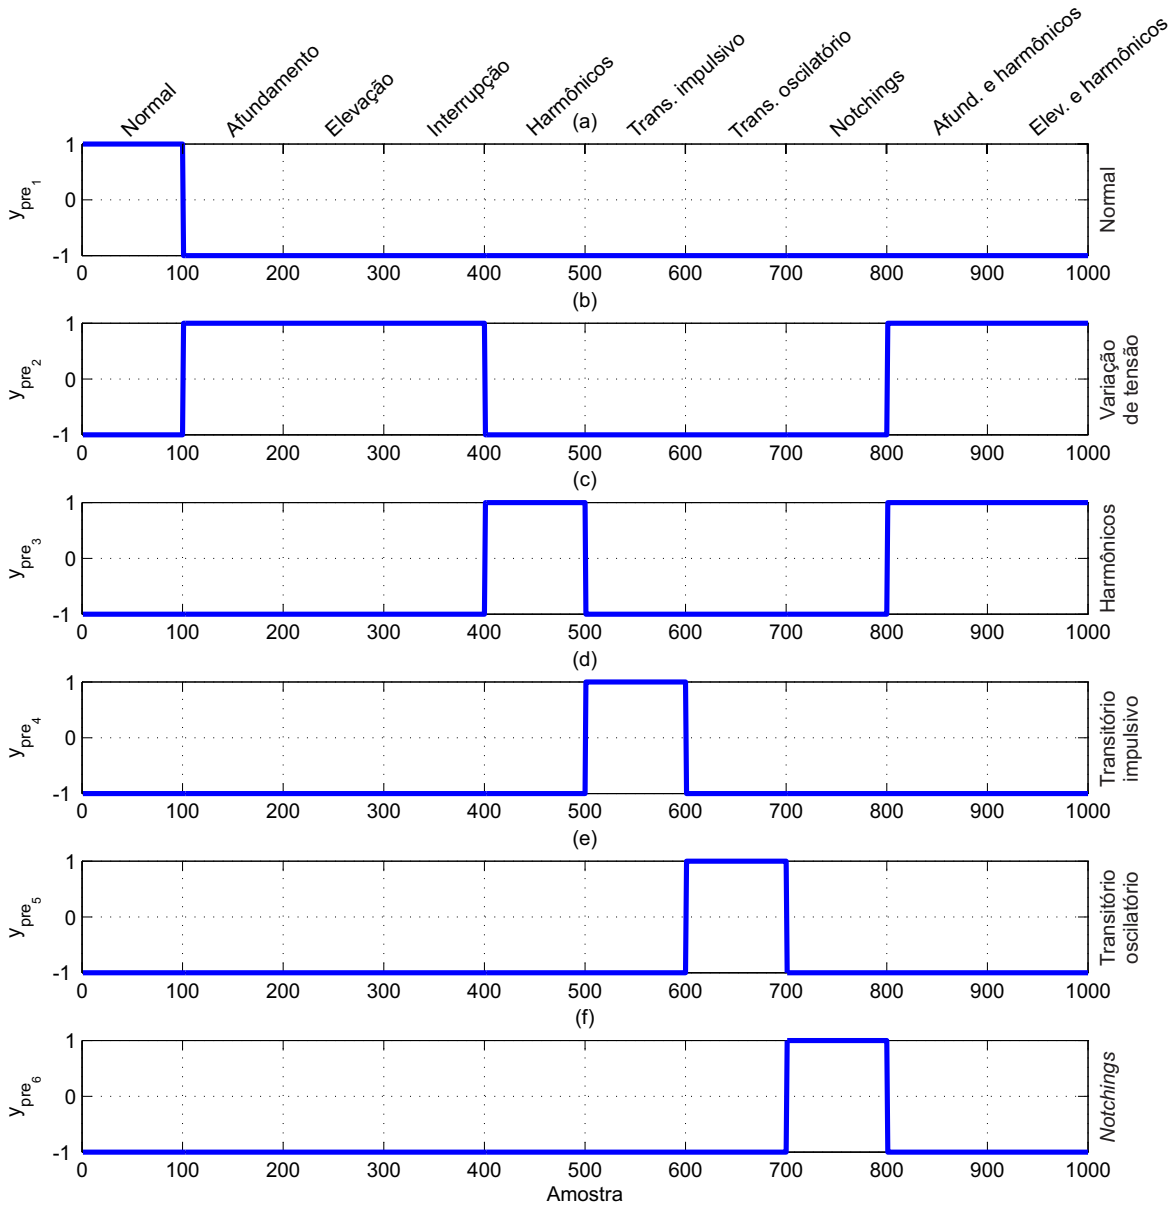


Figura 6.13: Distribuição das saídas desejadas para treinamento do classificador de distúrbios do sinal de erro isolados.

Para a geração dos dados de treinamento e teste do classificador de distúrbios do sinal de erro a partir dos sinais de entrada quem contêm as combinações de múltiplos distúrbios apresentadas na Tabela 6.2, com exceção das combinações de afundamento e harmônicos e de elevação e harmônicos, inicialmente serão utilizados os métodos FICA e SCICA como ferramenta de decomposição, e então os sinais obtidos por estes dois métodos serão em seguida apresentados às suas respectivas etapas de extração de características.

Os parâmetros de configuração do método FICA, constantes para a obtenção de todos os dados de treinamento e teste do classificador de múltiplos distúrbios no sinal de erro, são:

- Número de filtros: $M = 2$ filtros
- Ordem dos filtros: $K = 20$
- Filtro $H_1(z)$: FIR tipo 1 passa-todas
- Filtro $H_2(z)$: FIR tipo 1 passa-altas com $f_C = 300$ Hz
- Taxa de aprendizado do algoritmo LMS: $\eta = 0,01$
- Precisão para critério de parada do algoritmo LMS: $\varepsilon = 1,0 \times 10^{-7}$
- Algoritmo de estimação da ICA: FastICA

Já com relação ao método SCICA, os parâmetros de configuração, constantes para a obtenção de todos os dados de treinamento e teste, são:

- Número de sinais de observação gerados: $M = 12$
- Atraso entre sinais de observação consecutivos: $\tau = 1$ amostra
- Número de *clusters* da etapa de agrupamento: $C = 2$ *clusters*
- Número de faixas regulares de frequência para cálculo dos vetores de energia fornecidos como entrada para o algoritmo *k-means*: $R = 16$ faixas
- Largura de cada faixa de frequência: $L = 480$ Hz
- Algoritmo de estimação da ICA: FastICA

Como não há garantia da recuperação da ordem de estimação dos componentes independentes nem pelo método FICA nem pelo método SCICA (veja os resultados das Figuras 5.38 e 5.43), será utilizada a estratégia proposta na Figura 6.14 para associar cada estimativa de componente independente àquela fonte original cuja forma de onda mais se aproxima de sua forma de onda, no sentido do menor erro quadrático médio entre estimativa e fonte.

A medida de aproximação entre uma fonte original e uma estimativa será calculada utilizando-se a raiz normalizada do erro quadrático médio (*Relative Root Mean Square Error* (RRMSE)), que é definida como:

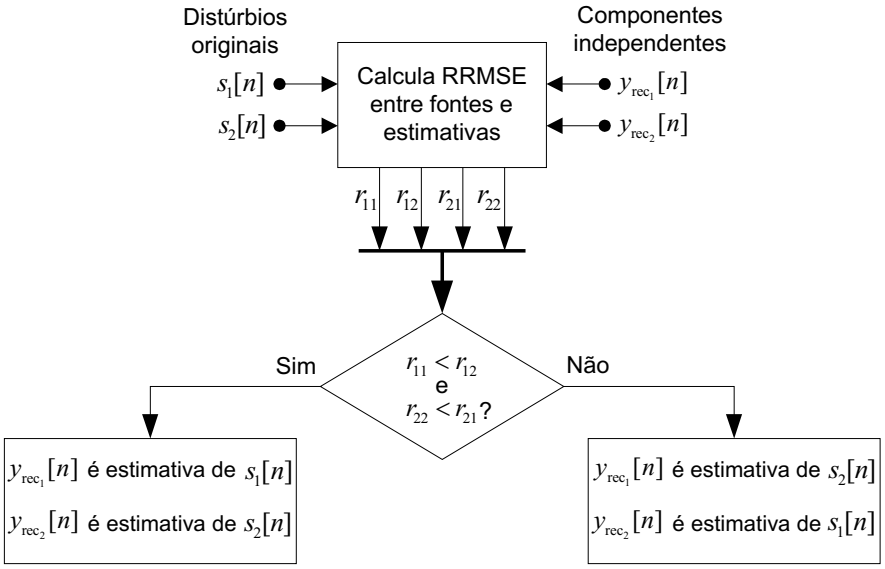


Figura 6.14: Fluxograma do esquema de ordenação das estimativas de componentes independentes em relação às fontes originais.

$$r_{ij} = \frac{\sqrt{\frac{1}{N}\sum_{n=0}^{N-1}(s_i[n] - y_{\text{rec}_j}[n])^2}}{\sqrt{\frac{1}{N}\sum_{n=0}^{N-1}(s_i[n])^2}}, \tag{6.6}$$

onde $s_i[n]$ é a $i$-ésima fonte original e $y_{\text{rec}_j}[n]$ é a $j$-ésima estimativa de componente independente fornecida pelo método FICA ou pelo método SCICA. Como pode ser visto em (6.6), quanto mais próximo de zero for o valor de $r_{ij}$, mais próxima será a estimativa $j$ da fonte original $i$.

Tendo sido calculados os valores de RRMSE entre as formas de onda de todos os distúrbios originais presentes no sinal de erro e as formas de onda de todas as estimativas de componentes independentes, procede-se com a aplicação da lógica de decisão apresentada na Figura 6.14, a qual determina que se os valores de RRMSE entre fontes e estimativas de índices iguais forem menores do que os valores de RRMSE entre fontes e estimativas de índices diferentes, então não houve inversão da ordem de estimação por parte dos métodos de decomposição. Caso contrário, houve inversão.

Como um exemplo, considere que o sinal de erro seja composto pela presença simultânea de harmônicos, que será assumido ser a primeira fonte ($s_1[n]$), e de transitório oscilatório, que será assumido ser a segunda fonte ($s_2[n]$). Então, se $r_{11}$ for menor que $r_{12}$ e $r_{22}$ for menor que $r_{21}$, então será assumido que $y_{\text{rec}_1}[n]$ é uma estimativa associada aos harmônicos e $y_{\text{rec}_2}[n]$ é uma estimativa associada ao transitório oscilatório, não tendo havido, portanto, inversão na ordem

de estimação.

Desta forma, com a aplicação deste procedimento, para cada sinal de entrada dos conjuntos de treinamento e teste que contêm múltiplos distúrbios no sinal de erro, realiza-se inicialmente sua decomposição pelas metodologias baseadas nos métodos FICA e SCICA. Em seguida, associa-se cada estimativa de componente independente ao tipo de distúrbio ao qual a mesma seja mais semelhante, de forma a definir as saídas desejadas do classificador para cada estimativa. Finalmente, extrai-se de cada estimativa de componente independente os parâmetros de entrada do módulo classificador da Figura 6.6, utilizando-se para isto a estrutura da Figura 6.5, quando utilizado o método FICA, e a estrutura da Figura 6.8, quando utilizado o método SCICA.

A Figura 6.15 mostra a distribuição das amostras dos padrões de entrada do módulo classificador de distúrbios do sinal de erro, extraídos do conjunto de treinamento contendo distúrbios múltiplos decompostos pelo método FICA. Cada faixa de amostras de padrões de entrada corresponde à estimativa associada ao tipo de distúrbio escrito em negrito, quando o mesmo foi separado do tipo de distúrbio não escrito em negrito. Por exemplo, a faixa de amostras de 1 até 100 contém padrões extraídos de estimativas de harmônicos que foram separados de transitórios oscilatórios, a faixa de amostras de 101 até 200 contém padrões extraídos de estimativas de harmônicos que foram separados de *notchings*, e assim por diante.

Como pode ser observado na Figura 6.15, o parâmetro $\mathbf{EY}_{\mathrm{rec}_p}[1]$, o qual representa a parcela de energia da estimativa de componente independente contida dentro da faixa de frequências de 0 a 180 Hz, basicamente não fornece informação que seja relevante para distinguir entre os quatro tipos de distúrbios identificados pelo sinal de erro. Como foi comentado durante a análise da Figura 6.11(a), este parâmetro é útil para detectar a ocorrência de uma variação de tensão no sinal de erro, que vai ser precisamente identificada pelo classificador de distúrbios do componente fundamental, como sendo devido à ocorrência de um afundamento, uma elevação ou uma interrupção dentro da janela de dados analisada.

O parâmetro $\mathbf{EY}_{\mathrm{rec}_p}[2]$, o qual representa a parcela de energia da estimativa de componente independente contida dentro da faixa de frequências de 180 a 480 Hz, é útil na distinção entre as estimativas de harmônicos e as estimativas dos demais tipos de distúrbios. Pode ser observado na Figura 6.15(b) que para todas as estimativas de harmônicos, tendo sido os mesmos separados dos demais tipos de distúrbios, a distribuição deste parâmetro possui perfil semelhante àquele encontrado na Figura 6.11(b), que foi extraído de sinais contendo apenas harmônicos isolados. Portanto, este fato é um indicativo de que o método FICA promoveu uma separação eficiente

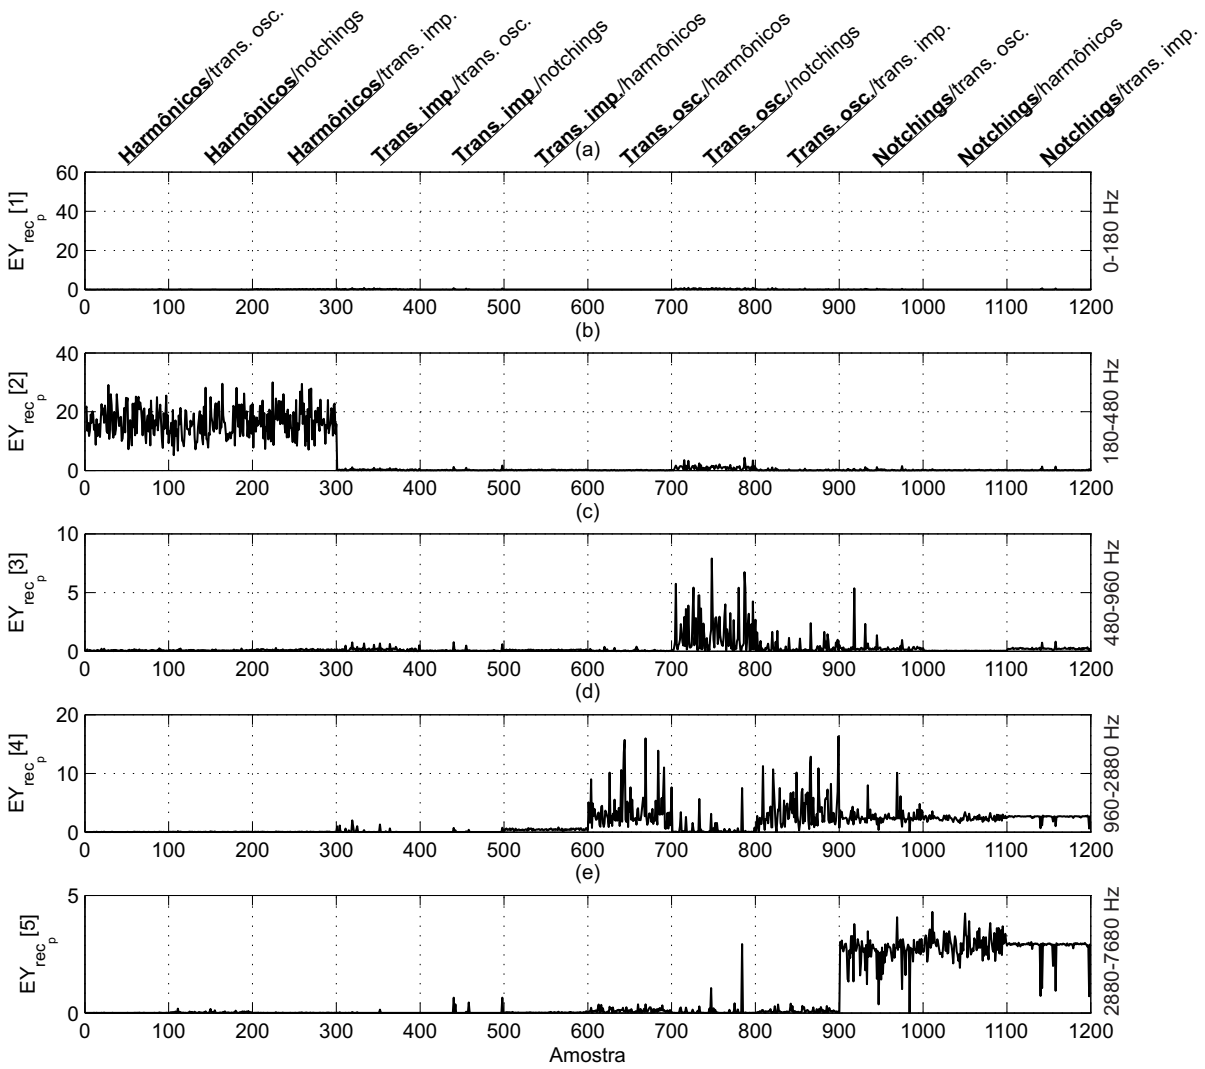


Figura 6.15: Distribuição dos padrões de entrada para treinamento do classificador de distúrbios do sinal de erro separados pelo método FICA.

dos harmônicos quando misturados aos demais tipos de distúrbios.

O parâmetro $\mathbf{EY}_{\mathrm{rec}_p}[3]$, o qual representa a parcela de energia da estimativa de componente independente contida dentro da faixa de frequências de 480 a 960 Hz, contém informações que distinguem principalmente os transitórios oscilatórios quando os mesmos são separados de sinais que também contêm *notchings*.

O parâmetro $\mathbf{EY}_{\mathrm{rec}_p}[4]$, o qual representa a parcela de energia da estimativa de componente independente contida dentro da faixa de frequências de 960 a 2880 Hz, contém informações úteis principalmente para a distinção de estimativas de transitório oscilatório que são separados de sinais contendo também harmônicos ou transitório impulsivo. O mesmo parâmetro também contém informações que auxiliam na distinção entre *notchings* e os demais tipos de distúrbios

que foram separados do mesmo.

Por fim, o parâmetro $\mathbf{EY}_{\mathrm{rec}_p}[5]$, que representa a parcela de energia da estimativa de componente independente contida dentro da faixa de frequências de 2880 a 7680 Hz, auxilia principalmente na distinção entre *notchings* e os demais tipos de distúrbios que foram separados deles.

A Figura 6.16 mostra a distribuição das amostras dos padrões de entrada do módulo classificador de distúrbios do sinal de erro, extraídos do mesmo conjunto de treinamento contendo distúrbios múltiplos, porém desta vez decompostos pelo método SCICA. Pode-se perceber uma grande semelhança com o perfil da distribuição mostrada anteriormente na Figura 6.15, para os distúrbios decompostos pelo método FICA. Isto é um indicativo de que, embora os métodos FICA e SCICA possam apresentar diferenças com relação à qualidade da separação dos distúrbios múltiplos (sendo em alguns casos o método FICA melhor que o SCICA, sendo em outros casos o contrário), as faixas de frequências escolhidas para o cálculo das energias dentro das etapas de extração de características dos classificadores, para ambas as metodologias, se mostraram adequadas para minimizar essas diferenças.

A Figura 6.17 mostra a distribuição das saídas desejadas para treinamento dos classificadores de distúrbios decompostos tanto pelo método FICA quanto pelo método SCICA. Repare que essa distribuição segue a mesma codificação apresentada na Tabela 6.5 para distúrbios isolados. Cada amostra de saída desejada corresponde a sua respectiva amostra de padrões de entrada das Figuras 6.15 ou 6.16.

## 6.4 Projeto, treinamento e teste das RNAs dos classificadores

A seguir será apresentada a metodologia de projeto, bem como os resultados alcançados para o treinamento e para o teste, das RNAs contidas nos classificadores de distúrbios de QEE propostos.

### 6.4.1 RNA responsável pela classificação dos distúrbios do componente fundamental

A topologia da RNA projetada para a classificação dos distúrbios do componente fundamental é mostrada na Figura 6.18. Tal RNA possui arquitetura *feed-forward*, sendo mais precisamente uma rede do tipo PMC. A camada de entrada de dados da RNA é composta pelos padrões

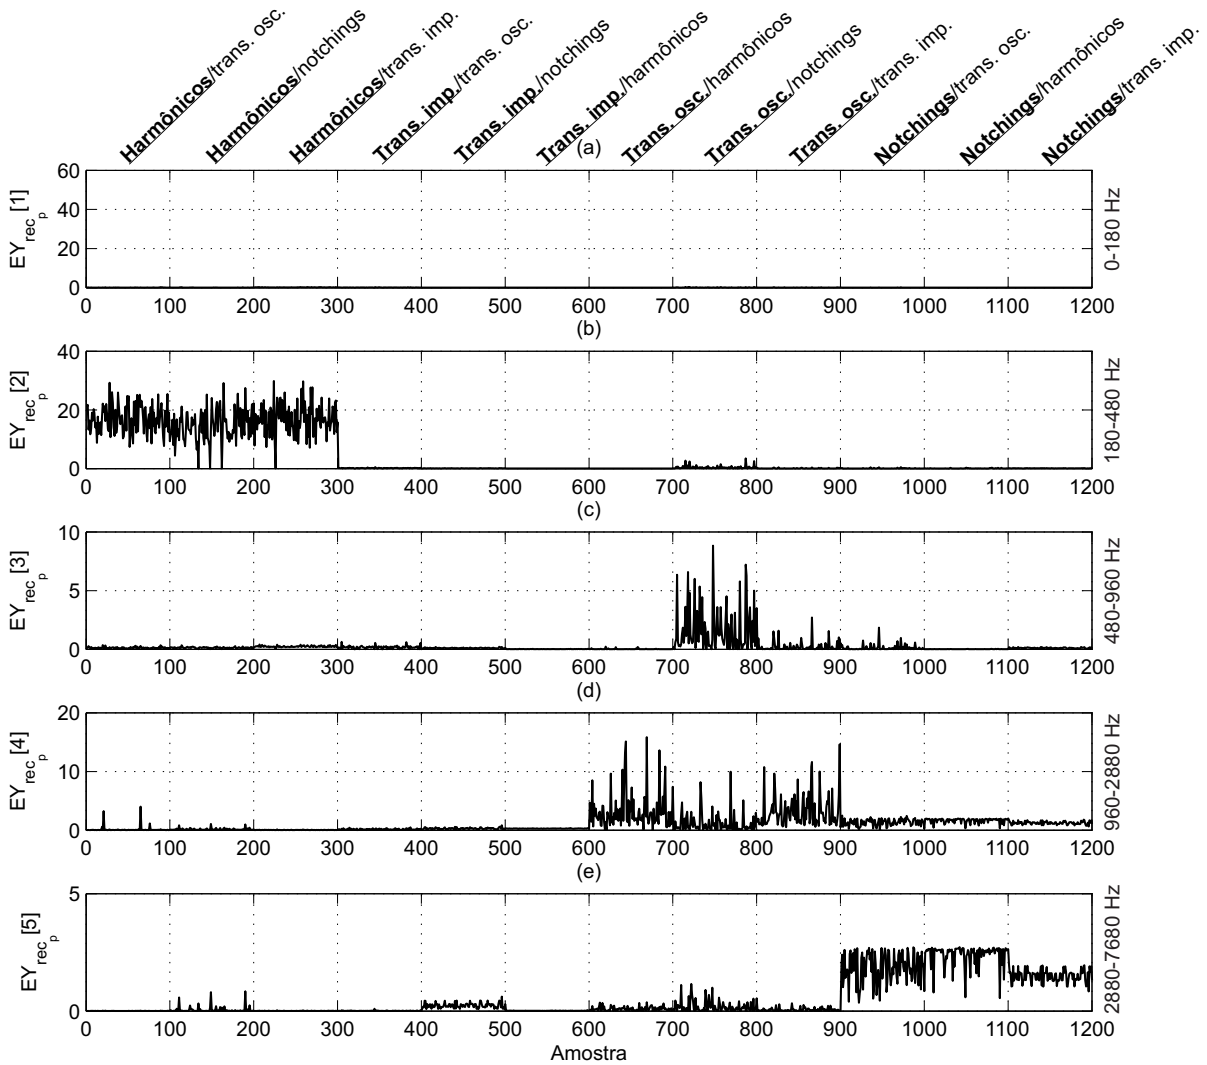


Figura 6.16: Distribuição dos padrões de entrada para treinamento do classificador de distúrbios do sinal de erro separados pelo método SCICA.

de entrada normalizados advindos da etapa de extração de características da Figura 6.3. A RNA possui duas camadas neurais, sendo a camada neural intermediária composta por $N_1 = 15$ neurônios, e a camada neural de saída composta por $N_2 = 4$ neurônios. Cada neurônio da camada neural de saída é responsável por acusar a presença ou a ausência de uma determinada classe de distúrbio. A função de ativação empregada nos neurônios da camada intermediária é a tangente hiperbólica. A função de ativação dos neurônios da camada de saída é a linear, responsável por produzir uma combinação linear de suas entradas, advindas das saídas dos neurônios da camada intermediária.

O treinamento da RNA foi executado admitindo-se um valor limite de 1000 épocas e visando um Erro Quadrático Médio (EQM) mínimo de $1,0 \times 10^{-7}$, sendo o processo de treinamento da RNA encerrado assim que qualquer um dos dois critérios acima for primeiramente alcançado.

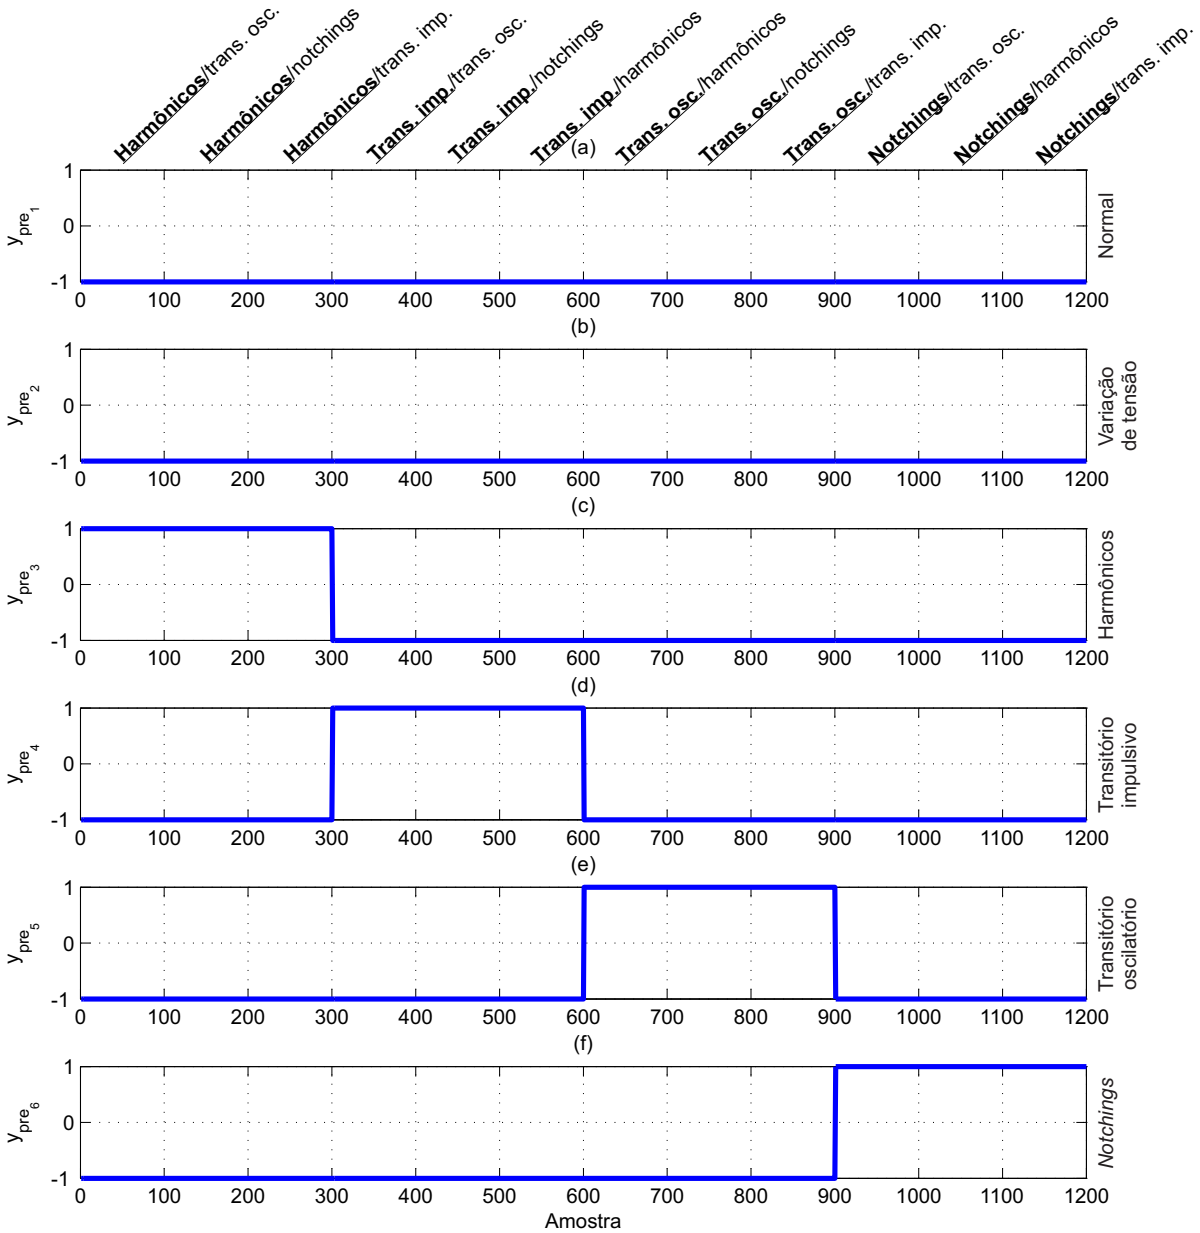


Figura 6.17: Distribuição das saídas desejadas para treinamento do classificador de distúrbios do sinal de erro separados pelo método FICA ou pelo método SCICA.

Foram fornecidos ao algoritmo de treinamento as amostras dos padrões de entrada (normalizados) da Figura 6.9, juntamente com as respectivas amostras dos padrões de saídas desejadas da Figura 6.10. O algoritmo de treinamento utilizado foi o de Levenberg-Marquardt, por ser um método da ordem de 10 a 100 vezes mais rápido que o algoritmo *backpropagation* convencional (da Silva *et al.*, 2010). A Figura 6.19 mostra a evolução do EQM em função da época de treinamento, onde percebe-se que o critério de parada de treinamento acionado foi o alcance do EQM mínimo estipulado. O treinamento foi paralisado na 76ª época.

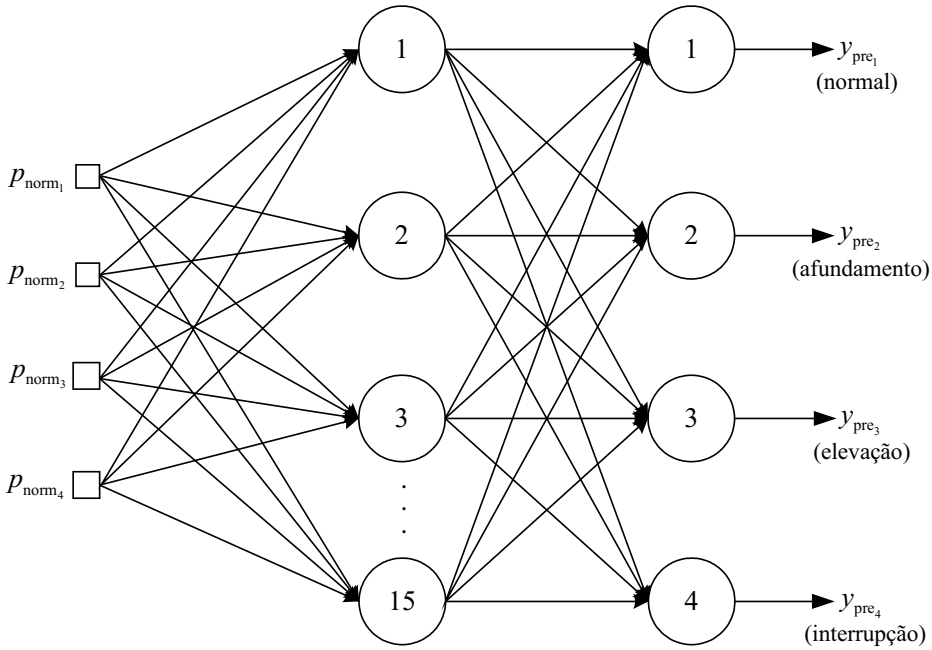


Figura 6.18: Topologia da RNA utilizada para classificar os distúrbios do componente fundamental.

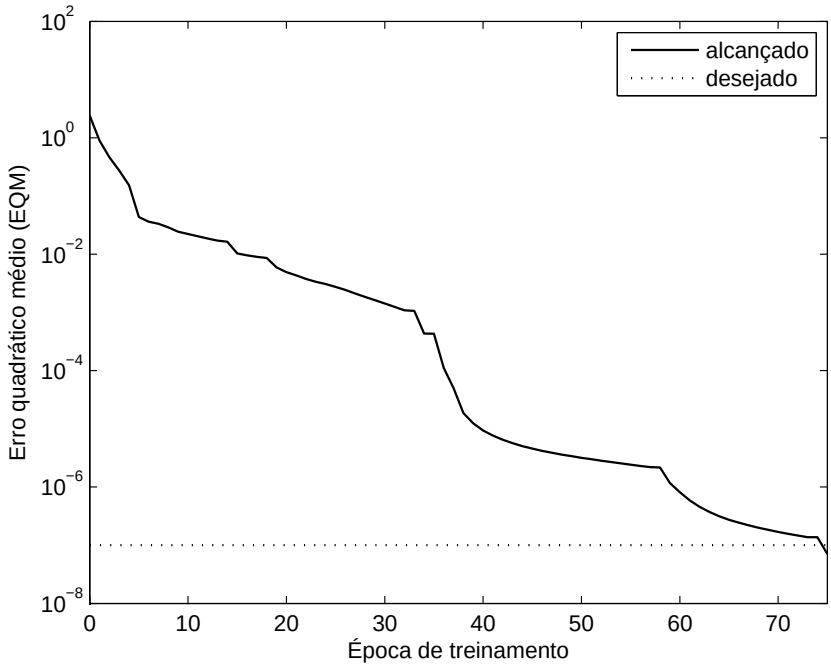


Figura 6.19: Gráfico de treinamento da RNA especializada na identificação do distúrbio presente no componente fundamental.

A Figura 6.20 apresenta o resultado do teste da RNA, realizado após finalizado o seu treinamento. Para tanto, foram utilizados somente os dados do conjunto de teste, os quais foram

gerados de forma independente dos dados do conjunto de treinamento. Tal estratégia servirá para quantificar o grau de generalização alcançado pela RNA, ao serem apresentados padrões de entrada desconhecidos, mas que estejam dentro do seu domínio de definição.

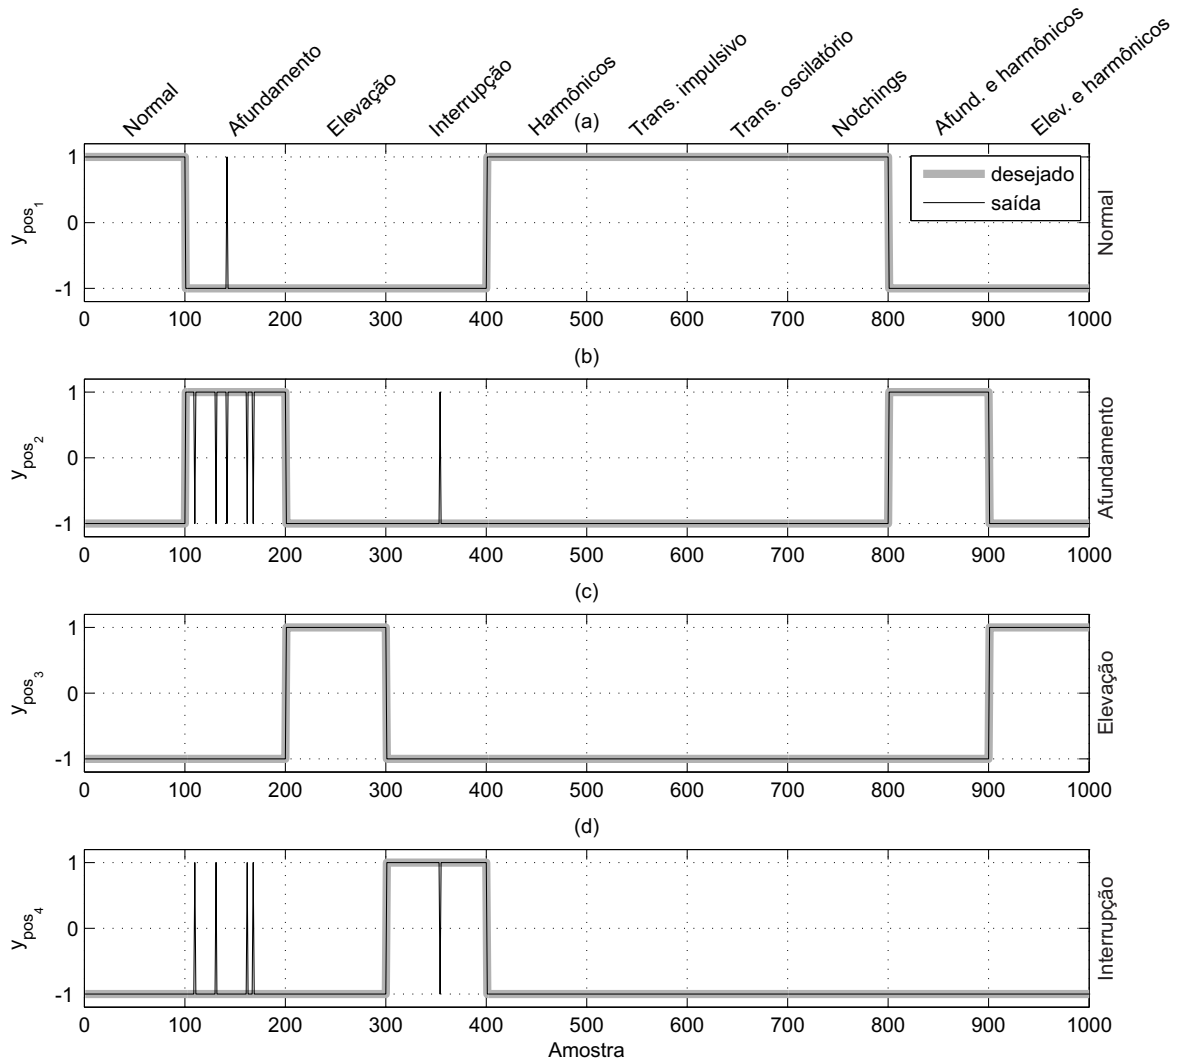


Figura 6.20: Resultado de teste da RNA especializada na identificação dos distúrbios presentes no componente fundamental.

Conforme observado na Figura 6.20, são apresentadas as curvas dos valores desejados e das saídas da RNA (após a etapa de pós-processamento). Percebe-se que o classificador não apresentou erro na identificação de componente fundamental normal (sem distúrbio), já que para todas as amostras que possuem distúrbios que não afetam o componente fundamental, ou seja, para as amostras que possuem distúrbios diferentes de afundamento, elevação ou interrupção, as saídas da RNA foram todas iguais aos valores desejados. Já para as amostras que possuem afundamento (amostras 101 até 200 e 801 até 900), cinco destas foram classificadas indevidamente, sendo quatro amostras classificadas como interrupção (saída $y_{\mathrm{pos}_4}$ ativada) e uma amostra classi-

ficada como normal (saída $y_{\text{pos}_1}$ ativada). Para as amostras que possuem elevação (amostras 201 até 300 e 901 até 1000), não houve erro na sua classificação. Finalmente, para as amostras que possuem interrupção (amostras 301 até 400), apenas uma foi classificada erroneamente como sendo afundamento (saída $y_{\text{pos}_2}$ ativada). A Tabela 6.6 resume numericamente os resultados alcançados.

Tabela 6.6: Taxa de classificação e eficiência global obtidas pelo classificador de distúrbios do componente fundamental, para o conjunto de teste.

| Classe/tipo de distúrbio | Taxa de acerto (%) |
|---|---|
| Normal (sem distúrbio) | 100,00 |
| Afundamento | 97,50 |
| Elevação | 100,00 |
| Interrupção | 99,00 |
| Taxa de acerto global | 99,40 |

### 6.4.2 RNA responsável pela classificação dos distúrbios do sinal de erro - metodologia baseada no método FICA

A topologia da RNA projetada para a classificação dos distúrbios do sinal de erro é mostrada na Figura 6.21. Assim como a RNA do classificador de distúrbios do componente fundamental, esta RNA também possui arquitetura *feed-forward*, sendo também uma rede do tipo PMC. A camada de entrada de dados da RNA é composta pelos padrões de entrada normalizados advindos da etapa de extração de características da Figura 6.5. A RNA possui três camadas neurais, sendo, portanto, mais complexa do que a RNA responsável por classificar os distúrbios do componente fundamental. Isto se deve ao próprio fato de haver uma maior complexidade na distinção entre os tipos de distúrbios do sinal de erro, que podem tanto ser originalmente isolados quanto terem sido decompostos pelo método FICA. Ambas as camadas neurais intermediárias ($N_1$ e $N_2$) são compostas por 15 neurônios cada, e a camada neural de saída é composta por $N_3 = 6$ neurônios, sendo cada um responsável por acusar a presença ou a ausência de uma determinada classe de distúrbio do sinal de erro. A função de ativação empregada nos neurônios das camadas intermediárias é do tipo tangente hiperbólica, e a função de ativação dos neurônios da camada de saída é do tipo linear.

Para o treinamento desta RNA, foram fornecidos como entradas as amostras dos padrões de distúrbios isolados da Figura 6.11, em conjunto com as amostras dos padrões de distúrbios múltiplos decompostos pelo método FICA da Figura 6.15. Como consequência, os dados de

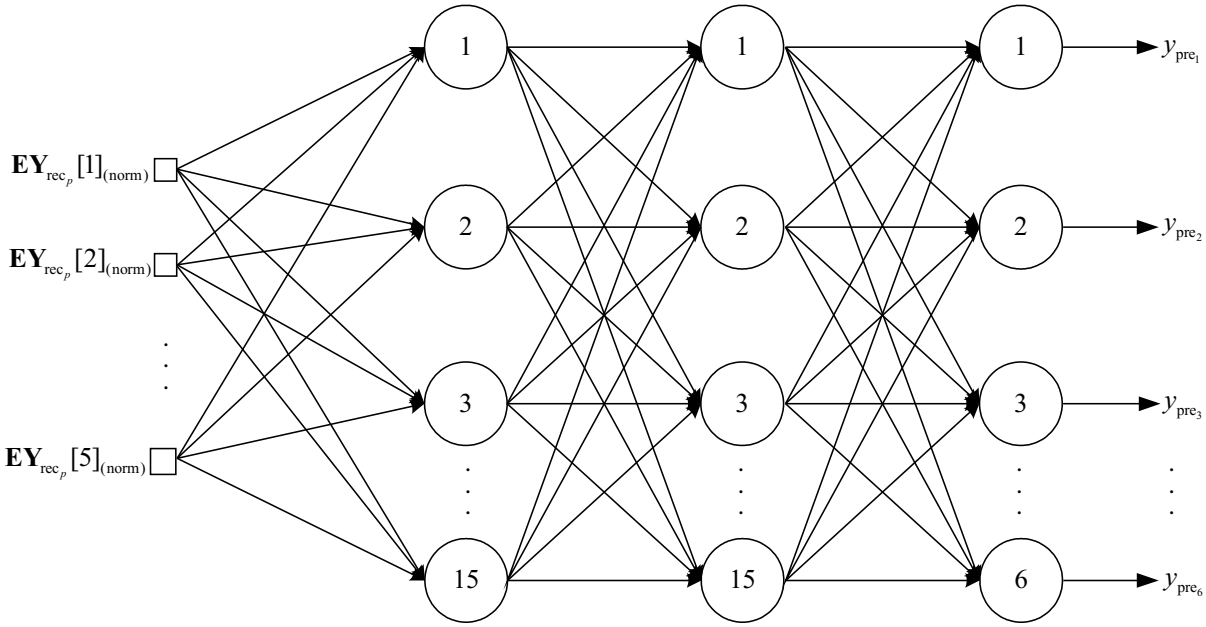


Figura 6.21: Topologia da RNA utilizada para classificar os distúrbios do sinal de erro.

saídas desejadas são compostos pela junção das amostras das Figuras 6.13 e 6.17. Com isso, espera-se que esta RNA possa reconhecer tanto um distúrbio originalmente isolado quanto uma estimativa de distúrbio separado que tenha sido obtida pelo método FICA a partir de sinais contendo múltiplos distúrbios.

O treinamento da RNA foi executado admitindo-se um valor limite de 500 épocas e visando um EQM mínimo de $1,0 \times 10^{-3}$, sendo o processo de treinamento encerrado assim que qualquer um dos dois critérios for primeiramente alcançado. O algoritmo de treinamento utilizado foi o de Levenberg-Marquardt. A Figura 6.22 mostra a evolução do EQM em função da época de treinamento, onde percebe-se que o critério de parada de treinamento acionado foi o alcance do número máximo de épocas. O valor do EQM mínimo alcançado foi $2,3 \times 10^{-3}$.

A Figura 6.23 apresenta os resultados de teste da RNA, para o conjunto de dados de teste contendo distúrbios isolados. Como pode ser observado, o classificador apresentou erro apenas para duas amostras, em um conjunto de 1000 amostras. A primeira, extraída de um sinal contendo transitório oscilatório (faixa de amostras de 601 a 700), foi classificada como contendo transitório impulsivo (saída $y_{\mathrm{pos}_4}$ ativada). A segunda, extraída de um sinal contendo elevação e harmônicos (faixa de amostras de 901 a 1000), foi classificada como contendo, além da variação de tensão (saída $y_{\mathrm{pos}_2}$ ativada) e dos harmônicos (saída $y_{\mathrm{pos}_3}$ ativada), também transitório impulsivo (saída $y_{\mathrm{pos}_4}$ ativada) e transitório oscilatório (saída $y_{\mathrm{pos}_5}$ ativada).

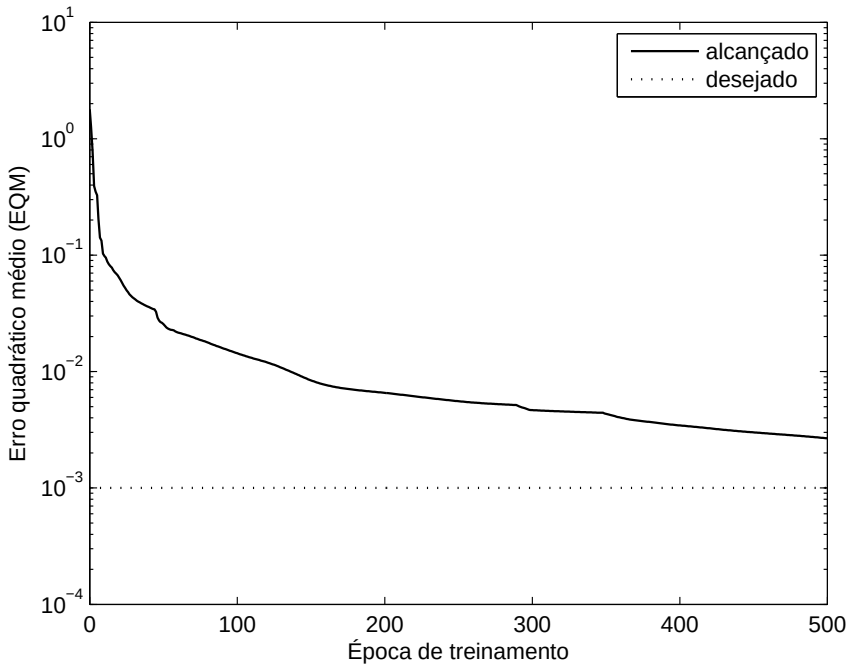


Figura 6.22: Gráfico de treinamento da RNA especializada na identificação do distúrbio presente no sinal de erro - método FICA.

A Figura 6.24 apresenta os resultados de teste da RNA, desta vez para o conjunto de dados de teste contendo estimativas de distúrbios decompostos pelo método FICA. Pode ser observado que a RNA apresentou piores resultados para a classificação destes dados do que para os dados de distúrbios isolados, o que é natural de acontecer, já que as estimativas podem conter contaminação de informação de outros distúrbios. Percebe-se que o maior número de falhas ocorreu para as estimativas de transitórios oscilatórios que foram extraídas de sinais que também continham *notchings* (**Trans. osc.**/notchings, amostras 701 a 800). Outras falhas que também chamam atenção ocorreram para as estimativas de transitórios oscilatórios extraídas de sinais que também continham transitórios impulsivos (**Trans. osc.**/trans. imp., amostras 801 a 900). Isto ocorre em função justamente desses distúrbios serem os mais difíceis de ser separados pelo método FICA, como foi visto nos resultados da Seção 5.3.2. Repare que a maioria absoluta das estimativas de transitórios oscilatórios que foram classificadas indevidamente foram classificadas como transitório impulsivo (saída $y_{\text{pos}_5}$ desativada e saída $y_{\text{pos}_4}$ ativada). Apesar desses resultados gráficos talvez levarem a uma interpretação negativa da identificação desses distúrbios, será visto na Tabela 6.7, a qual resume numericamente os resultados alcançados, que a menor taxa de acerto alcançada por esse classificador é de 89%, para as estimativas de transitórios oscilatórios separados de *notchings*.

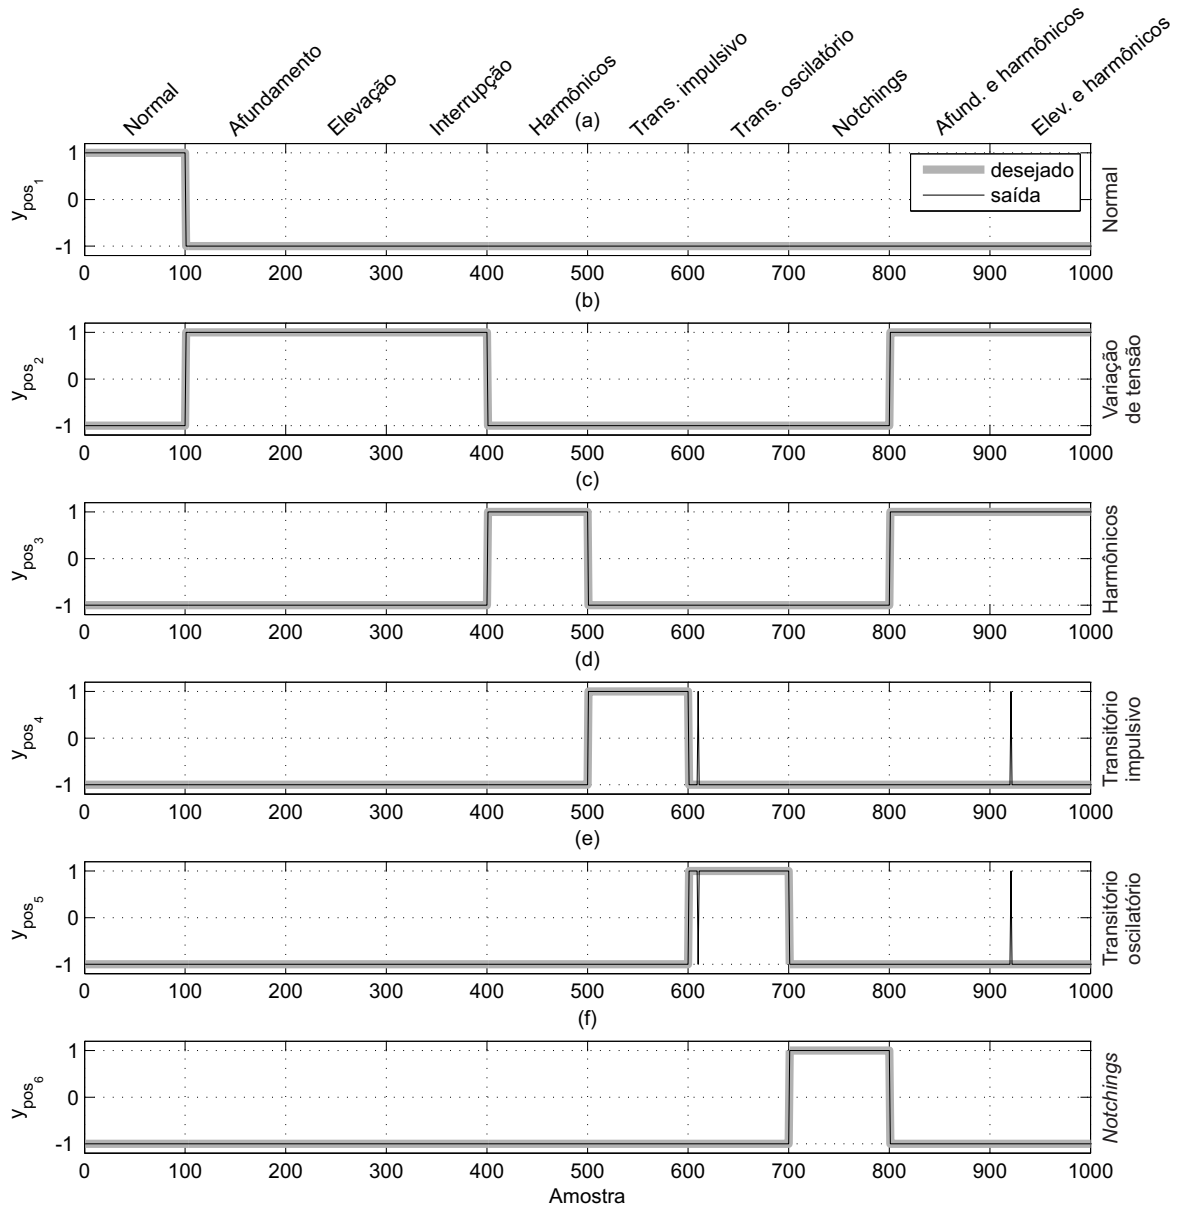


Figura 6.23: Resultado de teste da RNA especializada na identificação dos distúrbios presentes no sinal de erro, para a metodologia baseada no método FICA - distúrbios isolados.

### 6.4.3 RNA responsável pela classificação dos distúrbios do sinal de erro - metodologia baseada no método SCICA

Esta RNA possui a mesma topologia daquela mostrada na Figura 6.21. A diferença é que agora a camada de entrada de dados recebe os padrões de entrada normalizados advindos da etapa de extração de características da Figura 6.8. Para o treinamento desta RNA, foram fornecidas como entradas as amostras dos padrões de distúrbios isolados da Figura 6.11, em conjunto com as amostras dos padrões de distúrbios múltiplos decompostos pelo método SCICA

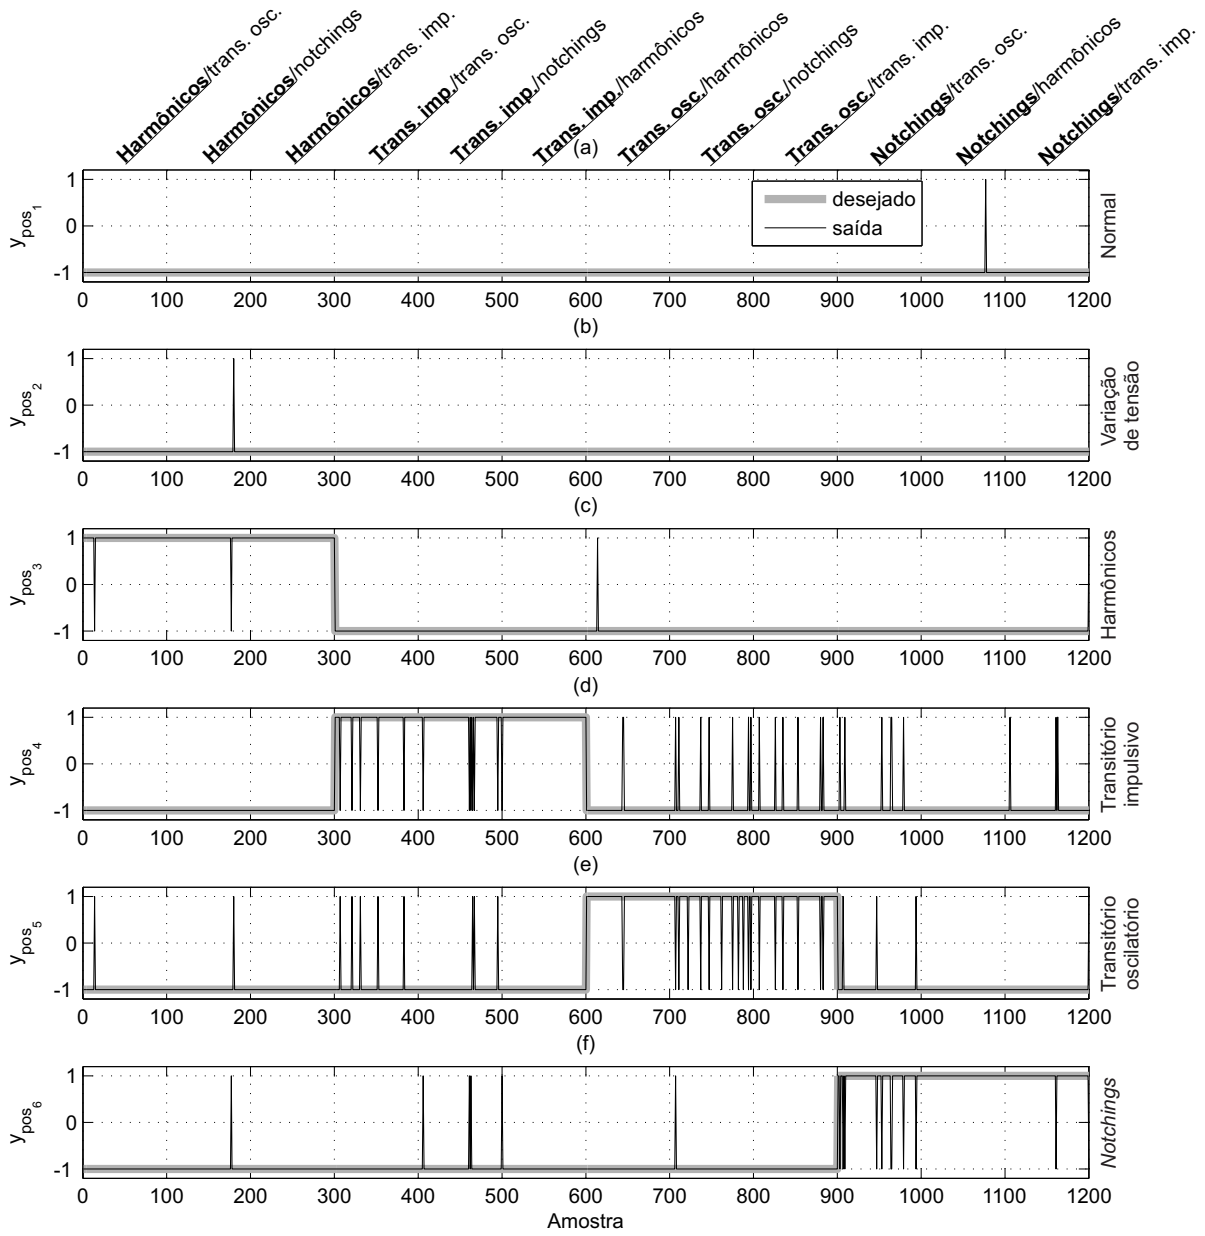


Figura 6.24: Resultado de teste da RNA especializada na identificação dos distúrbios presentes no sinal de erro, para a metodologia baseada no método FICA - distúrbios múltiplos decompostos.

da Figura 6.16. Os dados de saídas desejadas são compostos pela junção dos conjuntos de amostras das Figuras 6.13 e 6.17.

Assim como para a RNA empregada em conjunto com o método FICA, o treinamento desta RNA também foi executado admitindo-se um valor limite de 500 épocas e visando um EQM mínimo de $1,0 \times 10^{-3}$. O algoritmo de treinamento utilizado também foi o de Levenberg-Marquardt. A Figura 6.25 mostra a evolução do EQM em função da época de treinamento, onde percebe-se que para este caso, diferentemente do anterior para o método FICA, o critério

de parada de treinamento acionado foi o alcance do EQM mínimo estipulado, na época de número 284.

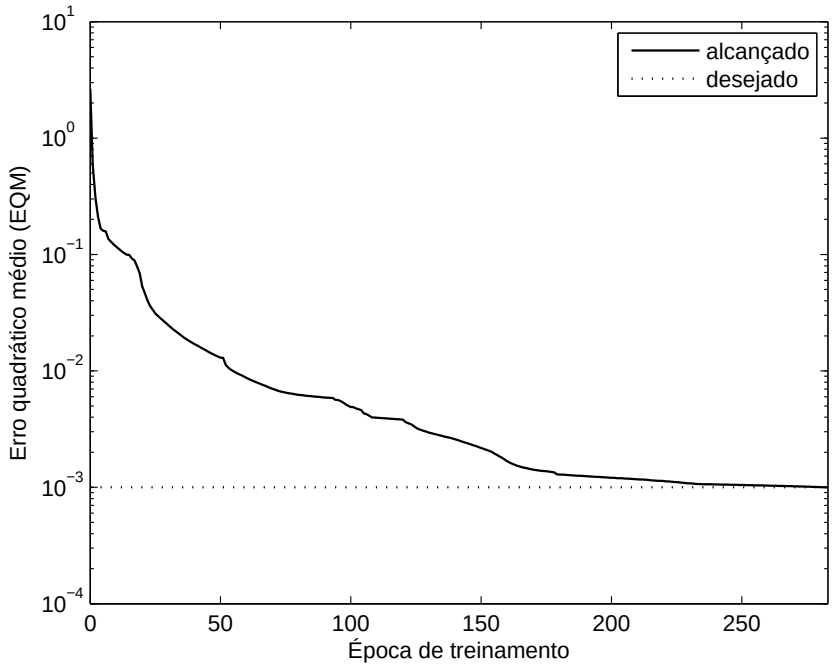


Figura 6.25: Gráfico de treinamento da RNA especializada na identificação do distúrbio presente no sinal de erro - método SCICA.

A Figura 6.26 apresenta os resultados de teste da RNA, para o conjunto de dados de teste contendo distúrbios isolados. Observa-se que houve apenas três amostras classificadas indevidamente. A primeira, tendo sido extraída de um sinal contendo afundamento (faixa de amostras de 101 até 200), foi classificada como contendo, além de uma variação de tensão (saída $y_{\text{pos}_2}$ ativada), também um transitório oscilatório (saída $y_{\text{pos}_5}$ ativada). A segunda, extraída de um sinal contendo transitório oscilatório (faixa de amostras de 601 até 700), foi classificada como contendo transitório impulsivo (saída $y_{\text{pos}_4}$ ativada) e não transitório oscilatório (saída $y_{\text{pos}_5}$ desativada). A terceira, extraída de um sinal contendo elevação e harmônicos (faixa de amostras de 901 até 1000), foi classificada como contendo harmônicos (saída $y_{\text{pos}_3}$ ativada), mas como não contendo variação de tensão (saída $y_{\text{pos}_2}$ desativada). Além disso, também foi classificada como contendo transitório oscilatório (saída $y_{\text{pos}_5}$ ativada).

A Figura 6.27 apresenta os resultados de teste da mesma RNA, agora para o conjunto de dados de teste contendo estimativas de distúrbios decompostos pelo método SCICA. Assim como para o classificador baseado no método FICA, observa-se também aqui que a RNA apresentou piores resultados para a classificação desses dados do que para os dados de distúrbios

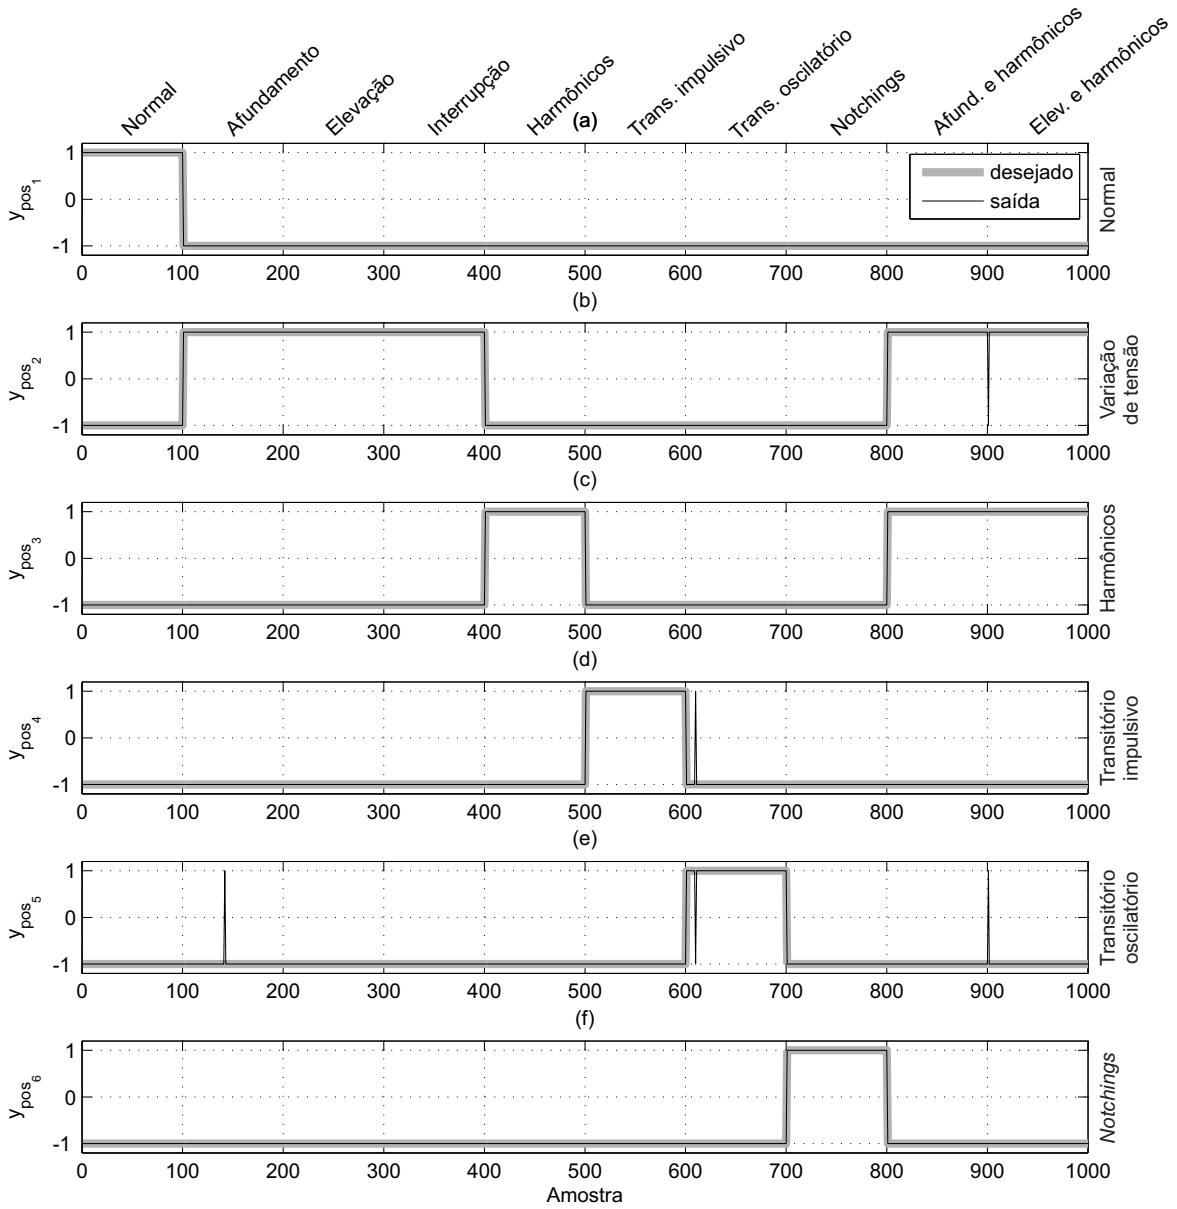


Figura 6.26: Resultado de validação da RNA especializada na identificação dos distúrbios presentes no sinal de erro, para a metodologia baseada no método SCICA - distúrbios isolados.

isolados. Percebe-se que aqui o maior número de falhas também ocorreu para as estimativas de transitórios oscilatórios que foram extraídas de sinais que também continham *notchings* (**Trans. osc.**/notchings, amostras 701 a 800). Isto se deve ao fato dos transitórios oscilatórios serem mais difíceis de serem separados dos *notchings* do que dos demais distúrbios pelo método SCICA. Outras falhas que chamam atenção ocorreram para as estimativas de transitórios oscilatórios extraídas de sinais que também continham harmônicos (**Trans. osc.**/harmônicos, amostras 601 a 700). Isto se deve a erros da etapa de agrupamento do método SCICA. Assim como para o classificador baseado no método FICA, a maior parte das estimativas de transitórios

oscilatórios que foram classificadas indevidamente foram classificadas como sendo estimativas de transitórios impulsivos. De uma maneira geral, ao se comparar os resultados das Figuras 6.24 e 6.27, percebe-se que o classificador baseado no método SCICA apresentou menor quantidade de erros do que o classificador baseado no método FICA.

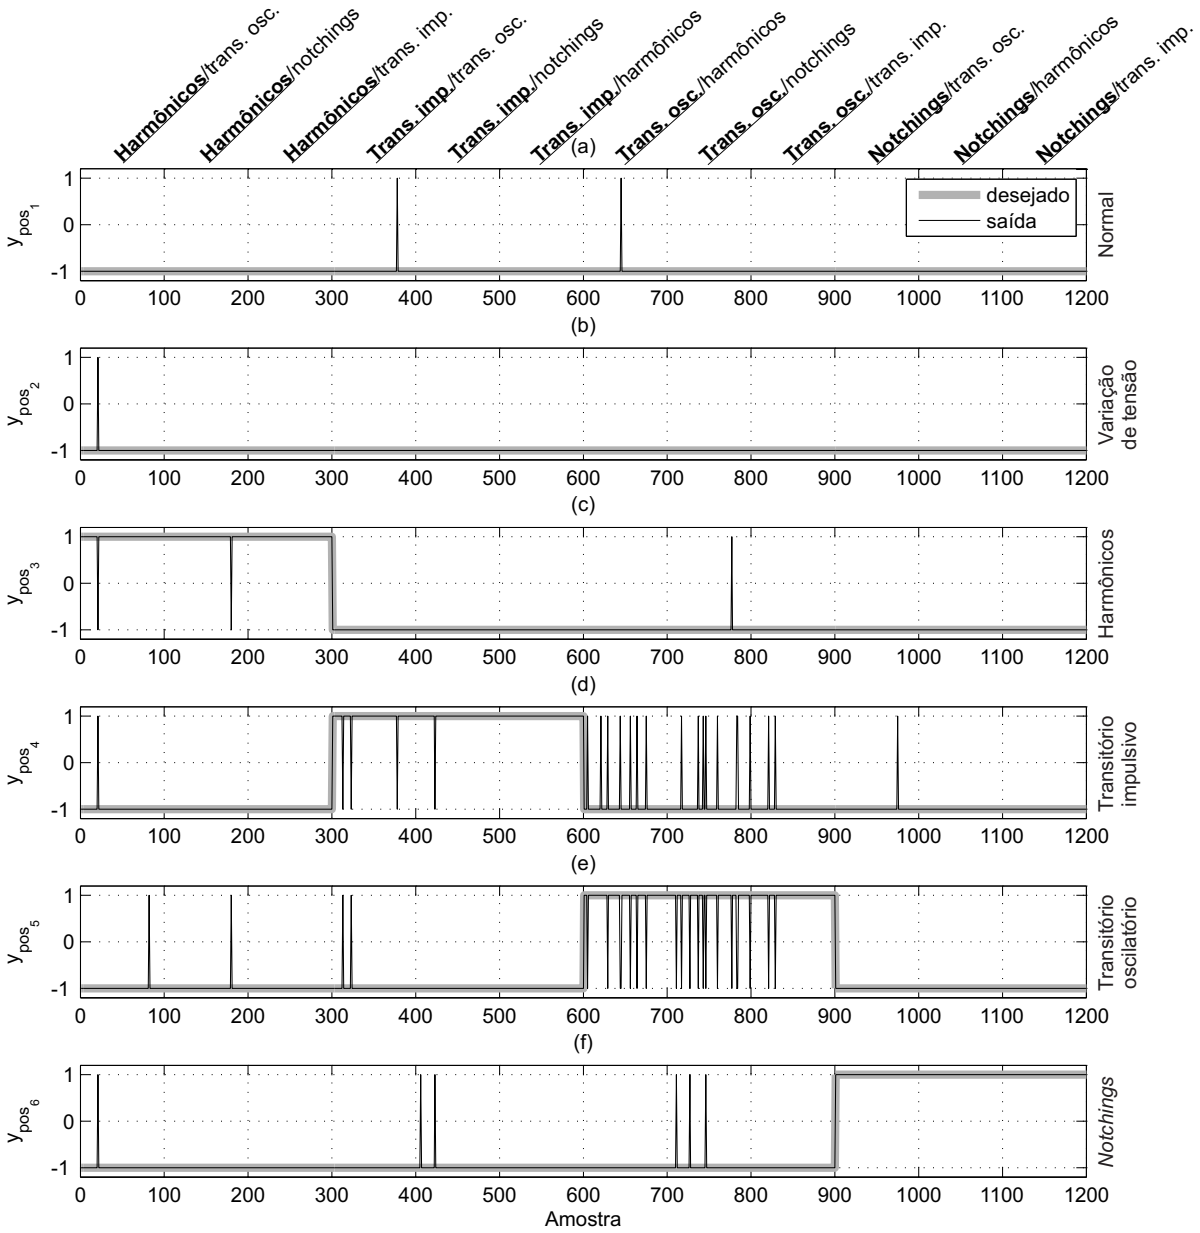


Figura 6.27: Resultado de validação da RNA especializada na identificação dos distúrbios presentes no sinal de erro, para a metodologia baseada no método SCICA - distúrbios decompostos.

A Tabela 6.7 resume de forma numérica a comparação dos resultados alcançados pelos classificadores de distúrbios do sinal de erro para ambos os métodos, onde confirma-se que o sistema classificador que utiliza o método SCICA como ferramenta de decomposição apresentou resultados ligeiramente superiores àqueles alcançados pelo sistema classificador que utiliza o método

FICA. Isto pode ser atribuído ao fato do método SCICA ter alcançado resultados de separação de múltiplos distúrbios na maior parte das vezes melhores do que o método FICA. Com isto, a RNA do classificador baseado no método SCICA conseguiu aproximar melhor as fronteiras de separação entre as classes de distúrbios. De fato, o treinamento desta RNA foi melhor do que daquela do classificador baseado no método FICA, como pode ser constatado através da comparação das curvas de EQM das Figuras 6.22 e 6.25. A RNA do classificador baseado no método FICA não alcançou o EQM mínimo desejado. Já a RNA do classificador baseado no método SCICA o alcançou.

Tabela 6.7: Taxa de classificação e eficiência global (%) obtidas pelos classificadores de distúrbios no sinal de erro, para o conjunto de teste.

| Classe de distúrbio | Taxa de acerto (%) | |
|---|---|---|
| | FICA | SCICA |
| Normal (sem distúrbio) | 100,00 | 100,00 |
| Variação de tensão | 100,00 | 99,67 |
| Harmônicos | 100,00 | 100,00 |
| Transitório impulsivo | 100,00 | 100,00 |
| Transitório oscilatório | 99,00 | 99,00 |
| *Notchings* | 100,00 | 100,00 |
| Afundamento/Elevação e harmônicos | 99,50 | 99,50 |
| **Harmônicos**/transitório oscilatório | 99,00 | 98,00 |
| **Harmônicos**/*notchings* | 98,00 | 99,00 |
| **Harmônicos**/transitório impulsivo | 100,00 | 100,00 |
| **Transitório impulsivo**/transitório oscilatório | 95,00 | 97,00 |
| **Transitório impulsivo**/*notchings* | 93,00 | 98,00 |
| **Transitório impulsivo**/harmônicos | 100,00 | 100,00 |
| **Transitório oscilatório**/harmônicos | 97,00 | 93,00 |
| **Transitório oscilatório**/*notchings* | 89,00 | 89,00 |
| **Transitório oscilatório**/transitório impulsivo | 94,00 | 98,00 |
| ***Notchings***/transitório oscilatório | 91,00 | 99,00 |
| ***Notchings***/harmônicos | 99,00 | 100,00 |
| ***Notchings***/transitório impulsivo | 96,00 | 100,00 |
| Taxa de acerto global | 97,86 | 98,60 |

Observa-se na Tabela 6.7 que os resultados de teste de classificação para ambos os métodos foram satisfatórios. Para a classificação de distúrbios originalmente isolados, as taxas de acerto são muito semelhantes e altamente satisfatórias, sendo a menor delas igual a 99%, para a identificação de transitórios oscilatórios, para ambos os métodos. Com relação à identificação de distúrbios múltiplos separados, ambos os métodos também obtiveram resultados satisfatórios, porém inferiores àqueles encontrados para o caso de distúrbios isolados, já que as estimativas

neste caso não estão imunes à contaminação de informação por parte de outros distúrbios. A menor taxa de acerto foi igual a 89% para ambos os métodos, para a identificação de transitórios oscilatórios separados de *notchings*. Para a identificação dos demais tipos de distúrbios múltiplos separados, o sistema de classificação baseado no método SCICA na maioria dos casos apresentou resultados superiores, próximos a 100% de acerto.

## 6.5 Considerações finais do capítulo

Este capítulo apresentou um metodologia para classificação dos sinais resultantes da aplicação do sistema de decomposição proposto no capítulo anterior, sendo sua função reconhecer automaticamente todos os distúrbios presentes no sinal de entrada. A metodologia de classificação se divide em dois subsistemas. O primeiro subsistema é responsável pela classificação dos distúrbios do componente fundamental, e o segundo subsistema é responsável pela classificação dos distúrbios do sinal de erro, sendo que este último subsistema recebe os sinais de saída do método FICA ou do método SCICA.

A utilização da metodologia de decomposição possibilitou estimar os componentes primitivos do sinal de entrada, sobretudo na condição de múltiplos distúrbios. Pelo fato dos componentes primitivos carregarem informações diretas dos diferentes distúrbios independentes, ferramentas especialistas, porém simples, como o valor RMS e a DFT, puderam ser utilizadas com sucesso para a extração dos parâmetros fornecidos para as RNAs identificarem os distúrbios. Tanto o sistema de classificação que utiliza o método FICA quanto o que utiliza o método SCICA obtiveram altas taxas de acerto na identificação dos distúrbios originalmente isolados ou dos distúrbios múltiplos que foram separados, sendo as taxas de acerto globais superiores a 97% para ambos os métodos. Contudo, os resultados do sistema que utiliza o método SCICA foram ligeiramente superiores, fato este devido a este método obter resultados de separação de múltiplos distúrbios na maior parte das vezes melhores do que o método FICA. O próximo capítulo apresenta as conclusões finais acerca de toda a pesquisa desenvolvida e aponta sugestões para sua continuidade.

# Capítulo 7

# Conclusões

Foi abordado neste trabalho o problema de ocorrência de múltiplos distúrbios de QEE, tendo sido proposta uma metodologia para decomposição adaptativa e não-supervisionada do sinal medido em componentes que estimam as formas de onda dos distúrbios individuais, com a posterior identificação automática de cada um deles. Para tanto, foram utilizadas técnicas de processamento de sinais e inteligência computacional tipicamente empregadas nas áreas de separação cega de fontes e classificação de padrões. As principais ferramentas computacionais utilizadas no trabalho foram a ICA e as RNAs.

A metodologia de decomposição proposta se fundamenta no *princípio de dividir para conquistar*, que sugere a decomposição de um problema assumido complexo em sub-problemas mais simples. De acordo com o modelo de sinal elétrico empregado neste trabalho, um sinal de tensão ou corrente é composto pela soma de parcelas denominadas componentes primitivos, dos quais padrões primitivos podem ser independentemente extraídos, sendo cada componente primitivo associado a um conjunto reduzido e disjunto de distúrbios de QEE. Então, o objetivo da aplicação da metodologia foi decompor o sinal elétrico em componentes primitivos que pudessem recuperar as formas de onda dos distúrbios individuais, sobretudo na condição de ocorrência de múltiplos distúrbios.

Para realizar a decomposição, a metodologia inicialmente divide o sinal medido em seu componente fundamental e no sinal de erro, sendo este último a diferença entre o sinal medido e a estimativa de componente fundamental obtida pelo filtro *notch*. Então, empregando-se a ICA, são obtidas estimativas dos componentes independentes do sinal de erro. Para que a ICA pudesse ser aplicada tendo-se disponível apenas este sinal para realizar a separação não-supervisionada

de seus múltiplos distúrbios, foram propostos dois métodos: o método FICA e o método SCICA.

Ambos os métodos foram apresentados no Capítulo 4, tendo sido demonstrado em detalhes seus princípios de funcionamento e as condições para que os mesmos sejam capazes de separar e recuperar as fontes misturadas no sinal aplicado em sua entrada. As aplicações tradicionais da ICA (múltiplos sensores) buscam pela independência espacial das fontes, já que é assumido que tanto elas quanto os sensores se localizam em posições distintas entre si no espaço. Já os métodos propostos buscam pela independência das fontes no plano tempo-frequência, já que não há como recuperar a independência espacial dispondo-se de um único sensor. Desta forma, eles não conseguem separar fontes misturadas que possuam sobreposição espectral. Para gerar artificialmente múltiplos sinais de observação para a ICA a partir de um único sinal de entrada, o método FICA realiza a filtragem do mesmo por meio de um banco de filtros FIR pré-determinados e fixos, e o método SCICA realiza a aplicação de sucessivos atrasos temporais neste sinal de entrada.

Foi demonstrado que a estrutura geral do método FICA equivale a um banco de filtros FIR adaptativos cujos coeficientes são ajustados por meio de uma operação conjunta da ICA e do banco de filtros FIR fixos que geram os sinais de observação. Também foi demonstrado que, além das fontes independentes terem que ocorrer em bandas distintas de frequência, outra condição para que o método FICA possa recuperá-las a partir do sinal de entrada é que os filtros FIR fixos apliquem ganhos e atrasos constantes nas bandas de frequência de cada uma delas.

Os filtros fixos devem também gerar sinais de observação linearmente independentes, para que a matriz de mistura obtida artificialmente por eles seja invertível, para que desta forma, a ICA possa encontrar a sua inversa e recuperar as fontes unicamente a partir dos sinais de observação. Além de constantes, os atrasos de todos os filtros fixos devem ser iguais, significando que todos eles devem possuir a mesma ordem, mantendo assim o sincronismo entre as observações fornecidas à ICA. Assim sendo, a menos das indeterminações de escala e ordem inerentes ao modelo da ICA, e do atraso provocado pelo banco de filtros fixos, é possível a ICA ajustar uma matriz de separação que recupere as fontes. O problema da indeterminação das escalas é eficientemente resolvido por meio da utilização do combinador linear adaptativo para estimar os pesos das fontes através do algoritmo LMS.

A maior dificuldade na utilização do método FICA é, sem dúvida, o projeto adequado dos filtros fixos de forma que eles cumpram todas as restrições acima, já que isto poder demandar algum conhecimento prévio a respeito dos espectros de frequência das fontes, embora tenha

sido visto que ele pode ainda fornecer resultados excelentes mesmo que essas restrições sejam parcialmente cumpridas. O método SCICA não utiliza filtros fixos para gerar os sinais de observação, e sim a aplicação de sucessivos atrasos temporais no sinal de entrada.

A operação geral do método SCICA também equivale a um banco de filtros FIR adaptativos, capaz de separar de maneira não-supervisionada as fontes independentes não-sobrepostas espectralmente no sinal de entrada. O método proposto também possui um esquema para recuperar as escalas das fontes, por meio do mapeamento destas de volta ao domínio dos sinais de observação com base nas próprias matrizes de mistura e separação estimadas pela ICA. Uma importante característica do método SCICA ao mapear os componentes independentes de volta ao domínio dos sinais de observação é que ele alcança uma reconstrução perfeita do sinal de entrada.

O método SCICA geralmente necessita de um número de sinais de observação maior do que o número de fontes, para se alcançar filtros com comprimentos suficientes para filtrá-las. Como consequência, mais de um componente independente pode estar associado a uma mesma fonte, tendo sido utilizado o algoritmo *k-means* para identificar e agrupar os componentes independentes associados a cada fonte. Este algoritmo é passível de erros de operação, podendo agrupar juntas as estimativas associadas a fontes diferentes ou agrupar separadamente as estimativas associadas a uma mesma fonte. Devido ao fato do método SCICA não necessitar de qualquer projeto inicial, ele é mais fácil de ser utilizado do que o método FICA. Porém, sua estrutura computacional é mais complexa, já que nele a ICA é aplicada em dados de dimensões maiores e ele necessita da etapa de agrupamento.

No Capítulo 5, foi proposta a metodologia para decompor uma forma de onda de tensão ou corrente, metodologia esta composta pelo filtro *notch* para estimar o componente fundamental, e pelo método FICA ou pelo método SCICA para estimar os componentes independentes e espectralmente disjuntos restantes no sinal de erro. Para a metodologia que utiliza o método FICA, importantes aspectos de projeto são o número de filtros fixos, a ordem desses filtros e suas respostas em frequência. Suas respostas em frequência devem atender às próprias restrições do método, já comentadas anteriormente. O número de filtros está diretamente relacionado ao número de componentes independentes a serem estimados pela ICA. Usualmente, dois ou três filtros são suficientes, já que a probabilidade de mais de três distúrbios independentes ocorrerem simultaneamente seria pequena. A ordem desses filtros deve ser suficiente para gerar misturas linearmente independentes e não deve ser demasiadamente elevada para não provocar atrasos

também elevados e transitórios indesejáveis nos sinais de observação.

Os testes realizados variando-se a frequência de corte do filtro $h_2[n]$, para a separação entre dois tipos de distúrbios pelo método FICA, mostraram que ela pode ser escolhida aleatoriamente dentro de uma faixa relativamente larga de valores, que ainda assim as restrições do método são satisfeitas e os resultados alcançados são satisfatórios. Os testes variando-se a ordem de ambos os filtros fixos ($h_1[n]$ e $h_2[n]$) mostraram que a ordem também afeta pouco os resultados, podendo a mesma ser escolhida aleatoriamente dentro de uma faixa larga de valores. A maior parte dos testes realizados neste trabalho empregaram uma ordem $K = 20$. Os resultados dos testes mostraram que, embora haja a necessidade do projeto inicial do banco de filtros fixos, este não precisa ser rígido.

Os testes realizados escolhendo-se um número de filtros maior do que o número de distúrbios mostraram que estimativas bem representativas de cada distúrbio ainda podem ser obtidas, mas pelo menos um dos distúrbios pode também ser sub-decomposto em mais de uma estimativa. Para os testes envolvendo um número de filtros menor do que o número de distúrbios, a configuração não é suficiente para obter estimativas que separem por completo todos os distúrbios envolvidos.

Para a metodologia que emprega o método SCICA, os parâmetros mais importantes são o número de sinais de observação e o número de *clusters* definidos. O comprimento dos filtros adaptativos obtidos é igual ao número de sinais de observação. Sendo assim, este parâmetro interfere na qualidade das estimativas, pois quanto maior o comprimento de um filtro linear, mais seletivo na frequência ele é. Foi visto nos testes de separação de distúrbios variando-se o número de sinais de observação que, à medida que se aumenta sua quantidade, a qualidade das estimativas obtidas também aumenta. Entretanto, a partir de um certo ponto, não se alcança mais melhoria significativa, podendo até mesmo obter resultados instáveis devido ao aumento da dimensão dos dados e da complexidade de todo o processo de estimação. A maior parte dos testes realizados neste trabalho utilizaram $M = 12$ sinais de observação.

O número de *clusters* estimados na etapa de agrupamento diz respeito ao número de sinais de saída a ser fornecido pelo método SCICA. Idealmente, seu valor deve ser igual ao número de distúrbios independentes a serem separados. Os testes realizados escolhendo-se um número de *clusters* maior do que o número de distúrbios revelaram que aquele distúrbio que possui espectro de frequências mais amplo foi sub-decomposto em mais de uma saída. Para os testes escolhendo-se um número de *clusters* menor do que o número de distúrbios, observou-se que

aqueles distúrbios que possuem espectros de frequências mais estreitos foram agrupados juntos dentro de um mesmo *cluster*.

De uma maneira geral, os diversos resultados de decomposição alcançados por ambos os métodos propostos, sobretudo na análise quantitativa, revelaram que ambos são capazes de separar e reconstruir com grande exatidão as formas de onda dos distúrbios independentes que não possuem sobreposição espectral. Entretanto, mesmo quando há sobreposição parcial de seus espectros, eles ainda são capazes de obter estimativas que se aproximam mais das formas de onda dos distúrbios individuais do que o sinal de erro, o qual contém os distúrbios ainda misturados. Ambos os métodos FICA e SCICA obtiveram desempenhos semelhantes, com uma ligeira superioridade do método SCICA, sobretudo para a aplicação em dados reais. Isto mostrou que a metodologia de decomposição proposta pode efetivamente vir a ser empregada como uma ferramenta para análise de QEE.

O Capítulo 6 apresentou uma metodologia proposta para classificação dos sinais provenientes da aplicação do sistema de decomposição, sendo sua função identificar automaticamente todos os distúrbios presentes no sinal de entrada. Seguindo a filosofia do *princípio de dividir para conquistar*, o sistema de classificação se subdivide em dois subsistemas, sendo um dedicado à identificação dos distúrbios do componente fundamental a partir de sua estimativa fornecida pelo filtro *notch*, e o outro subsistema dedicado à identificação dos distúrbios do sinal de erro, sendo que este último recebe os sinais de saída do método FICA ou do método SCICA.

O subsistema dedicado à classificação dos distúrbios do componente fundamental utiliza o cálculo de estatísticas relacionados ao valor RMS para o fornecimento dos padrões de entrada para a RNA. A extração de informações que distinguem individualmente esses distúrbios (afundamento, elevação, interrupção ou componente fundamental sem distúrbio) é eficientemente realizada pela utilização do valor RMS, embora esta seja uma ferramenta simples. O classificador de uma maneira geral é computacionalmente simples e alcançou uma taxa de acerto global de 99,40%.

O subsistema dedicado à classificação dos distúrbios do sinal de erro utiliza o cálculo das energias acumuladas em diferentes faixas de frequências que distinguem individualmente esses distúrbios (variação de tensão, harmônicos, transitório impulsivo, transitório oscilatório, *notchings* ou sinal de erro sem distúrbio). Para transformar os sinais para o domínio da frequência, é utilizada a DFT, mais uma ferramenta simples, porém suficiente para o propósito. Tendo sido os distúrbio múltiplos decompostos pelo método FICA ou pelo método SCICA nas faixas de

frequências que os distinguem, a RNA foi capaz de determinar as fronteiras de separação entre as classes. O classificador que utiliza o método FICA alcançou uma taxa de acerto global de 97,86%, e o classificador que utiliza o método SCICA atingiu 98,60%.

Por fim, os resultados alcançados mostraram que as metodologias de decomposição e classificação propostas podem proporcionar uma análise e um diagnóstico preciso a respeito dos distúrbios que estejam ocorrendo isoladamente ou em multiplicidade dentro de uma janela de dados do sinal amostrado. Dadas as restrições do método FICA, especialmente da necessidade do projeto adequado do banco de filtros fixos, e que a utilização do método SCICA levou a resultados de decomposição e classificação melhores, ainda que ligeiramente, a utilização deste pode ser preferida em relação àquele em aplicações práticas, embora seja computacionalmente mais complexo.

## 7.1 Propostas de continuidade da pesquisa

A seguir são listadas algumas propostas que podem ser pesquisadas ou implementadas como continuidade do trabalho desenvolvido até então. Estas propostas visam, especialmente, melhorias de desempenho e aplicações práticas da metodologia proposta. As sugestões são enumeradas como se segue.

- Inicialmente, propõe-se testes substituindo-se o algoritmo FastICA por outras alternativas que também realizam a separação cega de fontes, tais como o algoritmo Infomax, o algoritmo AMUSE e o algoritmo JADE (Leite, 2004). Com isto, torna-se possível estudar as diferenças entre os diferentes algoritmos com relação ao desempenho e esforço computacional.

- Vislumbra-se também a implementação em *hardware* das metodologias propostas neste trabalho, levando com isto a um estudo mais aprofundado de suas complexidades computacionais e de possíveis simplificações para serem passíveis de ser implementadas, realizando-se uma relação de compromisso adequada entre esforço e desempenho computacional.

- No método FICA, propor um estágio para desfazer, baseando-se em conceitos de filtragem inversa, a distorção provocada pelos filtros fixos nas fontes quando as restrições de separabilidade são apenas parcialmente cumpridas. Com isto, espera-se melhorar a qualidade da separação das fontes promovida por este método.

- Investigar a aplicação do método de decomposição empírica (Empirical-Mode Decomposition (EMD)) como alternativa para gerar os sinais de observação para a ICA a partir de um único sinal medido, tomando como base o método proposto em Mijovic *et al.* (2010). A EMD é uma técnica não-linear capaz de decompor uma série temporal em um conjunto de modos oscilatórios espectralmente independentes. A vantagem da EMD em relação a um banco de filtros fixos é que ela é um algoritmo iterativo que depende da natureza do sinal aplicado em sua entrada, sendo desta forma adaptativo. Os componentes obtidos pela EMD contêm apenas uma frequência em cada instante de tempo, a qual é denominada frequência instantânea. A propriedade da ortogonalidade implica que diferentes componentes não possuem conteúdo de frequência similar. Pretende-se com a utilização deste método alcançar a separação de fontes que possuam sobreposição de espectros.

- Por fim, objetiva-se também realizar uma pesquisa utilizando-se medições obtidas por múltiplos monitores de QEE dispostos em diferentes posições de um SEP, e com a utilização do modelo de misturas convolutivas da ICA, tentar identificar os distúrbios e as prováveis localizações de suas fontes, sem o conhecimento prévio da topologia do SEP.

# Referências Bibliográficas


Abdel-Galil, T., M. Kamel, A. M. Youssef, E. F. El-Saadany, e M. M. A. Salama (2004). Power quality disturbance classification using the inductive inference approach. *IEEE Transactions on Power Delivery 19*(4), 1812–1818.

Ai, Y. e H. Zhang (2013). Harmonic Separation Based on Independent Component Analysis Method. *Journal of Computers 8*(2), 433–440.

ANEEL (2012). *Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - PRODIST*. http://www.aneel.gov.br/area.cfm?idArea=82: ANEEL.

Angrisani, L., P. Daponte, e M. D'Apuzzo (2001). Wavelet network-based detection and classification of transients. *IEEE Trans. Instrim. Measurement 50*(5), 1425–1435.

Arrillaga, J., M. H. J. Bollen, e N. R. Watson (2000). Power quality following deregulation. *Proceedings of the IEEE 88*(2), 246–261.

Arruda, E. F. (2003). *Análise de Distúrbios Relacionados com a Qualidade da Energia Elétrica Utilizando a Transformada Wavelet*. Dissertação de Mestrado, Escola de Engenharia de São Carlos, Universidade de São Paulo.

Axelberg, P. G. V., I. Y. H. Gu, e M. H. J. Bollen (2007). Support vector machine for classification of voltage disturbances. *IEEE Trans. on Power Delivery 22*(3), 1297–1303.

Barros, J. e E. Perez (2006). Automatic detection and analysis of voltage events in power systems. *IEEE Trans. Instrum. Measure. 55*(5), 1487–1493.

Bentley, E. C., G. A. Putrus, S. McDonald, e P. Minns (2010). Power quality disturbance source identification using self-organising maps. *IET Generation, Transmission & Distribution 4*(10), 1188–1196.

Biswal, B., P. K. Dash, e B. K. Panigrahi (2009). Power Quality Disturbance Classification Using Fuzzy C-Means Algorithm and Adaptive Particle Swarm Optimization. *IEEE Transactions on Industrial Electronics 56*(1), 212–220.

Bollen, M. H. J. e I. Gu (2006). *Signal Processing of Power Quality Disturbances.* Wiley-IEEE Press.

Bollen, M. H. J., I. Y. H. Gu, S. Santoso, M. F. McGranaghan, P. A. Crossley, M. V. Ribeiro, e P. F. Ribeiro (2009). Bridging the Gap Between Signal and Power. *IEEE Signal Processing Mazazine 23*(4), 12–31.

Bollen, M. H. J., E. Styvaktakis, e I. Y. H. Gu (2005). Categorization and analysis of power system transients. *IEEE Transactions on Power Delivery 20*(3), 2298–2306.

Bollen, M. H. J., J. Zhong, F. Zavoda, J. Meyer, A. McEachern, e F. C. López (2010). Power quality aspects of smart grids. In *International Conference on Renewable Energies and Power Quality.*

Castells, F., C. Mora, J. Millet, J. J. Rieta, C. Sanchez, e J. Sanchis (2004). Multidimensional ICA for the separation of atrial and ventricular activities from single lead ECGs in paroxysmal atrial fibrillation epsiodes. In *Proceedings of International Conference on ICA 2004, Lecture Notes in Computer Science*, Volume 3195, pp. 1229–1234.

Cavalcante, C. C. (2004). *Sobre Separação Cega de Fontes: Proposições e Análise de Estratégias para Processamento Multi-Usuário.* Tese de Doutorado, UNICAMP.

Chen, S. e H. Y. Zhu (2007). Wavelet transform for processing power quality disturbances. *EURASIP J. Adv. Signal Process (Special Issue on Emerging Signal Processing Techniques for Power Quality Applications).*

Chuang, C. L., Y. L. Lu, T. L. Huang, Y. T. Hsiao, e J. A. Jiang (2005a). Recognition of multiple PQ disturbances using dynamic structure neural networks - Part 1: Theoretical introduction. In *IEEE/PES Transmission and Distribution Conference and Exhibition: Asia and Pacific.*

Chuang, C. L., Y. L. Lu, T. L. Huang, Y. T. Hsiao, e J. A. Jiang (2005b). Recognition of multiple PQ disturbances using dynamic structure neural networks - Part 2: Implementation and applications. In *IEEE/PES Transmission and Distribution Conference and Exhibition: Asia and Pacific.*

Chung, J., E. J. Powers, W. M. Grady, e S. C. Bhatt (2002). Power disturbance classifier using a rule-based method and wavelet packet-based Hidden Markov Model. *IEEE Trans. on Power Delivery 17*(1), 233–241.

Coifman, R. R. e D. L. Donoho (1995). Translation-invariant denoising. In *A. Antoniadis, G. Oppenheim (EDs.), Wavelets and Statistics, Springer Lecture Notes in Statistics*, Volume 103, pp. 126–150.

Comon, P. (1994). Independent component analysis, A new concept? *Signal Processing 36*, 287–314.

Cover, T. M. e J. A. Thomas (1991). *Elements of Information Theory* (Second Edition ed.). John Wiley & Sons.

da Silva, I. N., D. H. Spatti, e R. A. Flauzino (2010). *Redes Neurais Artificiais: para engenharia e ciências aplicadas.* Artliber Editora.

Dash, P. K., B. K. Panigrahi, D. K. Sahoo, e G. Panda (2003). Power quality disturbance data compression, detection, and classification using integrated spline waveelt and S-Transform. *IEEE Trans. on Power Delivery 18*(2), 595–600.

Dash, P. K., M. M. A. Salama, S. Mishra, e A. C. Liew (2000). Classification of power system disturbances using a fuzzy expert system and a fourier linear combiner. *IEEE Trans. Power Deliv. 15*(2), 472–477.

Davies, M. E. e C. J. James (2007). Source Separation Using Single Channel ICA. *Signal Processing 87*(8), 1819–1832.

Dubey, H. C., S. R. Mohanty, e N. Kishore (2011). Abrupt change detection of fault in power system using independent component analysis. In *Proceedings of 2011 International Conference on Signal Processing, Communication, Computing and Networking Technologies (ICSCCN 2001)*, pp. 659–664.

Dugan, R. C., M. F. McGranaghan, S. Santoso, e H. W. Beaty (2004). *Electrical Power Systems Quality* (2 ed.). McGraw-Hill.

Duque, C. A., M. V. Ribeiro, F. R. Ramos, e J. Szczupak (2005). Power quality event detection based on the divide and conquer principle and innovation concept. *IEEE Transactions on Power Delivery 20*(4), 2361–2369.

Duque, C. A., P. M. Silveira, T. Baldwin, e P. F. Ribeiro (2008). Novel method for tracking time-varying power harmonic distortions without frequency spillover. In *Proc. IEEE Power Engineering Soc. General Meeting*, pp. 1–6.

Electrotek Concepts, Inc. (2013). *TOP, The Output Processor - Example Output Files.* http://www.pqsoft.com/top/download2.htm: Electrotek Concepts, Inc.

Faisal, M. F. e A. Mohamed (2009). Identification of multiple power quality disturbances using S-transform and rule based classification technique. *Journal of Applied Sciences 9*(15), 2688–2700.

Farhoodnea, M., A. Mohamed, e H. Shareef (2010). Identification of multiple harmonic sources in power systems using independent component analysis and mutual information. *Engineering Intelligent Systems 1*, 51–63.

Ferreira, D., J. de Seixas, e A. Cerqueira (2009). ICA-based method for power quality disturbance analysis. In *Intelligent System Applications to Power Systems, 2009. ISAP '09. 15th International Conference on*, pp. 1–6.

Ferreira, D., J. de Seixas, e A. Cerqueira (2012). Single channel ICA-based method for power quality disturbance analysis. In *XIX Congresso Brasileiro de Automática, 2012*, pp. 1561–1568.

Ferreira, D. D. (2010). *Análise de Distúrbios Elétricos em Sistemas de Potência.* Tese de Doutorado, Universidade Federal do Rio de Janeiro.

Flores, R. A. (2002). State of the art in the classification of power quality events, an overview. In *International Conference on Harmonics and Quality of Power*, pp. 17–20.

Gaing, Z.-L. (2004). Wavelet-based neural network for power disturbance recognition and classification. *IEEE Trans. on Power Delivery 19*(4), 1560–1568.

Gaouda, A. M., S. H. Kanoun, M. M. A. Salama, e A. Y. Chikhani (2002). Pattern recognition applications for power system disturbance classification. *IEEE Transactions on Power Delivery 17*(3), 677–683.

Gaouda, A. M., M. M. Salama, M. R. Sultan, e A. Y. Chikhani (1999). Power quality detection and classification using wavelet-multiresolution signal decomposition. *IEEE Trans. on Power Delivery 14*(4), 1469–1476.

Gu, I. Y. H. e M. H. J. Bollen (2000). Time-frequency and time-scale domain analysis of voltage disturbances. *IEEE Trans. on Power Delivery 15*(4), 1279–1284.

Gu, I. Y. H. e M. H. J. Bollen (2008). Estimating interharmonics by using sliding-window ESPRIT. *IEEE Transactions on Power Delivery 23*(1), 13–23.

Gu, I. Y. H., N. Ernberg, E. Styvaktakis, e M. H. J. Bollen (2004). Statistical-based sequential method for fast online detection of fault-induced voltage dips. *IEEE Trans. on Power Delivery 19*(2), 497–504.

Gu, I. Y.-H. e E. Styvaktakis (2003). Bridge the gap: signal processing for power quality applications. *Electric Power Systems Research 66*, 83–96.

Gu, I. Y. H., E. Styvaktakis, e M. H. J. Bollen (2000). Analyzing power disturbances using the residuals of AR models. *IEEE Power Eng. Rev. 20*(4), 60–62.

Gursoy, E. e D. Niebur (2005). Impact of sample size on ICA-based harmonic souce estimation. In *Proceedings of* $13^{th}$ *International Conference on Intelligent Systems Applications to Power Systems (ISAP 2005)*, pp. 123–127.

Gursoy, E. e D. Niebur (2009). Harmonic Load Identification Using Complex Independent Component Analysis. *IEEE Transactions on Power Delivery 24*(1), 285–292.

Hagan, M. T. e M. B. Menhaj (1994). Training Feedforward Networks with the Marquardt Algorithm. *IEEE Transactions on Neural Networks 5*(6), 989–993.

Han, S.-H., H.-H. Kim, e H.-D. Bae (2005). Extraction of Rotating Machine Sources for Fault Diagnostics using Independent Component Analysis. In *IMTC 2005 - Instrumentation and Measurement Technology Conference*, Ottawa, Canada.

Haykin, S. (2002). *Adaptive Filter Theory* (4 ed.). Prentice-Hall.

Haykin, S. (2008). *Neural Networks and Learning Machines* (3 ed.). Prentice Hall.

He, H. e J. A. Starzyk (2006). A self-organizing learning array system for power quality classification based on wavelet transform. *IEEE Transactions on Power Delivery 21*(1), 286–295.

Hooshmand, R. e A. Enshaee (2010). Detection and classification of single and combined power quality distubances using fuzzy systems oriented by particle swarm optimization algorithm. *Electric Power Systems Research 80*(12), 1552–1561.

Hyvärinen, A. (1999). Fast and robust fixed-point algorithms for independent component analysis. *IEEE Transactions on Neural Networks 10*(3), 626–634.

Hyvärinen, A., J. Karhunen, e E. Oja (2001). *Independent Component Analysis.* John Wiley & Sons.

Ibrahim, W. R. A. e M. M. Morcos (2002). Artificial intelligence and advanced mathematical tools for power quality applications: A survey. *IEEE Transactions on Power Delivery 17*(2), 668–673.

IEEE P1159.3 Task Force (2013). http://grouper.ieee.org/groups/1159/3/docs.html: IEEE P1159.3 Task Force.

IEEE Std. 1159 (2009). *IEEE Recommended Practices for Monitoring Electric Power Quality.*

Janik, P. e T. Lobos (2006). Automated classification of power-quality disturbances using SVM and RBF networks. *IEEE Transactions on Power Delivery 21*(3), 1663–1669.

Jung, T., S. Makeig, C. Humphries, T. Lee, M. McKeown, V. Iragul, e T. Sejnowski (2000). Removing electroencephalographic artifacts by blind source separation. *Psychophysiology 37*, 163–168.

Kapoor, R. e M. K. Saini (2011). Hybrid demodulation comcept and harmonic analysis for single/multiple power quality events detection and classification. *International Journal of Electrical Power and Energy Systems 33*, 1608–1622.

Khan, A. K. (2001). Monitoring power for the future. *Power Engineering Journal 15*(2), 81–85.

Leite, V. C. M. N. (2004). *Separação Cega de Sinais: Análise Comparativa entre Algoritmos.* Dissertação de Mestrado, Universidade Federal de Itajubá.

Liao, H. W. e D. Niebur (2003). Load profile estimation in electric transmission networks using independent component analysis. *IEEE Transactions on Power Systems 18*(2), 707–715.

Lima, M. A. A. (2009). *Análise de Componentes Independentes Aplicada em Distúrbios de Qualidade de Energia.* Dissertação de Mestrado, Faculdade de Engenharia da Universidade Federal de Juiz de Fora.

Liquan, Z. e J. Yanfei (2010). Interharmonic estimation based on complex valued independent component analysis. In *Wireless Communications, Networking and Information Security (WCNIS), 2010 IEEE International Conference on*, pp. 248–251.

Littler, T. B. e D. J. Marrow (1999). Wavelet for the analysis and compression of power system disturbances. *IEEE Trans. on Power Delivery 14*, 358–362.

Lu, Y.-L., C.-L. Chuang, C.-S. Fahn, e J.-A. Jiang (2008). Multiple disturbances classifier for electric signals using adaptive structuring neural networks. *Measurement Science and Technology 19*, 1–11.

Ma, H. e A. A. Girgis (1996). Identification and tracking of harmonic sources in a power system using a Kalman filter. *IEEE Transactions on Power Delivery 11*(3), 1659–1665.

McCulloch, W. S. e W. Pitts (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics 5*, 115–133.

Mijovic, B., M. D. Vos, I. Gligorijevic, J. Taelman, e S. V. Huffel (2010). Source Separation From Single-Channel Recordings by Combining Empirical-Mode Decomposition and Independent Component Analysis. *IEEE Transactions on Biomedical Engineering 57*(9), 2188–2196.

Mishra, S., C. N. Bhende, e B. K. Panigrahi (2008). Detection and classification of power quality disturbances using S-transform and probabilistic neural network. *IEEE Transactions on Power Delivery 23*(1), 280–287.

Mitra, S. K. (2006). *Digital Signal Processing: A Computer-Based Approach* (Third ed.). Tata McGraw-Hill.

Mohan, N., T. M. Underland, e W. P. Robbins (1995). *Power Electronics: Converters, Applications, and Design* (2 ed.). John Wiley & Sons, Inc.

Oleskovicz, M., D. V. Coury, O. D. Filho, W. F. Usida, A. A. F. M. Carneiro, e L. R. S. Pires (2009). Power quality analysis applying a Hybrid methodology with wavelet transforms and neural networks. *International Journal of Electrical Power & Energy Systems 31*, 206–212.

Oppenheim, A. V. e R. W. Schafer (1998). *Discrete-Time Signal Processing* (2 ed.). Prentice Hall Signal Processing Series.

Papoulis, A. e S. U. Pillai (2002). *Probability, Random Variables and Stochastic Process* (Fourth ed.). McGraw Hill.

PC/104 Consortium (2013). *No Title*. http://www.pc104.org: Online.

Ribeiro, M. V. e J. L. R. Pereira (2007). Classification of single and multiple disturbances in electric signals. *EURASIP Journal on Advances in Signal Processing 2007*, 1–18.

Ruiz-Llata, M., G. Guarnizo, e C. Boya (2011). Embedded power quality monitoring system based on independent component analysis and svms. In *Neural Networks (IJCNN), The 2011 International Joint Conference on*, pp. 2229–2234.

Santacana, E., G. Rackliffe, L. Tang, e X. Feng (2010). Getting smart. *IEEE Power and Energy Magazine 8*(2), 41–48.

Santoso, S., W. M. Grady, E. J. Powers, J. Lamoore, e S. Bhatt (2000). Characterization of distribution power quality events with Fourier and wavelet transforms. *IEEE Transactions on Power Delivery 15*(1), 247–254.

Santoso, S., E. J. Powers, e W. M. Grady (1997). Power quality disturbance data compression using wavelet transform methods. *IEEE Trans. on Power Delivery 12*(3), 1250–1257.

Santoso, S., E. J. Powers, W. M. Grady, e A. C. Parsons (2000). Power quality disturbance waveform recognition using wavelet-based neural classifier. *IEEE Transactions on Power Delivery 15*(1), 222–235.

Saxena, D., K. S. Verma, e S. N. Singh (2010). Power quality event classification: an overview and key issues. *International Journal of Engineering, Science and Technology 2*(3), 186–199.

Stockwell, R. G., L. Mansinha, e R. P. Lowe (1996). Localization of the complex spectrum: The S transform. *IEEE Transactions on Signal Processing 44*(4), 998–1001.

Stranneby, D. (2001). *Digital Signal Processing: DSP & Applications* (1 ed.).

Styvaktakis, E. (2002). *Automating Power Quality Analysis*. Ph.D. dissertation, Dept. of Signals and Systems, Chalmers Univ. Technology, Gothenburg, Sweden.

Styvaktakis, E., M. H. J. Bollen, e I. Y. H. Gu (2002). Expert system for classification and analysis of power system events. *IEEE Trans. on Power Delivery 17*(2), 423–428.

Supriya, P. e P. Nambiar (2012). Integrated Kalman-Independent Component Analysis Method for Harmonic Current Estimation on an Interconnected Four Bus Simulated and Laboratory Model. *International Journal of Emerging Electric Power Systems 13*(3), 1–15.

Supriya, P. e T. N. P. Nambiar (2011). Harmonic current estimation using blind signal processing techniques. In *Proceedings of IEEE Conference on Signal Processing, Comunication, Computing and Network Technologies*, pp. 107–111.

Theodoridis, S. e K. Koutroumbas (2003). *Pattern Recognition* (2 ed.).

Trindade, R. M. (2005). *Sistema Digital de Detecção e Classificação de Eventos de Qualidade de Energia.* Dissertação de Mestrado, Faculdade de Engenharia da Universidade Federal de Juiz de Fora.

van Casteren, J. F. L., J. F. G. Cobben, J. H. R. Enslin, W. T. J. Hulshorst, W. L. Kling, e M. D. Hamoen (2005). A customer oriented approach to the classification of voltage dips. In *Proc. CIRED Conf.*

Wang, F. e M. H. J. Bollen (2004). Frequency-Response Characteristics and Error Estimation in RMS Measurement. *IEEE Transactions on Power Delivery 19*(5), 1569–1578.

Wang, M. e A. V. Mamishev (2004). Classification of power quality events using optimal time-frequency representations - Part 1: Theory. *IEEE Transactions on Power Delivery 19*(3), 1488–1495.

Wang, M., G. I. Rowe, e A. V. Mamishev (2004). Classification of power quality events using optimal time-frequency representations - Part 2: Application. *IEEE Transactions on Power Delivery 19*(3), 1496–1503.

Widrow, B. e R. Winter (1988). Neural nets for adaptive filtering and adaptive pattern recognition. *IEEE Computer Magazine 21*(3), 25–39.

Yu, K. K. C., N. R. Watson, e J. Arrillaga (2005). An adaptive Kalman filter for dynamic harmonic state estimation and harmonic injection tracking. *IEEE Transactions on Power Delivery 20*(2), 1577–1584.

Yu, X. e K. Wang (2009). Digital system for detection and classification of power quality disturbance. In *Asia-Pacific Power and Energy Engineering Conference. APPEEC 2009.*, pp. 1–4.

Zhang, M., K. Li, e Y. Hu (2011). A real-time classification method of power quality disturbances. *Electric Power Systems Research 81*, 660–666.

Zhao, F. e R. Yang (2007). Power-quality disturbance recognition using S-transform. *IEEE Transactions on Power Delivery 22*(2), 944–950.

Zhu, T. X., S. K. Tso, e K. L. Lo (2004). Wavelet-based fuzzy reasoning approach to power-quality disturbance recognition. *IEEE Trans. on Power Delivery 19*(4), 1928–1935.

# Apêndice A

# Produção científica relacionada a esta pesquisa

## A.1 Artigos publicados em periódicos internacionais

Lima, Marcelo A. A.; Coury, Denis V.; Cerqueira, Augusto S.; Nascimento, Vítor H. . A Method Based on Independent Component Analysis for Adaptive Decomposition of Multiple Power Quality Disturbances. *Journal of Control, Automation and Electrical Systems*, 2013 (aceito para publicação).

Lima, Marcelo A. A.; Cerqueira, Augusto S.; Coury, Denis V.; Duque, Carlos A. . A novel method for power quality multiple disturbance decomposition based on Independent Component Analysis. *International Journal of Electrical Power & Energy Systems*, vol. 42, pp. 593-604, 2012.

## A.2 Artigos publicados em congressos internacionais

Coury, Denis V.; Lima, Marcelo A. A.; Cerqueira, Augusto S. . An ICA-based method for adaptive decomposition of multiple PQ disturbances. *2012 IEEE 15th International Conference on Harmonics and Quality of Power (ICHQP)*, 2012, Hong Kong.

Lima, Marcelo A. A.; Coury, Denis V.; Cerqueira, Augusto S. . A method for PQ multiple disturbance decomposition based on digital filtering and Independent Component Analysis. *2012 IEEE Power & Energy Society General Meeting* 2012, San Diego, EUA.

Cerqueira, Augusto S.; Lima, Marcelo A. A.; Salmento, Marlon L. G.; Souza, Julio V.; Coury, Denis V. . Nonlinear Filtering for Power Quality Disturbances Analysis. *14th International Conference on HARMONICS AND QUALITY OF POWER* 2010, Bergamo, Itália.

Lima, Marcelo A. A.; Ferreira, Danton D.; Cerqueira, Augusto S.; Duque, Carlos A.; Ribeiro, Moisés V.; Seixas, José M. de . Separation And Recognition of Multiple PQ Disturbances Using Independent Component Analysis And Neural Networks. *IEEE 13th International Conference on Harmonics and Quality of Power (ICHQP 2008)*, 2008, Wollongong, Austrália.

## A.3 Artigos publicados em congressos nacionais

Lima, Marcelo A. A.; Cerqueira, Augusto S.; Duque, Carlos A.; Coury, Denis V. . Análise de Componentes Independentes Aplicada em Distúrbios de Qualidade da Energia Elétrica. *VIII Conferência Brasileira sobre Qualidade da Energia Elétrica (CBQEE 2009)*, 2009, Blumenau, Santa Catarina.

Lima, Marcelo A. A.; Cerqueira, Augusto S.; Ferreira, Danton D.; Duque, Carlos A.; Ribeiro, Moisés V.; Seixas, José M. de . Separação de Múltiplos Distúrbios de Qualidade de Energia Utilizando Análise de Componentes Independentes. *XVII Congresso Brasileiro de Automática (CBA 2008)*, 2008, Juiz de Fora, Minas Gerais.