



ANÁLISE DE DISTÚRBIOS ELÉTRICOS EM SISTEMAS DE POTÊNCIA

Danton Diego Ferreira

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Elétrica.

Orientadores: José Manoel de Seixas

Augusto Santiago Cerqueira

Rio de Janeiro
Dezembro de 2010

ANÁLISE DE DISTÚRBIOS ELÉTRICOS EM SISTEMAS DE POTÊNCIA

Danton Diego Ferreira

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Examinada por:

Prof. José Manoel de Seixas, D.Sc.

Prof. Augusto Santiago Cerqueira, D.Sc.

Prof. Germano Lambert- Torres, Ph.D.

Prof. Oriane Magela Neto, Ph.D.

Prof. Glauco Nery Taranto, Ph.D.

RIO DE JANEIRO, RJ – BRASIL

DEZEMBRO DE 2010

Ferreira, Danton Diego

Análise de Distúrbios Elétricos em Sistemas de Potência/Danton Diego Ferreira. – Rio de Janeiro: UFRJ/COPPE, 2010.

XXIII, 210 p.: il.; 29, 7cm.

Orientadores: José Manoel de Seixas

Augusto Santiago Cerqueira

Tese (doutorado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2010.

Referências Bibliográficas: p. 167 – 180.

1. Qualidade de Energia. 2. Distúrbios Elétricos. 3. Inteligência Computacional. I. Seixas, José Manoel de *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

*Ao Adler Luiz Salgado de
Carvalho pela intensa dedicação,
honestidade, cidadania,
dignidade, carisma, humildade e
brilhante sabedoria que
prevaleceram em intensos e
gratificantes momentos de sua
vida. À minha família, que
sempre unida, me deu forças para
avançar e quebrar as barreiras.*

Agradecimentos

Gostaria de agradecer a Deus por me dar forças e sabedoria.

Aos meus orientadores, prof. Seixas e prof. Augusto, pela confiança depositada, paciência e dedicação. Agradeço também pela amizade e bom relacionamento construído durante o período de desenvolvimento do trabalho.

À minha família, pelo amor, apoio e compreensão.

À Ana Cláudia, pelo amor, carinho e atenção.

Aos amigos do Labsel - UFJF, pelo apoio, amizade, e por proporcionar um ambiente de trabalho confortável.

Ao amigo Cristiano Marques que forneceu boas contribuições para o desenvolvimento do trabalho.

Aos professores que, diretamente e/ou indiretamente, deram boas contribuições para o desenvolvimento do trabalho.

Aos colegas do Departamento de Engenharia da UFLA, pelo apoio e compreensão.

Aos amigos do LPS - UFRJ, pelo apoio e amizade.

Aos colegas de república de Juiz de Fora pela força e apoio.

Aos professores do Departamento de Engenharia Elétrica da UFJF, em especial aos professores Augusto Cerqueira, Carlos Duque e Moisés Ribeiro, pelo excelente trabalho realizado.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

ANÁLISE DE DISTÚRBIOS ELÉTRICOS EM SISTEMAS DE POTÊNCIA

Danton Diego Ferreira

Dezembro/2010

Orientadores: José Manoel de Seixas

Augusto Santiago Cerqueira

Programa: Engenharia Elétrica

Nesta tese, técnicas de processamento de sinais e inteligência computacional foram aplicadas à análise, detecção e classificação dos distúrbios elétricos. A técnica de curvas principais (CP) foi utilizada para análise dos distúrbios. Como resultado, foi possível avaliar a complexidade de cada classe de distúrbios, em que parâmetros importantes à detecção e classificação foram revelados. Na detecção, estes parâmetros foram explorados em comparação com parâmetros comumente utilizados como o valor rms. Como resultados, desempenhos superiores a 98 %, para dados de simulação e experimentais, com janelas de até 1/16 ciclo do sinal foram alcançados, com reduzido processamento. Para classificação, as CP e estatísticas de ordem superior (EOS) foram utilizadas como pré-processamento. O classificador baseado em EOS alcançou maior desempenho, porém o sistema baseado em CP requer menor processamento. Em geral, eficiências globais acima de 99 % foram obtidas. No que tange a classificação de múltiplos distúrbios, um sistema baseado em um banco de filtros foi proposto. Uma eficiência global superior a 99 % foi alcançada. A técnica de análise de componentes independentes foi também aplicada aos múltiplos distúrbios, com o propósito de estimar os distúrbios isolados, para fins de classificação e análises. Testes em sinais simulados e experimentais mostraram que o método é bastante promissor e passível de aplicações em tempo real.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

ELECTRICAL DISTURBANCE ANALYSIS IN POWER SYSTEMS

Danton Diego Ferreira

December/2010

Advisors: José Manoel de Seixas

Augusto Santiago Cerqueira

Department: Electrical Engineering

In this work, electrical disturbance analysis, detection and classification systems were proposed. Signal processing and computational intelligence techniques were used. The principal curves (PC) technique was applied for disturbance analysis in order to investigate the complexity of different disturbance classes. As a result, important features were revealed and fed a set of neural networks to detect disturbances. A simple system based on the rms value was also designed for comparison. The PC-based system outperforms the rms-based one. The systems were tested with both simulated and experimental data, where efficiencies exceeding 98 % were achieved with fast processing. Isolated disturbances classification systems based on higher order statistics (HOS) and PC were also proposed. The HOS-based system outperformed the PC-based one. On the other hand, the HOS-based system requires more computational cost. Global efficiencies exceeding 99 % were achieved. A multiple disturbance classification system based on a filter bank was designed. Seven isolated disturbances and twelve multiple disturbances were considered. A global efficiency of about 99 % was achieved. The independent component analysis (ICA) technique was also applied to the multiple disturbances. The goal was to estimate the isolated disturbances from the multiple ones for classification purposes. Simulated and experimental results shown that the ICA-based method is very promising and suitable for real-time applications.

Sumário

Lista de Figuras	xii
Lista de Tabelas	xviii
Lista de Abreviaturas	xxi
1 Introdução	1
1.1 Motivação	2
1.2 O que foi feito	4
1.3 Organização do Documento	6
2 Qualidade de Energia Elétrica	8
2.1 Definição	8
2.2 Distúrbios em QEE	9
2.2.1 Transitórios	9
2.2.2 Variações de tensão de curta duração	12
2.2.3 Variações de tensão de longa duração	12
2.2.4 Deformação da forma de onda da tensão	13
2.2.5 Tipos de Desbalanceamentos	13
2.3 Indicadores de Qualidade de Energia Elétrica	14
2.4 Estado da Arte	17
2.5 Equipamentos de Monitoramento de Energia Elétrica	26
3 Formulação Matemática dos Distúrbios e Metodologia	29
3.1 Formulação Matemática dos Distúrbios de QEE	29
3.2 Banco de Dados Utilizado	31
3.2.1 Análise de Distúrbios Por Curvas Principais	31

3.2.2	Detecção de Distúrbios	32
3.2.3	Classificação de Distúrbios	33
3.2.4	Análise de Múltiplos Distúrbios Usando ICA	34
3.2.5	Banco de Distúrbios Reais	34
3.3	Filtro Notch	35
4	Análise e Representação de Distúrbios Por Curvas Principais	38
4.1	Curvas Principais	38
4.1.1	Algoritmo k-segmentos	41
4.2	Análise e Representação de Distúrbios	43
4.3	Extração de Parâmetros via Curvas Principais	46
5	Detecção de Distúrbios Elétricos	49
5.1	Detecção de Distúrbios	49
5.2	Sistema de Detecção Baseado Em Curvas Principais	51
5.2.1	Resultados e Discussões	54
5.3	Sistema de Detecção Baseado no Valor RMS	57
5.3.1	Resultados e Discussões	59
5.4	Estudo de Complexidade Computacional	60
6	Classificação de Distúrbios Elétricos Isolados	62
6.1	Classificação de Distúrbios: Generalidades	62
6.2	Classificação Baseada em Parâmetros Extraídos Por Curvas Principais	64
6.2.1	Resultados e Discussões	66
6.3	Curvas Principais Como Ferramenta de Classificação	66
6.3.1	Projeto do Sistema	67
6.3.2	Resultados e Discussões	71
6.3.3	Aplicação em Dados Experimentais	73
6.3.4	Monitoramento Trifásico	74
6.4	Sistema de Classificação Baseado em Estatísticas de Ordem Superior	76
6.4.1	EOS Como Parâmetros	79
6.4.2	Projeto do Classificador	81
6.4.3	Resultados e Discussões	83

6.5	Análise de Complexidade Computacional	83
7	Classificação de Distúrbios Elétricos Simultâneos	85
7.1	Como Abordar o Problema de Múltiplos Distúrbios?	85
7.2	Análise Wavelet	88
7.3	Desacoplamento Via Banco de Filtros	93
7.3.1	Projeto do Classificador	100
7.3.2	Metodologia	104
7.3.3	Resultados e Discussões	106
8	Análise de Componentes Independentes	110
8.1	Contextualização do Problema	110
8.2	SCICA	113
8.3	SCICA para o Desacoplamento de Distúrbios de QEE	114
8.3.1	Análise Qualitativa	115
8.3.2	Análise Quantitativa	121
8.3.3	Análise com um Enfoque de Processamento Digital de Sinais .	126
8.4	Classificação de Distúrbios de QEE Através de Componentes Inde- pendentes	130
8.5	Influência do Tamanho da Janela na Estimação dos Componentes Independentes	135
8.5.1	Classificação de Distúrbios com Janelas Reduzidas	140
8.6	Influência do Ruído de Fundo	143
8.7	Aplicação em Dados Experimentais	145
8.8	SCICA com Menor Complexidade Computacional	147
8.9	Análise Por Branqueamento	154
8.10	Discussões Gerais	157
9	Conclusões e Perspectivas	160
9.1	Perspectivas	164
	Referências Bibliográficas	167
A	Redes Neurais Artificiais	181
A.1	Resilient Propagation	182

B	Complexidade Computacional	184
C	Discriminante Linear de Fisher	185
	C.1 FDR Como Classificador	185
	C.2 FDR Para Seleção de Parâmetros	187
D	Classificador Bayesiano	188
E	Filtro de Fourier	190
F	Análise de Componentes Independentes	193
	F.1 Branqueamento	194
	F.2 Independência Estatística	195
	F.2.1 Descorrelação Não-Linear	195
	F.2.2 Informação Mútua	196
	F.3 Algoritmo FastICA	197
	F.3.1 ICA por Método Tensorial	198
G	Transformada Wavelet	200
	G.1 Transformada Wavelet Contínua	200
	G.2 Transformada Wavelet Discreta	201
H	Lista de Publicações	203
	H.1 Capítulo de Livro	203
	H.2 Artigos Publicados em Periódicos	204
	H.3 Artigos Publicados em Anais de Congressos	205
	H.4 Resumos Publicados em Anais de Congressos	209

Lista de Figuras

2.1	Exemplos de transitórios impulsivos.	11
2.2	Exemplos de transitórios oscilatórios na forma de onda da tensão. . .	12
2.3	Exemplos de variações de tensão: (a) Afundamento de tensão; (b) Elevação de tensão e; (c) Interrupção.	13
2.4	Exemplos de deformações de tensão: (a) Harmônicos e (b) <i>Notches</i> . .	14
3.1	Diagrama em blocos da obtenção de $e[n]$ utilizando um filtro <i>Notch</i> . .	35
3.2	Resposta em frequência do filtro <i>notch</i> IIR utilizado, para $\rho_0 = 0,97$. .	36
3.3	Exemplos dos sinal $e[n]$ com distúrbios. Em (a) tem-se um sinal sem distúrbio, em (b), um afundamento de tensão, em (c) um transitório oscilatório, em (d) um <i>notch</i> , e em (e) harmônicos.	37
4.1	Curva Principal para um conjunto de dados de duas dimensões. . . .	39
4.2	Projeção dos dados na CP.	40
4.3	Ponto autoconsistente de uma CP.	40
4.4	Fluxograma simplificado do algoritmo k-segmentos não-suave.	42
4.5	Espaço de parâmetros entre sinais sem distúrbios e harmônicos e <i>notches</i>	48
5.1	Sistema geral de detecção.	50
5.2	Espaço de parâmetros para interrupções de tensão em (a) e para para transitórios oscilatórios em (b) para $N = 256$ amostras.	51
5.3	Espaço de parâmetros para interrupções de tensão em (a) e para para transitórios oscilatórios em (b) para $N = 16$ amostras.	52
5.4	Diagrama em blocos da etapa de detecção em detalhes.	53

5.5	Espaço de parâmetros para as classes de afundamento (a) e elevação (b) de tensão para $N = 256$ amostras.	54
5.6	Probabilidades de Detecção (PD) e de falso alarme (PF) em função do limiar de detecção.	55
5.7	Exemplos de sinais de tensão de dados reais com distúrbios obtidos no site do grupo de trabalho IEEE (<i>working group</i> P1159.3).	57
5.8	Espaço de parâmetros para interrupções de tensão (a) e para para transitórios oscilatórios (b) para $N = 256$ amostras.	58
5.9	Espaço de parâmetros para as classes de interrupções (a), harmônicos (b), afundamentos (c) e elevações de tensão (d), para $N = 16$	58
6.1	Estrutura da rede neural de detecção de distúrbios.	64
6.2	Exemplo de classificação utilizando curvas principais.	67
6.3	Ilustração dos passos de pré-processamento.	69
6.4	Formas de onda da tensão experimentais: (a) harmônicos e (b) transitório oscilatório.	73
6.5	Eventos experimentais com múltiplos distúrbios.	74
6.6	Sistema trifásico de monitoramento de QEE.	75
6.7	Valores do critério FDR obtidos para as classes de harmônicos e <i>notches</i>	80
6.8	Espaço de parâmetros para as classes: (S1) harmônicos, (S2) afundamento, (S3) elevação, (S4) interrupção, (S5) impulsos, (S6) <i>notches</i> , (S7) transitório oscilatório e (S8) sinal de tensão nominal.	80
6.9	Espaço de parâmetros para as classes: (S2) afundamento, (S3) elevação, e (S8) sinal de tensão nominal.	81
6.10	Sistema de classificação proposto.	81
6.11	Sistema de classificação de afundamentos e elevações de tensão.	82
7.1	Banco de filtros para desacoplar múltiplos de distúrbios.	86
7.2	Classificação baseada em árvore de decisão.	87
7.3	Sistema com classificadores especialistas.	88
7.4	Forma de onda da tensão com transitório oscilatório e harmônicos em (a), e o respectivo sinal filtrado $e[n]$	89

7.5	Decomposições da TW. A_i e D_i são, respectivamente, as aproximações e os detalhes da TW para o nível i	89
7.6	Forma de onda da tensão com <i>notches</i> e harmônicos em (a), e o respectivo sinal filtrado $e[n]$	90
7.7	Decomposições da TW. A_i e D_i são, respectivamente, as aproximações e os detalhes da TW para o nível i	90
7.8	Sinal de tensão corrompido por transitório oscilatório $\{v[n]\}$ e o respectivo sinal filtrado $e[n]$	91
7.9	Decomposições da TW para o sinal $e[n]$ ilustrado na Figura 7.8.	92
7.10	Coeficientes da TW.	92
7.11	Diagrama em blocos sistema de filtragem de $v[n]$	93
7.12	Módulo médio normalizado da TDF aplicada aos sinais $e[n]$ das classes: (a) Transitório oscilatório, (b) Harmônicos, (c) <i>Notch</i> e (d) Impulsos.	95
7.13	Resposta em frequência do filtro passa-baixa.	96
7.14	Resposta em frequência do filtro passa-faixa.	96
7.15	Resposta em frequência do filtro passa-alta.	96
7.16	Saídas do sistema de filtragem para um transitório oscilatório.	97
7.17	Saídas do sistema de filtragem para um <i>notch</i>	97
7.18	Saídas do sistema de filtragem para um transitório impulsivo.	98
7.19	Saídas do sistema de filtragem para harmônicos.	98
7.20	Saídas do sistema de filtragem para um afundamento de tensão.	99
7.21	Saídas do sistema de filtragem para uma elevação de tensão.	99
7.22	Múltiplos distúrbios reais.	100
7.23	Saídas do sistema de filtragem para um múltiplo distúrbio da Figura 7.22 (a).	101
7.24	Saídas do sistema de filtragem para um múltiplo distúrbio da Figura 7.22 (b).	101
7.25	Diagrama em blocos do processo de extração de parâmetros.	102
7.26	Diagrama em blocos do Classificador Final	104

7.27	Formas de onda de aquisições reais do sinal de tensão com distúrbios múltiplos de transitórios oscilatórios e afundamento de tensão em (a) e transitórios oscilatórios, harmônicos e afundamento de tensão em (b)	106
8.1	Sistema genérico de desacoplamento de múltiplos distúrbios via ICA.	113
8.2	Modelo de misturas SCICA genérico.	114
8.3	Múltiplos distúrbios: (a) Harmônicos com transitório oscilatório e (b) Harmônicos com <i>notches</i> .	115
8.4	SCICA aplicado a sinais de tensão.	115
8.5	Componentes independentes da mistura de harmônicos com transitório oscilatório e suas correspondentes fontes originais utilizadas para gerar a mistura M1.	116
8.6	Componentes independentes, da mistura de harmônicos com <i>notches</i> e suas fontes originais, utilizadas para gerar a mistura M2.	117
8.7	Espectro normalizado das fontes de transitório oscilatório e harmônicos que compõem a mistura M1 e das respectivas estimativas.	117
8.8	Espectro normalizado das fontes de <i>notches</i> e harmônicos que compõem a mistura M2 e das respectivas estimativas.	118
8.9	Comparação entre a mistura original $e[n]$ e a mistura obtida pelo modelo SCICA.	119
8.10	Correlação cruzada entre a mistura original e a obtida pelo modelo SCICA.	119
8.11	Componentes independentes da mistura de harmônicos com transitório oscilatório em (a) e harmônicos com <i>notches</i> em (b).	120
8.12	Espectro normalizado dos componentes independentes obtidos para o caso $M = 3$.	120
8.13	Componentes independentes da mistura de harmônicos com transitório oscilatório em (a) e harmônicos com <i>notches</i> em (b).	121
8.14	Espectro normalizado dos componentes independentes obtidos para o caso $M = 4$.	122
8.15	Sinais padrões utilizados na seleção das melhores componentes independentes para os casos $M = 3$ e $M = 4$.	124

8.16	Resposta em frequência dos filtros formados pelas linhas da matriz \mathbf{W} para as misturas de harmônicos com transitório oscilatório (a) e harmônicos com <i>notches</i> (b). O Filtro 1 é formado pela linha 1 de \mathbf{W} e o Filtro 2 pela linha 2.	128
8.17	Resposta em frequência dos filtros formados pelas linhas da matriz \mathbf{W} para as misturas de harmônicos com transitório oscilatório (a) e harmônicos com <i>notches</i> (b). O Filtro 1 é formado pela linha 1 de \mathbf{W} , o Filtro 2 pela linha 2 e o Filtro 3 pela linha 3.	128
8.18	Resposta em frequência dos filtros formados pelas linhas da matriz \mathbf{W} para as misturas de harmônicos com transitório oscilatório (a) e harmônicos com <i>notches</i> (b). O Filtro 1 é formado pela linha 1 de \mathbf{W} , o Filtro 2 pela linha 2, o Filtro 3 pela linha 3 e o Filtro 4 pela linha 4.	129
8.19	Saída dos filtros formados pelas linhas da matriz \mathbf{W} para a abordagem $M = 3$	130
8.20	Componentes independentes obtidos da mistura M1 para $M = 10$. . .	134
8.21	Componentes independentes obtidos da mistura M2 para $M = 10$. . .	135
8.22	Componentes independentes obtidas considerando-se apenas 1 ciclo do sinal $e[n]$	136
8.23	Componentes independentes obtidas considerando-se apenas 1/2 ciclo do sinal $e[n]$	137
8.24	Componentes independentes obtidas considerando-se sinais com SNR de 30 dB.	144
8.25	Múltiplos distúrbios experimentais.	145
8.26	Componentes obtidas considerando-se $M = 3$	146
8.27	Componentes independentes obtidos da mistura M1.	148
8.28	Componentes independentes obtidos da mistura M2.	149
8.29	Componentes obtidos com as matrizes de separação gerais \mathbf{W} , considerando-se $M = 3$	149
8.30	Componentes obtidos com a matriz de separação da mistura M1, considerando-se $M = 3$. (a) refere-se ao distúrbio de transitórios oscilatório e (b) refere-se ao harmônico.	153

8.31	Componentes obtidas com a matriz de separação da mistura M2, considerando-se $M = 3$. (a) refere-se ao distúrbio de <i>notches</i> e (b) refere-se ao harmônico.	153
8.32	Misturas branqueadas, considerando-se $M = 3$	154
9.1	Sistema genérico de desacoplamento de múltiplos distúrbios via ICA fazendo o monitoramento de dois pontos do SEP.	166
9.2	Sistema trifásico de desacoplamento de múltiplos distúrbios via ICA.	166
A.1	Perceptron de múltiplas camadas.	182
C.1	Exemplo da aplicação do FDR para classificação.	186
G.1	Decomposição Wavelet. L = filtro passa-baixas e H = filtro passa-altas.	202

Lista de Tabelas

2.1	Características de alguns distúrbios de qualidade de energia [1].	10
2.2	Evolução da tecnologia e campo de aplicação do monitoramento da QE. Extraído de [2].	17
2.3	Métodos de Classificação - Parte 1.	20
2.4	Métodos de Classificação - Parte 2.	21
4.1	Número de segmentos e comprimento (u.a.) das curvas principais. . .	44
4.2	Distâncias entre as curvas principais em u.a..	46
5.1	Eficiência global em % para os dados simulados.	56
5.2	Eficiência global em % para os dados reais.	56
5.3	Eficiência global em % para os dados simulados.	60
5.4	Eficiência global em % para os dados reais.	60
5.5	Complexidade computacional dos métodos para $N = 256$	61
5.6	Complexidade computacional dos métodos para $N = 16$	61
6.1	Desempenho do classificador proposto em %.	66
6.2	Número de segmentos e comprimento das curvas de cada classe em unidade arbitrária (u.a.).	70
6.3	Distâncias entre as curvas principais (u.a.).	71
6.4	Eficiência de Classificação e eficiência global em % obtida pelo método proposto e por redes neurais (RNA).	72
6.5	Padrões de Saída da RNA.	72
6.6	Distância dos distúrbios às curvas.	74
6.7	Resultados de Classificação para Desbalanceamentos via Curvas Prin- cipais.	76

6.8	Eficiência de classificação em % para dados de teste.	83
6.9	Complexidade computacional dos métodos propostos.	84
7.1	Matriz de confusão para a classificação relativa ao conjunto de teste. .	107
8.1	Medidas de independência entre as fontes originais dos distúrbios. . .	111
8.2	Medida normalizada de gaussianidade das fontes de distúrbios.	112
8.3	Medidas entre as misturas, entre as fontes e entre os componentes independentes para a mistura M1.	125
8.4	Medidas entre as misturas, entre as fontes e entre os componentes independentes para a mistura M2.	125
8.5	Medidas entre as fontes originais e os componentes independentes para a mistura M1.	126
8.6	Medidas entre as fontes originais e os componentes independentes para a mistura M2.	126
8.7	Desempenho do classificador para as estimativas dos distúrbios por componentes independentes.	133
8.8	Desempenhos de classificação para diferentes números de deslocamen- tos.	135
8.9	Medidas entre as misturas, entre as fontes e entre os componentes independentes para a mistura M1 e diferentes tamanhos de janela. . .	138
8.10	Medidas entre as misturas, entre as fontes e entre os componentes independentes para a mistura M2 e diferentes tamanhos de janela. . .	139
8.11	Medidas entre as fontes originais e os componentes independentes para a mistura M1 e diferentes tamanhos de janela.	140
8.12	Medidas entre as fontes originais e os componentes independentes para a mistura M2 e diferentes tamanhos de janela.	140
8.13	Desempenhos de classificação para diferentes tamanhos de janelas em %.	141
8.14	Desempenhos de classificação, obtidos com classificadores projetados a partir das estimativas dos distúrbios, em %.	143
8.15	Desempenhos de classificação para diferentes níveis de ruído em %. .	144

8.16	Medidas entre as misturas e entre os componentes independentes para os distúrbios experimentais.	147
8.17	Medidas entre os componentes independentes obtidos pelo FastICA e pela matriz geral de separação \mathbf{W} , para a mistura M1.	150
8.18	Medidas entre as fontes originais e os componentes independentes obtidos pelo FastICA e pela matriz geral de separação \mathbf{W} , para a mistura M1.	150
8.19	Medidas entre os componentes independentes obtidos pelo FastICA e pela matriz geral de separação \mathbf{W} , para a mistura M2.	151
8.20	Medidas entre as fontes originais e os componentes independentes obtidos pelo FastICA e pela matriz geral de separação \mathbf{W} , para a mistura M2.	151
8.21	Desempenhos de classificação para a matriz de separação geral \mathbf{W} em %	152
8.22	Medidas entre os componentes independentes obtidos pelo FastICA e as misturas M1 branqueadas.	155
8.23	Medidas entre os componentes independentes obtidos pelo FastICA e as misturas M2 branqueadas.	155
8.24	Medidas entre as fontes originais e os componentes independentes obtidos pelo FastICA e as misturas M1 branqueadas.	155
8.25	Medidas entre as fontes originais e os componentes independentes obtidos pelo FastICA e as misturas M2 branqueadas.	156
8.26	Desempenhos de classificação para os sinais branqueados em % . . .	156
8.27	Medida normalizada de gaussianidade dos dados.	157
B.1	Custo computacional dos algoritmos utilizados em tempo real no contexto desta tese.	184

Lista de Abreviaturas

ANEEL	Agência Nacional de Energia Elétrica, p. 17
BSS	<i>Blind Source Separation</i> , p. 194
CL	Correlação Linear, p. 111
CNL	Correlação Não-linear, p. 111
DEC	Duração Equivalente de Interrupção por Unidade Consumidora, p. 16
DIC	Duração de Interrupção por Unidade Consumidora, p. 16
DMIC	Duração Máxima de Interrupção por Unidade Consumidora, p. 16
DSP	<i>Digital Signal Processor</i> , p. 5
ECG	Eletrocardiograma, p. 181
EDCM	<i>Enhanced Data Compression Method</i> , p. 22
EEG	Eletroencefalograma, p. 181
EOS	Estatística de Ordem Superior, p. 23
EPLL	<i>Enhanced Phase Locked-loop</i> , p. 36
FDR	<i>Fisher's discriminat ratio</i> , p. 24
FEC	Frequência Equivalente de Interrupção por Unidade Consumidora, p. 16
FFT	<i>Fast Fourier Transform</i> , p. 22

FIC	Frequência de Interrupção por Unidade Consumidora, p. 16
FPGA	<i>Flexible Programmable Gate Array</i> , p. 17
FastICA	<i>Fast Fixed Point Algorithm For Independent Component Analysis</i> , p. 197
ICA	<i>Independent Component Analysis</i> , p. 110
IEC	<i>International Electrotechnical Commission</i> , p. 2
IEEE	<i>Institute of Electrical and Electronics Engineers</i> , p. 9
IM	Informação Mútua, p. 111
MLP	<i>Multilayer Perceptron</i> , p. 181
ML	<i>Maximum Likelihood</i> , p. 103
MSE	<i>Mean Squared Error</i> , p. 118
PD	Probabilidade de Detecção, p. 55
PF	Probabilidade de Falso Alarme, p. 55
PRODIST	Procedimentos de Distribuição, p. 17
QEE	Qualidade de Energia Elétrica, p. 1
RMS	<i>Roots Mean Square</i> , p. 5
RNA	Rede Neural Artificial, p. 5
RPROP	<i>Resilient Propagation</i> , p. 182
Rr	Razão Residual, p. 123
SCE	<i>Sistema de Classificação Especialista</i> , p. 87
SCICA	<i>Single Channel ICA</i> , p. 112
SEP	Sistema Elétrico de Potência, p. 17
SNR	<i>Signal Noise Ratio</i> , p. 23

THD	Taxa de Distorção Harmônica, p. 22
TWC	Transformada Wavelet Contínua, p. 200
TWD	Transformada Wavelet Discreta, p. 201
TW	Transformada Wavelet, p. 22
pdf	<i>probability density function</i> , p. 188

Capítulo 1

Introdução

O termo “qualidade de energia elétrica” (QEE), em geral, compreende a qualidade das formas de onda da tensão e corrente elétricas em um sistema elétrico [3]. Nas últimas duas décadas este termo tem recebido bastante atenção de pesquisadores. Alguns dos principais fatores que fazem da QEE um tema de grande interesse são:

- O crescente uso de equipamentos computadorizados e sensíveis às perturbações do sistema elétrico;
- A exigência, por parte dos consumidores, de uma energia de melhor qualidade;
- O aumento do número de cargas de natureza não-linear (sistemas microprocessados, fontes chaveadas, etc) em instalações elétricas residenciais, comerciais e industriais, o que provoca o aumento significativo da ocorrência de deformidades (distúrbios) nas formas de onda da tensão e corrente nos seus sistemas de distribuição;
- A regulamentação do setor elétrico, no que diz respeito à QEE, em fase de implantação.

O aparecimento de deformidades nas formas de onda da tensão e corrente caracteriza a falta de qualidade da energia elétrica. Estas deformidades são definidas pelo IEC (*International Electrotechnical Commission*, IEC-91) como fenômenos eletromagnéticos ou simplesmente distúrbios, dentre os quais destacam-se os harmônicos, interharmônicos, flutuações de tensão, afundamentos, transitórios, entre outros. Algumas modificações e complementações na classificação do IEC foram realizadas

pela norma IEEE (IEEE-95), com a inclusão da categoria de ruído, de elevação de tensão e a definição da categoria de distorção de forma de onda da corrente alternada, que inclui as distorções harmônicas, interharmônicas e de componente contínua. Estes distúrbios estão relacionados com diferentes eventos nos sistemas de potência. Alguns são gerados pela operação normal dos sistemas, tais como chaveamento de banco de capacitores e entrada e saída de grandes cargas lineares ou não, enquanto outros estão relacionados com eventos não operacionais do sistema, como as descargas atmosféricas e as faltas na rede elétrica.

1.1 Motivação

Os distúrbios elétricos, causadores de baixa qualidade de energia elétrica, independente da sua causa, podem gerar perdas consideráveis aos consumidores de energia, sendo as indústrias as mais afetadas, uma vez que tais distúrbios podem causar o funcionamento incorreto ou até mesmo a queima dos equipamentos conectados à rede elétrica e, conseqüentemente, interromper um processo de produção. Com isso, desperta-se uma preocupação por parte das concessionárias de energia elétrica em garantir a qualidade do produto e, por outro lado, desperta-se também o interesse dos usuários de energia em monitorar a qualidade da energia elétrica recebida. Este interesse de ambas as partes tem motivado o desenvolvimento de sistemas de monitoramento da qualidade de energia elétrica, o que constitui-se no objetivo geral desta tese.

Os distúrbios de QEE podem ter duração de 50ns, em transitórios impulsivos, até vários minutos, em afundamentos. Dessa forma, quando tais eventos são monitorados por oscilógrafos, geram arquivos de dados de grande extensão que, além de serem de difícil armazenamento, trazem muitas vezes informações desnecessárias para a avaliação da QEE. Este ponto motiva o desenvolvimento de técnicas de compactação de sinais e de detecção de distúrbios, em que o objetivo principal é armazenar apenas as informações relevantes dos distúrbios, isto é, aquelas que os caracterizam bem e, possivelmente, contribuem para a identificação das possíveis causas.

Para desenvolver as aplicações de QEE, as atividades de pesquisa têm sido

focadas em:

- caracterizar de forma simples, rápida e eficiente as variações da tensão e corrente que podem afetar equipamentos sensíveis;
- processar as variações da tensão e corrente para entender como os equipamentos eletrônicos podem ser uma fonte de distorção da forma de onda (transitórios e harmônicos);
- monitorar de forma online o sistema elétrico classificando o distúrbio com precisão e possibilitando a identificação da fonte geradora do mesmo;
- desenvolver equipamentos de monitoramento da QEE que não apenas capturem os distúrbios, mas também processem os mesmos de forma a classificá-los;
- processar as formas de onda da tensão e corrente correlacionando-as com problemas em equipamentos ou sistemas (tais como cabos, emendas, e contato com árvores);
- processar as formas de onda da tensão e corrente com o objetivo de localizar a fonte causadora do distúrbio.

Dentre as principais atividades a serem realizadas em um monitoramento da QEE, usando a completa caracterização de um problema de qualidade de energia em um sistema de potência, destacam-se: 1) detecção, segmentação e classificação de distúrbios; 2) compressão de dados; 3) estimação e extração de parâmetros; 4) localização e identificação das fontes geradoras de distúrbios.

A correta caracterização dos distúrbios requer um entendimento de suas definições básicas e do seu possível impacto nos equipamentos conectados à rede elétrica. Para tal, monitores de QEE são frequentemente utilizados para medir e caracterizar os distúrbios. Algumas limitações destes equipamentos, tais como capacidade de processamento e armazenamento, têm motivado o desenvolvimento de técnicas de processamento de sinais e inteligência computacional rápidas e eficientes para a caracterização eficiente das variações no sinal de tensão e corrente que podem afetar os equipamentos eletrônicos.

Neste contexto, o principal interesse dos pesquisadores é desenvolver técnicas capazes de detectar e identificar (classificar) tais distúrbios, correlacionando-os com as possíveis causas, de forma a diagnosticar o problema em tempo mínimo.

Entretanto, os distúrbios elétricos podem aparecer de forma isolada, ou seja, apenas um distúrbio em um dado trecho do sinal, ou de forma múltipla, que caracteriza os múltiplos distúrbios, em que mais de um distúrbio aparece simultaneamente ou em sequência no mesmo trecho do sinal. Os distúrbios isolados são melhor caracterizados e, portanto, mais fáceis de serem classificados. Por outro lado, os múltiplos distúrbios geram formas de ondas difíceis de serem identificadas, até mesmo na presença de um especialista. Porém, a maioria das técnicas desenvolvidas, até o presente momento, concentram-se na classificação de distúrbios isolados e, o uso das mesmas gera resultados contraditórios e não representativos quando aplicadas aos múltiplos distúrbios. Conseqüentemente, o uso de uma solução para a identificação da fonte geradora do distúrbio, se torna bastante comprometido. Desta forma, o desenvolvimento de técnicas que abordem os múltiplos distúrbios torna-se necessário e constitui-se em um dos principais objetivos desta tese.

O foco desta tese, portanto, está no desenvolvimento e o aperfeiçoamento de técnicas de inteligência computacional e processamento de sinais para o monitoramento da QEE, com destaque para a detecção e classificação dos distúrbios elétricos.

1.2 O que foi feito

No contexto de monitoramento da QEE, técnicas para análise, detecção e classificação de distúrbios elétricos foram propostas.

A análise dos distúrbios foi realizada no espaço dimensional das Curvas Principais (CP). Para isso, a curva principal de cada classe foi extraída e, baseando-se no comprimento de cada curva e no número de segmentos da mesma, foi possível identificar as classes de distúrbios mais homogêneas e as mais heterogêneas. A partir das distâncias entre as curvas e das características de cada curva, pode-se inferir sobre a complexidade do processo de classificação dos distúrbios pertencentes a cada classe. Com esta análise foi possível também revelar parâmetros relevantes à detecção e classificação dos distúrbios.

Com relação à detecção, procurou-se desenvolver sistemas com reduzida complexidade computacional na fase de operação e alto desempenho. Para isso, reduzidas janelas de aquisição do sinal de tensão foram utilizadas para projetar e testar os sistemas de detecção propostos. A partir de distúrbios simulados, dois sistemas baseados em redes neurais foram desenvolvidos, um utilizando a técnica de curvas principais, e outro utilizando o valor eficaz (*RMS-Roots Mean Square*) e valores de pico do sinal, na etapa de extração de parâmetros. Como detector, utilizou-se uma rede neural artificial do tipo *perceptron* multi-camadas. Os desempenhos dos sistemas foram comparados para os diferentes tamanhos de janelas. Por fim, um estudo de complexidade computacional dos métodos, com vistas a futuras implementações em DSP (*Digital Signal Processor*), foi realizado.

Com relação à classificação, procurou-se desenvolver, primeiramente, sistemas de classificação de distúrbios isolados, objetivando traçar caminhos para explorar os múltiplos distúrbios. Neste sentido, os parâmetros baseados em curvas principais, anteriormente aplicados à análise e detecção de distúrbios, mostraram-se bastante discriminantes e, portanto, foram também utilizados para o desenvolvimento de sistemas de classificação, em que duas abordagens foram consideradas: (i) as curvas principais foram utilizadas apenas como extratoras de parâmetros; (ii) as curvas principais foram utilizadas como ferramentas de classificação. Algumas análises acerca da aplicação do método baseado em curvas principais em múltiplos distúrbios foram também realizadas. Um sistema de monitoramento trifásico, baseado em curvas principais, foi proposto, em que foi possível identificar os tipos de desbalanceamentos, assim como a fase em que ocorreram com alto desempenho.

Ainda explorando a classificação de distúrbios isolados, informações baseadas em Estatísticas de Ordem Superior, extraídas do sinal de tensão, foram também utilizadas como parâmetros na classificação dos distúrbios. Um estudo preliminar foi realizado. O discriminante linear de Fisher foi utilizado para selecionar os parâmetros com maior capacidade de caracterização. A partir destes parâmetros, uma rede neural artificial foi projetada para realizar a classificação.

Em seguida, metodologias para a análise e classificação de múltiplos distúrbios foram discutidas, focando-se em técnicas de desacoplamento de múltiplos dis-

túrbios. Um sistema bastante compacto, em que um banco de filtros é utilizado para desacoplar os múltiplos distúrbios, foi desenvolvido. Dezenove classes de distúrbios foram abordadas, das quais, sete de distúrbios isolados, oito com ocorrências de dois distúrbios simultâneos, e quatro com ocorrências de três distúrbios simultâneos.

Abordando ainda o problema de múltiplos distúrbios, a técnica análise de componentes independentes foi proposta como ferramenta para estimar os distúrbios presentes na janela de eventos com múltiplos distúrbios. A idéia principal foi decompor o sinal corrompido por distúrbios simultâneos em componentes independentes, que são, teoricamente, estimativas dos distúrbios isolados. Primeiramente, testou-se a adequação do modelo ICA ao problema de QEE, mostrando que as estimativas dos distúrbios, dadas pelo modelo ICA proposto, são qualitativamente e quantitativamente válidas, do ponto de vista de classificação. Diferentes algoritmos que implementam a ICA foram testados. Verificou-se também a influência dos ruídos de fundo no modelo e qual a sensibilidade do sistema quando reduzidas janelas do sinal são adquiridas.

1.3 Organização do Documento

Este documento está organizado da seguinte maneira: o Capítulo 2 define o termo “Qualidade de Energia Elétrica”, os principais distúrbios de QEE, assim como suas características e os fatores desencadeadores de cada um deles. É realizado também um estudo acerca das principais e mais recentes técnicas de classificação e detecção de distúrbios elétricos encontradas na literatura, em que as vantagens e desvantagens destas são brevemente discutidas.

O Capítulo 3 apresenta a formulação dos distúrbios elétricos e a metodologia utilizada para a geração dos resultados do trabalho.

O Capítulo 4 introduz a técnica conhecida por curvas principais e sua aplicação para a análise de distúrbios elétricos. Tais análises inferem sobre a complexidade da classificação de cada classe de distúrbio, assim como a disposição dos distúrbios no espaço das curvas principais, dando uma ideia da homogeneidade e heterogeneidade das classes. Parâmetros importantes para a detecção e classificação são aqui revelados.

No Capítulo 5, os parâmetros obtidos pelas curvas principais alimentam uma rede neural artificial que realiza a detecção de distúrbios elétricos. Diferentes comprimentos da janela de aquisição do sinal de tensão são analisados, com aplicações em ambos dados simulados e experimentais. Em seguida, um sistema mais simples, que utiliza apenas o valor eficaz do sinal e valores de pico como parâmetros, é também proposto. Os resultados são comparados. Por fim, uma análise de complexidade computacional com vistas a futuras implementações é realizada.

O Capítulo 6 aborda a classificação de distúrbios isolados. Dois métodos de classificação baseados em curvas principais são propostos. São também realizados testes utilizando-se dados experimentais corrompidos por múltiplos distúrbios, mostrando a possibilidade de se realizar a classificação destes via curvas principais. Ainda utilizando-se curvas principais, é proposto um sistema de monitoramento trifásico, em que os tipos de desbalanceamentos são classificados e identificados com alto desempenho. Desenvolveu-se também um sistema de classificação baseado em parâmetros de estatísticas de ordem superior, mostrando a boa capacidade dos parâmetros extraídos para discriminação das classes de distúrbios.

No Capítulo 7, os múltiplos distúrbios são abordados. O capítulo inicia-se com uma discussão sobre as diferentes formas de classificar os múltiplos distúrbios. Um sistema de classificação de múltiplos distúrbios foi proposto. Este sistema tem como inovação a utilização de um banco de filtros que faz o desacoplamento dos múltiplos distúrbios. Aplicações em dados experimentais são também apresentadas.

No Capítulo 8, um método baseado na Análise de Componentes Independentes é proposto para estimação dos distúrbios isolados presentes no múltiplo distúrbio em análise. Neste capítulo, o método proposto para análise é também utilizado como pré-processamento para um sistema de classificação, onde os classificadores foram projetos para distúrbios isolados.

Por fim, no Capítulo 9, as conclusões gerais deste trabalho são apresentadas. Conjuntamente, as perspectivas de continuidade são apontadas, mostrando os possíveis caminhos a serem seguidos como continuidade deste trabalho.

Capítulo 2

Qualidade de Energia Elétrica

Neste capítulo, será realizada uma revisão sobre o estado da arte de sistemas de monitoramento da QEE, definindo o termo QEE e os principais distúrbios.

2.1 Definição

Antes do estudo sobre o estado da arte do monitoramento da QEE, é importante conceituar o termo QEE (*power quality - PQ*), que não possui uma definição única. O Instituto de Engenheiros Eletricistas e Eletrônicos (IEEE - *Institute of Electrical and Electronics Engineers*) define QEE como “O conceito de fornecer e estabelecer a alimentação de um equipamento elétrico sensível de forma adequada ao seu funcionamento” [1]. Já a norma internacional IEC (*International Electrotechnical Commission*) define o termo como “Características da eletricidade em um dado ponto do sistema elétrico, em relação a um conjunto de parâmetros técnicos de referência” [4]. Note que a definição dada pelo IEEE dá mais importância à operação do equipamento, não dando muita importância a determinados distúrbios que não afetam a operação do equipamento, já a definição dada pelo IEC se preocupa com os parâmetros de referência do sistema, não importando o tipo de equipamento a ele conectado. Conforme [5], o termo QEE, em seu sentido amplo, deve ser interpretado como qualidade do serviço efetuado pelas concessionárias, englobando três aspectos: confiabilidade, qualidade da energia oferecida e provisão de informação. Uma definição alternativa, em que as diferenças entre qualidade do produto e qualidade de serviço relacionadas à QEE são bem apresentadas, encontra-se no Módulo

8-Qualidade de Energia Elétrica do PRODIST [6]. No entanto, uma definição mais abrangente do termo QEE é encontrada em [7], o qual define: “Qualidade de Energia Elétrica é a combinação entre a qualidade da tensão e a qualidade da corrente. Uma tensão ideal é uma tensão senoidal com amplitude e frequência constantes, onde ambos apresentam valores nominais”. Esta é uma definição mais relacionada às aplicações de processamento de sinais e está diretamente relacionada à habilidade do sistema elétrico de operar cargas sem danificá-las e à habilidade de cargas operarem no sistema sem perturbar ou reduzir a eficiência do sistema elétrico.

2.2 Distúrbios em QEE

De acordo com a norma do IEEE [1] e o PRODIST [6], os diversos tipos de distúrbios em QEE se enquadram em 7 diferentes categorias: transitórios, variações de curta duração, variações de longa duração, desequilíbrios de tensão, distorções na forma de onda, flutuações de tensão e variações da frequência do sistema. A Tabela 2.1 mostra um resumo, baseado na norma do IEEE [1], das principais características dos principais distúrbios elétricos.

Em [8], os distúrbios são divididos em duas categorias, que requerem diferentes tipos de processamento: variações e eventos de QEE. As variações de QEE são pequenos desvios da tensão nominal, tais como: variações de tensão, variações de frequência, desbalanceamentos trifásicos, presença de harmônicos e inter-harmônicos e flutuações de tensão. As definições básicas das variações de QEE estão bem documentadas e padronizadas em [9]. Já os eventos de QEE correspondem aos desvios maiores no sinal de tensão, tais como: interrupções, afundamentos de tensão, transitórios oscilatórios e transitórios impulsivos.

A seguir será apresentada uma breve descrição de alguns distúrbios.

2.2.1 Transitórios

O termo transitório é empregado para caracterizar a ocorrência de um evento de curta duração no sistema elétrico. Fenômenos transitórios ocorrem no sistema em função de diversas condições. Muitos transitórios são decorrentes de variações instantâneas na corrente, as quais interagem com a impedância do sistema, resul-

Tabela 2.1: Características de alguns distúrbios de qualidade de energia [1].

Categoria	Conteúdo espectral	Duração típica	Amplitude típica
Transitórios			
Transitórios Impulsivos	Tempo de subida entre 5 ns e 1 ms	< 1 ms	
Transitórios Oscilatórios	Até 5 MHz	5 μ s - 50 ms	0 - 8 pu
Variações de Curta duração			
Sag (afundamento)		0,5 ciclo - 1 min.	0,1 - 0,9 pu
Swell (sobre-tensão)		0,5 ciclo - 1 min.	1,1 - 1,8 pu
Interrupção		< 1 min.	< 0,1 pu
Variações de longa Duração			
Sub-tensão		> 1 min.	0,8-0,9 pu
Sobre-tensão		> 1 min.	1,1-1,8 pu
Interrupção sustentada		> 1 min.	0,0 pu
Distorções da forma de onda			
Dc offset		Regime permanente	0-0,1%
Harmônicos	0-100° harmônico	Regime permanente	0-20%
Inter harmônicos	0-6 KHz	Regime permanente	0-2%
Notching		Regime permanente	
Ruído	Toda banda	Regime permanente	0-1%
Outros distúrbios			
Desbalanceamento de tensão		Regime permanente	0,5-2%
Flutuação de tensão (flicker)	< 25 Hz	Intermitente	0,1-7%
Variações na frequência fundamental		< 10 s	

tando em elevadas tensões instantâneas. Transitórios podem também ser consequência de cargas com operação intermitente, chaveamento de bancos de capacitores, faltas fase-terra, operação de dispositivos de semicondutores e falhas em condutores. Descargas atmosféricas são um caso especial de transitórios devido aos níveis extremamente altos de energia e intervalo de tempo bastante reduzido [1]. Os tipos de transitórios são: impulsivos e oscilatórios.

Transitórios Impulsivos

Os transitórios impulsivos são causados por descargas atmosféricas e, geralmente, são caracterizados pelo tempo de subida e de descida do impulso. Sua definição pode ser dada por uma alteração repentina nas condições de regime permanente da tensão, corrente ou ambas, caracterizando-se por apresentar impulsos unidirecionais em polaridade (positivo ou negativo) e com frequência bastante diferente daquela da rede elétrica.

A Figura 2.1 mostra dois exemplos típicos de transitórios impulsivos gerados sinteticamente.




Figura 2.1: Exemplos de transitórios impulsivos.

Transitórios Oscilatórios

Conforme [1], os transitórios oscilatórios consistem em uma rápida variação nos valores e na polaridade da tensão e corrente. São decorrentes de energização de linhas, corte de carga indutiva, eliminação de faltas, chaveamento de bancos de

capacitores e transformadores. A Figura 2.2 ilustra dois transitórios oscilatórios gerados sinteticamente.




Figura 2.2: Exemplos de transitórios oscilatórios na forma de onda da tensão.

2.2.2 Variações de tensão de curta duração

As variações de tensão de curta duração são caracterizadas pela elevação (*swell*), ou redução (*sag*) da amplitude da tensão no sistema durante um curto intervalo de tempo. A redução da amplitude da tensão a valores inferiores a 0,1 p.u. caracteriza uma interrupção momentânea do sistema. Os limites de tempo de ocorrência e intervalo de variação da amplitude da tensão para estes eventos são mostrados na Tabela 2.1. Tais variações de tensão são, geralmente, causadas por condições de falta, energização de grandes cargas as quais requerem altas correntes de partida, curto-circuitos, ou por intermitentes falhas nas conexões dos cabos do sistema.

A Figura 2.3 ilustra variações de tensão com afundamento de tensão em (a), elevação de tensão em (b) e interrupção de tensão em (c).

2.2.3 Variações de tensão de longa duração

As variações de tensão de longa duração são caracterizadas pela alteração do valor *RMS* (do inglês *Root Mean Square*) da tensão na frequência fundamental do sistema por um período maior que 1 minuto. Estas variações podem ser positivas, caracterizando uma sobre-tensão, ou negativas, ocasionando uma sub-tensão. Todas




Figura 2.3: Exemplos de variações de tensão: (a) Afundamento de tensão; (b) Elevação de tensão e; (c) Interrupção.

elas são geralmente causadas por variações de carga e operações de chaveamento no sistema.

2.2.4 Deformação da forma de onda da tensão

As distorções das formas de onda de tensão são definidas como desvios da forma senoidal da tensão na frequência fundamental do sistema. Estas distorções se apresentam em regime permanente no sistema e são causadas em sua grande maioria pela presença de tensão de *offset*, harmônicos, inter harmônicos, *notches* e ruído no sistema elétrico. As principais características destes tipos de distúrbios são apresentadas na Tabela 2.1.

A Figura 2.4 ilustra dois exemplos típicos de deformações da forma de onda da tensão.

2.2.5 Tipos de Desbalanceamentos

São considerados, a nível de classificação, conforme [5], quatro tipos de desbalanceamento trifásico, o tipo A que é devido a uma falta trifásica e os tipos B, C e D, que são devidos a faltas monofásicas e fase-fase. Basicamente, o tipo A é uma falta trifásica, isto é, um afundamento nas 3 fases. O tipo B é um afundamento em apenas uma das fases. O tipo C é um afundamento em duas das fases e o tipo D é um afundamento em uma das fases e deslocamento de fase das outras duas. Os




Figura 2.4: Exemplos de deformações de tensão: (a) Harmônicos e (b) *Notches*.

outros tipos de desbalanceamentos não serão considerados neste trabalho.

2.3 Indicadores de Qualidade de Energia Elétrica

Um sistema elétrico trifásico ‘ideal’ deve satisfazer às seguintes condições de operação em regime permanente:

1. Tensões e correntes alternadas, com formas senoidais;
2. Amplitudes constantes, nos valores nominais;
3. Frequência constante, no valor síncrono;
4. Tensões trifásicas equilibradas;
5. Fator de potência unitário nas cargas;
6. Perdas nulas na transmissão e distribuição.

Estas seis condições podem garantir que o sistema atenda adequadamente a carga prevista para operar com corrente alternada na frequência industrial. Em um sistema real é praticamente impossível satisfazer totalmente a estas condições, pois a rede e os equipamentos elétricos estão sempre sujeitos a falhas ou perturbações que deterioram de alguma maneira as condições que seriam desejáveis para a operação. Quem determina o grau de confiabilidade com que essas condições podem ser

atendidas depende, em grande parte, dos equipamentos de monitoração e controle que estiverem disponíveis no sistema.

Usando como referência as condições de operação de um sistema ideal, pode-se adotar como critério para avaliar a qualidade de energia elétrica o afastamento que o sistema real experimenta dessas condições ideais. Essa abordagem permite que índices avaliem a deterioração das condições de operação, em função dos distúrbios que são impostos ao sistema.

Assim colocado, o critério de avaliação da qualidade de energia elétrica pode incluir a verificação das normas estabelecidas para qualificar e quantificar a deterioração imposta por um distúrbio. Em resumo, podem ser considerados:

- a) **Confiabilidade/disponibilidade do fornecimento.** A confiabilidade é definida pelo número de cortes de energia em um determinado período de tempo. A disponibilidade é caracterizada pelo número de interrupções do fornecimento, a duração de cada interrupção e a duração total de interrupção por ano. A resolução ANEEL 24/2000, de 27/01/2000 regulamenta estes indicadores. Atualmente, esta resolução encontra-se em processo de substituição pelo PRODIST [6];
- b) **Nível de tensão adequado.** Obtido através do controle dos limites mínimos e máximos de tensão dos consumidores;
- c) **Distorção da forma de onda.** Através da avaliação da presença de frequências harmônicas e de inter-harmônicas;
- d) **Regulação da tensão.** Em torno dos valores nominais, mesmo com cargas variáveis, quantificando a amplitude e frequência das flutuações de tensão;
- e) **Frequência nominal da rede.** Atualmente é estabelecida através do balanço de energia entre sistema produtor e consumidor;
- f) **Fator de potência.** O valor mínimo atual é 0,92 e é regulamentado através de legislação específica;
- g) **Desequilíbrio entre fases.** Dado como valor percentual dos componentes de sequência negativa e zero, medidos em relação à sequência positiva.

A interrupção do fornecimento é definida como a descontinuidade da tensão disponível em qualquer uma das fases de um circuito elétrico que atende a unidade consumidora. Considera-se tensão interrompida aquela em que a amplitude do valor eficaz é inferior a 10% do valor nominal da tensão, com duração maior ou igual a três minutos.

O desempenho das concessionárias quanto à continuidade do serviço prestado de energia elétrica é medido pela ANEEL com base nos indicadores DEC (Duração Equivalente de Interrupção por Unidade Consumidora) e FEC (Frequência Equivalente de Interrupção por Unidade Consumidora), obtidos, respectivamente, por [6]:

$$DEC = \frac{\sum_{i=1}^n Ca(i) \times T(i)}{Cs} \quad (2.1)$$

e

$$FEC = \frac{\sum_{i=1}^n Ca(i)}{Cs}, \quad (2.2)$$

em que i é o número de interrupções, $T(i)$ é o tempo de duração da interrupção i do conjunto de consumidores considerados em horas, $Ca(i)$ é o número de consumidores do conjunto considerado, atingido nas interrupções, e Cs é o número total de consumidores do conjunto considerado.

A ANEEL implantou também, no ano de 2000, mais três indicadores destinados a aferir a qualidade prestada diretamente ao consumidor, quais sejam [6]: DIC (Duração de Interrupção por Unidade Consumidora) e FIC (Frequência de Interrupção por Unidade Consumidora), que indicam por quanto tempo e o número de vezes, respectivamente, que uma unidade consumidora ficou sem energia elétrica durante um período considerado; e o DMIC (Duração Máxima de Interrupção por Unidade Consumidora), que é um indicador que limita o tempo máximo de cada interrupção, impedindo que a concessionária deixe o consumidor sem energia elétrica durante um período muito longo.

De fato, o setor elétrico encontra-se em fase de regulamentação, no que diz respeito à QEE. No Brasil, existe um esforço, por parte do governo, para a regulamentação dos padrões da qualidade de energia elétrica nos níveis de transmissão e distribuição. Atualmente, encontra-se em fase de regulamentação o PRODIST, Procedimentos de Distribuição da ANEEL (Agência Nacional de Energia Elétrica),

que no seu módulo 8 contém documentos regulatórios com alguns indicadores de desempenho e de qualidade dos serviços de energia elétrica.

2.4 Estado da Arte

O monitoramento da QEE teve início na década de 70 utilizando a tecnologia dos voltímetros da época. Em seguida, na década de 80 começaram a aparecer os sistemas de visualização gráfica multi-funcionais, contribuindo para a evolução do monitoramento da QEE [10].

Em meados da década de 80 e início da década de 90, os avanços na área de processamento de sinais, a redução do custo de sistemas de monitoramento baseados em dispositivos *Digital Signal Processor* (DSP) [11] e *Flexible Programmable Gate Array* (FPGA) [12], contribuíram de forma significativa para o uso de técnicas de processamento de sinais em sistemas elétricos de potência (SEP) e, conseqüentemente, para o monitoramento da QEE, conforme apontado em [13].

É possível ter-se uma idéia do estado da arte do monitoramento da QEE observando-se a evolução da tecnologia empregada para tal e de seus usuários [14]. A Tabela 2.2, mostra essa evolução desde a década de 70. Na década de 90, com o advento dos computadores, a tecnologia aplicada no monitoramento da QEE passou a utilizar cada vez mais técnicas de processamento de sinais.

Tabela 2.2: Evolução da tecnologia e campo de aplicação do monitoramento da QE. Extraído de [2].

Década de 70	Década de 80	Década de 90	2000
Tecnologia			
- Voltímetros	- Osciloscópios - Gráficos	- Processamento Digital de Sinais - Computadores - Armazenamento de dados - Comunicação	- Reconhecimento de padrões - Compressão de Dados - Fronteira de decisão - Redes - Internet
Usuários			
- Engenheiros	- Engenheiros - Grupos de QE	- Engenheiros - Companhias - Indústrias	- Agências Reguladoras - ISO - Concessionárias

Recentemente, o uso de técnicas de inteligência computacional contribuiu

bastante para o desenvolvimento e aperfeiçoamento de técnicas de reconhecimento de padrões [15–18] e compactação da informação [19–21], que foram incorporadas como novas tecnologias para o monitoramento da QEE. Este avanço tende a processar os sinais de forma a obter um conjunto mais reduzido e suficientemente representativo dos mesmos, facilitando o processo de decisão de classe pelo detector e/ou classificador.

Neste contexto, diversos trabalhos de detecção e classificação automática de distúrbios no sinal de tensão têm sido publicados nos últimos anos. Estes se dividem em dois grupos [8]:

1. Classificação de formas de onda, incluindo classes típicas de distúrbios, como variações de tensão e transitórios. Este tipo de trabalho tem um grande valor para o desenvolvimento de ferramentas de classificação.
2. Classificação de formas de onda baseada nas suas origens, incluindo classes de distúrbios como faltas, energização de transformadores e energização de capacitores. Este tipo de trabalho tem grande valor prático. O trabalho de [22] é um exemplo interessante sobre a classificação de distúrbios de acordo com suas origens. Neste trabalho, os seguintes eventos foram abordados: faltas, saturação de transformadores, partida de motores de indução e interrupções. O sistema apresentou um bom desempenho e foi testado em aquisições de monitores de QEE. A principal técnica utilizada foi o filtro de Kalman.

O reconhecimento de padrões tem como objetivo principal a classificação de sinais (padrões) em um número de categorias ou classes [15]. As técnicas de reconhecimento de padrões são usadas para classificar e/ou descrever padrões através de um conjunto de propriedades ou características extraídas dos dados brutos ou pré-processados. A extração de características pode ser realizada por inúmeras técnicas [16] e, geralmente, é tratada como um problema estocástico. O objetivo principal desta etapa é extrair características com boa capacidade de discriminação entre as classes do problema. Contudo, a extração de características pode levar a um conjunto de parâmetros em alta dimensão e, portanto, técnicas de seleção de parâmetros e compactação de sinais são frequentemente utilizadas para reduzir o espaço de parâmetros a uma dimensão menor e de mais fácil visualização. Estas etapas de

extração de características e compactação de sinais estão diretamente relacionadas à capacidade de aplicação em tempo real dos sistemas de reconhecimento de padrões, uma vez que um reduzido conjunto de parâmetros (características) com boa capacidade de discriminação viabiliza a utilização de uma técnica de classificação mais simples, reduzindo, conseqüentemente, o tempo de processamento. A capacidade de aplicação em tempo real é uma importante característica frequentemente requerida dos sistemas de reconhecimento de padrões, entretanto, dependendo da aplicação alvo, sistemas de reconhecimento de padrões *off-line* são desejados.

Dentre as principais técnicas de reconhecimento de padrões aplicadas em sistemas de potência, destacam-se os classificadores baseados na teoria de Bayes, os classificadores lineares e os não lineares (sistemas fuzzy, redes neurais e etc), “*template matching*” e os classificadores dependentes do contexto [18, 23–25]. É importante citar o trabalho [17], que faz uma revisão apontando vantagens e desvantagens de algumas das principais técnicas de classificação de distúrbios elétricos. Estas vantagens e desvantagens estão destacadas nas Tabelas 2.3 e 2.4, que foram extraídas de [17].

A classificação, contudo, deve ser precedida pela etapa de detecção de distúrbios [19]. A detecção de distúrbios em QEE é o primeiro passo para uma correta análise do problema de QEE, uma vez que a correta detecção da presença destes facilita o emprego das técnicas de classificação, de identificação e de compactação de sinais, posto que o uso das mesmas deve ocorrer quando os distúrbios são detectados. Várias técnicas baseadas na transformada de wavelet, *Fast Fourier Transform* (FFT) e inteligência computacional têm sido aplicadas diretamente na detecção de distúrbios em QEE [26–29]. É importante mencionar também os trabalhos de [19–21], que apresentam uma diferente contribuição para a detecção de distúrbios, com técnicas baseadas no princípio Dividir e Conquistar. Em [19], é apresentada, além de uma nova técnica de detecção de distúrbios em baixa, média e alta tensão, uma nova solução para medir o índice de distorção harmônica (THD), que não requer a utilização da FFT. Em [20], foi proposto um método (EDCM - *enhanced data compression method*) que utiliza processamento adaptativo de sinais para estimar o componente fundamental do sinal de tensão monitorado e separá-lo da parte transitória, onde foi aplicada a transformada *wavelet* (TW) para a análise e representação dos dis-

Tabela 2.3: Métodos de Classificação - Parte 1.

Método	Propriedade	Comentários
Template matching	Caracterizar o modelo mais similar.	Os modelos e os parâmetros devem ser informados pelo usuário; o procedimento pode incluir normalizações não lineares.
Nearest Mean Classifier	Caracterizar a classe média mais próxima	Quase não precisa de treinamento; processo de teste rápido.
Método dos subespaços	Caracteriza o subespaço de classes mais próximo	O espaço de invariantes é usado ao invés de ser normalizado;
Regra do vizinho mais próximo-I	Caracteriza a classe de treinamento mais próxima	Não necessita de treinamento; desempenho robusto; etapa de teste lenta.
Regra do vizinho mais próximo-K	Caracteriza a classe com a maioria dos K vizinhos mais próximos usando um desempenho otimizado pelo valor de K.	Assintoticamente ótimo; escala dependente; etapa de teste lenta.
Teoria de Bayes	Caracteriza a classe que tem a máxima estimativa da probabilidade a posteriori.	Produz classificadores simples (linear ou quadráticos) para distribuições Gaussianas; sensível a erros da estimativa da densidade.
Classificador Logístico	Regra da Máxima Verossimilhança para probabilidades posteriores logística	Linear; procedimento iterativo; ótimo para diferentes distribuições (Gaussianas); apropriado para dados com intersecções.

Tabela 2.4: Métodos de Classificação - Parte 2.

Método	Propriedade	Comentários
Classificador Parzen	Regra de Bayes para estimativas de densidades com desempenho kernel otimizado.	Assintoticamente ótimo; escala dependente; etapa de teste lenta.
Discriminante Linear de Fisher	Classificador linear, usado para selecionar parâmetros.	Simples e rápido; semelhante ao Bayesiano para distribuições Gaussianas com matrizes de covariância idêntica.
Árvore de decisão binária	Encontra um conjunto de limiars para uma seqüência de parâmetros.	Treinamento iterativo; sensibilidade ao excesso de treinamento; necessidade de cortes; etapa de teste lenta.
Perceptron	Otimização iterativa de um classificador linear.	Sensível aos parâmetros de treinamento; pode produzir limites de confiança.
Perceptron Multi-Camadas	Otimização iterativa de duas ou mais camadas usando funções sigmoidais.	Sensível aos parâmetros de treinamento; treinamento lento; função de classificação não-linear; pode produzir limites de confiança; sensível ao excesso de treinamento; precisa de regularização.
Redes de Bases Radiais	Otimização MSE iterativa de uma rede neural alimentada adiante com ao menos uma camada de neurônios.	Sensível aos parâmetros de treinamento; função de classificação não-linear; pode produzir limites de confiança; sensível ao excesso de treinamento; precisa de regularização; pode ser robusta.
Classificador de Vetor de Suporte	Maximiza as fronteiras entre classes pela seleção de um número mínimo de vetores de suporte.	Escala dependente; Iterativo; treinamento lento; insensível ao excesso de treinamento; boa capacidade de generalização;

túrbios. Já em [21], foi proposta uma nova técnica para detecção e compressão de eventos de QEE em que a técnica EDCM modificada foi introduzida juntamente com a utilização de filtros “notch” e FIR.

A detecção de distúrbios envolve a etapa de segmentação [30], que está diretamente relacionada com a determinação da amostra que marca o início e fim de um distúrbio no sinal de tensão monitorado.

A maioria dos métodos de detecção e segmentação requerem janelas do sinal maiores (para o cálculo de RMS ou aplicação de filtros digitais, dentre outros) e, conseqüentemente, um tempo de processamento maior [3]. Em contrapartida, métodos de detecção com tempo de processamento reduzido, podem ser aplicados em tempo real e, portanto, destacam-se sobre os demais. A detecção em tempo real é importante para que se possa atuar no sistema, dada a ocorrência de certo distúrbio, isolando a área de ocorrência do distúrbio do resto do sistema ou até mesmo tomando ações corretivas. Neste sentido, destaca-se o trabalho de [31], que após segmentar o sinal de tensão em janelas de até 1/8 de ciclo do componente fundamental, detecta os distúrbios através do valor RMS. Porém, este trabalho apresenta reduzido desempenho (de 40 % a 50 %) para janelas de 1/8 de ciclo quando a razão de falso alarme é próxima de zero.

Cumpramos ressaltar o grande interesse dos pesquisadores na utilização de técnicas baseadas na TW para o monitoramento da QEE, o que pode ser evidenciado em diversos trabalhos [27–29, 32–37]. De fato, as técnicas baseadas na TW se mostram muito eficazes quando utilizadas para extrair parâmetros de distúrbios em sinais de tensão cujo ruído de fundo aditivo tenha potência baixa. O trabalho de [38] mostra uma boa aplicação da TW para extrair parâmetros de distúrbios, com o objetivo de classificação, em diferentes níveis de ruído. As TW se mostram bastante eficientes também na identificação do início e fim do distúrbio no sinal de tensão, conforme apresentado em [39] e [40]. Por outro lado, quando a potência do ruído de fundo se torna elevada, as técnicas baseadas em TW apresentam perda considerável de desempenho. De acordo com [28], os sinais de tensão com relação sinal ruído (SNR - *Signal Noise Ratio*) baixa degradam severamente o desempenho das técnicas de detecção baseadas na TW. Além disso, conforme apontado em [41], a TW necessita de um considerável esforço computacional e possui dependência da escolha das bases

wavelets.

Ainda no campo de detecção de distúrbios, destacam-se os trabalhos propostos em [42] e [43], em que um sistema de detecção automático de distúrbios elétricos bastante atraente do ponto de vista de desempenho e complexidade computacional foi proposto. Nestes trabalhos, o detector de Bayes é aplicado em um vetor contendo dois parâmetros obtidos utilizando estatísticas de ordem superior (EOS) [23, 44, 45]. Estes sistemas alcançam desempenhos próximos a 100 % para reduzidas janelas do sinal de tensão (até 1/16 ciclo do componente fundamental) com uma razão de falso alarme próxima de zero.

As EOS têm sido frequentemente utilizadas como parâmetros extraídos de um dado sinal pelos cálculos dos chamados ‘cumulantes’ e aplicadas em diversas áreas, conforme apontado em [44]. Isto se deve ao fato de que estas são imunes ao ruído gaussiano e possuem uma boa capacidade de fornecer informações importantes a cerca do sinal analisado [46]. Além dos trabalhos propostos em [42] e [43], destacam-se também os propostos em [47] e [48] que utilizaram extração de parâmetros baseada em cumulantes de ordem superior para a classificação e análise de distúrbios em QEE com grande sucesso. Adicionalmente, como as EOS possuem uma grande capacidade de extrair informações importantes dos sinais, é mostrado em [42] e [43], que com poucos parâmetros EOS (cumulantes de ordem superior), selecionados utilizando o critério de Fisher [15], pode-se caracterizar bem os distúrbios elétricos, no que tange a detecção e a classificação, maximizando então as fronteiras de separação entre os mesmos. Dessa forma, é possível alcançar bons resultados de detecção e classificação utilizando técnicas de classificação mais simples, o que é bastante importante sob o ponto de vista de implementação e aplicações de monitoramento *on-line*, que requerem reduzida complexidade computacional na fase de operação.

Um requisito importante em algoritmos de monitoramento é a capacidade de execução em tempo real. Algoritmos com baixa complexidade computacional com vistas à detecção e classificação de distúrbios foram introduzidos em [49–51]. A característica principal destes algoritmos é a detecção e classificação de distúrbios em sinais de tensão utilizando uma janela de comprimento igual a um ciclo do componente fundamental do sinal monitorado.

O desempenho das técnicas de reconhecimento de padrões está diretamente

relacionado com os parâmetros extraídos dos padrões. Contudo, a extração de um conjunto representativo de parâmetros é uma questão bastante complexa, visto que a mesma é dependente da aplicação alvo. Tal questão, dentro do contexto de classificação, é, normalmente, analisada conjuntamente com a seleção de um classificador adequado para a aplicação.

Em geral, os métodos de classificação de distúrbios de QEE utilizam técnicas de extração de parâmetros seguida de técnicas tradicionais de reconhecimentos de padrões. No campo de extração de parâmetros com a finalidade de classificação, as TW são as mais empregadas [32, 33, 35, 36, 51–55] e no campo da classificação, as redes neurais artificiais [51, 56–61], lógica fuzzy [37, 62–64], algoritmos genéticos [64] e SVMs [37, 65, 66] têm sido as técnicas mais utilizadas.

Dado o grande número de técnicas disponíveis para a extração de parâmetros dos sinais, o número de parâmetros disponíveis para o sistema de classificação é bastante grande. No entanto, no projeto de um classificador, geralmente, um número reduzido de parâmetros é considerado por várias razões, dentre as quais destacam-se [67]:

1. a complexidade computacional devido às limitações de custo computacional e de processamento em tempo real.
2. a propriedade de generalização do classificador. Um conjunto finito de vetores de treinamento com um elevado número de parâmetros leva a um classificador também com elevado número de parâmetros. De fato, sabe-se que classificadores com grande número de parâmetros tendem a se adaptar apenas aos detalhes específicos dos conjuntos de dados de treinamento [15, 16]. Portanto, utilizando-se um número reduzido de parâmetros nos vetores de treinamento, classificadores com boa capacidade de generalização podem ser obtidos.

Para evitar o elevado número de parâmetros em projetos de classificadores, diferentes técnicas têm sido propostas, dentre as quais, destacam-se: o teste estatístico de hipóteses, as medidas de separação entre classes, as matrizes *scatter*, a razão de discriminação de Fisher (FDR - *Fisher's discriminat ratio*), a transformação linear, etc [15, 16].

Sabe-se que os sistemas de potência estão sujeitos à ocorrência de diversos distúrbios, provocados por diferentes fontes. Tais distúrbios podem aparecer nas formas de onda da tensão e corrente isoladamente ou de forma simultânea (múltiplos distúrbios). Para o problema de detecção e classificação de distúrbios isolados, várias soluções baseadas em diferentes técnicas podem ser encontradas na literatura [14, 19, 21, 26–29, 33, 36, 37, 41–43, 47–50, 52, 53, 55, 57, 59, 60, 65, 68–73]. Por outro lado, o mesmo não acontece quando o problema se trata de múltiplos distúrbios. O projeto de sistemas de monitoramento de QEE que estejam preparados para o tratamento de eventos contendo múltiplos distúrbios não é uma tarefa trivial, e em sistemas de potência, é possível em algumas redes a ocorrência de alguns distúrbios simultaneamente. Ademais, o uso das técnicas propostas pelos trabalhos anteriormente citados poderá gerar resultados contraditórios e não representativos acerca do aparecimento de múltiplos distúrbios e, conseqüentemente, o uso de uma solução para a identificação da fonte geradora de distúrbio, tal como proposto em [74], é bastante comprometido. De fato, a classificação de múltiplos distúrbios é um problema ainda em aberto e, portanto, demanda novas investigações para que a caracterização destes seja a mais correta possível. Isso resultará em maior confiabilidade na identificação das fontes geradoras de distúrbios, dentre outras vantagens.

Neste contexto, destacam-se os trabalhos de [32, 57, 61, 66, 75, 76] que propuseram classificadores que atacam o problema de múltiplos distúrbios apenas para o caso da ocorrência simultânea de harmônicos e afundamentos de tensão (*swells*), e harmônicos e elevações de tensão (*sags*). É importante citar também o trabalho de [58], que faz uma importante contribuição propondo um sistema de classificação em tempo real utilizando redes neurais. Este sistema foi projetado para classificar até dois distúrbios simultâneos que podem ser compostos por desvios na frequência (leves e severos), desvios na tensão (*flickers*, *sags*, *swells*, sobretensão e sub-tensão) e harmônicos. Os trabalhos de [77, 78] aparecem como importantes contribuições também, uma vez que abordam até 3 tipos de distúrbios simultâneos utilizando um sistema baseado em *wavelet* e redes neurais.

Uma maneira interessante de atacar o problema de múltiplos distúrbios é decompor o sinal de tensão monitorado $\{v(n)\}$ nos sinais $\{f(n)\}$, $\{h(n)\}$ e $\{u(n)\}$, conforme proposto em [67]. Os sinais $\{f(n)\}$, $\{h(n)\}$ e $\{u(n)\}$ representam, res-

pectivamente, as estimativas do componente fundamental do sinal de tensão, dos harmônicos e, por último, dos componentes inter-harmônicos, transitórios e ruídos de fundo. Desta forma, cada um destes sinais está restrito ao aparecimento de um grupo reduzido de distúrbios. De fato, esta é uma forma de separar os múltiplos distúrbios, o que facilita a classificação dos mesmos.

Em geral, as técnicas de classificação de distúrbios processam pelo menos 4 ciclos do componente fundamental do sinal de tensão para realizar a classificação. Dependendo do processamento envolvido, o sistema final pode não ser eficiente em aplicações em tempo real. Por outro lado, a utilização de janelas reduzidas do sinal de tensão pode não ser suficiente para caracterizar bem os distúrbios, o que pode comprometer o desempenho da classificação.

Uma área também de grande interesse e diretamente relacionada à QEE é a identificação e caracterização de cargas no SEP. Considerando-se que o aumento de cargas não lineares na rede elétrica tem contribuído bastante para a degradação da QEE, a identificação e localização de tais cargas são essenciais para o controle da influência destas no SEP. Estas atividades são importantes por várias razões: (i) os estudos de fluxo de cargas harmônicas requerem informações sobre o tipo de carga; (ii) o conhecimento do tipo de carga pode ajudar no planejamento de sistemas de potência; (iii) cargas não lineares são fontes de harmônicos e inter-harmônicos e, sabe-se, que os harmônicos podem causar sobrecarga no sistema, danos em equipamentos, mau funcionamento de equipamentos de proteção, perda de dados em computadores, dentre outros; (iv) procedimentos corretivos podem ser tomados contra clientes (consumidores) que não são capazes de manter a sua carga em níveis aceitáveis de poluição.

2.5 Equipamentos de Monitoramento de Energia Elétrica

Com o advento de novas tecnologias em processamento digital de sinais, microprocessadores e dispositivos de armazenamento de dados, tornou-se possível o desenvolvimento de sistemas de monitoramento. Assim, diferentes equipamentos de monitoramento de sinais de tensão vêm sendo desenvolvidos para diferentes propósi-

tos.

Estes equipamentos de monitoramento são projetados para determinados níveis de tensão e corrente. Instrumentos típicos têm suas tensões e correntes de entrada limitadas, respectivamente, em 600 V rms e 5 A rms [30]. Transdutores de tensão e transformadores de corrente são utilizados para obter o nível de sinal desejado [10].

Monitores digitais modernos utilizam conversores analógico-digital (A/D) com alta resolução e diferentes razões de amostragem. As medições e parâmetros calculados podem ser gravados no próprio equipamento ou transferidos para um computador, para serem, posteriormente, analisados. Tecnologias de *Intranet* são empregadas para a aquisição dos dados obtidos em locais apropriados [79].

Os parâmetros típicos de QEE, obtidos pela maioria dos monitores são:

- Valores rms de tensão e corrente;
- Harmônicos da tensão e corrente;
- Total de distorção harmônica da tensão e corrente (THD).

Estes parâmetros devem ser calculados em curto intervalo de tempo e armazenados pelo monitor. Entretanto, a tarefa mais importante dos monitores é, provavelmente, a captura de distúrbios no sinal monitorado sem ultrapassar a capacidade máxima de memória do equipamento durante o monitoramento. O método mais comumente empregado nos monitores para capturar os distúrbios é detectar as mudanças no valor rms, pela comparação com limiares previamente definidos. Tipicamente, os limiares são definidos em $\pm 10\%$ do sinal de tensão nominal. A comparação de cada ciclo do sinal com os ciclos anteriores é também utilizada para capturar eventos que não causam mudanças significantes no valor rms [30].

A escolha dos limiares é importante para evitar a saturação de memória do monitor com eventos de pouca importância. Limiares adaptativos podem também ser utilizados para regular a razão da captura dos eventos em casos de grande número de ocorrências [10]. Em [19], um sistema interessante de detecção de distúrbios com limiar adaptativo foi proposto, em que uma alta razão de detecção foi obtida. Contudo, conforme apontado por [30], a melhor solução para os monitores seria analisar os eventos e, baseado nos resultados da análise, decidir entre o armazenamento ou

não do evento. Para automatizar este processamento, importantes ferramentas de processamento de sinais e inteligência computacional são requeridas. Além disso, é também importante, o conhecimento do sistema de potência monitorado e os maiores danos causados pelos distúrbios mais frequentes.

Capítulo 3

Formulação Matemática dos Distúrbios e Metodologia

Este capítulo tem por objetivo descrever a formulação dos distúrbios e a metodologia utilizada, detalhando o banco de sinais utilizados para a obtenção dos resultados.

3.1 Formulação Matemática dos Distúrbios de QEE

Um sistema desenvolvido para detecção e classificação de distúrbios elétricos em QEE deve identificar corretamente a ocorrência de cada anormalidade em um sinal de tensão do sistema de potência discreto no tempo $v[n]$, que pode ser expresso como uma adição da contribuição de vários tipos de fenômenos [80], como:

$$v[n] = v(t)|_{t=\frac{n}{f_s}} := f[n] + h[n] + i[n] + t[n] + r[n] \quad (3.1)$$

onde $n = 0, \dots, N-1$, f_s é a frequência de amostragem, as sequências $f[n]$, $h[n]$, $i[n]$, $t[n]$ e $r[n]$ representam o componente fundamental, harmônicos, inter-harmônicos, transitórios, e ruído, respectivamente. Cada um destes sinais pode ser definido como:

$$f[n] := A_0[n] \cos\left[2\pi \frac{f_0[n]}{f_s} n + \theta_0[n]\right], \quad (3.2)$$

$$h[n] := \sum_{m=1}^M h_m[n], \quad (3.3)$$

$$i[n] := \sum_{j=1}^J i_j[n], \quad (3.4)$$

$$t[n] := t_{imp}[n] + t_{not}[n] + t_{osc}[n], \quad (3.5)$$

e $r[n]$ é um ruído com distribuição normal $\mathcal{N}(0, \sigma_r^2)$ e independente de $f[n]$, $h[n]$, $i[n]$ e $t[n]$.

Em (3.2), $A_0[n]$, $f_0[n]$ e $\theta_0[n]$ representam a amplitude, frequência fundamental, e fase do sinal de tensão, respectivamente.

Em (3.3) e (3.4), $h_m[n]$ e $i_j[n]$ são o m -ésimo harmônico e o j -ésimo inter-harmônico, respectivamente, definidos como:

$$h_m[n] := A_m[n] \cos[2\pi m \frac{f_0[n]}{f_s} n + \theta_m[n]] [u[n - n_{h_{m,i}}] - u[n - n_{h_{m,f}}]], \quad (3.6)$$

e

$$i_j[n] := A_{I,j}[n] \cos[2\pi \frac{f_{I,j}[n]}{f_s} n + \theta_{I,j}[n]] [u[n - n_{i_{j,i}}] - u[n - n_{i_{j,f}}]], \quad (3.7)$$

em que $u[n]$ denota a sequência degrau unitário, $n_{h_{m,i}}$ e $n_{h_{m,f}}$ representam as amostras de início e fim dos harmônicos, respectivamente. De forma análoga, $n_{i_{j,i}}$ e $n_{i_{j,f}}$ representam as amostras de início e fim dos inter-harmônicos, respectivamente. Em (3.6), $A_m[n]$ é a amplitude e $\theta_m[n]$ é a fase do m -ésimo harmônico. Em (3.7), $A_{I,j}[n]$, $f_{I,j}[n]$, e $\theta_{I,j}[n]$ são a amplitude, frequência e fase do j -ésimo inter-harmônico, respectivamente. Em (3.5), $t_{imp}[n]$, $t_{not}[n]$ e $t_{osc}[n]$ representam transitórios impulsivos, *notches* e transitórios oscilatórios, respectivamente, e são expressos por [80]:

$$t_{imp}[n] := \sum_{i=1}^{N_{imp}} t_{imp,i}[n] [u[n - n_{t_{imp,i}}] - u[n - n_{t_{imp,f}}]], \quad (3.8)$$

$$t_{not}[n] := \sum_{i=1}^{N_{not}} t_{not,i}[n] [u[n - n_{t_{not,i}}] - u[n - n_{t_{not,f}}]], \quad (3.9)$$

$$t_{osc}[n] := \sum_{i=1}^{N_{osc}} A_{osc,i}[n] \exp[-\alpha_{osc,i}(n - n_{osc,i})] [u[n - n_{t_{osc,i}}] - u[n - n_{t_{osc,f}}]], \quad (3.10)$$

onde $t_{imp,i}[n]$ e $t_{not,i}[n]$ são as n -ésimas amostras do i -ésimo transitório impulsivo e do i -ésimo *notch*, respectivamente. $n_{t_{imp,i}}$, $n_{t_{not,i}}$ e $n_{t_{osc,i}}$ representam as amostras de início de cada transitório impulsivo e $n_{t_{imp,f}}$, $n_{t_{not,f}}$ e $n_{t_{osc,f}}$ representam as amostras que marcam o fim de cada um deles.

3.2 Banco de Dados Utilizado

Conforme já destacado, o objetivo desta tese se resume em analisar, detectar e classificar os distúrbios elétricos. As etapas de análise, detecção e classificação dos distúrbios, no entanto, são caracterizadas por diferentes propósitos e requerem diferentes abordagens.

Ao longo desta tese, estarão sendo utilizados diferentes conjuntos de dados para o desenvolvimento das análises e dos sistemas de detecção e classificação de distúrbios elétricos na forma de onda da tensão.

Os eventos foram modelados de acordo com a Seção 3.1 e gerados sinteticamente seguindo as normas definidas pelo IEEE [1], com uma frequência de amostragem $f_s = 256$ amostras por ciclo do componente fundamental (15.360 Hz) e SNR igual a 30 dB.

3.2.1 Análise de Distúrbios Por Curvas Principais

Para a análise dos distúrbios, a técnica de inteligência computacional conhecida por curvas principais [81] foi utilizada. A análise dos distúrbios pode ser feita *off line* ou em tempo real, dependendo do objetivo. No contexto desta tese, o propósito da análise dos distúrbios é de extrair informações que possam contribuir de alguma forma no projeto de sistemas de detecção e classificação. Por um lado, esta contribuição pode ser de forma indireta, auxiliando o projetista no que diz respeito ao conhecimento do problema e de sua complexidade. Por outro lado, a contribuição pode ser feita diretamente, a partir da extração de parâmetros que alimentem os

sistemas de detecção e classificação.

Nesta análise, foram abordadas as seguintes classes de eventos: sinais sem distúrbios, harmônicos, *notches*, transitórios impulsivos, transitórios oscilatórios, flutuações de tensão (*flicker*), elevações, afundamentos e interrupções de tensão. 500 eventos foram gerados para cada classe de distúrbio, sendo que 250 foram utilizados para a extração das curvas principais e os 250 restantes foram utilizados na extração de parâmetros. Esta metodologia foi então utilizada para gerar os resultados mostrados no Capítulo 4.

A definição do tamanho das janelas a serem utilizadas para analisar os distúrbios é bastante dependente da aplicação. Para fins de classificação, uma janela de 4 ciclos pode ser interessante para facilitar a identificação dos distúrbios. Alguns distúrbios de baixa frequência e longa duração, como os *flickers*, precisam ser analisados em janelas longas, caso contrário eles poderão ser confundidos com outros distúrbios. Distúrbios de curta duração podem ser corretamente classificados dentro de uma janela pequena. Assim, como em aplicação de classificação ainda não existe uma norma clara para aplicações de grande velocidade (como no caso de proteção de sistemas), o reduzido tamanho da janela só se justificará levando em conta um compromisso entre o desempenho da classificação e a velocidade requerida pela aplicação.

3.2.2 Detecção de Distúrbios

Para fins de detecção, existem duas vertentes. A primeira é definir se dentro da janela existe ou não o distúrbio e a ação requerida não é de controle ou proteção, mas simplesmente de aquisição da janela e processamento da mesma (classificação e análise do distúrbio). Neste caso, o tamanho da janela não é tão importante, pois não existe ação imediata ou em tempo real. No entanto, supondo uma aplicação de proteção, em que se deseja detectar e identificar um tipo de distúrbio e, caso este exista, seja preciso isolar o sistema ou parte do sistema o mais rápido possível, uma janela de sinal reduzida é requerida. Ademais, a utilização de janelas reduzidas torna a implementação do algoritmo mais adequada para aplicações *on-line*.

Para se alcançar um rápido processamento, além do uso de técnicas que demandam menor complexidade computacional, o uso de técnicas que alcancem

alto desempenho quando reduzidas janelas de aquisição são processadas, torna-se relevante. Uma abordagem neste sentido foi realizada em [31] e [68].

Para este fim, no projeto e teste dos sistemas de detecção propostos no Capítulo 5, janelas de aquisição com os seguintes comprimentos foram consideradas: $N = 256$ (1 ciclo do componente fundamental), $N = 128$, $N = 64$, $N = 32$ e $N = 16$ amostras.

Para cada comprimento de janela, foram gerados 110 eventos isolados de cada distúrbio. Os distúrbios abordados foram: afundamentos de tensão, elevações de tensão, interrupções de tensão, transitórios oscilatórios, harmônicos, transitórios impulsivos e *notches*, acumulando um total de 770 eventos. Foram gerados também 770 sinais sem distúrbio. Do total, 2/3 foi utilizado para o projeto dos sistemas (1/3 para treino e 1/3 para validação) e 1/3 para o teste.

3.2.3 Classificação de Distúrbios

A etapa de classificação, pode ser realizada sob dados armazenados, de forma *off line* ou fazendo a monitoração em tempo real do sistema elétrico.

Sabe-se que o problema de classificação de distúrbios é bastante complexo, principalmente quando classes de múltiplos distúrbios são consideradas. Embora o processamento em tempo real também seja importante nesta etapa, deu-se um foco maior no desempenho das técnicas de processamento de sinais e inteligência computacional utilizadas. Algumas considerações quanto à complexidade computacional de cada método, com vistas a implementações em tempo real, serão dadas no decorrer da tese.

Para o projeto dos sistemas de classificação, quatro ciclos do componente fundamental do sinal foram considerados, o que é equivalente a $N = 1.024$ amostras.

A análise de dados realizada no Capítulo 4 revela parâmetros, obtidos pelas curvas principais, que são interessantes à classificação. Estes parâmetros foram então explorados no Capítulo 6, em que dois classificadores baseados em curvas principais foram propostos. Alternativamente, as estatísticas de ordem superior [46] foram também aplicadas, em conjunto com as redes neurais artificiais [82]. Apenas as classes de distúrbios isolados foram abordadas. Para o projeto e teste dos sistemas propostos, 1.000 distúrbios de cada uma das classes (harmônicos, transitórios os-

oscilatórios, transitórios impulsivos, *notches*, afundamentos, elevações e interrupções de tensão) foram utilizados. Dos 1.000 distúrbios, 500 foram utilizados para o projeto (treino e validação) do classificador e 500 para o teste.

No Capítulo 7, além das classes de distúrbios isolados abordadas no Capítulo 6, classes de múltiplos distúrbios (distúrbios simultâneos), formados pela combinação entre os distúrbios isolados, foram também consideradas. Os distúrbios gerados para o Capítulo 6 foram utilizados para o projeto do classificador. Para testar o desempenho do sistema para distúrbios simultâneos, 500 distúrbios de cada classe abordada (vide Capítulo 7) foram gerados.

3.2.4 Análise de Múltiplos Distúrbios Usando ICA

No Capítulo 8, a técnica de inteligência computacional, conhecida por Análise de Componentes Independentes [83], foi explorada com o objetivo de desacoplar os eventos independentes presentes em um múltiplo distúrbio. Os esforços neste sentido foram concentrados em dois múltiplos distúrbios em particular: harmônicos com transitórios (M1) oscilatórios e harmônico com *notches* (M2). Estes foram os casos abordados, já que estes distúrbios são os principais remanescentes, quando o componente fundamental do sinal é removido. Neste caso, um banco de sinais de projeto, composto por 250 fontes de harmônicos, 250 de *notches* e 250 de transitórios oscilatórios, foi utilizado.

Para testar o sistema, 500 eventos da classe M1 e 500 da classe M2 foram gerados com SNR de 100 dB e, em seguida com SNR de 30 dB. Utilizaram-se sinais com SNR de 100 dB, com o propósito de testar a qualidade das estimativas dos distúrbios independente da influência de ruídos de fundo.

3.2.5 Banco de Distúrbios Reais

Para testar o desempenho dos sistemas de análise, detecção e classificação propostos para distúrbios reais, os sinais experimentais com distúrbios amostrados a $f_s = 15.360 \text{ Hz}$ e adquiridos pelo grupo de trabalho do IEEE (*working group* P1159.3), foram utilizados. A SNR estimada destes sinais é de 40 dB.

3.3 Filtro Notch

As etapas de análise, detecção e classificação, abordadas no contexto desta tese, foram pré-processadas por um filtro *notch* [84], sintonizado na frequência do componente fundamental ($f_0 = 60 \text{ Hz}$) do sinal monitorado. Esta metodologia é bastante aplicada em análises de distúrbios, já que, desta forma, o sinal de tensão monitorado $v[n]$ é decomposto em $f[n]$, referente à estimativa do componente fundamental do sinal, e $e[n]$, que, conforme a Equação (3.1), representa os harmônicos, inter-harmônicos, transitórios, e ruídos, presentes em $v[n]$. Esta decomposição está ilustrada na Figura 3.1.




Figura 3.1: Diagrama em blocos da obtenção de $e[n]$ utilizando um filtro *Notch*.

Devido, principalmente, ao baixo custo computacional e a maior seletividade na frequência de interesse, neste trabalho se utiliza uma estrutura de filtro IIR de 2ª ordem [85], cuja transformada z é dada pela equação:

$$H_0(z) = \frac{1 + a_0 z^{-1} + z^{-2}}{1 + \rho_0 a_0 z^{-1} + \rho_0^2 z^{-2}}, \quad (3.11)$$

em que

$$a_0 = -2 \cos \omega_0 \quad (3.12)$$

e ρ_0 é o fator *notch*, com $0 \ll \rho_0 < 1$. Conforme analisado em [86] e [87], para detecção e classificação de distúrbios, $\rho_0 = 0,97$ leva a melhores resultados e, portanto, este foi o fator *notch* utilizado no contexto da presente tese.

A curva de resposta em frequência da magnitude deste filtro é mostrada na figura 3.2.

Por outro lado, é comum em sistemas elétricos de potência uma variação suave na frequência do componente fundamental de até 2 % do valor nominal; entretanto, este valor pode chegar a até 5 % em sistemas mais vulneráveis [88]. De fato, estas variações na frequência fundamental podem degradar o desempenho de sistemas de

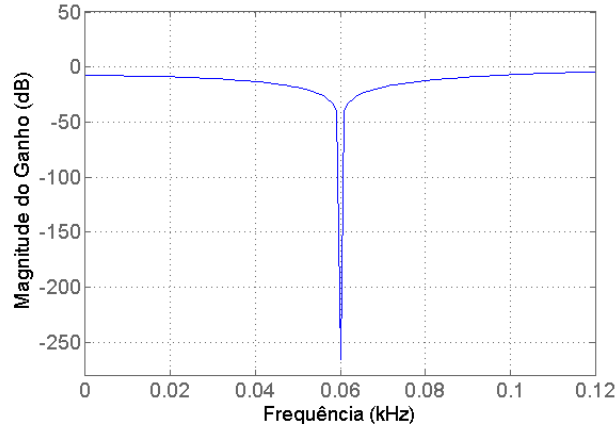


Figura 3.2: Resposta em frequência do filtro *notch* IIR utilizado, para $\rho_0 = 0,97$.

monitoramento da QEE. Nestes casos, é sugerido o uso de um filtro *notch* digital, sintonizado numa frequência controlada por uma estrutura EPLL (*Enhanced phase locked-loop*) [89, 90].

Com a decomposição mostrada na Figura 3.1, parâmetros extraídos de ambos os sinais $e[n]$ e $f[n]$ podem ser utilizados em sistemas de monitoramento de QEE. Contudo, sabe-se que o sinal $f[n]$ carrega informações referentes a um grupo mais restrito de distúrbios, tais como os de afundamentos, elevações e interrupções de tensão. Sendo assim, a análise deste sinal, quanto à detecção e/ou classificação, pode ser facilmente realizada monitorando o seu valor rms, conforme [30] e [42]. Por outro lado, uma pequena energia, referente a estes distúrbios, pode aparecer no sinal $e[n]$ devido ao transitório gerado pelo filtro *notch* na presença deles. Além disso, a energia referente aos demais distúrbios também está presente no sinal $e[n]$ e, portanto, a análise deste demanda mais esforço. As técnicas desenvolvidas no contexto desta tese possuem um foco maior nas análises do sinal $e[n]$.

A Figura 3.3 ilustra um sinal sem distúrbios em (a), e quatro tipos de distúrbios, de (b) a (e), em janelas de 1.024 amostras de $e[n]$. Observe que o afundamento de tensão aparece no sinal $e[n]$ devido ao transitório do filtro notch no instante em que o distúrbio aparece.




Figura 3.3: Exemplos dos sinal $e[n]$ com distúrbios. Em (a) tem-se um sinal sem distúrbio, em (b), um afundamento de tensão, em (c) um transitório oscilatório, em (d) um *notch*, e em (e) harmônicos.

Capítulo 4

Análise e Representação de Distúrbios Por Curvas Principais

Este capítulo propõe a utilização da técnica conhecida por Curvas Principais (CP) [81] na análise das classes de distúrbios e na representação das mesmas em um espaço de dimensões reduzidas.

4.1 Curvas Principais

As Curvas Principais consistem numa generalização não-linear da análise de componentes principais [91] e foram introduzidas por [81], como curvas suaves, unidimensionais, que passam no meio de um conjunto multidimensional de dados, fornecendo um bom resumo unidimensional destes (vide Fig. 4.1). Além disso, elas são não-paramétricas e sua forma é sugerida pelos dados.

As CP têm despertado bastante interesse da comunidade científica. Diversos trabalhos que aprimoraram sua definição inicial foram publicados após o trabalho original [81]. Tais trabalhos apresentam definições alternativas e propõem aplicações diversas. Em [92] é apresentado um apanhado destes trabalhos. Dentre os algoritmos propostos para a extração das curvas, destaca-se o k-segmentos não-suave [93]. Este algoritmo destaca-se por sua robustez na estimação das CP, menos susceptibilidade a mínimos locais e convergência garantida.

Em geral, na extração das CP de um conjunto de dados, o primeiro componente principal deste conjunto é tomado como ponto de partida para a construção da




Figura 4.1: Curva Principal para um conjunto de dados de duas dimensões.

curva. Em seguida, a curva é alterada sucessivamente até que o algoritmo convirja e, finalmente, obtém-se a CP.

Matematicamente, as CP são definidas a partir do conceito de autoconsistência [81]. Para entender este conceito, é necessário definir o índice de projeção de um ponto \mathbf{x}_i numa curva \mathbf{f} . Uma curva unidimensional no espaço d -dimensional é um vetor $\mathbf{f}(t)$ de d funções contínuas e uma única variável t , ou seja:

$$\mathbf{f}(t) = [f_1(t) \ f_2(t) \ \cdots \ f_d(t)]^T \quad (4.1)$$

em que T indica transposto.

Estas funções são denominadas de funções de coordenadas e o parâmetro t está relacionado ao ordenamento ao longo da curva.

Seja \mathbf{x} um vetor aleatório em \mathfrak{R}^d , com densidade de probabilidade h , e momento de segunda ordem finito. Seja \mathbf{f} uma curva suave no intervalo fechado $I \subseteq \mathfrak{R}^1$ que não intercepta a si própria, ou seja, $t_1 \neq t_2 \Rightarrow f(t_1) \neq f(t_2)$. O índice de projeção $t_f: \mathfrak{R}^d \rightarrow \mathfrak{R}^1$ é definido como:

$$t_f(\mathbf{x}) = \sup\{t : \|\mathbf{x} - \mathbf{f}(t)\| = \inf\|\mathbf{x} - \mathbf{f}(\mu)\|\} \quad (4.2)$$

sendo μ uma variável auxiliar definida em \mathfrak{R}^1 .

O índice de projeção $t_f(\mathbf{x})$ é o valor de t para o qual a CP $\mathbf{f}(t)$ está mais próxima de \mathbf{x} . Se houver mais de um valor possível, o maior deles é selecionado.

A Figura 4.2 ilustra o índice de projeção relativo a uma CP. São mostrados

cinco eventos $\mathbf{x}_1, \dots, \mathbf{x}_5$, os quais projetam nos pontos $\mathbf{f}(t_f(\mathbf{x}_1)), \dots, \mathbf{f}(t_f(\mathbf{x}_5))$ da curva, respectivamente. Observe que $t = t_f(\mathbf{x}_i)$ é o valor do parâmetro t relativo ao ponto da curva mais próximo ao evento \mathbf{x}_i e, por isso, corresponde ao valor do índice de projeção desse ponto sobre a curva.




Figura 4.2: Projeção dos dados na CP.

De acordo com [81], a CP é autoconsistente, ou seja, os pontos que a compõem constituem a média dos dados que nela se projetam, conforme Equação (4.3).

$$\mathbf{f}(t) = \mathbf{E}[\mathbf{x}|t_f(\mathbf{x}) = t], \quad \forall t \quad (4.3)$$

A Figure 4.3 ilustra um ponto $f(t_i)$ autoconsistente de uma CP para dados em duas dimensões.




Figura 4.3: Ponto autoconsistente de uma CP.

As CP podem ser aplicadas em três diferentes abordagens: (i) como técnica de análise de dados; (ii) como técnica de extração de parâmetros e; (iii) como técnica

de detecção e classificação de eventos. Na presente tese, estas três abordagens serão aplicadas aos distúrbios elétricos.

A motivação para a utilização das CP está na sua boa capacidade de extrair modelos compactos dos dados [92] e baixa complexidade computacional na fase de operação. Assim, pode-se representar distúrbios por CP e utilizá-las para detectar e classificar cada tipo de distúrbio.

4.1.1 Algoritmo k-segmentos

Este algoritmo extrai as curvas principais de forma incremental e se destaca, em relação aos demais, por apresentar uma maior robustez na estimação das curvas, menos susceptibilidade a mínimos locais e convergência prática garantida [93]. A extração das CP utilizando este algoritmo é efetuada, basicamente, em três passos, descritos a seguir.

Passo 0: Inserção do primeiro segmento. Na inserção do primeiro segmento, todos os eventos do conjunto de projeto são considerados. Assim, define-se um centro correspondente ao valor médio dos dados e, a partir deste centro, obtém-se o primeiro segmento, na direção do primeiro componente principal e com comprimento de $3/2$ do desvio padrão associado a este componente.

Passo 1: Inserção do segundo segmento. No segundo segmento, define-se um novo ponto a ser tomado como centro e, utilizando o algoritmo k-vizinhos mais próximos (k-means) [16], define-se quais eventos pertencerão ao novo agrupamento. Este novo agrupamento é baseado nas regiões de Voronoi, que são compostas por eventos que estão mais próximos de um outro evento (centro da região) do que de um dos segmentos que compõe a curva. Em seguida, o primeiro segmento é recalculado, uma vez que o conjunto de eventos que o define, ou seja, seu agrupamento foi alterado. Os dois segmentos obtidos são unidos por uma linha reta (não-suave). Para os próximos segmentos, os mesmos procedimentos são realizados.

Passo 2: Convergência. Verifica-se se o algoritmo atingiu o número máximo de segmentos definido pelo usuário ou se houve a convergência. A convergência

acontece quando o maior agrupamento possível tem menos de três segmentos. Caso não ocorra nenhuma das duas hipóteses, volta-se ao Passo 1.

Este processo de extração das CP pelo algoritmo k-segmentos não-suave é ilustrado na Figura 4.4, onde k representa o número de segmentos já obtidos e k_max o número máximo de segmentos que se deseja obter.

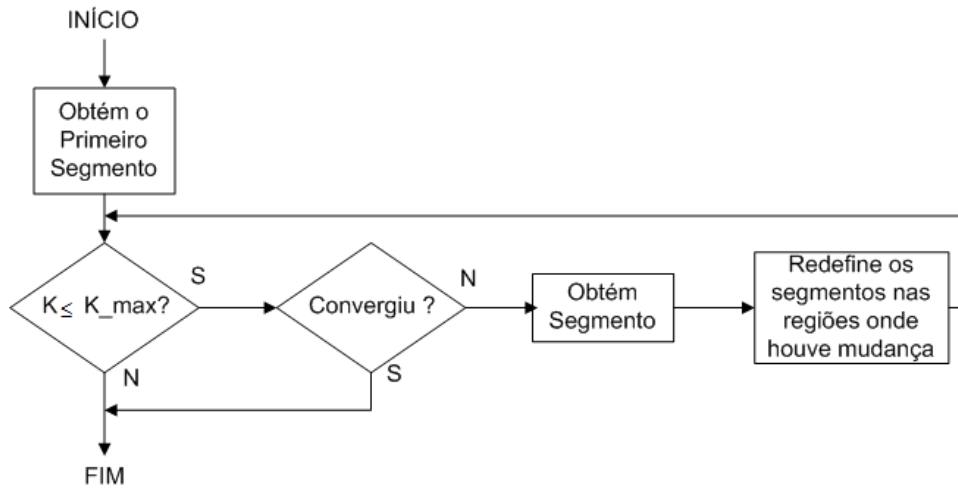


Figura 4.4: Fluxograma simplificado do algoritmo k-segmentos não-suave.

Ao final da extração, o algoritmo sugere uma determinada quantidade de segmentos para a curva principal. Esta sugestão baseia-se na variação do comprimento total da curva após a inserção de um segmento. O comprimento total é obtido através da medição do comprimento de todos os segmentos inseridos mais o comprimento da ligação entre eles. Como o algoritmo seleciona as regiões de Voronoi em ordem decrescente, a cada iteração o segmento inserido é menor que o anterior. Assim, haverá um momento em que o segmento inserido não representa uma grande modificação na curva como um todo. Dessa forma, o método de extração sugere uma quantidade de segmentos que resulte em uma curva que não esteja super treinada.

O algoritmo k-vizinhos mais próximos, empregado na construção da curva principal, possibilita o agrupamento dos dados em regiões de Voronoi, sendo que, a cada passo do algoritmo k-segmentos não-suave, um novo segmento é inserido na maior das regiões obtidas. Aparentemente, este procedimento não parece produzir curvas que, de alguma forma, incorporam o conceito de auto-consistência definido em [81]. No entanto, dois aspectos fazem da curva obtida pelo algoritmo k-segmentos não-suave uma curva principal, que são [94]:

- Os segmentos com direção da primeira componente principal são autoconsistentes;
- Se a região é uma região de Voronoi, então os k pontos pertencentes a ela são autoconsistentes.

4.2 Análise e Representação de Distúrbios

Nesta seção, a curva principal de cada classe de distúrbio abordado é extraída de forma a representá-los em um espaço unidimensional e estudar a complexidade das diferentes classes de distúrbios e do processo de detecção e classificação dos mesmos. Para tal, cada janela, contendo N amostras do sinal de tensão monitorado, passa a ser representada por um ponto no espaço de parâmetros das curvas, de N coordenadas. O número de segmentos e o comprimento de cada curva pode dar informações sobre a complexidade das estruturas dos dados e da sua distribuição no espaço de coordenadas. Curvas mais longas podem indicar a presença de classes compostas por eventos que produzem informação bastante diversificada, fazendo com que seus dados formem agrupamentos distantes uns dos outros. Por outro lado, curvas mais curtas podem indicar que os dados pertencem a uma classe mais homogênea, compostas por um ou mais agrupamentos relativamente próximos. A distância entre as curvas representativas de cada classe de distúrbios pode dar uma importante informação sobre a complexidade do processo de classificação, mostrando a proximidade entre as classes no espaço de parâmetros considerado.

Para a extração das curvas utilizou-se o algoritmo k-segmentos não-suave [93], descrito na seção anterior.

Na presente análise, as classes de sinais consideradas foram:

S1: Sinais sem distúrbios;

S2: Harmônicos

S3: Afundamentos de tensão;

S4: Elevações de tensão;

S5: Transitórios Oscilatórios;

S6: Flutuações de tensão (*Flickers*);

S7: *Notches*;

S8: Impulsos;

S9: Interrupções de tensão;

As curvas principais foram então extraídas dos sinais $e[n]$, obtido pelo pré-processamento descrito na Seção 3.3, considerando-se janelas com 1.024 amostras (4 ciclos do componente fundamental) e o conjunto de projeto (250 eventos) de cada classe (S1-S9). Os sinais foram gerados conforme descrito no Capítulo 3.

A Tabela 4.1 mostra o número máximo de segmentos (k_max) das curvas de cada classe de sinal e o comprimento destas em unidades arbitrárias (u.a.). O número de segmentos fornece informações sobre a complexidade geométrica dos dados, e o comprimento fornece informações sobre a diversidade dos dados no espaço de parâmetros. Logo, pode-se inferir que as classes de harmônicos e *notches* produzem informações mais diversificadas no espaço de parâmetros, dado que o comprimento de suas curvas são maiores do que o das outras classes. Por outro lado, curvas menores indicam classes homogêneas, tais como os sinais sem distúrbios, afundamentos, elevações e flutuações de tensão. As classes de transitórios oscilatórios, *notches* e impulsos apresentam-se mais dispersas no espaço de parâmetros, geometricamente, pois suas curvas representativas possuem mais de 40 segmentos.

Tabela 4.1: Número de segmentos e comprimento (u.a.) das curvas principais.

Classes	Numero de Segmentos	Comprimento (u.a.)
S1	1	$4,19 \times 10^{-9}$
S2	23	2,028
S3	29	26,85
S4	34	9,66
S5	41	433,96
S6	33	2,11
S7	43	1.023
S8	47	519,98
S9	35	206,39

Outra informação importante na análise de distúrbios em QEE, que pode ser extraída via curvas principais, é a distância entre as curvas representativas de

cada classe de sinal. Esta informação pode quantificar a complexidade do projeto de sistemas de detecção ou classificação, uma vez que distâncias maiores indicam classes bem separadas no espaço de parâmetros. Estas distâncias podem ser obtidas por:

$$d_{min}(A, B) = \inf_{a \in A} \{ \inf_{b \in B} \{ d(a, b) \} \}, \quad (4.4)$$

em quem a e b são pontos das curvas A e B , respectivamente, e $d(a, b)$ é a distância entre os pontos a e b . A métrica utilizada aqui foi o quadrado da distância Euclidiana.

A Tabela 4.2 mostra as distâncias entre as curvas representativas de cada classe de sinal no espaço de parâmetros. É importante observar que os eventos sem distúrbios, afundamentos, elevações e flutuações de tensão possuem distâncias entre suas curvas menores, indicando que estão próximos no espaço de parâmetros e, possivelmente, com alguma interseção. Este fato já era esperado, uma vez que as características destes distúrbios aparecem no componente fundamental que foi removido pelo filtro *notch* e, portanto, a energia, referente ao distúrbio, resultante no sinal $e[n]$ é pouco significativa. Já os harmônicos e interrupções de tensão obtiveram distâncias maiores entre si e das demais classes consideradas, o que indica que, no espaço de parâmetros considerado, estes distúrbios são os mais fáceis de serem distinguidos dos demais, principalmente se o método de classificação adotado for baseado na medida de distância do evento às curvas representativas de cada classe de distúrbio. Este método de classificação será abordado no Capítulo 6.

Do ponto de vista de detecção, a Tabela 4.2 mostra que os distúrbios de transitórios oscilatórios (S5) e *flickers* (S6) possuem curvas mais próximas da curva dos sinais sem distúrbios, em comparação com as outras classes. Sendo assim, um sistema de detecção baseado nas distâncias entre as curvas pode ter dificuldade maior em detectar estas classes. Neste ponto, dois comentários relacionados ao comprimento ($N = 1.024$ amostras) da janela de aquisição utilizada são importantes: (i) os distúrbios da classe S5 são de curta duração e, portanto, janelas longas, representadas no espaço das curvas, podem não dar destaque ao transitório; (ii) as flutuações do sinal de tensão que caracterizam a classe S6 podem não ser destacadas suficientemente no sinal $e[n]$ com apenas 1.024 amostras. Logo, as curvas representativas para

estas classes podem ter muita similaridade com a da classe de sinais sem distúrbios.

Tabela 4.2: Distâncias entre as curvas principais em u.a..

Classes	S1	S2	S3	S4	S5	S6	S7	S8	S9
S1	0	3,20	0,06	0,02	$2,08 \times 10^{-9}$	$4,57 \times 10^{-4}$	0,56	0,16	2,96
S2		0	3,24	3,21	3,20	3,19	3,71	2,49	5,78
S3			0	0,04	0,06	0,06	0,61	0,21	2,97
S4				0	0,02	0,01	0,57	0,17	1,60
S5					0	$4,56 \times 10^{-4}$	0,56	0,15	2,96
S6						0	0,56	0,16	2,63
S7							0	0,71	3,51
S8								0	3,07
S9									0

De fato, a disposição das curvas, assim como seu comprimento e número de segmentos, no espaço de coordenadas é dependente dos parâmetros utilizados para extraí-las. A aplicação de pré-processamentos mais elaborados para extrair parâmetros mais representativos dos distúrbios, pode melhorar a capacidade de discriminação dos parâmetros e, conseqüentemente, levar à obtenção de curvas mais compactas, reduzindo a interseção entre as diferentes classes com o aumento da distância entre suas curvas. Esta análise será abordada no Capítulo 6.

4.3 Extração de Parâmetros via Curvas Principais

A técnica de curvas principais tem como principal vantagem a boa capacidade de extração de características (parâmetros). Na seção anterior, as características extraídas foram as medidas de distâncias entre as curvas de cada classe de sinal, o número de segmentos e o comprimento de cada curva. Tais características são úteis na análise dos dados. Contudo, além destes, outros parâmetros podem ser extraídos e utilizados para representar os distúrbios em um espaço dimensional reduzido, de forma a maximizar a separabilidade entre as classes de distúrbios. Estes parâmetros podem, portanto, alimentar detectores e classificadores, conforme será mostrado nos próximos capítulos.

Neste contexto, três diferentes tipos de parâmetros podem ser extraídos uti-

lizando as curvas:

1. As distâncias do evento aos segmentos da curva;
2. O índice de projeção do evento à curva;
3. O próprio evento projetado na curva;

A primeira alternativa apresenta-se mais atraente, já que, com o algoritmo k -segmentos não suave, pode-se controlar o número de segmentos na extração das curvas e, conseqüentemente, o número de parâmetros extraídos. Por exemplo, uma curva principal com 3 segmentos permitiria extrair 3 parâmetros, que seriam as distâncias do evento a cada segmento da curva, independente da dimensão do evento. Assim, um evento de dimensão N passa a ser representado por apenas três parâmetros. Esta metodologia facilita a redução de complexidade, porém, a definição da quantidade de parâmetros necessários é bastante dependente do problema em questão.

Para ilustrar este espaço de parâmetros, a curva principal com apenas 3 segmentos foi extraída, a partir dos sinais $e[n]$, para as classes de harmônicos e *notches*. A visualização das curvas principais, neste caso, não é possível, uma vez que estão em um espaço de 1.024 coordenadas. As distâncias dos eventos de sinais sem distúrbios (S1) aos 3 segmentos das curvas de harmônicos e *notches* foram medidas, gerando os espaços de parâmetros mostrados na Figura 4.5. Assim, $d_{ij}^{(1)}$, $d_{ij}^{(2)}$ e $d_{ij}^{(3)}$, para $i = 1, 2, \dots, 250$, representam, respectivamente, as distâncias do evento i ao primeiro, segundo e terceiro segmento da curva principal representativa da classe j . Os espaços de parâmetros gerados mostram que não há interseção entre os distúrbios de harmônicos e *notches*, e os sinais sem distúrbios. Estes parâmetros, portanto, podem alimentar técnicas que realizam a detecção. No próximo capítulo, estes parâmetros serão apresentados a uma rede neural artificial para fins de detecção.

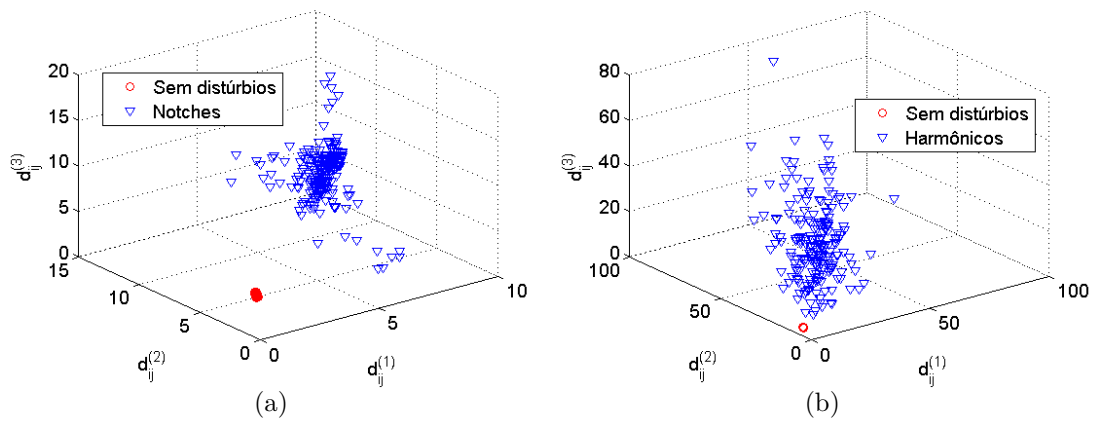


Figura 4.5: Espaço de parâmetros entre sinais sem distúrbios e harmônicos e *notches*.

Capítulo 5

Detecção de Distúrbios Elétricos

Neste capítulo, dois sistemas de detecção de distúrbios elétricos são propostos. Ambos os sistemas utilizam como técnica de classificação a rede neural artificial, porém, com diferentes metodologias de extração de parâmetros. Um sistema utiliza a técnica de curvas principais, que foi introduzida no Capítulo 4, e o outro sistema utiliza como parâmetros o valor rms, o máximo e o mínimo absoluto do sinal.

5.1 Detecção de Distúrbios

Uma das principais atribuições do monitoramento da qualidade de energia elétrica é a análise dos distúrbios elétricos. Para tal, os sinais de tensão do sistema monitorado devem ser primeiramente armazenados. No entanto, o armazenamento destes gera arquivos de dados de grande extensão. Portanto, torna-se importante utilizar sistemas de detecção para armazenar apenas os sinais elétricos com distúrbios e, posteriormente, analisá-los realizando a classificação, identificação e localização das fontes geradoras dos mesmos. Esta análise é, contudo, realizada de forma *off-line*, baseando-se nos sinais armazenados. De qualquer forma, a detecção deve ser realizada em tempo real, o que demanda sistemas com rápido processamento de sinais e bom desempenho.

A detecção de distúrbios, em geral, compreende basicamente a extração de parâmetros e a aplicação de um algoritmo que realize a detecção baseada nos parâmetros extraídos. A extração de parâmetros consiste em uma transformação dos dados para um novo espaço onde as características dos distúrbios são destacadas

em relação aos sinais sem distúrbios. Estas características são então selecionadas e apresentadas à técnica de detecção. Assim, o compromisso em projetar um detector com alto desempenho e rápido processamento está na escolha das técnicas de extração de parâmetros e de detecção. Neste capítulo, a extração de parâmetros será abordada de duas formas: utilizando-se curvas principais e utilizando-se parâmetros mais simples, tais como o valor rms e valores de pico.

O esquema geral do sistema de detecção proposto é ilustrado pelo diagrama em blocos da Figura 5.1, em que, assim como nas análises de distúrbios discutidas nos capítulos anteriores, o sinal a ser processado pelo detector será o sinal resultante $\{e[n]\}$ da filtragem do componente fundamental via filtro *Notch* (ver Capítulo 3).




Figura 5.1: Sistema geral de detecção.

No primeiro bloco da Figura 5.1, o sinal $e[n]$ é segmentado em janelas $\{s_i[n]\}$ com N amostras cada, onde $n = 1, 2, \dots, N$, e i representa cada janela. O bloco Extração de Parâmetros utiliza as curvas principais para extrair parâmetros relevantes à detecção dos distúrbios, conforme sugerido no Capítulo 4, Seção 4.3.

Considerando o vector $\mathbf{s} = [s_i[n] \cdots s_i[n - N - 1]]^T$, o problema de detecção pode ser formulado pelas hipóteses:

$$\begin{aligned} \mathcal{H}_0 : \mathbf{s} &= \mathbf{r}_s \\ \mathcal{H}_1 : \mathbf{s} &= \mathbf{i} + \mathbf{t} + \mathbf{h} + \mathbf{r}_s \end{aligned} \quad (5.1)$$

em que $\mathbf{i} = [i[n] \cdots i[n - N - 1]]^T$, $\mathbf{t} = [t[n] \cdots t[n - N - 1]]^T$, $\mathbf{h} = [h[n] \cdots h[n - N - 1]]^T$, $\mathbf{r}_e + \mathbf{r}_f = \mathbf{r} = [r[n] \cdots r[n - N - 1]]^T$. A hipótese \mathcal{H}_0 está associada à operação nominal do sistema elétrico e a hipótese \mathcal{H}_1 está associada com as condições anormais do sistema elétrico, isto é, à presença de distúrbios elétricos.

5.2 Sistema de Detecção Baseado Em Curvas Principais

Para o projeto do sistema, as curvas principais de cada classe de distúrbios considerada são extraídas a partir de $s_i[n]$, com três segmentos cada. Conforme mostrado no Capítulo 4, com curvas com apenas três segmentos obtém-se representações compactas das classes de distúrbios e um espaço de parâmetros, baseado nas distâncias do evento aos segmentos da curva, com boa separabilidade entre classes. Assim, os parâmetros extraídos pelo bloco Extração de Parâmetros da Figura 5.1 serão as distâncias do sinal $s_i[n]$ a cada um dos segmentos da curva de cada classe de distúrbio. Logo, cada janela de sinal processado $\{s_i[n]\}$, passa a ser representada pelo vetor de parâmetros $\mathbf{p}_{ij} = [d_{ij}^{(1)} \ d_{ij}^{(2)} \ d_{ij}^{(3)}]$, onde $d_{ij}^{(1)}$, $d_{ij}^{(2)}$ e $d_{ij}^{(3)}$ são as distâncias do evento i aos segmentos 1, 2 e 3 da curva principal j . Neste caso, $j = 1, 2, \dots, M$, representa as M classes de distúrbios consideradas.

Ilustrativamente, a Figura 5.2 (a) mostra o espaço de parâmetros representado pelas distâncias dos distúrbios de interrupções de tensão e eventos sem distúrbios aos segmentos da curva principal representativa da classe de interrupções de tensão. A Figura 5.2 (b) mostra o espaço de parâmetros representado pelas distâncias dos distúrbios transitórios oscilatórios e eventos sem distúrbios aos segmentos da curva principal representativa da classe transitórios oscilatórios. Ambos os espaços de parâmetros foram obtidos para eventos considerando-se $N = 256$ amostras.




Figura 5.2: Espaço de parâmetros para interrupções de tensão em (a) e para para transitórios oscilatórios em (b) para $N = 256$ amostras.

Nesta etapa é interessante destacar a importância da extração de parâmetros utilizando curvas principais, uma vez que, conforme mostra a Figura 5.2, com apenas três parâmetros é possível obter uma boa separabilidade entre os distúrbios de interrupções de tensão e transitórios oscilatórios e os eventos sem distúrbios. É importante também notar que a classe sem distúrbios compõe uma classe bastante homogênea, o que facilita sua classificação.

Por outro lado, quando a extração de parâmetros acontece para sinais com o número de amostras inferior a 256, como, por exemplo, em um caso mais crítico, com 16 amostras (equivalente a 1/16 de um ciclo do sinal de tensão monitorado, para os dados utilizados neste trabalho), a separação entre classes não é trivial, conforme ilustra a Figura 5.3 (a). Nestes casos, a utilização de uma ferramenta não linear, tal como uma RNA, conforme é proposto neste trabalho, torna-se necessária.

Existem algumas classes, como é o caso da classe de transitórios oscilatórios, em que, mesmo extraindo parâmetros de uma janela reduzida (16 amostras) do sinal $s_i[n]$, é possível obter um bom espaço de parâmetros, do ponto de vista de separação entre classes, conforme ilustra a Figura 5.3 (b). Isto se deve à boa capacidade de caracterização das curvas principais.

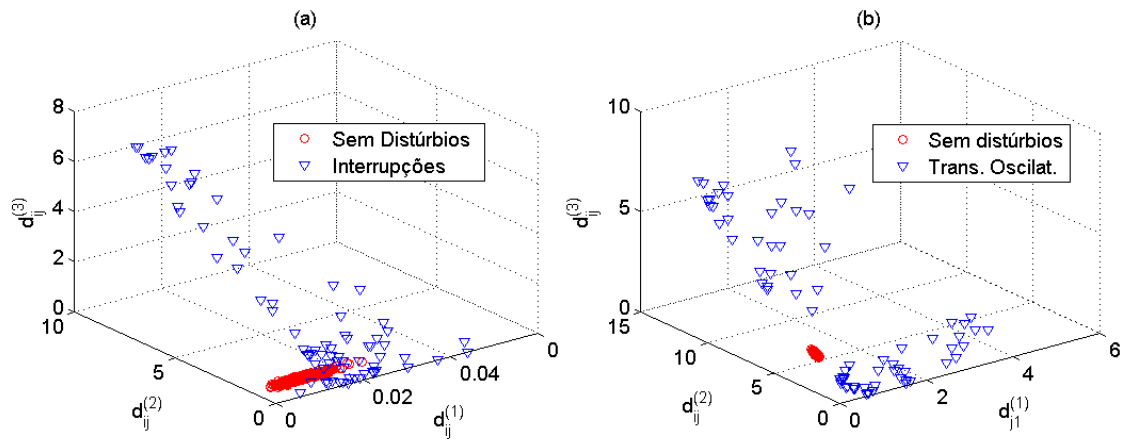


Figura 5.3: Espaço de parâmetros para interrupções de tensão em (a) e para para transitórios oscilatórios em (b) para $N = 16$ amostras.

Baseada nestes parâmetros, uma rede neural artificial (RNA) especialista [82] foi treinada para cada classe de distúrbios, com o objetivo de separar o distúrbio específico da classe sem distúrbio.

O diagrama em blocos da etapa de detecção é mostrado na Figura 5.4.

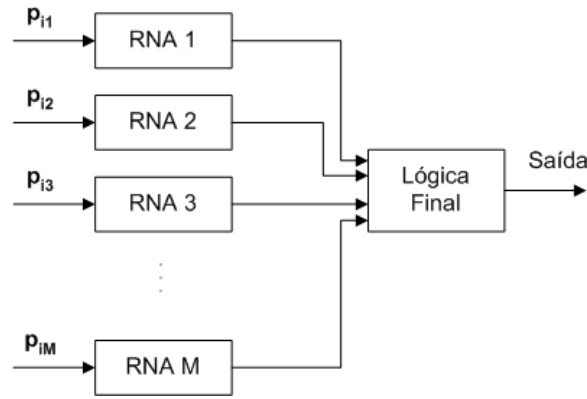


Figura 5.4: Diagrama em blocos da etapa de detecção em detalhes.

Dessa forma, o detector será composto por M RNA especialistas, onde M é o número de distúrbios abordados. Cada RNA possui três nós de entrada, que são referentes aos parâmetros $d_{ij}^{(1)}$, $d_{ij}^{(2)}$ e $d_{ij}^{(3)}$, uma camada escondida contendo quatro neurônios nas redes especialistas em afundamentos e elevações de tensão e três neurônios nas demais redes. A camada de saída contém apenas um neurônio. O número de neurônios na camada intermediária foi escolhido de acordo com o maior desempenho obtido para o conjunto de sinais de validação.

Esta metodologia de detecção usando RNA especialistas é bastante interessante por dois motivos: (i) é fácil acrescentar novas classes de distúrbios a serem abordadas sem que haja a necessidade de reprojeter todo o sistema e; (ii) pode auxiliar a classificação e/ou gerar parâmetros para alimentar sistemas de classificação, conforme será discutido no próximo capítulo.

Cumprе ressaltar, que o espaço de parâmetros para as classes de afundamentos e elevações de tensão apresentaram maior interseção com a classe de eventos sem distúrbios, conforme mostra a Figura 5.5, dificultando o processo de classificação e, portanto, um número maior de neurônios na camada intermediária da RNA foi necessário neste caso. A função de ativação utilizada em todas as RNA foi a tangente sigmóide e o algoritmo RPROP [95] (vide Anexo A) foi usado para treinar cada RNA. O critério de parada adotado para o treinamento da rede foi o do menor erro aliado ao melhor desempenho do conjunto de validação.

Uma regra de decisão será aplicada às saídas das redes neurais especializadas para decidir pela presença ou não de distúrbio elétrico no segmento de sinal processado.

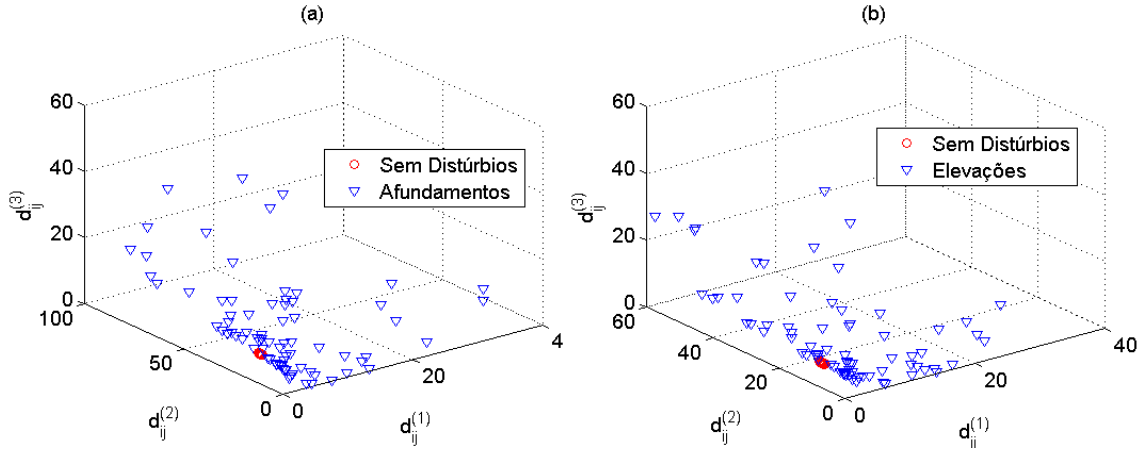


Figura 5.5: Espaço de parâmetros para as classes de afundamento (a) e elevação (b) de tensão para $N = 256$ amostras.

Cada RNA foi treinada para separar entre um tipo de distúrbio e o sinal sem distúrbio. Logo, a lógica final foi implementada de forma a apontar para sinal pertencente à classe sem distúrbio apenas quando todas as RNA o fizerem. Caso contrário, o evento será assinado como distúrbio. Esta lógica, contudo, é favorecida pelo fato de que a classe de sinais sem distúrbio é bastante homogênea, o que facilita sua classificação.

O projeto do sistema consistiu em obter as curvas principais de cada classe, extrair o vetor de parâmetros, treinar e validar as RNA especialistas, e definir a lógica final. É importante ressaltar que a extração das curvas principais acontece apenas na fase de projeto do sistema. A operação do sistema consiste em, a cada evento, medir as distâncias do mesmo aos segmentos das curvas e, em seguida, apresentar estas distâncias às RNA.

A utilização de curvas principais com poucos segmentos torna-se vantajoso, do ponto de vista de complexidade de processamento e de memória requerida do processador para o armazenamento das curvas.

5.2.1 Resultados e Discussões

O sistema proposto foi testado utilizando-se dados simulados e experimentais, seguindo a metodologia apresentada no Capítulo 3. Um detector de energia foi também projetado e comparado ao sistema proposto. A definição do limiar no detector de energia foi baseada na inspeção das probabilidades de detecção (PD)

e de falso alarme (PF). A Figura 5.6 mostra as probabilidades normalizadas de detecção e de falso alarme em função do limiar de detecção, para $N = 256$ amostras e $N = 16$ amostras, respectivamente, em (a) e (b), obtidas para o conjunto de sinais de treinamento. Os limiares foram escolhidos para PF de detecção dos distúrbios nula. Observe que para $N = 16$ amostras, a PF nula implica em redução da PD.




Figura 5.6: Probabilidades de Detecção (PD) e de falso alarme (PF) em função do limiar de detecção.

Resultados Para Dados Simulados

A Tabela 5.1 mostra os resultados de desempenho obtidos para os dados de teste, considerando-se o número de amostras (N) utilizadas na segmentação do sinal. O desempenho mostrado é referente à eficiência global do método, obtida pela média aritmética entre os desempenhos das classes de distúrbios e sem distúrbios. Os resultados mostram que o método proposto apresentou melhor desempenho que o detector de energia, com 100 % de acerto para a classe sem distúrbios (falso alarme nulo) e reduzido percentual de erro para os casos de 32 e 16 amostras. Estes erros aconteceram para os distúrbios de afundamentos e elevações de tensão com menor intensidade. Os afundamentos e elevações de tensão, quando não são muito intensos, são eliminados no componente fundamental removido pelo filtro notch. A detecção destes distúrbios através do sinal $e[n]$, acontece devido ao transitório causado pelo filtro notch quando há o aparecimento destes. No entanto, uma possível solução, que poderia melhorar o resultado de detecção para estas classes, seria utilizar também as informações do componente fundamental. Tal solução aparece como proposta para

trabalhos futuros.

Tabela 5.1: Eficiência global em % para os dados simulados.

Comprimento da janela de aquisição	Sistema Proposto	Detector de Energia
$N = 256$	100	100
$N = 128$	100	96
$N = 64$	100	81
$N = 32$	99	63
$N = 16$	99	54

Resultados Para Dados Experimentais

A Tabela 5.2 mostra os resultados referentes aos dados experimentais. Observa-se que o método proposto detectou corretamente todos os distúrbios para os cinco casos.

Tabela 5.2: Eficiência global em % para os dados reais.

Comprimento da janela de aquisição	Sistema Proposto	Detector de Energia
$N = 256$	100	81
$N = 128$	100	74
$N = 64$	100	68
$N = 32$	100	51
$N = 16$	100	40

Estes resultados mostram que em sistemas reais, técnicas mais elaboradas e com características não-lineares podem alcançar melhor capacidade de generalização, já que o sistema foi projetado utilizando apenas dados simulados e obteve um desempenho melhor em dados reais. Ademais, o banco de dados experimentais é bastante heterogêneo, composto por diversos distúrbios que acontecem em sequência e/ou simultaneamente (múltiplos distúrbios), conforme mostra a Figura 5.7, onde se pode observar a ocorrência de uma interrupção de tensão seguida de elevação, harmônicos e curtos transitórios, em (a). Em (b) observa-se o aparecimento de harmônicos, impulsos e, possivelmente, algum outro distúrbio difícil de ser identificado.




Figura 5.7: Exemplos de sinais de tensão de dados reais com distúrbios obtidos no site do grupo de trabalho IEEE (*working group P1159.3*).

5.3 Sistema de Detecção Baseado no Valor RMS

O sistema de detecção proposto nesta seção possui a mesma estrutura geral mostrada na Figura 5.1, porém faz a extração de parâmetros calculando o valor RMS do sinal $s_i[n]$ conforme mostra a Equação 7.5.

$$s_{iRMS} = \sqrt{\frac{1}{N} \sum_{n=1}^N s_i^2[n]} \quad (5.2)$$

Em adição, ambos os valores máximos absolutos positivo (p_{i1}) e negativo (p_{i2}) de $s_i[n]$ são também utilizados e, portanto, o vetor de parâmetros extraído será composto por três valores: $\mathbf{p}_i = [s_{iRMS} \ p_{i1} \ p_{i2}]$.

A utilização do valor RMS como parâmetro na detecção de distúrbios foi, inicialmente, realizada em [31], onde utilizou-se o valor RMS amostra por amostra considerando-se janelas de meio ciclo do sinal de tensão.

A inovação da extração de parâmetros realizada no sistema aqui proposto está na utilização dos valores máximos absolutos positivos e negativos da janela de sinal processada e na filtragem do componente fundamental pelo filtro notch. Ademais, esta extração de parâmetros é bastante simples e leva a uma boa separação entre classes, como mostra a Figura 5.8 para as classes de transitórios oscilatórios e interrupções contra a classe de eventos sem distúrbios.

Por outro lado, a extração de parâmetros de uma janela de sinal ($s_i[n]$) com um número reduzido de amostras pode levar à interseção entre as classes de




Figura 5.8: Espaço de parâmetros para interrupções de tensão (a) e para para transitórios oscilatórios (b) para $N = 256$ amostras.

distúrbios e eventos sem distúrbios, conforme ilustra a Figura 5.9 para algumas classes.

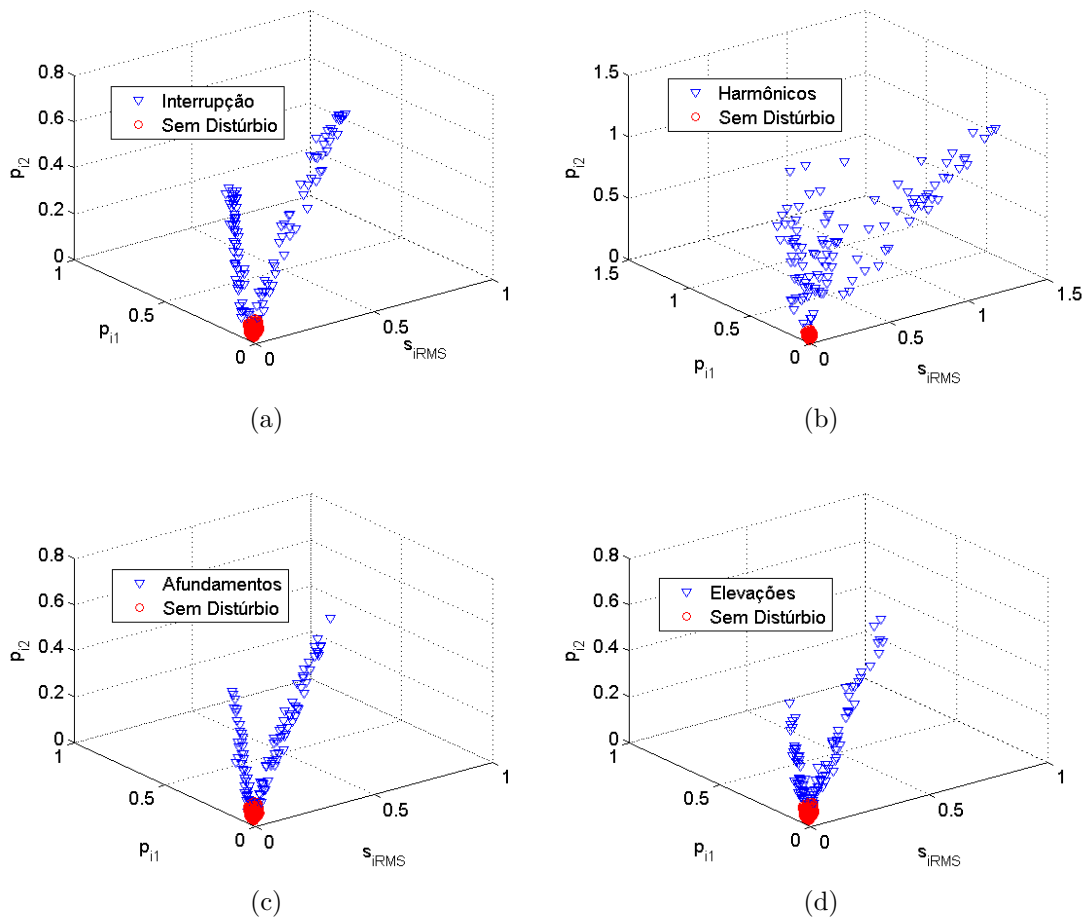


Figura 5.9: Espaço de parâmetros para as classes de interrupções (a), harmônicos (b), afundamentos (c) e elevações de tensão (d), para $N = 16$.

Após a extração de parâmetros, o vetor \mathbf{p}_i é, então, apresentado a uma RNA que realiza a detecção. A vantagem deste método ao método anteriormente proposto, baseado em curvas principais, é que, neste caso, apenas um vetor de parâmetros é extraído e, conseqüentemente, utiliza-se apenas uma RNA, que é treinada para distinguir duas classes: eventos com distúrbios e sem distúrbios.

A rede neural foi treinada utilizando o algoritmo RPROP [95] e é composta, basicamente, por três nós de entrada, três neurônios na camada intermediária e um neurônio de saída. A função de ativação utilizada foi a tangente sigmóide. O número de neurônios na camada intermediária foi definido pelo menor erro durante o treinamento e o critério de parada no treinamento foi o do menor erro aliado ao melhor desempenho para o conjunto de validação.

5.3.1 Resultados e Discussões

O sistema proposto foi testado utilizando-se dados simulados e experimentais. Os resultados foram comparados com os do detector baseado em curvas principais e o detector de energia, descritos na seção anterior. O mesmo banco de dados, utilizado na seção anterior foi aqui utilizado para a obtenção dos resultados.

Resultados Para Dados Simulados

A Tabela 5.3 mostra os resultados de desempenho obtidos para os dados de teste, considerando-se o número de amostras (N) utilizado na segmentação do sinal. O desempenho mostrado é referente à eficiência global do método, obtida pela média aritmética entre os desempenhos das classes de distúrbios e sem distúrbios. Os resultados mostram que o método proposto apresentou melhor desempenho que o detector de energia, com 100 % de acerto para a classe sem distúrbios (falso alarme nulo) e reduzido percentual de erro para os casos de 64, 32 e 16 amostras. Estes resultados foram compatíveis com o método baseado em curvas principais.

Resultados Para Dados Experimentais

A Tabela 5.4 mostra os resultados referentes aos dados experimentais, organizados conforme a Seção 7.3.2. Observa-se que o método proposto detectou corretamente todos os distúrbios para dois dos cinco casos. Comparando com os outros

Tabela 5.3: Eficiência global em % para os dados simulados.

Comprimento da janela de aquisição	Sistema Proposto (RMS)	Curvas Principais	Detector de Energia
$N = 256$	100	100	100
$N = 128$	100	100	96
$N = 64$	99	100	81
$N = 32$	99	99	63
$N = 16$	98	99	54

dois métodos, o método proposto foi superior ao detector de energia e levemente inferior ao detector baseado em curvas principais. Este fato já era esperado, devido à boa capacidade de representação de dados das curvas principais, o que permite ao sistema, maior capacidade de generalização dos sinais.

Tabela 5.4: Eficiência global em % para os dados reais.

Comprimento da janela de aquisição	Sistema Proposto (RMS)	Curvas Principais	Detector de Energia
$N = 256$	98	100	81
$N = 128$	99	100	73
$N = 64$	100	100	67
$N = 32$	98	100	51
$N = 16$	100	100	40

5.4 Estudo de Complexidade Computacional

Conforme discutido em [42], uma forma de medir a complexidade computacional de um método com vistas a futuras implementações em DSP (*Digital Signal Processor*) é obter o número de operações matemáticas (multiplicações e adições) e tangentes hiperbólicas realizadas pelo algoritmo proposto na fase de operação. É importante ressaltar que as tangente hiperbólicas podem ser obtidas, na implementação em *hardware*, por meio de tabela aproximada.

As Tabelas 5.5 e 5.6 mostram, respectivamente, a complexidade computacional dos métodos de detecção apresentados nas seções anteriores, em termos das operações matemáticas necessárias para processar uma janela do sinal com 256 e 16 amostras. O número de adições e multiplicações foi calculado conforme mostrado

no Anexo B.

Tabela 5.5: Complexidade computacional dos métodos para $N = 256$.

Operações Matemáticas	Sistema baseado no valor RMS	Sistema baseado em Curvas Principais	Detector de Energia
Adições	1.285	21.567	255
Multiplicações	1.043	10.836	256
$\tan(\cdot)$	4	30	0

Tabela 5.6: Complexidade computacional dos métodos para $N = 16$.

Operações Matemáticas	Sistema baseado no valor RMS	Sistema baseado em Curvas Principais	Detector de Energia
Adições	105	1.407	15
Multiplicações	98	756	16
$\tan(\cdot)$	4	30	0

Os resultados mostram que o detector de energia requer menor complexidade computacional. O método baseado no valor RMS possui menor complexidade computacional do que o método baseado em curvas principais. No entanto, para reduzidas amostras ($N = 16$), ambos os sistemas propostos exigem um reduzido número de operações. Portanto, considerando-se o desempenho dos métodos propostos, e que 16 amostras equivale a 1/16 de um ciclo do sinal de tensão monitorado, estes resultados são bastante atrativos para implementações em tempo real.

Capítulo 6

Classificação de Distúrbios Elétricos Isolados

Neste capítulo, sistemas de classificação de distúrbios isolados são propostos, em que as técnicas de curvas principais e estatísticas de ordem superior são aplicadas com bastante sucesso. Análises de desempenho e complexidade computacional dos sistemas são discutidas e apresentadas em forma de resultados.

6.1 Classificação de Distúrbios: Generalidades

A classificação de distúrbios elétricos consiste em uma importante etapa num processo de monitoramento da QEE, uma vez que pode contribuir diretamente na identificação das causas dos distúrbios, assim como na localização dos mesmos. A etapa de classificação, em geral, caracteriza-se como uma etapa posterior à detecção e pode ser, neste caso, realizada *off-line*, com dados previamente armazenados, ou em tempo real.

As análises em tempo real requerem técnicas com reduzida complexidade computacional, o que se resume em rápido processamento dos dados. As análises *off-line* não requerem rápido processamento e, portanto, técnicas com maior complexidade computacional podem ser empregadas. Geralmente, aliar uma técnica com reduzido custo computacional a uma alta eficiência não é uma tarefa fácil. Atualmente, o desenvolvimento de processadores cada vez mais eficientes tem contribuído bastante, viabilizando a aplicação de técnicas mais robustas.

Em geral, a classificação é precedida por uma importante etapa de extração de parâmetros. Os principais objetivos da extração de parâmetros para fins de classificação são:

- (i) Maximizar as fronteiras de separação entre as classes extraindo parâmetros com informações importantes e restritas acerca de cada classe. Estas informações são comumente extraídas utilizando-se transformações, onde, geralmente, são empregadas as transformadas discretas de Fourier, transformadas Wavelet, transformadas S, dentre outras. Outra forma comum de extrair informações importantes é através de estatísticas de segunda ordem, estatísticas de ordem superior, e outros parâmetros mais comuns, tais como o valor RMS do sinal.
- (ii) Reduzir a complexidade computacional diminuindo o número de parâmetros, o que pode ser feito diretamente, pela extração dos parâmetros desejáveis, quando se tem um conhecimento suficiente sobre o problema, ou utilizando-se ferramentas de seleção de parâmetros, tais como o discriminante de Fisher, testes de relevância, dentre outros. A aplicação de técnicas de seleção de parâmetros torna a escolha dos melhores parâmetros automática e menos dependente do conhecimento do problema por parte do projetista.

Conforme discutido no Capítulo 4, no contexto de classificação, as curvas principais podem ser utilizadas tanto como ferramenta extratora de parâmetros como ferramenta de classificação. Neste Capítulo, estas duas abordagens com curvas principais serão discutidas para o desenvolvimento de classificadores de distúrbios elétricos isolados.

Em seguida, um sistema de classificação de distúrbios isolados baseado em estatísticas de ordem superior é também proposto. A motivação para o uso de EOS está no fato de que estas são nulas para dados gaussianos e, portanto, são imunes à presença de ruído Gaussiano [45, 46]. Ademais, as EOS são capazes de fornecer informações representativas do sinal analisado e, conseqüentemente, facilitar o processo de classificação, levando a um espaço de parâmetros bem definido.

6.2 Classificação Baseada em Parâmetros Extraídos Por Curvas Principais

Conforme mencionado no Capítulo 5, Seção 5.2, o detector proposto, baseado em curvas principais e redes neurais (vide Figura 5.4), pode auxiliar na classificação dos distúrbios, uma vez que são utilizadas redes neurais especialistas para cada classe de distúrbios. A ideia é utilizar as informações das redes especialistas em conjunto, alimentando uma nova rede neural que fará a classificação dos distúrbios.

A Figura 6.1 ilustra a arquitetura das redes neurais utilizadas na detecção de distúrbios, conforme proposto no Capítulo 5. Observe que a rede é alimentada pelo vetor \mathbf{p}_{ij} , referente à distância do evento i aos segmentos da curva principal j , e que a respectiva saída da camada intermediária (oculta) está representada pelos parâmetros z_1 , z_2 e z_3 . Conforme bem discutido em [82], a camada intermediária (oculta) de uma rede neural do tipo *perceptron* é responsável por realizar uma ‘transformação’ dos dados para um novo espaço onde a separação entre as classes é máxima. Assim, o sistema de classificação proposto consiste em utilizar a saída da camada oculta da rede de detecção como parâmetros que alimentam uma nova rede neural que fará a classificação. Esta situação é interessante para mostrar a operação do classificador em paralelo com o detector sem que o processamento dos dados seja alterado.




Figura 6.1: Estrutura da rede neural de detecção de distúrbios.

Como foram consideradas sete classes de distúrbios, utilizou-se sete curvas principais ($j = 1, 2, \dots, 7$) e, conseqüentemente, sete redes neurais especialistas para a detecção, o que soma um total de 21 parâmetros referentes às saídas das camadas ocultas, representados pelo parâmetro z_i , em que ($i = 1, 2, \dots, 21$). Então, o método de classificação, aqui proposto, consiste em utilizar estes 21 parâmetros,

obtidos durante o processo de detecção, e alimentar uma nova rede neural, cujo objetivo é classificar os distúrbios.

Para o projeto e teste do sistema de classificação aqui proposto, seguiu-se a metodologia descrita no Capítulo 3.

Conforme já discutido anteriormente, os distúrbios de interrupções, elevações e afundamentos de tensão, quando analisados no sinal $e[n]$, apresentam formas de ondas bastante semelhantes. A análise por curvas, realizada no Capítulo 4, mostrou que as curvas representativas das classes de afundamentos e elevações de tensão encontram-se próximas umas das outras no espaço de parâmetros. Durante o treinamento da rede neural, observou-se uma dificuldade em separar os afundamentos das elevações e interrupções de tensão. Assim, a solução foi agrupar estes distúrbios em uma única classe, de forma que a rede neural classificará apenas cinco classes: Harmônicos, *Notches*, Impulsos, Transitórios oscilatórios, e Interrupções/Afundamentos/Elevações de tensão.

A rede neural de classificação foi então treinada, utilizando o algoritmo RPROP [95], em que os alvos foram os vetores $[1 \ -1 \ -1 \ -1 \ -1]$, $[-1 \ 1 \ -1 \ -1 \ -1]$, $[-1 \ -1 \ 1 \ -1 \ -1]$, $[-1 \ -1 \ -1 \ 1 \ -1]$ e $[-1 \ -1 \ -1 \ -1 \ 1]$, para as classes Harmônicos, *Notches*, Impulsos, Transitórios oscilatórios, e Interrupções/Afundamentos/Elevações de tensão, respectivamente. Assim, a rede é composta por 21 nodos de entrada, 5 neurônios na camada oculta e 5 neurônios de saída. A função de ativação utilizada foi a tangente hiperbólica. O critério de parada adotado foi o do menor erro aliado ao maior desempenho para dados de validação. Dos 500 eventos de cada classe, previamente separados para o projeto do sistema, conforme descrito no Capítulo 3, 250 foram utilizados para a extração das curvas principais e 250 para o treino e validação da rede neural. Dos 250 separados para o projeto da rede neural, 2/3 foi utilizado para o treinamento e 1/3 para a validação.

A separação dos distúrbios agrupados, interrupções, afundamentos e elevações de tensão, será realizada no espaço de parâmetros das estatísticas de ordem superior na Seção 6.4. Uma metodologia alternativa também será discutida no próximo capítulo.

6.2.1 Resultados e Discussões

Após o projeto do classificador, o conjunto de sinais de teste foram aplicados ao sistema proposto. O desempenho obtido pelo método é mostrado na Tabela 6.1.

Tabela 6.1: Desempenho do classificador proposto em %.

Classes	Desempenho
Harmônicos	98,5
<i>Notches</i>	100
Impulsos	100
Transitórios Oscilatórios	97,0
Afundamentos/Elevações/Interrupções	100

Em geral, estes resultados são bastante expressivos, considerando-se o alto desempenho e o fato de que os mesmos parâmetros utilizados para fazer a detecção são também utilizados pelo sistema de classificação. Esta característica é muito interessante, do ponto de vista de complexidade computacional, já que, em geral, os sistemas de monitoramento propostos recentemente implementam diferentes estruturas para a detecção e classificação.

6.3 Curvas Principais Como Ferramenta de Classificação

Até o presente momento, no contexto desta tese, a técnica de curvas principais foi explorada para fins de análise de dados, no Capítulo 4, e como ferramenta extratora de parâmetros relevantes para a detecção (Capítulo 5) e classificação (Seção anterior) de distúrbios, em que resultados bastantes expressivos foram alcançados.

O objetivo desta seção é mostrar como as curvas principais podem fazer a classificação dos distúrbios de uma forma bastante simples. Para exemplificar esta aplicação, considere duas classes C_1 e C_2 , representadas em um espaço de duas dimensões, respectivamente pelas curvas principais $f_1(t)$ e $f_2(t)$, conforme ilustra a Figura 6.2. Assim, dado um evento desconhecido x , em que d_1 e d_2 medem a distância deste evento às curvas $f_1(t)$ e $f_2(t)$, respectivamente, o critério de classificação será atribuir o evento à classe cuja curva principal está mais próxima do evento, ou

seja, a menor distância define a curva à qual o evento pertence. Logo, o evento x será dado como pertencente à classe $C1$, já que a desigualdade $d_1 < d_2$ é satisfeita.




Figura 6.2: Exemplo de classificação utilizando curvas principais.

6.3.1 Projeto do Sistema

O projeto do sistema consiste, basicamente, em extrair as curvas principais de cada classe de distúrbios e, utilizando-se o conjunto de dados de validação, definir o melhor número de segmentos para cada curva principal. Nesta etapa, 250 sinais de cada classe do banco de sinais de projeto (vide Capítulo 3) foram utilizados para a construção das curvas. Os 250 restantes foram utilizados para a escolha do número de segmentos em cada curva.

Como o critério de classificação aqui proposto é baseado na distância do distúrbio às curvas principais, é importante que as curvas principais estejam bem definidas no espaço de parâmetros e o mais distantes umas das outras quanto possível. No Capítulo 4, as distâncias entre as curvas principais de cada classe de distúrbios é analisada, considerando-se um pré-processamento simples que consiste na remoção do componente fundamental do sinal (veja a Figura 3.1). De fato, as curvas principais tentam representar um conjunto de dados, em um espaço d -dimensional,

acompanhando a disposição dos dados no espaço. Sendo assim, a aplicação de pré-processamentos nos dados, levando-os a um novo espaço de parâmetros, pode levar à obtenção de curvas mais compactas e, principalmente, mais distantes umas das outras, o que é bastante relevante, dado o critério de classificação proposto. Com este objetivo, os seguintes passos de pré-processamentos são aplicados aos sinais de tensão com distúrbios antes da extração das curvas principais:

Passo 1: Remoção do componente fundamental, utilizando-se um filtro Notch, conforme mostrado no Capítulo 3.

Passo 2: Alinhamento do sinal $e[n]$ pelo início do distúrbio. Este alinhamento foi realizado utilizando-se um filtro média móvel de 10 coeficientes da seguinte forma: se

$$\frac{1}{10} \sum_{n=i}^{(9+i)} e[n] > \rho, \quad (6.1)$$

então $n_b = n$, onde N é o tamanho da janela do sinal $e[n]$ e $i = 1, \dots, N/2$.

O algoritmo retorna n_b , que é a amostra onde o distúrbio se inicia, quando a saída do filtro é maior que o limiar previamente definido ρ . O valor de ρ depende do valor da SNR do sinal. Uma vez que o início do evento é detectado, a janela de sinal $e[n]$ é truncada com um número de amostras igual a duas vezes o período do componente fundamental do sinal. Este filtro, de certa forma, tem a importante característica de eliminar os ruídos.

Passo 3: Sub-amostragem. A Janela resultante é sub-amostrada por um fator $L = 8$, como descrito na Equação (6.2).

$$e_d[n] = e[Ln] \quad (6.2)$$

Nesta etapa, é importante escolher L de forma que $e_d[n]$ mantenha as características básicas de cada distúrbio. O objetivo principal desta etapa é a redução de complexidade computacional.

Passo 4: Normalização. Nesta etapa, o sinal $e_d[n]$ é normalizado pelo seu valor máximo absoluto, de acordo com a Equação 6.3

$$e_n[n] = \frac{e_d[n]}{\|e_d[n]\|_\infty} \quad (6.3)$$

A Figura 6.3 ilustra cada passo de processamento. É importante notar que o pré-processamento aplicado tem como principais características a capacidade de eliminar ruídos e de reduzir a dimensão dos dados.

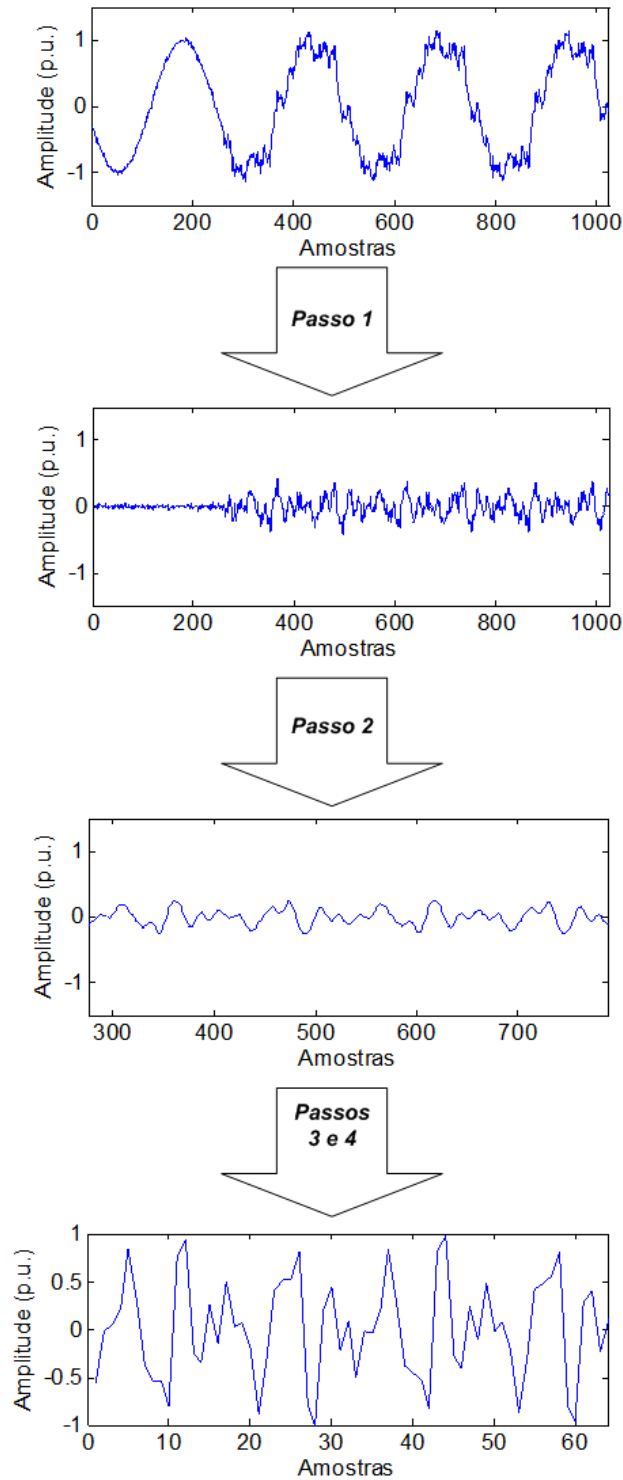


Figura 6.3: Ilustração dos passos de pré-processamento.

Após pré-processar o sinal, a curva principal de cada classe de distúrbio é

extraída do conjunto de treino a partir de $e_n[n]$ utilizando-se o algoritmo k-segmentos não suave [93]. É importante ressaltar que a etapa de extração das curvas principais é realizada somente na fase de projeto.

O número de segmentos da curva principal para cada classe foi escolhido analisando-se o resultado final de classificação para o conjunto de dados de validação, isto é, o número de segmentos de cada curva foi alterado gradativamente até que se alcançasse o maior número de acertos. A Tabela 6.2 mostra o resultado final para o número de segmentos de cada curva principal. A partir do número de segmentos, o comprimento das curvas foi também obtido, utilizando-se a distância euclidiana entre os vértices de cada segmento que compõe a curva.

Tabela 6.2: Número de segmentos e comprimento das curvas de cada classe em unidade arbitrária (u.a.).

Classes	Número de segmentos	Comprimento (u.a.)
Harmônicos	20	911,4
Afundamentos/Elevações/Interrupções	2	228,4
Transitório Oscilatório	3	21,9
<i>Notches</i>	2	31,0
Impulsos	2	19,1

Note que as classes de afundamentos, elevações e interrupções de tensão foram agrupadas em uma única classe, pois o pré-processamento aplicado levou a curvas principais bem próximas entre estas classes. A separação destas classes será discutida no próximo capítulo.

Observa-se que as classes de harmônicos e afundamentos/elevações/interrupções possuem informações mais diversificadas do que as outras classes. A classe de harmônicos possui maior complexidade geométrica no espaço de parâmetros das curvas do que as demais classes. A classe de afundamentos/elevações/interrupções, apesar de apresentar reduzido número de segmentos, é representada por segmentos longos, o que indica dados diversificados no espaço de parâmetros das curvas.

Um dos objetivos do pré-processamento (passo 1 ao 4) aplicado aos distúrbios, além de reduzir o espaço de parâmetros, é obter curvas principais mais distantes umas das outras, já que a decisão da classe à qual o distúrbio pertence é baseada

nas distâncias do distúrbio às curvas principais. A Tabela 6.3 mostra as distâncias entre as curvas principais representativas de cada classe de distúrbios. Comparando-se estas distâncias com as distâncias entre as curvas obtidas no Capítulo 4, Tabela 4.2, observa-se que, em geral, as distâncias apresentadas pelas curvas extraídas dos dados pré-processados conforme proposto nesta seção (passo 1 ao 4) são superiores e, portanto, as curvas principais obtidas aqui localizam-se mais distantes umas das outras no espaço de parâmetros, o que é desejável para o classificador proposto e justifica o pré-processamento aplicado.

Tabela 6.3: Distâncias entre as curvas principais (u.a.).

Classes	Harmônicos	Afundamentos Elevações Interrupções	Transitórios Oscilatórios	<i>Notch</i>	Impulsos
Harmônicos	0	15,18	2,40	3,63	1,98
Afundamentos Elevações Interrupções		0	13,46	10,13	12,69
Trans. Oscilat.			0	2,31	0,48
<i>Notch</i>				0	2,19
Impulsos					0

6.3.2 Resultados e Discussões

O projeto do sistema descrito anteriormente consistiu apenas em pré-processar os dados e, em seguida, obter as curvas principais de cada classe de distúrbios. A operação do sistema consiste em pré-processar o distúrbio e, em seguida, medir o quadrado da distância euclidiana deste às curvas principais de cada classe. A distância menor indica à qual classe o distúrbio pertence. Nesta etapa é importante ressaltar que a extração das curvas principais é realizada apenas no projeto do sistema.

A Tabela 6.4 mostra os resultados de desempenho do método proposto, considerando-se os 500 distúrbios de cada classe do banco de sinais de teste. Os dados pré-processados foram também apresentados à uma rede neural previamente treinada para a classificação. Os padrões de saída da rede são mostrados na Tabela 6.5. A função de ativação utilizada foi a tangente sigmóide e o algoritmo de treinamento foi o RPROP [95]. A configuração final da rede foi 64 nodos de entrada, 10

neurônios na camada oculta e 5 neurônios de saída.

Tabela 6.4: Eficiência de Classificação e eficiência global em % obtida pelo método proposto e por redes neurais (RNA).

Classes	Sistema Proposto	RNA
Harmônicos	99,5	98,5
Afundamentos/Elevações/Interrupções	100	97,0
Transitórios Oscilatórios	100	100
<i>Notch</i>	99,5	100
Impulsos	100	100
Eficiência Global	99,8	99,1

Tabela 6.5: Padrões de Saída da RNA.

Padrões	Distúrbio Correspondente
[+1 -1 -1 -1 -1]	Transitório Oscilatório
[-1 +1 -1 -1 -1]	Afundamento/Elevação/Interrupção
[-1 -1 +1 -1 -1]	Impulsos
[-1 -1 -1 +1 -1]	Notches
[-1 -1 -1 -1 +1]	Harmônicos

Os resultados mostram que o método proposto obtêve uma eficiência global superior à RNA. A RNA alcançou um desempenho inferior para as classes de harmônicos e afundamentos/elevações/interrupções. Esta comparação é interessante pelo fato de que o método proposto implementa uma técnica simples que faz a classificação utilizando apenas um critério de menor distância, enquanto que a RNA implementa um *perceptron* multi-camadas e, no entanto, resultados inferiores são alcançados.

Por outro lado, o desempenho de uma técnica de classificação está diretamente relacionada à qualidade dos parâmetros apresentados à mesma. No caso do pré-processamento aqui proposto, a técnica de curvas principais baseada na distância euclidiana mostrou-se um bom classificador. Outros pré-processamentos poderiam obter parâmetros que, apresentados a uma RNA, poderiam levar a melhores resultados, conforme proposto em [47], onde cumulantes de segunda e quarta ordem são extraídos como pré-processamento.

6.3.3 Aplicação em Dados Experimentais

Para testar o sistema em dados experimentais, utilizou-se o banco de distúrbios adquirido pelo grupo de trabalho do IEEE P1159.3, descrito no Capítulo 3. Assim, as formas de onda da tensão mostradas na Figura 6.4, foram apresentadas ao classificador proposto.




Figura 6.4: Formas de onda da tensão experimentais: (a) harmônicos e (b) transitório oscilatório.

Analisando-se visualmente as formas de onda da Figura 6.4, observa-se, claramente, a presença de harmônicos em (a), transitório oscilatório e afundamento de tensão em (b). Neste caso, a saída do classificador proposto para estes sinais apontou corretamente harmônicos para a forma de onda em (a) e transitório oscilatório em (b).

Na prática, a ocorrência de múltiplos distúrbios é comum, e a correta caracterização destes não é uma tarefa trivial, exigindo sistemas mais elaborados de classificação. Nos capítulos seguintes, esta abordagem será investigada em detalhes. Contudo, para investigar a viabilidade de, a partir do sistema aqui proposto, desenvolver-se um sistema capaz de classificar múltiplos distúrbios, considere as formas de onda mostradas na Figura 6.5. Em (a) observa-se um curto transitório, harmônicos e, possivelmente, algum outro distúrbio difícil de ser identificado por inspeção visual. Em (b) um transitório oscilatório nas amostras iniciais, harmônicos e impulsos. As distâncias Euclidianas de cada distúrbio (após pré-processamento requerido pelo método proposto de classificação) a cada curva principal são mostradas na Tabela 6.6. A partir disso, dado o critério da menor distância, o método proposto classifica ambas as formas de onda como distúrbios de transitório oscilatório.

No entanto, considerando-se também a segunda menor distância, a forma de onda da Figura 6.5 (a) passa a ser caracterizada como múltiplo distúrbio de transitório oscilatório com harmônicos. Já a forma de onda da Figura 6.5 (b) será identificada como transitório oscilatório com impulsos. Estes resultados sugerem a possibilidade de uma nova metodologia baseada em curvas principais, em que múltiplos distúrbios possam ser considerados. Tal metodologia será explorada em trabalhos futuros.




Figura 6.5: Eventos experimentais com múltiplos distúrbios.

Tabela 6.6: Distância dos distúrbios às curvas.

Curvas	Evento da Fig. 6.5(a)	Evento da Fig. 6.5(b)
Harmonônicos	7.7	6.9
Afund./Elev./Interr.	20.9	16.0
Transitório Oscilatório	6.8	5.0
<i>Notches</i>	10.3	8.0
Impulsos	8.1	5.1

6.3.4 Monitoramento Trifásico

O sistema de classificação aqui proposto, pode facilmente realizar um monitoramento simultâneo das três fases do sistema elétrico de potência, constituindo, portanto, um sistema de monitoração trifásico, conforme mostrado na Figura 6.6.

Esta monitoração é realizada de forma sincronizada. Este sincronismo viabiliza a identificação dos tipos de desbalanceamentos, além de possibilitar a identificação de distúrbios monofásicos em cada uma das fases do sistema de potência. Assim, um classificador principal monitora cada uma das fases do sistema. Quando

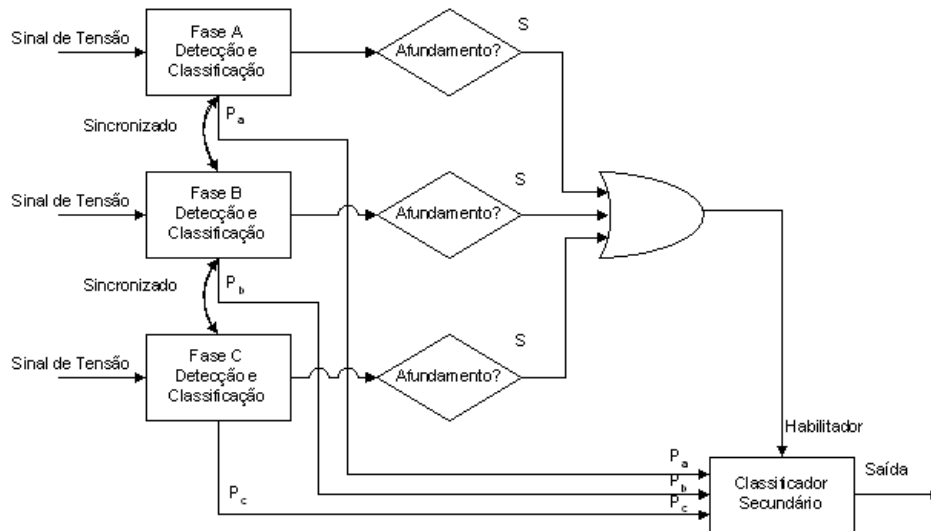


Figura 6.6: Sistema trifásico de monitoramento de QEE.

um dos classificadores de qualquer uma das fases aponta um afundamento de tensão (*sag*), uma porta “OU” habilita um novo classificador (secundário) que, baseado na estimativa do fasor do sinal de tensão monitorado, identifica os quatro tipos básicos de desbalanceamentos: tipo A, tipo B, tipo C e tipo D, descritos no Capítulo 2.

As CP foram extraídas a partir de um conjunto de fasores das fases A, B e C de cada tipo de desbalanceamento. Assim, a classificação dos desbalanceamentos é realizada sobre o vetor $\mathbf{p} = [\mathbf{P}_a \ \mathbf{P}_b \ \mathbf{P}_c]$, em que \mathbf{P}_a , \mathbf{P}_b e \mathbf{P}_c são, respectivamente, os fasores das fases A, B e C do sistema elétrico, que podem ser precisamente medidos utilizando métodos baseados na transformada discreta de Fourier (TDF) como proposto em [96].

Os resultados de classificação para os tipos de desbalanceamento são mostrados na Tabela 6.7. O tipo A refere-se a uma falta trifásica e os tipos B, C e D são subdivididos em 3 classes, indicando, para o tipo B, em qual fase ocorre o desbalanceamento, para o tipo C, em qual par de fases ocorre o desbalanceamento, e no Tipo D é indicado em qual fase acontece o desbalanceamento, ficando subentendido que o deslocamento de fase ocorre nas outras duas fases. Estes resultados foram obtidos considerando-se 200 eventos simulados de cada caso. Cumpre ressaltar que as CP obtidas para cada uma das classes de desbalanceamentos são compostas por apenas um segmento, o que implica em reduzida complexidade computacional. Este método de classificação é bastante interessante pelo fato de que além de classificar o tipo de desbalanceamento, é identificado a fase em que ocorreu o desbalanceamento,

o que é bastante interessante do ponto de vista de análise e detecção de falhas em sistemas elétricos de potência.

Tabela 6.7: Resultados de Classificação para Desbalanceamentos via Curvas Principais.

Desbalanceamentos		Desempenho em %
Tipo A		100
Tipo B	Fase A	100
Tipo B	Fase B	100
Tipo B	Fase C	100
Tipo C	Fase BC	100
Tipo C	Fase AC	100
Tipo C	Fase AB	100
Tipo D	Fase A	100
Tipo D	Fase B	100
Tipo D	Fase C	100

6.4 Sistema de Classificação Baseado em Estatísticas de Ordem Superior

Conforme [46], as estatísticas de ordem superior (EOS) podem levar a resultados mais representativos quando empregadas em processos não Gaussianos e sistemas não lineares do que as estatísticas de segunda ordem. Sabe-se que um sinal gaussiano é completamente caracterizado pela sua média e variância. Consequentemente, as EOS de um sinal gaussiano são nulas ou possuem informações redundantes. Logo as EOS são menos afetadas por ruídos gaussianos do que as estatísticas de segunda ordem.

Dado que muitas aplicações práticas possuem ruído aditivo gaussiano, as EOS têm sido utilizadas com bastante frequência, conforme é mostrado em [46]. No que tange o monitoramento da QEE, as EOS têm sido utilizadas como parâmetros que alimentam sistemas de detecção e classificação de distúrbios elétricos com muito sucesso [42, 47, 68].

Conforme apontado em [46], as EOS podem ser definidas em termos de momentos e cumulantes. Momentos são mais indicados para sinais determinísticos, enquanto que cumulantes são mais aplicados em sinais aleatórios. Como os distúrbios elétricos apresentam, em sua maioria, características não lineares, o uso de

métodos baseados em cumulantes pode ser muito promissor na classificação e detecção de distúrbios. De fato, vetores extraídos do sinal de tensão com técnicas baseadas em EOS são capazes de fornecer, para cada classe de eventos de tensão (ω_i , $i = 1, \dots, C$), informações muito bem definidas, conforme resultados apresentados em [47]. As expressões dos cumulantes de segunda, terceira e quarta ordem de um sinal aleatório $x[n]$, quando $E\{x[n]\} = 0$, são, respectivamente [46]:

$$c_{2,x}[i] = E\{x[n]x[n+i]\}, \quad (6.4)$$

$$c_{3,x}[i] = E\{x[n]x^2[n+i]\}, \quad (6.5)$$

$$c_{4,x}[i] = E\{x[n]x^3[n+i]\} - 3c_{2,x}[i]c_{2,x}[0], \quad (6.6)$$

em que i é o i -ésimo atraso, e $x[n]$ é o n -ésimo elemento do vetor \mathbf{x} .

Para um vetor com comprimento finito (N), as aproximações estocásticas oferecem as seguintes expressões:

$$\hat{c}_{2,x}[i] := \frac{2}{N} \sum_{n=0}^{N/2-1} x[n]x[n+i], \quad (6.7)$$

$$\hat{c}_{3,x}[i] := \frac{2}{N} \sum_{n=0}^{N/2-1} x[n]x^2[n+i] \quad (6.8)$$

e

$$\hat{c}_{4,x}[i] := \frac{2}{N} \sum_{n=0}^{N/2-1} x[n]x^3[n+i] - \frac{2}{N^2} \sum_{n=0}^{N/2-1} x[n]x[n+i] \sum_{n=0}^{N/2-1} x^2[n], \quad (6.9)$$

em que $i = 0, 1, \dots, N/2 - 1$.

Note que as Equações (6.7)-(6.9) não podem ser usadas se $i > N/2 + 1$, pois $n + i$ será maior que N . Desta forma, perdem-se informações no cálculo dos cumulantes. Em [43], é proposta uma abordagem alternativa, em que cada cumulante é calculado utilizando todas as N amostras de sinal disponível. Basicamente, forma-se um tipo de *Buffer* circular nos sinais, de tal forma que se o valor de $n + i$ for maior

que N em k unidades, este valor é substituído por k , tomando com isso as amostras antecessoras ao valor i que anteriormente não eram utilizadas. Na verdade, é como se houvesse uma continuidade da última amostra para a primeira, fazendo com que o sinal seja virtualmente circular.

Matematicamente, a substituição de $n + 1$, quando $n + 1 > N$, pode ser dada por:

$$\text{mod}(n + i, N) = [n + i] - bN, \quad (6.10)$$

em que b é o número inteiro obtido quando se desconsidera as casas decimais da divisão de $n + i$ por N , o que na verdade resulta no resto da divisão de $n + i$ por N .

Assim, as expressões (6.4)-(6.6) podem ser estimadas, para N finito, por:

$$\hat{c}_{2,x}[i] := \frac{1}{N} \sum_{n=0}^{N-1} x[n]x[\text{mod}[n + i, N]], \quad (6.11)$$

$$\hat{c}_{3,x}[i] := \frac{1}{N} \sum_{n=0}^{N-1} x[n]x^2[\text{mod}[n + i, N]] \quad (6.12)$$

e

$$\hat{c}_{4,x}[i] := \frac{1}{N} \sum_{n=0}^{N-1} x[n]x^3[\text{mod}[n + i, N]] - \frac{1}{N^2} \sum_{n=0}^{N-1} x[n]x[\text{mod}[n + i, N]] \sum_{n=0}^{N-1} x^2[n], \quad (6.13)$$

em que $\text{mod}[n + i, N]$ é o resto inteiro da divisão de $n + i$ por N .

As aproximações apresentadas em 6.11-6.13 levam a uma boa simplificação para problemas onde é empregado um vetor de comprimento finito. Estas aproximações são mais indicadas quando o sinal é periódico. Portanto, considerando-se a natureza periódica dos sinais de tensão em sistemas de potência, esta é uma boa aproximação das EOS.

Pode-se observar que para um sinal com N amostras, tem-se N cumulantes para cada ordem de EOS. Para efeitos de classificação e detecção, a combinação de poucos destes cumulantes são suficientes para a obtenção de um bom desempenho, conforme mostrado em [47, 68].

É importante ressaltar que as análises apresentadas em [47] mostram que o cumulante de terceira ordem pouco contribui para a classificação dos distúrbios.

Assim, neste capítulo, estaremos considerando apenas os cumulantes de segunda e quarta ordem.

6.4.1 EOS Como Parâmetros

Para ilustrar a capacidade das EOS de extrair parâmetros relevantes dos distúrbios, 250 eventos de cada classe (*notch*, impulsos, harmônicos, interrupções, afundamentos e elevações de tensão, transitórios oscilatórios e sinais com tensão nominal), do banco de sinais de projeto (vide Capítulo 7.3.2), foram utilizados. Estes sinais foram apresentados ao sistema de decomposição utilizando o filtro Notch (vide Figura 3.1), gerando, para cada evento, dois sinais, $e[n]$ e $f[n]$.

Considere, primeiramente, o sinal $e[n]$. Considerando-se as janelas de $N = 1.024$ amostras (4 ciclos do componente fundamental), as expressões (6.11) e (6.13) foram aplicadas e um vetor de parâmetros $\mathbf{p} = [c_{2,e} \ c_{4,e}]$ foi obtido para cada janela. Assim, um total de $2 \times N$ parâmetros são obtidos para cada janela de sinal. Para reduzir a dimensão dos parâmetros extraídos e, conseqüentemente, a complexidade computacional e o tempo de processamento, o discriminante de Fisher (FDR) [16] é usado para selecionar um conjunto reduzido de dados composto pelos parâmetros mais representativos (do ponto de vista de separação de classes) dentre os obtidos usando EOS. É importante destacar que o FDR seleciona os parâmetros que apresentam uma melhor separabilidade entre classes distintas, verificando a distância entre as médias das classes, ponderada pelas suas variâncias, conforme mostrado no Anexo C.

A Figura 6.7 ilustra o FDR (\mathbf{J}_c) para os harmônicos contra todas as outras classes e os *notches* contra todas as outras classes, obtidos utilizando o vetor \mathbf{p} . Os primeiros 1.024 índices referem-se aos cumulantes de segunda ordem ($c_{2,e}$), e o restante aos cumulantes de quarta ordem ($c_{4,e}$). Estas duas classes foram escolhidas como exemplo, propositalmente, para mostrar que existem classes em que os parâmetros de segunda ordem são mais discriminativos do que os de quarta ordem, como pode ser visto para os harmônicos e, no entanto, para os *notches*, os cumulantes de quarta ordem mostram-se mais discriminativos, segundo o critério FDR. Na verdade, o uso de ambos os cumulantes pode ser mais interessante, já que eles retêm informações distintas sobre os eventos, conforme discutido em [46].




Figura 6.7: Valores do critério FDR obtidos para as classes de harmônicos e *notches*.

A Figura 6.8 mostra a capacidade de discriminação dos cumulantes de segunda e quarta ordem. Analisando os eventos no espaço de parâmetros das EOS é possível notar que as classes de *notches*, sinal de tensão nominal, afundamentos, elevações e interrupções de tensão, são mais homogêneas, enquanto que os harmônicos, impulsos e transitórios oscilatórios são classes mais heterogêneas. Observa-se também que existem interseções entre as classes de tensão nominal, afundamentos e elevações de tensão. Contudo, a maioria das classes são bem caracterizadas utilizando este espaço de parâmetros.

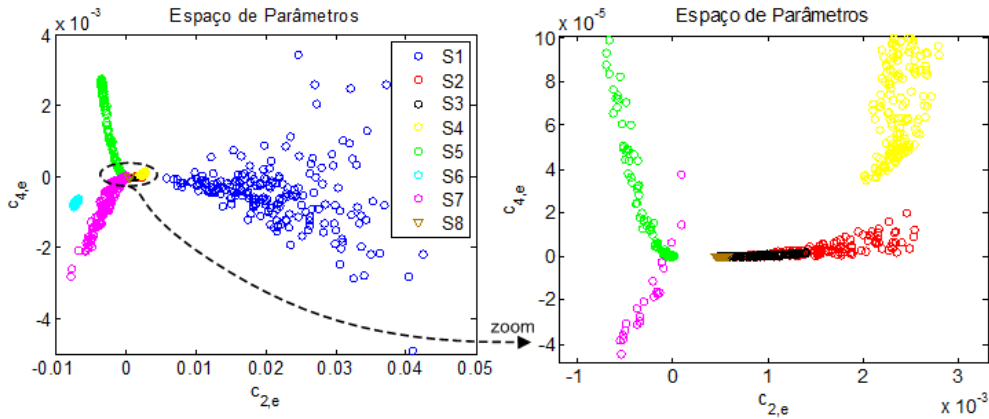


Figura 6.8: Espaço de parâmetros para as classes: (S1) harmônicos, (S2) afundamento, (S3) elevação, (S4) interrupção, (S5) impulsos, (S6) *notches*, (S7) transitório oscilatório e (S8) sinal de tensão nominal.

Por outro lado, as informações relacionadas ao componente fundamental ($f[n]$) podem levar a uma boa separação entre as classes de sinal de tensão nominal, afundamentos e elevações de tensão. A Figura 6.9 mostra o espaço de parâmetros obtido com cumulantes que foram extraídos de $f[n]$. Neste novo espaço de parâmetros, torna-se fácil separar as classes de afundamentos, elevações de tensão e

tensão nominal.

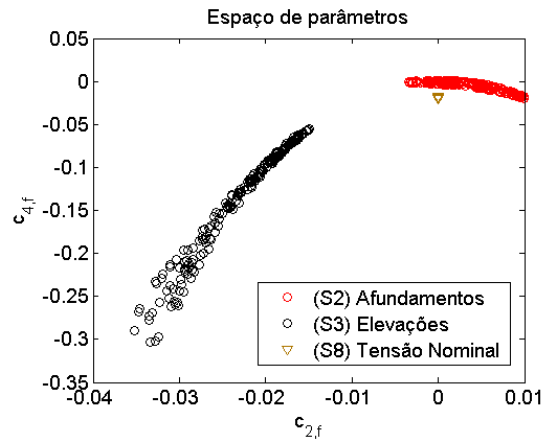


Figura 6.9: Espaço de parâmetros para as classes: (S2) afundamento, (S3) elevação, e (S8) sinal de tensão nominal.

Estas análises são muito importantes no projeto do classificador, pois pode-se ter uma idéia da complexidade do processo de classificação e, a partir disso, escolher técnicas de classificação coerentes, além de ser possível também reduzir consideravelmente o número de parâmetros a serem utilizados pelo classificador.

6.4.2 Projeto do Classificador

O sistema de classificação proposto é representado pelo diagrama em blocos da Figura 6.10. Os parâmetros extraídos e selecionados conforme mostrado na seção anterior são apresentadas a uma rede neural artificial com o propósito de classificação. Este classificador é responsável pela identificação de seis classes: afundamentos/elevações de tensão, *notches*, impulsos, interrupções, harmônicos e transitórios oscilatórios. A classe de afundamentos e elevações de tensão foram agrupadas em uma única classe.

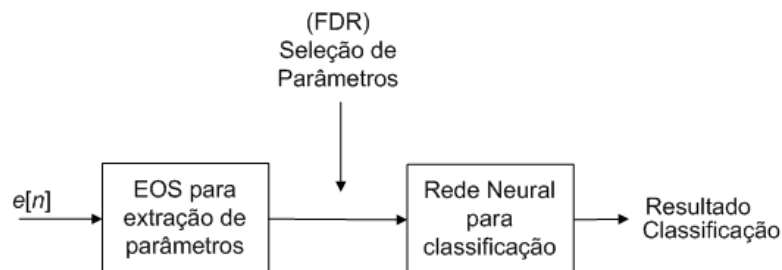


Figura 6.10: Sistema de classificação proposto.

Tomando-se o maior valor de \mathbf{J}_c relacionado aos cumulantes de segunda e quarta ordem, 2 parâmetros para cada classe são selecionados, resultando num total de 12 parâmetros (6 classes) para cada distúrbio. Assim, a dimensão original de cada evento foi reduzida de 1.024 para 12. É importante ressaltar que esta etapa de seleção de parâmetros é realizada *off line*, apenas na fase de projeto.

O vetor de parâmetros selecionado é então apresentado a uma rede neural que realiza a classificação. A rede neural foi treinada utilizando-se 150 eventos de cada classe de distúrbios através do algoritmo RPROP [95] e validada com 100 eventos de cada classe. Estes 250 eventos fazem parte do banco de sinais de projeto do sistema, conforme descrito no Capítulo 3. A topologia final da rede foi 12 nós de entrada, 6 neurônios na camada intermediária e 6 neurônios de saída. O critério de parada adotado durante o treinamento foi o de maior desempenho do conjunto de validação.

Quando o classificador decide pela classe de afundamentos/elevações de tensão, um novo sistema (vide Figura 6.11) que analisa $f[n]$ é habilitado. Este sistema é responsável por identificar entre afundamentos e elevações de tensão. Conforme as análises da Seção anterior, os parâmetros baseados em cumulantes de segunda e quarta ordem de $f[n]$ levam a uma boa separação entre as classes de afundamentos e elevações de tensão (vide Figura 6.9) e, portanto, um simples classificador Bayesiano [16] foi utilizado, baseado no critério ML (*Maximum Likelihood*) devido a sua simplicidade, facilidade de projeto e baixo custo computacional (vide Anexo D). A Figura 6.11 ilustra este sistema. Neste ponto, parâmetros alternativos, tais como o valor RMS ou a estimativa da amplitude de $f[n]$ podem também ser utilizados para separar os afundamentos das elevações de tensão.

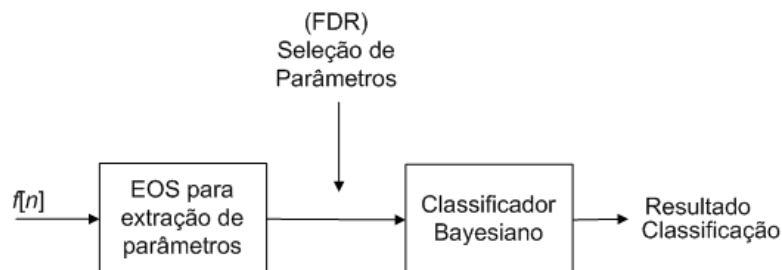


Figura 6.11: Sistema de classificação de afundamentos e elevações de tensão.

6.4.3 Resultados e Discussões

Para computar os resultados do método proposto, um banco de dados de teste, composto por 500 eventos de cada classe de distúrbios foi então apresentado ao sistema proposto. Os resultados são mostrados na Tabela 6.8. Como pôde ser visto, um desempenho de 100 % foi alcançado, mostrando que poucos cumulantes são suficientes para obter bons resultados de classificação, utilizando-se uma rede neural.

Tabela 6.8: Eficiência de classificação em % para dados de teste.

Classes	EOS
Harmônicos	100
Afundamentos de tensão	100
Elevações de tensão	100
Interrupções de tensão	100
Transitórios Oscilatórios	100
<i>Notch</i>	100
Impulsos	100
Eficiência Global	100

6.5 Análise de Complexidade Computacional

Nesta seção, os três métodos propostos neste capítulo para a classificação dos distúrbios isolados são comparados, do ponto de vista de complexidade computacional.

A complexidade computacional de cada método foi realizada em termos das suas operações matemáticas necessárias para processar um evento de 1.024 amostras, conforme as equações apresentadas no Anexo B. A Tabela 6.9 ilustra os resultados, em que CP I refere-se ao sistema descrito na Seção 6.2, CP II refere-se ao sistema descrito na Seção 6.3. O sistema EOS refere-se ao sistema baseado em estatísticas de ordem superior, descrito na Seção 6.4.

Para a correta interpretação destes resultados, algumas questões devem ser levadas em consideração:

1. As tangentes hiperbólicas computadas pelas redes neurais podem ser implementadas em DSP utilizando-se uma tabela de valores aproximados.

2. No método CP II, o cálculo das adições foi obtido considerando-se a máxima complexidade para processar o evento. A mínima complexidade, no entanto, acontece quando o filtro média móvel (Equação (6.1)), no passo 2 do pré-processamento, detectar o início do distúrbio logo nas primeiras 10 amostras do evento processado. Para este caso, o número de adições diminui consideravelmente para 7.434.
3. No método EOS, a complexidade do sistema secundário, que analisa $f[n]$ para separar afundamentos de elevações de tensão, não foi incluída. Por outro lado, este método aborda duas classes a mais do que os métodos CP I e CP II.

Tabela 6.9: Complexidade computacional dos métodos propostos.

Operações	CP I	CP II	EOS
Adições	86.156	33.383	24.666
Multiplicações	64.642	5.570	37.008
$\tan(\cdot)$	70	0	12

Diante dos resultados mostrados na Tabela 6.9 e das questões anteriormente consideradas, nota-se que o sistema CP II requer menor complexidade computacional e, portanto, é mais sugerido em aplicações de tempo real. Contudo, sistemas baseados em curvas principais necessitam de memória para o armazenamento das curvas, que podem ser armazenadas na forma matricial.

Uma forma sugestiva de representar as curvas matricialmente é dada pelo próprio algoritmo k-segmentos não suave [93], que retorna duas matrizes: (i) uma contendo as coordenadas dos vértices que compõem a curva e é da ordem $2k \times d$, em que k é o número de segmentos e d é a dimensão dos dados; (ii) a outra matriz, da ordem $2k \times 2k$, define como os vértices estão ligados, a fim de formar a curva principal.

O método CP I requer maior complexidade computacional, porém tem a vantagem de se realizar a detecção utilizando-se os mesmos parâmetros.

O método baseado em EOS possui uma complexidade computacional intermediária e tem como vantagem o alto desempenho, além de propor metodologia para separar os afundamentos, elevações e interrupções de tensão.

Capítulo 7

Classificação de Distúrbios Elétricos Simultâneos

Sabe-se que o aparecimento de múltiplos distúrbios (simultâneos) é comum em sistemas elétricos de potência e, de fato, a caracterização destes é bastante complexa. Os sistemas de classificação de distúrbios isolados podem gerar informações errôneas dado o aparecimento de um múltiplo distúrbio. Desta forma, este capítulo apresenta diferentes metodologias para classificar e analisar os múltiplos distúrbios.

7.1 Como Abordar o Problema de Múltiplos Distúrbios?

Os múltiplos distúrbios se caracterizam pelo aparecimento de um ou mais distúrbios elétricos simultaneamente em uma mesma janela de sinal. A seguir, algumas soluções para a classificação e/ou análise de múltiplos distúrbios são apresentadas.

Banco de Filtros

Uma solução para a análise de múltiplos distúrbios, seria, antes de qualquer outro processamento, desacoplá-los, decompondo o sinal de tensão monitorado em parcelas. Este procedimento é motivado pela modelagem do sinal de tensão do sistema de potência pela contribuição aditiva de vários tipos de distúrbios, conforme formulado na Seção 3.1. Assim, após esta decomposição, as parcelas de sinal podem

então ser analisadas individualmente e tratadas como distúrbios isolados.

De fato, a forma como o sinal de tensão foi abordado nos sistemas de detecção e classificação, no contexto desta tese, utilizando-se um filtro notch para decompor o sinal $v[n]$ em $f[n]$ e $e[n]$, já desacopla, dos demais, os distúrbios de afundamentos, elevações e interrupções de tensão, que aparecem com maior intensidade no componente fundamental $f[n]$. Assim, um banco de filtros digitais pode ser aplicado ao sinal $e[n]$, com o objetivo de desacoplar os distúrbios fortemente presentes, tais como impulsos, transitórios oscilatórios, harmônicos e *notches*.

De acordo com a norma do IEEE [1], cada classe de distúrbio é bem definida em termos de algumas variáveis, tais como amplitude, faixa de frequência, etc. Assim, um conjunto de distúrbios bem definidos pode fornecer informações espectrais bem consistentes sobre cada classe de distúrbios e, a partir disso, um simples e eficiente banco de filtros pode ser projetado. A Figura 7.1 ilustra um sistema genérico de filtragem. Observe que a saída de cada filtro é individualmente analisada e, portanto, técnicas de extração de parâmetros e classificação aplicadas à distúrbios isolados podem ser empregadas. Cada classificador pode ser projetado para classificar uma classe específica de distúrbio ou um reduzido número de classes. Finalmente, as saídas *Saída 1*, *Saída 2*, ..., *Saída M* alimentam uma lógica final que define o tipo de distúrbio (múltiplo ou isolado) presente em $e[n]$. A lógica final pode também incorporar informações baseadas em $f[n]$, de forma a abordar os afundamentos, elevações e interrupções de tensão.

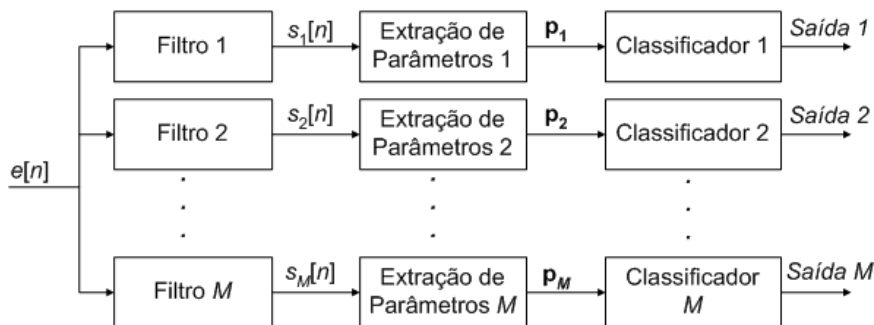


Figura 7.1: Banco de filtros para desacoplar múltiplos de distúrbios.

Neste contexto, o banco de filtros pode ser facilmente implementado por filtros IIR [85]. Métodos mais sofisticados, tais como transformadas wavelets [33], podem também ser empregadas. Esta abordagem será discutida adiante.

Dividir para Conquistar

Por outro lado, técnicas baseadas no princípio *dividir para conquistar*, tais como as árvores de decisão [16, 97] podem desenvolver uma importante tarefa na triagem dos distúrbios presentes em um múltiplo distúrbio. A idéia é, a partir de parâmetros específicos, subdividir o problema de classificação de forma a obter as classes presentes no sinal analisado. A Figura 7.2 exemplifica um processo de classificação via árvore de decisão para um espaço bi-dimensional e um problema de duas classes.




Figura 7.2: Classificação baseada em árvore de decisão.

A vantagem em utilizar as árvores de decisão está na sua reduzida complexidade computacional e fácil interpretação de resultados.

Sistemas de Classificação Especialistas

Alternativamente, a classificação de múltiplos distúrbios pode também ser realizada utilizando-se sistemas especialistas, isto é, projetar um sistema de classificação especialista (SCE) para cada distúrbio. Dessa forma, o número de SCE é determinado pela quantidade de distúrbios possíveis de estarem presentes do sinal monitorado, conforme ilustra a Figura 7.3. A vantagem deste método é a facilidade de incluir novas classes no sistema. As saídas dos SCEs alimentam uma lógica final que define o tipo de distúrbio (múltiplo ou isolado) presente no sinal monitorado.

Cumprе ressaltar que técnicas de pré-processamento devem ser aplicadas ao sinal monitorado de forma a reduzir a complexidade computacional e facilitar a classificação.

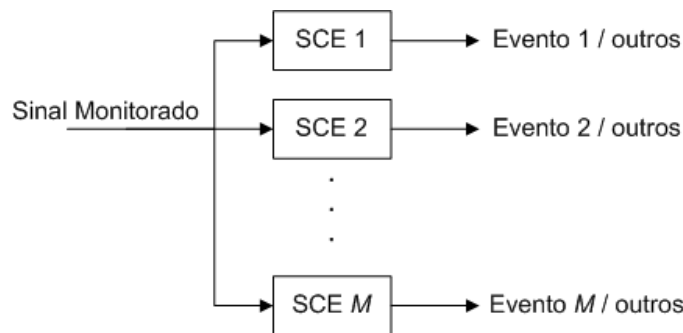


Figura 7.3: Sistema com classificadores especialistas.

7.2 Análise Wavelet

A transformada wavelet vem sendo extensivamente aplicada à análise de distúrbios elétricos. A frequente utilização da TW se dá pela sua habilidade de destacar curtos transitórios em componentes de alta frequência e longos transitórios em componentes de baixa frequência [33, 98]. Tal habilidade facilita a análise de impulsos e transitórios localizados mesmo na presença do componente fundamental e harmônicos de baixa ordem [98]. Na verdade, a TW utiliza uma janela que se adapta automaticamente, de acordo com as frequências presentes no sinal em análise, gerando uma resolução apropriada em componentes de altas e baixas frequências. Para maiores detalhes sobre a definição da TW veja o Anexo G.

Para ilustrar a capacidade da TW de destacar transitórios em meio a harmônicos, considere as formas de onda mostradas na Figura 7.4, que ilustra um sinal de tensão corrompido por harmônicos e transitórios oscilatórios $\{v[n]\}$ e a sua versão sem o componente fundamental, filtrado pelo filtro notch, que é representada por $e[n]$. Assim, o sinal $e[n]$ é então decomposto em três níveis pela TW. As aproximações $\{A_i\}$ e detalhes $\{D_i\}$ de cada nível (i) são ilustradas na Figura 7.5. É fácil ver que os harmônicos aparecem isoladamente dos transitórios oscilatórios nas aproximações A_2 e A_3 . Já os transitórios oscilatórios aparecem isolados dos harmônicos e com maior intensidade no detalhe D_2 .

A Figura 7.6 ilustra um sinal de tensão corrompido por harmônicos e *notches* $\{v[n]\}$ e o seu componente $e[n]$ após a remoção de $f[n]$. $e[n]$ foi então decomposto em três níveis pela TW, que são ilustrados na Figura 7.7. Pode-se observar que os harmônicos aparecem claramente na aproximação A_3 , sem resíduos de distúrbios de *notches*. Os *notches* aparecem claramente nos detalhes D_1 e D_2 .




Figura 7.4: Forma de onda da tensão com transitório oscilatório e harmônicos em (a), e o respectivo sinal filtrado $e[n]$.




Figura 7.5: Decomposições da TW. A_i e D_i são, respectivamente, as aproximações e os detalhes da TW para o nível i .




Figura 7.6: Forma de onda da tensão com *notches* e harmônicos em (a), e o respectivo sinal filtrado $e[n]$.




Figura 7.7: Decomposições da TW. A_i e D_i são, respectivamente, as aproximações e os detalhes da TW para o nível i .

De fato, monitorar as aproximações e detalhes da TW é bastante atraente e tem sido utilizado por alguns autores na detecção e classificação de distúrbios elétricos [99]. Contudo, conforme bem mencionado em [98], a TW utiliza uma janela de filtragem que é adaptada automaticamente, de acordo com o sinal em análise, obtendo uma resolução apropriada. Dessa forma, como pôde ser visto na análise anterior, um determinado distúrbio pode possuir energia em diferentes decomposições da wavelet e também compartilhar energia com outros distúrbios em alguma decomposição. Com esta característica não é possível garantir, por exemplo, que um transitório oscilatório aparecerá sempre nos detalhes D1 e D2 da TW, o que dificulta o projeto de um classificador a partir das informações das aproximações e detalhes da TW. A Figura 7.8 ilustra um sinal de tensão corrompido por um transitório oscilatório e o seu respectivo sinal filtrado $e[n]$. Observe, na Figura 7.9, que o transitório oscilatório presente no sinal $e[n]$ aparece em todas as decomposições da wavelet, o que não fica claro na Figura 7.5 devido ao maior conteúdo de energia dos harmônicos, nas aproximações, em relação a energia do transitório oscilatório.




Figura 7.8: Sinal de tensão corrompido por transitório oscilatório $\{v[n]\}$ e o respectivo sinal filtrado $e[n]$.

Por outro lado, conforme bem destacado em [98] e [33], além da TW ter a boa capacidade de destacar os eventos transitórios, as TW também permitem uma representação tempo-frequência através dos seus coeficientes a (dilatação - frequência) e b (escala - tempo). A Figura 7.10 ilustra esta representação para o transitório




Figura 7.9: Decomposições da TW para o sinal $e[n]$ ilustrado na Figura 7.8.

oscilatório $e[n]$ da Figura 7.8. Observe que a escala b representa as amostras do sinal, definindo o instante de tempo em que o transitório ocorre, e a escala a , define as faixas de frequência do transitório divididas em dez níveis.




Figura 7.10: Coeficientes da TW.

A representação tempo-frequência da TW permite caracterizar melhor os distúrbios, dando informações importantes como a duração de um afundamento por exemplo. Por tanto, inúmeros pesquisadores tem sido motivados a investigar a capacidade destes coeficientes de caracterizar os distúrbios elétricos [27–29, 32, 34, 37–40, 51, 77, 78, 97, 100–102]. Estes pesquisadores têm proposto sistemas de

classificação interessantes utilizando-se a TW, no entanto, o número de classes de distúrbios envolvidas e de múltiplos distúrbios abordadas ainda é reduzido.

7.3 Desacoplamento Via Banco de Filtros

Nesta seção, uma metodologia alternativa à TW é proposta. A idéia principal é utilizar um banco de filtros para desacoplar os múltiplos distúrbios. O uso de banco de filtros justifica-se pelo fato de que os distúrbios elétricos podem ser classificados de acordo com suas características espectrais. Desta forma, um banco de filtros projetado de acordo com o conteúdo espectral dos distúrbios pode apresentar um desempenho superior à transformada wavelet em sistemas de classificação.

O banco de filtros proposto é constituído por quatro filtros IIR [85], projetados de forma a possibilitar o desacoplamento dos diversos distúrbios. A Figura 7.11 ilustra o diagrama em blocos em detalhes deste sistema. Inicialmente, um filtro Notch [84], sintonizado na frequência do componente fundamental (60Hz) do sinal monitorado, conforme descrito no Capítulo 3, foi utilizado para dividir o sinal em dois componentes básicos, $e[n]$ e $f[n]$. O sinal $f[n]$, que corresponde à estimativa do componente fundamental do sinal de tensão monitorado, contém as informações do componente fundamental e dos distúrbios a ela relacionados, tais como afundamento, interrupção e elevação de tensão. O componente $e[n]$, denominado aqui de componente de “erro”, carrega as informações associadas aos distúrbios de frequências mais altas, tais como harmônicos, transitórios, impulsos, *notches*, entre outros. Os detalhes sobre o filtro Notch são encontrados na Seção 4.2.

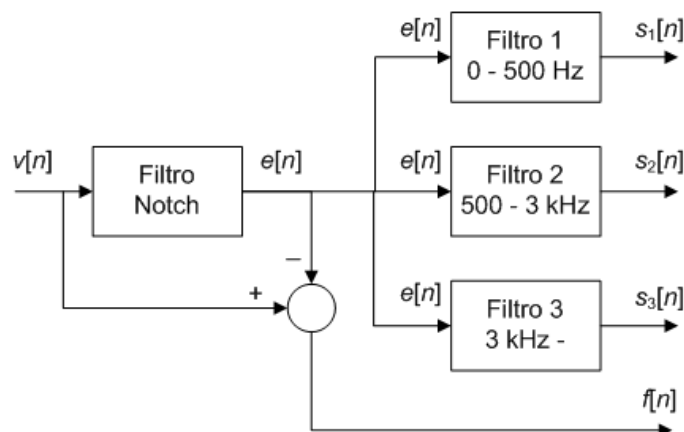


Figura 7.11: Diagrama em blocos sistema de filtragem de $v[n]$.

Para o projeto dos filtros 1, 2 e 3, mostrados na Figura 7.11, a informação espectral dos distúrbios presentes no sinal $\{e[n]\}$ foi obtida utilizando a Transformada Discreta de Fourier (TDF) [85]. A Figura 7.12 mostra a média dos módulos das transformadas para 200 eventos de transitório oscilatório, harmônicos, *notch* e impulsos. Estas informações espectrais evidenciam a faixa de frequência onde há maior concentração de energia referente a estes distúrbios. Assim, projetou-se um filtro passa-baixa com frequência de corte de 500 Hz, buscando eventos de baixa frequência, um filtro passa-faixa com frequências de corte em 500 Hz e 3 kHz, buscando eventos de média frequência, e um filtro passa-alta com frequência de corte de 3 kHz, buscando eventos de alta frequência. Na saída do filtro passa-baixa, os harmônicos e impulsos aparecem com energia relevante. Na saída do filtro passa-faixa, os distúrbios de transitório oscilatórios, *notches*, impulsos e harmônicos aparecem com maior energia. A saída do filtro passa-alta fica restrita, basicamente, ao aparecimento de *notches*. Assim, seguindo a formulação da Seção 3.1, tem-se que:

$$s_1[n] = h[n][u[n - n_{h_{m,i}}] - u[n - n_{h_{m,f}}]] + t_{imp}[n][u[n - n_{t_{imp,i}}] - u[n - n_{t_{imp,f}}]]; \quad (7.1)$$

$$s_2[n] = h[n][u[n - n_{h_{m,i}}] - u[n - n_{h_{m,f}}]] + t_{osc}[n][u[n - n_{t_{osc,i}}] - u[n - n_{t_{osc,f}}]] + t_{not}[n][u[n - n_{t_{not,i}}] - u[n - n_{t_{not,f}}]] + t_{imp}[n][u[n - n_{t_{imp,i}}] - u[n - n_{t_{imp,f}}]]; \quad (7.2)$$

$$s_3[n] = t_{not}[n][u[n - n_{t_{not,i}}] - u[n - n_{t_{not,f}}]]. \quad (7.3)$$

Neste ponto, é importante tecer alguns comentários sobre a distribuição espectral para os harmônicos, mostrada na Figura 7.12(b)¹. Nota-se claramente uma concentração de energia para as frequências menores que 1kHz. Num primeiro momento pode parecer contraditório, pois muitas normas estabelecem a medição de harmônicos de ordem elevada. Por exemplo, o PRODIST estabelece até a 25^a componente [6]. Entretanto, duas observações justificam a faixa espectral utilizada:

1. Os componentes harmônicos, presentes no sinal de tensão, devem apresentar

¹A Figura 7.12 foi gerada a partir dos eventos de treinamento.




Figura 7.12: Módulo médio normalizado da TDF aplicada aos sinais $e[n]$ das classes: (a) Transitório oscilatório, (b) Harmônicos, (c) *Notch* e (d) Impulsos.

energias decrescentes, com o aumento da frequência. As mesmas normas estabelecem o máximo de distorção harmônica individual (energia) para cada componente harmônico [6], o que foi levado em conta para gerar o banco de dados, que incluiu componentes até a 7ª ordem;

2. A técnica de separação por filtros utilizada neste trabalho procura contribuir para a melhor separação das classes, o que possibilita o projeto de classificadores mais eficientes, porém, em toda técnica de separação poderá existir alguma interseção entre as classes.

Os três filtros projetados são IIR de quarta ordem e foram desenvolvidos utilizando aproximação elíptica [85]. A aproximação elíptica produz funções de transferência com zeros no eixo imaginário do plano complexo e resposta em frequência equiríple na faixa de passagem. Como resultado, é uma aproximação mais eficiente em termos de seletividade em frequência e, em geral, requerem aproximações de ordens menores. A Equação (7.4) mostra a função de transferência de um filtro IIR de quarta ordem.

$$H(z) = \frac{b_0 + b_1z^{-1} + \dots + b_4z^{-4}}{a_0 + a_1z^{-1} + \dots + a_4z^{-4}} \quad (7.4)$$

As respostas em frequência dos filtros passa-baixa, passa-faixa e passa-alta são mostradas nas Figuras 7.13, 7.14 e 7.15, respectivamente. Estes filtros foram projetados para *ripple* na faixa de passagem de 0,5 dB e atenuação mínima de 40 dB na faixa de rejeição.




Figura 7.13: Resposta em frequência do filtro passa-baixa.




Figura 7.14: Resposta em frequência do filtro passa-faixa.




Figura 7.15: Resposta em frequência do filtro passa-alta.

As Figuras 7.16-7.21 ilustram, respectivamente, as saídas do sistema de fil-

tragem proposto para um distúrbio sintético de transitório oscilatório, *notch*, transitório impulsivo, harmônicos, afundamento e elevação de tensão. Suas amplitudes estão representadas em sistema **por unidade** (p.u.).




Figura 7.16: Saídas do sistema de filtragem para um transitório oscilatório.




Figura 7.17: Saídas do sistema de filtragem para um *notch*.

De fato, estas ilustrações podem mostrar a capacidade dos filtros de restringir suas saídas a um único distúrbio (filtro 3) ou a um grupo reduzido de distúrbios. É interessante observar que a saída $s_3[n]$ apresenta energia considerável apenas para




Figura 7.18: Saídas do sistema de filtragem para um transitório impulsivo.




Figura 7.19: Saídas do sistema de filtragem para harmônicos.




Figura 7.20: Saídas do sistema de filtragem para um afundamento de tensão.




Figura 7.21: Saídas do sistema de filtragem para uma elevação de tensão.

os *notches* e, portanto, o projeto de um classificador de *notch* baseado na saída $s_3[n]$ pode ser simples. É importante notar também a presença de resíduos, referentes aos harmônicos, em $f[n]$. Contudo, a metodologia proposta para classificar os afundamentos e elevações de tensão baseada em $f[n]$ não sofre muita interferência destes resíduos.

Para ilustrar melhor a capacidade de desacoplar os múltiplos distúrbios do sistema de filtros proposto, considere os múltiplos distúrbios reais da Figura 7.22, adquiridos pelo grupo de trabalho do IEEE (*working group* P1159.3). As saídas do sistema de filtros proposto para os distúrbios ilustrados na Figura 7.22 (a) e (b) são mostradas, respectivamente, nas Figuras 7.23 e 7.24. Em ambas é possível observar, claramente, o aparecimento dos distúrbios de afundamento de tensão na saída $f[n]$, harmônicos em $s_1[n]$, e transitório oscilatório em $s_2[n]$, o que pode comprovar, analiticamente, a eficiência do método para desacoplar múltiplos distúrbios.




Figura 7.22: Múltiplos distúrbios reais.

7.3.1 Projeto do Classificador

Após a filtragem, o projeto do classificador consiste, basicamente, em extrair e selecionar parâmetros das saídas $s_1[n]$, $s_2[n]$, $s_3[n]$ e $f[n]$ do banco de filtros, e desenvolver classificadores individuais para cada uma destas saídas. No final, uma lógica de decisão avalia a saída de cada um destes classificadores para o evento processado e decide por uma das classes de distúrbio ou múltiplo distúrbio abordada.




Figura 7.23: Saídas do sistema de filtragem para um múltiplo distúrbio da Figura 7.22 (a).




Figura 7.24: Saídas do sistema de filtragem para um múltiplo distúrbio da Figura 7.22 (b).

Extração de Parâmetros

Após a filtragem do sinal $\{v[n]\}$ e a obtenção dos sinais $\{f[n]\}$, $\{s_1[n]\}$, $\{s_2[n]\}$ e $\{s_3[n]\}$ (veja a Fig. 7.11), alguns parâmetros são extraídos, visando à redução de dimensionalidade da informação e um melhor desempenho na classificação. A Figura 7.25 mostra o diagrama em blocos da extração de parâmetros.

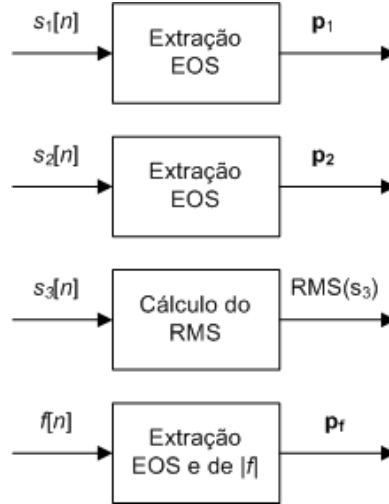


Figura 7.25: Diagrama em blocos do processo de extração de parâmetros.

Para o sinal $\{s_3[n]\}$, que carrega a informação de *notches*, o valor RMS (*Root Mean Square*) foi utilizado, já que, para os eventos considerados, apenas ruído e eventos de *notch* têm componentes espectrais acima de 3 kHz e, portanto, o parâmetro RMS pode ser utilizado para separar o *notch* dos demais distúrbios. O valor RMS é calculado da seguinte forma:

$$RMS(y) = \sqrt{\frac{\sum_{n=1}^N (y[n] - \bar{y})^2}{N - 1}} \quad (7.5)$$

onde N é o número de amostras do sinal discreto no tempo $\{y[n]\}$ e \bar{y} é a sua média aritmética.

Os sinais $\{s_1[n]\}$ e $\{s_2[n]\}$ podem representar mais de uma classe de distúrbios e, portanto, o uso de uma extração de parâmetros mais elaborada, de forma a maximizar as fronteiras de separação entre estes distúrbios, foi utilizada. Neste caso, a metodologia baseada em EOS, proposta e aplicada com bastante sucesso no capítulo anterior, foi aplicada aos sinais $\{s_1[n]\}$ e $\{s_2[n]\}$.

Após a extração e seleção dos cumulantes, são obtidos os vetores de parâmetros (\mathbf{p}_{s1} e \mathbf{p}_{s2}) relativos aos sinais $\{s_1[n]\}$ e $\{s_2[n]\}$, respectivamente, con-

forme mostra a Figura 7.25. Cada vetor é composto por 16 parâmetros, sendo 8 cumulantes de segunda ordem e 8 de quarta ordem. O número de parâmetros foi escolhido na fase de treinamento do classificador, de forma a maximizar o desempenho do mesmo.

Sabe-se que os afundamentos, elevações e interrupções de tensão se diferenciam, principalmente, pela amplitude do componente fundamental, conforme mostra a Tabela 2.1. Assim, a partir de $f[n]$, os seguintes parâmetros foram extraídos: a amplitude do componente fundamental (60 Hz), que foi estimada utilizando o filtro de Fourier de 1 ciclo, conforme descrito na Anexo E e os cumulantes de segunda e quarta ordem de $f[n]$, selecionados pelo critério FDR. Conforme mostrado no capítulo anterior, os cumulantes podem levar a um espaço de parâmetros em que os eventos de afundamentos, elevações e interrupções de tensão podem ser facilmente separados.

Etapa de Classificação

Na etapa de classificação baseada na análise do sinal de erro $\{e[n]\}$, utilizam-se \mathbf{p}_{s1} , \mathbf{p}_{s2} e $RMS(s_3)$, que são os vetores de parâmetros extraídos dos sinais $s_1[n]$, $s_2[n]$ e $s_3[n]$, respectivamente, sendo que o último é composto por um único parâmetro, o valor RMS do sinal $s_3[n]$. Na etapa referente à análise do sinal $f[n]$, utiliza-se o vetor \mathbf{p}_f como parâmetro.

Quatro classificadores independentes são utilizados para classificar os distúrbios associados ao sinal $v[n]$, conforme mostra a Figura 7.26. O bloco Lógica de Decisão implementa o algoritmo que decide sobre a ocorrência das diferentes classes de distúrbios que aparecem no sinal monitorado.

Os blocos Classificador Neural 1 e Classificador Neural 2 são constituídos por uma rede neural artificial (RNA) de três camadas [82], de modo a explorar a informação EOS. O bloco Limiar de Decisão é constituído por uma fronteira linear, de modo que valores de $RMS(s_3)$ acima de um patamar (α), previamente definido com dados de treinamento, indicam distúrbios de *notches*. O Classificador Bayesiano é responsável por definir entre afundamentos, elevações, interrupções de tensão ou componente fundamental nominal. O classificador bayesiano realiza a classificação baseada no critério ML (*Maximum Likelihood*) [16].

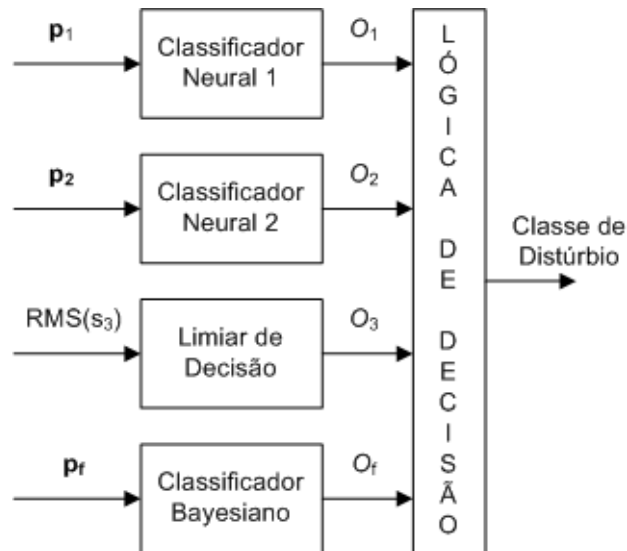


Figura 7.26: Diagrama em blocos do Classificador Final

As RNAs utilizadas foram compostas por 16 nós de entrada, referentes aos 8 cumulantes de segunda e quarta ordem selecionados utilizando o critério de maior FDR, 10 neurônios na única camada oculta e quatro nós de saída. Os nós de saída são associados, na rede referente ao classificador 1, às classes de harmônicos, impulsos, afundamentos/interrupções/elevações de tensão e sinais sem estes distúrbios.

Já os nós de saída da rede neural referente ao classificador 2 representam as classes de *notches*, impulsos, transitório oscilatório e sinais sem estes distúrbios. O nó de saída que apresentar o maior valor define a qual classe de distúrbio o evento pertence.

De fato, os quatro classificadores abordam algumas classes de distúrbios em comum, como os classificadores 2 e 3, ambos utilizados para a identificação da classe de notches. Neste caso, como o classificador 3 é especialista em *notches*, sua saída terá prioridade quanto à afirmação da ocorrência ou não do *notch* na lógica de decisão final. Para isso, o bloco Lógica de Decisão implementa uma lógica, baseada na saída dos classificadores, que decide qual ou quais distúrbios apareceram na janela de sinal de tensão em análise, resultando na saída final do classificador.

7.3.2 Metodologia

Neste trabalho, foram abordadas seis classes de distúrbios isolados, oito classes com ocorrência simultânea (múltiplos distúrbios) envolvendo dois distúrbios

e quatro classes de múltiplos distúrbios envolvendo três distúrbios. As classes são:

1. Interrupções de tensão (S1);
2. Harmônicos (S2);
3. Afundamento de tensão (S3);
4. Elevação de tensão (S4);
5. Transitório Oscilatório (S5);
6. Notch (S6);
7. Impulsos (S7);
8. Afundamento de tensão com harmônicos (S8);
9. Elevação de tensão com harmônicos (S9);
10. Afundamento de tensão com transitório oscilatório (S10);
11. Elevação de tensão com transitório oscilatório (S11);
12. Afundamento de tensão com notch (S12);
13. Elevação de tensão com notch (S13);
14. Notch com harmônicos (S14);
15. Transitório oscilatório com harmônicos (S15);
16. Afundamento de tensão com transitório oscilatório e harmônicos (S16);
17. Afundamento de tensão com notch e harmônicos (S17);
18. Elevação de tensão com notch e hamônicos (S18);
19. Elevação de tensão com transitório oscilatório e harmônicos (S19).

Para o projeto e teste do sistema proposto, foram utilizados 1.000 eventos simulados de cada classe de distúrbios (S1-S19). Estes sinais foram gerados sinteticamente, conforme descrito no Capítulo 3.

Dos 1.000 eventos gerados para cada classe, 200 foram usados para treinamento dos classificadores, 300 para validação e 500 foram utilizados para o teste.

Para avaliar a eficiência do sistema proposto em dados experimentais, duas formas de onda da tensão com ocorrências de múltiplos distúrbios, adquiridos pelo grupo de trabalho do IEEE (*working group* P1159.3), foram apresentadas ao sistema proposto. Estas formas de onda estão ilustradas na Figura 7.27.




Figura 7.27: Formas de onda de aquisições reais do sinal de tensão com distúrbios múltiplos de transitórios oscilatórios e afundamento de tensão em (a) e transitórios oscilatórios, harmônicos e afundamento de tensão em (b)

7.3.3 Resultados e Discussões

Esta seção apresenta os resultados e discussões do sistema proposto para as aplicações em dados de teste simulados e experimentais.

Dados Simulados

Os resultados finais do classificador, para os eventos de validação, são mostrados na Tabela 7.1, onde pode-se observar que o desempenho na classificação para distúrbios isolados é muito bom, com a eficiência se situando acima de 99,0 % (S1-S7). Para distúrbios múltiplos (S8-S19), o desempenho cai levemente, com a eficiência de classificação ficando acima de 97,2%. Uma eficiência global de 99,1 %, considerando-se a média aritmética dos desempenhos obtidos para cada classe de distúrbio, foi alcançada.

Tabela 7.1: Matriz de confusão para a classificação relativa ao conjunto de teste.

(%)	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10	S11	S12	S13	S14	S15	S16	S17	S18	S19
S1	100																		
S2	0,0	99,0																	
S3	0,0	0,0	100																
S4	0,0	0,0	0,0	100															
S5	0,0	1,0	0,0	0,0	99,0														
S6	0,0	0,0	0,0	0,0	0,0	100													
S7	0,0	0,0	0,0	0,0	0,0	0,0	100												
S8	0,0	0,2	0,8	0,0	0,0	0,0	0,0	99,0											
S9	0,0	0,0	0,0	2,8	0,0	0,0	0,0	0,0	97,2										
S10	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	100									
S11	0,0	0,0	0,0	0,0	0,6	0,0	0,0	0,0	0,0	0,0	99,4								
S12	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	100							
S13	0,0	0,0	0,0	0,0	0,0	1,0	0,0	0,0	0,0	0,0	0,0	0,0	99,0						
S14	0,0	0,0	0,0	0,0	0,0	0,6	0,0	0,0	0,0	0,0	0,0	0,0	0,0	99,4					
S15	0,0	0,8	0,0	0,0	1,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	98,2				
S16	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,6	0,0	1,2	0,0	0,0	0,0	0,0	0,0	98,2			
S17	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,2	0,0	0,4	0,0	0,0	98,4		
S18	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	1,2	0,0	0,0	0,0	0,0	98,8	
S19	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,2	0,0	2,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	97,8

A Tabela 7.1 mostra a matriz de confusão do classificador, permitindo uma análise mais detalhada do seu desempenho. É importante verificar que, para os casos de múltiplos distúrbios, quando o classificador erra, o resultado é apontado para um dos distúrbios que compõe o múltiplo distúrbio analisado. Para as classes de múltiplos distúrbios compostas por dois distúrbios (S8-S15), o percentual de erro do classificador sempre aponta para uma das classes que compõe o múltiplo distúrbio e, para as classes compostas por três distúrbios (S16-S19), o percentual de erro do classificador se concentra sempre em uma classe de dois distúrbios que faz parte da classe original (com três distúrbios). Portanto, nestes casos, pode-se dizer que o classificador acertou parcialmente a classificação, omitindo a ocorrência de um dos distúrbios que compõe o múltiplo distúrbio analisado.

Como os eventos de harmônicos, impulsos e *notches* são avaliados por mais de um classificador, a lógica final, implementada no bloco Decisor Classe (vide Fig. 7.26) bloqueia a saída dos classificadores com desempenho inferior para estas classes, deixando a classificação destes distúrbios restrita ao classificador com melhor desempenho. Isso explica o fato do erro de 1 % para a classe S1 (vide Tab. 7.1) não aparecer em outras classes, ou seja, neste caso, o classificador apontou os eventos relacionados a este percentual de erro para uma classe cuja saída foi bloqueada pela lógica final.

Dados Experimentais

Nesta etapa, as formas de onda mostradas na Figura 7.27 foram utilizadas como exemplo de aplicação, conforme mencionado na Seção 7.3.2.

Pode-se verificar a presença de um leve transitório oscilatório de curta duração seguido de um afundamento de tensão na forma de onda da Figura 7.27 (a). O sistema proposto acertou a classificação deste sinal, apontando-o como um múltiplo distúrbio de transitório oscilatório com afundamento de tensão, classe S9, conforme esperado.

Na Figura 7.27 (b), pode-se observar a presença de um transitório oscilatório de curta duração, com uma intensidade superior ao da Figura 7.27 (a), seguido de afundamento de tensão, suaves transitórios e harmônicos. O sistema proposto, classifica este sinal, como pertencente à classe S15, referente a afundamento de

tensão, com transitório oscilatório e harmônicos.

É importante ressaltar que o banco de dados reais do IEEE utilizado neste exemplo é composto de 60 formas de ondas com diferentes ocorrências de distúrbios. No entanto, não há uma classificação prévia destes e, portanto, as duas formas de ondas mostradas na Figura 7.27 foram escolhidas devido à possibilidade de caracterização visual.

Os resultados dos dois exemplos mostram o potencial do método proposto para aplicações com dados reais.

Capítulo 8

Análise de Componentes Independentes

Este capítulo introduz a técnica de análise de componentes independentes para a estimação de distúrbios elétricos a partir de múltiplos distúrbios. O principal objetivo é desenvolver uma técnica via ICA que permita o desacoplamento dos múltiplos distúrbios para posterior análise e classificação destes.

8.1 Contextualização do Problema

O sinal de tensão do sistema de potência pode ser modelado pela combinação linear do componente fundamental e as parcelas de sinal referente a cada distúrbio. Esta formulação é similar ao modelo de misturas utilizado pela técnica Análise de Componentes Independentes (*ICA-Independent Component Analysis*) [103] (veja o Anexo F). Assim, a partir do sinal de tensão contendo múltiplos distúrbios, é possível estimar cada componente, que representaria um distúrbio isolado. A utilização da ICA para análise de distúrbios de qualidade de energia foi introduzida em [104, 105], em que um banco de filtros foi utilizado para, a partir do sinal monitorado $v[n]$, gerar novos sinais (as saídas dos filtros), que formarão a matriz de misturas a ser apresentada ao algoritmo ICA. No entanto, mostrou-se no capítulo anterior que um banco de filtros, projetados de acordo com as características espectrais dos distúrbios, pode desacoplá-los. Neste capítulo, uma abordagem diferente de [104, 105] será proposta.

Para utilização desta abordagem, deve-se garantir que os distúrbios originais são, em cada instante de tempo, estatisticamente independentes. Conceitualmente, variáveis aleatórias, y_1, y_2, \dots, y_N , serão independentes se a informação contida em y_i não fornecer nenhuma informação sobre y_j , para $i \neq j$. Em se tratando de distúrbios elétricos, isto significa que a informação de um distúrbio não fornece nenhuma informação sobre outros distúrbios. Para averiguar esta independência, a correlação linear (CL), a correlação não linear (CNL) e a informação mútua (IM) entre as fontes originais dos distúrbios foram calculadas. A Tabela 8.1 ilustra estas medidas entre as fontes de harmônicos e transitórios oscilatórios e as fontes de harmônicos e *notches*, que serão abordadas neste capítulo. Para estes resultados, considerou-se a média aritmética das medidas extraídas do banco de distúrbios previamente separado para o treinamento, conforme a metodologia descrita no Capítulo 3. Observa-se que as correlações linear e não linear apontam para a independência entre as fontes. Por outro lado, a IM mostra que as fontes não são tão independentes, e que as fontes de harmônicos são mais independentes das fontes de transitórios oscilatórios do que das de *notches*.

Tabela 8.1: Medidas de independência entre as fontes originais dos distúrbios.

Fontes	Harmônicos e Trans. Oscil.	Harmônicos e <i>Notches</i>
CL	$0,0171 \pm 0,0019$	$0,0308 \pm 0,0029$
CNL	$0,0172 \pm 0,0018$	$0,0308 \pm 0,0028$
IM (histograma)	$0,4719 \pm 0,0079$	$0,8247 \pm 0,0040$
IM (kernel)	$0,1842 \pm 0,0387$	$0,9978 \pm 0,0001$

Adicionalmente, supõe-se que os distúrbios originais possuem distribuições não-gaussianas. A fim de verificar o quão realística é esta suposição, a medida de *kurtosis* [83], para cada fonte de distúrbios do conjunto de treinamento, foi obtida. Conforme bem discutido em [83], *kurtosis* elevada é obtida quando a distribuição do sinal é não gaussiana. A Tabela 8.2 mostra o cálculo da média aritmética da *kurtosis* para as fontes de transitórios oscilatórios, harmônicos da mistura com transitórios oscilatórios (M1), harmônicos da mistura com *notches* (M2), e *notches*. Os resultados foram normalizados, ou seja, *kurtosis* nula será obtida quando o sinal for gaussiano. Os resultados mostram que os transitórios oscilatórios e os *notches* são não gaussianos. Por outro lado, os harmônicos mostram-se mais gaussianos.

Conforme apontado em [103], é possível extrair no máximo uma fonte gaus-

Tabela 8.2: Medida normalizada de gaussianidade das fontes de distúrbios.

	Fontes
Transitórios Oscilatórios	$67,7291 \pm 2,0390$
Harmônicos de M1	$0,5100 \pm 0,0380$
Harmônicos de M2	$0,6097 \pm 0,0392$
<i>Notches</i>	$15,9000 \pm 0,0012$

siana como componente independente via ICA. Neste capítulo, os esforços serão concentrados nas misturas de harmônicos com transitórios oscilatórios (M1) e harmônicos com *notches*. Estas misturas serão analisadas individualmente e, portanto, a característica gaussiana da fonte de harmônicos não será um impedimento à aplicação ICA.

Contudo, na aplicação da ICA para desacoplar múltiplos distúrbios, normalmente dispõe-se de apenas uma mistura, que é o sinal de tensão contendo os distúrbios, supondo apenas um monitor de qualidade de energia ligado a um determinado ponto do sistema de potência. Neste caso, o número de misturas (M) será menor que o número fontes (N distúrbios). Este caso é conhecido na literatura como sub-determinado (*overcomplete ou underdetermined*) [106]. Alguns autores propuseram soluções para este problema [106–108]. Entretanto, tais soluções, em geral, demandam alto custo computacional e são desenvolvidas para aplicações específicas.

O problema da ICA com apenas uma mistura (um canal) é conhecido na literatura como uma extensão do caso sub-determinado, e é chamado de *single channel ICA* (SCICA). O trabalho [109] aborda em detalhes este problema, com aplicações em eletroencefalograma e eletrocardiograma. Neste capítulo, esta metodologia, baseada em SCICA, será estendida ao problema de múltiplos distúrbios. A Figura 8.1 ilustra a ideia geral de um sistema de desacoplamento de múltiplos distúrbios baseado em ICA. Note que os componentes independentes dados pelo método SCICA representam a estimativa de cada distúrbio isolado e, portanto, a partir disso, métodos simples de classificação e/ou análise de distúrbios isolados podem ser aplicados.

Uma das vantagens destes métodos de desacoplamento via ICA é que o resultado final, teoricamente, é a estimativa de cada distúrbio presente na mistura, o que permite posteriores análises em cada evento individualmente, em contrapartida




Figura 8.1: Sistema genérico de desacoplamento de múltiplos distúrbios via ICA.

a outros métodos que permitem apenas a classificação.

Neste capítulo, a abordagem SCICA aplicada às misturas M1 e M2 será explorada sob o ponto de vista de estimativa dos distúrbios e de classificação dos mesmos. Para tal, medidas quantitativas e análises qualitativas serão utilizadas, em que sinais simulados e experimentais serão testados. Será verificada também a influência do comprimento da janela de aquisição do sinal nas estimativas dos distúrbios. O desempenho do método para aquisições com elevada taxa de ruído será também analisado. Por último, os efeitos do branqueamento das misturas formadas por distúrbios serão também investigados, já que para a maioria dos algoritmos ICA, o branqueamento executa uma importante tarefa de pré-processamento.

8.2 SCICA

Para aplicar a técnica ICA em um único canal (mistura), é preciso formar uma representação de dados multi-canais, que pode ser feita gerando vetores com atrasos temporais a partir do dado observado $x[n]$. Assim, obtém-se uma matriz de misturas composta por versões do sinal observado deslocadas no tempo, como:

$$\mathbf{X} = \begin{pmatrix} x[n] \\ x[n-1] \\ \vdots \\ x[n-M+1] \end{pmatrix}. \quad (8.1)$$

Conforme apontado em [109], para garantir que as fontes possam ser separadas com sucesso pela ICA é preciso que elas possuam espectros distintos. A Figura 8.2 ilustra o modelo de misturas SCICA genérico. De acordo com [110], este processo pode ser representado pela soma de séries convolutivas, em que os M sinais $a_i[n]$ são convoluídos com a resposta ao impulso dos M filtros $s_i[n]$. Neste caso, assume-se

que as respostas ao impulso são estatisticamente independentes e representam as fontes originais da mistura $x[n]$. Adicionalmente, é possível interpretar o modelo de misturas linear para o caso de uma única mistura como [103]:

$$x[n] = \sum_{i=1}^M s_i[n] * a_i[n], \quad (8.2)$$

em que $*$ denota convolução.




Figura 8.2: Modelo de misturas SCICA genérico.

Em resumo, as fontes de sinais s_i representam repostas ao impulso de um filtro FIR, e os sinais $a_i[n]$ são as colunas da matriz de mistura \mathbf{A} .

Em [109], mostrou-se que a ICA aplicada a \mathbf{X} , produzida pelas cópias deslocadas da mistura $x[n]$, gera vetores bases \mathbf{a}_i que podem ser agrupados em um subconjunto γ^p . Estes vetores bases tendem a ser aproximações deslocadas de filtros individuais, tal que todos os vetores bases associados a um subconjunto particular terão características espectrais similares. Portanto, a estimativa de cada componente independente pode ser dada pela adição das contribuições das versões filtradas da mistura $x[n]$, onde os coeficientes do filtro são dados pelas linhas da matriz de separação \mathbf{W} . Neste caso, a ordem do filtro será dada pelo número de deslocamentos menos 1 ($M - 1$).

8.3 SCICA para o Desacoplamento de Distúrbios de QEE

Nesta seção, a aplicação do método SCICA, conforme [110], em sinais de tensão com múltiplos distúrbios será abordada. Inicialmente, o modelo SCICA será

testado, do ponto de vista de QEE e, em seguida, serão apresentadas e discutidas as vantagens e desvantagens do método.

8.3.1 Análise Qualitativa

Para iniciar a aplicação do método SCICA aos sinais de tensão, consideremos duas classes de múltiplos distúrbios: (M1) harmônicos com transitórios oscilatórios e (M2) harmônicos com *notches*. A Figura 8.3 ilustra estes distúrbios, contendo 4 ciclos do componente fundamental. Estes distúrbios foram gerados considerando-se uma SNR de 100 dB e frequência de amostragem $f_s = 15.360 \text{ Hz}$.




Figura 8.3: Múltiplos distúrbios: (a) Harmônicos com transitório oscilatório e (b) Harmônicos com *notches*.

Estes múltiplos distúrbios foram então pré-processados, filtrando-se o componente fundamental. O sinal restante $e[n]$ foi apresentado ao método SCICA, conforme ilustra o diagrama em blocos da Figura 8.4.




Figura 8.4: SCICA aplicado a sinais de tensão.

Geralmente, para as aplicações de SCICA, um número elevado de versões deslocadas da mistura observada é apresentado à técnica ICA. Contudo, como na presente análise de sinais de tensão foi considerada inicialmente apenas misturas com dois distúrbios (duas fontes), o estudo terá como partida a seguinte matriz de

misturas:

$$\mathbf{X} = \begin{pmatrix} e[n] \\ e[n-1] \end{pmatrix}, \quad (8.3)$$

em que $n = 1, 2, \dots, N$, para $N = 1.024$ amostras, o que equivale a quatro ciclos do componente fundamental do sinal de tensão. Assim, a matriz \mathbf{X} é da ordem $M \times N$, em que $M = 2$.

Em seguida, o vetor de misturas foi apresentado ao algoritmo FastICA [111], que implementa a ICA utilizando o algoritmo do ponto fixo, maximizando a não-gaussianidade dos dados como medida de independência (ver o Anexo F). Os componentes independentes obtidos são mostradas nas Figuras 8.5 e 8.6, assim como as suas correspondentes fontes originais. Note que os componentes independentes foram normalizados pelo valor máximo absoluto do sinal.




Figura 8.5: Componentes independentes da mistura de harmônicos com transitório oscilatório e suas correspondentes fontes originais utilizadas para gerar a mistura M1.

Qualitativamente, a similaridade entre os componentes independentes obtidos e as fontes originais pode ser claramente observada. Entretanto, pequenas interferências provenientes das misturas estão presentes nos componentes independentes.

Para obtenção de um desempenho ótimo na aplicação do modelo SCICA, deve-se assegurar que as fontes de distúrbios possuam espectros distintos (disjuntos) [110]. As Figuras 8.7 e 8.8 mostram os espectros normalizados das fontes originais $\{s_1[n]\}$ e $\{s_2[n]\}$ que compõem, respectivamente, as misturas M1 e M2, e dos respectivos componentes independentes $\{y_1[n]\}$ e $\{y_2[n]\}$. Pode-se observar, claramente




Figura 8.6: Componentes independentes, da mistura de harmônicos com *notches* e suas fontes originais, utilizadas para gerar a mistura M2.

que os espectros das fontes originais possuem pouca interseção. Já nos componentes independentes obtidos pelo modelo SCICA, interseções entre os espectros podem ser mais claramente observadas. Estas interseções são causadas pelo resíduo proveniente das misturas em cada uma das estimativas, em função da utilização de apenas um único sinal deslocado para formar a matriz de observações.

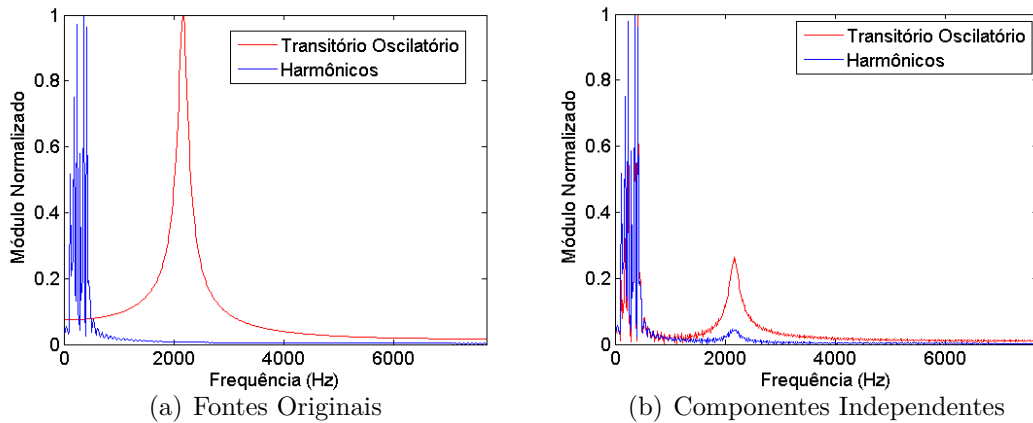


Figura 8.7: Espectro normalizado das fontes de transitório oscilatório e harmônicos que compõem a mistura M1 e das respectivas estimativas.

Uma forma interessante de verificar a adequação do modelo SCICA aos sinais de tensão corrompidos por distúrbios se dá a partir das fontes originais, $\{s_1[n]\}$ e $\{s_2[n]\}$ e da matriz de mistura $\mathbf{B} = \mathbf{W}^{-1}$ obtida pelo algoritmo FastICA, como uma estimativa da matriz original \mathbf{A} . Assim, é possível obter a mistura observada $e[n]$ através da Equação (8.2), que representa o modelo de misturas mostrado na Figura 8.2. A Figura 8.9 ilustra a mistura original $e[n]$ para harmônicos com transitórios

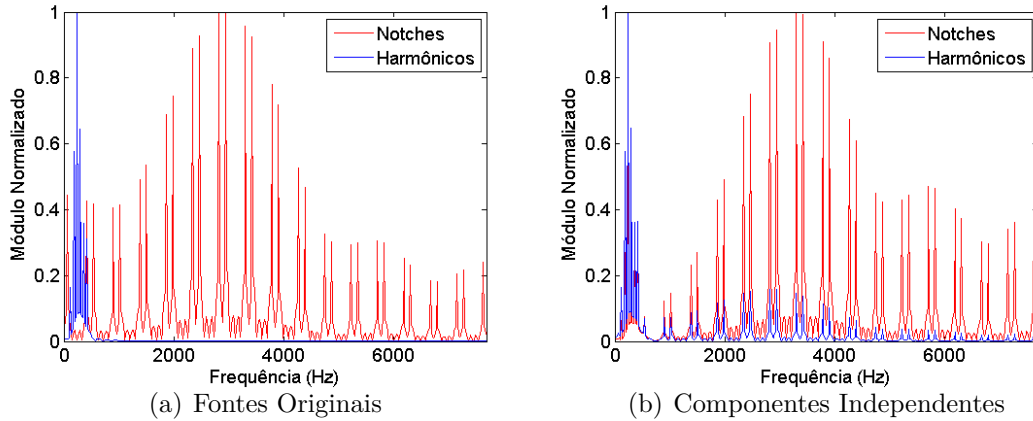


Figura 8.8: Espectro normalizado das fontes de *notches* e harmônicos que compõem a mistura M2 e das respectivas estimativas.

oscilatórios e a mistura obtida pelo modelo convolutivo SCICA. Pode-se observar a semelhança entre os sinais. Esta semelhança pode ser comprovada quantitativamente utilizando-se o índice MSE (*Mean Squared Error*) entre o sinal $e[n]$ original e o modelado, que neste caso resultou em 0,0264, mostrando a similaridade entre os sinais. Visando generalizar as conclusões do resultado anterior, 250 misturas de harmônicos com transitórios oscilatórios foram geradas a partir de 250 fontes de harmônicos e 250 de transitórios oscilatórios. A reconstrução de $e[n]$ foi então processada e a média aritmética do índice MSE entre o $e[n]$ modelado e o original, para as 250 misturas, foi de $0,0235 \pm 0,0005$, com 95% de confiança. Em seguida, 250 novas fontes de harmônicos e transitórios oscilatórios foram geradas. Utilizando-se as matrizes \mathbf{W} obtidas com o banco de dados anterior, tentou-se reconstruir $e[n]$ a partir destas novas fontes que, obviamente, não deram origem às misturas. A média do índice MSE entre o novo $e[n]$ modelado e o original foi então de $0,1192 \pm 0,0034$. Portanto, pode-se concluir que o modelo convolutivo SCICA, equacionado em (8.2) e ilustrado na Figura 8.2, se aplica com boa generalização. A reprodução destes resultados para a mistura M2 (harmônicos com *notches*) será omitida por simplificação.

Como a própria formulação do problema utiliza sinais deslocados no tempo, é interessante também verificar se o sinal $e[n]$, obtido pelo modelo, está deslocado ou não em relação ao sinal original. Para isso, utilizou-se a correlação cruzada entre a mistura original $e[n]$ e a mistura obtida pelo modelo convolutivo SCICA. A Figura 8.10 mostra, por meio da correlação cruzada que os sinais $e[n]$, original e modelado, estão alinhados no tempo, já que o pico máximo da correlação cruzada coincide com




Figura 8.9: Comparação entre a mistura original $e[n]$ e a mistura obtida pelo modelo SCICA.

a defasagem zero.




Figura 8.10: Correlação cruzada entre a mistura original e a obtida pelo modelo SCICA.

Objetivando melhorar a qualidade dos componentes independentes estimados, considerou-se uma terceira versão de $e[n]$, formando a matriz de misturas dada por:

$$\mathbf{X} = \begin{pmatrix} e[n] \\ e[n-1] \\ e[n-2] \end{pmatrix}. \quad (8.4)$$

Neste caso, $M = 3$ e, portanto, mais informação sobre a mistura $e[n]$ está disponível e, assim, a mistura pode ser melhor representada [109].

A Figura 8.11 ilustra os componentes independentes obtidos para a mistura de harmônicos com transitório oscilatório e harmônicos com *notches*. Observa-se que, dos três componentes independentes para ambas as misturas, dois são estimati-

vas dos transitórios e o terceiro é a estimativa dos harmônicos. Das duas estimativas de transitórios, uma sofre menos interferência da mistura e, apresenta-se visualmente melhor do que aquelas estimadas para o caso $M = 2$. As estimativas de harmônicos também são visualmente melhores do que as estimativas do caso $M = 2$. A Figura 8.12 ilustra o espectro normalizado dos componentes independentes obtidos para ambas as misturas considerando-se $M = 3$. Estes espectros referem-se aos componentes $y_1[n]$ e $y_3[n]$. Neste caso, observa-se que os espectros entre os componentes independentes obtidos possuem menos interseção do que para o caso $M = 2$, o que se justifica pela obtenção de melhores estimativas.




Figura 8.11: Componentes independentes da mistura de harmônicos com transitório oscilatório em (a) e harmônicos com *notches* em (b).

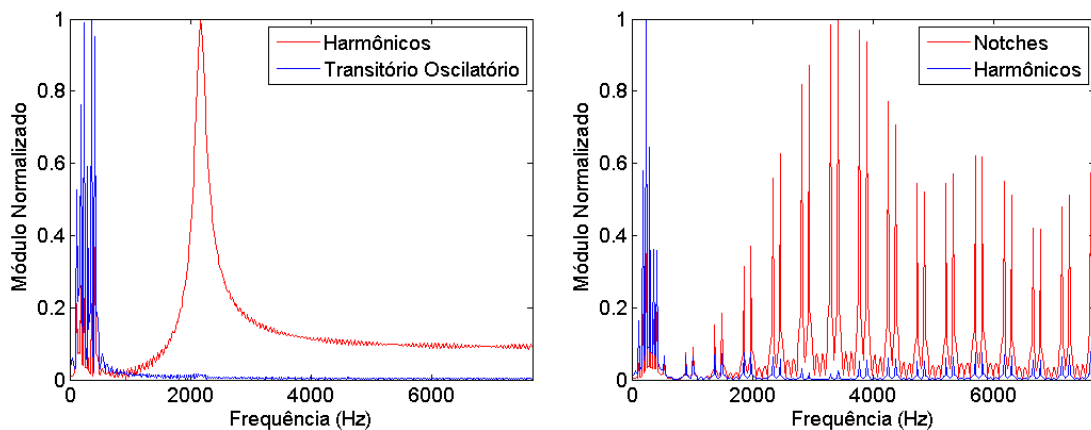


Figura 8.12: Espectro normalizado dos componentes independentes obtidos para o caso $M = 3$.

A análise anterior foi também reproduzida para $M = 4$, ou seja:

$$\mathbf{X} = \begin{pmatrix} e[n] \\ e[n-1] \\ e[n-2] \\ e[n-3] \end{pmatrix}. \quad (8.5)$$

Os componentes independentes obtidos são mostradas na Figura 8.13. Dos quatro componentes, três são estimativas dos transitórios e o quarto é a estimativa dos harmônicos. Por inspeção visual, observa-se que os harmônicos estão mais isentos de ruídos provenientes da mistura do que aqueles obtidos para $M = 2$ e $M = 3$. Os espectros normalizados dos componentes $y_2[n]$ e $y_4[n]$ de cada mistura são ilustrados na Figura 8.14. Aparentemente, os espectros referentes à mistura M2 são semelhantes aos obtidos com os componentes do caso $M = 3$. Já os espectros referentes à mistura M1 apresentam menor interferência entre si do que aqueles obtidos com os componentes do caso $M = 3$. Nesta etapa, é fundamental se apoiar em medidas quantitativas para dar continuidade às análises.




Figura 8.13: Componentes independentes da mistura de harmônicos com transitório oscilatório em (a) e harmônicos com *notches* em (b).

8.3.2 Análise Quantitativa

A análise qualitativa das formas de onda dos componentes independentes obtidos por ICA e dos seus espectros é interessante e elucida boa parte das questões. Contudo, alguns critérios podem ser utilizados para quantificar a qualidade das




Figura 8.14: Espectro normalizado dos componentes independentes obtidos para o caso $M = 4$.

estimativas e do processo de estimação das fontes. Nesta trabalho, os critérios adotados foram:

- (i) **Informação mútua (IM) (vide Anexo F).** A IM foi normalizada [112], de forma que os resultados estarão entre 0 (ausência de informação mútua) e 1 (máximo de informação mútua). Neste caso, a pdf foi estimada utilizando-se histogramas [113] e kernel adaptativo [114]. Ambos os resultados serão mostrados;
- (ii) **Correlação Linear (CL);**
- (iii) **Correlação Não-linear (CNL) (vide Anexo F).** Utilizou-se a função tangente hiperbólica em um dos sinais.
- (iv) **Razão Residual (Rr).** A razão residual é um índice bastante intuitivo e aqui proposto para quantificar a quantidade de resíduo proveniente da mistura de distúrbios, presente na estimativa obtida pela ICA. A razão residual (Rr) pode ser computada conforme a Equação (8.6), em que N é o número de amostras na janela de sinal analisada, $y(n)$ é a componente independente estimada pela ICA e $s(n)$ é a fonte original de $y(n)$.

$$Rr = \frac{\sum_{n=1}^N [s(n) - y(n)]^2}{\sum_{n=1}^N s^2(n)} \quad (8.6)$$

De acordo com (8.6), quanto melhor for a estimativa de $s(n)$, mais próximo de

zero será o resultado de Rr . De forma similar ao índice MSE, a razão residual estima a diferença entre a fonte estimada e o valor verdadeiro (fonte original), porém, relativamente à fonte original.

(v) Diferença Espectral. Este critério é extremamente coerente com a modelagem SCICA, já que as fontes originais devem possuir espectros distintos e, portanto, espera-se a mesma para os componentes independentes. A diferença espectral pode ser calculada por:

$$DE_{ij} = \sqrt{[\mathbf{P}_i - \mathbf{P}_j] \cdot [\mathbf{P}_i - \mathbf{P}_j]^T}, \quad (8.7)$$

em que, \mathbf{P}_i e \mathbf{P}_j são os vetores dos espectros dos componentes i e j , respectivamente. T denota transposto.

Em [103], foi proposto um índice para medir o desempenho estatístico do algoritmo ICA, definido como:

$$E_1 = \sum_{i=1}^m \left\{ \left(\sum_{k=1}^m \frac{|p_{ik}|}{\max_j |p_{ij}|} - 1 \right) + \left(\sum_{k=1}^m \frac{|p_{ki}|}{\max_j |p_{ji}|} - 1 \right) \right\}, \quad (8.8)$$

em que p_{ij} é o elemento da linha i e coluna j da matriz $m \times m$, $\mathbf{P} = \mathbf{WA}$. Quando a separação dos sinais é perfeita, o índice E_1 é zero. Pode-se utilizar no lugar do valor absoluto de p_{ij} , p_{ij}^2 . Neste caso, tem-se o índice E_2 .

Os múltiplos distúrbios utilizados na presente tese foram gerados considerando-se as normas do IEEE [1], e de acordo com a modelagem descrita no Capítulo 3, não atentando-se, portanto, à utilização de uma matriz de mistura \mathbf{A} para obter os múltiplos distúrbios. Logo, utilizou-se os índices alternativos, listados anteriormente de (i) a (v).

A fim de avaliar o processo de estimação das fontes, a correlação linear (CL), a correlação não-linear (CNL), a informação mútua (IM) e a diferença espectral (DE_{ij}) entre os componentes independentes foram comparadas com as mesmas medidas, entre as misturas, e entre as fontes. As Tabelas 8.3 e 8.4 mostram estes resultados, respectivamente, para as misturas de harmônicos com transitório oscilatório (M1) e harmônicos com *notches* (M2), em que os casos $M = 2$, $M = 3$ e $M = 4$ foram considerados. Estas medidas foram computadas para as misturas ilustradas




Figura 8.15: Sinais padrões utilizados na seleção das melhores componentes independentes para os casos $M = 3$ e $M = 4$.

na Figura 8.3 e suas correspondentes fontes e estimativas. Para os casos $M = 3$ e $M = 4$, selecionaram-se os dois componentes independentes menos corrompidos pela mistura para a obtenção das medidas. A seleção se deu pela correlação não linear dos componentes independentes com o padrão de cada classe de distúrbios. Assim, os dois componentes que obtiverem o maior índice de correlação são selecionados¹. A Figura 8.15 ilustra o sinal padrão utilizado para cada uma das classes.

A CL e a CNL apontam para decorrelação entre os componentes obtidos em ambas as misturas, similarmente à CL e à CNL entre as fontes. A IM entre os componentes independentes apresenta valores inferiores aos das misturas, porém superiores aos das fontes para os três casos $M = 2$, $M = 3$ e $M = 4$. Isso mostra que o algoritmo ICA buscou por componentes independentes, porém, aqueles obtidos são menos independentes do que as fontes originais, o que é comum na prática. É importante verificar que, de acordo com os valores da IM, os componentes obtidos para o caso $M = 4$ são mais independentes do que aqueles dos casos $M = 2$ e $M = 3$ para a mistura M1. Os valores dos parâmetros DE_{ij} mostram que os componentes independentes obtidos possuem espectros quase tão disjuntos quanto as fontes originais. Neste caso, observa-se que as fontes obtidas para $M = 4$ possuem os espectros mais disjuntos.

¹Nesta etapa, índices alternativos como a correlação linear e a informação mútua podem também ser utilizados.

Tabela 8.3: Medidas entre as misturas, entre as fontes e entre os componentes independentes para a mistura M1.

Sinais	Misturas \mathbf{X}	Fontes \mathbf{S}	Componentes \mathbf{Y}		
Medidas			$M = 2$	$M = 3$	$M = 4$
CL	0,95	0,00	0,00	0,00	0,00
CNL	0,95	0,00	0,00	0,01	0,00
IM (hist./kernel)	1,00/0,99	0,52/0,29	0,92/0,84	0,80/0,63	0,70/0,35
DE_{ij}	0,00	0,26	0,20	0,25	0,26

Tabela 8.4: Medidas entre as misturas, entre as fontes e entre os componentes independentes para a mistura M2.

Sinais	Misturas \mathbf{X}	Fontes \mathbf{S}	Componentes \mathbf{Y}		
Medidas			$M = 2$	$M = 3$	$M = 4$
CL	0,89	0,02	0,00	0,00	0,00
CNL	0,89	0,02	0,01	0,01	0,00
IM (hist./kernel)	0,99/0,99	0,81/1,00	0,96/0,96	0,94/0,94	0,96/0,94
DE_{ij}	0,00	0,27	0,16	0,18	0,19

Em geral, as medidas mostradas nas Tabelas 8.3 e 8.4 indicam que a abordagem utilizando três versões deslocadas de $e[n]$ ($M = 4$) leva a componentes mais independentes e com espectros mais disjuntos do que as outras abordagens ($M = 2$ e $M = 3$). Por outro lado, as abordagens $M = 3$ e $M = 4$, supondo que o número de fontes é conhecido, demandam o desenvolvimento de ferramentas para escolher as melhores componentes independentes.

Para quantificar a qualidade dos componente independentes obtidos com relação às correspondentes fontes originais, as medidas de CL, CNL, IM, DE_{ij} e Rr entre as fontes originais e as suas estimativas (componentes independentes) foram obtidas. As Tabelas 8.5 e 8.6 mostram estes resultados. Pode-se observar, em ambas as tabelas, que os valores para as medidas de CL, CNL, e IM foram mais significativos (com índices próximos ou iguais a 1) para as estimativas dos harmônicos. Isso mostra que os componentes independentes que carregam as informações dos harmônicos estão mais correlacionadas e mais estatisticamente dependentes das fontes originais do que as estimativas dos transitórios oscilatórios e *notches*. Os índices Rr que apresentam os menores valores são para as estimativas dos harmônicos. Isso mostra que tais estimativas carregam menos resíduos (interferências) provenientes da mistura do que as estimativas de transitórios oscilatórios e *notches*. Ademais, observa-se também que os harmônicos da mistura M1 (harmônicos com transitórios

oscilatórios) são melhores estimados do que os harmônicos da mistura M2 (harmônicos com *notches*).

Tabela 8.5: Medidas entre as fontes originais e os componentes independentes para a mistura M1.

Sinais	Harmônicos			Transitórios Oscilatórios		
Medidas	$M = 2$	$M = 3$	$M = 4$	$M = 2$	$M = 3$	$M = 4$
CL	0,96	0,99	0,99	0,86	0,91	0,86
CNL	0,96	0,99	0,98	0,85	0,93	0,86
IM (hist./kernel)	1,00/0,99	1,00/0,99	1,00/0,99	0,57/0,52	0,62/0,51	0,63/0,18
DE_{ij}	0,02	0,03	0,02	0,03	0,02	0,02
Rr	0,07	0,02	0,02	0,30	0,17	0,26

Tabela 8.6: Medidas entre as fontes originais e os componentes independentes para a mistura M2.

Sinais	Harmônicos			<i>Notches</i>		
Medidas	$M = 2$	$M = 3$	$M = 4$	$M = 2$	$M = 3$	$M = 4$
CL	0,93	0,97	0,95	0,62	0,80	0,85
CNL	0,94	0,97	0,95	0,64	0,77	0,83
IM (hist./kernel)	1,00/1,00	0,99/1,00	0,99/0,99	0,85/1,00	0,82/1,00	0,80/1,00
DE_{ij}	0,11	0,09	0,09	0,05	0,06	0,05
Rr	0,18	0,13	0,14	0,92	0,43	0,29

8.3.3 Análise com um Enfoque de Processamento Digital de Sinais

Conforme apontado em [110], as linhas da matriz de separação \mathbf{W} , obtida pelo algoritmo ICA, podem ser interpretadas como versões deslocadas do filtro de separação. Assim, supondo que

$$\mathbf{W} = \begin{pmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \end{pmatrix}, \quad (8.9)$$

então

$$\begin{pmatrix} y_1[n] \\ y_2[n] \end{pmatrix} = \begin{pmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \end{pmatrix} \begin{pmatrix} e[n] \\ e[n-1] \end{pmatrix}. \quad (8.10)$$

Reescrevendo a Equação (8.10) no domínio da transformada Z [85], tem-se:

$$Y_1[z] = w_{11}E[z] + w_{12}E[z]z^{-1} \quad (8.11)$$

e

$$Y_2[z] = w_{21}E[z] + w_{22}E[z]z^{-1}. \quad (8.12)$$

Assim, conforme discutido na Seção 8.2, os componentes estimados, $\{y_1[n]\}$ e $\{y_2[n]\}$, são versões filtradas do sinal $e[n]$, pelos filtros FIR:

$$H_1[z] = w_{11} + w_{12}z^{-1} \quad (8.13)$$

e

$$H_2[z] = w_{21} + w_{22}z^{-1}, \quad (8.14)$$

Observe que a ordem dos filtros é dada por $M - 1$, onde M é o número de linhas da matriz de separação \mathbf{W} .

A Figura 8.16 (a) e (b) ilustram as respostas em frequência dos filtros relacionados com os componentes independentes mostrados nas Figuras 8.5 e 8.6, respectivamente (para um único deslocamento $M = 2$). Os filtros em (a) implementam um passa-baixas com frequência de corte $fc = 3.456 Hz$ (Filtro 1) e um filtro passa-altas com frequência de corte $fc = 3.840 Hz$. Para a geração dos harmônicos, considerou-se até o sétimo harmônico, o que implica em uma frequência de no máximo $420 Hz$. O filtro passa-altas, neste caso, atenua os harmônicos, gerando o componente de transitórios oscilatórios. Por outro lado, o filtro passa-baixas atenua muito pouco o transitório, já que a frequência de oscilação considerada na sua geração foi de, no mínimo, $1.000 Hz$ e, no máximo, $2.500 Hz$. Os filtros em (b) implementam um passa-altas (Filtro 2), similar ao da Figura (a), e um filtro que é aproximadamente um passa-tudo com pequena atenuação para sinais de frequências mais altas.

Estendendo-se esta metodologia para o caso $M = 3$, obtém-se as respostas em frequência mostradas na Figura 8.17. Em (a), o Filtro 1 implementa um passa-altas com $fc \approx 4.680 Hz$, eliminando os harmônicos. O Filtro 2 também implementa um passa-altas com $fc \approx 2304 Hz$, dando origem ao transitório oscilatório com resíduos dos harmônicos. Diferentemente, o Filtro 3 implementa um rejeita-faixa, com frequências de corte $f_1 \approx 1.300 Hz$ e $f_2 \approx 4.900 Hz$, eliminando parte dos transitórios oscilatórios. Analogamente, em (b) os Filtros 1 e 2 implementam passa-altas com frequências de corte $fc \approx 3.000 Hz$ e $fc \approx 4.200 Hz$, respectivamente. Neste caso, o Filtro 2 atenua melhor os harmônicos do que o Filtro 1. Ambos dão




Figura 8.16: Resposta em frequência dos filtros formados pelas linhas da matriz \mathbf{W} para as misturas de harmônicos com transitório oscilatório (a) e harmônicos com *notches* (b). O Filtro 1 é formado pela linha 1 de \mathbf{W} e o Filtro 2 pela linha 2.

origem a componentes em que os *notches* são destacados. O Filtro 3 implementa um rejeita-faixa com frequências de corte $f_1 \approx 1.800 \text{ Hz}$ e $f_2 \approx 5.100 \text{ Hz}$, eliminando parte dos *notches*. Este filtro gera um componente independente que estima os harmônicos da mistura, porém, resíduos provenientes dos *notches* ainda aparecem, conforme mostra a Figura 8.11.




Figura 8.17: Resposta em frequência dos filtros formados pelas linhas da matriz \mathbf{W} para as misturas de harmônicos com transitório oscilatório (a) e harmônicos com *notches* (b). O Filtro 1 é formado pela linha 1 de \mathbf{W} , o Filtro 2 pela linha 2 e o Filtro 3 pela linha 3.

Finalmente, a Figura 8.18 ilustra as respostas em frequência dos filtros formados pelas linhas da matriz \mathbf{W} quando $M = 4$, em que (a) é referente à mistura M1 e (b) à mistura M2. Em (a) é importante observar os Filtros 2 e 4, que implementam passa-altas e rejeita-faixa, respectivamente. O passa-altas elimina quase

todos os harmônicos, com $f_c \approx 3.000 \text{ Hz}$, gerando o componente independente $y_2[n]$, ilustrado na Figura 8.13 (a). O rejeita-faixa elimina grande parte dos transitórios oscilatórios, com $f_1 \approx 1.400 \text{ Hz}$ e $f_2 \approx 3.600 \text{ Hz}$, dando origem ao componente $y_4[n]$, ilustrado na Figura 8.13 (a). Em (b), os filtros que levam aos componentes independentes com menor resíduo proveniente da mistura são os Filtros 1 e 4, que implementam passa-altas e rejeita-faixa, respectivamente. O passa-altas elimina os harmônicos, com $f_c \approx 3.000 \text{ Hz}$, e o rejeita-faixa atenua os notches presentes nos harmônicos. Estes filtros, portanto, dão origem aos componentes independentes $y_1[n]$ e $y_4[n]$, respectivamente, ilustrados na Figura 8.13 (b).

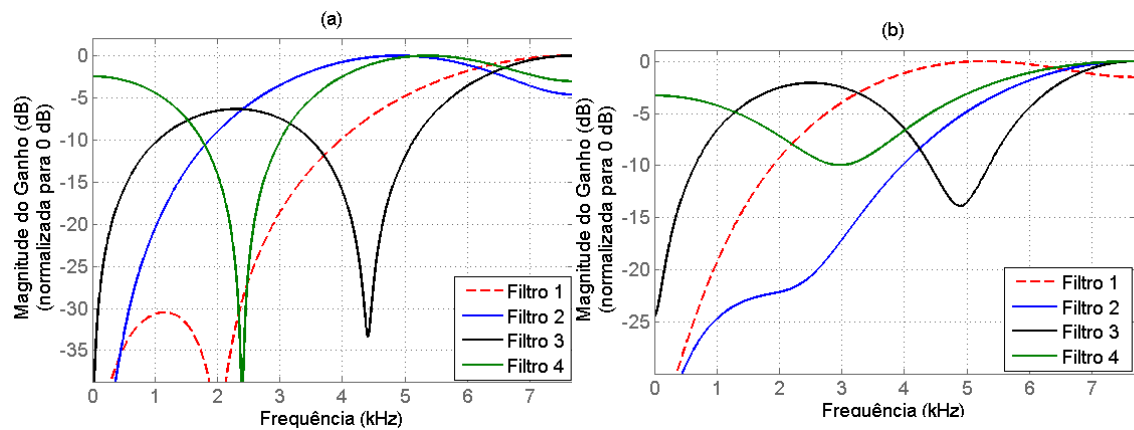


Figura 8.18: Resposta em frequência dos filtros formados pelas linhas da matriz \mathbf{W} para as misturas de harmônicos com transitório oscilatório (a) e harmônicos com *notches* (b). O Filtro 1 é formado pela linha 1 de \mathbf{W} , o Filtro 2 pela linha 2, o Filtro 3 pela linha 3 e o Filtro 4 pela linha 4.

Estas análises mostram que, com mais versões deslocadas de $e[n]$ na matriz de misturas \mathbf{X} , encontram-se filtros mais seletivos por frequência e, conseqüentemente, componentes independentes menos poluídas por resíduos provenientes da mistura serão obtidos. Isso se deve, também, ao fato de que o uso de mais versões deslocadas de $e[n]$ leva a filtros com ordem maior. A ordem dos filtros obtidos com $M = 2$, $M = 3$ e $M = 4$ é, respectivamente, 1, 2 e 3, o que justifica maior seletividade por frequência nos casos $M = 3$ e $M = 4$.

Para verificar o funcionamento das linhas matriz \mathbf{W} como filtros FIR, os sinais $e[n]$ e suas versões deslocadas foram processados pelos correspondentes filtros. Aqui serão mostrados apenas os resultados para $M = 3$ por simplicidade. As saídas dos filtros são mostradas na Figura 8.19 em (a), para a mistura M1, e em (b), para

a mistura M2. Pode-se observar que as saídas são similares às obtidas pelo ICA, ilustradas na Figura 8.11. Isto comprova o funcionamento das linhas de \mathbf{W} como filtros de separação.




Figura 8.19: Saída dos filtros formados pelas linhas da matriz \mathbf{W} para a abordagem $M = 3$.

8.4 Classificação de Distúrbios de QEE Através de Componentes Independentes

Para testar os componentes independentes estimados pelo algoritmo ICA, do ponto de vista de classificação de distúrbios, 500 misturas de harmônicos com transitórios oscilatórios (M1) e 500 de harmônico com notches (M2) foram geradas, com $f_s = 15.360$ Hz, $N = 1.024$ amostras e SNR de 100 dB, conforme descrito no Capítulo 3. Estes distúrbios compõem o banco de teste do método SCICA proposto.

Em seguida, 250 fontes de cada distúrbio (harmônicos, *notches* e transitórios oscilatórios) foram geradas. Estas fontes foram utilizadas para projetar um classificador de distúrbios isolados, utilizando-se EOS extraídas dos distúrbios como parâmetros e uma RNA *perceptron* multicamadas para classificação, conforme proposto no Capítulo 6. Destes 250, 150 de cada distúrbio foram utilizados para treino, e os 100 restantes para validar a RNA. O algoritmo de treinamento foi o RPROP. O critério de parada foi o de menor erro para o conjunto de sinais de treino aliado ao maior desempenho global (média aritmética do desempenho de cada classe) do conjunto de validação. A composição final da rede foi de 8 nodos de entrada, 4

neurônios na camada intermediária e 3 neurônios de saída, sendo um neurônio associado a cada classe. Os nodos de entrada são referentes ao cumulante de segunda e de quarta ordem de cada classe com maior capacidade de discriminação, segundo o critério de Fisher. O número de neurônios na camada intermediária foi escolhido com base no maior desempenho obtido para o conjunto de sinais de validação. A função de ativação utilizada foi a tangente sigmóide. O alvo da rede foram os vetores $[1 \ -1 \ -1]^T$, $[-1 \ 1 \ -1]^T$ e $[-1 \ -1 \ 1]^T$ para, respectivamente, transitórios oscilatórios, harmônicos e *notches*. O desempenho para o conjunto de treino e de validação foi de 100% para transitórios, 100% para harmônicos e 100% para *notches*.

Cumprе ressaltar que o classificador neural foi projetado utilizando-se as fontes originais dos distúrbios, que são isentas de resíduos. A próxima etapa compreende ao processamento das misturas de acordo com o modelo SCICA. Finalmente, os componentes independentes obtidos serão então apresentados ao classificador.

As 500 misturas geradas para testar o método SCICA foram então filtradas por um filtro notch, sintonizado em 60 Hz e, em seguida, gerou-se uma matriz de misturas, considerando-se as abordagens $M = 2$, $M = 3$ e $M = 4$. As matrizes de misturas foram então apresentadas ao algoritmo ICA. Os componentes independentes obtidos pelo ICA foram apresentados ao classificador. Para os casos $M = 3$ e $M = 4$, apenas dois componentes independentes, de cada mistura (M1 e M2), foram selecionados pela correlação não linear com os padrões ilustrados na Figura 8.15. Assim, os dois maiores valores da correlação entre o componente independente e os padrões das classes de distúrbios definiram quais os dois componentes independentes a serem apresentados ao classificador.

Existem, na literatura atual, diversos algoritmos, além do FastICA, que implementam a ICA [103]. O que difere um algoritmo do outro é, principalmente, a forma como a estatística de ordem superior é acessada. O algoritmo FastICA utiliza o algoritmo do ponto fixo, maximizando a não-gaussianidade [111]. Os algoritmos Sobi (*Second Order Blind Identification*) [115], SobiRo [116], Amuse [117] e dAmuse [118] utilizam a informação temporal dos dados. O algoritmo Akuzawa realiza a ICA pelo método do gradiente natural [119]. O algoritmo JADE (*Joint Approximate Diagonalization of Eigenmatrices*) [103] soluciona o problema de autovalores do tensor cumulante, realizando uma diagonalização do tensor através da

decomposição dos autovalores. Desta forma, uma análise dos diferentes algoritmos para obtenção dos componentes independentes, do ponto de vista de desempenho de classificação, é interessante. A Tabela 8.7 ilustra o desempenho do classificador para os componentes independentes obtidos por cada método. O índice p na tabela representa o deslocamento temporal utilizado na matriz de covariância dos dados, com relação aos métodos que utilizam a informação temporal.

Analisando-se os resultados da Tabela 8.7, observa-se que, em geral, os três casos $M = 2$, $M = 3$ e $M = 4$ levam a bons resultados, dado que o classificador foi projetado utilizando-se fontes originais, desprovidas de ruídos provenientes da mistura. Dentre os três casos, $M = 3$ alcançou melhores desempenhos. Os algoritmos ICA utilizados apresentaram desempenhos próximos, com exceção do Akuzawa, que obteve um desempenho consideravelmente inferior para os transitórios oscilatórios e *notches*. Exceto pelo Akuzawa, todos os algoritmos alcançaram um desempenho de 100% para as três abordagens ($M = 2$, $M = 3$ e $M = 4$) nas estimativas de *notches*. Para as estimativas de transitórios oscilatórios, com exceção do Akuzawa, os algoritmos alcançaram desempenhos semelhantes entre si para $M = 2$ (99,5%) e $M = 3$ (100%), enquanto que para $M = 4$ os algoritmos FastICA, Amuse, Sobi e dAmuse se destacaram com desempenhos superiores. Os harmônicos da mistura M1 foram melhores estimados pelos algoritmos FastICA, Amuse, JADE, Sobi e dAmuse na abordagem $M = 2$, com desempenhos de 97%. Na abordagem $M = 3$, desempenhos de 100% foram alcançados pelos algoritmos Amuse, Sobi e dAmuse para um deslocamento $p = 5$ na matriz de covariância. Para $M = 4$, desempenhos de 100% foram alcançados pelos algoritmos Amuse ($p = 5$), SobiRo ($p = 100$) e dAmuse ($p = 5$). Para os harmônicos da mistura M2, desempenhos de 100% foram obtidos na abordagem $M = 2$, para os algoritmos Amuse, Sobi e dAmuse. Já na abordagem $M = 3$, apenas o SobiRo ($p = 100$) alcançou 100% de desempenho. Os algoritmos Amuse, Sobi e dAmuse obtiveram 99,5%. Para a abordagem $M = 3$, o desempenho maior foi de 99,5% para os algoritmos Amuse ($p = 1, 5$), SobiRo ($p = 100$), Sobi e dAmuse.

Cumprе ressaltar que, em geral, as aplicações em EEG que utilizam o modelo SCICA, tais como [110] e [109], realizam elevados números de deslocamentos no sinal de mistura, de tal forma que M é da ordem de 100. Em seguida, utilizam-se

Tabela 8.7: Desempenho do classificador para as estimativas dos distúrbios por componentes independentes.

Eventos	Trans. Oscil.			Harmônicos de M1			Harmônicos de M2			Notches		
	M = 2	M = 3	M = 4	M = 2	M = 3	M = 4	M = 2	M = 3	M = 4	M = 2	M = 3	M = 4
Abordagens	99,5	100	100	97,0	98,5	99,0	99,0	99,0	99,0	99,0	100	100
FastICA	99,5	100	100	97,0	99,5	99,0	100	100	99,5	100	100	100
Amuse ($p = 1$)	99,5	100	100	97,0	100	100	100	100	99,5	100	100	100
Amuse ($p = 5$)	99,5	100	100	97,0	100	100	100	100	99,5	100	100	100
Amuse ($p = 10$)	99,5	100	99,5	97,0	91,5	93,0	100	99,5	97,5	100	100	100
JADE	99,5	100	91,0	97,0	99,5	94,5	99,0	99,0	91,0	100	100	100
Akuzawa	77,5	73,5	80,0	93,0	99,0	99,0	99,0	99,0	97,5	83,5	91,5	90,0
SobiRo ($p = 5$)	99,5	100	96,2	96,0	99,0	93,0	98,0	100	93,0	100	100	100
SobiRo ($p = 10$)	99,5	100	84,5	96,0	95,0	99,5	97,0	100	97,5	100	100	100
SobiRo ($p = 100$)	99,5	100	84,5	96,0	96,0	100	99,0	100	99,5	100	100	100
Sobi ($p = 1$)	99,5	100	100	97,0	99,5	99,0	100	99,5	99,5	100	100	100
Sobi ($p = 5$)	99,5	100	100	97,0	100	99,0	100	99,5	99,5	100	100	100
dAmuse ($p = 5$)	99,5	100	100	97,0	100	100	100	99,5	99,5	100	100	100

PCA para reduzir a dimensão. Com isso, torna-se interessante analisar as saídas do modelo SCICA para distúrbios, considerando-se um número elevado de deslocamentos. As Figuras 8.20 e 8.21 mostram os componentes independentes obtidos pelo método SCICA (via FastICA), considerando-se $M = 10$, para as misturas M1 e M2, respectivamente.




Figura 8.20: Componentes independentes obtidos da mistura M1 para $M = 10$

Pode-se observar, que para a mistura M1, o transitório oscilatório aparece, claramente, nos componentes $y_6[n]$ e $y_8[n]$. Os harmônicos aparecem nos componentes $y_9[n]$ e $y_{10}[n]$. No restante dos componentes, apenas um curto transitório, que não pode ser caracterizado como transitório oscilatório, aparece. Já nos componentes independentes obtidos para a mistura M2, os harmônicos se destacam no componente $y_{10}[n]$, enquanto que o restante dos componentes replicam versões dos *notches* que estavam presentes na mistura. Sendo assim, é interessante verificar se estes componentes independentes são mais representativos, do ponto de vista de classificação, do que aqueles obtidos para os casos $M = 2$, $M = 3$ e $M = 4$. Com esta finalidade, os 500 sinais do conjunto de teste foram processados pelo modelo SCICA, via FastICA, para $M = 10$. Dos 10 componentes independentes obtidos para cada mistura, selecionaram-se os dois mais representativos através da correlação não linear com os padrões dos distúrbios. Finalmente, estes componentes




Figura 8.21: Componentes independentes obtidos da mistura M2 para $M = 10$

foram apresentados ao classificador neural projetado para fontes originais. A Tabela 8.8 mostra os resultados de desempenho obtidos para $M = 10$ em comparação com aqueles obtidos para $M = 2$, $M = 3$ e $M = 4$. Observa-se que a composição $M = 10$ alcança um resultado compatível com a composição $M = 4$, que por sua vez, alcança um desempenho pouco superior às composições $M = 2$ e $M = 3$.

Tabela 8.8: Desempenhos de classificação para diferentes números de deslocamentos.

Distúrbios	Trans. Oscil.	Harm. de M1	Harm. de M2	<i>Notches</i>
$M = 2$	99,5	97,0	99,0	100
$M = 3$	100	98,5	99,0	100
$M = 4$	100	99,0	99,0	100
$M = 10$	100	99,0	99,0	100

8.5 Influência do Tamanho da Janela na Estimação dos Componentes Independentes

Conforme já discutido, o desenvolvimento de técnicas de análise de distúrbios com reduzida complexidade computacional é de extremo interesse, já que o monitoramento da QEE em tempo real requer alta velocidade de processamento.

Neste contexto, processar janelas do sinal de tensão contendo um reduzido número de amostras, sem que haja uma redução significativa de desempenho, torna-se um desafio.

As análises até então apresentadas neste capítulo foram realizadas sobre janelas do sinal de tensão com 1.024 amostras, o que é equivalente a 4 ciclos do componente fundamental. Nesta seção, estas análises serão reproduzidas considerando-se apenas 1 ciclo do sinal de tensão (256 amostras) e em seguida, considerando-se 1/2 ciclo de duração (128 amostras).

Por simplificação, apenas a abordagem $M = 3$ será considerada. Os resultados aqui obtidos para 1 e 1/2 ciclo de duração serão comparados com os mostrados na Seção 8.3, que foram obtidos para 4 ciclos. Assim, as mesmas misturas de harmônicos com transitório oscilatório (M1) e harmônicos com *notches* (M2) serão utilizadas. As Figuras 8.22 e 8.23 ilustram os componentes independentes obtidos, utilizando-se o algoritmo FastICA, para ambas as misturas, utilizando-se apenas 1 ciclo e 1/2 ciclo do componente fundamental, respectivamente. Um resultado similar ao processamento com 4 ciclos foi obtido, sendo que um dos componentes estima corretamente os transitórios $\{y_1[n]\}$, outro $\{y_2[n]\}$ apresenta-se um pouco corrompido por harmônicos, e o terceiro estima os harmônicos, que aparecem corrompidos pelos transitórios, o que parece ser mais nítido quando apenas 1/2 ciclo de duração é considerado.




Figura 8.22: Componentes independentes obtidas considerando-se apenas 1 ciclo do sinal $e[n]$.

Apoiando-se nas análises quantitativas, observa-se, pelas Tabelas 8.9 e 8.10,




Figura 8.23: Componentes independentes obtidas considerando-se apenas 1/2 ciclo do sinal $e[n]$.

referentes às medidas entre os próprios componentes independentes, que estes mantêm a decorrelação linear e não-linear para 1 ciclo e 1/2 ciclo. Os valores de CL e CNL para as misturas é reduzido, já que o número de amostras é também reduzido. A IM entre os componentes independentes, em M1 e M2, mostra-se pouco superior às fontes e inferior às misturas, indicando que os componentes obtidos são mais independentes do que as misturas, porém menos independentes do que as fontes, o que já é esperado na prática. Observa-se, no entanto, que os valores da IM são menores quanto maior for o tamanho da janela e, portanto, componentes mais independentes são obtidos para tamanhos de janela (N) maiores. A diferença espectral DE_{ij} entre os componentes obtidos da mistura M1 é levemente reduzida quando janelas de 1 ciclo e 1/2 ciclo são consideradas. Em contrapartida, a diferença espectral entre os componentes obtidos da mistura M2 é maior, quando uma janela de 1/2 ciclo de duração é utilizada.

As medidas entre os componente independentes e as fontes originais para 4, 1 e 1/2 ciclos são mostradas nas Tabelas 8.11 e 8.12, para as misturas M1 e M2, respectivamente. Os índices de CL e CNL são reduzidos para os harmônicos de ambas as misturas, quando janelas menores são considerados. As estimativas de transitórios oscilatórios estão mais correlacionadas com as fontes quando 4 ciclos e 1/2 ciclo de janela são utilizados. O pior caso acontece para a janela de 1 ciclo. As estimativas de *notches* obtiveram índices de CL e CNL próximos para as diferentes janelas de sinal. Contudo, cumpre ressaltar que menores janelas implicam em

Tabela 8.9: Medidas entre as misturas, entre as fontes e entre os componentes independentes para a mistura M1 e diferentes tamanhos de janela.

Sinais	Misturas X			Fontes S			Componentes Y		
	4 ciclos	1 ciclo	1/2 ciclo	4 ciclos	1 ciclo	1/2 ciclo	4 ciclos	1 ciclo	1/2 ciclo
Tamanho da Janela									
CL	0,95	0,87	0,74	0,00	0,00	0,00	0,00	0,00	0,00
CNL	0,95	0,87	0,74	0,00	0,00	0,00	0,01	0,01	0,00
IM (hist./kernel)	1,00/0,99	1,00/0,94	1,00/0,85	0,52/0,29	0,96/0,63	1,00/0,57	0,80/0,63	0,98/0,76	1,00/0,65
DE_{ij}	0,00	0,00	0,00	0,26	0,28	0,35	0,25	0,24	0,20

Tabela 8.10: Medidas entre as misturas, entre as fontes e entre os componentes independentes para a mistura M2 e diferentes tamanhos de janela.

Sinais	Misturas X			Fontes S			Componentes Y		
	4 ciclos	1 ciclo	1/2 ciclo	4 ciclos	1 ciclo	1/2 ciclo	4 ciclos	1 ciclo	1/2 ciclo
Tamanho da Janela									
CL	0,89	0,90	0,85	0,02	0,06	0,00	0,00	0,00	0,00
CNL	0,89	0,90	0,85	0,02	0,06	0,00	0,01	0,01	0,00
IM (hist./kernel)	0,99/0,99	0,99/0,99	1,00/0,99	0,81/1,00	0,81/1,00	0,87/0,99	0,94/0,94	0,97/0,92	0,99/0,93
DE_{ij}	0,00	0,00	0,01	0,27	0,27	0,28	0,18	0,17	0,27

menores amostras e, portanto, é esperado que o valor da correlação seja levemente reduzido. A IM mostra que considerando-se janelas de apenas 1 ciclo ou 1/2 ciclo, as estimativas dos distúrbios ainda são tão estatisticamente dependentes das suas correspondentes fontes quanto no caso de janelas de 4 ciclos. A razão residual é aumentada quando se reduz o tamanho da janela apenas para os distúrbios da mistura M1. A diferença espectral entre o componente independente e sua correspondente fonte só é consideravelmente maior para os harmônicos da mistura M1, quando 1/2 ciclo de janela é considerado.

Tabela 8.11: Medidas entre as fontes originais e os componentes independentes para a mistura M1 e diferentes tamanhos de janela.

Sinais	Harmônicos			<i>Transitório Oscilatório</i>		
	4 ciclos	1 ciclo	1/2 ciclo	4 ciclos	1 ciclo	1/2 ciclo
Medidas						
CL	0,99	0,97	0,75	0,91	0,82	0,86
CNL	0,99	0,96	0,78	0,93	0,83	0,88
IM (hist./kernel)	1,00/0,99	1,00/0,95	1,00/0,78	0,62/0,51	0,94/0,92	0,99/0,88
DE_{ij}	0,03	0,06	0,20	0,02	0,05	0,04
Rr	0,02	0,07	0,44	0,17	0,33	0,25

Tabela 8.12: Medidas entre as fontes originais e os componentes independentes para a mistura M2 e diferentes tamanhos de janela.

Sinais	Harmônicos			<i>Notches</i>		
	4 ciclos	1 ciclo	1/2 ciclo	4 ciclos	1 ciclo	1/2 ciclo
Medidas						
CL	0,97	0,96	0,95	0,80	0,81	0,80
CNL	0,97	0,96	0,95	0,77	0,78	0,77
IM (hist./kernel)	0,99/1,00	1,00/0,99	1,00/0,98	0,82/1,00	0,81/1,00	0,88/1,00
DE_{ij}	0,09	0,10	0,07	0,06	0,05	0,05
Rr	0,13	0,15	0,10	0,43	0,41	0,44

Em geral, observa-se que mesmo com janelas reduzidas, de 1 ciclo e de 1/2 ciclo, ainda é possível obter boas estimativas dos distúrbios. Entretanto, deve-se chamar a atenção para o fato de que janelas reduzidas podem não caracterizar suficientemente um distúrbio e, como consequência, o desempenho do classificador pode ser reduzido, independentemente da qualidade das estimativas dos distúrbios.

8.5.1 Classificação de Distúrbios com Janelas Reduzidas

A fim de testar a extração de componentes independentes sob o ponto de vista de classificação de distúrbios com janelas de aquisição reduzidas, um classificador,

para cada largura de janela, de 1 ciclo e 1/2 ciclo de duração, foi projetado a partir das fontes originais. Nesta etapa, utilizou-se o mesmo banco de distúrbios usado para gerar os resultados da Seção 8.4, já que os resultados aqui obtidos serão comparados com os obtidos para janelas de sinais com 4 ciclos de duração. Neste caso, as fontes de distúrbios foram adquiridas com 1 ciclo e 1/2 ciclos de duração, truncando-se cada sinal, a partir do início do distúrbio, em 256 e 128 amostras, respectivamente.

Os classificadores foram projetados, seguindo a mesma metodologia da Seção 8.4, em que parâmetros EOS foram extraídos dos sinais e uma RNA foi utilizada como técnica de classificação. Procurou-se manter a mesma topologia e treinamento de rede utilizada para 4 ciclos, alcançando-se assim, um desempenho geral de 100 % para o treinamento e 100 % para dados de validação, em ambos os casos (para 1 ciclo e 1/2 ciclo).

Em seguida, para cada evento, uma matriz de misturas \mathbf{X} foi gerada, composta pelo sinal e duas versões do mesmo deslocadas (abordagem $M = 3$). A matriz de mistura foi então apresentada ao algoritmo ICA e, dos três componentes independentes obtidos, dois foram selecionados por correlação não linear com os correspondentes padrões de sinais, conforme descrito na Seção 8.4. Os componentes independentes assim selecionados foram apresentados ao classificador projetado para atuar sobre fontes originais. Os desempenhos, para cada tamanho de janela, são mostrados na Tabela 8.13, em comparação com os obtidos considerando-se janelas de 4 ciclos de aquisição. Por simplificação, utilizou-se apenas resultados obtidos pelo algoritmo FastICA. Observa-se que houve redução de desempenho considerável para os distúrbios estimados da mistura M1, que são os transitórios oscilatórios e os harmônicos, principalmente para janelas de 1/2 ciclo.

Tabela 8.13: Desempenhos de classificação para diferentes tamanhos de janelas em %.

Distúrbios	Trans. Oscil.	Harm. de M1	Harm. de M2	<i>Notches</i>
4 ciclos	100	98,5	99,0	100
1 ciclo	97,5	98,0	100	100
1/2 ciclo	80,0	89,5	100	99,5

De fato, poucas amostras do sinal podem não caracterizar suficientemente um distúrbio e, como consequência, o desempenho do classificador pode ser reduzido, independentemente da qualidade das estimativas dos distúrbios. Para verificar se

a redução de desempenho para janelas de 1/2 ciclo se deve à baixa qualidade das estimativas ou à restrição de informações sobre os distúrbios (devido ao reduzido número de amostras), os componentes independentes obtidos para janelas de 4 ciclos foram segmentadas em janelas de apenas 1/2 ciclo e, em seguida, apresentados ao classificador de sinais com 1/2 ciclo. O desempenho obtido foi de 97,0 % para transitórios oscilatórios, 92,5 % para harmônicos da mistura M1, 100 % para harmônicos da mistura M2, e 99,5 % para os *notches*. Este resultado mostra que o baixo desempenho do classificador para janelas de 1/2 ciclo se deve tanto à baixa qualidade das estimativas quanto à redução de informação disponível dos distúrbios.

Os resultados de classificação mostrados anteriormente foram obtidos por classificadores projetados a partir de fontes originais. Esta aplicação é interessante para testar a qualidade das estimativas. No entanto, para o desenvolvimento de classificadores que operem sobre as estimativas dos distúrbios via ICA, é mais interessante projetar estes classificadores a partir das próprias estimativas dos distúrbios. Isso pode levar a melhores resultados, já que o classificador pode incorporar o ruído proveniente das misturas e presente nas estimativas, como parte do processo. Com o propósito de se realizar esta análise, novos bancos de misturas (M1 e M2) com 250 eventos cada foi gerado. Um banco para cada largura da janela: 4 ciclos, 1 ciclo e 1/2 ciclo de duração. Estes novos bancos foram processados, conforme o modelo SCICA, para $M = 3$. O algoritmo FastICA foi utilizado. Em seguida, classificadores foram projetados a partir das estimativas dos distúrbios. Os classificadores foram projetados seguindo a mesma metodologia descrita anteriormente e considerando-se a mesma topologia da rede neural. As redes neurais foram treinadas com 150 eventos e validadas com 100. Em seguida, os 500 eventos de cada mistura (M1 e M2), previamente separados para teste foram então aplicados ao modelo SCICA ($M = 3$) e, finalmente, apresentados aos classificadores, considerando-se janelas de 4 ciclos, 1 ciclo e 1/2 ciclo. Cumpre lembrar que o mesmo banco de dados de teste foi utilizado para diferentes janelas, o que é possível segmentando-se cada evento a partir do início do distúrbio.

Os resultados de desempenho para os dados de treino (TR), validação (VA) e teste (TE) são mostrados na Tabela 8.14. Observa-se que, independente do tamanho da janela de sinal utilizada, o classificador alcançou desempenho máximo para os

distúrbios presentes na mistura M2, que são os harmônicos e *notches*. Houve uma pequena queda de desempenho para os harmônicos da mistura M1 quando janelas de 1 ciclo são utilizadas. O desempenho menor foi obtido para os distúrbios da mistura M1 (harmônicos e transitórios oscilatórios), quando janelas de 1/2 ciclo são utilizadas. Comparativamente aos resultados da Tabela 8.13, observa-se que o projeto dos classificadores a partir dos distúrbios estimados, de fato, leva a melhores resultados. Em geral, estes resultados podem comprovar a qualidade das estimativas dos distúrbios, principalmente, quando o objetivo principal é classificá-los.

Tabela 8.14: Desempenhos de classificação, obtidos com classificadores projetados a partir das estimativas dos distúrbios, em %.

Distúrbios	Trans. Oscil.			Harm. de M1			Harm. de M2			<i>Notches</i>		
	TR	VA	TE	TR	VA	TE	TR	VA	TE	TR	VA	TE
4 ciclos	100	100	100	100	100	100	100	100	100	100	100	100
1 ciclo	100	100	100	100	99	98,0	100	100	100	100	100	100
1/2 ciclo	96	94	90,5	93	91	85,0	100	100	100	100	100	100

8.6 Influência do Ruído de Fundo

Para as análises realizadas, até o presente momento, no contexto deste capítulo, consideraram-se sinais de tensão com SNR de 100 dB, objetivando estudar a fundo a adequação do modelo SCICA à análise de distúrbios elétricos. A fim de estudar a influência do ruído de fundo nas estimativas dos distúrbios, um novo banco de distúrbios com SNR de 30 dB, com 500 eventos de cada mistura (M1 e M2), foi gerado.

Considerando-se a abordagem $M = 3$, os eventos escolhidos foram processados, conforme o modelo SCICA e utilizando-se o algoritmo FastICA. A Figura 8.24 ilustra os componentes independentes obtidos para cada mistura. Observa-se que das duas estimativas dos transitórios, para ambas as misturas, que aparecem nos componentes $y_1[n]$ e $y_2[n]$, a segunda possui mais ruído de fundo do que a primeira. Por outro lado, a primeira possui mais resíduos dos harmônicos (proveniente do processo de separação) do que a segunda.

Também é interessante observar o desempenho do classificador, treinado com fontes originais (SNR 100 dB), quando aplicado às estimativas dos distúrbios para




Figura 8.24: Componentes independentes obtidas considerando-se sinais com SNR de 30 dB.

as misturas com SNR de 30 dB, considerando-se janelas com 1.024 amostras (4 ciclos de duração). A escolha dos dois componentes independentes foi realizada pelo maior índice de correlação não linear com os padrões de sinal de cada classe de distúrbio, conforme já discutido. Os resultados alcançados, ilustrados na Tabela 8.15, foram satisfatórios, já que em ambos os casos o desempenho alcançado é compatível. O desempenho para os harmônicos estimados para as misturas com SNR de 30 dB foi um pouco superior aos harmônicos obtidos para as misturas com SNR de 100 dB. Já o desempenho para os transitórios oscilatórios foi levemente reduzido quando misturas com SNR de 30 dB foram processadas. O desempenho para as estimativas de *notches* alcançou 100 % para ambas SNR de 30 e 100 dB.

Tabela 8.15: Desempenhos de classificação para diferentes níveis de ruído em %.

Distúrbios	Trans. Oscil.	Harm. de M1	Harm. de M2	<i>Notches</i>
SNR de 100 dB	100	98,5	99,0	100
SNR de 30 dB	99,5	99,5	100	100

Em geral, a comparação entre os resultados com dados de SNR iguais a 100 dB e 30 dB mostra que a estimativa dos distúrbios via SCICA não sofre muita influência dos ruídos de fundo. Por outro lado, o elevado desempenho do classificador se deve também à sua imunidade a ruídos gaussianos, já que este utiliza parâmetros de estatísticas de ordem superior.

8.7 Aplicação em Dados Experimentais

Para avaliar a eficiência do método para dados experimentais, consideraram-se distúrbios adquiridos pelo grupo de estudos do IEEE (*working group P1159.3*), com uma frequência de amostragem de 15.360 Hz, 4 ciclos do componente fundamental (60 Hz) e SNR estimada de 40 dB, conforme mostrado na Figura 8.25. Na Figura 8.25 (a), observa-se uma variação na amplitude da tensão de curta duração, harmônicos e transitórios de curta duração. Na Figura 8.25 (b), aparecem harmônicos, transitórios que apresentam um decaimento na oscilação, e possivelmente, outro tipo de distúrbio difícil de ser categorizado *a priori*.




Figura 8.25: Múltiplos distúrbios experimentais.

Estes distúrbios foram apresentados ao sistema SCICA proposto, considerando-se $M = 3$ e o algoritmo FastICA. Os componentes independentes extraídos são mostrados na Figura 8.26. Em (a), observa-se nitidamente que os transitórios foram isolados em $y_1[n]$ e os harmônicos apareceram em $y_3[n]$. Em (b), os transitórios aparecem mais nítidos na componente $y_1[n]$ e os harmônicos, ainda muito poluídos por transitórios, em $y_3[n]$.

Para quantificar esta análise, alguns índices foram extraídos entre as misturas e entre os componentes independentes. Neste caso, escolheram-se os componentes $y_1[n]$ e $y_3[n]$ para ambos os eventos (a) e (b), mostrados na Figura 8.26. A escolha destes componentes se deu pelo critério da maior diferença espectral entre os componentes. Cumpre ressaltar que outros critérios podem também ser utilizados, tal




Figura 8.26: Componentes obtidas considerando-se $M = 3$.

como escolher os componente que apresentarem menor informação mútua entre si.

A aplicação em sinais experimentais levanta uma questão importante, que é o fato de que não se sabe quantas fontes de distúrbios estão presentes na mistura. Neste caso, sugere-se definir um limiar de diferença espectral ou informação mútua entre os componentes estimados, de tal forma que se possa descartar componentes com características similares aos outros. Esta análise será explorada em trabalhos futuros.

As medidas quantitativas são mostradas na Tabela 8.16. Observa-se, para ambos os eventos, que os componentes obtidos estão descorrelacionados linearmente e não-linearmente. A IM entre os componentes obtidos é inferior à IM entre as correspondentes misturas, indicando que os componentes são mais independentes do que as misturas. Por último, o índice DE_{ij} mostra que os componentes independentes possuem espectros mais disjuntos do que as misturas. Desta forma, os índices quantitativos comprovam a eficiência do método SCICA para separar os múltiplos distúrbios experimentais.

Tabela 8.16: Medidas entre as misturas e entre os componentes independentes para os distúrbios experimentais.

Índices	Misturas \mathbf{X}		Componentes \mathbf{Y}	
	Evento (a)	Evento (b)	Evento (a)	Evento (b)
CL	0,99	0,92	0,00	0,00
CNL	0,99	0,92	0,00	0,00
IM (hist./kernel)	0,99/0,99	0,98/0,98	0,71/0,81	0,75/0,81
DE_{ij}	0,00	0,00	0,12	0,15

8.8 SCICA com Menor Complexidade Computacional

Conforme já destacado anteriormente, é de extremo interesse o desenvolvimento de ferramentas que possibilitem a análise dos distúrbios em tempo real. As aplicações do modelo SCICA, mostradas neste capítulo até o presente momento, demandaram a aplicação do algoritmo ICA a cada janela de mistura analisada. De fato, a utilização desta aplicação em tempo real vai depender do tempo de processamento do algoritmo ICA utilizado. Por outro lado, para análises *off line*, o método mostra-se bastante promissor.

Objetivando tornar o método SCICA menos complexo do ponto de vista computacional, buscou-se obter uma matriz de separação \mathbf{W} que possa ser aplicada diretamente na fase de operação.

Analisando-se individualmente cada mistura (M1 - harmônicos com transitórios oscilatórios e M2 - harmônicos com *notches*), gerou-se, a partir das misturas de treinamento, um único vetor de mistura $\{\mathbf{e}_{gi}\}$, formado pela justaposição das janelas de sinais de treinamento:

$$\mathbf{e}_{gi} = [\mathbf{e}_{1i} \ \mathbf{e}_{2i} \ \mathbf{e}_{3i} \ \dots \ \mathbf{e}_{Zi}], \quad (8.15)$$

em que os vetores \mathbf{e}_{1i} , \mathbf{e}_{2i} , ..., \mathbf{e}_{Zi} representam as janelas do banco de sinais de treinamento $e[n]$ da mistura $i = 1, 2$, referente a mistura M1 e M2, respectivamente. $Z = 250$ é o número total de misturas do conjunto de treinamento e $n = 1, \dots, N$, tal que $N = 1.024$ amostras. Assim, o comprimento do vetor \mathbf{e}_{gi} será dado por $Z \times N = 256.000$ amostras.

Desta forma, o vetor \mathbf{e}_{gi} pode representar melhor o processo estatístico gerado

por cada tipo de mistura. Este vetor foi então processado, seguindo a metodologia SCICA para $M = 3$, utilizando-se o algoritmo FastICA. Escolheu-se a abordagem $M = 3$ devido à obtenção de resultados satisfatórios. Os componentes independentes obtidos para as misturas M1 e M2 são mostradas nas Figuras 8.27 e 8.28, respectivamente. Para melhorar a visualização, o número de amostras foi fixado em 5.120 amostras. Pode-se observar que, similarmente à aplicação com as misturas evento a evento, o resultado das estimativas dos distúrbios é aqui reproduzido de uma forma geral.




Figura 8.27: Componentes independentes obtidos da mistura M1.

Com este procedimento, obtém-se uma matriz de separação \mathbf{W} para cada tipo de mistura (M1 e M2). A ideia principal é que este processo de obtenção da matriz de separação seja realizado uma única vez com dados de treinamento, na fase de projeto. Na fase de operação, a cada múltiplo distúrbio a ser processado, deve-se simplesmente gerar a matriz de misturas \mathbf{X} , considerando-se $M = 3$, e realizar a operação matricial $\mathbf{Y} = \mathbf{W}\mathbf{X}$. Dessa forma, a complexidade computacional do método proposto, na fase de operação, se resume em uma única multiplicação matricial, o que viabiliza a utilização do método em aplicações em tempo real. Cumpre lembrar que \mathbf{W} será da ordem $M \times M$, e \mathbf{X} será da ordem $M \times N$.

Para testar a eficiência da matriz \mathbf{W} obtida para cada tipo de mistura, os eventos ilustrados na Figura 8.3 foram passados pelo filtro notch e, os respectivos




Figura 8.28: Componentes independentes obtidos da mistura M2.

sinais $e[n]$ formaram a matriz de misturas \mathbf{X} , considerando-se duas versões deslocadas dos mesmos ($M = 3$). Finalmente, os componentes independentes foram então extraídos através de $\mathbf{Y} = \mathbf{W}\mathbf{X}$. A Figura 8.29 ilustra estes componentes.




Figura 8.29: Componentes obtidos com as matrizes de separação gerais \mathbf{W} , considerando-se $M = 3$.

Em seguida, dois componentes de cada mistura foram selecionados pela correlação não linear com os padrões dos distúrbios, conforme já discutido. Assim, extraindo cada medida quantitativa destes componentes e comparando-as com aquelas obtidas pela aplicação evento a evento do FastICA, observa-se nas Tabelas 8.17, 8.18, 8.19 e 8.20 que os resultados são, em geral, compatíveis, comprovando a eficiência

das matrizes de separação gerais \mathbf{W} . Alguns pontos importantes a serem destacados foram colocados em negrito nas tabelas, tais como:

- Pela Tabela 8.17, observa-se que a IM obtida pela aplicação do FastICA foi superior, dando um indicativo de que a matriz geral de separação \mathbf{W} , para esta mistura, levou à obtenção de componentes mais independentes entre si.
- A Tabela 8.18 mostra que o transitório oscilatório estimado pela aplicação evento a evento do FastICA é mais corrompido por resíduos provenientes da mistura do que aquele obtido pela matriz geral de separação \mathbf{W} .
- Na Tabela 8.19, componentes obtidos pela matriz geral de separação \mathbf{W} possuem os espectros mais distintos do que aqueles obtidos pela aplicação do FastICA.
- A Tabela 8.20 mostra que os harmônicos estimados da mistura M2, pela aplicação do FastICA, possuem maior razão residual do que aqueles estimados pela matriz geral de separação \mathbf{W} .

Tabela 8.17: Medidas entre os componentes independentes obtidos pelo FastICA e pela matriz geral de separação \mathbf{W} , para a mistura M1.

Teste	FastICA	\mathbf{W}
CL	0,00	0,01
CNL	0,01	0,02
IM (hist./kernel)	0,80/0,63	0,76/0,52
DE_{ij}	0,25	0,25

Tabela 8.18: Medidas entre as fontes originais e os componentes independentes obtidos pelo FastICA e pela matriz geral de separação \mathbf{W} , para a mistura M1.

Sinais	Harmônicos		<i>Transitório Oscilatório</i>	
	FastICA	\mathbf{W}	FastICA	\mathbf{W}
CL	0,99	0,99	0,91	0,93
CNL	0,99	0,99	0,93	0,94
IM (hist./kernel)	1,00/0,99	1,00/0,99	0,62/0,51	0,64/0,37
DE_{ij}	0,03	0,03	0,02	0,02
Rr	0,02	0,02	0,17	0,13

Os componentes independentes obtidos pelo modelo SCICA com rápido processamento, que utiliza apenas a matriz de separação geral \mathbf{W} , foram também avaliados sob o ponto de vista de classificação. Para isso, o banco de sinais de teste

Tabela 8.19: Medidas entre os componentes independentes obtidos pelo FastICA e pela matriz geral de separação \mathbf{W} , para a mistura M2.

Teste	FastICA	\mathbf{W}
CL	0,00	0,01
CNL	0,01	0,00
IM (hist./kernel)	0,94/0,94	0,94/0,92
DE_{ij}	0,18	0,21

Tabela 8.20: Medidas entre as fontes originais e os componentes independentes obtidos pelo FastICA e pela matriz geral de separação \mathbf{W} , para a mistura M2.

Sinais	Harmônicos		<i>Notches</i>	
	FastICA	\mathbf{W}	FastICA	\mathbf{W}
CL	0,97	0,97	0,80	0,79
CNL	0,97	0,97	0,77	0,76
IM (hist./kernel)	0,99/1,00	1,00/1,00	0,82/1,00	0,83/1,00
DE_{ij}	0,09	0,07	0,06	0,05
<i>Rr</i>	0,13	0,08	0,43	0,44

com 500 eventos de cada mistura (M1 e M2) foi processado pelo método SCICA via matriz de separação geral \mathbf{W} considerando-se o caso $M = 3$. Dos três componentes obtidos, os dois com menor interferência de resíduos foram selecionados pela correlação não linear com os padrões dos distúrbios, conforme discutido anteriormente. Estes componentes foram então apresentados ao classificador neural projetado na Seção 8.4 para fontes originais. Os resultados de desempenho do classificador são mostrados na Tabela 8.21, em comparação com os resultados obtidos pela aplicação evento a evento do algoritmo FastICA. Observa-se que os resultados obtidos com a matriz de separação geral \mathbf{W} são superiores, o que pode ser explicado pelo fato de que as misturas utilizadas para gerá-la representavam melhor o processo estocástico formado pelos distúrbios, já que englobavam todas as informações dos 250 eventos de treino. É importante observar, também, que a operação com a matriz \mathbf{W} pode ser aplicada a diferentes comprimentos de janela de aquisição do sinal de mistura com, possivelmente, alguma redução de desempenho.

Para os casos $M = 3$ e $M = 4$, considerando-se a aplicação com a matriz de separação geral \mathbf{W} , pode-se, na fase de projeto, observar quais as linhas da \mathbf{W} que levam às melhores componentes independentes. Isso pode ser feito pela análise das respostas em frequência do filtros formados pelas linhas de \mathbf{W} . Logo, na fase de operação, pode-se utilizar apenas estas linhas, não necessitando, contudo,

desenvolver métodos para descartar os componentes independentes com maiores interferências, o que otimiza ainda mais o processo de estimativa dos distúrbios.

Tabela 8.21: Desempenhos de classificação para a matriz de separação geral \mathbf{W} em %.

Distúrbios	Trans. Oscil.		Harm. de M1		Harm. de M2		<i>Notches</i>	
	FastICA	\mathbf{W}	FastICA	\mathbf{W}	FastICA	\mathbf{W}	FastICA	\mathbf{W}
4 ciclos	100	100	98,5	99,0	99,0	100	100	100
1 ciclo	97,5	100	98,0	99,0	100	100	100	100
1/2 ciclo	80,0	99,5	89,5	95,0	100	100	99,5	99,5

Sob o ponto de vista operacional, deve-se avaliar qual será a saída do sistema para o aparecimento de um distúrbio isolado. Sabe-se que, em geral, os sistemas que analisam e classificam os distúrbios são precedidos por sistemas de detecção. Estes detectores não informam se o distúrbio detectado é isolado ou múltiplo. Assim, é interessante observar as saídas do sistema proposto SCICA para distúrbios isolados. Com este propósito, um distúrbio isolado de transitório oscilatório e um de harmônico foram processados pelo sistema SCICA implementado utilizando-se a matriz de separação geral \mathbf{W} . As saídas do sistema projetado para a mistura M1 estão ilustradas na Figura 8.30, em (a), para o transitório oscilatório e, em (b), para o harmônico. Estas estimativas foram apresentadas ao classificador treinado por fontes originais. As três estimativas de transitórios oscilatórios foram classificadas como transitório oscilatórios e as três de harmônicos foram classificadas como harmônicos. É importante observar que os eventos isolados aparecem nas três estimativas porque elas são normalizadas após passar pela matriz de separação. Desta forma, a atenuação dos filtros é compensada parcialmente pela normalização dos sinais.

A Figura 8.31 mostra as saídas do sistema proposto, projetado para as misturas M2, para um evento isolado de *notch*, em (a), e para um harmônico, em (b). Estas estimativas foram apresentadas ao classificador treinado por fontes originais. Neste caso, as estimativas também foram classificadas corretamente.

A vantagem em se aplicar o FastICA e obter uma matriz de separação a cada mistura processada está no fato de que distúrbios desconhecidos pela matriz de separação geral podem aparecer. Neste caso, ao se aplicar o FastICA, pode-se obter uma matriz de separação a partir do distúrbio desconhecido.




Figura 8.30: Componentes obtidos com a matriz de separação da mistura M1, considerando-se $M = 3$. (a) refere-se ao distúrbio de transitórios oscilatório e (b) refere-se ao harmônico.




Figura 8.31: Componentes obtidas com a matriz de separação da mistura M2, considerando-se $M = 3$. (a) refere-se ao distúrbio de *notches* e (b) refere-se ao harmônico.

8.9 Análise Por Branqueamento

Sabe-se que o branqueamento da matriz de misturas \mathbf{X} executa uma importante tarefa de pré-processamento na maioria dos algoritmos ICA [103]. O PCA seguido por branqueamento é capaz de garantir a decorrelação dos sinais e variância unitária, enquanto a ICA busca pela independência estatística dos mesmos.

A fim de estudar os efeitos do branqueamento na matriz de misturas gerada por fontes deslocadas, as misturas M1 e M2 (vide Figura 8.3) foram processadas pelo filtro notch e suas respectivas matrizes de misturas \mathbf{X} , para $M = 3$, foram branqueadas. Os sinais branqueados são mostrados na Figura 8.32, em que pode-se observar que a separação dos transitórios e harmônicos foi alcançada.




Figura 8.32: Misturas branqueadas, considerando-se $M = 3$.

A partir dos sinais branqueados a pergunta é: Apenas o branqueamento é suficiente para estimar os distúrbios da mistura M1 e M2? A fim de responder esta pergunta, as medidas quantitativas entre os sinais branqueados foram comparadas com as medidas entre os componentes estimados pelo FastICA, considerando-se o modelo SCICA para o caso $M = 3$. Os melhores componentes foram selecionados utilizando-se a correlação não linear com os padrões dos distúrbios. As Tabelas 8.22 e 8.23 mostram estes resultados para as misturas M1 e M2, respectivamente. Os índices de CL, CNL e DE_{ij} mostram que tanto as saídas do FastICA quanto os sinais branqueados estão decorrelacionados entre si e possuem espectros disjuntos. A medida mais interessante, neste caso, é a IM, que infere diretamente sobre a independência entre os sinais. Conforme esperado, a IM é maior entre os sinais branqueados do que entre as saídas do FastICA, mostrando que estas são mais

independentes do que os sinais branqueados.

Tabela 8.22: Medidas entre os componentes independentes obtidos pelo FastICA e as misturas M1 branqueadas.

Teste	FastICA	Branqueamento
CL	0,00	0,00
CNL	0,01	0,00
IM (hist./kernel)	0,80/0,63	0,94/0,89
DE_{ij}	0,25	0,24

Tabela 8.23: Medidas entre os componentes independentes obtidos pelo FastICA e as misturas M2 branqueadas.

Teste	FastICA	Branqueamento
CL	0,00	0,00
CNL	0,01	0,00
IM (hist./kernel)	0,94/0,94	0,98/0,96
DE_{ij}	0,18	0,22

Apesar disso, ainda é interessante comparar também se os sinais branqueados estimam as fontes originais tão bem quanto as saídas do FastICA. As Tabelas 8.24 e 8.25 mostram estes resultados. Observa-se que, em geral, os índices obtidos para os sinais branqueados são similares aos obtidos para as saídas do FastICA, dando um indicativo de que os sinais branqueados podem estimar as fontes originais.

Tabela 8.24: Medidas entre as fontes originais e os componentes independentes obtidos pelo FastICA e as misturas M1 branqueadas.

Sinais	Harmônicos		<i>Transitório Oscilatório</i>	
	FastICA	Branqueamento	FastICA	Branqueamento
CL	0,99	0,97	0,91	0,92
CNL	0,99	0,97	0,93	0,93
IM (hist./kernel)	1,00/0,99	1,00/0,99	0,62/0,51	0,58/0,51
DE_{ij}	0,03	0,05	0,02	0,02
Rr	0,02	0,05	0,17	0,15

Por fim, os 500 evento de cada tipo de mistura (M1 e M2) que compõem o banco de dados de teste foram processados ($M = 3$) e branqueados. Em seguida, cada evento branqueado foi apresentado ao classificador projetado por fontes originais. Os resultados de desempenhos são mostrados na Tabela 8.26, em comparação com os algoritmos FastICA e Amuse. Observa-se que os desempenhos para os dados branqueados são levemente superiores aos obtidos para os componentes do FastICA

Tabela 8.25: Medidas entre as fontes originais e os componentes independentes obtidos pelo FastICA e as misturas M2 branqueadas.

Sinais	Harmônicos		<i>Notches</i>	
Teste	FastICA	Branqueamento	FastICA	Branqueamento
CL	0,97	0,96	0,80	0,81
CNL	0,97	0,96	0,77	0,80
IM (hist./kernel)	0,99/1,00	1,00/1,00	0,82/1,00	0,84/1,00
DE_{ij}	0,09	0,07	0,06	0,07
Rr	0,13	0,08	0,43	0,41

nas estimativas dos harmônicos. Por outro lado, o algoritmo Amuse alcança um resultado pouco superior ao branqueamento. Isso mostra que, sob o ponto de vista de classificação, utilizar os sinais apenas branqueados pode levar a bons resultados.

Tabela 8.26: Desempenhos de classificação para os sinais branqueados em %.

Distúrbios	Trans. Oscil.	Harm. de M1	Harm. de M2	<i>Notches</i>
Branqueamento	100	99,5	99,5	100
FastICA	100	98,5	99,0	100
Amuse ($p = 5$)	100	100	99,5	100

Uma forma de quantificar a atuação do algoritmo FastICA sobre os sinais já branqueados constitui-se em analisar o processo de maximização da não-gaussianidade do algoritmo. Para isso, a kurtosis [103] foi medida para as misturas, para as fontes originais dos distúrbios, para as misturas branqueadas e para as saídas do FastICA. Utilizou-se a kurtosis normalizada, isto é, distribuições gaussianas levam a kurtosis 0.

Estas medidas foram efetuadas nos dados do conjunto de treino para ambas as misturas M1 e M2. A Tabela 8.27 mostra os resultados da média aritmética da kurtosis. O erro padrão da média foi calculado considerando-se um intervalo de 95% de confiança. A kurtosis das fontes mostra que os transitórios oscilatórios e os *notches* são menos gaussianos do que os harmônicos. Os dados branqueados, assim como as saídas do FastICA, levam também a transitórios oscilatórios e *notches* menos gaussianos do que os harmônicos. Interessante observar que os transitórios oscilatórios obtidos pelo branqueamento e pelo FastICA são menos gaussianos do que as fontes originais. Por outro lado, os *notches* obtidos por ambos FastICA e branqueamento são mais gaussianos do que as correspondentes fontes originais. O FastICA levou a sinais menos gaussianos, porém, as barras de erro sobrepõem

aquelas obtidas para os dados branqueados de transitórios oscilatórios, harmônicos de M1 e harmônicos de M2, e, portanto, a diferença entre suas médias pode não ser significativa. As estimativas dos *notches* pelo FastICA são menos gaussianas do que aquelas obtidas pelo branqueamento.

Tabela 8.27: Medida normalizada de gaussianidade dos dados.

	Mistura	Fontes	Sinais Branqueados	FastICA
Trans. Oscil.	$0,77 \pm 0,13$	$67,73 \pm 2,04$	$125,45 \pm 9,21$	$140,10 \pm 9,98$
Harm. de M1	$0,77 \pm 0,13$	$0,51 \pm 0,04$	$0,55 \pm 0,08$	$0,58 \pm 0,09$
Harm. de M2	$0,49 \pm 0,06$	$0,61 \pm 0,04$	$0,52 \pm 0,04$	$0,55 \pm 0,05$
<i>Notches</i>	$0,49 \pm 0,06$	$15,90 \pm 0,00$	$9,99 \pm 0,52$	$13,20 \pm 0,17$

De fato, o algoritmo FastICA buscou por fontes mais independentes entre si do que o branqueamento, conforme mostram os resultados da IM nas Tabelas 8.22 e 8.23. Contudo, os resultados de classificação mostrados na Tabela 8.26 mostram que o processo de branqueamento pode levar a boas estimativas dos distúrbios.

8.10 Discussões Gerais

Neste capítulo, o problema de múltiplos distúrbios foi explorado utilizando-se a técnica análise de componentes independentes, em sua versão adaptada para o problema de um único canal (modelo SCICA).

Mostrou-se que os múltiplos distúrbios de harmônicos com transitórios oscilatórios e harmônicos com *notches* se enquadram ao modelo convolutivo SCICA. Análises qualitativas e quantitativas mostraram que, com poucos deslocamentos temporais na mistura monitorada, pode-se obter boas estimativas das fontes de distúrbios presentes na mistura. Este reduzido número de deslocamentos apresenta-se como uma grande vantagem em comparação com as aplicações EEG [109, 110], dada a redução de complexidade computacional na aplicação do algoritmo ICA para poucas entradas.

Foi verificado também que, conforme descreve a teoria SCICA, as linhas da matriz de separação \mathbf{W} constituem vetores de coeficientes de filtros FIR que, ao processar as misturas, levam aos componentes independentes.

O teste dos componentes independentes sob o ponto de vista de classificação foi realizado utilizando-se um classificador projetado para fontes originais. Diversos

algoritmos ICA foram testados, destacando-se com maior desempenho os algoritmos Amuse e dAmuse. É interessante observar que ambos algoritmos utilizam deslocamentos temporais na matriz de covariância. Adicionalmente, o algoritmo dAmuse foi proposto para aplicações em sinais deslocados, conforme apresentado em [118].

Com o objetivo de reduzir complexidade computacional, o modelo SCICA foi aplicado a sinais com reduzida janela de aquisição. Os resultados mostraram que é possível obter boas estimativas dos distúrbios, com baixa queda de desempenho, com até meio ciclo de duração da janela de aquisição, o que significa processar apenas 128 amostras.

O desempenho do método para sinais com SNR de 30 dB foi também investigado, em comparação com os sinais com SNR de 100 dB. Esta investigação foi realizada sob o ponto de vista de classificação, mostrando que, a partir de misturas com alta taxa de ruído de fundo, pode-se obter componentes independentes que levam o classificador a alcançar um desempenho compatível. Na verdade, pôde-se observar que o modelo SCICA processa os sinais com ruídos sem que haja redução na capacidade de separação das fontes presentes na mistura. Contudo, o ruído presente na mistura aparece nos componentes independentes estimados, o que reduz a qualidade das estimativas das fontes. O alto desempenho alcançado pelo classificador, neste caso, se dá pela imunidade do sistema a ruídos gaussianos devido à utilização de estatísticas de ordem superior como parâmetros.

O modelo SCICA foi também testado em sinais experimentais, em que a boa capacidade do método de separar fenômenos transitórios e impulsivos de harmônicos foi destacada.

Visando propor metodologias de análise de distúrbios em tempo real, uma matriz geral de separação foi obtida. Os resultados obtidos com esta matriz foram compatíveis com aqueles obtidos pela aplicação do FastICA evento a evento. O ganho em complexidade computacional, neste caso, é bastante considerável e, portanto, o desenvolvimento de metodologias, a partir desta matriz geral de separação, torna-se extremamente interessante para aplicações em tempo real.

Por último, os efeitos do branqueamento como etapa de pré-processamento ao modelo SCICA foram investigados. Os resultados mostraram que, no caso das misturas consideradas, o processamento só até a etapa de branqueamento pode levar

a boas estimativas das fontes de distúrbios. A análise de gaussianidade dos dados, realizada por meio da *kurtosis*, mostrou que cada mistura (M1 e M2) é composta por um sinal muito não gaussiano e outro quase gaussiano. O branqueamento reproduziu estes resultados, o que pode explicar as boas estimativas de distúrbios alcançadas com o mesmo. O FastICA, no entanto, maximizou a não gaussianidade dos sinais branqueados menos gaussianos.

Capítulo 9

Conclusões e Perspectivas

A presente tese teve como principal objetivo o desenvolvimento e aperfeiçoamento de técnicas de processamento de sinais e inteligência computacional aplicadas à detecção, classificação e análise de distúrbios elétricos.

Antes de atacar diretamente o problema de detecção e classificação, realizou-se uma análise dos distúrbios por curvas principais. O objetivo desta análise foi avaliar a complexidade da classificação de cada tipo de distúrbio, assim como a complexidade dos sinais de cada classe de distúrbios, o que permitiu ter-se uma ideia de homogeneidade ou heterogeneidade das mesmas. A inovação desta análise está no fato de se observar os distúrbios no espaço dimensional das curvas. Cada classe de distúrbios foi representada pela correspondente curva principal. Com base na curva principal obtida para cada classe, o número de segmentos e o comprimento da mesma pôde revelar a disposição dos eventos de cada classe no espaço das curvas, o que pode dar uma ideia da variabilidade das características dos eventos pertencentes às classes. As características das curvas, tais como o número de segmentos e o seu comprimento, aliadas às medidas de distâncias entre as mesmas, apontaram por curvas bastante compactas e espaçadas umas das outras. Além disso, as curvas principais possibilitaram a extração de informações e/ou parâmetros relevantes à detecção e classificação dos distúrbios.

A partir dos parâmetros dos distúrbios extraídos por curvas, foi possível projetar um sistema de detecção com elevada eficiência mesmo quando janelas de até 1/16 ciclos do componente fundamental (o que é equivalente a 16 amostras) foram processadas. O sistema apresentou uma complexidade computacional relativamente

reduzida, já que a extração das curvas é realizada apenas na fase de projeto. Na fase de operação, apenas as distâncias euclidianas do evento processado aos segmentos das curvas são extraídas. Neste caso, três segmentos foram suficientes para distinguir os distúrbios dos sinais sem distúrbios. Ademais, as distâncias extraídas alimentaram uma rede neural especialista para cada classe e, portanto, o sistema resultante mostrou-se bastante versátil quanto à inclusão de uma nova classe de distúrbios. No caso da inclusão de uma nova classe, não será necessário reprojeter as curvas e as redes neurais das demais classes.

Em paralelo, objetivando desenvolver um sistema mais simples ainda, no que tange a complexidade computacional, utilizou-se o valor RMS da janela de aquisição do evento e seus valores máximo e mínimo como parâmetros, que alimentaram uma única rede neural. Mostrou-se que, como a classe de sinais sem distúrbios é bastante homogênea, pôde-se utilizar uma rede neural com uma arquitetura simples. Evidentemente, este sistema demandou menor esforço computacional do que o sistema baseado em curvas. Porém, a capacidade de generalização para dados experimentais foi melhor para o sistema baseado em curvas principais. Comparativamente às demais técnicas propostas na literatura, os sistemas de detecção propostos mostraram elevada eficiência, devido ao seu alto desempenho quando reduzidas janelas de aquisição são processadas.

Em geral, as curvas principais mostraram-se excelentes ferramentas de análise de distúrbios e de extração de parâmetros. Os parâmetros extraídos por curvas mostraram-se representativos tanto na detecção quanto na classificação. Como vantagem, os mesmos parâmetros que alimentaram o detector, também alimentaram o classificador, tornando o sistema mais compacto. A conexão entre o detector e o classificador, neste caso realizada por meio da camada intermediária das RNA de detecção, podem fortalecer a capacidade de generalização do método. Adicionalmente, a boa capacidade de representação de dados das curvas pôde construir assinaturas distintas umas das outras para cada classe de distúrbios. A partir das distâncias entre estas assinaturas, constituídas pelas curvas de cada classe, um classificador de distúrbios simples e com alto desempenho foi projetado. Neste caso, apenas uma medida de distância do evento às curvas principais de cada classe possibilitou a classificação, não necessitando, contudo, da utilização de um classificador não linear.

Posto a complexidade do problema de classificação, o desempenho alcançado pelo classificador comprova a eficiência do método.

As curvas principais, portanto, mostram boa adequação ao problema de distúrbios isolados, realizando-se análise, detecção e classificação com bastante sucesso. Como diferencial, compôs um sistema trifásico com boa eficiência na classificação de quatro tipos de desbalanceamentos, identificando também a fase em que o mesmo ocorreu.

Uma metodologia alternativa, baseada em estatísticas de ordem superior, foi também proposta. A motivação principal foi a característica intrínseca das EOS de serem nulas para dados gaussianos. Esta característica pode dar aos sistemas projetados a partir das EOS imunidade a ruídos gaussianos. Não obstante, foi verificado que os parâmetros extraídos pelas EOS, em particular os cumulantes de segunda e quarta ordem, podem carregar informações acerca dos distúrbios capazes de gerar um espaço de parâmetros com boa separabilidade entre as classes. Nesta etapa, o discriminante de Fisher mostrou-se uma importante ferramenta na seleção dos cumulantes com maior poder de discriminação entre classes.

Comparativamente às curvas principais, as EOS tornam o projeto do sistema de classificação mais automático, já que os parâmetros são selecionados automaticamente pelo discriminante de Fisher. Já o projeto por curvas demanda mais esforços, posto que o número de segmentos em cada curva representativa de cada classe influencia diretamente no desempenho do sistema. Entretanto, a escolha do número de segmentos da curva é realizada com base no desempenho do sistema para o conjunto de sinais de validação, isto é, o número de segmentos é escolhido de acordo com o maior desempenho alcançado. Porém, o uso das curvas permite analisar a complexidade das classes dos distúrbios e do processo de classificação das mesmas, o que é útil para tomadas de decisões no projeto do classificador.

Em relação a abordagem do problema da ocorrência de distúrbios simultâneos, inicialmente foi proposto um método baseado em um banco de filtros para classificação. Dessa forma, sistemas mais simples podem fazer a classificação, enquanto uma lógica final, baseada nas saídas dos classificadores, decide pela classe de distúrbio múltiplo ou isolado que ocorreu. A vantagem desta abordagem é o fato de que a complexidade dos múltiplos distúrbios é superada pela sua divisão em

bandas de frequência específicas, permitindo, portanto, o uso de classificadores mais simples. Além disso, o número máximo de ocorrências de distúrbios em um mesmo segmento de sinal que o sistema pode classificar é dado pelo número de saídas do banco de filtros. Essa característica permite que o sistema possa abordar um número elevado de classes de múltiplos distúrbios. Um desempenho geral superior a 99 % foi alcançado pelo método, em que sete classes de distúrbios isolados e doze classes de múltiplos distúrbios foram abordadas.

Uma abordagem alternativa para análise de múltiplos distúrbios, com um enfoque maior na estimação dos distúrbios isolados, foi também realizada. Neste caso, o desacoplamento dos múltiplos distúrbios foi realizado através da Análise de Componentes Independentes. A técnica ICA, sob as considerações do modelo SCICA (ICA para um canal), foi aplicada às misturas de harmônicos com transitórios oscilatórios e harmônicos com *notches*. Essa abordagem é desejável, na prática, quando apenas um ponto no sistema elétrico de potência é monitorado. As estimativas dos distúrbios foram analisadas qualitativamente e quantitativamente, comparando-as com as fontes originais e sob o ponto de vista de classificação. Os resultados mostraram que o método se enquadra muito bem ao problema de múltiplos distúrbios, possibilitando posteriores aplicações de técnicas de análises, detecção e classificação.

Um resultado bastante promissor nesta abordagem foi o fato de que a utilização de uma matriz de separação geral, obtida com um conjunto de sinais de treinamento, possa estimar os distúrbios com boa qualidade, não necessitando, contudo, de se utilizar o algoritmo ICA a cada mistura processada. O ganho em velocidade de processamento, neste caso, é grande, uma vez que uma única multiplicação matricial é capaz de desacoplar os múltiplos distúrbios. Esta análise, apesar de ainda testada com apenas duas classes de múltiplos distúrbios, mostra-se bastante promissora, principalmente pela reduzida complexidade computacional requerida em fase operacional.

Adicionalmente, as técnicas inteligentes propostas neste trabalho podem ser utilizadas nas tão conhecidas redes inteligentes de energia, ou popularmente *smart grids*, que têm ganhado cada vez mais popularidade e destacam-se, de forma significativa, na lista de prioridades dos governos.

Desta forma, foram apresentados estudos originais e resultados inéditos relacionados à utilização de Curvas Principais, Estatísticas de Ordem Superior e Análise de Componentes Independentes para o problema de monitoração da Qualidade de Energia Elétrica.

9.1 Perspectivas

O projeto do detector e classificadores de distúrbios por curvas principais foi baseado nas informações reveladas pela prévia análise dos distúrbios por curvas. Esta análise apontou as distâncias dos eventos às curvas como parâmetros mais relevantes à detecção e classificação. Contudo, outros parâmetros são oferecidos no espaço das curvas, tais como os índices de projeção do evento à curva e o próprio evento projetado na curva. Sabe-se que o desempenho de técnicas de classificação e detecção está diretamente relacionado com a qualidade dos parâmetros utilizados. Portanto, propõe-se, como atividade futura, utilizar parâmetros alternativos na detecção e classificação por curvas, comparando-se os resultados com aqueles aqui obtidos. Nesta etapa, é sugerida a utilização de alguma técnica de seleção de parâmetros, tal como o discriminante de Fisher.

Conforme já discutido, a escolha do número de segmentos em cada curva principal, para fins de classificação, foi realizada testando-se o desempenho do classificador para os sinais de validação. Uma alternativa para otimizar este processo se dá pela realização da extração das curvas de cada classe simultaneamente (duas a duas), em que o ponto de corte para a inserção de mais segmentos seja escolhido pela maior distância obtida entre as curvas. Assim, a cada inserção de um novo segmento, calcula-se a distância entre as curvas.

A análise de desempenho das curvas para a classificação de múltiplos distúrbios, conforme sugerido no Capítulo 6, também constitui-se em uma interessante proposta de continuidade.

Sabe-se que uma das principais características das curvas é a sua capacidade de representar dados de alta dimensão em uma única dimensão. Esta qualidade pode, portanto, ser explorada de forma a fazer a compactação dos sinais de tensão corrompidos por distúrbios. Um problema comum no monitoramento da QEE é a

geração de arquivos de dados de grande extensão nos oscilógrafos. Neste contexto, pode-se utilizar as curvas principais para realizar a compactação dos distúrbios.

Os detectores aqui propostos não fazem uso das informações do componente fundamental do sinal, que é filtrado pelo filtro notch. O componente fundamental carrega informações mais relacionadas aos distúrbios de afundamentos, elevações e interrupções de tensão. Foi mostrado que os distúrbios não detectados pelos sistemas propostos foram suaves afundamentos de tensão. Como proposta futura, pretende-se incorporar informações extraídas do componente fundamental nos detectores propostos, objetivando-se elevar o desempenho.

Do ponto de vista da análise de múltiplos distúrbios, o classificador baseado em banco de filtros alcançou alto desempenho cobrindo um elevado número de classes. Espera-se realizar estudos visando a implementação deste sistema em dispositivos de *hardware*, tais como DSP ou FPGA, propondo-se a confecção de um produto para o monitoramento de QEE que explore os problemas de múltiplos distúrbios apresentados neste trabalho.

A estimação dos distúrbios por Análise de Componentes Independentes apresentada, limitou-se, até o momento, a três tipos de distúrbios: harmônicos, transitórios oscilatórios e *notches*, compondo apenas duas misturas, harmônicos com transitórios oscilatórios e harmônico com *notches*. Os resultados alcançados foram motivadores e, estudar as saídas do sistema proposto quando outras classes de distúrbios acontecem é de muita importância, e constitui-se em uma das propostas de continuidade deste trabalho. Ainda nesta linha, os resultados obtidos para a análise por branqueamento mostraram-se promissores e, portanto, requerem maiores investigações no sentido de definir até que ponto apenas o branqueamento pode ser suficiente na abordagem SCICA para múltiplos distúrbios.

Por outro lado, sabe-se que a origem de um distúrbio no sistema elétrico não o restringe a um único ponto. Em outras palavras, um mesmo distúrbio pode ser propagado para diferentes pontos no sistema elétrico e, portanto, o monitoramento de mais de um ponto pode ser interessante e será explorado em trabalhos futuros. Esta abordagem é interessante também pelo fato de que o distúrbio passa a ser monitorado por diferentes pontos simultaneamente. Logo, no caso do aparecimento de um múltiplo distúrbio, mais misturas podem estar disponíveis. Neste caso, a técnica

ICA se aplica em uma abordagem diferente da SCICA. É importante estudar as vantagens, do ponto de vista de desacoplamento de múltiplos distúrbios via ICA, em se monitorar mais de um ponto no sistema elétrico de potência. Este monitoramento pode ser realizado conforme ilustra a Figura 9.1, em que $v_1[n]$ e $v_2[n]$ representam os sinais de tensão monitorados no ponto 1 e ponto 2 do SEP, respectivamente. Esta figura ilustra um sistema genérico em que dois pontos do SEP são monitorados, no entanto, mais pontos podem ser simultaneamente monitorados.



Figura 9.1: Sistema genérico de desacoplamento de múltiplos distúrbios via ICA fazendo o monitoramento de dois pontos do SEP.

Por outro lado, pode-se realizar a monitoração trifásica. Neste caso, os sinais de tensão das fases A, B e C serão apresentados ao algoritmo ICA, conforme ilustra o diagrama em blocos da Figura 9.2. Esta abordagem trifásica, contudo, será explorada em trabalhos futuros.




Figura 9.2: Sistema trifásico de desacoplamento de múltiplos distúrbios via ICA.

Referências Bibliográficas

- [1] ON POWER QUALITY, I. S. C. C. . *IEEE recommended practice for monitoring electric power quality*. Relatório técnico, IEEE, 1995.
- [2] VEGA, T. Y., ROIG, V. F., SEGUNDO, H. B. S. “Evolution of signal processing techniques in power quality”, *9th International Conference on Electrical Power Quality and Utilisation - EPQU2007*, pp. 1–5, Outubro 2007.
- [3] BOLLEN, M. H. J., RIBEIRO, P. F., GU, I. Y. H., et al. “Trends, challenges and opportunities in power quality research”, *EUROPEAN, Transactions on Electrical Power*, v. 20, pp. 3–18, 2009.
- [4] IEC. *IEC-91- Draft Classification of Electromagnetic Environments*. Relatório técnico, IEC: TC77WG6 (Secretary) 110-R5, Janeiro 1991.
- [5] ARRILLAGA, J., BOLLEN, M. H. J., WATSON, N. R. “Power Quality Following Deregulation”, *Proceedings of the IEEE*, v. 88, n. 2, pp. 246–261, Fevereiro 2000.
- [6] ANEEL. *PRODIST: Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional*. Relatório técnico, www.aneel.gov.br, 2007.
- [7] BOLLEN, M. H. J., GU, I. Y. H. *Signal processing of power quality disturbances*. Wiley-Interscience, 2006.
- [8] BOLLEN, M. H. J., GU, I. Y. H., SANTOSO, S., et al. “Bridging the gap between signal and power”, *IEEE Signal Processing Magazine*, v. 23, n. 4, pp. 12–31, Julho 2009.
- [9] IEC. *Power Quality Measurement Methods*. Relatório técnico, IEC 610000-4-30, 2003.

- [10] KHAN, A. “Monitoring power for the future”, *Power Engineering Journal* [see also *Power Engineer*], v. 15, n. 2, pp. 81–85, Abril 2001.
- [11] WANG, M., ROWE, G., MAMISHEV, A. “Real-time power quality waveform recognition with a programmable digital signal processor”, *IEEE Power Engineering Society General Meeting*, v. 2, pp. 1268–1273, Julho 2003.
- [12] *FPGA realization of power quality disturbance detection: an approach with wavelet, ANN and fuzzy logic*, v. 4, Agosto 2005. Proceedings of International Joint Conference on Neural Networks - IJCNN.
- [13] CARNOVALE, D., ELLIS, D. “The evolution of power quality data acquisition systems-triggering to capture power quality events”, *Conference Record of the 2002 Annual Pulp and Paper Industry Technical Conference*, pp. 159–167, Junho 2002.
- [14] FLORES, R. A. “State of the Art in the Classification of Power Quality Events, An Overview”, *Harmonics and Quality of Power, 2002. 10th International Conference on*, v. 1, pp. 17–20, 2002.
- [15] THEODORIDIS, S., KOUTROUMBAS, K. *Pattern Recognition*. Academic Press, San Diego, 1999.
- [16] DUDA, R. O., HART, P. E., STORK, D. G. *Pattern Classification*. 2 ed. , Wiley-Interscience, 2000.
- [17] JAIN, A., DUIN, R., MAO, J. “Statistical pattern recognition: a review”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 22, n. 1, pp. 4–37, Janeiro 2000.
- [18] HAYKIN, S. *Neural networks. A comprehensive foundation*. 2 ed. , NJ: Englewood Cliffs, Prentice Hall, 1999.
- [19] DUQUE, C. A., RIBEIRO, M. V., RAMOS, F. R., et al. “Power Quality Event Detection Based on the Divide and Conquer Principle and Innovation Concept”, *IEEE Transactions on Power Delivery*, v. 20, n. 4, pp. 2361 – 2369, Outubro 2005.

- [20] RIBEIRO, M. V., DUQUE, C. A., ROMANO, J. M. T. “An improved method for signal processing and compression in power quality evaluation”, *IEEE Transactions on Power Delivery*, v. 19, n. 2, pp. 464–471, Abril 2004.
- [21] RAMOS, F. R., RIBEIRO, M. V., ROMANO, J. M. T., et al. “On signal processing approach for event detection and compression applied to power quality evaluation”, in *Proc. IEEE 10th International Conference on Harmonic and Quality of Power*, pp. 133–138, 2002.
- [22] STYVAKTAKIS, E., BOLLEN, M. H. J., GU, I. Y. H. “Expert system for classification and analysis of power system events”, *IEEE Transaction on Power Delivery*, v. 17, n. 2, pp. 423–428, Abril 2002.
- [23] MENDEL, J. M. *Uncertain rule-based fuzzy logic systems. Introduction and new directions*. NJ: Prentice Hall, 2001.
- [24] PEDRYCZ, W., GOMIDE, F. *An introduction to fuzzy sets: Analisis and design*. 2 ed. ed. , MIT Press, 1998.
- [25] PRÍNCIPE, J. C., EULIANO, N. R., LEFEBVRE, W. C. *Neural and adaptive systems. Fundamentals through simulations*. 2 ed. ed. , John Wiley & Sons, 2000.
- [26] IBRAHIM, A. W. R., MORCOS, M. M. “Artificial intelligence and advanced mathematical tools for power quality applications: a survey”, *IEEE Trans. on Power Delivery*, v. 17, n. 2, pp. 668–673, Abril 2002.
- [27] POISSON, O., RIOUAL, P., MEUNIER, M. “Detection and measurement of power quality disturbances using wavelet transform”, *IEEE Transactions on Power Delivery*, v. 15, n. 3, pp. 1039–1044, Julho 2000.
- [28] YANG, H.-T., LIAO, C.-C. “A de-noising scheme for enhancing wavelet-based power quality monitoring system”, *IEEE Transactions on Power Delivery*, v. 16, n. 3, pp. 353–360, Julho 2001.
- [29] SANTOSO, S., GRADY, W. M., POWERS, E. J., et al. “Characterization of distribution power quality events with Fourier and wavelet transforms”, *IEEE Transactions on Power Delivery*, v. 15, n. 1, pp. 247–254, 2000.

- [30] STYVAKTAKIS, E. *Automating Power Quality Analysis*. Ph.D. dissertation, Dept. of Signals and Systems, Chalmers Univ. Technology, Gothenburg, Sweden, 2002.
- [31] GU, I. Y. H., ERNBERG, N., STYVAKTAKIS, E., et al. “A Statistical-Based Sequential Method for Fast Online Detection of Fault-Induced Voltage Dips”, *IEEE Transactions on Power Delivery*, v. 19, n. 2, pp. 497–504, Abril 2004.
- [32] HE, H., STARZYK, J. A. “A Self-Organizing Learning Array System for Power Quality Classification Based on Wavelet Transform”, *IEEE Transactions on Power Delivery*, v. 21, n. 1, pp. 286–295, Janeiro 2006.
- [33] KIM, C. H., AGGAWAL, R. “Wavelet transforms in power systems Part 2: Examples of application to actual power system transients”, *Power Engineering Journal*, pp. 193–202, Agosto 2001.
- [34] DELMONT, O. F. *Utilização da Transformada Wavelet para Caracterização de Distúrbios na Qualidade da Energia Elétrica*. Dissertação de Mestrado, Escola de Engenharia de São Carlos - Universidade de São Paulo, 2003.
- [35] SANTOSO, S., POWERS, E. J., HOFMANN, P. “Power quality assessment via wavelet transform analysis”, *IEEE Trans. on Power Delivery*, v. 11, n. 2, pp. 924–930, Abril 1996.
- [36] GAOUDA, A. M., SALAMA, M. A., SULTAN, M. R., et al. “Power quality detection and classification using wavelet-multiresolution signal decomposition”, *IEEE Transactions on Power Delivery*, v. 14, pp. 1469–1476, 1999.
- [37] HU, G.-S., XIE, J., ZU, F.-F. “Classification of Power Quality Disturbances Using Wavelet and Fuzzy Support Vector Machines,”. In: *Fourth International Conference on Machine Learning and Cybernetics*, Guangzhou, China, Agosto 2005.
- [38] PANIGRAHI, B. K., PANDI, V. R. “Optimal feature selection for classification of power quality disturbances using wavelet packet-based fuzzy

- k-nearest neighbour algorithm”, *IET Generation, Transmission & Distribution*, v. 3, n. 3, pp. 296–306, Outubro 2009.
- [39] XUE, C., HUI-JIN, L., QUAN-MING, Z., et al. “Power Quality Disturbances Detection and Location Using Mathematical Morphology and Complex Wavelet Transformation”. In: *3rd IEEE Conference on Industrial Electronics and Applications*, pp. 2263–2268, 2008.
- [40] LIU, L., ZENG, Z. “The detection and location of power quality disturbances based on orthogonal wavelet packet transform”. In: *Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies*, pp. 1831–1835, 2008.
- [41] YOUSSEF, A. M., ABDEL-GALIL, T. K., EL-SAADANY, E. F., et al. “Disturbance Classification Utilizing Dynamic Time Warping Classifier”, *IEEE Transaction on Power Delivery*, v. 19, n. 1, pp. 272–278, Janeiro 2004.
- [42] FERREIRA, D. D., MARQUES, C. A. G., CERQUEIRA, A. S., et al. “Sistema Automático de Detecção e Classificação de Distúrbios Elétricos em Qualidade de Energia Elétrica”, *Sociedade Brasileira de Automática*, v. 20, pp. 53–62, 2009.
- [43] RIBEIRO, M. V., MARQUES, C. A. G., DUQUE, C. A., et al. “Power Quality Disturbances Detection Using HOS”, *IEEE Power Engineering Society General Meeting*, pp. 1–6, 2006.
- [44] NIKIAS, C., MENDEL, J. “Signal processing with higher-order statistics”, *IEEE Trans. on Signal Processing*, v. 41, n. 1, pp. 10–38, Janeiro 1999.
- [45] NIKIAS, C. L., PETROPULU, A. P. *Higher-Order Spectra Analysis - A Non-linear Signal Processing Framework*. NJ, Englewood Cliffs, Prentice Hall, 1993.
- [46] MENDEL, J. M. “Tutorial on higher-order statistics (spectra) in signal processing and system theory: theoretical results and some applications”, *Proc. of the IEEE*, v. 79, n. 3, pp. 278–305, Março 1991.

- [47] FERREIRA, D. D., CERQUEIRA, A. S., DUQUE, C. A., et al. “HOS-based method for classification of power quality disturbances”, *Electronics Letters*, v. 45, n. 3, pp. 83–185, 2009.
- [48] ÖMER NEZİH GEREK, ECE, D. G. “Power-Quality Event Analysis Using Higher Order Cumulants and Quadratic Classifiers”, *IEEE Transactions on Power Delivery*, v. 21, n. 2, pp. 883–889, Abril 2006.
- [49] FERRERO, A., SALICONE, S. “An easy VI program to detect transient disturbances in the supply voltage”, *IEEE Trans. on Instrumentation and Measurement*, v. 54, n. 4, pp. 1471–1474, Agosto 2005.
- [50] ARTIOLI, M., PASINI, G., PERETTO, L., et al. “Low-cost DSP-based equipment for the real-time detection of transients in power systems”, *IEEE Trans. on Instrumentation and Measurement*, v. 53, n. 4, pp. 933–939, Agosto 2004.
- [51] COSTA, F., SOUZA, B., BRITO, N. “A wavelet-based algorithm to analyze oscillographic data with single and multiple disturbances”, *Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century, 2008 IEEE*, pp. 1–8, Julho 2008.
- [52] WANG, M., MAMISHEV, A. V. “Classification of Power Quality Events Using Optimal Time-Frequency Representations - Part 1: Theory”, *IEEE Transactions on Power Delivery*, v. 19, n. 3, pp. 1488–1495, 2004.
- [53] WANG, M., ROWE, G. I., MAMISHEVV, A. V. “Classification of Power Quality Events Using Optimal Time-Frequency Representations - Part 2: Application”, *IEEE Transactions on Power Delivery*, v. 19, n. 3, pp. 1496–1503, 2004. NJ.
- [54] LEE, J., LEE, C., KIM, J., et al. “Classification of power quality disturbances using orthogonal polynomial approximation and bispectra”, *Electronics Letters*, v. 33, n. 18, pp. 1522–1524, 1997.
- [55] WANG, M., OCHENKOWSKI, P., MAMISHEVV, A. V. “Classification of Power Quality disturbances using time-frequency ambiguity plane and

- neural networks”, *IEEE Power Eng. Soc. Summer Meeting*, v. 2, pp. 1246–1251, 2001.
- [56] FERREIRA, D. D., CERQUEIRA, A. S., RIBEIRO, M. V., et al. “Técnica para a Classificação de Distúrbios Elétricos Relacionados à Qualidade de Energia”, *XVI Congresso Brasileiro de Automática - CBA2006*, pp. 1567–1572, 2006.
- [57] MISHRA, S., BHENDE, C. N., PANIGRAHI, B. K. “Detection and Classification of Power Quality Disturbances Using S-Transform and Probabilistic Neural Network”, *IEEE Transactions on Power Delivery*, v. 23, n. 1, pp. 280–287, Janeiro 2008.
- [58] MONEDERO, I., LEÓN, C., ROPERO, J., et al. “Classification of Electrical Disturbances in Real Time Using Neural Networks”, *IEEE Transactions on Power Delivery*, v. 22, n. 3, pp. 1288–1296, Julho 2007.
- [59] HOANG, T. A., NGUYEN, D. T. “Improving training of radial basis function network for classification of power quality disturbances”, *Electronics Letters*, v. 38, n. 17, pp. 976–977, 2002.
- [60] FERREIRA, D. D., CERQUEIRA, A. S., RIBEIRO, M. V., et al. “Hos-based method for power quality event classification”, *14th European Signal Processing Conference-EUSIPCO 2006*, v. 1, pp. 200–206, 2006.
- [61] GAOUDA, A. M., KANAUN, S. H., SALAMA, M. A., et al. “Pattern Recognition Applications for Power System Disturbance Classification”, *IEEE Transactions on Power Delivery*, v. 17, n. 3, pp. 677–683, Julho 2002.
- [62] HUANG, J., NEGNEVITSKY, M., NGUYEN, D. T. “A neural-fuzzy classifier for recognition of power quality disturbances”, *IEEE Transaction on Power Delivery*, v. 17, n. 4, pp. 609 – 616, Abril 2002.
- [63] ELMITWALLY, A., ABDELKADER, S., ELKATEB, M. “Universal power quality manager with a new control scheme”, *Proc. Inst. Electr. Eng. Gener. Transm. Distrib.*, v. 147, pp. 183–189, Maio 2000.

- [64] K.KUNG, C., DEVANEY, M. J., HUANG, C. M., et al. “Fuzzy-based adaptive digital power metering using a genetic algorithm”, *IEEE Trans.Instrum. Meas.*, v. 47, n. 1, pp. 183–188, Janeiro 1998.
- [65] CERQUEIRA, A. S., FERREIRA, D. D., RIBEIRO, M. V., et al. “Power quality events recognition using a SVM-based method”, *Electric Power Systems Research*, v. 78, pp. 1546–1552, Março 2008.
- [66] LIN, W.-M., WU, C.-H., LIN, C.-H., et al. “Classification of Multiple Power Quality Disturbances Using Support Vector Machine and One-versus-One Approach”, *International Conference on Power System Technology*, pp. 1–8, 2006.
- [67] RIBEIRO, M. V. *Técnicas de Processamento de Sinais Aplicadas à Transmissão de Dados Via Rede Elétrica e ao Monitoramento da Qualidade de Energia*. Tese de Doutorado, Universidade Estadual de Campinas (UNICAMP), Abril 2005.
- [68] RIBEIRO, M. V., MARQUES, C. A. G., DUQUE, C. A., et al. “Detection of Disturbances in Voltage Signals for Power Quality Analysis Using HOS”, *EURASIP Journal on Applied Signal Processing, Special Issue on Emerging Signal Processing Techniques for Power Quality Applications*, v. 2007, 2007.
- [69] JANIK, P., LOBOS, T., SCHEGNER, P. “Classification of Power Quality Events Using SVM Networks”, *Developments in Power System Protection. Eighth IEE International Conference on*, v. 2, pp. 768 – 771, Abril 2004.
- [70] QIAN, L., CARTES, D. A., LI, H. “An Improved Adaptive Detection Method for Power Quality Improvement”, *IEEE Transactions on Industry Applications*, v. 44, n. 2, pp. 525–533, Março/Abril 2008.
- [71] LEE, J., WON, Y. J., JEONG, J. M., et al. “Classification of power quality disturbances using feature extraction in time-frequency plane”, *Electronics Letters*, v. 38, n. 15, pp. 833–835, 2002.

- [72] GU, I. Y.-H., STYVAKTAKIS, E. “Bridge the gap: signal processing for power quality applications”, *Electric Power Systems*, v. 66, pp. 83–96, 2003.
- [73] GARGOOM, A. M., ERTUGRUL, N., SOONG, W. L. “Automatic Classification and Characterization of Power Quality Events”, *IEEE Transactions on Power Delivery*, v. 23, n. 4, pp. 2417–2425, Outubro 2008.
- [74] AZAM, M. S., TU, F., PATTIPATI, K. R., et al. “A dependency model-based approach for identifying and evaluating power quality problems.” *IEEE Transaction on Power Delivery*, v. 19, n. 3, pp. 1154–1166, Julho 2004.
- [75] ZHAO, F., YANG, R. “Power-Quality Disturbance Recognition Using S-Transform”, *IEEE Transaction on Power Delivery*, v. 22, n. 2, pp. 944–950, Abril 2007.
- [76] ABDEL-GALIL, T. K., KAMEL, M., YOUSSEF, A. M., et al. “Power Quality Disturbance Classification Using the Inductive Inference Approach”, *IEEE Transaction on Power Delivery*, v. 19, n. 4, pp. 1812 – 1818, Outubro 2004.
- [77] CHUANG, C.-L., LU, Y.-L., HUANG, T., et al. “Recognition of Multiple PQ Disturbances Using Wavelet-based Neural Networks - Part 1: Theoretical Introduction”, *IEEE/PES Transmission and Distribution Conference & Exhibition: Asia and Pacific Dalian, China*, 2005.
- [78] CHUANG, C.-L., LU, Y.-L., HUANG, T., et al. “Recognition of Multiple PQ Disturbances Using Wavelet-based Neural Networks - Part 2: Implementation and Applications”, *IEEE/PES Transmission and Distribution Conference & Exhibition: Asia and Pacific Dalian, China*, 2005.
- [79] TSUKUI, R., BEAUMONT, P., TANAKA, T., et al. “Power system protection and control utilising intranet technology”, *Power Engineering Journal*, v. 15, n. 5, pp. 249–255, Outubro 2001.
- [80] RIBEIRO, M. V., PEREIRA, J. L. R. “Classification of Single and Multiple Disturbances in Electric Signals”, *EURASIP Journal on Advances in Signal Processing*, v. 2007, 2007.

- [81] HASTIE, T. J., STUETZLE, W. “Principal Curves”, *Journal of the American Statistical Association*, v. 84, n. 406, pp. 502–516, 1989.
- [82] HAYKIN, S. *Neural networks and Learning Machines*. 3 ed. , Prentice Hall, 2008.
- [83] HYVÄRINEN, A., OJA, E. “Independent component analysis: algorithms and applications”, *Neural Networks*, v. 13, pp. 411–430, Março 2000.
- [84] HIRANO, K., NISHIMURA, S., MITRA, S. K. “Design of digital notch filters”, *IEEE Trans. on Communications*, v. 22, n. 7, pp. 964–970, Julho 1974.
- [85] MITRA, S. K. *Digital Signal Processing: A computer-based approach*. third ed. , McGraw-Hill, 2005.
- [86] MARQUES, C. A. G. *Técnica de Detecção de Distúrbios Para o Monitoramento da Qualidade de Energia Elétrica*. Dissertação, Universidade Federal de Juiz de Fora, Juiz de Fora, MG, Março 2007.
- [87] FERREIRA, D. D. *Classificação Automática de Distúrbios Elétricos Ligados À Qualidade de Energia*. Dissertação, Universidade Federal de Juiz de Fora, Juiz de Fora, MG, Fevereiro 2007.
- [88] SOCIETY, I. I. A. *Ieee guide for the design and application of power electronics in electrical power systems on ships*. Relatório técnico, IEEE, 2008.
- [89] KARIMI-GHARTEMANI, M., IRAVANI, M. R. “A Nonlinear Adaptive Filter for Online Signal Analysis in Power Systems: Applications”, *IEEE Transactions on Power Delivery*, v. 17, n. 2, 2002.
- [90] KARIMI-GHARTEMANI, M., IRAVANI, M. R. “Robust and frequency-adaptive measurement of peak value”, *IEEE Transactions on Power Delivery*, v. 19, n. 2, pp. 481–489, Abril 2004.
- [91] SHLENS, J. “A tutorial on Principal Component Analysis”. In: *Systems Neurobiology Laboratory, Salk Institute for Biological Studies*, 2005.
- [92] DE SEIXAS, J. M., FERNANDEZ, H. L., NEVES, S. R., et al. “Combining Morphological Mapping and Principal Curves for Ship Classification”,

IEEE International Symposium on Signals, Circuits and System, pp. 605–608, 2005.

- [93] VERBEEK, J. J., VLASSIS, N., KROSE, B. “A K-segments Algorithm for Finding Principal Curves”, *Pattern Recognition Letters*, v. 23, n. 8, pp. 1009–1017, 2002.
- [94] TARPEY, T., LI, L., FLURY, B. D. “Principal Points and Self-consistent Points of Elliptical Distributions”, *Annals of Statistics*, v. 23, n. 6, pp. 103–112, 1995.
- [95] RIEDMILLER, M., BRAUN, H. “A direct adaptive method for faster backpropagation learning: The rprop algorithm”. In: *IEEE Intl. Conf. on Neural Networks*, pp. 586–591, 1993.
- [96] WANG, M., SUN, Y. “A practical, precise method for frequency tracking and Phasor Estimation”, *IEEE Transactions on Power Delivery*, v. 19, n. 2, pp. 1547–1552, Outubro 2004.
- [97] SAMANTARAY, S. R. “Decision tree-initialised fuzzy rule-based approach for power quality events classification”, *IET Generation, Transmission & Distribution*, v. 4, n. 4, pp. 538–551, Abril 2010.
- [98] KIM, C. H., AGGAWAL, R. “Wavelet transforms in power systems Part 1: Geral introduction to the wavelet transforms”, *Power Engineering Journal*, pp. 81–87, Abril 2000.
- [99] VIANELLO, R., FERREIRA, D. D., DUQUE, C. A., et al. “Classificação de Múltiplos Distúrbios de Qualidade de Energia Baseado em Transformada Wavelet, EOS e Redes Neurais”. In: *Anais do VIII CBQEE Conferência Brasileira Sobre Qualidade de Energia Elétrica*, Blumenau, 2009.
- [100] CHANDEL, A., GULERIA, G., CHANDEL, R. “Classification of power quality problems using wavelet based artificial neural network”, *Transmission and Distribution Conference and Exposition, 2008. T&D. IEEE/PES*, pp. 1–5, Abril 2008.

- [101] RUIJUAN, J., CHUNXIA, X. “Power quality event detection and recognition using wavelet analysis and intelligent neural network”, *Control Conference, 2008. CCC 2008. 27th Chinese*, pp. 486–489, Julho 2008.
- [102] WEIJIAN, H., WEILI, H. “Automatic power quality recognition and analysis system using wavelet-based neural network”, *Control Conference, 2008. CCC 2008. 27th Chinese*, pp. 222–225, Julho 2008.
- [103] HYVÄRINEN, A., KARHUNEN, J., OJA, E. *Independent Component Analysis*. A Wiley-Interscience Publication, 2001.
- [104] LIMA, M. A. A., FERREIRA, D. D., CERQUEIRA, A. S., et al. “Separation And Recognition of Multiple PQ Disturbances Using Independent Component Analysis And Neural Networks”, *13th International Conference on Harmonics and Quality of Power - ICHQP2008*, 2008.
- [105] LIMA, M. A. A. *Análise de Componentes Independentes Aplicada em Distúrbios de Qualidade de Energia*. Dissertação, Universidade Federal de Juiz de Fora, Juiz de Fora, MG, Fevereiro 2009.
- [106] HYVÄRINEN, A., INKI, M. “Estimating Overcomplete Independent Component Bases for Image Windows”, *Journal of Mathematical Imaging and Vision*, v. 17, n. 2, pp. 139–152, 2002.
- [107] THEIS, F. J., LANG, E. W., PUNTONET, C. G. “A Geometric algorithm for Overcomplete Linear ICA”, *International Journal of Neurocomputing*, v. 56, pp. 381–398, 2004.
- [108] BORSCHBACH, M., HAHN, I. “Separation capability of overcomplete ICA approaches”. In: *Proceedings of the 6th Conference on 6th WSEAS international Conference on Signal Processing*, v. 6, pp. 146–151, 2007.
- [109] DAVIES, M. E., JAMES, C. J. “Source separation using single channel ICA”, *Signal Processing*, v. 87, pp. 1819–1832, 2007.
- [110] JAMES, C. J., WANG, S. “Blind Source separation in single-channel EEG analysis: An application to BCI”. In: *28th Annual International Con-*

- ference of the IEEE Engineering in Medicine and Biology Society*, pp. 6544–6547, 2006.
- [111] OJA, E., YUAN, Z. “The FastICA Algorithm Revisited: Convergence Analysis”, *IEEE Transactions on Neural Networks*, v. 17, n. 6, pp. 1373–1381, 2006.
- [112] JOE, H. “Relative Entropy Measures of Multivariate Dependence”, *Journal of the American Statistical Association*, v. 84, n. 405, pp. 157–164, Março 2000.
- [113] MODDEMEIJER, R. “A statistic to estimate the variance of the histogram based mutual information estimator based on dependent pairs of observations”, *Signal Processing*, v. 75, n. 1, pp. 51–63, 1999.
- [114] BOTEV, Z. I., GROTHOWSKI, J. F., KROESE, D. P. “Kernel Density Estimation Via Diffusion”, *The Annals of Statistics*, v. 38, n. 5, pp. 2916–2957, 2010.
- [115] BELOUHRANI, A., MERAİM, K. A., CARDOSO, J., et al. “A blind source separation technique based on second order statistics”, *IEEE Transactions on Signal Processing*, v. 45, n. 2, pp. 434–444, 1997.
- [116] BELOUHRANI, A., CICHOCKI, A. “Robust whitening procedure in blind source separation context”, *Electronics Letter*, v. 36, n. 24, pp. 2050–2051, Novembro 2000.
- [117] TONG, L., SOON, V. C., HUANG, Y. F., et al. “Amuse: A new blinde identification algorithm”. In: *International Symposium On Circuits and Systems*, v. 3, pp. 1784–1787, New Orleans, USA, 1990.
- [118] TOME, A. M., TEIXEIRA, A. R., LANG, E. W., et al. “Blind source separation using time-delayed signals”, *Neural Networks*, v. 3, pp. 2187–2191, Julho 2004.
- [119] T.AKUZAWA. “Extended quasi-Newton method for the ICA”. In: *Proceedings of the International Workshop on Independent Component Analysis and Blind Signal Separation*, pp. 521–525, 2000.

- [120] ROSENBLATT, F. *Principles of neurodynamics*. New York: Spartan Books, 1962.
- [121] THORP, J. S., PHADKE, A. G., KARIMI, K. J. “Real Time Voltage-Phasor Measurements For Static State Estimation”, *IEEE Transactions on Power Apparatus and Systems*, v. 104, n. 11, pp. 3098–3106, Novembro 1985.
- [122] MIRANDA, A. L. L. *Projetos de Filtros Digitais para Análise de Sinais do Sistema Elétrico*. Dissertação de mestrado, Universidade Federal do Rio de Janeiro, Fevereiro 2005.
- [123] GEORGIEV, P., RALESCU, A., RALESCU, D. “Cross-cumulants measure for independence”, *Journal of Statistical Planning and Inference*, v. 137, pp. 1085–1098, Julho 2006.
- [124] CICHOCKI, A., UNBEHAUEN, R. “Robust Neural Networks with On-Line Learning for Blind Identification and Blind Separation of Sources”, *Transactions on Circuits and Systems*, v. 43, n. 11, pp. 894–906, Novembro 1996.
- [125] HYVÄRINEN, A., OJA, E. “A fast fixed-point algorithm for independent component analysis”, *Neural Computation*, v. 9, n. 7, pp. 1483–1492, 1997.
- [126] HYVÄRINEN, A. “Fast and robust fixed-point algorithms for independent component analysis”, *IEEE Transactions on Neural Networks*, v. 10, n. 3, pp. 626–634, 1999.
- [127] DAUBECHIES, I. “The wavelet transform, time-frequency location and signal analysis”, *IEEE Transaction Information Theory*, v. 36, pp. 961–1005, 1990.

Apêndice A

Redes Neurais Artificiais

As redes neurais artificiais (RNA) [82] apresentam uma grande versatilidade na resolução de diversos tipos de problemas, como em sistemas de reconhecimento de padrões e compressão de voz e imagem, pilotos automáticos de aviões, sistemas de predição de taxa de câmbio, desenvolvimento de produtos, controle de processos, análises de eletroencefalograma (EEG) e eletrocardiograma (ECG), e vários outros problemas em diferentes áreas..

Das diversas arquiteturas (estruturas) de redes, a mais utilizada em aplicações de reconhecimento de padrões é a rede alimentada diretamente com múltiplas camadas. Conforme definido em [82], esta rede consiste de um conjunto de unidades sensoriais que constituem a camada de entrada, uma ou mais camadas ocultas e uma camada de saída. O sinal de entrada se propaga para frente através da rede, camada por camada. Tais redes são, normalmente, chamadas de perceptrons de múltiplas camadas (MLP - *Multilayer Perceptron*) [120]. A Figura A.1 ilustra um perceptron com quatro camadas, sendo duas camadas ocultas.

Os perceptrons de múltiplas camadas têm sido aplicados com bastante sucesso para resolver diversos problemas complexos, através do seu treinamento de forma supervisionada com um algoritmo muito popular conhecido como algoritmo de retro-propagação de erro (*error back-propagation*) [82].

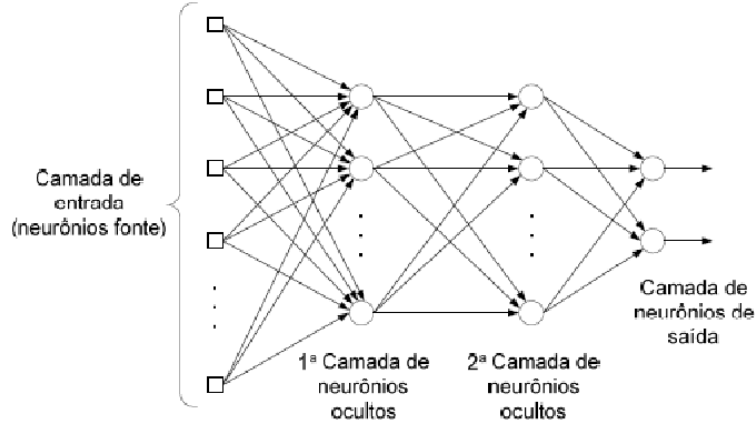


Figura A.1: Perceptron de múltiplas camadas.

A.1 Resilient Propagation

As RNA extrai informações relevantes de padrões de informações que lhe forem apresentadas, criando assim uma representação própria. Esta etapa é conhecida por aprendizagem ou treinamento, e consiste em um processo iterativo de ajuste de parâmetros da rede, dos pesos de conexões entre as unidades de processamento que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente que está operando.

Nesta etapa, destaca-se o algoritmo *Resilient Propagation* (Pprop) [95], que tem capacidade de acelerar o processo de aprendizagem. A principal característica deste algoritmo é que os ajustes dos pesos (ω) e da taxa de aprendizado (η) depende apenas dos sinais dos gradientes da função erro $E(\omega)$, não dependendo, portanto, da sua amplitude. A função $E(\omega)$ é responsável pela especificação de um critério de desempenho que está associado à rede [82].

No algoritmo Rprop, os pesos e a taxa de aprendizagem são alterados apenas uma única vez a cada época de treinamento. Cada peso ω_{ij} possui sua própria taxa de variação Δ_{ij} , a qual varia conforme a Equação A.1 [95].

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial E}{\partial \Delta \omega_{ji}}^{(t-1)} \frac{\partial E}{\partial \Delta \omega_{ji}}^{(t)} > 0 \\ \eta^- \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial E}{\partial \Delta \omega_{ji}}^{(t-1)} \frac{\partial E}{\partial \Delta \omega_{ji}}^{(t)} < 0 \\ \Delta_{ij}^{(t-1)}, & \text{caso contrário} \end{cases} \quad (\text{A.1})$$

em que, $0 < \eta^- < 1 < \eta^+$. Assim, cada vez que a derivada parcial do peso correspondente ω_{ij} alterar o sinal, significa que a última atualização foi muito excessiva

e o algoritmo pulou o mínimo local. Como consequência, o valor de Δ_{ij} é reduzido pelo fator η^- . Se o sinal da derivada se mantém, o valor de Δ_{ij} é levemente aumentado para acelerar o processo de convergência. Os pesos da rede são então alterados conforme mostra a Equação A.2.

$$\omega_{ij}^{(t+1)} = \omega_{ij}^{(t)} + \Delta\omega_{ij}^{(t)}, \quad (\text{A.2})$$

em que $\Delta\omega_{ij}^{(t)}$ é definido conforme Equação A.3.

$$\Delta\omega_{ij}^{(t)} = \begin{cases} -\Delta_{ij}^{(t)}, & \text{se } \frac{\partial E}{\partial \Delta\omega_{ji}}^{(t)} > 0 \\ +\Delta_{ij}^{(t)}, & \text{se } \frac{\partial E}{\partial \Delta\omega_{ji}}^{(t)} < 0 \\ 0, & \text{caso contrário} \end{cases} \quad (\text{A.3})$$

Apêndice B

Complexidade Computacional

Pode-se inferir sobre a complexidade computacional de um método calculando o número de operações matemáticas necessárias para processar um evento (ou uma realização) em termos do tamanho da janela de aquisição analisada.

A Tabela B.1 ilustra o custo computacional das principais técnicas utilizadas nesta tese, em termos do número de operações matemáticas necessárias para processar uma janela de sinal com N amostras. M representa a ordem de um filtro IIR. O número de entradas, saídas e neurônios na camada intermediária da rede neural é dado, respectivamente, por N_e , N_s e N_n . d_{ij} é a distância do evento i ao segmento de curva j de uma curva principal.

Tabela B.1: Custo computacional dos algoritmos utilizados em tempo real no contexto desta tese.

Rotinas	Adições	Multiplificações	$\tan(\cdot)$
RMS	$3N$	$N + 1$	—
Filtro <i>Notch</i>	$4N$	$3N$	—
Filtro IIR	$N(2M)$	$N(2M + 1)$	—
Cumulante de 2ª Ordem	$N - 1$	$N + 1$	—
Cumulante de 4ª Ordem	$3N - 2$	$5(N + 1)$	—
Rede Neural	$N_n(N_e + N_s + 1) + N_s$	$N_n(N_e + N_s)$	$N_n + N_s$
d_{ij}	$4N$	$3N$	—

Apêndice C

Discriminante Linear de Fisher

O discriminante linear de Fisher (FDR - *Fisher Discriminat Ratio*) é uma técnica bastante simples para discriminação de dados multi-dimensionais. Conforme bem discutido em [16], o FDR tem duas principais e diferentes aplicações: pode ser usado como separador de classes e como ferramenta de seleção de parâmetros.

C.1 FDR Como Classificador

Para entender ambas as aplicações do FDR, suponha um espaço de n eventos d -dimensionais, $\mathbf{x}_1, \dots, \mathbf{x}_n$, em que n_1 pertence à classe 1 (C_1) e n_2 à classe 2 (C_2). Se a média das amostras d -dimensionais da classe i é:

$$\mathbf{m}_i = \frac{1}{n_i} \sum_{\mathbf{x} \in C_i} \mathbf{x}, \quad (\text{C.1})$$

pode-se definir as matrizes *scatters* \mathbf{S}_i , \mathbf{S}_W e \mathbf{S}_B por:

$$\mathbf{S}_i = \sum_{\mathbf{x} \in C_i} (\mathbf{x} - \mathbf{m}_i)(\mathbf{x} - \mathbf{m}_i)^T, \quad (\text{C.2})$$

$$\mathbf{S}_W = \mathbf{S}_1 + \mathbf{S}_2 \quad (\text{C.3})$$

e

$$\mathbf{S}_B = (\mathbf{m}_1 - \mathbf{m}_2)(\mathbf{m}_1 - \mathbf{m}_2)^T, \quad (\text{C.4})$$

em que T significa transposto.

A matriz \mathbf{S}_W é conhecida por matriz *scatter* intra-classes e é proporcional à matriz de covariância dos dados. É também simétrica, semi-definida positiva e, usualmente, não-singular se $n > d$. A matriz \mathbf{S}_B é também simétrica e semi-definida positiva. É chamada de matriz *scatter* entre-classes.

Em termos de \mathbf{S}_W e \mathbf{S}_B , a função custo para o critério FDR como discriminante é escrita como

$$\mathbf{J}(\mathbf{w}) = \frac{\mathbf{w}^T \mathbf{S}_B \mathbf{w}}{\mathbf{w}^T \mathbf{S}_W \mathbf{w}}. \quad (\text{C.5})$$

O vetor \mathbf{w} que maximiza $\mathbf{J}(\cdot)$ será:

$$\mathbf{w} = \mathbf{S}_W^{-1}(\mathbf{m}_1 - \mathbf{m}_2). \quad (\text{C.6})$$

Assim, o vetor \mathbf{w} obtido representa a máxima razão entre a matriz *scatter* entre-classes e a intra-classes. Dessa forma, o processo de classificação é convertido de um espaço d -dimensional para um espaço uni-dimensional. Neste novo espaço, pode-se obter um limiar que fará a separação entre os dados projetados em \mathbf{w} das classes 1 e 2. A Figura C.1 ilustra este procedimento. Observe na Figura C.1 (a), a distribuição espacial das classes 1 e 2, e o vetor \mathbf{w} . Cada classe é composta por 100 eventos, em que cada evento é caracterizado pelo vetor de parâmetros $\mathbf{p} = [x \ y \ z]$. Na Figura C.1 (b) é mostrado os dados projetados no vetor \mathbf{w} . Dessa forma, neste novo espaço uni-dimensional, pode-se definir um limiar que separe a classe 1 da 2 linearmente.




Figura C.1: Exemplo da aplicação do FDR para classificação.

C.2 FDR Para Seleção de Parâmetros

Diferentemente do critério FDR para classificação, a função custo do critério FDR como ferramenta de seleção de parâmetros é:

$$\mathbf{J}_c = (\mathbf{m}_1 - \mathbf{m}_2)^2 \odot \frac{1}{\mathbf{D}_1^2 + \mathbf{D}_2^2} \quad (\text{C.7})$$

onde $\mathbf{J}_c = [J_1 \cdots J_{L_l}]^T$, L_l é o número total de parâmetros, \mathbf{m}_1 e \mathbf{m}_2 , e \mathbf{D}_1^2 e \mathbf{D}_2^2 são, respectivamente, os vetores de média e variância dos dados da classe 1 e da classe 2. O símbolo \odot refere-se ao produto de Hadamard $\mathbf{r} \odot \mathbf{s} = [r_0 s_0 \cdots r_{L_r-1} s_{L_r-1}]^T$.

Pode-se entender que os i -ésimos elementos do vetor de parâmetros, referentes aos maiores valores de \mathbf{J}_c , representam os parâmetros que apresentam melhor separabilidade entre classes. Esta técnica é bastante útil em processos de classificação mais complexos, uma vez que torna possível selecionar os melhores parâmetros (que mais discriminam as classes envolvidas) e, conseqüentemente, reduzir o número de parâmetros utilizado na classificação. Esta redução de parâmetros é atraente em sistemas que necessitam de menor complexidade computacional, tais como sistemas que operam em tempo real. Ademais, o uso de um número reduzido de parâmetros pode levar ao projeto de classificadores mais simples e com melhor desempenho, já que os parâmetros responsáveis pela interseção entre classes são, teoricamente, descartados.

Apêndice D

Classificador Bayesiano

Considere o problema de decisão entre duas hipóteses, uma hipótese \mathcal{H}_0 , referente à classe 0, e outra hipótese \mathcal{H}_1 , referente à classe 1. Diversas técnicas lineares e não-lineares podem ser aplicadas para determinar a superfície de separação entre as hipóteses \mathcal{H}_0 e \mathcal{H}_1 . O classificador de Bayes [15, 16] realiza a classificação através da seguinte inequação:

$$\frac{p(\mathbf{x}|\mathcal{H}_1)}{p(\mathbf{x}|\mathcal{H}_0)} \underset{>}{\leq} \frac{P(\mathcal{H}_0)}{P(\mathcal{H}_1)}, \quad (\text{D.1})$$

em que \mathbf{x} é um vetor constituído de elementos aleatórios, $P(\mathcal{H}_i)$ representa a probabilidade a *priori* e $p(\mathbf{x}|\mathcal{H}_i)$ representa a função densidade de probabilidade (pdf - *probability density function*) condicional de obter \mathbf{x} , dado que a classe é \mathcal{H}_i . Se a função densidade de probabilidade condicional for gaussiana, ela pode ser expressa como:

$$p(\mathbf{x}|\mathcal{H}_i) = \frac{1}{(2\pi)^{L/2} |\Sigma_i|^{1/2}} e^{-\frac{1}{2}(\mathbf{x}-\mu_i)^T \Sigma_i^{-1}(\mathbf{x}-\mu_i)}, \quad (\text{D.2})$$

onde $\mu_i = E\{\mathbf{x}\}$ é o vetor valor médio da classe \mathcal{H}_i , Σ_i é a matriz de covariância da mesma classe definida por

$$\Sigma_i = E\{(\mathbf{x} - \mu_i)(\mathbf{x} - \mu_i)^T\}, \quad (\text{D.3})$$

e $|\Sigma_i|$ denota o determinante de Σ_i .

Supondo as classes equiprováveis, onde $P(\mathcal{H}_0)=P(\mathcal{H}_1)=1/2$ e as pdf's dadas

por (D.2), o classificador dado por (D.1) assume a forma:

$$\frac{|\Sigma_0|^{-\frac{1}{2}} e^{-\frac{1}{2}(\mathbf{x}-\mu_b)^T \Sigma_1^{-1}(\mathbf{x}-\mu_1)}}{|\Sigma_1|^{-\frac{1}{2}} e^{-\frac{1}{2}(\mathbf{x}-\mu_a)^T \Sigma_0^{-1}(\mathbf{x}-\mu_0)}} \underset{<}{\overset{\geq}{}} 1 \quad (\text{D.4})$$

onde μ_0 e μ_1 são os vetores valor médio das classes \mathcal{H}_0 e \mathcal{H}_1 respectivamente, e Σ_0 e Σ_1 são as matrizes de covariância das respectivas classes.

Sendo assim, a expressão a esquerda de (D.4) é aplicada ao vetor de parâmetros extraído, e se o valor encontrado for maior ou igual a 1, o sinal é dado como pertencente à classe 0, caso contrário o mesmo é dado como pertencente à classe 1.

Apêndice E

Filtro de Fourier

O Filtro de Fourier é muito utilizado para extrair informações do componente fundamental dos sinais [121]. Os algoritmos clássicos de filtros de Fourier podem usar janela de dois ciclos, um ciclo ou meio ciclo. Para o sinal discreto $x(n)$ representado por:

$$x[n] = A \sin\left(\frac{2\pi}{N}n + \phi\right), \quad (\text{E.1})$$

têm-se os seguintes filtros de Fourier [122]:

Filtro de Fourier de dois ciclos:

$$X_c[n] = \frac{1}{N} \sum_{l=0}^{2N-1} v[k+l-2N+1] \cos\left(\frac{2\pi}{N}l\right) \quad (\text{E.2})$$

$$X_s[n] = \frac{1}{N} \sum_{l=0}^{2N-1} v[k+l-2N+1] \sin\left(\frac{2\pi}{N}l\right) \quad (\text{E.3})$$

$$|x[n]| = \sqrt{Y_c^2[n] + Y_s^2[n]} \quad (\text{E.4})$$

$$\phi_x[n] = -\arctan \frac{Y_s[n]}{Y_c[n]} \quad (\text{E.5})$$

Filtro de Fourier de um ciclo:

$$X_c[n] = \frac{2}{N} \sum_{l=0}^{N-1} v[k+l-N+1] \cos\left(\frac{2\pi}{N}l\right) \quad (\text{E.6})$$

$$X_s[n] = \frac{2}{N} \sum_{l=0}^{N-1} v[k+l-N+1] \sin\left(\frac{2\pi}{N}l\right) \quad (\text{E.7})$$

$$|x[n]| = \sqrt{Y_c^2[n] + Y_s^2[n]} \quad (\text{E.8})$$

$$\phi_x[n] = -\arctan \frac{Y_s[n]}{Y_c[n]} \quad (\text{E.9})$$

Filtro de Fourier de meio ciclo:

$$X_c[n] = \frac{4}{N} \sum_{l=0}^{\frac{N}{2}-1} v[k+l-\frac{N}{2}+1] \cos\left(\frac{2\pi}{N}l\right) \quad (\text{E.10})$$

$$X_s[n] = \frac{4}{N} \sum_{l=0}^{\frac{N}{2}-1} v[k+l-\frac{N}{2}+1] \sin\left(\frac{2\pi}{N}l\right) \quad (\text{E.11})$$

$$|x[n]| = \sqrt{Y_c^2[n] + Y_s^2[n]} \quad (\text{E.12})$$

$$\phi_x[n] = -\arctan \frac{Y_s[n]}{Y_c[n]} \quad (\text{E.13})$$

Conforme bem discutido em [122], o filtro de Fourier com janela retangular de um ciclo é o normalmente utilizado para o cálculo dos fasores, devido ao bom compromisso entre o atraso do processamento e o resultado do cálculo fasorial. O filtro de Fourier usando janela de dois (ou mais) ciclos melhora o resultado do cálculo fasorial. São utilizados em aplicações que toleram um processamento mais lento do que o proporcionado pelo filtro de Fourier com a janela de um ciclo. O filtro de Fourier de meio ciclo é bem útil quando é necessária uma resposta rápida, como em aplicações de proteção e controle. Vale ressaltar que, apesar de o filtro de Fourier de

meio ciclo ser usado em algumas aplicações para a determinação do fasor, ele é muito susceptível à variação de frequência e não consegue filtrar nem o segundo harmônico, nem o nível CC (corrente contínua) do sinal, sendo necessário um pré-processamento do sinal para minimizar esses efeitos.

Apêndice F

Análise de Componentes Independentes

O objetivo da técnica Análise de Componentes Independentes (ICA-*Independent Component Analysis*) [103] é a separação de fontes estatisticamente independentes a partir de um determinado modelo de mistura das fontes originais. O modelo de mistura consiste em N dados observáveis x_1, \dots, x_N que resultam de uma combinação linear de N variáveis aleatórias s_1, \dots, s_N estatisticamente independentes entre si:

$$x_i = a_{i1}s_1 + a_{i2}s_2 + \dots + a_{iN}s_N, \forall i = 1, \dots, N \quad (\text{F.1})$$

No modelo, apenas as variáveis aleatórias x_i são conhecidas, e a partir delas serão estimados os coeficientes da mistura a_{ij} e as componentes independentes s_j . Em notação matricial [103]:

$$\mathbf{x} = \mathbf{A} \cdot \mathbf{s} \quad (\text{F.2})$$

onde $\mathbf{x} = [x_1[n], x_2[n], \dots, x_N[n]]^T$, $\mathbf{s} = [s_1[n], s_2[n], \dots, s_N[n]]^T$ e \mathbf{A} é a matriz de mistura.

O objetivo da ICA é encontrar uma matriz de separação \mathbf{W} tal que:

$$\mathbf{y} = \mathbf{W} \cdot \mathbf{x} \quad (\text{F.3})$$

onde $\mathbf{y} = [y_1[n], y_2[n], \dots, y_N[n]]^T$ fornece uma estimativa dos sinais originais \mathbf{s} com

as ambigüidades de não ser possível determinar a ordem, a variância e a polaridade das componentes independentes. O que favorece o método é que estas limitações são insignificantes em boa parte das aplicações.

A ICA está intimamente relacionada com o método de separação cega de fontes (BSS - *Blind Source Separation*). O método é chamado de cego, pois muito pouco, ou mesmo nada, é conhecido sobre a matriz de mistura, e são feitas poucas considerações acerca das fontes a serem estimadas. A ICA é o método mais aplicado para separação cega de fontes.

Há várias aproximações para separar as fontes independentes a partir dos sinais de mistura, que utilizam certas propriedades estatísticas dos sinais das fontes, tais como não-gaussianidade, estrutura temporal, cumulantes cruzados e não-estacionariedade [103]. A partir destas propriedades, vários algoritmos foram propostos na literatura. A seguir serão detalhados o algoritmo FastICA e JADE, devido à sua popularidade.

Para assegurar que o modelo ICA dado possa ser estimado, temos que considerar certas hipóteses e restrições [103]: (i) as componentes independentes são estatisticamente independentes entre si. (ii) as componentes independentes devem apresentar distribuições não-gaussianas. Na verdade, no máximo, uma das componentes independentes pode apresentar distribuição gaussiana. (iii) a matriz de mistura é quadrada. Em outras palavras, o número de componentes independentes é igual ao número de misturas observadas.

F.1 Branqueamento

O branqueamento consiste é um pré-processamento da ICA, e é utilizado para remover a correlação entre os dados.

Um vetor \mathbf{z} de variáveis aleatórias de média nula é dito *branco* se suas componentes forem descorrelacionadas e possuírem variância unitária [103]. Isto implica que a matriz de covariância de \mathbf{z} é igual à matriz identidade. O processo de branqueamento também referido como esferização, e é uma operação ligeiramente mais forte do que a simples descorrelação.

A matriz de transformação \mathbf{V} que conduzirá ao branqueamento das variáveis

aleatórias de um vetor aleatório \mathbf{x} de média nula será dada por:

$$\mathbf{V} = \mathbf{\Lambda}^{-1/2} \mathbf{E}^T \quad (\text{F.4})$$

em que \mathbf{E} é a matriz onde cada coluna é um autovetor (com norma unitária) da matriz de covariância (\mathbf{C}_x) de \mathbf{x} , e $\mathbf{\Lambda}$ é a matriz diagonal com os autovalores de (\mathbf{C}_x).

Assim, o branqueamento dos dados do vetor \mathbf{x} pode ser dado pela transformação linear

$$\mathbf{z} = \mathbf{V}\mathbf{x}. \quad (\text{F.5})$$

F.2 Independência Estatística

Dois vetores \mathbf{v}_1 e \mathbf{v}_2 serão estatisticamente independentes se, e somente se

$$p_{\mathbf{v}_1\mathbf{v}_2}(\mathbf{v}_1, \mathbf{v}_2) = p_{\mathbf{v}_1}(\mathbf{v}_1)p_{\mathbf{v}_2}(\mathbf{v}_2), \quad (\text{F.6})$$

em que $p_{\mathbf{v}_1}(\mathbf{v}_1)$ e $p_{\mathbf{v}_2}(\mathbf{v}_2)$ são, respectivamente, as funções densidade de probabilidade (pdf) de \mathbf{v}_1 e \mathbf{v}_2 , e $p_{\mathbf{v}_1\mathbf{v}_2}(\mathbf{v}_1, \mathbf{v}_2)$ é a pdf conjunta [103].

Geralmente, nas aplicações de ICA dispõe-se de muito pouco conhecimento sobre a fonte dos sinais, e, conseqüentemente, a estimação da pdf dos mesmos não é uma tarefa trivial. Portanto, medidas alternativas de independência são comumente empregadas durante a busca pelos componentes independentes [103, 123].

F.2.1 Descorrelação Não-Linear

Duas variáveis aleatórias (y_1 e y_2) são consideradas linearmente decorrelacionadas se a correlação cruzada ($R_{y_1y_2}$) das mesmas for zero. Utilizando-se $E\{\cdot\}$ para representar o operador de média, tem-se

$$R_{y_1y_2} = E\{y_1y_2\}. \quad (\text{F.7})$$

De fato, independência estatística entre duas variáveis implica decorrelação, porém, decorrelação nem sempre implica independência. A correlação linear utiliza momentos de primeira e segunda ordem do processo, enquanto que a independência

utiliza, além destes, informações de ordem superior acessadas de forma direta ou indireta.

Estendendo o conceito de correlação, pode-se definir a correlação não-linear entre as variáveis y_1 e y_2 como $E\{f(y_1)g(y_2)\}$ [103], em que $f(y_1)$ e $g(y_2)$ são funções, tal que pelo menos uma delas é não-linear. Tipicamente, utilizam-se polinômios de grau superior a um, ou funções mais complexas como a tangente hiperbólica.

De acordo com [103], as variáveis y_1 e y_2 serão estatisticamente independentes se e somente se

$$E\{f(y_1)g(y_2)\} = E\{f(y_1)\}E\{g(y_2)\}. \quad (\text{F.8})$$

A medida de independência estatística fornecida pela Equação (F.8) é, frequentemente, chamada de *descorrelação não-linear* [124].

F.2.2 Informação Mútua

A definição básica da informação mútua utiliza a medida de entropia diferencial H [83]. Conceitualmente, a entropia diferencial de um vetor aleatório \mathbf{y} com densidade $p(\mathbf{y})$ é definida como:

$$H(\mathbf{y}) = - \int p(\mathbf{y}) \log p(\mathbf{y}) d\mathbf{y}. \quad (\text{F.9})$$

A versão normalizada da entropia é dada pela negentropia J , que é definida por

$$J(\mathbf{y}) = H(\mathbf{y}_{gauss}) - H(\mathbf{y}), \quad (\text{F.10})$$

em que \mathbf{y}_{gauss} é um vetor aleatório gaussiano com a mesma matriz de covariância (ou correlação) de \mathbf{y} . A Negentropia é sempre não negativa, e zero somente para vetores aleatórios gaussianos.

A informação mútua (IM) entre m variáveis aleatórias, y_i , $i = 1 \dots m$, é definida como:

$$IM(y_1, y_2, \dots, y_m) = \sum_{i=1}^m H(y_i) - H(\mathbf{y}). \quad (\text{F.11})$$

A informação mútua, conforme definida na Equação (F.11), é uma medida

natural de dependência entre variáveis aleatórias, uma vez que é sempre não negativa, e zero se e somente se as variáveis forem estatisticamente independentes.

F.3 Algoritmo FastICA

O algoritmo FastICA (*Fast Fixed Point Algorithm For Independent Component Analysis*) foi proposto em [125] e versões melhoradas do algoritmo foram apresentadas em [126] e [111]. Basicamente, o algoritmo estima o modelo ICA utilizando o algoritmo do ponto fixo. Dois passos de pré-processamento são aplicados: branqueamento e centralização dos dados. A centralização dos dados consiste na subtração da média dos dados.

O algoritmo do ponto fixo pode ser representado pela realização das Equações F.12 e F.13 em sequência.

$$\mathbf{w}^*(n) = \mathbf{C}^{-1} \mathbf{E} \mathbf{z} g(\mathbf{w}(n-1)^T \mathbf{z}) - \mathbf{E} g'(\mathbf{w}(n-1)^T \mathbf{z}) \mathbf{w}(n-1) \quad (\text{F.12})$$

$$\mathbf{w}(n) = \frac{\mathbf{w}^*(n)}{\sqrt{\mathbf{w}^*(n)^T \mathbf{C} \mathbf{w}^*(n)}} \quad (\text{F.13})$$

em que, g pode ser alguma função contraste não quadrática [103], com derivada g' , e \mathbf{C} é a matriz de covariância das misturas \mathbf{x} .

O esquema de obtenção da matriz de separação \mathbf{W} mostrado em F.13 é deflacionário, isto é, as componentes independentes são obtidas em sequência, uma a uma. Com o algoritmo FastICA é possível, também, obter as componentes independentes simultaneamente, pelo uso de uma decorrelação simétrica, que pode ser realizada por:

$$\mathbf{W} = \mathbf{W}(\mathbf{W}^H \mathbf{W})^{-1/2}, \quad (\text{F.14})$$

em que $\mathbf{W} = (\mathbf{w}_1 \ \cdots)$ é a matriz de vetores.

F.3.1 ICA por Método Tensorial

Suponha uma combinação linear qualquer de x_i dada por $y = \mathbf{b}^T \cdot \mathbf{x} = \sum_i b_i x_i$. Como $\mathbf{x} = \mathbf{A} \cdot \mathbf{s}$, pode-se escrever $y = \mathbf{b}^T \cdot \mathbf{x} = \mathbf{b}^T \cdot \mathbf{A} \cdot \mathbf{s}$. Se \mathbf{b}^T for uma linha da inversa da matriz \mathbf{A} , então $\mathbf{b}^T \cdot \mathbf{A}$ será um vetor linha com um dos elementos igual a 1 e os demais iguais a zero, e y será uma das fontes originais. Entretanto, apenas o vetor de mistura \mathbf{x} é conhecido e, portanto, o vetor \mathbf{b} não pode ser determinado exatamente. Precisa-se, então, encontrar um estimador que forneça uma boa aproximação de \mathbf{b} .

Existem, na literatura atual, alguns estimadores que são capazes de gerar bons resultados. Um apanhado geral sobre estes estimadores pode ser encontrado em [103].

O método tensorial consiste em utilizar o cumulante tensor. O algoritmo mais conhecido, que implementa este método é o JADE (*Joint Approximate Diagonalization of Eigenmatrices*) [103], que soluciona o problema de autovalores do tensor cumulante, realizando uma diagonalização do tensor através da decomposição dos autovalores. O tensor cumulante é um operador linear definido por cumulantes de quarta ordem. Os tensores podem ser considerados como uma generalização linear de matrizes [83]. Esta transformação linear gera a matriz

$$\mathbf{F}_{ij}(M) = \sum_{kl} m_{kl} \text{cum}(\mathbf{x}_i, \mathbf{x}_j, \mathbf{x}_k, \mathbf{x}_l), \quad (\text{F.15})$$

em que m_{ij} são os elementos da matriz \mathbf{M} que será transformada.

No algoritmo JADE, a decomposição do autovalor é considerado como uma etapa de pré-processamento. O cumulante de segunda ordem é usado para assegurar o branqueamento dos dados (descorrelação). Isto produz uma matriz de branqueamento \mathbf{W} que diagonaliza a matriz $\mathbf{F}(\mathbf{M}_i)$ que passa a ser

$$\mathbf{Q} = \mathbf{W}\mathbf{F}(\mathbf{M}_i)\mathbf{W}^T. \quad (\text{F.16})$$

Assim são criadas matrizes de dados branqueadas. A matriz de separação pode ser estimada a partir do produto $\mathbf{V} \cdot \mathbf{W}$, onde \mathbf{V} é uma matriz de rotação que faz as matrizes cumulantes tão diagonais quanto possível.

A minimização da soma dos quadrados dos elementos fora da diagonal da Equação F.16 é equivalente à maximização da soma dos quadrados dos elementos

da diagonal. Isto se deve ao fato da matriz \mathbf{W} ser uma matriz ortogonal o que não altera a soma total dos quadrados de uma matriz. A maximização do algoritmo JADE é um método que fornece uma diagonal conjunta aproximada de $\mathbf{F}(\mathbf{M}_i)$ pela formulação

$$\mathbf{J}_{JADE} = \sum_i \|\text{diag}(\mathbf{W}\mathbf{F}(\mathbf{M}_i)\mathbf{W}^2)\|, \quad (\text{F.17})$$

onde $\|\text{diag}(\bullet)\|$ realiza a soma dos quadrados da diagonal. A maximização da função contraste \mathbf{J}_{JADE} é uma maneira de realizar uma diagonalização conjunta aproximada da matriz $\mathbf{F}(\mathbf{M}_i)$. As matrizes \mathbf{M}_i são escolhidas das automatrizes dos tensores cumulantes. Este é o princípio básico do algoritmo JADE, de acordo com [103].

Apêndice G

Transformada Wavelet

A Transformada Wavelet (TW) constitui uma poderosa ferramenta de processamento de sinais, com uma variedade de aplicações: acústica, comunicações, análise de transitórios, medicina, etc. A principal razão para a grande popularidade da TW é a sua habilidade de decompor o sinal em componentes de frequência através de uma divisão não uniforme, em que componentes de alta frequência são capturados em curtos intervalos de tempo e componentes de baixa frequência em longos intervalos de tempo [98]. Esta resolução na frequência pode facilitar a análise de sinais e a detecção de parâmetros que podem ser úteis na caracterização de fontes de transitórios e/ou do estado do sistema após a ocorrência de um distúrbio, conforme apontado em [33].

G.1 Transformada Wavelet Contínua

Matematicamente, a Transformada Wavelet Contínua (TWC) de um dado sinal $x(t)$ é obtida em relação a uma função $g(t)$, conhecida por wavelet *mãe*, como:

$$TWC(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) g\left(\frac{t-b}{a}\right) dt, \quad (\text{G.1})$$

em que a é a dilatação ou fator de escala e b é o fator de translação da TW..

Pela Equação (G.1) fica claro que o sinal uni-dimensional no domínio do tempo $x(t)$ é mapeado para um novo espaço de duas dimensões. Pode-se inferir também que o conjunto dos coeficientes wavelet $TWC(a, b)$ associados com um dado sinal é a representação wavelet do mesmo com relação à função wavelet *mãe*

$g(t)$. Existem muitos tipos de wavelets *mãe* que podem ser empregados na prática. No entanto, não existe uma regra para se escolher a wavelet *mãe* mais adequada ao problema. Contudo, observa-se na literatura atual que a wavelet Daubechies de quarta ordem (dB4) [127] apresenta melhores resultados para análises de distúrbios de QEE [38].

G.2 Transformada Wavelet Discreta

A Transformada Wavelet Discreta (TWD) é definida como [98]:

$$TWD(m, k) = \frac{1}{\sqrt{a_0^m}} \sum_n x[n] g\left(\frac{k - nb_0 a_0^m}{a_0^m}\right), \quad (\text{G.2})$$

em que $g(\cdot)$ é a wavelet *mãe* e os parâmetros de escala e translação a e b são funções de um parâmetro inteiro m , tal que $a = a_0^m$ e $b = nb_0 a_0^m$. k é uma variável inteira que se refere às amostras no sinal de entrada..

Manipulando as variáveis n e k em (G.2), obtém-se:

$$TWD(m, k) = \frac{1}{\sqrt{a_0^m}} \sum_n x(n) g(a_0^m n - b_0 k), \quad (\text{G.3})$$

que representa, similarmente, a operação de convolução para um filtro FIR:

$$y[n] = \frac{1}{c} \sum x[k] h[n - k], \quad (\text{G.4})$$

em que $h[n - k]$ é a resposta ao impulso do filtro FIR, que em (G.3) é representada por $g(a_0^m n - b_0 k)$.

A análise Wavelet é realizada decompondo-se o sinal original em níveis, conforme ilustra a Figura G.1. Cada nível representa a ocorrência do sinal original em uma faixa específica de frequência e tempo. Os sinais decompostos, portanto, possuem uma poderosa propriedade de localização tempo frequência, que é um dos maiores benefícios que a TW oferece em processamento de sinais. A1, A2 e A3 representam o sinal original (S) em baixa resolução, e são chamadas de aproximações. D1, D2 e D3 representam a diferença entre duas aproximações sucessivas e são chamados de detalhes (ou coeficientes) da TW. Os detalhes e aproximações do sinal original S são obtidos por um banco de filtros, composto por filtros passa-baixas (L)

e passa-altas (H). O processo de decomposição pode ser definido como:

$$D_j(n) = \sum_k h(k)\Lambda_{j-l}(n - k) \quad (\text{G.5})$$

e

$$A_j(n) = \sum_k l(k)\Lambda_{j-l}(n - k), \quad (\text{G.6})$$

em que l e h são os coeficientes dos filtros passa-baixas e passa-altas, respectivamente. D_j e A_j são os detalhes e aproximações na resolução j , respectivamente. Λ_{j-l} é a aproximação do nível imediatamente abaixo do nível j . k refere-se aos coeficientes dos filtros.

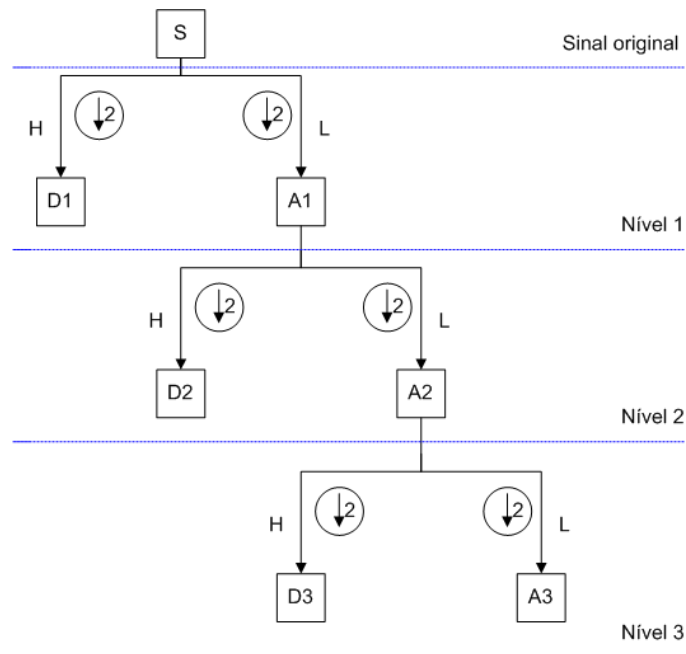


Figura G.1: Decomposição Wavelet. L = filtro passa-baixas e H = filtro passa-altas.

Apêndice H

Lista de Publicações

Nesta seção, os capítulos de livro, artigos e resumos relacionados ao desenvolvimento desta, publicados em congressos e periódicos nacionais e internacionais, são apresentados. Estes estão organizados em ordem cronológica e acompanham breve descrição.

H.1 Capítulo de Livro

1. FERREIRA, D. D., MARQUES, C. A. G., SEIXAS, J. M., CERQUEIRA, A. S., RIBEIRO, M. V., DUQUE, C. A., *Exploiting Higher-Order Statistics Information for Power Quality Monitoring*. Intech, 2010. (Aguardando Publicação)

Neste trabalho, as estatísticas de ordem superior, extraídas do componente fundamental do sinal de tensão e do sinal de tensão após filtragem do componente fundamental foram exploradas, do ponto de vista de detecção e classificação de distúrbios elétricos. O principal objetivo foi mostrar a capacidade dos cumulantes de ordem superior de representarem os distúrbios em reduzido espaço dimensional, com parâmetros relevantes à detecção e classificação de classes de múltiplos e isolados distúrbios, com alto desempenho e reduzida complexidade computacional.

H.2 Artigos Publicados em Periódicos

1. MARQUES, C. A. G., FERREIRA, D. D., FREITAS, L. R., DUQUE, C. A., RIBEIRO, M. V., “Improved Disturbance Detection Technique for Power Quality Analysis”, *IEEE Transactions on Power Delivery Letters*, 2010. (Aguardando Publicação)

Este trabalho apresenta uma técnica de detecção de distúrbios elétricos melhorada para aplicações em sistemas de potência. A principal vantagem da técnica é sua imunidade a variações de frequência da componente fundamental do sinal de tensão monitorado. Além disso, o método é capaz de detectar distúrbios em janelas de aquisição do sinal que correspondem a 1/64 amostras do componente fundamental. Resultados de simulação indicam que a técnica pode oferecer melhor desempenho em comparação com a técnica anterior, que motivou este trabalho.

2. FERREIRA, D. D., CERQUEIRA, A. S., DUQUE, C. A., SEIXAS, J. M., RIBEIRO, M. V., “Sistema Automático de Classificação de Distúrbios Elétricos Múltiplos e Isolados”. *Revista Controle & Automação - SBA*, 2010. (Aguardando Publicação)

Neste trabalho, um sistema de classificação de distúrbios elétricos múltiplos e isolados é proposto. A inovação deste sistema está na utilização de um conjunto de filtros no pré-processamento, o que possibilita a separação de algumas classes de distúrbios e, conseqüentemente, a classificação de distúrbios múltiplos a partir de classificadores mais simples. O sistema proposto foi projetado com dados simulados e testado tanto com dados simulados quanto com dados reais. Bons resultados foram alcançados, uma vez que um desempenho global superior a 99 % foi obtido, para o conjunto de dados considerado. Testes em dados experimentais foram também realizados mostrando a eficiência do método também em dados reais.

3. FERREIRA, D. D., CERQUEIRA, A. S., DUQUE, C. A., RIBEIRO, M. V., “HOS-based method for classification of power quality disturbances”, *Electronics Letters*, v. 45, n. 3, pp. 183-185, janeiro 2009.

Neste trabalho, um novo método para classificação de distúrbios elétricos foi proposto. A inovação do método está no uso de estatísticas de ordem superior (EOS) para extrair parâmetros relevantes à classificação. Além disso, o sistema final torna-se imune a ruído gaussiano, já que as EOS possuem esta característica. Os parâmetros extraídos levam a um espaço reduzido de parâmetros e a uma boa separabilidade entre as classes, resultando a uma razão de classificação de 100 % para o conjunto de dados de teste considerado.

4. FERREIRA, D. D., MARQUES, C. A. G, CERQUEIRA, A. S., DUQUE, C. A., RIBEIRO, M. V., “Sistema Automático de Detecção e Classificação de Distúrbios Elétricos em Qualidade da Energia Elétrica”, *Revista Controle & Automação - SBA*, v. 20, n. 1, pp. 53-62, janeiro, fevereiro, março 2009.

Este trabalho apresenta um sistema de detecção e classificação de distúrbios de qualidade da energia elétrica (QEE) que se baseia na decomposição do sinal de tensão em dois novos sinais, referentes à componente fundamental e ao sinal de erro e, em seguida, utiliza Estatísticas de Ordem Superior (EOS) para extrair parâmetros representativos de cada classe para simplificar o algoritmo de detecção e classificação. Como detector é utilizado um algoritmo baseado na teoria de Bayes e para implementar o algoritmo de classificação utilizou-se uma rede neural artificial. O sistema foi testado em simulações para seis classes de distúrbios, apresentando uma eficiência global próxima a 100 % para tais distúrbios. Os resultados aqui apresentados são comparados com os resultados de outros sistemas propostos na literatura.

H.3 Artigos Publicados em Anais de Congressos

1. CERQUEIRA, A. S., FERREIRA, D. D., PINTO, M. B. S., SALMENTO, M. L. G., SEIXAS, J. M., “Power Quality Disturbances Classification Using Specialized Neural Networks”, *14th International Conference on Harmonics and Quality of Power - ICHQP*, Bergamo, Itália, setembro 2010.

Este trabalho apresenta um sistema automático de classificação de distúrbios baseado em redes neurais especialistas. O sistema é capaz de classificar múltiplos distúrbios, o que é uma importante característica em sistemas de potência

com grande ocorrência de eventos simultâneos. O sistema foi projetado utilizando sinais simulados e foi testado com sinais experimentais e simulados. Uma eficiência global de 98,9 % foi alcançada.

2. MARQUES, C. A. G., FREITAS, L. R., FERREIRA, D. D., DUQUE, C. A., RIBEIRO, M. V., “Improved Disturbance Detection Technique for Power Quality Monitoring”, *XVIII Congresso Brasileiro de Automática - CBA*, pp. 1209-1214, Bonito, setembro 2010.

Este trabalho propõe uma técnica de detecção de distúrbios elétricos para aplicações em sistemas de potência. A principal vantagem da técnica é sua imunidade a variações de frequência da componente fundamental do sinal de tensão monitorado. Além disso, o método é capaz de detectar distúrbios utilizando um reduzido número de amostras com boa eficiência. Basicamente, o método proposto decompõe o sinal de entrada em duas componentes (fundamental e erro) e alguns parâmetros selecionados são apresentados ao detector de Bayes.

3. CERQUEIRA, A. S., SOUZA, J. V., FERREIRA, D. D., SEIXAS, J. M., “Classificação Automática de Distúrbios de Qualidade de Energia Baseado em Redes Neurais Especialistas”, *XVIII Congresso Brasileiro de Automática - CBA*, pp. 4846-4850, Bonito, setembro 2010.

Neste trabalho, foi proposto um sistema de classificação automática para distúrbios de qualidade de energia elétrica baseado em redes neurais especialistas. O sistema proposto foi capaz de classificar distúrbios simultâneos presentes no sinal, o que é fundamental em alguns cenários do sistema de potência. O sistema foi projetado e testado utilizando um banco de eventos gerado sinteticamente segundo as normas, apresentando um desempenho global de 98,9 %.

4. FERREIRA, D. D., SEIXAS, J. M., CERQUEIRA, A. S., ABREU, A. J. C., “Sistema de Detecção de Distúrbios Elétricos Baseado em Curvas Principais e Redes Neurais”, *III Simpósio Brasileiro de Sistemas Elétricos - SBSE*, Belém, 2010.

Este trabalho apresentou uma nova metodologia baseada em Curvas Principais e Redes Neurais Artificiais para a detecção de distúrbios elétricos em sistemas de potência. O sistema foi projetado utilizando dados simulados e testados em ambos os dados simulados e reais. Três diferentes métodos foram utilizados para comparação dos resultados de eficiência. Os resultados mostraram que o sistema proposto é bastante atrativo para aplicações *on-line* em sistemas de potência.

5. FERREIRA, D. D., SEIXAS, J. M., NAZARÉ, F. V. B., CERQUEIRA, A. S., CALÔBA, L. P., MARQUES, C. A. G., “Sistema de Detecção de Distúrbios Elétricos Baseado em Redes Neurais”, *IX Congresso Brasileiro de Redes Neurais / Inteligência Computacional - CBRN*, Ouro Preto, outubro 2009.

Este trabalho propõe um sistema para a detecção de distúrbios elétricos em sistemas de potência baseado em redes neurais artificiais. O sistema é aplicado em ambos dados reais e simulados e comparado com dois outros sistemas referidos na literatura especializada. É observado que o sistema apresenta alto desempenho e reduzido custo computacional na fase de operação e, portanto, pode ser bastante útil em sistemas online de monitoramento da qualidade de energia elétrica.

6. FERREIRA, D. D., SEIXAS, J. M., CERQUEIRA, A. S., “ICA-based Method for Power Quality Disturbance Analysis”, *The 15th International Conference on Intelligent System Applications to Power Systems - ISAP*, Curitiba, setembro 2009.

Este trabalho apresenta uma nova metodologia baseada em Análise de Componentes Independentes (ICA) para a análise de distúrbios de Qualidade de Energia Elétrica. As misturas apresentadas à técnica de ICA são as janelas do sinal contendo o distúrbio deslocadas de uma amostra. A metodologia proposta analisa os distúrbios que aparecem como misturas (múltiplos distúrbios) no sinal de tensão em um sistema de potência. Os resultados são obtidos para ambos os dados simulados e experimentais, em que uma razão de classificação superior a 97 % foi alcançada.

7. VIANELLO, R., FERREIRA, D. D., DUQUE, C. A., CERQUEIRA, A. S.,

RIBEIRO, M. V., “Classificação de Múltiplos Distúrbios de Qualidade de Energia Baseado em Transformada Wavelet, EOS e Redes Neurais”, *XVIII Congresso Brasileiro de Qualidade de Energia Elétrica - CBQEE*, 2009.

Este trabalho propôs uma metodologia de classificação de múltiplos distúrbios integrando transformada Wavelet, estatísticas de ordem superior e redes neurais. O sistema de classificação resultante foi testado utilizando eventos de qualidade de energia agrupados em três classes: isolados, duplos e múltiplos. Um desempenho superior a 93 % foi alcançado.

8. LIMA, M. A., FERREIRA, D. D., CERQUEIRA, A. S., DUQUE, C. A., RIBEIRO, M. V., “Separation and Recognition of Multiple PQ Disturbances Using Independent Component Analysis and Neural Networks”, *13th IEEE International Conference on Harmonics and Quality of Power - ICHQP*, p. 1-6, 2008.

Este trabalho apresenta o desenvolvimento de um sistema para a análise de múltiplos distúrbios em qualidade de energia elétrica utilizando uma recente técnica não-supervisionada chamada análise de componentes independentes. A técnica utiliza como pré-processamento um banco de filtros. Uma aplicação da técnica para classificação de múltiplos distúrbios baseado em cumulantes de ordem superior e redes neurais artificiais foi também apresentada. Resultados promissores com dados simulados são apresentados.

9. FERREIRA, D. D., SEIXAS, J. M., CERQUEIRA, A. S., “Curvas Principais Aplicadas à Classificação de Distúrbios Elétricos em Sistemas de Potência”, *Congresso Brasileiro de Automática - CBA*, 2008.

Este trabalho apresenta um estudo sobre a utilização de curvas principais na classificação de distúrbios elétricos em sistemas de potência. Os resultados mostram que as curvas principais são capazes de extrair modelos de curvas compactas para cada uma das seis classes de distúrbios consideradas, resultando em um classificador simples. Uma eficiência global de 99,8 % foi alcançada. O método proposto foi comparado com outros métodos da literatura

10. LIMA, M. A., CERQUEIRA, A. S., FERREIRA, D. D., DUQUE, C. A., RIBEIRO, M. V., SEIXAS, J. M., “Separação de Múltiplos Distúrbios de

Qualidade de Energia Utilizando Análise de Componentes Independentes”, *Congresso Brasileiro de Automática - CBA*, 2008.

Este trabalho apresenta o desenvolvimento de um sistema para separação de múltiplos distúrbios de qualidade de energia utilizando uma recente técnica não-supervisionada chamada análise de componentes independentes. A estrutura apresentada possui uma etapa de filtragem como pré-processamento que possibilita a aplicação de análise de componentes independentes dado apenas um sinal de monitoramento. Resultados promissores com dados simulados são apresentados.

11. FERREIRA, D. D., SEIXAS, J. M., CERQUEIRA, A. S., “A Three-phase Electric Disturbance Classification System Using Principal Curves”, *VIII Conferência Internacional de Aplicações Industriais - INDUSCON*, Poços de Caldas, 2008.

Este trabalho apresenta um sistema trifásico para classificação de distúrbios elétricos baseado em curvas principais. É mostrado que a técnica de curvas principais extrai modelos compactos das classes de distúrbios, levando ao projeto de um classificador simples. Utilizando dados de simulação, o sistema proposto alcança uma eficiência global de 98,3% para distúrbios monofásicos e de 100% para distúrbios trifásicos (desbalanceamentos). Os resultados de desempenho foram comparados com o de outros métodos propostos na literatura.

H.4 Resumos Publicados em Anais de Congressos

1. RAMOS, L. S., ABREU, A. J. C., FERREIRA, D. D., MARQUES, C. A. G., “Desenvolvimento de Técnicas para a Detecção Automática de Distúrbios Elétricos em Sistemas de Potência”, *Reunião Regional da SBPC*, Lavras, Minas Gerais, 2010.

Este trabalho teve como objetivo o desenvolvimento de ferramentas de detecção de distúrbios em QEE com reduzida complexidade computacional. Neste contexto, duas técnicas para a detecção automática de distúrbios elétri-

cos foram desenvolvidas e testadas: o detector de pico e o detector de energia. Em ambos os casos, a escolha de um patamar (limiar), foi baseada na análise da curva ROC considerando-se a probabilidade de falso alarme nula. As técnicas foram desenvolvidas utilizando-se dados sintéticos e testadas em ambos dados sintéticos e reais. Bons resultados foram alcançados para o detector de energia, principalmente quando janelas de aquisição com 256 amostras foram consideradas. O detector de pico torna-se inviável para tal aplicação, pois apresenta índices bastante reduzidos de detecção. Do ponto de vista de implementação em tempo real, o detector de pico possui uma reduzida complexidade computacional, já que demanda de $(N-1)$ somas e N multiplicações.