

UNIVERSIDADE FEDERAL DE JUIZ DE FORA  
FACULDADE DE ENGENHARIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**ANÁLISE DE COMPONENTES  
INDEPENDENTES APLICADA EM  
DISTÚRBIOS DE QUALIDADE DE ENERGIA**

**Autor**

Marcelo Antônio Alves Lima

**Orientador**

Prof. Dr. Augusto Santiago Cerqueira

Banca Examinadora:

Prof. Dr. Augusto Santiago Cerqueira (Faculdade de Engenharia/UFJF)

Prof. Dr. Carlos Augusto Duque (Faculdade de Engenharia/UFJF)

Prof. Dr. Denis Vinicius Coury (EESC/USP)

Dissertação apresentada à Faculdade de Engenharia da Universidade Federal de Juiz de Fora como parte dos requisitos para obtenção do título de mestre em Engenharia Elétrica.

Juiz de Fora, Fevereiro de 2009

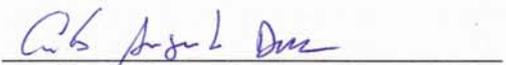
ANÁLISE DE COMPONENTES INDEPENDENTES APLICADA EM DISTÚRBIOS  
DE QUALIDADE DE ENERGIA

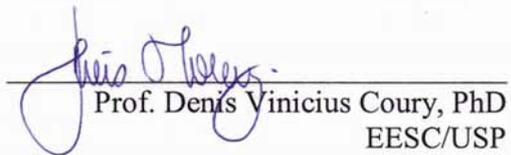
MARCELO ANTÔNIO ALVES LIMA

DISSERTAÇÃO DE MESTRADO SUBMETIDA AO CORPO DOCENTE DO  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA DA  
FACULDADE DE ENGENHARIA DA UNIVERSIDADE FEDERAL DE JUIZ DE  
FORA COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO  
DO GRAU DE MESTRE EM ENGENHARIA ELÉTRICA.

Aprovada por:

  
Prof. Augusto Santiago Cerqueira, D.Sc.  
(Orientador)  
Faculdade de Engenharia/UFJF

  
Prof. Carlos Augusto Duque, D.Sc.  
Faculdade de Engenharia/UFJF

  
Prof. Denis Vinicius Coury, PhD  
EESC/USP

Juiz de Fora, MG – Brasil  
Fevereiro de 2009

# Resumo

Esta dissertação apresenta o desenvolvimento de uma técnica para análise de qualidade de energia, considerando o caso pouco explorado de ocorrência de múltiplos distúrbios. O propósito é separar os distúrbios que estejam ocorrendo em sequência ou ao mesmo tempo em sinais de tensão presentes em sistemas elétricos de potência. Para isto, é utilizada a filosofia de separação cega de fontes, que parte do pressuposto de que não são conhecidas a priori as fontes (os distúrbios) que compõem os dados disponíveis e nem como elas foram misturadas. É utilizada para tal fim a recente técnica não-supervisionada denominada análise de componentes independentes, visando o desacoplamento entre os diferentes distúrbios independentes que estejam ocorrendo durante o mesmo intervalo de tempo, a partir de um determinado modelo de misturas dos distúrbios originais. Esta separação dos distúrbios é fundamental como etapa de pré-processamento, já que as técnicas existentes de localização no tempo e classificação apresentam desempenho reduzido quando ocorre tal situação. São apresentadas duas estruturas para separar múltiplos distúrbios, no que diz respeito ao número de misturas (sinais medidos) disponíveis: a primeira é aplicada quando são disponíveis mais de um dispositivo de monitoramento alocados em pontos distintos do sistema elétrico e sincronizados, e a segunda é aplicada quando se tem disponível um único monitor de qualidade de energia. No segundo caso, é proposta a utilização de um banco de filtros para gerar um número suficiente de misturas que são necessárias para se utilizar a análise de componentes independentes na estimação dos distúrbios envolvidos em um único sinal medido. O desempenho da técnica proposta foi analisado com dados sintéticos.

# Abstract

This dissertation presents the development of a technique for power quality analysis, considering the case of multiple disturbances. The purpose is to separate the disturbances that are occurring in sequence or at the same time, in voltage signals of the electric power systems. For this, is used the philosophy of blind source separation, with the assumption that the sources (the disturbances) that compose the data available are not known a priori, nor how they were mixed. It is used for this purpose the recent non-supervised technique called Independent Component Analysis for the decoupling between the different disturbances that are independent and occurring during the same interval, from a mixture model of the original disturbances. This separation of disturbances is crucial as a pre-processing step, since the existing techniques of location in time and classification have reduced performance when multiple disturbances occur. Two structures are presented to separate multiple disturbances, with regard to the number of mixtures (measured signals) available: the first is applied when are available more then one synchronized monitoring device placed in different points of the electric system, and the second is applied when there is only one available monitor. In the second case, it is proposed to use a filter bank to generate a sufficient number of mixtures required to the use of independent component analysis in the estimation of the disturbances involved in a single measured signal. The performance of the proposed technique was derived with synthetic data.

*Dedico este trabalho aos meus pais Márcio e Eva, e  
à minha noiva Tatiana*

*“Nem tudo que se enfrenta pode ser modificado, mas nada pode ser modificado até que seja enfrentado. (Albert Einstein)”*

# Agradecimentos

A Deus, por ter me proporcionado força de vontade e dedicação para concluir este trabalho.

Aos meus pais Márcio e Eva, por terem me oferecido toda a educação necessária para que eu pudesse chegar a este momento.

À minha irmã Marina, por sempre ter acreditado no meu potencial.

À minha querida noiva Tatiana, pelo carinho, por participar da minha vida, e ter me apoiado sempre nos meus estudos.

A todos os meus verdadeiros amigos, pelos momentos de alegria dados por suas presenças em minha vida, e pelos ensinamentos e conselhos.

Aos professores Augusto Santiago Cerqueira e Carlos Augusto Duque, pelas discussões e idéias, fundamentais para a concepção deste trabalho. Em especial ao professor Augusto Santiago Cerqueira, pela orientação e confiança depositada em meu trabalho.

À UFJF e ao CNPq, pelo apoio financeiro dado a este trabalho.

# Sumário

<b>Resumo</b>	<b>iii</b>
<b>Abstract</b>	<b>iv</b>
<b>Dedicatória</b>	<b>v</b>
<b>Agradecimentos</b>	<b>vii</b>
<b>Lista de Figuras</b>	<b>xii</b>
<b>Lista de Tabelas</b>	<b>xv</b>
<b>Abreviaturas</b>	<b>xvi</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Estrutura da Dissertação . . . . .	6
<b>2 Distúrbios de Qualidade de Energia</b>	<b>7</b>
2.1 Transitórios . . . . .	8
2.1.1 Transitório impulsivo . . . . .	8
2.1.2 Transitórios oscilatórios . . . . .	10
2.2 Variações de curta duração . . . . .	12
2.2.1 Afundamento ( <i>Sag</i> ) . . . . .	12
2.2.2 Elevação ( <i>Swell</i> ) . . . . .	12
2.2.3 Interrupção . . . . .	13

2.3	Variações de longa duração . . . . .	14
2.3.1	Sobretensão . . . . .	15
2.3.2	Subtensão . . . . .	15
2.3.3	Interrupção sustentada . . . . .	16
2.4	Distorções de forma de onda . . . . .	16
2.4.1	Nível CC . . . . .	17
2.4.2	Harmônicos . . . . .	17
2.4.3	Interharmônicos . . . . .	18
2.4.4	<i>Notches</i> . . . . .	19
2.4.5	Ruídos . . . . .	20
2.5	Desequilíbrios de tensão . . . . .	20
2.6	Flutuações de tensão . . . . .	21
2.7	Variações na frequência do sistema . . . . .	22
2.8	Sumário . . . . .	23
<b>3</b>	<b>Revisão Sobre Técnicas de Análise de Distúrbios de QEE</b>	<b>24</b>
3.1	Problema de análise de distúrbios de QEE . . . . .	25
3.2	Revisão Bibliográfica . . . . .	27
3.3	Sumário . . . . .	31
<b>4</b>	<b>Separação Cega de Fontes</b>	<b>32</b>
4.1	Descrição do problema . . . . .	32
4.2	Aplicações . . . . .	36
4.3	Análise de Componentes Independentes . . . . .	38
4.3.1	Definição . . . . .	38
4.3.2	Aplicação da ICA ao problema de BSS . . . . .	38
4.3.3	Restrições da ICA . . . . .	39
4.3.4	Indeterminações da estimação pela ICA . . . . .	40
4.3.4.1	Indeterminação dos ganhos de escala das fontes . . . . .	40
4.3.4.2	Indeterminação da ordem das fontes . . . . .	41
4.3.5	Aplicações de técnicas baseadas em estatísticas de segunda ordem à ICA . . . . .	41

4.3.5.1	Análise de Componentes Principais . . . . .	41
4.3.5.2	Branqueamento . . . . .	44
4.3.6	Um simples exemplo de ilustração da ICA . . . . .	45
4.3.6.1	Por que variáveis gaussianas são proibidas? . . . . .	50
4.3.7	Funções objetivo utilizadas como medida de independência estatística . . . . .	52
4.3.7.1	Informação mútua . . . . .	53
4.3.7.2	Princípio Infomax e a abordagem de Máxima Verossimilhança . . . . .	54
4.3.7.3	Maximização da não-gaussianidade . . . . .	56
4.3.8	Algoritmos para resolução da ICA . . . . .	59
4.3.8.1	Algoritmo Infomax e Infomax estendido . . . . .	60
4.3.8.2	Algoritmo FastICA . . . . .	61
4.3.9	Aplicações da ICA . . . . .	63
4.4	Sumário . . . . .	64
<b>5</b>	<b>Separação de Múltiplos Distúrbios de QEE Utilizando a ICA</b>	<b>65</b>
5.1	O sistema proposto . . . . .	66
5.1.1	Caso 1: $M$ monitores . . . . .	69
5.1.1.1	Filtros <i>notch</i> adaptativos . . . . .	69
5.1.1.2	ICA . . . . .	72
5.1.2	Caso 2: Um monitor . . . . .	73
5.1.2.1	Filtro <i>notch</i> adaptativo . . . . .	74
5.1.2.2	Banco de filtros . . . . .	74
5.1.2.3	ICA . . . . .	75
5.2	Resultados e Discussões . . . . .	75
5.3	Sumário . . . . .	92
<b>6</b>	<b>Conclusões</b>	<b>93</b>
	<b>Referências Bibliográficas</b>	<b>97</b>
	Referências . . . . .	97

<b>A Produção Científica</b>	<b>104</b>
A.1 Artigos em Congressos . . . . .	104

## Lista de Figuras

2.1	Exemplo de transitório oscilatório, proveniente do chaveamento de um banco de capacitores. . . . .	11
2.2	Exemplo de afundamento de tensão. . . . .	13
2.3	Exemplo de elevação de tensão. . . . .	14
2.4	Exemplo de harmônicos de tensão. . . . .	18
2.5	Exemplo de <i>notches</i> . . . . .	19
2.6	Exemplo de flutuação de tensão. . . . .	22
3.1	Sinal de tensão contendo dois distúrbios: <i>notch</i> e harmônicos. . . . .	27
3.2	Sinal de tensão contendo dois distúrbios: transitório de chaveamento capacitivo e elevação. . . . .	28
4.1	Sinais observados, que são assumidos como misturas de fontes desconhecidas. . . . .	34
4.2	Estimações das fontes desconhecidas, utilizando apenas os sinais observados da Figura 4.1. . . . .	35
4.3	Histogramas das fontes. . . . .	46
4.4	Distribuição de probabilidade conjunta de $\mathbf{s}$ . . . . .	47
4.5	Histogramas das misturas. . . . .	47
4.6	Distribuição de probabilidade conjunta de $\mathbf{x}$ . . . . .	48
4.7	Distribuição de probabilidade conjunta de $\mathbf{z}$ . . . . .	49

4.8	Distribuição de probabilidade conjunta de duas fontes gaussianas independentes. . . . .	50
4.9	Processo de mistura e separação da ICA. . . . .	52
4.10	Estrutura de uma rede neural artificial. . . . .	54
5.1	Distúrbios originais. . . . .	66
5.2	Misturas instantâneas dos distúrbios originais. . . . .	67
5.3	Estimações dos distúrbios originais. . . . .	68
5.4	Diagrama de blocos da estrutura de separação para $M$ pontos de medição. . . . .	69
5.5	Diagrama de blocos de um sistema EPLL. . . . .	70
5.6	Aplicação do EPLL a um sinal de tensão contendo harmônicos. . . . .	72
5.7	Diagrama de blocos da estrutura de separação para um único ponto de medição. . . . .	73
5.8	Sinais medidos contendo <i>notches</i> e transitório de chaveamento capacitivo. . . . .	76
5.9	Misturas obtidas pelos EPLLs. . . . .	77
5.10	Amplitudes do componente fundamental rastreadas pelos EPLLs. . . . .	78
5.11	Estimações dos distúrbios contidos nos sinais da Figura 5.8. . . . .	78
5.12	Sinal medido contendo dois distúrbios ( <i>notch</i> e harmônicos). . . . .	79
5.13	Módulos das DFTs dos distúrbios e do sinal de erro ( <i>notch</i> e harmônicos). . . . .	80
5.14	Misturas provenientes do banco de filtros ( <i>notch</i> e harmônicos). . . . .	80
5.15	Estimações normalizadas dos distúrbios fornecidas pela ICA, comparadas aos distúrbios originais ( <i>notch</i> e harmônicos). . . . .	81
5.16	Sinal medido contendo dois distúrbios (transitório de chaveamento capacitivo e harmônicos). . . . .	82
5.17	Módulos das DFTs dos distúrbios e do sinal de erro (transitório de chaveamento capacitivo e harmônicos). . . . .	83
5.18	Misturas provenientes do banco de filtros (transitório de chaveamento capacitivo e harmônicos). . . . .	83

5.19	Estimações normalizadas dos distúrbios fornecidas pela ICA, comparadas aos distúrbios originais (transitório de chaveamento capacitivo e harmônicos).	84
5.20	Coefficientes de correlação entre os distúrbios originais e suas estimações: <i>notch</i> e harmônicos.	85
5.21	Coefficientes de correlação entre os distúrbios originais e suas estimações: transitório de chaveamento capacitivo e harmônicos.	86
5.22	Sinal medido contendo dois distúrbios ( <i>spike</i> e harmônicos).	87
5.23	Módulos das DFTs dos distúrbios e do sinal de erro ( <i>spike</i> e harmônicos).	87
5.24	Misturas provenientes do banco de filtros ( <i>spike</i> e harmônicos).	88
5.25	Estimações normalizadas dos distúrbios fornecidas pela ICA, comparadas aos distúrbios originais ( <i>spike</i> e harmônicos).	88
5.26	Coefficientes de correlação entre os distúrbios originais e suas estimações: <i>spike</i> e harmônicos.	89
5.27	Sinal medido contendo dois distúrbios (transitório de chaveamento capacitivo e <i>notches</i> ).	90
5.28	Módulos das DFTs dos distúrbios e do sinal de erro (transitório de chaveamento capacitivo e <i>notches</i> ).	90
5.29	Misturas provenientes do banco de filtros (transitório de chaveamento capacitivo e <i>notches</i> ).	91
5.30	Estimações dos distúrbios fornecidas pela ICA (transitório de chaveamento capacitivo e <i>notches</i> ).	91
5.31	Coefficientes de correlação entre os distúrbios originais e suas estimações: transitório de chaveamento capacitivo e <i>notches</i> .	92

# Lista de Tabelas

2.1	Características de alguns distúrbios de qualidade de energia. . . . .	9
-----	---	---

# Abreviaturas

AM:	<i>Amplitude Modulation</i> - Modulação de Amplitude
AMR:	<i>Análise Multiresolução</i>
ANN:	<i>Artificial Neural Network</i> - Rede Neural Artificial
BSS:	<i>Blind Source Separation</i> - Separação Cega de Fontes
CA:	<i>Corrente Alternada</i>
CC:	<i>Corrente Contínua</i>
DFT:	<i>Discrete Fourier Transform</i> - Transformada Discreta de Fourier
DSP:	<i>Digital Signal Processor</i> - Processador Digital de Sinal
DWT:	<i>Discrete Wavelet Transform</i> - Transformada Wavelet Discreta
ECG:	<i>Eletrocardiograma</i>
EEG:	<i>Eletroencefalograma</i>
EPLL:	<i>Enhanced Phase-locked Loop</i> - Malha de Captura de Fase Melhorada
FDP:	<i>Função Densidade de Probabilidade</i>
FIR:	<i>Finite Impulse Response</i> - Resposta ao Impulso de Comprimento Finito
fMRI:	<i>Functional Magnetic Resonance Imaging</i> - Imagens de Ressonância Magnética Funcional
FPGA:	<i>Flexible Programmable Gate Array</i> - Arranjo de Portas Programável em Campo
HOS:	<i>Higher Order Statistics</i> - Estatísticas de Ordem Superior
ICA:	<i>Independent Component Analysis</i> - Análise de Componentes Independentes

PCA:	<i>Principal Component Analysis</i> - Análise de Componentes Principais
QEE:	<i>Qualidade de Energia Elétrica</i>
RMS:	<i>Root Mean Square</i> - Valor Quadrático Médio
SEP:	<i>Sistema Elétrico de Potência</i>
SOLAR:	<i>Self Organizing Learning Array</i>
STFT:	<i>Short Time Fourier Transform</i> - Transformada de Fourier de Tempo Curto
SVM:	<i>Support Vector Machines</i> - Máquinas de Vetor de Suporte
TC:	<i>Transformador de Corrente</i>
TP:	<i>Transformador de Potencial</i>

# 1

## Introdução

O crescente aumento de problemas relacionados à qualidade da energia elétrica (QEE) em sistemas elétricos de potência (SEP), tem levado ao longo dos últimos anos ao desenvolvimento de diversas técnicas de processamento de sinais para o monitoramento e análise de tais problemas. Dentre as áreas onde estas técnicas vêm sendo utilizadas, pode-se citar: *i*) detecção de distúrbios, *ii*) classificação de distúrbios, *iii*) identificação de fontes geradoras de distúrbios, *iv*) localização de fontes geradoras de distúrbios, *v*) análise de transitórios de distúrbios, *vi*) estimação de parâmetros de distúrbios, *vii*) compressão de distúrbios, etc.

O termo qualidade da energia elétrica refere-se a uma ampla variedade de fenômenos eletromagnéticos que caracterizam a tensão e/ou corrente em um determinado instante e em uma determinada localização em um sistema elétrico de potência (Power Quality, 1995). Este tema tem se tornado um assunto de extrema importância no mercado atual de energia elétrica, constituindo um fator crucial para

a competitividade de praticamente todos os setores industriais e de serviços, já que uma deficiente QEE resulta em mau-funcionamento, instabilidade e diminuição da vida útil de equipamentos elétricos. Dentre as principais razões para o seu crescente interesse, estão (Dugan, McGranaghan, Santoso, & Beaty, 2004):

1. O crescente uso de equipamentos e sistemas de controle microprocessados, que são mais sensíveis a variações da qualidade de energia.
2. O crescente avanço da eletrônica de potência, aumentando o número de cargas de natureza não-linear (sistemas microprocessados, inversores de frequência, fontes chaveadas, etc) em instalações residenciais, comerciais e industriais, o que provoca um aumento significativo na ocorrência de distúrbios em sistemas de potência assim como no número de falhas, o que, conseqüentemente, provoca a diminuição da vida útil dos equipamentos conectados às redes elétricas.
3. A crescente ênfase em eficiência de sistemas elétricos, resultando na aplicação de dispositivos de alta eficiência energética, em acionadores de motores com velocidade controlável e bancos de capacitores para correção de fator de potência para reduzir perdas. Isto é resultante do crescimento de níveis harmônicos em sistemas elétricos e a conseqüente preocupação a respeito de seus impactos.
4. Aumento de informação por parte de consumidores finais (principalmente os consumidores industriais) a respeito de qualidade de energia. Sendo assim, fornecedores são obrigados a melhorar a qualidade da energia fornecida.
5. A crescente interligação entre processos produtivos industriais na rede elétrica. Isto significa que a falha em qualquer componente tem conseqüências muito mais importantes.

Estes aspectos, levantados como motivadores das discussões sobre QEE, tornam a preocupação com a confiabilidade e o bom funcionamento do sistema elétrico um compromisso não apenas das concessionárias, mas também dos consumidores.

Segundo (Dugan et al., 2004), um problema de QEE é definido como “*qualquer desvio manifestado na tensão, corrente ou frequência que resulte em falha ou operação incorreta do equipamento consumidor*”. Entretanto, o principal foco das análises de QEE é a forma de onda da tensão, pois o sistema de fornecimento de energia não tem controle sobre a forma de onda das correntes que as diferentes cargas solicitam.

Sistemas elétricos de corrente alternada (CA) são projetados para operarem com tensão senoidal de frequência (tipicamente 50 ou 60 *Hz*) e amplitude determinadas. Qualquer desvio significativo na frequência, amplitude, forma de onda ou simetria de fases pode ser encarado como um problema de QEE.

Há sempre uma relação próxima entre tensão e corrente em qualquer sistema elétrico. Embora os geradores possam fornecer uma tensão senoidal, a corrente que circula através da impedância do sistema pode causar uma variedade de distúrbios à tensão, como por exemplo (Dugan et al., 2004):

1. A corrente resultante de um curto-circuito provoca um afundamento ou desaparecimento por completo da tensão.
2. A corrente proveniente de relâmpagos, circulando através do sistema elétrico pode provocar impulsos na forma de onda da tensão, além de causar o rompimento do isolamento elétrico entre os condutores e provocar curto-circuitos.
3. Correntes distorcidas por cargas que produzem harmônicos também distorcem as tensões. Como as correntes circulam pelas impedâncias do sistema elétrico, tensões distorcidas são também fornecidas a outras cargas.

Neste trabalho, serão analisados distúrbios refletidos na forma de onda da tensão, uma vez que os distúrbios na forma de onda da corrente estão relacionados, em sua maioria, ao tipo de carga inserida no sistema de potência, o que não é o foco deste trabalho. Também, a tensão tem seus parâmetros bem definidos em estado permanente e para condições normais. De fato, como definido nas normas de QEE, os principais problemas e definições da QEE estão relacionados com a tensão.

Considerando a forma de onda da tensão, podem ser encontrados vários tipos de distúrbios, tais como *notches*, presença de harmônicos, faltas, elevações (*swell*), afundamentos (*sag*), flutuações, transitórios impulsivos e de chaveamento, etc (Arrilaga, Bollen, & Watson, 2000; Dugan et al., 2004). Estes distúrbios podem ter duração de 50 ns, em transitórios impulsivos, e até vários minutos, em subtensões. Desta forma, quando tais eventos são monitorados por oscilógrafos, geram arquivos de dados de grande extensão que, além de serem difíceis de armazenar, trazem muitas vezes informações desnecessárias para a avaliação da QEE.

Deve-se ressaltar que a análise desses distúrbios pode demandar o uso de sofisticadas técnicas de Processamento Digital de Sinais e de Inteligência Computacional, uma vez que tais distúrbios são aleatórios e podem ocorrer tanto isoladamente quanto sequencialmente e/ou simultaneamente.

Deve-se notar que quando se trata de análise de distúrbios de QEE, diversos trabalhos têm sido publicados utilizando diversas técnicas de processamento digital de sinais com resultados muito bons (Santoso, Grady, Powers, Lamoree, & Bhatt, 2000; He & Starzyk, 2006; Santoso, Powers, Grady, & Parsons, 2000a; Hu, Xie, & Zhu, 2005), porém poucas metodologias utilizam a abordagem de múltiplos distúrbios agregados ao mesmo sinal de tensão, o que pode ser encontrado e, alguns casos práticos (Angrisani, Daponte, & D'Apuzzo, 1998; Kezunovic & Liao, 2002). A maioria dos métodos existentes lida com a análise de um único distúrbio presente no sinal de tensão. O desempenho destes métodos pode ser limitado porque frequentemente pode haver diversos tipos de distúrbios em um sinal de QEE monitorado em sistemas elétricos reais (Chuang, Lu, Huang, Hsiao, & Jiang, 2005, 2005). A fim de superar este problema, este trabalho propõe novos métodos para analisar sinais de QEE que apresentem múltiplos distúrbios.

A Transformada Wavelet Discreta (DWT, *Discrete Wavelet Transform*) se mostra como uma poderosa ferramenta de análise para os sinais de SEPs, sendo bastante utilizada em QEE devido a sua capacidade de separar diferentes componentes de frequência de um sinal preservando a informação temporal. Entretanto, quando se tem a presença de distúrbios simultâneos, a separação obtida com a DWT é limitada, uma vez que se dois ou mais distúrbios ocuparem a mesma

faixa de frequência e ocorrerem no mesmo intervalo de tempo, ela não será capaz de separá-los (Filho, 2003). Em (Ferreira, Cerqueira, Ribeiro, & Duque, 2006), é apresentada uma outra técnica para análise de distúrbios simultâneos, que se baseia no desacoplamento de diferentes distúrbios presentes em um sinal de tensão através da utilização de filtros digitais que separam o sinal adquirido em diferentes faixas de frequência. Entretanto, essa técnica encontra problemas na separação de distúrbios que ocupam a mesma faixa de frequência.

Neste trabalho, propõe-se a utilização inédita da Análise de Componentes Independentes (ICA, *Independent Component Analysis*) (Hyvärinen, Karhunen, & Oja, 2001) no estudo de distúrbios de QEE quando estes ocorrem simultaneamente (múltiplos distúrbios), visando o desacoplamento entre os diferentes distúrbios independentes que estejam ocorrendo durante o mesmo intervalo de tempo, a partir de um determinado modelo de mistura dos distúrbios originais. É importante salientar que este método recupera as formas de onda dos distúrbios isolados, sem o conhecimento prévio de quais distúrbios estejam envolvidos e de como foram misturados. Entretanto, para utilizar o modelo ICA, deve-se garantir que os componentes (distúrbios isolados) sejam estatisticamente independentes entre si e que os mesmos apresentem distribuições não-gaussianas, como será explicado no Capítulo 4. Além disso, o número de misturas observadas (sinais medidos) deve ser no mínimo igual ao número de componentes independentes. Desta forma, no que diz respeito à quantidade mínima necessária de misturas observadas, são propostas duas estruturas para separar múltiplos distúrbios. A primeira é aplicada quando são disponíveis  $M$  dispositivos de monitoramento ( $M \geq 2$ ) de QEE alocados em pontos distintos do SEP e sincronizados, e a outra é aplicada quando se tem disponível um único monitor de QEE, sendo necessário neste caso o uso de técnicas para se obter o número de misturas necessárias a partir de um único sinal medido. Esta situação é a mais comum e mais interessante, uma vez que equipamentos de monitoração ligados em pontos distantes da rede elétrica irão monitorar diferentes distúrbios, e mais econômica, já que não há a necessidade da utilização de dois ou mais equipamentos de monitoração próximos e sincronizados.

## 1.1 Estrutura da Dissertação

No próximo capítulo, são apresentados os principais distúrbios de qualidade de energia para que, no Capítulo 3, seja feita uma revisão bibliográfica sobre a utilização de técnicas de processamento digital de sinais para a análise de tais distúrbios. O capítulo 4 apresenta o conceito de separação cega de fontes e detalha a análise de componentes independentes. No capítulo 5, dois métodos baseados em ICA são propostos visando a análise de sinais de tensão da rede elétrica com a ocorrência de mais de um distúrbio simultaneamente. Neste capítulo, também são apresentados resultados e análises provenientes de simulações. Finalmente, no Capítulo 6, as conclusões do trabalho são apresentadas juntamente com as propostas para trabalhos futuros.

# 2

## Distúrbios de Qualidade de Energia

Este capítulo descreve resumidamente os tipos de distúrbios mais encontrados em sistemas de energia elétrica. De acordo com (Power Quality, 1995; Dugan et al., 2004), os diferentes tipos de distúrbios podem ser divididos em 7 categorias: transitórios, variações de curta duração, variações de longa duração, distorções na forma de onda, desequilíbrio de tensão, flutuação de tensão e variação na frequência do sistema. Estes distúrbios podem ser encontrados tanto em sistemas de transmissão quanto de distribuição de energia. Cada tipo de distúrbio apresenta características próprias e, por isso, pode causar diferentes falhas nos equipamentos conectados à rede elétrica. Deve-se ressaltar que estas características são, ainda, uma importante referência para o processo de identificação do distúrbio. Neste capítulo, algumas características importantes para a análise de distúrbios de QEE serão apresentadas, como a sua duração, espectro harmônico, possíveis causas e os possíveis danos causados às cargas sujeitas a estes distúrbios. A Tabela 2.1, extraída

de (Dugan et al., 2004), mostra algumas destas características para cada uma das categorias de distúrbios de QEE.

## 2.1 Transitórios

O termo transitório é utilizado para caracterizar manifestações ou respostas elétricas locais ou nas adjacências, oriundas de alterações súbitas nas condições operacionais de um sistema de energia elétrica. Muitos transitórios são decorrentes de variações instantâneas na corrente, as quais interagem com a impedância do sistema, resultado em elevadas tensões instantâneas. Transitórios podem ser consequência de cargas com operação intermitente, chaveamento de bancos de capacitores, faltas a terra, operação de dispositivos semicondutores e falhas em condutores. Descargas atmosféricas são um caso especial de transitórios, devido aos níveis extremamente altos de energia e rápido tempo envolvido (Power Quality, 1995).

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

### 2.1.1 Transitório impulsivo

Um transitório impulsivo pode ser definido como uma alteração repentina nas condições de estado permanente da tensão, corrente, ou ambas, caracterizando-se por apresentar impulsos unidirecionais em polaridade (positivo ou negativo) e nível de frequência bem diferenciado com relação à frequência fundamental do sistema elétrico. Suas principais causas são descargas atmosféricas (Power Quality, 1995).

Transitórios impulsivos são normalmente caracterizados por seus tempos de

Tabela 2.1: Características de alguns distúrbios de qualidade de energia.

Categoria	Conteúdo espectral	Duração típica	Amplitude típica
Transitórios			
Transitórios Impulsivos	Tempo de subida entre 5 ns e 0,1 ms	< 1 ms	
Transitórios Oscilatórios	Até 5 MHz	5 $\mu$ s - 50 ms	0 - 8 pu
Variações de curta duração			
Afundamento ( <i>sag</i> )		0,5 ciclo - 1 min.	0,1 - 0,9 pu
Elevação ( <i>swell</i> )		0,5 ciclo - 1 min.	1,1 - 1,8 pu
Interrupção		< 1 min.	< 0,1 pu
Variações de longa duração			
Subtensão		> 1 min.	0,8-0,9 pu
Sobretensão		> 1 min.	1,1-1,2 pu
Interrupção sustentada		> 1 min.	0,0 pu
Distorções da forma de onda			
Nível CC		Regime permanente	0-0,1%
Harmônicos	0-100° harmônico	Regime permanente	0-20%
Interharmônicos	0-6 KHz	Regime permanente	0-2%
<i>Notches</i>		Regime permanente	
Ruído	Toda banda	Regime permanente	0-1%
Outros distúrbios			
Desequilíbrio de tensão		Regime permanente	0,5-2%
Flutuação de tensão ( <i>flicker</i> )	< 25 Hz	Intermitente	0,1-7%
Variações na frequência fundamental		< 10 s	

subida e descida. Classificam-se ainda os transitórios impulsivos de acordo com seus tempos de duração, em nanossegundos (duração típica menor que 50 ns e tempo de subida de 5 ns), microssegundos (duração típica entre 50 ns e 1 ms e tempo de subida de 1  $\mu$ s), e milissegundos (duração típica maior que 1 ms e tempo de subida de 0,1 ms). Estes fenômenos podem também ser revelados por seus conteúdos espectrais. Devido as altas frequências envolvidas, transitórios impulsivos são amortecidos rapidamente pela impedância do sistema, não sendo conduzidos a pontos distantes do seu local de incidência. Transitórios impulsivos podem excitar a frequência natural do SEP e produzir assim transitórios oscilatórios (Power Quality, 1995).

### **2.1.2 Transitórios oscilatórios**

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

De acordo com o conteúdo espectral, os transitórios oscilatórios podem ser subdivididos em três classes: baixa frequência (conteúdo espectral  $<5$  kHz e duração típica de 3-50 ms), média frequência (conteúdo espectral de 5-500 kHz e duração típica de 20  $\mu$ s) e alta frequência (conteúdo espectral de 0,5-5 MHz e duração típica de 5  $\mu$ s). Os transitórios oscilatórios de baixa frequência são frequentemente encontrados em sistemas de subtransmissão e distribuição, e são causados por diversos eventos. O mais frequente é a energização de bancos de capacitores, o qual geralmente resulta em oscilações de tensão com frequência entre 300 Hz e 900 Hz, com magnitude máxima de 2,0 p.u, sendo valores típicos de 1,3 a 1,5 p.u com duração entre 0,5 e 3 ciclos, dependendo das características de amortecimento do sistema. A Figura 2.1 ilustra a simulação de um transitório de chaveamento capacitivo em um

sinal de tensão.

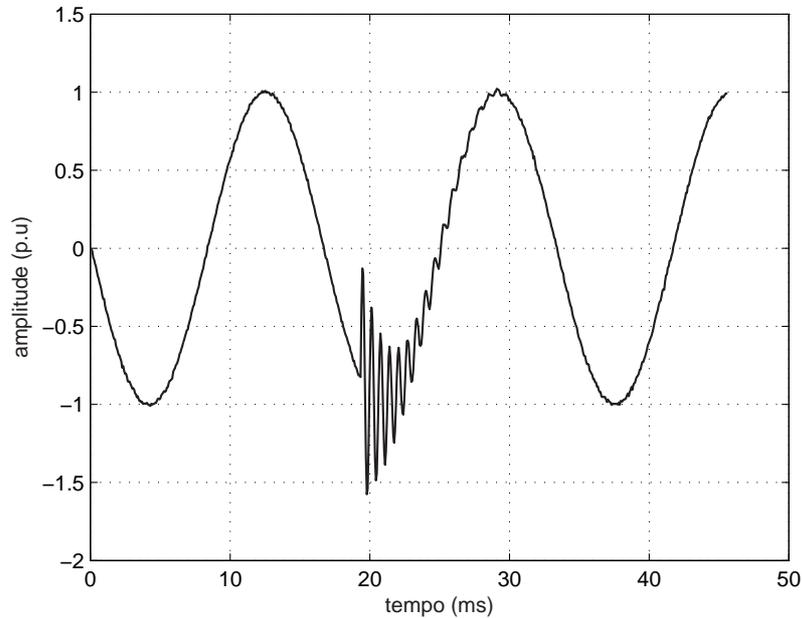


Figura 2.1: Exemplo de transitório oscilatório, proveniente do chaveamento de um banco de capacitores.

Com relação aos transitórios oscilatórios de média frequência, estes podem ser causados por energização de capacitores, resultando em correntes transitórias de dezenas de kHz, chaveamento de disjuntores para eliminação de faltas e podem também ser o resultado de uma resposta involuntária do sistema a um transitório impulsivo.

Já os transitórios oscilatórios de alta frequência são geralmente o resultado de uma resposta do sistema a um transitório impulsivo. Isto é, podem ser causados por descargas atmosféricas ou por chaveamento de circuitos indutivos. Também, a desenergização de cargas indutivas pode gerar impulsos de alta frequência. Apesar de serem de curta duração, estes transitórios podem interferir na operação de cargas eletrônicas. Filtros de alta frequência e transformadores isoladores podem ser usados para proteger as cargas contra este tipo de transitório.

## 2.2 Variações de curta duração

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

### 2.2.1 Afundamento (*Sag*)

Afundamento é a redução da amplitude do componente fundamental da tensão ou corrente (entre 0,1 e 0,9 pu), com duração entre 0,5 ciclo e 1 minuto (Power Quality, 1995). Os afundamentos podem ser classificados como instantâneos (duração entre 0,5 e 30 ciclos), momentâneos (duração entre 30 ciclos e 3 seg) ou temporários (duração entre 3 seg e 1 min). As principais causas de afundamentos estão geralmente associadas a faltas no sistema, chaveamento de grandes cargas, partida de grandes motores ou energização de transformadores. A Figura 2.2 mostra a simulação de um afundamento de tensão típico.

### 2.2.2 Elevação (*Swell*)

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

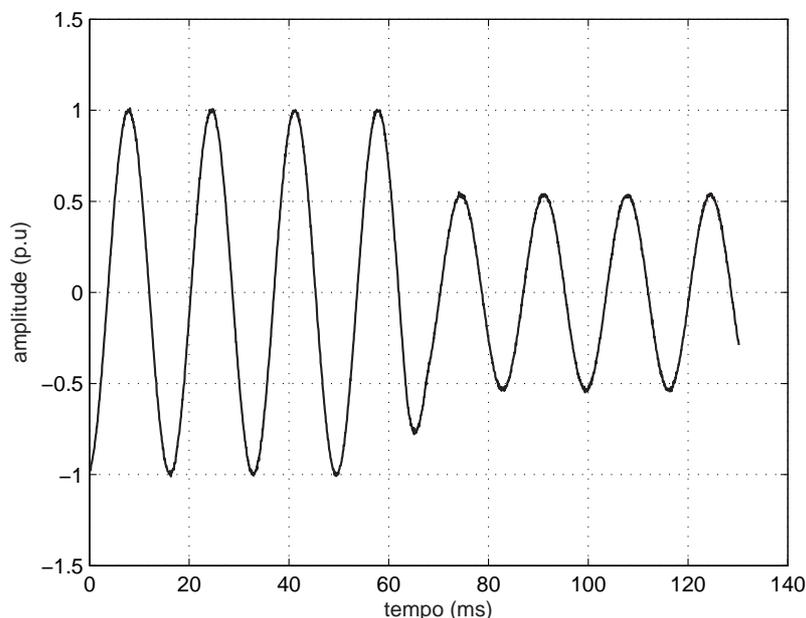


Figura 2.2: Exemplo de afundamento de tensão.

carga ou chaveamento de um grande banco de capacitores. A Figura 2.3 mostra a simulação de uma elevação de tensão típica.

A principal preocupação a respeito da ocorrência de elevações recai sobre os equipamentos eletrônicos, uma vez que elas podem vir a danificar os componentes internos destes equipamentos, conduzindo-os à má operação, ou em casos extremos, à completa inutilização.

### 2.2.3 Interrupção

Uma interrupção de curta duração ocorre quando a tensão ou corrente decresce a menos de 0,1 pu por um período de tempo não excedente a 1 min. Interrupções podem ser resultantes de faltas no SEP, falhas de equipamentos e mal funcionamento de sistemas de controle (Dugan et al., 2004). Uma interrupção é medida a partir de seu tempo de duração, pois a amplitude da tensão é sempre menor que 10% do seu valor nominal. A duração de uma interrupção, devido a uma falta no sistema da concessionária, é determinada pelo tempo de operação dos dispositivos de proteção

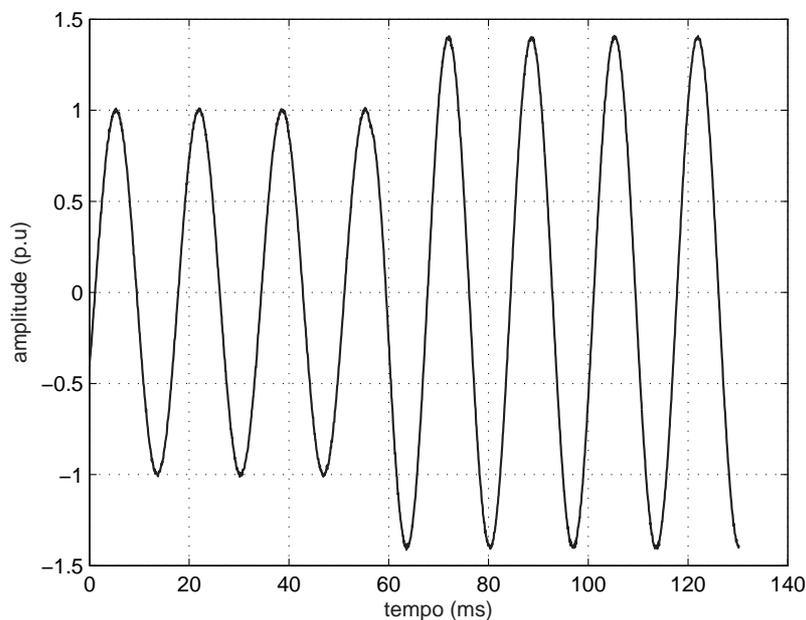


Figura 2.3: Exemplo de elevação de tensão.

e do evento particular que está causando a falta.

Alguns dados estatísticos revelam que 75 % das faltas em redes aéreas são de natureza temporária. No passado, este percentual não era considerado preocupante. Entretanto, com o crescente emprego de cargas eletrônicas, como inversores e computadores, este número passou a ser relevante nos estudos relacionados ao sistema. Agora, são tidos como responsáveis pela saída de operação de diversos equipamentos, interrompendo o processo produtivo e causando enormes prejuízos às indústrias.

## 2.3 Variações de longa duração

Variações de longa duração compreendem desvios no valor eficaz da tensão ou na frequência do sistema, por um período maior que 1 min. São classificadas em sobretensão, subtensão e interrupção sustentada, dependendo da causa da variação. Sobretensões e subtensões geralmente não são resultantes de faltas no

sistema (Power Quality, 1995), sendo causadas normalmente por variações de carga e operações de chaveamento no sistema.

### 2.3.1 Sobretensão

Uma sobretensão é caracterizada por um aumento no valor eficaz da tensão acima de 1,1 pu (valores típicos entre 1,1 e 1,2 pu), considerando-se a frequência do sistema, por um período de duração maior que 1 minuto (Dugan et al., 2004). Além de ser causada pela saída de grandes grupos de cargas da rede, também é causada por deficiências na regulação da tensão por bancos de capacitores e o incorreto uso de *taps* em transformadores.

Com relação às consequências das sobretensões, estas podem resultar em falhas dos equipamentos. Os dispositivos eletrônicos podem sofrer danos durante condições de sobretensões, embora transformadores, cabos, disjuntores, TCs (*Transformadores de corrente*), TPs (*Transformadores de tensão*) e máquinas rotativas, geralmente não apresentem falhas imediatas. Entretanto, tais equipamentos, quando submetidos a sobretensões sustentadas, poderão apresentar falhas de operação durante sua ocorrência.

### 2.3.2 Subtensão

Uma subtensão é caracterizada por um decréscimo no valor eficaz da tensão a valores menores que 0,9 pu, considerando-se a frequência do sistema, e com período de duração maior que 1 minuto (Dugan et al., 2004). Suas principais causas são entrada de grandes grupos de cargas na rede e saída de bancos de capacitores reguladores de tensão.

Dentre os problemas causados por subtensões, destacam-se:

- Redução da potência reativa fornecida por bancos de capacitores ao sistema;
- Possível interrupção da operação de equipamentos eletrônicos, tais como computadores e controladores eletrônicos;
- Redução do índice de iluminação em circuitos de iluminação incandescente.

### 2.3.3 Interrupção sustentada

Uma interrupção sustentada é caracterizada por um decréscimo da tensão a 0 pu por um período de tempo superior a 1 minuto. É frequentemente permanente e requer a intervenção da concessionária para reparar o sistema e restaurar o fornecimento de energia (Dugan et al., 2004).

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

A consequência de uma interrupção sustentada é o desligamento dos equipamentos, exceto para aquelas cargas protegidas por sistemas *no-breaks* ou por outras formas de armazenamento de energia. No caso de interrupção sustentada o prejuízo é ainda maior, visto que o tempo de duração da interrupção é muito grande, comparado com o da interrupção de curta duração, retardando a retomada do processo produtivo.

## 2.4 Distorções de forma de onda

Distorção de forma de onda é definida como um desvio, em regime permanente, da forma de onda idealmente senoidal na frequência do sistema. É caracterizada principalmente pelo conteúdo espectral do desvio. Os principais tipos de distorção de forma de onda são (Dugan et al., 2004):

- Nível CC (Corrente Contínua)
- Harmônicos
- Interharmônicos
- *Notches*

- Ruídos

### 2.4.1 Nível CC

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

### 2.4.2 Harmônicos

Harmônicos são tensões ou correntes senoidais contendo frequências que são múltiplos inteiros da frequência nominal do SEP (frequência fundamental, tipicamente 50 ou 60 Hz). Estes harmônicos distorcem as formas de onda da tensão e corrente e ocorrem devido a características não-lineares de equipamentos e cargas alimentados pelo SEP (Power Quality, 1995), tais como retificadores, inversores e diversos equipamentos advindos da eletrônica de potência.

Estes equipamentos podem ser modelados como fontes de corrente que injetam correntes harmônicas no SEP. Surgem também distorções harmônicas na tensão, já que estas correntes causam queda de tensão não-linear na impedância do sistema. A amplitude típica da resultante de harmônicos encontra-se em valores menores que 0,2 pu. A Figura 2.4 ilustra a simulação da presença de harmônicos na forma de onda da tensão.

No passado não havia grandes preocupações com harmônicos. Cargas com características não-lineares eram pouco utilizadas e os equipamentos eram mais resistentes aos efeitos provocados por harmônicos. Entretanto, nos últimos anos, com o rápido desenvolvimento da eletrônica de potência e a utilização de métodos que buscam o uso racional da energia elétrica, o conteúdo harmônico presente nos sistemas tem-se elevado, causando uma série de efeitos indesejáveis em diversos

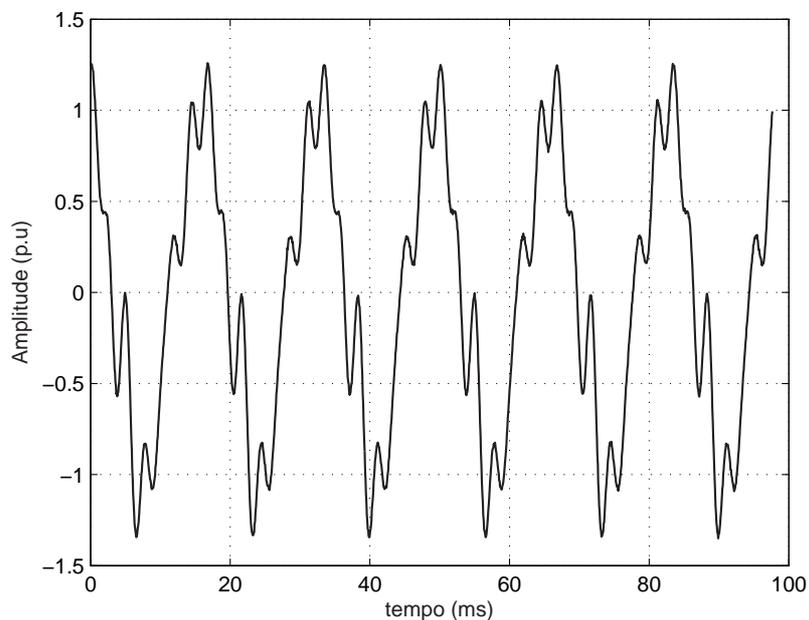


Figura 2.4: Exemplo de harmônicos de tensão.

equipamentos ou dispositivos, comprometendo a qualidade e o próprio uso racional da energia elétrica.

### 2.4.3 Interharmônicos

Tensões ou correntes contendo componentes de frequência que não são múltiplos inteiros da frequência fundamental são chamadas de interharmônicos. Podem aparecer como frequências discretas ou como uma ampla faixa espectral. Normalmente, a amplitude desses fenômenos se encontra abaixo de 0,02 pu. As principais causas de distorção interharmônica são conversores estáticos de frequência, cicloconversores, fornos de indução e equipamentos a arco (Dugan et al., 2004).

#### 2.4.4 *Notches*

*Notches* são distúrbios periódicos de tensão causados pela operação normal de dispositivos de eletrônica de potência quando a corrente é comutada de uma fase para outra.

*Notches* representam um caso especial que se situa entre transitórios e distorção harmônica. Desde que *notches* ocorrem continuamente (regime permanente), eles podem ser caracterizados por meio do espectro harmônico da tensão afetada. Entretanto, os componentes de frequência associados com *notches* são de alta ordem e podem não ser caracterizados por meio de equipamentos de medida normalmente utilizados para análise harmônica (Power Quality, 1995).

Conversores trifásicos que produzem corrente CC são a principal causa de *notches* de tensão. Os *Notches* ocorrem quando a corrente comuta de uma fase para outra. Durante este período, há um curto circuito momentâneo entre duas fases. A Figura 2.5 mostra a simulação de como os *notches* se manifestam no sinal de tensão.

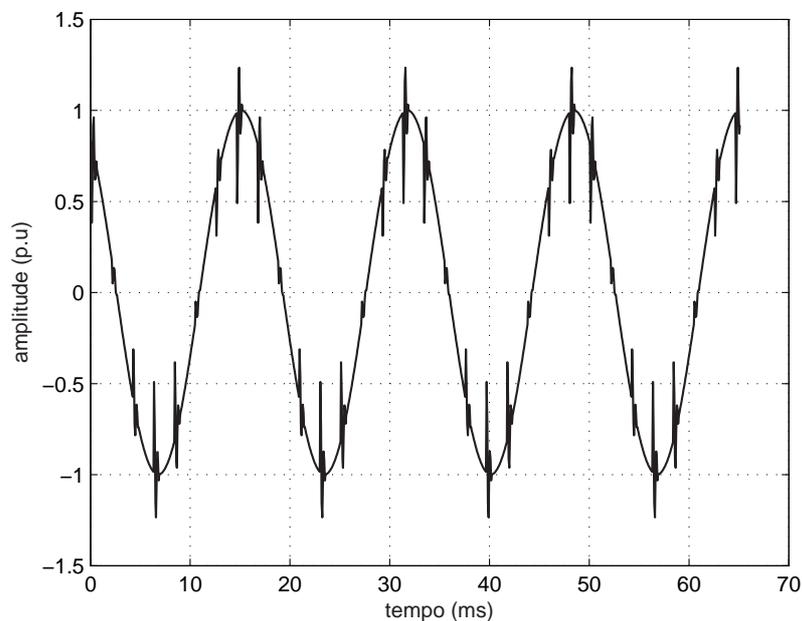


Figura 2.5: Exemplo de *notches*.

### 2.4.5 Ruídos

Ruídos são definidos como sinais elétricos indesejáveis com larga faixa espectral com frequências menores que 200 KHz e que são superpostos às tensões ou corrente de fase, ou encontrados em condutores de neutro. Valores típicos de magnitude se encontram em torno de 0,01 pu.

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

Ruídos podem causar distúrbios em equipamentos eletrônicos tais como microcomputadores e controladores programáveis. O problema pode ser suavizado por meio da utilização de filtros e transformadores de isolamento, entre outros (Dugan et al., 2004).

## 2.5 Desequilíbrios de tensão

Desequilíbrio de tensão (ou desbalanceamento) é definido como a razão entre o componente de sequência negativa e o componente de sequência positiva da tensão (Power Quality, 1995). O componente de sequência negativa da tensão em um SEP geralmente surge devido a cargas desbalanceadas que causam o fluxo de correntes de sequência negativa.

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

As principais fontes de desequilíbrios de tensão são alocações mal dimensionadas

de cargas monofásicas nos circuitos de alimentação trifásicos. Podem também ser resultantes da queima de fusíveis em uma das fases de um banco de capacitores trifásico.

Tais fatores fazem com que a qualidade no fornecimento de energia, idealizada pela concessionária, seja prejudicada e desta forma alguns consumidores têm em suas alimentações um desequilíbrio de tensão, o qual se manifesta sob três formas distintas: amplitudes diferentes, assimetria nas fases e assimetria conjunta de amplitudes e fases. Destas, apenas a primeira é frequentemente evidenciada no SEP.

## 2.6 Flutuações de tensão

Flutuações de tensão correspondem a variações sistemáticas ou aleatórias do valor eficaz da tensão, e que são compreendidas na faixa de 0,95 a 1,05 pu (Dugan et al., 2004).

Normalmente são causadas por cargas industriais que apresentam variações significativas de corrente, especialmente do componente reativo. Fornos a arco ligados a sistemas de transmissão e distribuição são as fontes mais comuns de geração de flutuações de tensão.

Os principais efeitos nos SEPs, causados por flutuações de tensão, são:

- Oscilações de potência e torque das máquinas elétricas;
- Queda de rendimento dos equipamentos elétricos;
- Interferência nos sistemas de proteção;
- Efeito *flicker* ou cintilação luminosa.

Flutuações de tensão geralmente se apresentam como uma modulação do componente fundamental da tensão (semelhante à modulação AM em um sinal de rádio). Tipicamente, o fenômeno de *flicker* é perceptível ao olho humano se a frequência de modulação situa-se na faixa de 6 a 8 Hz. A Figura 2.6 ilustra

a simulação de uma flutuação de tensão com frequência de modulação de 7 Hz e amplitude de 0,05 pu.

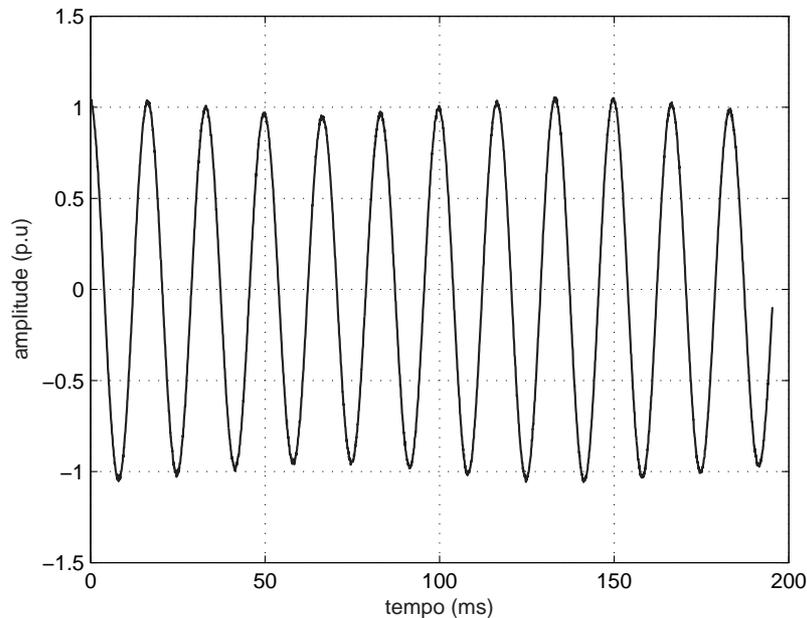


Figura 2.6: Exemplo de flutuação de tensão.

Geralmente o termo *flicker* é usado erroneamente para descrever flutuações de tensão. Na verdade, ele corresponde ao fenômeno de cintilação luminosa observado em algumas lâmpadas, e que é provocado por flutuações de tensão. Este tema merece especial atenção, uma vez que o desconforto visual associado à perceptibilidade do olho humano às variações da intensidade luminosa é indesejável.

## 2.7 Variações na frequência do sistema

Variações na frequência do sistema são definidas como o desvio da frequência fundamental do sistema elétrico do seu valor nominal. No Brasil, a frequência fundamental é de 60 Hz.

A frequência do sistema está diretamente relacionada à velocidade de rotação dos geradores que alimentam o sistema. Este fenômeno ocorre quando há um

desbalanceamento entre a potência solicitada por um sistema de cargas e a potência disponibilizada pelo gerador. Desvios típicos na frequência fundamental se situam na faixa de  $60 \pm 0,5$  Hz. A amplitude da variação e sua duração dependem das características da carga e da resposta do regulador de velocidade instalado no sistema de geração.

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

## **2.8 Sumário**

Este capítulo descreveu os principais distúrbios relacionados à qualidade de energia, já que este trabalho visa analisá-los. No próximo capítulo, será feita uma revisão bibliográfica sobre processamento digital de sinais aplicado para análise de distúrbios de QEE.

# 3

## Revisão Sobre Técnicas de Análise de Distúrbios de QEE

O monitoramento da QEE teve início a partir da década de 70 com o surgimento da tecnologia dos voltímetros analógicos. A seguir, na década de 80, começaram a aparecer os osciloscópios e sistemas de visualização gráfica, facilitando de certa forma o monitoramento da QEE (Khan, 2001).

A partir da década de 90, avanços na área de processamento digital de sinais, redução do custo de sistemas de monitoramento baseados em dispositivos DSP (*Digital Signal Processor*) e FPGA (*Field Programmable Gate Array*), e o maior conhecimento a respeito do uso e aplicação das técnicas de processamento digital de sinais e inteligência computacional para a análise de sinais de tensão e corrente em SEP, contribuíram de forma significativa para o uso de tais técnicas aplicadas a SEP e, conseqüentemente, para o monitoramento da QEE.

### 3.1 Problema de análise de distúrbios de QEE

Um sistema desenvolvido para análise de distúrbios de QEE deve identificar corretamente a ocorrência de cada anormalidade em um sinal de tensão do SEP. O sinal de tensão no domínio do tempo discreto,  $\{x[n]\}$ , pode ser expresso como uma soma da contribuição de diversos tipos de sinais primitivos, os quais são associados aos fenômenos de QEE (Ribeiro, 2005):

$$x[n] = x(t)|_{t=nT_s} := f[n] + h[n] + i[n] + t[n] + v[n], \quad (3.1)$$

onde  $n = 0, \dots, N - 1$ ;  $T_s = \frac{1}{F_s}$  é o período de amostragem; as sequências  $\{f[n]\}$ ,  $\{h[n]\}$ ,  $\{i[n]\}$ ,  $\{t[n]\}$  e  $\{v[n]\}$  representam o componente fundamental, harmônicos, interharmônicos, transitórios e ruído, respectivamente. Cada um destes sinais primitivos pode ser definido como:

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

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

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

$$t[n] := \sum_{k=1}^K t_k[n], \quad (3.5)$$

e  $\{v[n]\}$  é um ruído com distribuição normal  $\mathcal{N}(0, \sigma_v^2)$  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 e fase do componente fundamental do sinal de tensão, respectivamente. Repare que os parâmetros do componente fundamental podem variar com o tempo. Distúrbios associados a estas variações são: elevações e afundamentos instantâneos, momentâneos e temporários; interrupções momentâneas, temporárias e sustentadas;

sobretensões e subtensões; flutuações de tensão; e variações na frequência do sistema (Power Quality, 1995).

Em (3.3),  $h_m[n]$  é o  $m$ -ésimo harmônico, definido como:

$$h_m[n] := A_m[n] \cos \left( 2\pi m \frac{f_0[n]}{F_s} n + \theta_m[n] \right), \quad (3.6)$$

em (3.6),  $A_m[n]$  é a amplitude e  $\theta_m[n]$  é a fase do  $m$ -ésimo harmônico.

Em (3.4),  $i_j[n]$  é o  $j$ -ésimo interharmônico, definido como:

$$i_j[n] := A_{I,j}[n] \cos \left( 2\pi \frac{f_{I,j}[n]}{F_s} n + \theta_{I,j}[n] \right), \quad (3.7)$$

em (3.7),  $A_{I,j}[n]$  é a amplitude,  $f_{I,j}[n]$  é a frequência e  $\theta_{I,j}[n]$  é a fase do  $j$ -ésimo interharmônico.

Em (3.5),  $\{t_k[n]\}$  é o  $k$ -ésimo sinal transitório ou de deformação, tal como transitório impulsivo, transitório oscilatório, *spikes*, *notches*, etc.

A operação normal de um SEP pode ser modelada como:

$$x_n[n] = f[n] + v[n] = A_0 \cos \left( 2\pi \frac{f_0}{F_s} n + \theta_0 \right) + v[n], \quad (3.8)$$

e um distúrbio ocorre quando alguma condição anormal aparece na forma de onda da tensão, tal como o chaveamento de um capacitor  $x_c[n]$ , modelado por (3.9), ou a presença de harmônicos  $x_h[n]$ , modelada por (3.10).

$$x_c[n] = A_0 \cos \left( 2\pi \frac{f_0}{F_s} n + \theta_0 \right) + t[n] + v[n] \quad (3.9)$$

$$x_h[n] = A_0 \cos \left( 2\pi \frac{f_0}{F_s} n + \theta_0 \right) + h[n] + v[n] \quad (3.10)$$

Os distúrbios modelados por (3.9) e (3.10) são exemplos de distúrbios isolados. Contudo, a ocorrência de um distúrbio pode tornar o sistema suscetível à ocorrência de um novo distúrbio logo em seguida ou simultaneamente (Power Quality, 1995). Por exemplo, a ocorrência de uma falta ou um curto-circuito pode causar um transitório que vem seguido de um afundamento ou uma elevação. Sendo assim, é fundamental considerar a ocorrência também de múltiplos distúrbios, que podem

aparecer simultaneamente ou até mesmo em sequência na forma de onda da tensão. A Figura 3.1 ilustra um sinal de tensão simulado contendo dois distúrbios, que ocorrem simultaneamente: *notches* e harmônicos. Já no sinal de tensão da Figura 3.2, ocorre inicialmente um transitório de chaveamento capacitivo e, em sequência, uma elevação.

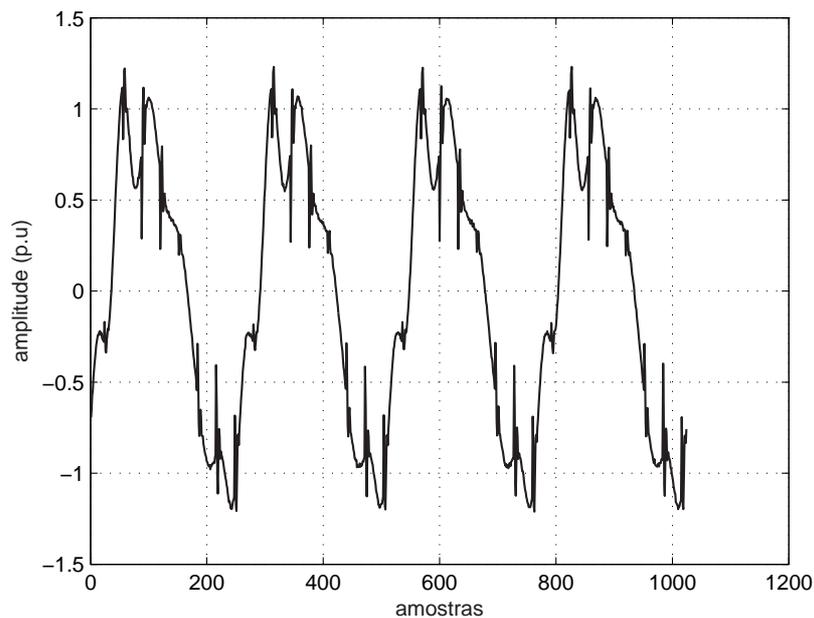


Figura 3.1: Sinal de tensão contendo dois distúrbios: *notch* e harmônicos.

## 3.2 Revisão Bibliográfica

Diversas técnicas de processamento digital de sinais e inteligência computacional têm sido aplicadas em análise de QEE. Em (Santoso, Grady, et al., 2000) é realizada a caracterização de eventos de QEE presentes em redes de distribuição através da Transformada Discreta de Fourier (DFT, *Discrete Fourier Transform*) e da Transformada Wavelet Discreta (DWT, *Discrete Wavelet Transform*), tais como a operação de conversores estáticos e a energização de transformadores e bancos de capacitores.

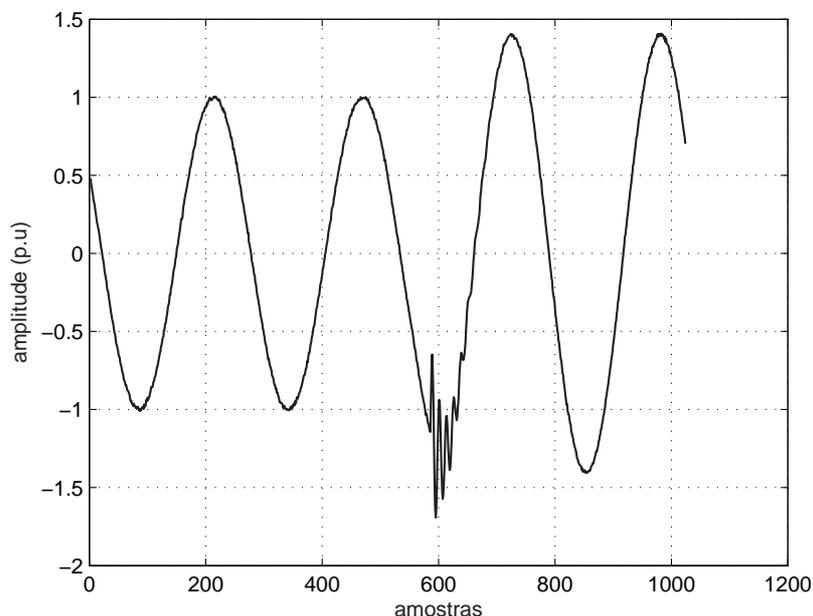


Figura 3.2: Sinal de tensão contendo dois distúrbios: transitório de chaveamento capacitivo e elevação.

O trabalho de (He & Starzyk, 2006) propõe uma nova técnica para a classificação de distúrbios de QEE baseada na DWT e em sistemas SOLAR (*Self Organizing Learning Array*). A DWT é utilizada para extrair vetores de parâmetros dos distúrbios de QEE baseado na Análise Multiresolução (AMR). Para compor o vetor de parâmetros, utiliza-se apenas a energia de cada nível de decomposição obtido pela AMR. Desta maneira, a dimensão do vetor de parâmetros é fortemente reduzida e é dada pelo número de decomposições. Estes vetores de parâmetros são aplicados ao sistema SOLAR para treinamento e teste.

O desempenho da DWT em detectar e localizar distúrbios é gravemente prejudicado na presença de ruídos, devido a sua dificuldade em distinguir os distúrbios e os ruídos. Em (Yang & Liao, 2001) é proposta uma técnica para detecção de distúrbios transitórios em ambientes ruidosos utilizando a DWT, em que um limiar de eliminação das influências dos ruídos é determinado adaptativamente de acordo com os ruídos de fundo presentes. Em (Kim & Aggarwal, 2001a) e (Kim &

Aggarwal, 2001b) são apresentadas algumas aplicações práticas da DWT em SEPs, tais como: proteção/deteção de faltas e deteção de distúrbios de QEE.

Em (Santoso, Powers, et al., 2000a) e (Santoso, Powers, Grady, & Parsons, 2000b) é realizada a combinação da DWT e de Redes Neurais Artificiais (ANNs, *Artificial Neural Networks*) para reconhecimento automático de distúrbios de QEE. A DWT é utilizada para detectar e extrair parâmetros dos distúrbios, e as ANNs para classificação. Diferente das técnicas de identificação de distúrbios implementadas no domínio do tempo utilizando uma ANN individual, o esquema de reconhecimento proposto é realizado no domínio *wavelet* utilizando um conjunto de múltiplas ANNs.

Em (Cerqueira, Duque, Trindade, & Ribeiro, 2005) e (Cerqueira, Duque, Ribeiro, & Trindade, 2006), é proposto um algoritmo de baixo esforço computacional para a deteção e a classificação de eventos elétricos relacionados à QEE. A deteção dos eventos é realizada com base na análise de características estatísticas da energia do sinal de erro, que é definido como a diferença entre o sinal amostrado e seu componente senoidal fundamental, gerado pelo algoritmo proposto. Para a classificação de eventos, é proposta a utilização da técnica de processamento multitaxa para a extração de vetores reduzidos de parâmetros dos sinais de erro. Estes vetores são apresentados a uma ANN *perceptron* multicamadas para que a mesma aproxime as superfícies de separação entre as diferentes classes de eventos associadas aos distúrbios comumente encontrados nas redes elétricas.

Em (Hu et al., 2005) são utilizadas Wavelets e Máquinas de Vetor de Suporte (SVMs, *Support Vector Machines*) aliadas a Sistemas Fuzzy para deteção e classificação automática de distúrbios de QEE. Os tipos de distúrbios de tensão analisados incluem: *sags*, *swells*, interrupções, transitórios de chaveamento, transitórios impulsivos, *flickers*, harmônicos e *notches*. As transformadas de Fourier e *Wavelet* são utilizadas para remover ruídos, decompor os sinais e então obter os vetores de parâmetros dos distúrbios. O sistema *Fuzzy-SVM* é projetado e treinado utilizando os vetores de parâmetros para classificar os distúrbios associados. Em (Lin, Wu, Lin, & Cheng, 2008) e (Cerqueira, Ferreira, Ribeiro, & Duque, 2008), também é utilizada SVM aliada a outras técnicas para classificar distúrbios.

Em (Oleskovicz et al., 2006) é apresentado um estudo comparativo entre

ferramentas de análise aplicáveis à QEE, enfatizando-se a Transformada de Fourier de Tempo Curto (STFT, *Short Time Fourier Transform*), a DWT e ANNs. Das ferramentas apontadas, a STFT e a DWT mostram-se aplicáveis à detecção, localização e classificação de distúrbios agregados às formas de onda de tensão em um sistema de distribuição, com o intuito de prover um diagnóstico preciso das situações enfrentadas. Além da detecção, localização e classificação pelas técnicas citadas, os distúrbios são também classificados segundo sua natureza, utilizando-se ANNs.

Todas as técnicas discutidas anteriormente são utilizadas para extrair características intrínsecas de cada tipo de distúrbio. Para distúrbios de QEE isolados, estas técnicas apresentam resultados satisfatórios, mas por outro lado, quando há ocorrência de múltiplos distúrbios, seus resultados são insatisfatórios. Assim, para os casos de distúrbios que ocorrem simultaneamente ou sequencialmente, é necessário o emprego de metodologias mais sofisticadas para a melhoria do desempenho dos classificadores.

A DWT se mostra como uma poderosa ferramenta de análise para os sinais de SEP, sendo bastante utilizada em QEE devido a sua capacidade de separar diferentes componentes de frequência de um sinal preservando a informação temporal. Em (Chuang et al., 2005) e (Chuang et al., 2005), a DWT é aplicada para análise de múltiplos distúrbios, mas seu desempenho é limitado, uma vez que se dois ou mais distúrbios ocuparem a mesma faixa de frequência e ocorrerem no mesmo intervalo de tempo, ela não será capaz de separá-los. Em (Ferreira et al., 2006), um sistema de classificação de distúrbios de QEE é proposto, considerando a possibilidade de ocorrência de múltiplos distúrbios. Este sistema é baseado na idéia de utilização de filtros para tentar inicialmente desacoplar a informação de distúrbios simultâneos, porém ainda enfrenta problemas na separação dos distúrbios que ocupam a mesma faixa de frequência.

Para tentar resolver o problema da análise de distúrbios de QEE quando estes ocorrem simultaneamente, foi proposto em (Lima, Cerqueira, et al., 2008) a utilização inédita da recente técnica não-supervisionada de análise de componentes independentes (Hyvärinen et al., 2001) para tal fim, visando o desacoplamento entre

os diferentes distúrbios independentes que estejam ocorrendo durante o mesmo intervalo de tempo. É importante salientar que este método recupera as formas de onda dos distúrbios isolados, sem o conhecimento prévio de quais distúrbios estejam envolvidos. O método também não necessita de etapa de treinamento. Já no trabalho (Lima, Ferreira, et al., 2008), além de separar os distúrbios estatisticamente independentes contidos nos dados analisados, realiza-se também a classificação dos distúrbios separados baseada em estatísticas de ordem superior como etapa de pré-processamento e em redes neurais artificiais para a classificação propriamente dita.

### **3.3 Sumário**

Neste capítulo, foram apresentados resumidamente diversos trabalhos que têm em comum a utilização de técnicas de processamento digital de sinais para a análise de distúrbios de QEE. Pode-se observar que a maioria das técnicas propostas até o momento visam a análise de distúrbios isolados, enquanto que poucas tratam o problema da ocorrência simultânea de eventos. Vale ressaltar que os dois últimos trabalhos citados apresentam resumidamente a proposta deste trabalho.

# 4

## Separação Cega de Fontes

Este capítulo apresenta os aspectos básicos relativos à Separação Cega de Fontes (BSS, *Blind Source Separation*). Inicialmente é descrito o problema e apresentada a sua caracterização matemática. Por fim, são discutidos os fundamentos de uma técnica fortemente relacionada à BSS, chamada Análise de Componentes Independentes (ICA, *Independent Component Analysis*), e que é o item principal deste trabalho.

### 4.1 Descrição do problema

Considere uma situação onde há uma certa quantidade de sinais emitidos ao mesmo tempo por diferentes objetos ou fontes. Estas fontes podem ser, por exemplo, diferentes áreas do cérebro emitindo sinais elétricos; pessoas conversando em uma sala, sendo assim, emitindo sinais de voz; ou telefones móveis emitindo suas ondas

de rádio frequência. Considere também que há diversos sensores colocados em diferentes posições, tal que cada sinal capturado seja uma mistura ponderada das fontes originais.

Para ilustrar o problema, considere que existem três sinais desconhecidos (fontes) e também três sinais observados. Denote por  $x_1(n), x_2(n)$  e  $x_3(n)$  os sinais observados, e por  $s_1(n), s_2(n)$  e  $s_3(n)$  as fontes originais (sinais desconhecidos). Considere ainda que os sinais  $x_i(n)$  são somas ponderadas dos sinais  $s_i(n)$ , onde os coeficientes dependem das distâncias entre as fontes e os sensores:

$$\begin{aligned} x_1(n) &= a_{11}s_1(n) + a_{12}s_2(n) + a_{13}s_3(n) \\ x_2(n) &= a_{21}s_1(n) + a_{22}s_2(n) + a_{23}s_3(n) \\ x_3(n) &= a_{31}s_1(n) + a_{32}s_2(n) + a_{33}s_3(n) \end{aligned} \tag{4.1}$$

Em (4.1), os termos  $a_{ij}$  são coeficientes constantes que correspondem aos pesos de mistura das fontes. Eles são assumidos *desconhecidos*, já que não se pode saber os seus valores sem conhecer todas as propriedades do sistema físico de mistura, que pode ser extremamente complicado. As fontes  $s_i$  são também *desconhecidas*, já que não se pode gravá-las diretamente.

Como um exemplo, considere os sinais na Figura 4.1. São três misturas lineares  $x_i$ ,  $i = 1, 2, 3$ , de algumas fontes originais desconhecidas. As misturas parecem ser completamente ruidosas, mas de fato, há alguns sinais muito bem estruturados por trás destes sinais observados.

O que o problema de BSS resolve é tentar encontrar as fontes originais a partir das misturas  $x_1(n), x_2(n)$  e  $x_3(n)$ . O termo *cego* significa que as fontes não são observáveis e que não há informação disponível acerca de como elas foram misturadas (J.-F. Cardoso, 1998a).

Pode-se com segurança assumir que os coeficientes de mistura  $a_{ij}$  sejam diferentes o suficiente para garantir que a matriz que eles formam seja inversível. Assim, existe uma matriz  $\mathbf{W}$  com coeficientes  $w_{ij}$ , tal que pode-se separar os sinais  $s_i$  como descrito em (4.2).

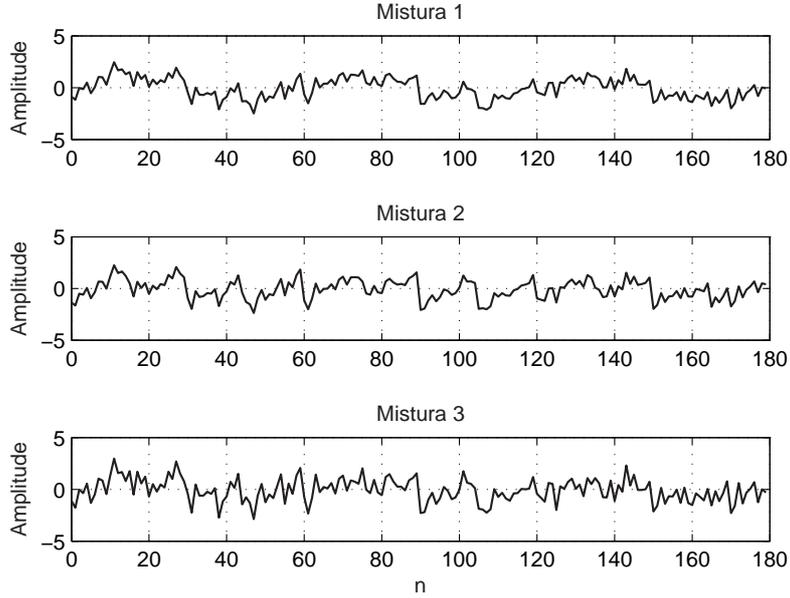


Figura 4.1: Sinais observados, que são assumidos como misturas de fontes desconhecidas.

$$\begin{aligned}
 s_1(n) &= w_{11}x_1(n) + w_{12}x_2(n) + w_{13}x_3(n) \\
 s_2(n) &= w_{21}x_1(n) + w_{22}x_2(n) + w_{23}x_3(n) \\
 s_3(n) &= w_{31}x_1(n) + w_{32}x_2(n) + w_{33}x_3(n)
 \end{aligned} \tag{4.2}$$

A matriz  $\mathbf{W}$  poderia ser encontrada simplesmente por meio da inversão da matriz que contém os coeficientes de mistura  $w_{ij}$ , se todos estes coeficientes fossem conhecidos.

A questão agora é: Como é possível estimar os coeficientes  $w_{ij}$  em (4.2)? O que se tem disponível são apenas os sinais observados  $x_1(n)$ ,  $x_2(n)$  e  $x_3(n)$ , e deseja-se encontrar uma matriz  $\mathbf{W}$  tal que se possa obter uma representação das fontes originais  $s_1(n)$ ,  $s_2(n)$  e  $s_3(n)$ .

Uma solução para este problema pode ser obtida assumindo a hipótese de independência estatística das fontes. Se elas também são não-gaussianas, é suficiente determinar os coeficientes  $w_{ij}$ , de forma que os sinais  $y_1(n)$ ,  $y_2(n)$  e  $y_3(n)$  em (4.3) sejam estatisticamente independentes entre si (Hyvärinen et al., 2001).

$$\begin{aligned}
y_1(n) &= w_{11}(n)x_1(n) + w_{12}(n)x_2(n) + w_{13}(n)x_3(n) \\
y_2(n) &= w_{21}(n)x_1(n) + w_{22}(n)x_2(n) + w_{23}(n)x_3(n) \\
y_3(n) &= w_{31}(n)x_1(n) + w_{32}(n)x_2(n) + w_{33}(n)x_3(n)
\end{aligned} \tag{4.3}$$

Se os sinais  $y_i(n)$  são estatisticamente independentes entre si, então eles são representações das fontes originais  $s_i(n)$ . (Eles podem ser multiplicados por constantes escalares, como será visto na Seção 4.3.)

Utilizando apenas esta informação da independência estatística, é possível estimar os coeficientes da matriz  $\mathbf{W}$  para os sinais da Figura 4.1. A Figura 4.2 apresenta o resultado das estimações das fontes, obtidas através do algoritmo FastICA (Hyvärinen, 1999), que será visto em detalhes na seção 4.3.

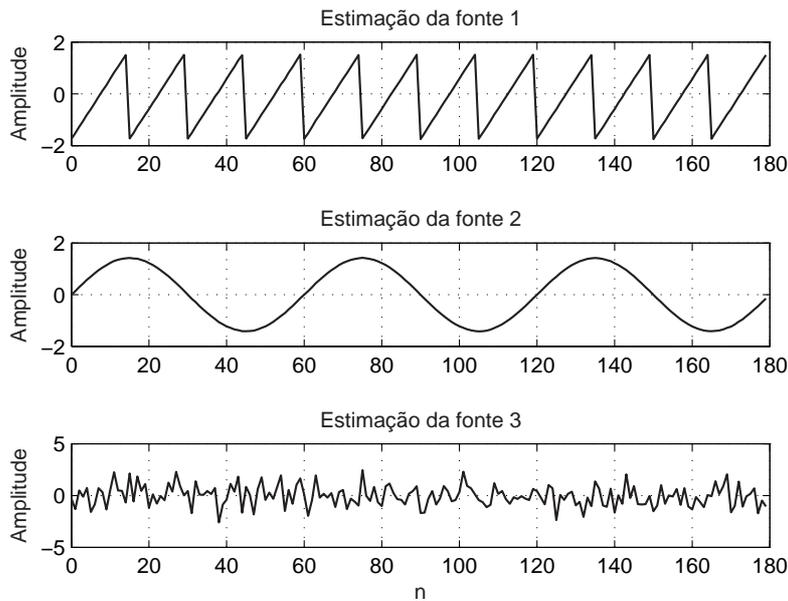


Figura 4.2: Estimções das fontes desconhecidas, utilizando apenas os sinais observados da Figura 4.1.

Observa-se da Figura 4.1 que os sinais de mistura parecem conter apenas ruídos, contudo o algoritmo FastICA foi capaz de estimar as fontes que os compõem, baseando-se apenas na informação de independência estatística das fontes. Estes

sinais estimados são praticamente iguais às fontes que foram utilizadas para criar as misturas da Figura 4.1. Assim, no problema de separação de fontes, as fontes originais são os “componentes independentes” do conjunto de dados.

## 4.2 Aplicações

A generalidade presente na formulação do problema de BSS possibilita uma vasta gama de aplicações, compreendendo desde problemas envolvendo sinais biomédicos a problemas relacionados à econometria. Será visto nesta seção algumas aplicações de destaque das técnicas de BSS em diferentes áreas.

- **Tratamento de Sinais de Voz/Áudio:** As técnicas de BSS podem servir como ferramenta para o processamento de sinais de áudio gravados em ambientes ruidosos, como o descrito pelo *Cocktail Party Problem*, no qual deseja-se extrair ou realçar algum sinal particular captado pelos sensores (Mitianoudis & Davies, 2003; Makino, Araki, Mukai, & Sawada, 2004). Pode-se considerar que esta aplicação se insere em um campo de pesquisa muito mais amplo, denominado *Computational Auditory Scene Analysis*, cujo objetivo é justamente estudar e mimetizar diferentes aspectos da habilidade de percepção auditiva humana (Arons, 1992; Ellis, 1996).

Outras aplicações incluem a transcrição musical automática (Plumbey et al., 2002), onde deve-se separar os sons provenientes de cada instrumento musical a fim de se identificar o número e tipos de instrumentos presentes no trecho processado, reconhecimento e realce de fala, entre outros.

- **Processamento de Sinais Biomédicos:** No campo de engenharia biomédica existe uma variedade de problemas nos quais se aplicam as técnicas de separação cega de fontes. Nesta área, muitas vezes, os sinais de interesse não podem ser obtidos de forma direta. A forma usual de se obter a medição é utilizar um conjunto de sensores o mais próximo possível das fontes, porém, neste caso, o sinal captado será necessariamente uma mistura dos sinais de interesse, configurando-se como um típico problema de separação de fontes.

Um exemplo clássico de aplicação é o de eletrocardiograma (ECG) fetal (Lathauwer, Moor, & Vandewalle, 2000; Chen et al., 2001), em que se pretende obter, de forma mais precisa possível, um eletrocardiograma do feto a partir de medidas feitas através de eletrodos na pele da mãe. Os sinais capturados, portanto, são misturas dos sinais provenientes do feto e da mãe, fazendo-se necessário o uso de técnicas de BSS para separá-los. Outros exemplos de aplicação envolvem a análise de eletroencefalogramas (EEG) (James & Gibson, 2003; Zhou, Zhou, Zhao, & Ju, 2005), análise de imagens obtidas por ressonância magnética funcional (fMRI) (Dodel, Hermann, & Geisel, 2000; Calhoun, Adali, Hansen, Larsen, & Pekar, 2003), etc.

- **Sistemas de Comunicações:** Em sistemas de comunicações sem fio, em especial nos sistemas de telefonia celular, pode-se ter, em uma dada frequência de operação, vários usuários transmitindo sinais para um único receptor, a estação rádio-base, de forma que o sinal resultante é uma combinação dos sinais emitidos, ponderados pelos efeitos de propagação dos canais relativos a cada um dos usuários (Cavalcante, 2004). Assim, a fim de recuperar as informações transmitidas, deve-se separar os sinais de cada um dos usuários, tarefa esta que pode ser realizada através das técnicas de BSS.

Outra possível aplicação é na equalização de canais de comunicação, onde busca-se combater o fenômeno de interferência intersimbólica. Este fenômeno, que decorre do espalhamento temporal dos pulsos transmitidos devido à limitação na largura de banda do canal (Neves, Attux, Suyama, Miranda, & Romano, 2006), ocasiona uma distorção no sinal recebido de forma que a amostra do sinal no instante  $k$  representa uma mistura dos pulsos correspondentes a diferentes instantes de tempo. Assim, equalizar o canal pode ser visto como um processo de separação de sinais (Wong, Obradovic, & Madhu, 2003; Cichocki & Amari, 2002).

## 4.3 Análise de Componentes Independentes

### 4.3.1 Definição

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

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

$$\mathbf{x} = \mathbf{A}\mathbf{s} \tag{4.4}$$

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

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

### 4.3.2 Aplicação da ICA ao problema de BSS

A ICA está intimamente relacionada ao problema da BSS. De fato, segundo (Hyvärinen et al., 2001), talvez seja o método mais utilizado para resolvê-lo. O modelo de sistema misturador mais simplificado, dado por (4.4), corresponde a (4.1), para  $M = N = 3$ . Sob a hipótese de que as fontes são estatisticamente independentes entre si, para uma matriz de mistura  $\mathbf{A}$ , os elementos de  $\mathbf{x}$  não são mais independentes. A ICA se propõe a separar as fontes a partir da recuperação da independência estatística. Assim, o sistema separador, no caso a matriz  $\mathbf{W}$ , é

ajustado de modo a gerar o vetor  $\mathbf{y}$  contendo as estimativas das fontes, de tal forma que os elementos deste vetor sejam o mais independentes possíveis entre si.

Eis que surge então uma pergunta: tornar as estimativas das fontes o mais independentes possíveis entre si implica necessariamente na sua recuperação? De acordo com (Comon, 1994), é possível separar as fontes com base na recuperação da independência estatística, desde que as fontes e o sistema misturador satisfaçam algumas restrições, como será visto adiante.

### 4.3.3 Restrições da ICA

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

1. As fontes são estatisticamente independentes entre si.
2. No máximo uma fonte apresenta distribuição *gaussiana*.
3. A matriz de mistura possui posto completo.

Como o próprio nome do algoritmo ICA diz, a primeira restrição é a independência estatística das fontes. As variáveis aleatórias  $y_1, y_2, \dots, y_N$  são ditas estatisticamente independentes se a informação do valor de  $y_i$  não fornece qualquer informação a respeito do valor de  $y_j$ , para  $i \neq j$ . Matematicamente, a independência estatística das variáveis aleatórias  $y_1, y_2, \dots, y_N$  ocorre quando a seguinte condição é estabelecida (Papoulis & Pillai, 2002):

$$p(y_1, y_2, \dots, y_N) = p_1(y_1)p_2(y_2) \dots p_N(y_N) \quad (4.5)$$

onde  $p(y_1, y_2, \dots, y_N)$  corresponde à função densidade de probabilidade conjunta das variáveis envolvidas e  $p_i(y_i)$  representa a função densidade de probabilidade marginal de  $y_i$ .

A segunda restrição com relação às fontes, é que devem possuir distribuições não-gaussianas. Como será visto na seção 4.3.7, as funções objetivo utilizadas nos algoritmos de estimação de ICA são baseadas em estatísticas de ordem superior

(HOS, *Higher Order Statistics*). Entretanto, para distribuições gaussianas, as HOS são nulas ou contém informação redundante. Também, a distribuição de probabilidade conjunta de variáveis gaussianas é rotacionalmente simétrica a uma transformação ortogonal, se os dados forem branqueados, como será visto na seção 4.3.6.1. Este é o resultado de que variáveis gaussianas descorrelacionadas são necessariamente independentes (Papoulis & Pillai, 2002). Portanto, apenas uma única variável gaussiana pode ser estimada.

A terceira restrição diz respeito à matriz de mistura. Ela requer que a matriz de mistura possua posto completo, indicando que o número de misturas observadas deve ser maior ou igual ao número de fontes, e que todas as misturas sejam linearmente independentes entre si. Há estudos de casos indeterminados, onde o número de medidas é menor que o número de fontes (T.-W. Lee, Lewicki, Girolami, & Sejnowski, 1999; Comon, 2004; Haddad, Petraglia, & Batalheiro, 2008a, 2008b).

### 4.3.4 Indeterminações da estimação pela ICA

Há duas indeterminações na estimação do modelo da ICA dado por (4.4). Estas indeterminações ocorrem devido ao fato de tanto as fontes  $\mathbf{s}$  quanto a matriz de misturas  $\mathbf{A}$  serem desconhecidas. A estimação da ICA não recupera a ordem das fontes nem seus ganhos de escala. De certo modo, essa limitação é bem intuitiva, pois a independência estatística entre os elementos de um vetor aleatório não é alterada por permutações e escalas (Papoulis & Pillai, 2002).

#### 4.3.4.1 Indeterminação dos ganhos de escala das fontes

A razão é que, sendo ambos  $\mathbf{s}$  e  $\mathbf{A}$  desconhecidos, qualquer constante escalar multiplicada por uma das fontes  $s_i$  pode sempre ser cancelada pela divisão da respectiva coluna  $\mathbf{a}_i$  de  $\mathbf{A}$  pelo mesmo escalar, digamos  $\alpha_i$  como em (4.6).

$$\mathbf{x} = \sum_i \left(\frac{1}{\alpha_i} \mathbf{a}_i\right) (s_i \alpha_i) \quad (4.6)$$

Como consequência, assume-se que os componentes independentes possuem variância unitária, ou seja,  $E\{s_i^2\} = 1$ . Então, a matriz  $\mathbf{A}$  é adaptada na solução

do algoritmo ICA para levar em conta esta restrição. Ainda assim, permanece a indeterminação no sinal, pois pode-se multiplicar um componente por -1 sem afetar o modelo. Esta indeterminação é irrelevante na maioria dos casos.

#### 4.3.4.2 Indeterminação da ordem das fontes

Novamente, como ambos  $\mathbf{s}$  e  $\mathbf{A}$  são desconhecidos, pode-se estimar os componentes independentes em qualquer ordem. Formalmente, uma matriz de permutação  $\mathbf{P}$  e sua inversa podem ser multiplicadas em (4.4), ou seja,  $\mathbf{x} = \mathbf{AP}^{-1}\mathbf{Ps}$ . Os elementos de  $\mathbf{Ps}$  são os componentes independentes originais, porém, em outra ordem. A matriz  $\mathbf{AP}^{-1}$  é uma outra matriz de mistura que será encontrada pelo algoritmo de ICA.

#### 4.3.5 Aplicações de técnicas baseadas em estatísticas de segunda ordem à ICA

Foi visto na Seção 4.3.2 que o problema BSS/ICA pode ser resolvido baseado na independência estatística das fontes, ou seja, através de HOS, já que a independência é caracterizada pelo conhecimento das densidades de probabilidade, e, conseqüentemente, de todas as estatísticas de uma variável aleatória. Portanto, as estatísticas de segunda ordem não são suficientes para resolver o problema por completo. Entretanto, será visto que estas estatísticas podem contribuir significativamente como etapa de pré-processamento na resolução dos algoritmos de ICA. Uma consagrada técnica baseada em estatísticas de segunda ordem, e muito utilizada no pré-processamento da ICA, é a Análise de Componentes Principais (PCA, *Principal Component Analysis*).

##### 4.3.5.1 Análise de Componentes Principais

A PCA (Jolliffe, 2002; Hyvärinen et al., 2001), conhecida também como transformada discreta de Karhunen-Loève ou transformada de Hotelling, é uma técnica clássica em análise estatística de dados, extração de parâmetros e compressão de dados. A PCA emprega a correlação como medida de redundância entre os

componentes, diferentemente da ICA, que emprega a independência estatística para realizar esta tarefa. Utilizando apenas correlação, a PCA pode ser calculada através de estatísticas de segunda ordem. Sendo assim, a PCA é uma medida “mais fraca” de informação se comparada à ICA, não sendo suficiente para explorar toda a redundância entre variáveis aleatórias. Entretanto, ela desempenha uma importante etapa de pré-processamento no cálculo da ICA, reduzindo o número de parâmetros a serem estimados.

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

$$\mathbf{x} \leftarrow \mathbf{x} - E\{\mathbf{x}\}. \quad (4.7)$$

Na prática, a média é estimada a partir das amostras temporais  $\mathbf{x}(1) \dots \mathbf{x}(T)$ . Em seguida, a PCA realiza uma transformação linear que, aplicada ao vetor  $\mathbf{x}$ , resulta em um vetor aleatório  $\mathbf{y} = [y_1 \dots y_N]^T$  ( $N < M$ ), cujos elementos, denominados componentes principais, são descorrelacionados entre si. Portanto, a redundância promovida pela correlação é removida pela PCA, tornando possível a compressão de  $\mathbf{x}$ . Ao mesmo tempo, as variâncias das projeções dos elementos de  $\mathbf{x}$  em  $\mathbf{y}$  são maximizadas, de tal forma que o primeiro eixo corresponde à máxima variância, o segundo eixo corresponde à máxima variância na direção ortogonal ao primeiro eixo, e assim por diante. A variância está relacionada à quantidade de informação que o componente pode oferecer. Sendo assim, o primeiro componente principal de  $\mathbf{y}$  concentra maior quantidade de informação a respeito de  $\mathbf{x}$ , o segundo componente principal concentra maior quantidade de informação na direção ortogonal ao primeiro, e assim por diante.

Em termos matemáticos, considere uma combinação linear

$$y_1 = \sum_{k=1}^n w_{k1} x_k = \mathbf{w}_1^T \mathbf{x}$$

dos elementos  $x_1 \dots x_n$  do vetor  $\mathbf{x}$ . Os termos  $w_{11} \dots w_{n1}$  são pesos escalares, elementos do vetor  $\mathbf{w}_1$ .

O termo  $y_1$  é o primeiro componente principal de  $\mathbf{x}$ , se a variância de  $y_1$  é maximizada. Devido ao fato da variância depender da norma e da orientação do vetor de pesos  $\mathbf{w}_1$ , impõe-se a restrição de que a norma de  $\mathbf{w}_1$  seja constante, normalmente igual a 1. Assim, a PCA procura pelo vetor de pesos  $\mathbf{w}_1$  que maximiza a variância de  $y_1$ :

$$J_1^{PCA}(\mathbf{w}_1) = E\{y_1^2\} = E\{(\mathbf{w}_1^T \mathbf{x})^2\} = \mathbf{w}_1^T E\{\mathbf{x}\mathbf{x}^T\} \mathbf{w}_1 = \mathbf{w}_1^T \mathbf{C}_x \mathbf{w}_1 \quad (4.8)$$

onde  $\|\mathbf{w}_1\| = 1$ .

A matriz  $\mathbf{C}_x$  em (4.8) é a matriz de covariância de  $\mathbf{x}$ , de dimensão  $n \times n$ . Sendo que  $\mathbf{x}$  possui média zero, então:

$$\mathbf{R}_x = E\{\mathbf{x}\mathbf{x}^T\} \quad (4.9)$$

é a matriz de correlação do vetor aleatório  $\mathbf{x}$ .

A solução da PCA é encontrada em termo dos autovetores  $\mathbf{e}_1 \dots \mathbf{e}_n$  da matriz  $\mathbf{R}_x$  (Diamantaras & Kung, 1996). A ordem dos autovetores é tal que seus respectivos autovalores  $d_1 \dots d_n$  satisfazem a relação  $d_1 \geq d_2 \geq \dots d_n$ . A solução que maximiza (4.8) é dada por:

$$\mathbf{w}_1 = \mathbf{e}_1. \quad (4.10)$$

Sendo assim, o primeiro componente principal de  $\mathbf{x}$  é  $y_1 = \mathbf{e}_1^T \mathbf{x}$ .

Para encontrar o segundo componente principal, procura-se pela máxima variância  $E\{y_2^2\} = E\{(\mathbf{w}_2^T \mathbf{x})^2\}$  no sub-espaço ortogonal ao primeiro autovetor de  $\mathbf{R}_x$ . A solução é então dada por:

$$\mathbf{w}_2 = \mathbf{e}_2$$

.

Para encontrar o  $k$ -ésimo componente principal, a solução é dada por:

$$\mathbf{w}_k = \mathbf{e}_k. \quad (4.11)$$

Assim, o  $k$ -ésimo componente principal é  $y_k = \mathbf{e}_k^T \mathbf{x}$ .

A PCA é muito útil para reduzir a dimensão dos dados na situação em que  $M > N$ , ou seja, em que o número de misturas é maior que o número de fontes. Isto é feito descartando os autovalores muito pequenos da matriz  $\mathbf{R}_x$ .

A solução analítica do problema de PCA baseada na decomposição de autovalores e autovetores da matriz de correlação de  $\mathbf{x}$  pode não ser viável em aplicações que exigem processamento em tempo real. Entretanto, há outras técnicas de solução do problema de PCA, que podem ser encontradas em (Hyvärinen et al., 2001).

#### 4.3.5.2 Branqueamento

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

O branqueamento é uma transformação linear do vetor observado  $\mathbf{x}$ , que produz um novo vetor  $\mathbf{z}$  que é branco, isto é, seus componentes são descorrelacionados e com variância igual a 1. Em outras palavras, a matriz de covariância de  $\mathbf{z}$  é igual à matriz identidade:

$$E\{\mathbf{z}\mathbf{z}^T\} = \mathbf{I}. \quad (4.12)$$

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

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

$$\mathbf{z} = \mathbf{V}\mathbf{x}. \quad (4.13)$$

Seja  $\mathbf{E} = (\mathbf{e}_1 \dots \mathbf{e}_n)$  uma matriz cujas colunas são os autovetores de norma unitária da matriz de covariância  $\mathbf{C}_x = E\{\mathbf{x}\mathbf{x}^T\}$  e  $\mathbf{D} = \text{diag}(d_1 \dots d_n)$  uma matriz diagonal contendo os autovalores de  $\mathbf{C}_x$ . Então uma matriz de branqueamento é dada por (Hyvärinen & Oja, 2000):

$$\mathbf{V} = \mathbf{E}\mathbf{D}^{-1/2}\mathbf{E}^T \quad (4.14)$$

A partir de (4.4), (4.13) e (4.14), pode-se escrever:

$$\mathbf{z} = \mathbf{V}\mathbf{x} = \mathbf{E}\mathbf{D}^{-1/2}\mathbf{E}^T\mathbf{A}\mathbf{s} = \tilde{\mathbf{A}}\mathbf{s}. \quad (4.15)$$

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

$$E\{\mathbf{z}\mathbf{z}^T\} = \tilde{\mathbf{A}}E\{\mathbf{s}\mathbf{s}^T\}\tilde{\mathbf{A}}^T = \tilde{\mathbf{A}}\tilde{\mathbf{A}}^T = \mathbf{I}. \quad (4.16)$$

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

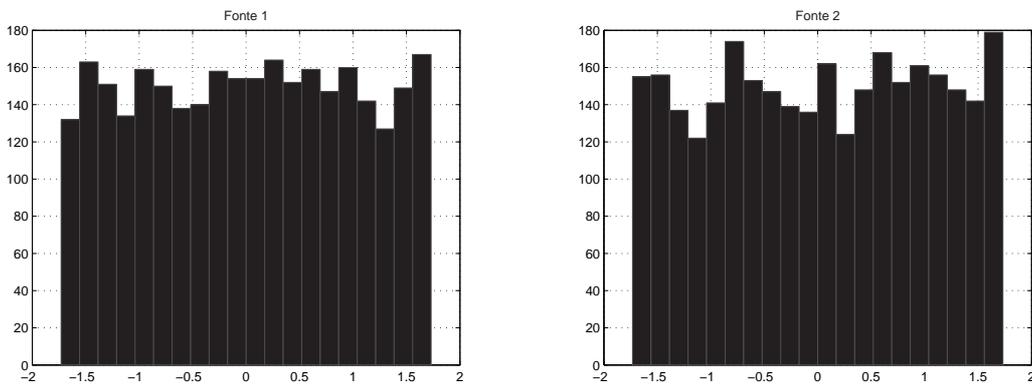
### 4.3.6 Um simples exemplo de ilustração da ICA

Para ilustrar a ICA em termos estatísticos, considere a simulação de dois componentes independentes que possuem a seguinte distribuição uniforme:

$$p(s_i) = \begin{cases} \frac{1}{2\sqrt{3}}, & \text{se } |s_i| \leq \sqrt{3} \\ 0, & \text{caso contrário} \end{cases} \quad (4.17)$$

Conforme observa-se em (4.17), as variáveis aleatórias  $s_1$  e  $s_2$  possuem ambas média zero e variância unitária. A Figura 4.3 mostra os histogramas de  $s_1$  e  $s_2$ . A distribuição de probabilidade conjunta do vetor aleatório  $\mathbf{s} = [s_1 \ s_2]^T$  é

mostrada na Figura 4.4. A distribuição conjunta de  $s_1$  e  $s_2$  é uniforme, formando um quadrado. Isto é resultado da definição de independência estatística dada por (4.5): a distribuição conjunta de duas variáveis independentes é igual ao produto de suas distribuições marginais. Os componentes  $s_1$  e  $s_2$  não contém nenhuma informação em comum. Claramente observa-se que o conhecimento de  $s_1$  não fornece nenhuma informação a respeito de  $s_2$ , e vice-versa.



(a) Histograma de  $s_1$ .

(b) Histograma de  $s_2$ .

Figura 4.3: Histogramas das fontes.

Agora serão misturados estes dois componentes independentes utilizando o modelo dado por (4.4).

Será utilizada a matriz de mistura  $\mathbf{A} = \begin{bmatrix} 5 & 10 \\ 10 & 2 \end{bmatrix}$ . Então, o modelo de mistura dado por (4.4) se torna:

$$\begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 5 & 10 \\ 10 & 2 \end{bmatrix} \begin{bmatrix} s_1 \\ s_2 \end{bmatrix} \quad (4.18)$$

A Figura 4.5 mostra os histogramas das misturas  $x_1$  e  $x_2$  obtidas. Pode-se ver que as distribuições das misturas são mais próximas da distribuição gaussiana do que as distribuições uniformes das fontes  $s_1$  e  $s_2$ . Este fato é explicado pelo Teorema do Limite Central (Papoulis & Pillai, 2002), que, em linhas gerais, estabelece que o resultado da soma de um conjunto de variáveis aleatórias resulta em uma variável

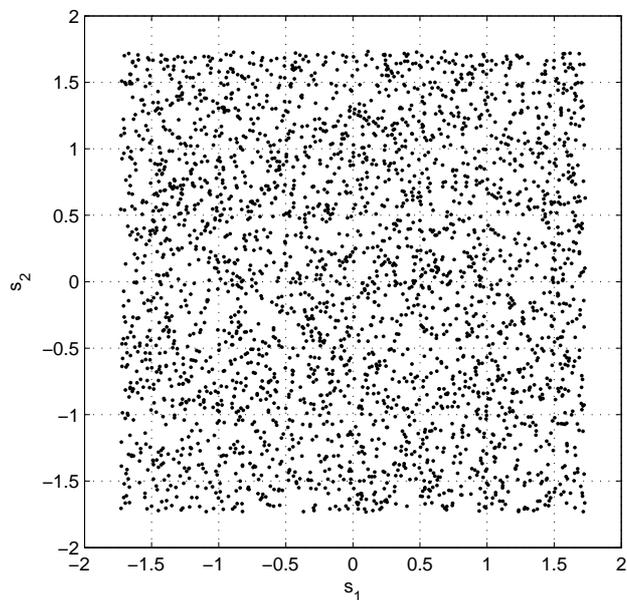
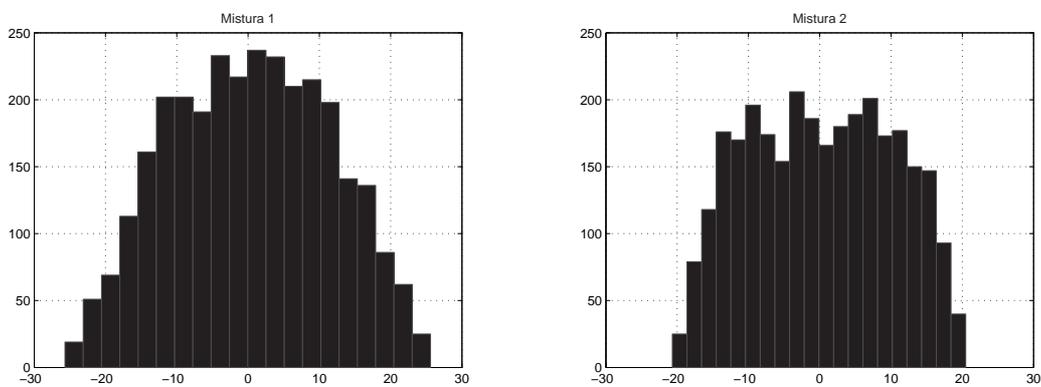


Figura 4.4: Distribuição de probabilidade conjunta de  $s$ .



(a) Histograma de  $x_1$ .

(b) Histograma de  $x_2$ .

Figura 4.5: Histogramas das misturas.

mais próxima de uma gaussiana do que qualquer uma pertencente a este grupo. Portanto, sob a ótica deste teorema, é de se esperar que as misturas sejam mais próximas a gaussianas se comparadas com as fontes.

A distribuição conjunta das misturas é mostrada na Figura 4.6. As variáveis

aleatórias  $x_1$  e  $x_2$  não são independentes, pois para um dado valor de  $x_1$ , é possível prever o valor de  $x_2$ , e vice-versa. Se  $x_1$  alcança um de seus valores máximo ou mínimo, então isto determina o valor de  $x_2$ . Para as variáveis  $s_1$  e  $s_2$ , a situação é diferente: da Figura 4.4 pode ser visto que o conhecimento de um dado valor de  $s_1$  não ajuda a encontrar o valor de  $s_2$ .

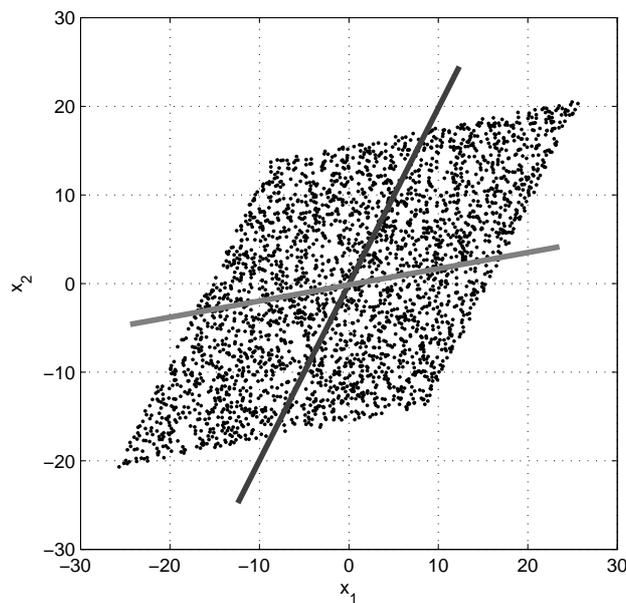


Figura 4.6: Distribuição de probabilidade conjunta de  $\mathbf{x}$ .

A ICA busca estimar a matriz de mistura  $\mathbf{A}$ , tendo disponível apenas  $\mathbf{x}$ , tal que maximize a independência entre as estimações das fontes. De fato, da Figura 4.6, pode-se observar uma maneira intuitiva de estimar  $\mathbf{A}$ : as *bordas* do paralelogramo estão nas direções das colunas de  $\mathbf{A}$ , como é mostrado através das retas na figura. A reta mais escura está na direção da primeira coluna de  $\mathbf{A}$ , enquanto que a reta mais clara está na direção da segunda coluna. Isto significa que, a princípio, pode-se estimar o modelo ICA primeiro calculando a distribuição conjunta de  $x_1$  e  $x_2$  e depois localizando suas bordas.

Na prática, entretanto, este método de localização de bordas não é viável, funcionando apenas para variáveis que possuem distribuições muito especiais, e quando o número de fontes é muito pequeno. Para a maioria das distribuições,

tais bordas não podem ser encontradas facilmente.

A ICA utiliza as seguintes etapas de pré-processamento às misturas: remoção de média e branqueamento. Portanto os sinais obtidos possuem média zero, variância unitária e são descorrelacionados. Estas etapas não são suficientes para resolver o problema da ICA, mas reduzem a sua complexidade.

Remove-se a média das misturas através de (4.7) e, em seguida, realiza-se o branqueamento através de (4.15). A distribuição conjunta das misturas branqueadas  $z_1$  e  $z_2$  é mostrada na Figura 4.7.

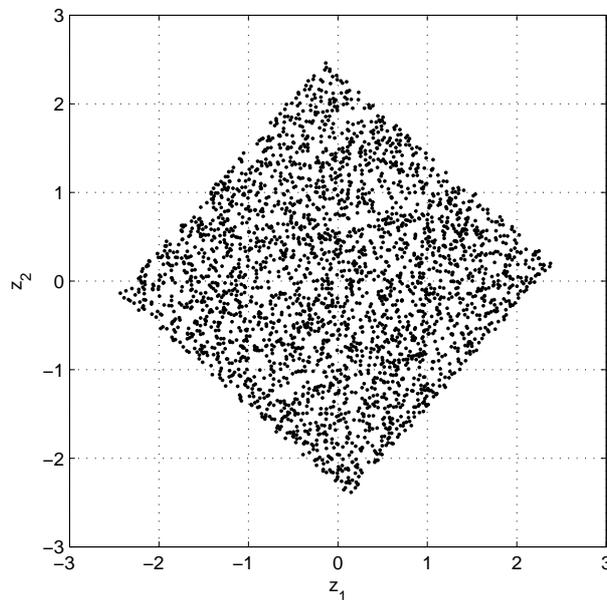


Figura 4.7: Distribuição de probabilidade conjunta de  $\mathbf{z}$ .

Pode-se observar que a distribuição conjunta das misturas branqueadas é uma versão rotacionada da distribuição conjunta das fontes da Figura 4.4. Conforme discutido no final da Seção 4.3.5.2, o branqueamento reduz o número de parâmetros a serem estimados pela ICA de  $n^2$  para  $n(n-1)/2$ . Portanto, ao invés da ICA ter que estimar os 4 elementos da matriz  $\mathbf{A}$ , ela tem agora que estimar apenas o ângulo que recupera a rotação das fontes.

#### 4.3.6.1 Por que variáveis gaussianas são proibidas?

A função densidade de probabilidade (FDP) de uma variável aleatória  $s$  com distribuição gaussiana de média  $m_s$  e variância  $\sigma_s$  é dada por:

$$p(s) = \frac{1}{\sqrt{2\pi\sigma_s^2}} \exp\left(-\frac{(s - m_s)^2}{2\sigma_s^2}\right). \quad (4.19)$$

Sejam  $s_1$  e  $s_2$  duas variáveis aleatórias independentes com distribuição gaussiana de média nula e variância unitária. A FDP conjunta  $p(s_1, s_2)$  tem a seguinte expressão:

$$p(s_1, s_2) = p(s_1)p(s_2) = \frac{1}{2\pi} \exp\left(-\frac{s_1^2 + s_2^2}{2}\right) = \frac{1}{2\pi} \exp\left(-\frac{\|\mathbf{s}\|^2}{2}\right). \quad (4.20)$$

A Figura 4.8 mostra a distribuição conjunta de duas variáveis gaussianas independentes  $s_1$  e  $s_2$  de média nula e variância unitária. Nota-se que a distribuição é simétrica.

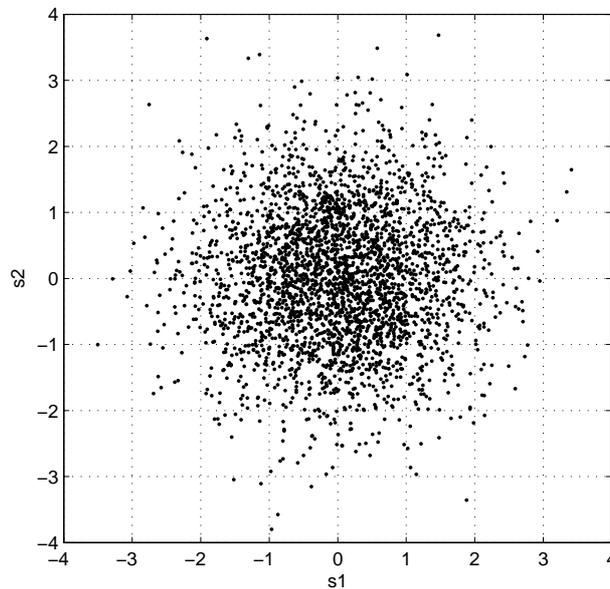


Figura 4.8: Distribuição de probabilidade conjunta de duas fontes gaussianas independentes.

Sobre  $s_1$  e  $s_2$  aplica-se o modelo de (4.4), utilizando-se a matriz de mistura ortogonal<sup>1</sup>

$$\mathbf{A} = \begin{bmatrix} \frac{\sqrt{2}}{2} & \frac{\sqrt{2}}{2} \\ \frac{\sqrt{2}}{2} & -\frac{\sqrt{2}}{2} \end{bmatrix}$$

As misturas  $x_1$  e  $x_2$  têm distribuição gaussiana, já que resultam da combinação linear de duas variáveis aleatórias com distribuição gaussiana (Papoulis & Pillai, 2002). Verifica-se que a FDP conjunta das misturas também é simétrica, ou seja, elas são estatisticamente independentes. Passa-se a demonstrar que, nestas condições, as misturas têm exatamente a mesma distribuição das fontes. Dado que  $\mathbf{x} = \mathbf{A}\mathbf{s}$ , utilizando a fórmula de transformação de FDP (Papoulis & Pillai, 2002) e assumindo que a matriz  $\mathbf{A}$  é ortogonal (essa suposição não invalida a dedução, uma vez que, como exposto na Seção 4.3.5.2, o branqueamento pode ser realizado previamente sem prejuízos ao método):

$$p(x_1, x_2) = \frac{1}{|\det(\mathbf{A})|} p_s(\mathbf{A}^{-1}\mathbf{x}) = p_s(\mathbf{A}^T\mathbf{x}). \quad (4.21)$$

Devido à ortogonalidade de  $\mathbf{A}$ , tem-se que  $\|\mathbf{A}^T\mathbf{x}\|^2 = \|\mathbf{x}\|^2$ , porque as transformadas ortogonais preservam a norma do vetor, dado que aplicam rotação sobre o mesmo (Hyvärinen et al., 2001). Portanto:

$$p_s(\mathbf{A}^T\mathbf{x}) = \frac{1}{2\pi} \exp\left(-\frac{\|\mathbf{A}^T\mathbf{x}\|^2}{2}\right) = \frac{1}{2\pi} \exp\left(-\frac{\|\mathbf{x}\|^2}{2}\right) = \frac{1}{2\pi} \exp\left(-\frac{x_1^2 + x_2^2}{2}\right), \quad (4.22)$$

concluindo-se que  $x_1$  e  $x_2$  têm a mesma distribuição de  $s_1$  e  $s_2$ , apresentada em (4.20). A matriz de mistura ortogonal não altera a FDP das misturas, em relação à FDP das fontes. Nesta situação, é impossível estimar a matriz de mistura  $\mathbf{A}$  através da ICA, porque as misturas não contém informação sobre a mesma. Sendo que sem a estimação da matriz de mistura, é impossível estimar as fontes  $s_1$  e  $s_2$ .

No caso em que alguns componentes independentes possuem distribuição gaussiana e outros não, é possível estimar todos aqueles que *não* têm distribuição gaussiana. Contudo, os componentes independentes com distribuição gaussiana

---

<sup>1</sup>A matriz quadrada  $\mathbf{A}$  se diz ortogonal se  $\mathbf{A}\mathbf{A}^T = \mathbf{I}$ , ou seja,  $\mathbf{A}^T = \mathbf{A}^{-1}$ .

não podem ser separados, obtendo-se simplesmente combinações lineares arbitrárias dos mesmos. Quando apenas um componente tem distribuição gaussiana, ainda é possível realizar a separação (Hyvärinen et al., 2001).

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

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

O processo de mistura e separação da ICA é mostrado na Figura 4.9. O branqueamento é utilizado como pré-processamento das misturas observadas. Os algoritmos de ICA funcionam sem esta etapa, mas ela simplifica a estimação e por isso é empregada na maioria dos casos. A estimação da matriz de separação  $\mathbf{W}$  é um processo iterativo baseado na otimização de uma função objetivo.

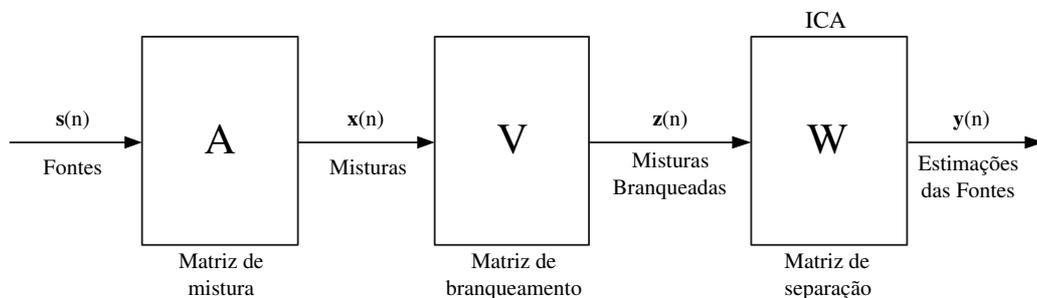


Figura 4.9: Processo de mistura e separação da ICA.

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

### 4.3.7.1 Informação mútua

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

$$I(y_1, y_2, \dots, y_N) = \sum_{i=1}^N H(y_i) - H(\mathbf{y}). \quad (4.23)$$

Em (4.23),  $H(y_i)$  é a entropia marginal de  $y_i$  e  $H(\mathbf{y})$  é a entropia conjunta do vetor  $\mathbf{y}$  incluindo todas as variáveis  $y_i$ .  $H(y_i)$  e  $H(\mathbf{y})$  são definidos como:

$$\begin{aligned} H(y_i) &= - \int p_{y_i}(y_i) \log p_{y_i}(y_i) dy_i, \\ H(\mathbf{y}) &= - \int p_{\mathbf{y}}(\mathbf{y}) \log p_{\mathbf{y}}(\mathbf{y}) d\mathbf{y}. \end{aligned} \quad (4.24)$$

A entropia<sup>2</sup> de uma variável aleatória fornece uma idéia da incerteza sobre o valor que esta variável assume (Cavalcante, 2004). Pode-se mostrar que a distribuição gaussiana apresenta a maior entropia dentre as distribuições com mesma variância.

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

$$D(f(\mathbf{r}), g(\mathbf{r})) = \int f(\mathbf{r}) \log \frac{f(\mathbf{r})}{g(\mathbf{r})} d\mathbf{r}. \quad (4.25)$$

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

$$D(p_{\mathbf{y}}(\mathbf{y}), p_{y_1}(y_1)p_{y_2}(y_2) \dots p_{y_N}(y_N)) = \int p_{\mathbf{y}}(\mathbf{y}) \log \frac{p_{\mathbf{y}}(\mathbf{y})}{p_{y_1}(y_1)p_{y_2}(y_2) \dots p_{y_N}(y_N)} d\mathbf{y}. \quad (4.26)$$

---

<sup>2</sup>A quantidade  $H(y)$  também pode ser definida para variáveis discretas. Neste caso,  $H(y) = -\sum_i p_i \log p_i$ , e apresenta propriedades semelhantes à entropia para variáveis contínuas.

Esta medida sempre assume valores não-negativos e é igual a zero se e somente se as duas funções em questão forem iguais. A partir de (4.5), esta condição ocorre quando os elementos de  $\mathbf{y}$  forem independentes.

Após um simples desenvolvimento, pode-se constatar que (4.26) é equivalente a (4.23), ou seja:

$$I(y_1, y_2, \dots, y_N) = \int p_{\mathbf{y}}(\mathbf{y}) \log \frac{p_{\mathbf{y}}(\mathbf{y})}{p_{y_1}(y_1)p_{y_2}(y_2) \dots p_{y_N}(y_N)} d\mathbf{y}. \quad (4.27)$$

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

#### 4.3.7.2 Princípio Infomax e a abordagem de Máxima Verossimilhança

Considere a estrutura apresentada na Figura 4.10, que representa uma rede neural artificial. O bloco  $\mathbf{g}(\cdot)$  aplica uma não-linearidade a cada saída  $y_i$ , ou seja:

$$\mathbf{g}(\mathbf{y}) = [g_1(y_1) \quad g_2(y_2) \quad \dots \quad g_N(y_N)]^T, \quad (4.28)$$

onde  $g_i(\cdot)$  são funções não-lineares monotonicamente crescentes, com  $g_i(-\infty) = 0$  e  $g_i(\infty) = 1$ .

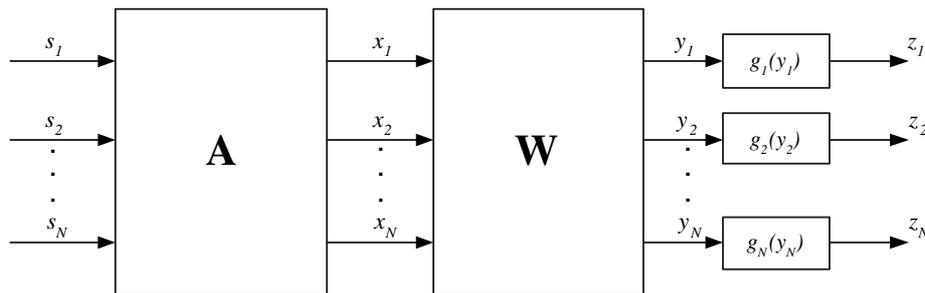


Figura 4.10: Estrutura de uma rede neural artificial.

Segundo o princípio *Infomax* (*Information Maximization*) (Bell & Sejnowski, 1995), os coeficientes da rede neural devem ser ajustados de forma a maximizar

a transferência de informação entre suas entradas e saídas, ou seja, corresponde a adaptar a matriz  $\mathbf{W}$  a fim de maximizar a informação mútua entre  $\mathbf{x}$  e  $\mathbf{z}$ .

Na ausência de ruído, a abordagem *Infomax* equivale à maximização da entropia da saída. Isto ocorre porque na ausência de ruído o mapeamento entre  $\mathbf{x}$  e  $\mathbf{z}$  torna-se determinístico, e nesta condição a entropia condicional  $H(\mathbf{z}|\mathbf{x})$  não dependerá dos parâmetros da rede (Bell & Sejnowski, 1995).

Reescrevendo (4.23), isolando a entropia conjunta para as saídas da rede neural, obtém-se:

$$H(\mathbf{z}) = \sum_{i=1}^N H(z_i) - I(\mathbf{z}), \quad (4.29)$$

onde pode-se observar que a maximização da entropia conjunta corresponde tanto à maximização das entropias marginais quanto à minimização da informação mútua entre os elementos de  $\mathbf{z}$ . Portanto, a maximização da transferência de informação tenderá, em geral, a reduzir a dependência estatística entre as saídas da rede neural e, conseqüentemente, dos elementos do vetor  $\mathbf{y}$ .

As não-linearidades  $g_i(\cdot)$  são importantes tanto para limitar o valor das variáveis  $z_i$  quanto para tornar as variáveis de saída da rede independentes. Portanto, devem ser escolhidas adequadamente, relacionando-se aos tipos de fontes presentes na mistura.

Dada a estrutura da Figura 4.10, pode-se verificar que:

$$H(\mathbf{z}) = H(\mathbf{x}) + E \left\{ \sum_{i=1}^N \log(g'_i(\mathbf{w}_i \mathbf{x})) \right\} + \log(| \det(\mathbf{W}) |), \quad (4.30)$$

onde  $g'_i$  representa a derivada da função  $g_i$  e  $\mathbf{w}_i$  a  $i$ -ésima linha da matriz de separação  $\mathbf{W}$ . Como a entropia conjunta de  $\mathbf{x}$  não depende da matriz de separação, ela não interfere no processo de adaptação e, portanto, a aplicação do princípio Infomax no problema de estimação da ICA resulta em maximizar a seguinte função objetivo:

$$J_{Infomax}(\mathbf{W}) = E \left\{ \sum_{i=1}^N \log(g'_i(\mathbf{w}_i \mathbf{x})) \right\} + \log(| \det(\mathbf{W}) |). \quad (4.31)$$

## Máxima Verossimilhança

Apesar de ser desenvolvida a partir de um princípio diferente, a abordagem de máxima verossimilhança possui uma estreita relação com o princípio Infomax (J. F. Cardoso, 1997; J.-F. Cardoso, 1998a). No contexto de BSS, a função de verossimilhança logarítmica assume a seguinte forma:

$$J_{Verossimilhança}(\mathbf{W}) \propto E \left\{ \sum_{i=1}^N \log(p_{s_i}(\mathbf{w}_i \mathbf{x})) \right\} + \log(| \det(\mathbf{W}) |) \quad (4.32)$$

Através da comparação entre (4.31) e (4.32), observa-se que a abordagem de máxima verossimilhança e o princípio Infomax possuem quase a mesma função objetivo, diferenciando apenas as funções não-lineares utilizadas.

### 4.3.7.3 Maximização da não-gaussianidade

A idéia principal deste critério é o ajuste do sistema separador de modo que as densidades de probabilidade da cada uma das estimativas das fontes sejam, em algum sentido, as mais distantes possível de uma variável gaussiana. Portanto, a estratégia consiste em adaptar a matriz de separação de forma a maximizar a não-gaussianidade dos sinais estimados. Embora não seja evidente, o princípio leva à estimação de sinais independentes entre si, mostrando-se um método apropriado para a ICA. Um dos principais benefícios desta estratégia é a possibilidade de recuperação individual das fontes. Um dos algoritmos mais conhecidos para resolução da ICA é o FastICA (Hyvärinen, 1999; Hyvärinen et al., 2001), que foi desenvolvido com base neste critério.

A chave da idéia presente na abordagem via maximização da não-gaussianidade está associada ao Teorema do Limite Central (Papoulis & Pillai, 2002), rapidamente descrito na Seção 4.3.6. Em linhas gerais, o teorema estabelece que o resultado da soma de um conjunto de variáveis aleatórias resulta em uma variável mais próxima de uma gaussiana do que qualquer uma pertencente a este conjunto. Portanto, baseado neste teorema, as misturas são mais gaussianas do que qualquer uma das

fontes. Este fato pode ser evidenciado pela comparação entre os histogramas das fontes e das misturas, respectivamente mostrados nas Figuras 4.3 e 4.5.

Logo, uma tentativa de ajustar  $\mathbf{W}$  fundamenta-se justamente na recuperação da não-gaussianidade das estimativas das fontes. No modelo de (4.4), suponha que esteja-se interessado em recuperar apenas uma das fontes e, para isto, utiliza-se um vetor de separação  $\mathbf{w}_1$ :

$$y_1 = \mathbf{w}_1^T \mathbf{x} = \mathbf{q}^T \mathbf{s} = \sum_{i=1}^N q_i s_i, \quad (4.33)$$

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

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

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

$$\kappa_4(y) = E \{y^4\} - 3 [E \{y^2\}]^2. \quad (4.34)$$

Uma interessante propriedade da *kurtosis* é que esta medida é não-nula para a grande maioria das variáveis aleatórias, sendo a gaussiana uma das poucas exceções desta regra. De fato, é usual classificar as distribuições com relação aos valores de suas *kurtosis*: caso  $\kappa_4(y) = 0$ , diz-se que  $y$  possui distribuição *gaussiana*; caso  $\kappa_4(y) < 0$ , diz-se que  $y$  possui distribuição *sub-gaussiana*; caso  $\kappa_4(y) > 0$ , diz-se

que  $y$  possui distribuição *super-gaussiana*. Deste modo, um critério para maximizar a não-gaussianidade pode ser obtido através da maximização do valor absoluto da *kurtosis* do sinal estimado, ou seja:

$$\max_{\mathbf{w}} |\kappa_4(y_i)|, \quad (4.35)$$

tendo como principal atrativo sua simplicidade. A *kurtosis* apresenta duas importantes propriedades úteis na derivação dos algoritmos de ICA:

$$\begin{aligned} \kappa_4(y_1 + y_2) &= \kappa_4(y_1) + \kappa_4(y_2), \\ \kappa_4(\alpha y_1) &= \alpha^4 \kappa_4(y_1). \end{aligned} \quad (4.36)$$

Há uma outra opção de medida de não-gaussianidade chamada *negentropia*, que é baseada na teoria da informação. Um dos principais resultados desta área afirma que, no conjunto de todas as variáveis aleatórias de mesma variância, a variável gaussiana é aquela que possui a maior entropia (Cover & Thomas, 1991). Logo, uma possível estratégia de maximização da não-gaussianidade seria buscar a minimização das entropias marginais das estimativas das fontes.

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

$$J_{Negentropia}(y) = H(y_{gauss}) - H(y), \quad (4.37)$$

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

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

A *negentropia* é uma medida eficiente da não-gaussianidade. Entretanto, ela é difícil de ser calculada porque requer uma estimativa da função densidade de probabilidade. Sendo assim, aproximações mais simples da *negentropia* se tornam necessárias (Hyvärinen, 1999).

A *negentropia* pode ser aproximada por meio de cumulantes de ordem superior:

$$J_{Negentropia}(y) \cong \frac{1}{12}\kappa_3^2(y) + \frac{1}{48}\kappa_4^2(y), \quad (4.38)$$

onde  $\kappa_3$  e  $\kappa_4$  são, respectivamente, os cumulantes de terceira e quarta ordem de uma variável aleatória  $y$  com média nula e variância unitária. A partir destas aproximações obtém-se meios simples para estimação da *negentropia*, sem a necessidade de se efetuar a integração de funções, conforme a definição de entropia de (4.24).

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

$$J(y) = \alpha (E\{G(y)\} - E\{G(v)\})^2, \quad (4.39)$$

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

### 4.3.8 Algoritmos para resolução da ICA

Uma vez definidas as principais funções objetivo a serem utilizadas, se fazem necessários métodos práticos para implementá-las e assim desenvolver as estruturas de otimização dos algoritmos de resolução da ICA. Nesta seção, serão vistos alguns destes algoritmos, baseados nas idéias expostas anteriormente.

#### 4.3.8.1 Algoritmo Infomax e Infomax estendido

Uma maneira de se obter uma matriz de separação  $\mathbf{W}$  que maximize (4.31) é realizar a busca a partir do método do gradiente descendente. Nesta situação, é possível mostrar (Hyvärinen et al., 2001) que o gradiente da entropia conjunta das saídas em relação à  $\mathbf{W}$  é dado por:

$$\frac{\partial H(\mathbf{z})}{\partial \mathbf{W}} = E\{\mathbf{G}(\mathbf{W}\mathbf{x})\mathbf{x}^T\} + (\mathbf{W}^T)^{-1}, \quad (4.40)$$

onde  $\mathbf{G}(\cdot) = [G_1(\cdot) \dots G_N(\cdot)]$  é um vetor de funções de modo que  $G_i(y) = \frac{d \log(g'_i(y))}{dy}$ . Diante disso, obtém-se a seguinte regra de atualização para o ajuste de  $\mathbf{W}$ :

$$\mathbf{W} \leftarrow \mathbf{W} + \mu \{E\{\mathbf{G}(\mathbf{W}\mathbf{x})\mathbf{x}^T\} + (\mathbf{W}^T)^{-1}\}, \quad (4.41)$$

onde  $\mu$  corresponde ao passo de adaptação. Esta regra de atualização é conhecida como algoritmo Infomax, ou ainda algoritmo Bell-Sejnowski (BS), e sua versão estocástica (adaptativa) pode ser obtida desconsiderando o operador de esperança matemática presente nesta equação.

Na sua forma original, o algoritmo Infomax considera uma não-linearidade fixa, de maneira que os cenários nos quais o algoritmo é capaz de separar os sinais fica restrito a alguns tipos particulares de fontes. A influência da escolha destas não-linearidades é assunto de alguns artigos encontrados na literatura (Amari, Chen, & Cichocki, 1997; J.-F. Cardoso, 1998b). No entanto, argumenta-se que, em geral, é possível obter bons resultados selecionando-se apenas algumas funções.

Esta idéia foi ponto de partida para uma das modificações do algoritmo Infomax, apresentada em (T. W. Lee, Girolami, & Sejnowski, 1999). No trabalho, introduziu-se um parâmetro adicional para determinar qual o tipo de não-linearidade deve ser utilizada. Empregando apenas duas não-linearidades:  $G(y) = y - \tanh(y)$ , para fontes sub-gaussianas, e  $G(y) = y + \tanh(y)$ , para fontes super-gaussianas, é possível obter o algoritmo denominado *Infomax Estendido*, capaz de trabalhar em cenários com fontes de diferentes classes. Com isso, a atualização da matriz  $\mathbf{W}$ , considerando um ajuste baseado no gradiente natural (Hyvärinen et al., 2001), é reescrita como:

$$\mathbf{W} \leftarrow \mathbf{W} + \mu(\mathbf{I} - E\{\mathbf{M} \tanh(\mathbf{y})\mathbf{y}^T - \mathbf{y}\mathbf{y}\}), \quad (4.42)$$

onde  $\mathbf{M} = \text{diag}(m_1, \dots, m_N)$  é uma matriz diagonal tal que, idealmente,  $m_i = 1$  para fontes super-gaussianas e  $m_i = -1$  para fontes sub-gaussianas. A adaptação dos parâmetros  $m_i$  é realizada através da seguinte equação:

$$m_i = \text{sign}(E\{\text{sech}^2(y_i)\}E\{y_i^2\} - E\{\tanh(y_i)y_i\}), \quad (4.43)$$

onde  $\text{sign}(\cdot)$  representa a função sinal.

#### 4.3.8.2 Algoritmo FastICA

Nesta seção, será apresentado um dos algoritmos mais utilizados para o cálculo da ICA, chamado FastICA (Hyvärinen et al., 2001). O algoritmo utiliza a *kurtosis* (Hyvärinen & Oja, 1997) ou a *negentropy* (Hyvärinen, 1999) como medida de não-gaussianidade. Será apresentado aqui o algoritmo FastICA baseado na *negentropy*. Para mostrar como é realizada a maximização da não-gaussianidade através do FastICA, considere a recuperação de uma única fonte, ou seja, o ajuste de uma das linhas da matriz de separação  $\mathbf{W}$ , denotada por  $\mathbf{w}_i^T$ , de forma que  $y_i = \mathbf{w}_i^T \mathbf{x}$  corresponda a uma estimativa da fonte. O algoritmo é baseado na maximização da *negentropy* aproximada, dada por (4.39), sujeito à restrição  $E\{y_i\} = E\{\mathbf{w}_i^T \mathbf{x}\} = 1$ .

Através do método de Lagrange, é possível verificar que o problema de otimização é resolvido quando a seguinte condição é satisfeita (Hyvärinen et al., 2001):

$$E\{\mathbf{x}G'(\mathbf{w}_i^T \mathbf{x})\} + \beta \mathbf{w}_i = 0, \quad (4.44)$$

onde  $\beta$  é uma constante que depende do valor ótimo da função objetivo.

Aplicando-se o método de Newton para a resolução de (4.44), e considerando que as misturas tenham sido previamente branqueadas, obtém-se a seguinte regra de atualização:

$$\begin{aligned} \mathbf{w}_i &\leftarrow E\{\mathbf{x}G'(\mathbf{w}_i^T \mathbf{x})\} - E\{G''(\mathbf{w}_i^T \mathbf{x})\}\mathbf{w}_i \\ \mathbf{w}_i &\leftarrow \mathbf{w}_i / \|\mathbf{w}_i\| \end{aligned} \quad (4.45)$$

Para misturas branqueadas, a normalização realizada em (4.45) garante a restrição sobre a variância da estimativa  $y_i$ . Com relação à derivada da função não-linear  $G(y)$ , boas escolhas são dadas por (Hyvärinen et al., 2001):

$$G'_1(y) = \tanh(a_1 y), \quad (4.46)$$

$$G'_2(y) = y \exp(-y^2/2), \quad (4.47)$$

$$G'_3(y) = y^3, \quad (4.48)$$

onde  $1 \leq a_1 \leq 2$ , sendo que frequentemente escolhe-se  $a_1 = 1$ .

Para extrair  $k$  fontes ( $k = 1 \dots N$ ) através da regra de atualização em (4.45), é necessário executá-la para  $k$  vetores  $\mathbf{w}_i, i = 1 \dots k$ . Entretanto, se faz necessária alguma regra que evite que estas execuções convirjam para um mesmo ponto de máxima não-gaussianidade, o que representaria a recuperação da mesma fonte. Caso a matriz de mistura seja previamente branqueada, as suas linhas são ortogonais. Portanto, uma estratégia viável seria inserir alguma etapa no algoritmo FastICA que garanta a ortogonalidade dos vetores estimados.

O procedimento para extração de mais de uma fonte pode ser efetuado utilizando-se pelo menos duas estratégias distintas, porém ambas explorando a idéia de ortogonalidade entre os vetores  $\mathbf{w}_i$  estimados:

1. **Estimação serial:** Nesta abordagem, os componentes são estimados sequencialmente. Inicia-se estimando, sem restrição, o primeiro componente independente, através da regra 4.45. A partir do segundo componente, a adaptação dos vetores  $\mathbf{w}_i$  deve ser feita sempre realizando um passo intermediário de ortonormalização do vetor em relação aos demais já obtidos, o que pode ser feito através do método de Gram-Schmidt (Golub & Loan, 1996; Hyvärinen et al., 2001). Esta abordagem também é conhecida como *separação de fontes por deflação* (do inglês *deflation approach*).
2. **Estimação paralela:** Nesta abordagem, os componentes são estimados ao mesmo tempo, adaptando-se paralelamente os vetores  $\mathbf{w}_i$ . No entanto, a cada passo executado, é necessário garantir que as soluções encontradas

são ortonormais entre si. Para isto, é possível utilizar uma técnica de ortogonalização simétrica (Hyvärinen et al., 2001), dada por:

$$\mathbf{W} \leftarrow (\mathbf{W}\mathbf{W}^T)^{-1/2} \mathbf{W}, \quad (4.49)$$

onde  $\mathbf{W}$  representa a matriz de separação composta pelos vetores  $\mathbf{w}_i$ .

### 4.3.9 Aplicações da ICA

A ICA tem sido uma técnica muito utilizada para resolver o problema de BSS em diferentes áreas, tais como: separação de áudio (Makino et al., 2004), separação de imagens (Pei & Zeng, 2006), telecomunicações (Zarzoso & Nandi, 2004) e análise de sinais biomédicos (Chen et al., 2001).

Embora haja muitas aplicações da ICA nas áreas mencionadas acima, ainda há poucos trabalhos que a utilizam nas áreas de SEP e QEE. São encontradas aplicações em monitoramento e análise de vibração em máquinas rotativas (Han, Kim, & Bae, 2005), em eliminação de harmônicos em inversores (Rabi, Paraithimarkalaignan, & Arumugam, 2004) e em estimação de perfis de carga em SEPs (Liao & Niebur, 2003). As análises dos métodos de separação de distúrbios de QEE utilizando a ICA, apresentados nesta dissertação, foram publicadas nos trabalhos (Lima, Cerqueira, et al., 2008) e (Lima, Ferreira, et al., 2008).

A aplicação clássica da ICA é no problema de BSS. Aliás, é habitual na literatura, principalmente nos trabalhos mais antigos, o tratamento da BSS e da ICA praticamente como sinônimos, o que corresponde a uma descrição errônea, dado que, rigorosamente, a ICA corresponde a uma metodologia capaz de resolver o problema de BSS. Isto fica evidente ao se observar o amplo número de aplicações da ICA que não necessariamente estão ligados ao problema de separação. Eis alguns exemplos:

- Extração de características (Bell & Sejnowski, 1997);
- Compressão de dados (Guilhon, Medeiros, & Barros, 2005);

- Econometria (Hyvärinen et al., 2001);
- Predição de séries temporais (Hyvärinen et al., 2001);
- Estágio de pré-processamento em sistemas classificadores (Sanchez-Poblador, Monte-Moreno, & Solé-Casal, 2004).

## 4.4 Sumário

Neste capítulo, os conceitos principais de Separação Cega de Fontes foram apresentados. A Análise de Componentes Independentes, que é uma das principais técnicas utilizadas para BSS, foi apresentada de forma mais detalhada, já que ela é utilizada no próximo capítulo para a análise de distúrbios de QEE.

# 5

## Separação de Múltiplos Distúrbios de QEE Utilizando a ICA

Este capítulo descreve o desenvolvimento do sistema de separação de múltiplos distúrbios de qualidade de energia utilizando a ICA. São propostas duas estruturas para realizar tal fim: uma é utilizada quando se tem disponível mais de 1 monitor de QEE alocados em pontos distintos do SEP; a outra é utilizada quando se tem disponível apenas 1 monitor de QEE. Em seguida, são apresentados e discutidos resultados de simulações de ambas as estruturas para diversos sinais de tensão contendo múltiplos distúrbios.

## 5.1 O sistema proposto

Considere um sistema com  $M$  sinais de QEE observáveis, cada um contendo os mesmos  $N$  múltiplos distúrbios ( $M \geq N$ ). Aqui, são omitidos quaisquer atrasos de tempo entre os sinais observáveis. Considere cada um destes sinais observáveis como sendo uma mistura instantânea dos distúrbios isolados (originais). Deseja-se então recuperar (separar) os distúrbios originais utilizando apenas as misturas, sem informação dos distúrbios isolados e de como eles foram misturados.

Para ilustrar o problema, considere os distúrbios da Figura 5.1, que foram simulados utilizando os modelos propostos em (Trindade, 2005), com frequência de amostragem  $F_S = 15360$  Hz e conforme as definições encontradas em (Dugan et al., 2004) e (Bollen, 2000), e descritos resumidamente no Capítulo 2. A frequência de amostragem em questão é suficiente para caracterizar corretamente os tipos de distúrbios analisados neste trabalho. Os distúrbios simulados correspondem a harmônicos, *notches* e transitório de chaveamento capacitivo, respectivamente denotados por  $s_1[n]$ ,  $s_2[n]$  e  $s_3[n]$ , e foram registrados simultaneamente em janelas de 1024 amostras. Note que a Figura 5.1 mostra apenas os distúrbios, sendo que o componente fundamental foi previamente extraído.

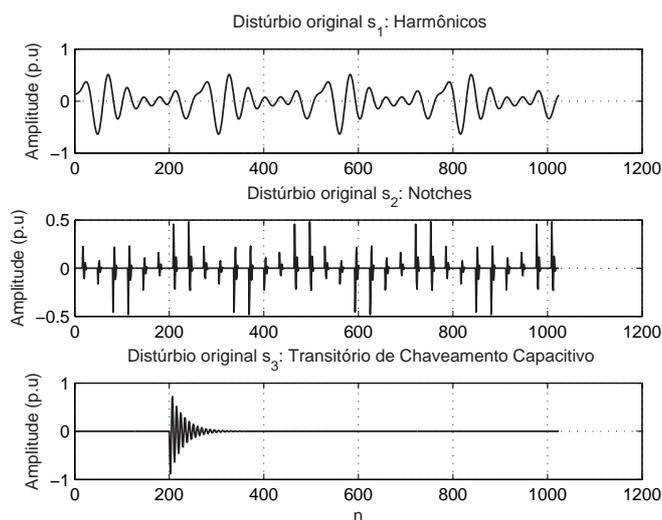


Figura 5.1: Distúrbios originais.

Os distúrbios originais foram então misturados, de acordo com (4.4), através da seguinte matriz quadrada, gerada aleatoriamente:

$$\mathbf{A} = \begin{bmatrix} 1 & 0.6 & 0.5 \\ 0.4 & 0.4 & 0.5 \\ 0.5 & 0.6 & 1 \end{bmatrix}$$

Portanto,  $M = N$ , ou seja, o número de misturas (sinais observáveis) é igual ao número de fontes (distúrbios originais). Denotando as misturas por  $x_1[n]$ ,  $x_2[n]$  e  $x_3[n]$ , obtém-se:

$$\begin{aligned} x_1[n] &= s_1[n] + 0.6s_2[n] + 0.5s_3[n] \\ x_2[n] &= 0.4s_1[n] + 0.4s_2[n] + 0.5s_3[n] \\ x_3[n] &= 0.5s_1[n] + 0.6s_2[n] + s_3[n] \end{aligned} \quad (5.1)$$

As misturas obtidas através de (5.1) são mostradas na Figura 5.2.

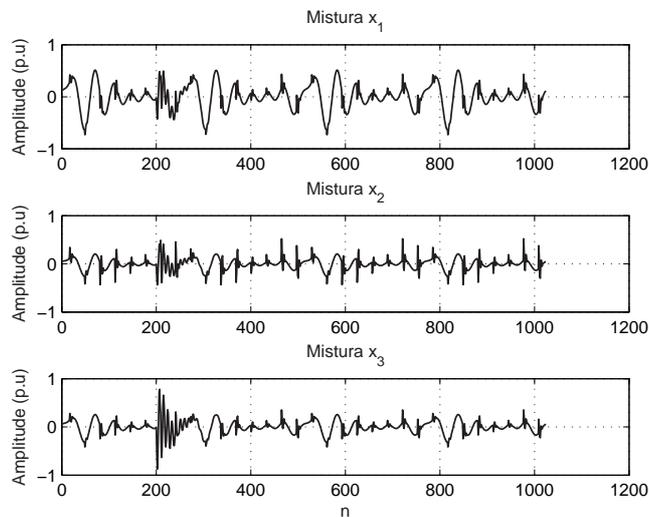


Figura 5.2: Misturas instantâneas dos distúrbios originais.

Deseja-se então recuperar os distúrbios originais apenas a partir das misturas, ou seja, separar múltiplos distúrbios em sinais de QEE. Esta situação se configura como um problema de BSS, tal como descrito na Seção 4.1. Para resolver o problema de

BSS em questão, será utilizada a ICA. Aplicando-se o algoritmo FastICA<sup>1</sup> aos sinais de mistura da Figura 5.2, obtém-se as estimações dos distúrbios originais, mostradas na Figura 5.3. Conforme descrito na Seção 4.3.4, e como pode-se observar, a ICA recupera as formas de onda dos distúrbios originais, mas não garante a recuperação de suas amplitudes e nem de sua ordem (ordem dos distúrbios originais: harmônicos, *notches*, transitório; ordem das estimações: transitório, *notches*, harmônicos). Para análises dos distúrbios separados pela ICA, tais como em localização no tempo e classificação, isto não seria um problema, já que as técnicas dedicadas a estes fins se baseiam na forma de onda do sinal.

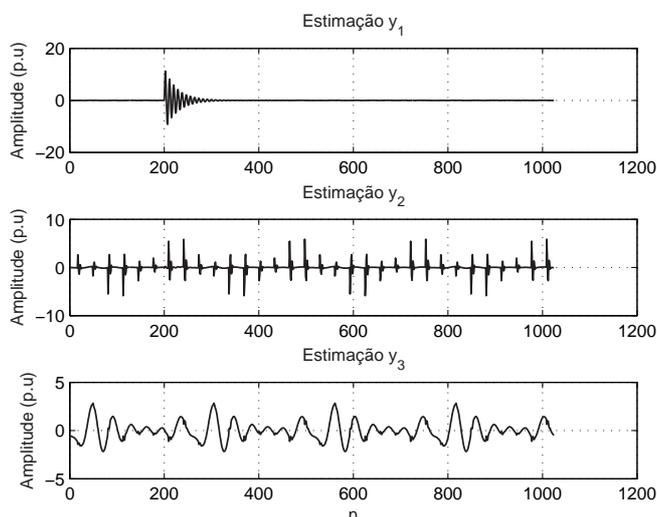


Figura 5.3: Estimacões dos distúrbios originais.

Para utilizar a ICA, assume-se que os distúrbios originais são, em cada instante de tempo  $n$ , estatisticamente independentes. Neste caso, a informação de um determinado distúrbio não fornece nenhuma informação a respeito dos outros distúrbios envolvidos. Os distúrbios originais simulados neste trabalho são gerados separadamente e depois somados para formar os sinais com múltiplos distúrbios, conforme o modelo descrito na Seção 3.1. Portanto, os distúrbios originais são

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

independentes entre si. Também assume-se que os distúrbios originais não possuem distribuição gaussiana.

A seguir, são apresentadas as duas estruturas desenvolvidas para separar múltiplos distúrbios. A primeira é aplicada quando são disponíveis  $M$  dispositivos de monitoramento de QEE alocados em pontos distintos do SEP e sincronizados, e a outra é aplicada quando se tem disponível um único monitor de QEE, sendo esta a situação mais comum. O dispositivo de monitoramento deve adquirir e amostrar o sinal de tensão do SEP, fornecendo assim as sequências de entrada para os algoritmos propostos.

### 5.1.1 Caso 1: $M$ monitores

O sistema proposto para a separação de múltiplos distúrbios para o caso de mais de um ponto de medição disponível é mostrado na Figura 5.4. A seguir são descritas as suas etapas.

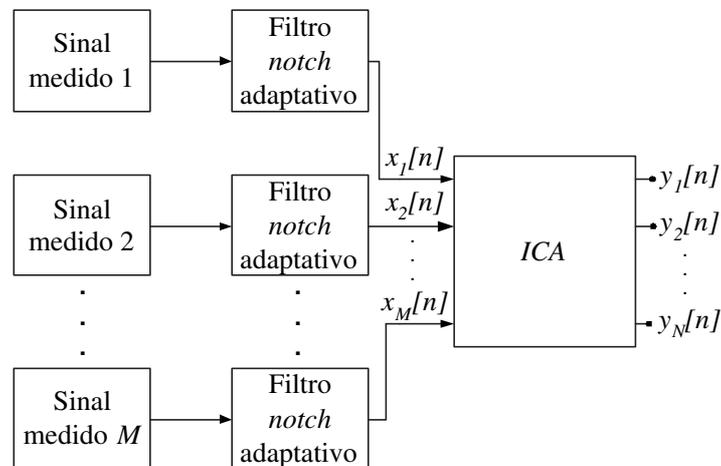


Figura 5.4: Diagrama de blocos da estrutura de separação para  $M$  pontos de medição.

#### 5.1.1.1 Filtros *notch* adaptativos

O primeiro estágio do sistema proposto é composto por filtros *notch* adaptativos, empregados na remoção do componente fundamental dos sinais de tensão medidos.

A razão para esta metodologia está no fato de que, para alguns distúrbios de QEE (transitórios, *notches*, etc), a maior parte da energia do sinal está concentrada no componente fundamental, o qual não contribui para o problema de separação dos distúrbios. Portanto, os sinais resultantes das saídas deste estágio contém apenas informações dos distúrbios de QEE, exceto para afundamentos, elevações e interrupções, que são distúrbios relacionados ao componente fundamental.

A estrutura utilizada é o EPLL (*Enhanced Phase-locked Loop*), conforme apresentado em (Karimi-Ghartemani & Iravani, 2002). O EPLL é um sistema capaz de fornecer como saída um sinal com amplitude e fase iguais às do componente fundamental do sinal de entrada. O EPLL pode ser encarado como um filtro *notch* adaptativo não-linear, e suas características são controladas por seus parâmetros internos.

A Figura 5.5 mostra o diagrama de blocos de um sistema EPLL. O EPLL rastreia um componente específico do sinal de entrada  $u(t)$  como sua saída  $y(t)$  e simultaneamente extrai sua amplitude  $A(t)$  e fase  $\phi(t)$ . O sinal de erro  $e(t)$  representa o desvio do sinal de entrada em relação ao sinal de saída. O sinal de saída é determinado pela sua frequência  $\omega_0$ . Portanto, o EPLL é um filtro *notch* não-linear.

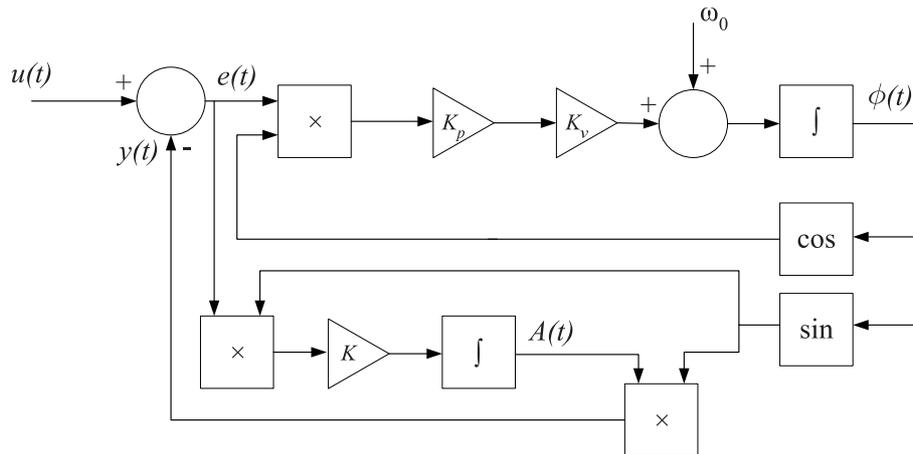


Figura 5.5: Diagrama de blocos de um sistema EPLL.

O EPLL fornece as seguintes vantagens quando comparado a um filtro *notch* clássico (Mitra, 1998): (i) não há diferença de fase entre o componente fundamental

estimado e o sinal de entrada. Portanto, o sinal de erro está sincronizado com o sinal de entrada; (ii) estimação em tempo real da amplitude e fase do componente fundamental; (iii) a estrutura é robusta com relação a variações de seus parâmetros internos e a ruído externo, além de também ser robusta a pequenas variações da frequência fundamental do sinal de entrada.

Os parâmetros  $K$  e  $K_p K_v$  determinam a velocidade de convergência do EPLL em direção à sua solução em termos de amplitude e fase, e são escolhidos de forma empírica. A velocidade de convergência cresce com o aumento nos valores dos parâmetros. Entretanto, isto pode resultar em um maior erro de estado permanente ou em um desajuste dos valores estimados na presença de ruído e distorções. Este efeito é uma característica inerente de algoritmos adaptativos. Portanto, os parâmetros devem ser escolhidos de forma a manter um bom comprometimento entre velocidade de convergência e erro de estado permanente.

As equações que governam o EPLL da Figura 5.5 são:

$$\begin{aligned} y(t) &= A(t) \sin(\phi(t)), \\ e(t) &= u(t) - y(t), \\ \dot{A} &= K e(t) \sin(\phi(t)), \\ \dot{\phi} &= \omega_0 + K_p K_v e(t) \cos(\phi(t)). \end{aligned} \tag{5.2}$$

A versão discreta das equações em (5.2), baseada na aproximação da derivada de primeira ordem, torna-se:

$$\begin{aligned} y[n] &= A[n] \sin(\phi[n]), \\ e[n] &= u[n] - y[n], \\ A[n+1] &= A[n] + K T_S e[n] \sin(\phi[n]), \\ \phi[n+1] &= \phi[n] + \omega_0 T_S + K_p K_v T_S e[n] \cos(\phi[n]). \end{aligned} \tag{5.3}$$

onde  $T_S$  é o período de amostragem. Investigações mostram que estas aproximações mantêm as propriedades desejadas do algoritmo devido à robustez estrutural do EPLL (Karimi-Ghartemani & Iravani, 2002).

A Figura 5.6 mostra um exemplo de aplicação do EPLL na remoção do componente fundamental ( $f_0 = 60$  Hz) de um sinal de tensão contendo harmônicos.

Como pode ser observado, o sinal de saída rastreia o componente fundamental do sinal de entrada, e o sinal de erro contém a diferença entre eles, ou seja, os harmônicos. Neste exemplo, foi utilizado  $K = K_p K_v = 80$ . Para esta condição, a velocidade de convergência foi lenta, entretanto o erro de estado permanente da estimação do componente fundamental foi pequeno. Na figura, não é mostrada a etapa transitória da estimação.

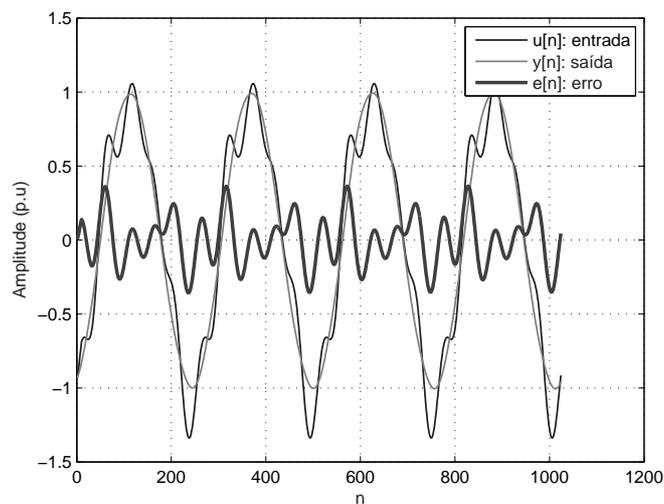


Figura 5.6: Aplicação do EPLL a um sinal de tensão contendo harmônicos.

### 5.1.1.2 ICA

Os  $M$  sinais adquiridos  $x_1[n], x_2[n], \dots, x_M[n]$  contendo as misturas dos supostos  $N$  distúrbios são fornecidos como entrada ao algoritmo FastICA, que tem como objetivo fornecer as estimações  $y_1[n], y_2[n], \dots, y_N[n]$  dos respectivos distúrbios isolados.

Em todas as simulações realizadas neste trabalho, as configurações do algoritmo FastICA foram:

- Estimação: Paralela (Ortogonalização simétrica).

Neste caso, todos os componentes independentes são estimados ao mesmo tempo. Uma motivação para a utilização da estimação paralela é que o

método de estimação serial (deflação) possui a desvantagem de que erros na estimação do primeiro componente se propagam na estimação dos componentes subsequentes.

- Medida de não-gaussianidade: *Negentropy*
- Função não-linear utilizada como aproximação da *negentropy*:  $G'(y) = y^3$
- PCA utilizada para redução da dimensão dos vetores de dados a serem fornecidos ao algoritmo FastICA quando há mais misturas do que fontes.
- PCA também utilizada para realizar o branqueamento dos vetores de dados a serem fornecidos ao algoritmo FastICA.

### 5.1.2 Caso 2: Um monitor

O sistema proposto para separar múltiplos distúrbios quando há disponível apenas um monitor de QEE é basicamente dividido nos blocos mostrados na Figura 5.7, que são descritos a seguir.

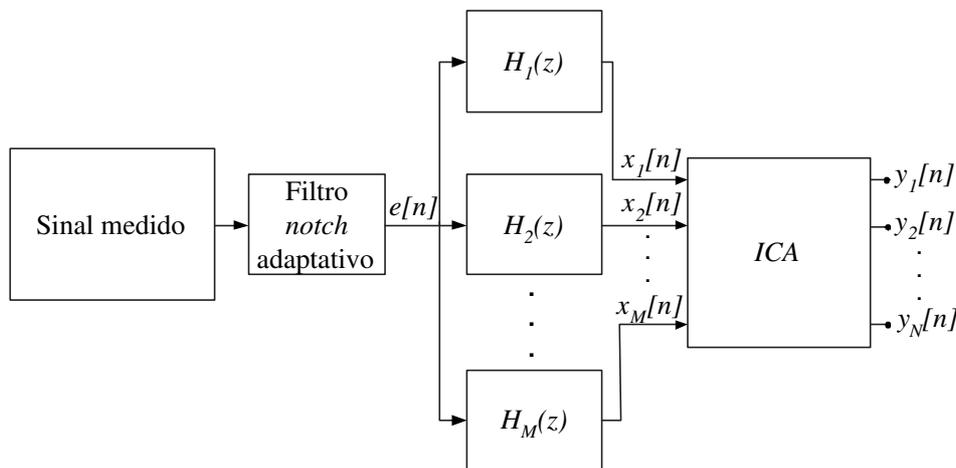


Figura 5.7: Diagrama de blocos da estrutura de separação para um único ponto de medição.

### 5.1.2.1 Filtro *notch* adaptativo

O filtro *notch* adaptativo utilizado é o mesmo descrito na Seção 5.1.1.1. Sua função é também de remover o componente fundamental do sinal medido. Sendo assim, o sinal  $e[n]$  contém informação apenas dos distúrbios contidos no sinal medido.

### 5.1.2.2 Banco de filtros

A diferença principal entre esta estrutura e a apresentada anteriormente (Seção 5.1.1) é o uso do banco de filtros  $H_1(z), H_2(z), \dots, H_M(z)$ . O banco de filtros gera  $M$  sinais contendo os múltiplos distúrbios a partir do sinal  $e[n]$  obtido pelo filtro *notch* adaptativo. As saídas dos  $M$  filtros, sinais  $x_1[n], x_2[n], \dots, x_M[n]$ , são então fornecidas como entradas ao algoritmo FastICA.

No sistema proposto, são utilizados filtros de Resposta ao Impulso de Comprimento Finito (FIR, *Finite Impulse Response*) (Mitra, 1998), por ser possível projetá-los de forma que apresentem fase linear. Este é um importante requerimento, pois assim é possível projetar todos os filtros com atrasos de grupo constantes. Além de constantes, é necessário que os atrasos dos  $M$  filtros sejam iguais, mantendo assim sincronismo entre os sinais que serão fornecidos à ICA.

A função de transferência de um filtro FIR é dada por:

$$H(z) = \sum_{k=0}^K h[k]z^{-k}, \quad (5.4)$$

onde  $K$  é a sua ordem. O atraso de grupo é definido como:

$$\tau(\omega) = -\frac{d\theta(\omega)}{d\omega}, \quad (5.5)$$

onde  $\theta(\omega)$  é a resposta de fase do filtro.

Os filtros FIR utilizados aqui são do Tipo 1 (Mitra, 1998). Possuem resposta ao impulso simétrica, comprimento ímpar e resposta de fase linear. Em um caso geral, a resposta em frequência destes filtros é da forma:

$$H(e^{j\omega}) = e^{-j\theta} |H(e^{j\omega})| = e^{-jK\omega/2} \check{H}(\omega), \quad (5.6)$$

onde a resposta de amplitude  $\check{H}(\omega)$ , também denominada resposta de fase zero, é da forma:

$$\check{H}(\omega) = h \left[ \frac{K}{2} \right] + 2 \sum_{k=1}^{K/2} h \left[ \frac{K}{2} - k \right] \cos(\omega k). \quad (5.7)$$

Portanto, conclui-se que se todos os filtros  $H_1(z), H_2(z), \dots, H_M(z)$  forem do Tipo 1 e possuírem a mesma ordem, todos terão atraso de grupo  $\tau(\omega) = K/2$ .

O filtro  $H_1(z)$  apresenta resposta de frequência dada por:

$$H(e^{j\omega}) = e^{-jK\omega/2}, \quad (5.8)$$

portanto,

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

e

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

Dessa forma, o filtro  $H_1(z)$  estará apenas atrasando o sinal  $e[n]$  de  $K/2$  amostras. Não haverá alteração da amplitude do sinal, guardando assim a máxima informação proveniente dos distúrbios envolvidos.

Os filtros  $H_2(z), \dots, H_M(z)$  são projetados segundo 5.7, de tal forma que cada um selecione uma determinada faixa de frequência do sinal  $e[n]$ .

### 5.1.2.3 ICA

As  $M$  saídas do banco de filtros são apresentadas ao algoritmo FastICA, que deve fornecer as estimações dos  $N$  distúrbios presentes no sinal de tensão do SEP. As configurações do algoritmo são as mesmas utilizadas na Seção 5.1.1.2.

## 5.2 Resultados e Discussões

Nesta seção, são apresentados resultados de simulações dos sistemas descritos na Seção 5.1. Os eventos de QEE utilizados neste trabalho foram simulados de acordo com as definições encontradas em (Dugan et al., 2004) e (Bollen, 2000), e utilizando

a metodologia proposta em (Trindade, 2005). Os eventos de QEE foram gerados com frequência de amostragem ( $f_s$ ) de 15360 amostras por segundo, e o componente fundamental de todos os sinais possui frequência  $f_0$  de 60 Hz.

A Figura 5.8 mostra 3 sinais a serem submetidos como entrada ao sistema proposto na Seção 5.1.1. Suponha que estes sinais foram coletados de 3 monitores de QEE próximos às fontes de distúrbios e sincronizados. Sendo assim, as misturas são assumidas instantâneas, ou seja, a matriz de misturas não contém atrasos. Portanto, os seus coeficientes são reais, aplicando apenas atenuações nas fontes, não seguidas de distorções. Também, suponha que os monitores estejam próximos entre si, razão pela qual os sinais parecem ser visualmente iguais, porém são diferentes o suficiente para a ICA interpretá-los como sendo três combinações distintas dos dois distúrbios envolvidos.

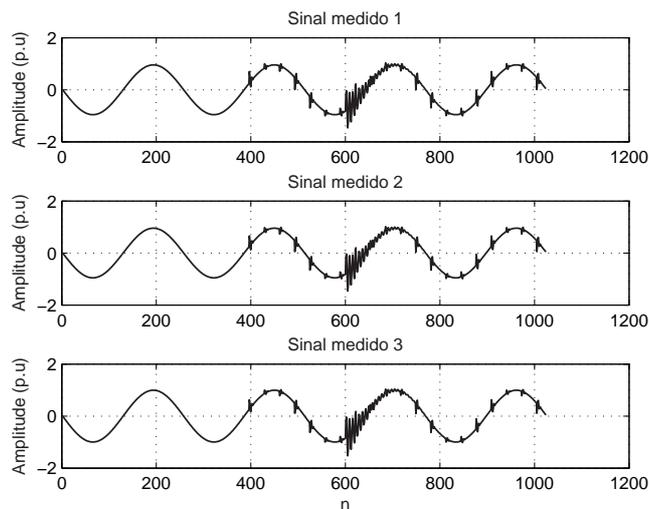


Figura 5.8: Sinais medidos contendo *notches* e transitório de chaveamento capacitivo.

Inicialmente é realizada a remoção do componente fundamental dos sinais medidos, através de 3 EPLLs sintonizados na frequência de 60 Hz, obtendo-se assim os sinais de mistura da Figura 5.9. A Figura 5.10 mostra as amplitudes do componente fundamental  $A_1[n]$ ,  $A_2[n]$  e  $A_3[n]$  rastreadas pelos EPLLs nos três sinais medidos da Figura 5.8, respectivamente. O objetivo da análise destas amplitudes é

detectar distúrbios que afetam o componente fundamental, tais como afundamento, elevação e interrupção. Como não há variação significativa nas amplitudes ao longo do tempo, constata-se a ausência destes tipos de distúrbios. Quantitativamente, a detecção automática destes tipos de distúrbios poderia ser realizada a partir do monitoramento da variação destas amplitudes. Esta abordagem não é realizada neste trabalho.

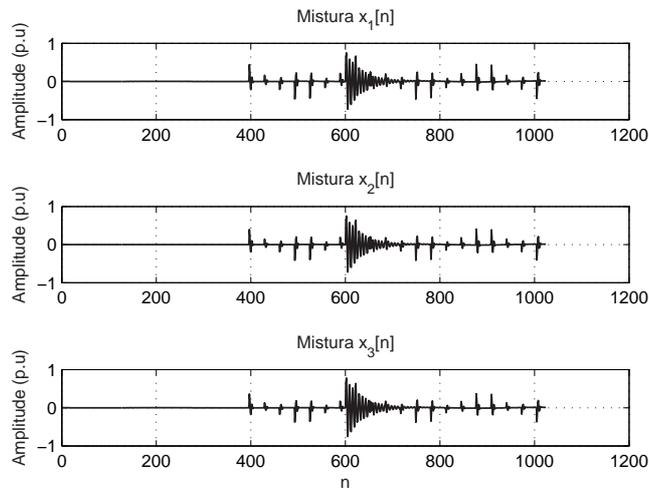


Figura 5.9: Misturas obtidas pelos EPLLs.

A Figura 5.11 mostra as estimações obtidas pela ICA dos componentes independentes presentes nas misturas  $x_1[n]$ ,  $x_2[n]$ ,  $x_3[n]$ . Visualmente, pode-se identificar os sinais  $y_1[n]$  e  $y_2[n]$  como sendo os distúrbios *notch* e transitório de chaveamento capacitivo, respectivamente. Como há 3 misturas ( $M = 3$ ) de 2 fontes ( $N = 2$ ) nos sinais medidos da Figura 5.8, há então informação redundante nas misturas, ou seja, apenas 2 misturas seriam suficientes para que a ICA estimasse os distúrbios. A PCA é utilizada então pelo algoritmo FastICA para reduzir a dimensão dos dados nesta situação, descartando automaticamente a mistura que fornece menos informação. Portanto, o algoritmo FastICA apresentou apenas 2 estimações, correspondentes aos 2 distúrbios envolvidos. Como já era de se esperar da teoria da ICA, e descrito na seção 4.3.4, ela apresenta a limitação de não garantir a recuperação das amplitudes dos distúrbios.

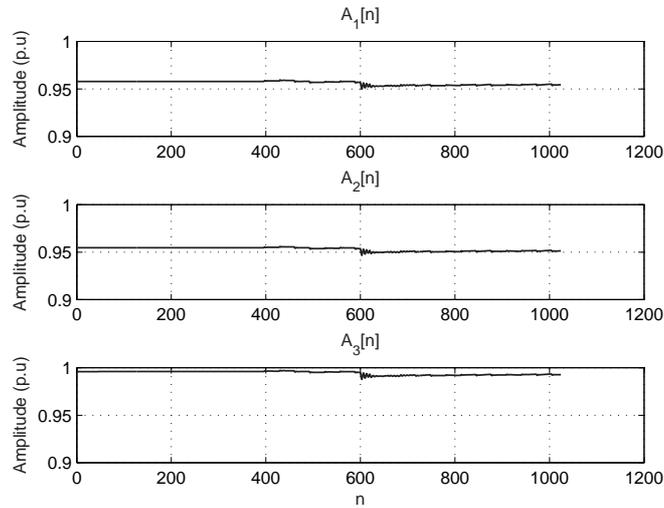


Figura 5.10: Amplitudes do componente fundamental rastreadas pelos EPLLs.

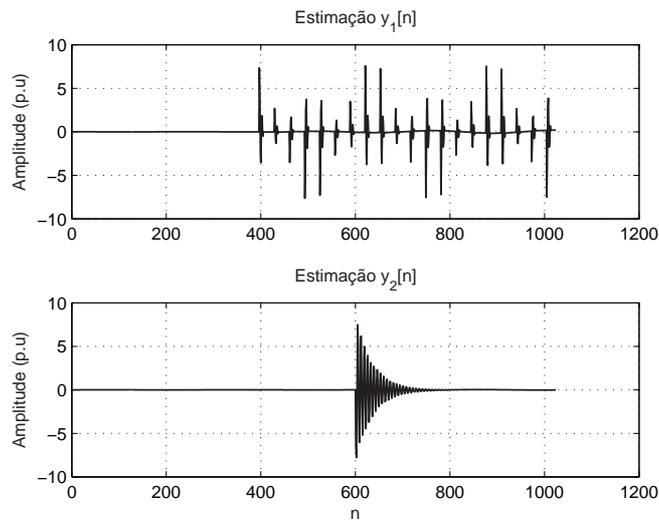


Figura 5.11: Estimações dos distúrbios contidos nos sinais da Figura 5.8.

O próximo exemplo mostra a análise do sinal da Figura 5.12, que contém dois distúrbios: harmônicos e *notches*. Neste caso, será utilizada a estrutura descrita na Seção 5.1.2, já que há disponível apenas 1 sinal medido.

O componente fundamental é removido pelo filtro *notch* adaptativo. Portanto, a maior parte da informação contida no sinal  $e[n]$  é composta pelos harmônicos e

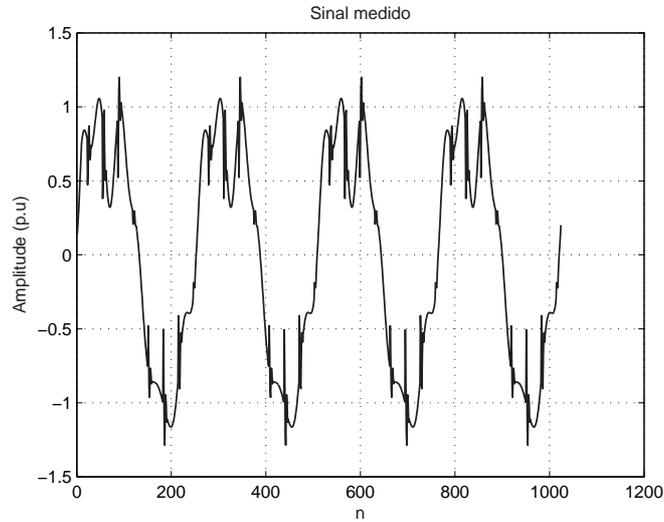


Figura 5.12: Sinal medido contendo dois distúrbios (*notch* e harmônicos).

*notches*. A Figura 5.13 mostra os módulos da DFT do *notch*, dos harmônicos e do sinal de erro, respectivamente. O objetivo é caracterizar os distúrbios no domínio da frequência, analisando o que acontece durante os processos de mistura e separação também neste domínio. O cálculo da DFT não é necessário para o funcionamento das etapas subsequentes do algoritmo. Observa-se a partir desta figura que há uma certa separação entre os distúrbios no domínio da frequência, ou seja, a maior parte da energia de cada um dos distúrbios ocorre em distintas regiões do espectro. Em outras palavras, os distúrbios em questão compartilham pouca energia no domínio da frequência.

Como há dois distúrbios presentes no sinal  $e[n]$ , a ICA precisa de, no mínimo, dois sinais de mistura para estimá-los corretamente. Os sinais de mistura  $x_1[n]$  e  $x_2[n]$  da Figura 5.14 foram obtidos a partir de dois filtros,  $H_1(z)$  e  $H_2(z)$ , respectivamente.

O filtro  $H_2(z)$  é um filtro FIR passa-altas tipo 1, de ordem  $K = 20$  e frequência de corte  $f_C = 500$  Hz. Portanto, o seu atraso de grupo  $\tau(\omega)$  é constante e igual a  $K/2 = 10$ , ou seja, ele atrasa todos os componentes de frequência do sinal  $e[n]$  em 10 amostras. Sendo assim, haverá apenas atenuação, não havendo distorção, requisito desejado para preservar a forma de onda do sinal filtrado.

Já o filtro  $H_1(z)$  apenas atrasa o sinal  $e[n]$  de 10 amostras, não provocando

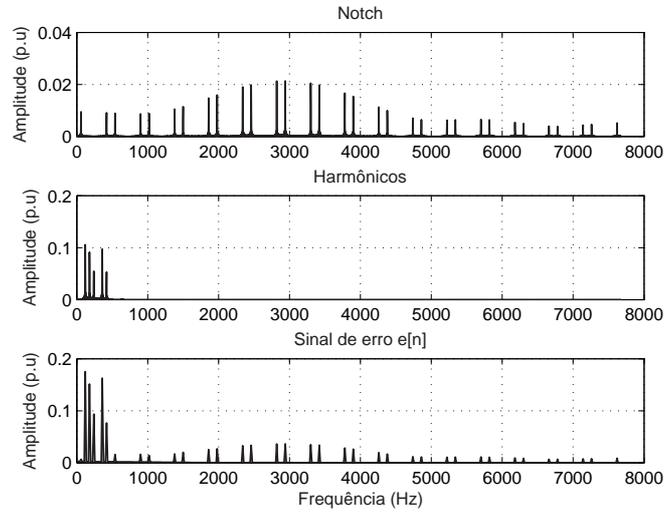


Figura 5.13: Módulos das DFTs dos distúrbios e do sinal de erro (*notch* e harmônicos).

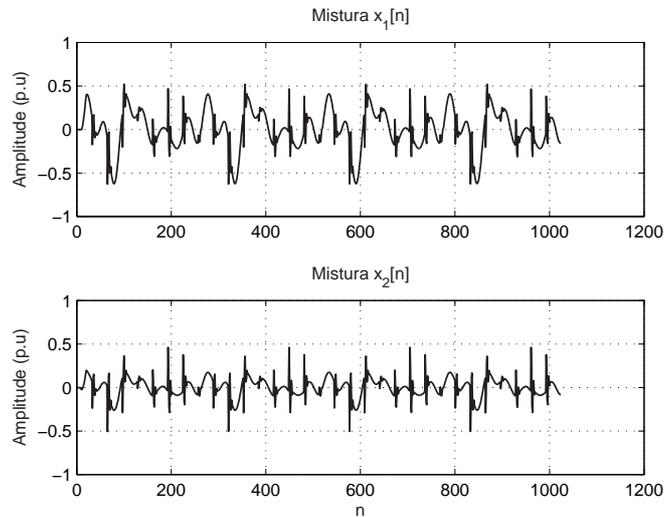


Figura 5.14: Misturas provenientes do banco de filtros (*notch* e harmônicos).

alteração de sua amplitude, preservando assim a máxima informação dos distúrbios. Portanto, os sinais de mistura  $x_1[n]$  e  $x_2[n]$  estão em fase um com o outro. A partir da Figura 5.13, constata-se que o filtro  $H_2(z)$  atenuará em sua maior parte a energia dos harmônicos, que se concentra em frequências inferiores a 500 Hz.

Por meio dos filtros, tenta-se obter então uma matriz de mistura  $2 \times 2$  dos 2 distúrbios presentes no sinal  $e[n]$ . O que a ICA faz agora é estimar a inversa dessa matriz, tentando recuperar os distúrbios isolados. A Figura 5.15 mostra as estimações normalizadas comparadas com os distúrbios originais normalizados. Foram realizadas as normalizações para possibilitar a apresentação tanto dos distúrbios originais quanto de suas estimações na mesma figura, já que as amplitudes dos distúrbios originais não são recuperadas em suas estimações. A partir dessa Figura, pode ser visto qualitativamente a similaridade entre os distúrbios originais e suas respectivas estimações, no que diz respeito às formas de onda. O atraso de amostras entre os distúrbios originais e suas estimações é causado pelo banco de filtros. Como o atraso de amostras é conhecido, e seu valor igual à metade da ordem dos filtros, as estimações poderiam ser automaticamente sincronizadas no tempo com os respectivos distúrbios originais adiantando-as pelo mesmo número de amostras. Isto não foi feito justamente para mostrar este efeito naturalmente provocado pelos filtros.

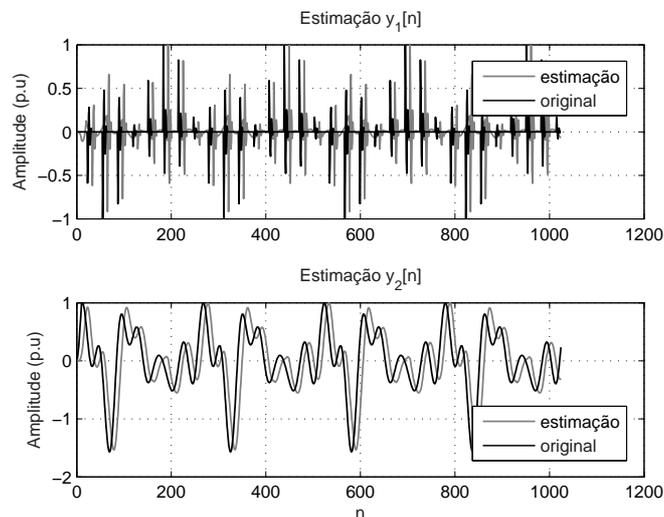


Figura 5.15: Estimaciones normalizadas dos distúrbios fornecidas pela ICA, comparadas aos distúrbios originais (*notch* e harmônicos).

O próximo exemplo mostra a análise do sinal da Figura 5.16, que contém dois distúrbios: harmônicos e transitório de chaveamento capacitivo. Neste caso, também

será utilizada a estrutura descrita na Seção 5.1.2, já que há disponível apenas 1 sinal medido.

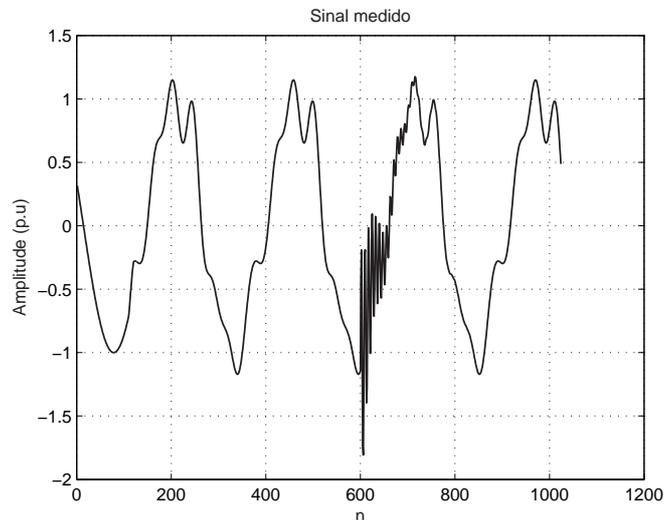


Figura 5.16: Sinal medido contendo dois distúrbios (transitório de chaveamento capacitivo e harmônicos).

O componente fundamental é removido pelo filtro *notch* adaptativo. Portanto, a maior parte da informação contida no sinal  $e[n]$  é composta pelos harmônicos e pelo transitório de chaveamento capacitivo. A Figura 5.17 mostra os módulos da DFT do transitório de chaveamento capacitivo, dos harmônicos e do sinal de erro, respectivamente. Novamente, como no exemplo anterior, o objetivo desta figura é mostrar o comportamento dos distúrbios envolvidos no domínio da frequência. Assim como no exemplo anterior, também se observa a partir desta figura que há uma certa separação entre os distúrbios no domínio da frequência, ou seja, a maior parte da energia de cada um dos distúrbios ocorre em distintas regiões do espectro.

Os filtros  $H_1(z)$  e  $H_2(z)$  utilizados neste exemplo são iguais aos filtros utilizados no exemplo anterior, sendo o filtro  $H_1(z)$  apenas um atrasador de 10 amostras e o filtro  $H_2(z)$  um passa-altas com frequência de corte  $f_C = 500\text{Hz}$ . A Figura 5.18 mostra as misturas  $x_1[n]$  e  $x_2[n]$  obtidas a partir dos filtros  $H_1(z)$  e  $H_2(z)$ , respectivamente. Repare que a mistura  $x_2[n]$  apresenta os harmônicos atenuados em relação à mistura  $x_1[n]$ , resultado provocado pelo filtro passa-altas. Como a

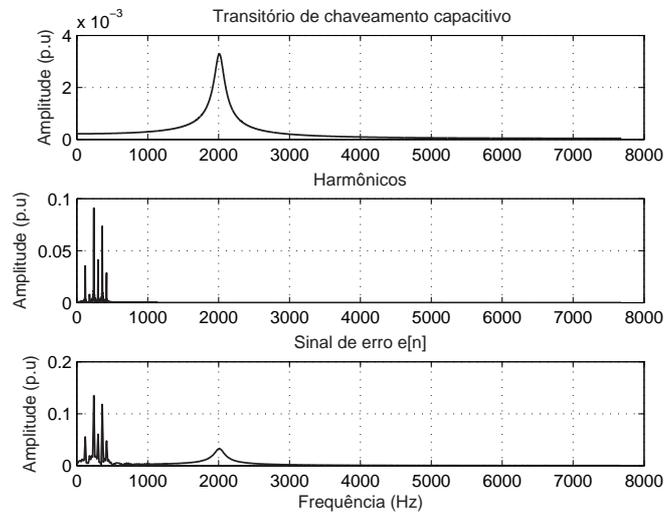


Figura 5.17: Módulos das DFTs dos distúrbios e do sinal de erro (transitório de chaveamento capacitivo e harmônicos).

energia do transitório de chaveamento capacitivo está concentrada em sua maior parte em torno da frequência de 2000 Hz, ele não é afetado pelo filtro.

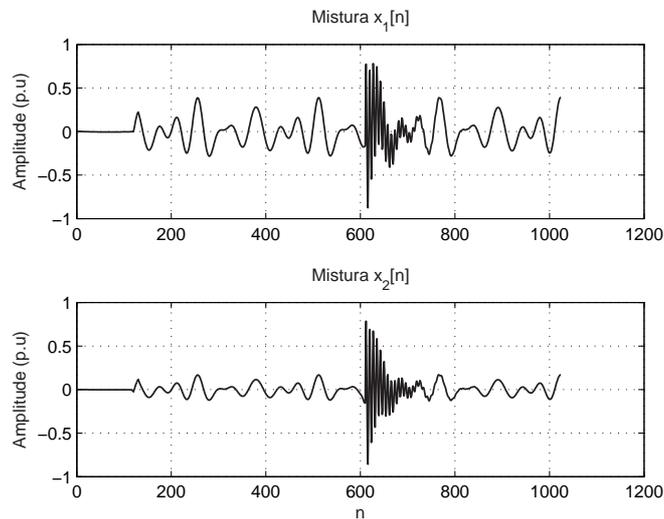


Figura 5.18: Misturas provenientes do banco de filtros (transitório de chaveamento capacitivo e harmônicos).

A Figura 5.19 mostra as estimações normalizadas comparadas com os distúrbios originais normalizados. Novamente, observa-se qualitativamente a similaridade entre as formas de onda dos distúrbios originais e suas respectivas estimações.

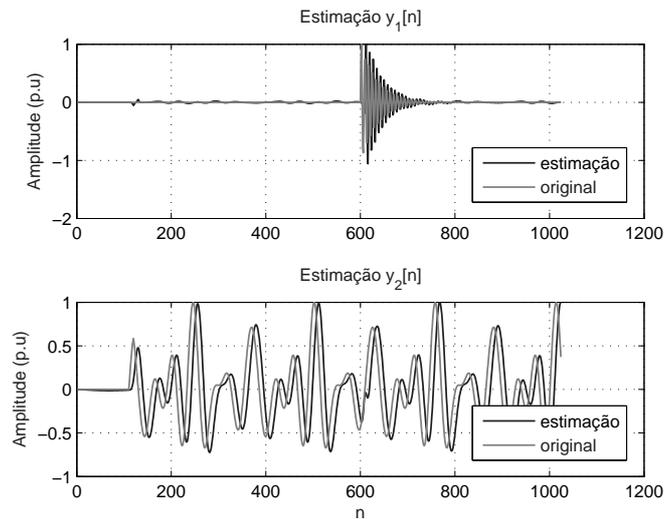


Figura 5.19: Estimaciones normalizadas dos distúrbios fornecidas pela ICA, comparadas aos distúrbios originais (transitório de chaveamento capacitivo e harmônicos).

Para fornecer uma informação quantitativa com relação ao desempenho dos métodos propostos, a Figura 5.20 mostra os coeficientes de correlação (Papoulis & Pillai, 2002) calculados entre os distúrbios isolados originais e suas respectivas estimações, para 200 simulações de eventos contendo cada um deles harmônicos e *notches* como múltiplos distúrbios. Os resultados são mostrados para ambos os casos considerados ( $M$  monitores e um monitor). Para o caso de  $M = 2$  monitores, havia portanto, em cada simulação, disponíveis dois sinais medidos em pontos distintos do SEP e sincronizados. Para o caso de um único monitor, havia um único sinal disponível em cada simulação contendo os dois distúrbios envolvidos. Pode ser verificado o bom desempenho dos métodos propostos, pois os coeficientes de correlação são próximos de 1 para todos os eventos, significando que em ambos os métodos as formas de onda das estimações são semelhantes às formas de onda dos respectivos distúrbios originais. Também, o desempenho para o caso de  $M$  monitores

é ligeiramente superior ao caso de 1 monitor. Isto ocorre porque, no primeiro caso, as misturas são geradas por meio de combinações lineares sem atrasos dos distúrbios originais; já no segundo caso, a matriz de mistura é gerada artificialmente através do banco de filtros, podendo estes causar distorções de tal forma que as estimações dos distúrbios apresentem um desvio na forma de onda se comparadas aos distúrbios originais.

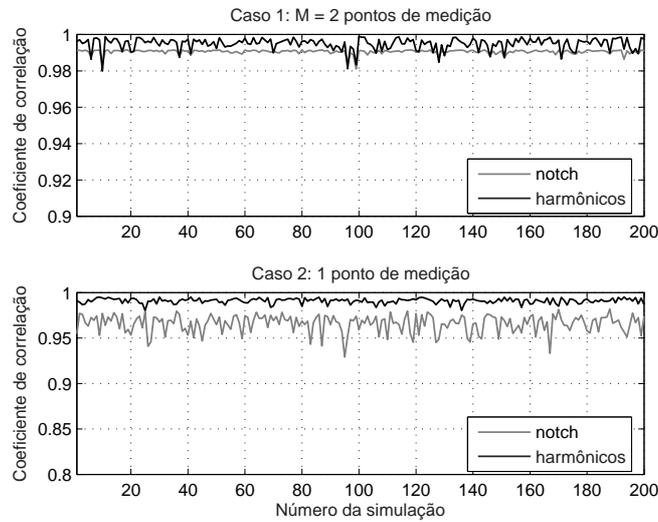


Figura 5.20: Coeficientes de correlação entre os distúrbios originais e suas estimações: *notch* e harmônicos.

Considerando agora sinais corrompidos por transitório de chaveamento capacitivo e harmônicos, são mostrados na Figura 5.21 os coeficientes de correlação para 200 simulações. Os resultados são semelhantes aos discutidos anteriormente.

Considere agora o sinal apresentado na Figura 5.22, que contém dois distúrbios: *spike* e harmônicos. Este sinal foi então fornecido como entrada à estrutura da Figura 5.7. A Figura 5.23 mostra os módulos da DFT do *spike*, dos harmônicos e do sinal de erro  $e[n]$ , respectivamente. Neste caso, diferentemente dos casos anteriores, os dois distúrbios presentes ocupam a mesma região do espectro de frequências. Outra importante característica a ser observada é que as amplitudes dos componentes de frequência que compõem o *spike* são bem menores do que as amplitudes dos componentes de frequência que compõem os harmônicos. Portanto,

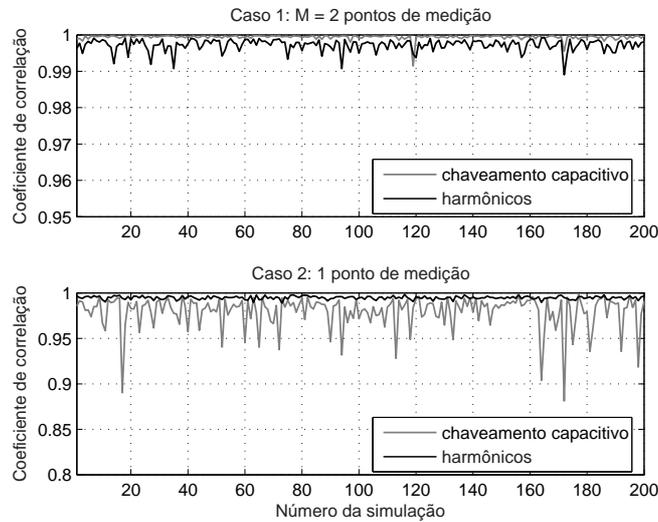


Figura 5.21: Coeficientes de correlação entre os distúrbios originais e suas estimações: transitório de chaveamento capacitivo e harmônicos.

como pode ser visto no espectro de frequências do sinal de erro, os componentes de frequência dos harmônicos predominam sobre os componentes de frequência do *spike*. Sendo assim, há mais informação dos harmônicos do que do *spike* contida neste sinal, e como os seus espectros se sobrepõem, quaisquer que sejam as respostas em frequência dos filtros necessários para gerar as misturas, estes irão sempre atuar em regiões de sobreposição dos espectros de frequência de ambos os distúrbios. A Figura 5.24 mostra os sinais de mistura obtidos a partir dos dois filtros necessários, que são os mesmos utilizados nas análises anteriores. Cabe ressaltar neste momento, que o objetivo é utilizar os mesmos filtros para todas as análises, de forma a generalizar a estrutura para todos os casos de sinais contendo dois distúrbios, em especial aos distúrbios que deformam a forma de onda do sinal de tensão (*notches*, *spike*, transitório de chaveamento capacitivo e harmônicos). Como já era de se esperar, há mais informação dos harmônicos do que do *spike* nos sinais de mistura. A Figura 5.25 mostra as estimações dos distúrbios normalizadas em comparação com os distúrbios originais normalizados. Como pode-se observar, as duas estimações apresentam grande quantidade de informação a respeito dos harmônicos. Portanto, a separação não foi bem sucedida neste caso.

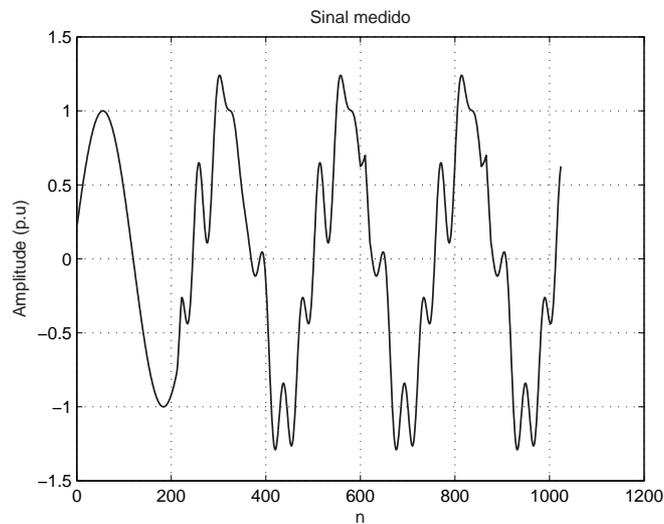


Figura 5.22: Sinal medido contendo dois distúrbios (*spike* e harmônicos).

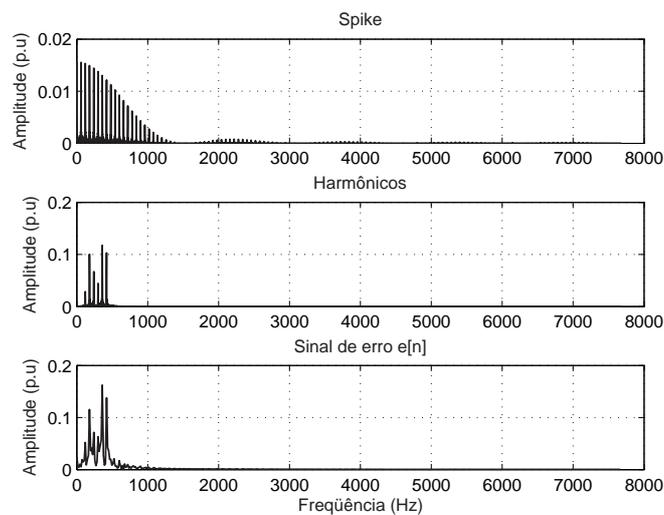


Figura 5.23: Módulos das DFTs dos distúrbios e do sinal de erro (*spike* e harmônicos).

Novamente, como forma de fornecer alguma informação quantitativa acerca do desempenho das técnicas propostas, a Figura 5.26 mostra os coeficientes de correlação calculados entre os distúrbios originais e suas respectivas estimações, para 200 simulações de diferentes sinais corrompidos por *spikes* e harmônicos. Mais uma

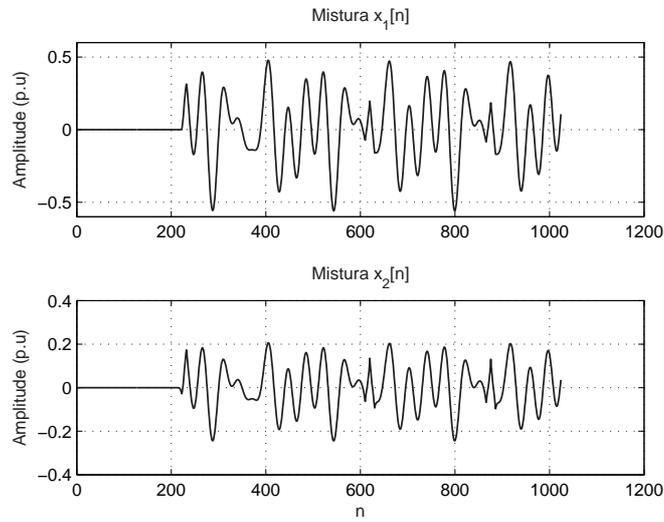


Figura 5.24: Misturas provenientes do banco de filtros (*spike* e harmônicos).

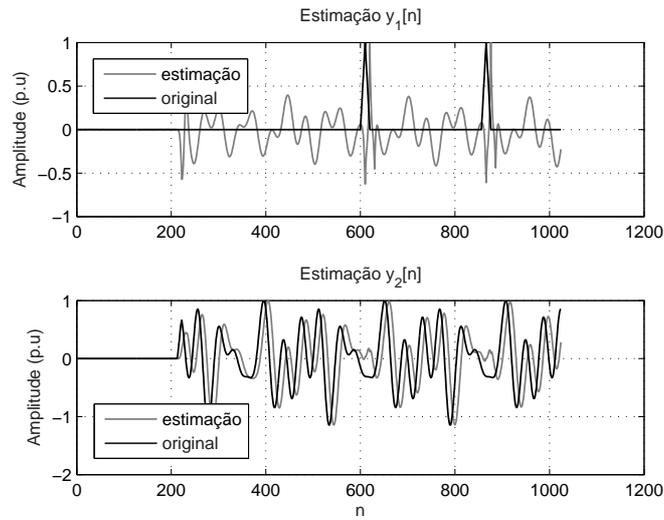


Figura 5.25: Estimacões normalizadas dos distúrbios fornecidas pela ICA, comparadas aos distúrbios originais (*spike* e harmônicos).

vez, o caso de  $M$  pontos de medição apresentou bom desempenho na recuperaçãõ de ambos os distúrbios em todas as simulações. Já para o caso de 1 monitor, todas as estimacões de *spikes* foram ruins, e algumas estimacões de harmônicos foram boas. No geral, as estimacões dos harmônicos apresentaram resultados melhores do

que as estimações dos *spikes*, pelo fato de conter mais informação dos harmônicos do que dos *spikes* nos sinais de mistura fornecidos pelos filtros. Como comparação entre as técnicas de  $M$  monitores e 1 monitor, a primeira novamente apresentou resultados superiores em relação à segunda, já que a primeira utiliza os sinais de mistura gerados pelo próprio SEP, enquanto que a segunda utiliza filtros para obter os sinais de misturas, que podem inserir alguma perda de informação em relação aos distúrbios originais.

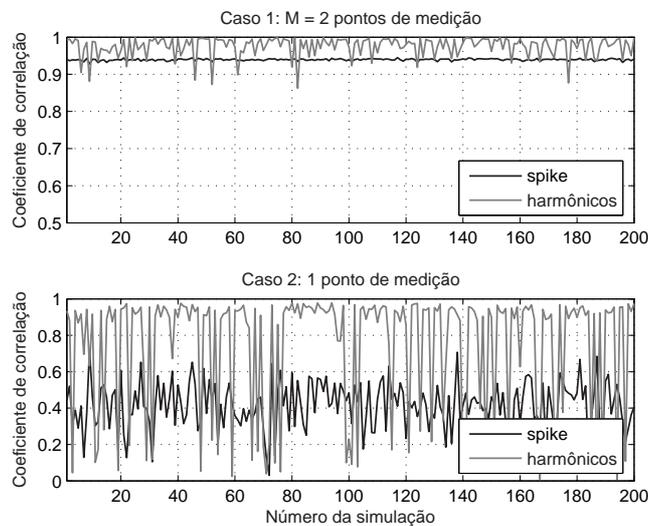


Figura 5.26: Coeficientes de correlação entre os distúrbios originais e suas estimações: *spike* e harmônicos.

Como última simulação, considere o sinal da Figura 5.27, que contém os distúrbios transitório de chaveamento capacitivo e *notches*. Este sinal foi então fornecido à estrutura de separação de distúrbios da Figura 5.7. Os dois distúrbios contidos neste sinal também ocupam a mesma faixa de frequência, como pode ser observado na Figura 5.28. Utilizando-se os mesmos filtros das análises anteriores, obteve-se os sinais de mistura, apresentados na Figura 5.29. A Figura 5.30 mostra as estimações fornecidas pela ICA. Como pode-se observar, ela não conseguiu separar os distúrbios.

A Figura 5.31 mostra os coeficientes de correlação calculados entre os distúrbios originais e suas respectivas estimações fornecidas pela ICA, para 200 simulações.

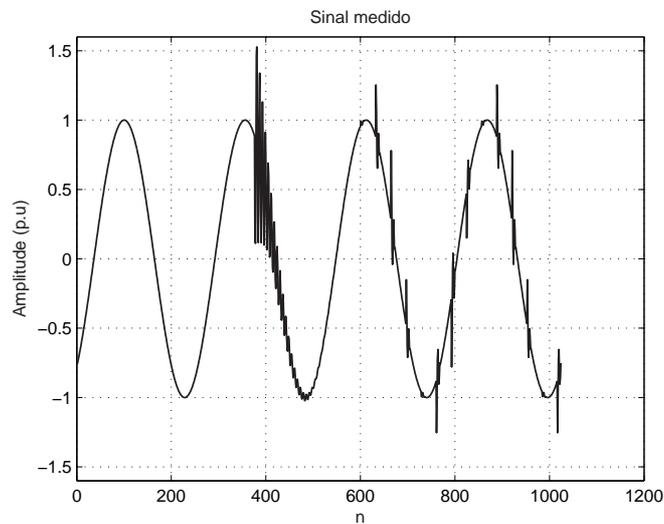


Figura 5.27: Sinal medido contendo dois distúrbios (transitório de chaveamento capacitivo e *notches*).

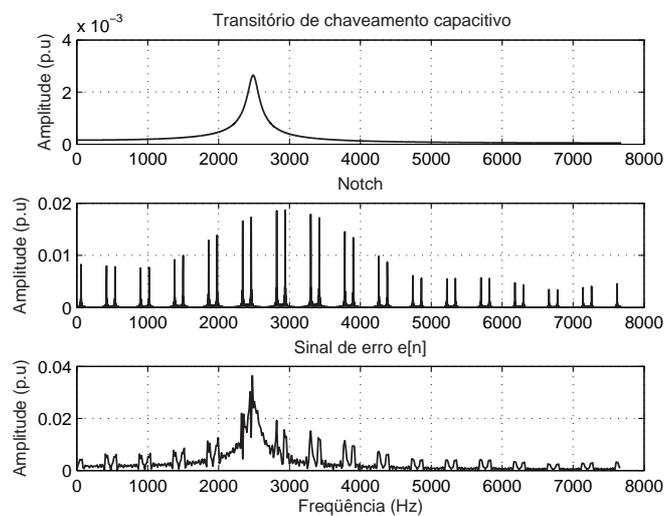


Figura 5.28: Módulos das DFTs dos distúrbios e do sinal de erro (transitório de chaveamento capacitivo e *notches*).

Para a técnica de  $M$  monitores, foram alcançados resultados satisfatórios, assim como em todas as análises anteriores. Já para o caso de 1 monitor, os resultados não foram bons. Como a ICA se baseia na suposição de que as fontes são estatisticamente

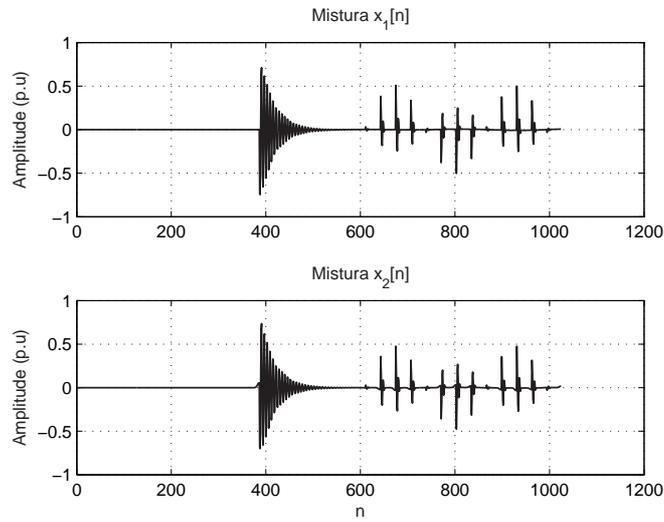


Figura 5.29: Misturas provenientes do banco de filtros (transitório de chaveamento capacitivo e *notches*).

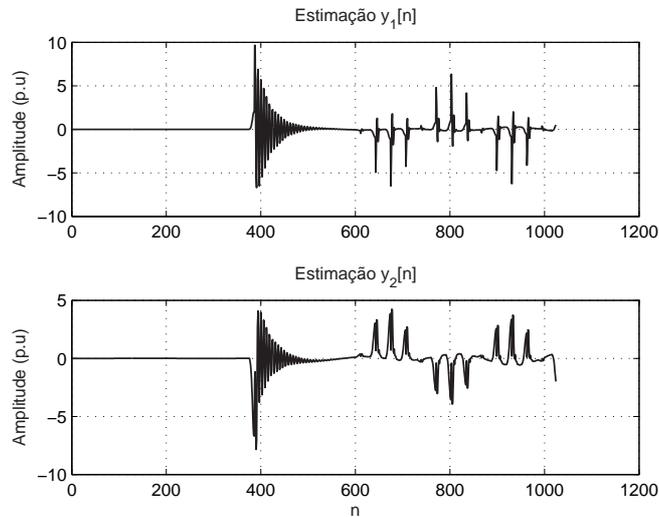


Figura 5.30: Estimaciones dos distúrbios fornecidas pela ICA (transitório de chaveamento capacitivo e *notches*).

independentes e não-gaussianas para conseguí-las a partir das misturas, pode-se dizer que o banco de filtros utilizado na estrutura de 1 ponto de medição modifica o sinal de tal forma que não consegue manter estas restrições acerca das

fontes, para os casos em que os distúrbios compartilham energias de forma acentuada em regiões comuns do espectro de frequências.

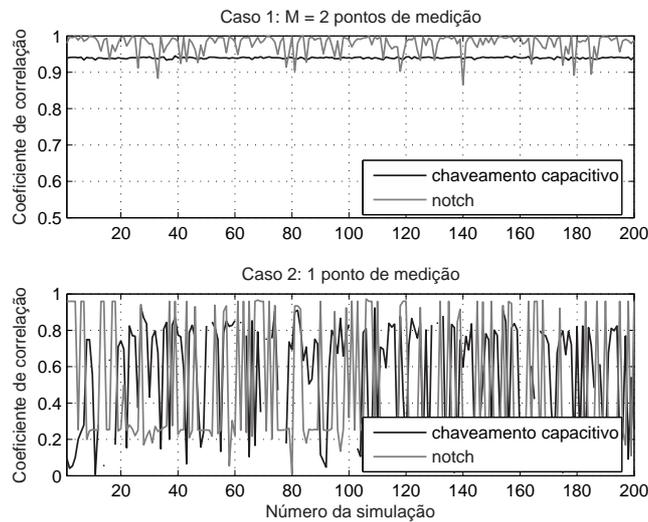


Figura 5.31: Coeficientes de correlação entre os distúrbios originais e suas estimações: transitório de chaveamento capacitivo e *notches*.

### 5.3 Sumário

Neste capítulo, foram apresentados os métodos propostos para análise e separação de múltiplos distúrbios de QEE baseados na técnica da ICA. O primeiro método ilustra o caso ideal onde se tem  $M$  medidores em diferentes locais e sincronizados, enquanto que o segundo método aproxima-se mais do caso real, quando há inexistência de mais de 1 medidor. Resultados a partir de sinais simulados foram apresentados, mostrando os pontos positivos e negativos dos métodos propostos.

# 6

## Conclusões

O presente trabalho apresentou uma nova técnica em análise de QEE para sinais de tensão que contém mais de um tipo de distúrbio, que podem ocorrer em sequência ou ao mesmo tempo no sinal analisado. O propósito foi separar os distúrbios utilizando a filosofia de separação cega de fontes, que parte do pressuposto de que não são conhecidas as fontes que compõem os dados disponíveis e nem como elas foram misturadas. Neste caso, as fontes seriam os distúrbios isolados e os dados disponíveis os sinais analisados contendo os múltiplos distúrbios. Foi utilizada para tal fim a recente técnica de análise de componentes independentes. Por meio desta técnica, visou-se então separar os diferentes distúrbios independentes que estivessem ocorrendo durante o mesmo intervalo de tempo, a partir de um determinado modelo de mistura dos distúrbios originais.

Para analisar a técnica proposta, foram utilizados sinais de tensão sintéticos compreendendo sempre combinações de dois dos quatro distúrbios contidos no

seguinte grupo: transitório de chaveamento capacitivo, *notches*, *spike* e harmônicos. Neste trabalho, que apresenta o início dos estudos destas novas técnicas de análise de múltiplos distúrbios utilizando a ICA, restringiu-se o número de distúrbios contidos em cada sinal analisado a dois, para tentar resolver inicialmente todos os casos que apresentem esta configuração. Futuramente, deseja-se aumentar gradativamente a quantidade de múltiplos distúrbios envolvidos, e, conseqüentemente, a complexidade do problema. Também, ao contemplar tal situação, deve-se inicialmente realizar um estudo bibliográfico mais aprofundado acerca de quais distúrbios podem ocorrer ao mesmo tempo na prática.

Foram apresentadas duas estruturas para separar múltiplos distúrbios, no que diz respeito à quantidade de sinais medidos disponíveis: a primeira é aplicada quando são disponíveis mais de um dispositivo de monitoramento alocados em pontos distintos do SEP e sincronizados, e a segunda é aplicada quando se tem disponível um único monitor de QEE. No segundo caso, foi proposta a utilização de um banco de filtros para artificialmente fornecer um número suficiente de misturas para a ICA na estimação dos distúrbios envolvidos a partir de um único sinal medido.

Para o caso de  $M$  monitores, descrito na seção 5.1.1, os sinais de entrada fornecidos ao algoritmo foram gerados como sendo misturas instantâneas dos distúrbios, ou seja, os coeficientes da matriz de misturas não continham atrasos, sendo os sinais observados considerados como misturas apenas de amostras atuais das fontes. Na prática, isto significaria que são desprezíveis as reatâncias entre os pontos de inserção dos distúrbios na rede e os pontos de medição. Portanto, foi assumida a hipótese de que os pontos de monitoração estivessem próximos das fontes de distúrbios e entre si. Para uma aproximação mais realista de um SEP real, deve-se considerar o modelo de misturas convolutivas (Hyvärinen et al., 2001) da ICA, em que os sinais observados representam uma mistura de amostras atuais e passadas das fontes. Este modelo é também chamado de sistema com memória. Portanto, neste caso, os coeficientes da matriz de mistura são compostos por filtros que representam as impedâncias entre os pontos de inserção dos distúrbios e os pontos de medição.

Para o caso de 1 monitor, descrito na seção 5.1.2, o sinal de entrada do

algoritmo foi modelado conforme descrito na seção 3.1, ou seja, como uma soma das contribuições individuais de cada tipo de distúrbio. Entretanto, este modelo não contém informações dos canais entre os pontos de inserção dos distúrbios na rede e o ponto de medição. Desta forma, em uma situação real, não seria possível estimar os distúrbios tal como ocorrem nos seus pontos de inserção na rede, mas ainda assim é possível separar as contribuições de cada um dos distúrbios originais encontradas no sinal medido.

Foram utilizados filtros *notch* adaptativos baseados na estrutura EPLL para remover o componente fundamental dos sinais de entrada dos algoritmos propostos, pois o componente fundamental não contém informações dos distúrbios, exceto para os que o afetam, tais como: afundamento, elevação e interrupção. No caso destes distúrbios, a detecção pode ser realizada por meio da análise da variação da amplitude do componente fundamental estimado pelo EPLL. O EPLL apresenta como maior inconveniente a baixa velocidade de convergência, de forma que o seu próprio transitório pode ser estimado como um distúrbio. Uma técnica para estimar o componente fundamental que não apresentaria este inconveniente seria a técnica do gerador senoidal, proposta em (Duque, Ribeiro, Ramos, & Szczupak, 2005).

A ICA não garante a recuperação das amplitudes dos distúrbios, mas para propósitos de localização no tempo e classificação, isto não é considerado um problema, já que as técnicas destinadas a tais fins se baseiam nas formas de onda dos distúrbios, o que justamente é proposto a se recuperar através da ICA.

A estrutura de  $M$  monitores apresentou resultados satisfatórios para todos os casos analisados, já que os coeficientes de correlação entre os distúrbios originais e suas respectivas estimações foram próximos de 1 para todas as simulações. Portanto, conclui-se que os blocos desta estrutura não modificaram os distúrbios presentes nos sinais de entrada, de forma que pudessem ser recuperados com sucesso pela ICA.

A estrutura de 1 monitor apresentou resultados satisfatórios na separação de distúrbios que não possuem interseção muito acentuada de espectros de frequência, tais como os pares: *notches* e harmônicos, transitório de chaveamento capacitivo e harmônicos. Já para distúrbios onde a interseção de espectros é acentuada, a separação não foi bem sucedida, tal como pode ser observado para os casos: *spike*

e harmônicos, transitório de chaveamento capacitivo e *notches*. Portanto, nestes casos, o banco de filtros não consegue produzir misturas a partir do sinal de erro que preservem todas as informações dos distúrbios originais. Pode-se dizer, sob a ótica da ICA que, nestes casos, a independência estatística dos distúrbios originais não é preservada pelos filtros.

Como trabalhos futuros, espera-se empregar o modelo de misturas convolutivas da ICA para o caso de  $M$  monitores, e obter os sinais de mistura a partir de simulações de SEPs reais. Também espera-se que estudos mais aprofundados em relação ao banco de filtros e a ICA para o caso de 1 monitor permitam boas separações para todos os casos envolvidos. Enfim, espera-se investigar uma estrutura utilizando-se da ICA que funcione bem para todos os casos de múltiplos distúrbios, inclusive os distúrbios que afetam o componente fundamental. Deseja-se também aumentar gradativamente o número de distúrbios envolvidos em cada sinal analisado, e, conseqüentemente, a complexidade do problema.

Ainda como proposição para novos estudos, espera-se testar as estruturas com sinais reais e visa-se a implementação da técnica em dispositivos de *hardware*, tais como DSP ou FPGA, intencionando-se a confecção de um produto para o monitoramento de QEE que explore os problemas de múltiplos distúrbios apresentados neste trabalho.

## Referências

- Amari, S. I., Chen, T. P., & Cichocki, A. (1997). Stability analysis of learning algorithms in blind source separation. *Neural Networks*, 10(8), 1345-1351.
- Angrisani, L., Daponte, P., & D'Apuzzo, M. A. (1998). Method Based on Wavelet Networks for the Detection and Classification of Transients. In *IEEE Instrumentation and Measurement Technology Conference* (Vol. 2, p. 903-908).
- Arons, B. (1992). A review of the cocktail party effect. *Journal of the American Voice I?O Society*, 12, 35-50.
- Arrilaga, J., Bollen, M. H. J., & Watson, N. R. (2000). Power Quality Following Deregulation. In *Proceedings of the IEEE* (Vol. 88, p. 246-261).
- Arruda, E. F. (2003). *Análise de Distúrbios Relacionados com a Qualidade da Energia Elétrica Utilizando a Transformada Wavelet*. Dissertação de Mestrado, Escola de Engenharia de São Carlos, Universidade de São Paulo.
- Bell, A. J., & Sejnowski, T. J. (1995). An information-maximization approach to blind separation and blind deconvolution. *Neural Computation*, 7(6), 1129-1159.
- Bell, A. J., & Sejnowski, T. J. (1997). The "Independent Components" of Natural Scenes are Edge Filters. *Vision Research*, 37, 3327-3338.
- Bollen, M. H. J. (2000). *Understanding Power Quality Problems: Voltage Sags and Interruptions*. IEEE Press.
- Calhoun, V., Adali, T., Hansen, L., Larsen, J., & Pekar, J. (2003). ICA of Functional MRI Data: an Overview. In *4th international symposium on Independent Component Analysis and Blind Source Separation (ICA2003)*.
- Cardoso, J. F. (1997). Infomax and maximum likelihood of blind source separation. *IEEE Signal Processing Letters*, 4(4), 112-114.
- Cardoso, J.-F. (1998a, October). Blind signal separation: statistical principles. In *Proceedings of the IEEE* (Vol. 9, p. 2009-2025).
- Cardoso, J.-F. (1998b). On the stability of some source separation algorithms. In *Proceedings of the IEEE Workshop on Neural Networks for Signal Processing*.

- Cambridge, Inglaterra.
- Cavalcante, C. C. (2004). *Sobre Separação Cega de Fontes: Proposições e Análise de Estratégias para Processamento Multi-Usuário*. Tese de Doutorado, UNICAMP.
- Cerqueira, A. S., Duque, C. A., Ribeiro, M. V., & Trindade, R. M. (2006). Sistema Digital de Detecção e Classificação de Eventos de Qualidade de Energia. *IEEE Latin America Transactions*, 4(5), 342-349.
- Cerqueira, A. S., Duque, C. A., Trindade, R. M., & Ribeiro, M. V. (2005). Digital system for detection and classification of electrical events. In *IEEE International Symposium on Circuits and Systems* (p. 5417-5420). Kobe.
- Cerqueira, A. S., Ferreira, D. D., Ribeiro, M. V., & Duque, C. A. (2008). Power Quality Events Recognition Using a SVM-Based Method. *Electric Power Systems Research*, 78, 1546-1552.
- Chen, W., Nemoto, T., Kobayashi, T., Honda, Y., Saito, T., & Kasuya, E. (2001). Fetal ECG Extraction From Maternal Body Surface Measurement Using Independent Component Analysis. In *23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (Vol. 2, p. 1900-1993).
- Chuang, C. L., Lu, Y. L., Huang, T. L., Hsiao, Y. T., & Jiang, J. A. (2005). Recognition of Multiple PQ Disturbances Using Dynamic Structure Neural Networks - Part 1: Theoretical Introduction. In *IEEE/PES Transmission and Distribution Conference and Exhibition: Asia and Pacific*.
- Chuang, C. L., Lu, Y. L., Huang, T. L., Hsiao, Y. T., & Jiang, J. A. (2005). Recognition of Multiple PQ Disturbances Using Dynamic Structure Neural Networks - Part 2: Implementation and Applications. In *IEEE/PES Transmission and Distribution Conference and Exhibition: Asia and Pacific*.
- Cichocki, A., & Amari, S. I. (2002). *Adaptive Blind Signal and Image Processing: Learning Algorithms and Applications*. John Wiley & Sons, Inc.
- Comon, P. (1994). Independent component analysis, A new concept? *Signal Processing*, 36, 287-314.
- Comon, P. (2004). Blind identification and source separation in 2x3 under-determined mixtures. *IEEE Transactions on Signal Processing*, 52(1), 11-22.

- Cover, T. M., & Thomas, J. A. (1991). *Elements of Information Theory* (Second Edition ed.). John Wiley & Sons.
- Diamantaras, K. I., & Kung, S. Y. (1996). *Principal Component Neural Networks: Theory and Applications*. Wiley.
- Dodel, S., Hermann, J. M., & Geisel, T. (2000). Localization of brain activity - Blind separation of fMRI data. *Neurocomputing*, *32*, 701-708.
- Dugan, R. C., McGranaghan, M. F., Santoso, S., & Beaty, H. (2004). *Electrical Power Systems Quality* (2 ed.). McGraw-Hill.
- Duque, C. A., Ribeiro, M. V., Ramos, F. R., & Szczupak, J. (2005). Power quality event detection based on the principle of divide to conquer and innovation concept. *IEEE Transactions on Power Delivery*, *20*(4).
- Ellis, D. P. W. (1996). *Prediction-driven computational auditory scene analysis*. PHD thesis, Massachusetts Institute of Technology.
- Ferreira, D. D., Cerqueira, A. S., Ribeiro, M. V., & Duque, C. A. (2006). Técnica para a Classificação de Distúrbios Elétricos Relacionados à Qualidade de Energia. In *CBA2006, XVI Congresso Brasileiro de Automática*. Salvador, Brasil.
- Filho, O. D. (2003). *Utilização da Transformada de Wavelet para Caracterização de Distúrbios na Qualidade da Energia Elétrica*. Dissertação de Mestrado, Escola de Engenharia de São Carlos - Universidade de São Paulo.
- Golub, G. H., & Loan, C. F. V. (1996). *Matrix Computations*. Johns Hopkins Series in the Mathematical Sciences. Johns Hopkins University Press.
- Guilhon, D., Medeiros, E., & Barros, A. K. (2005). ECG Data Compression by Independent Component Analysis. In *Proceedings of the IEEE Workshop on Machine Learning for Signal Processing*. Mystic, EUA.
- Haddad, D. B., Petraglia, M. R., & Batalheiro, P. B. (2008a, September). Duas contribuições para a separação cega de fontes em misturas instantâneas e indeterminadas. In *Anais do XVII Congresso Brasileiro de Automática*.
- Haddad, D. B., Petraglia, M. R., & Batalheiro, P. B. (2008b, September). Recuperação das fontes em misturas indeterminadas: Avaliação de propostas e experimentos. In *Anais do XVII Congresso Brasileiro de Automática*.

- Han, S.-H., Kim, H.-H., & Bae, H.-D. (2005). Extraction of Rotating Machine Sources for Fault Diagnostics using Independent Component Analysis. In *IMTC 2005 - Instrumentation and Measurement Technology Conference*. Ottawa, Canada.
- He, H., & Starzyk, J. A. (2006). A Self-Organizing Learning Array System for Power Quality Classification Based on Wavelet Transform. *IEEE Transactions on Power Delivery*, 21(1), 286-295.
- Hu, G. S., Xie, J., & Zhu, F. F. (2005). Classification of Power Quality Disturbances Using Wavelet and Fuzzy Support Vector Machines. In *4th International Conference on Machine Learning and Cybernetics*. Guangzhou, China.
- Hyvärinen, A. (1999, May). Fast and robust fixed-point algorithms for independent component analysis. *IEEE Transactions on Neural Networks*, 10(3), 626-634.
- Hyvärinen, A., Karhunen, J., & Oja, E. (2001). *Independent Component Analysis*. John Wiley & Sons, Inc.
- Hyvärinen, A., & Oja, E. (1997). A fast fixed-point algorithm for independent component analysis. *Neural Computation*, 9(7), 1483-1492.
- Hyvärinen, A., & Oja, E. (2000). Independent Component Analysis: Algorithms and Applications. *Neural Networks*, 13(4-5), 411-430.
- James, C. J., & Gibson, O. J. (2003). Temporally constrained ICA: an application to artifact rejection in electromagnetic brain signal analysis. *IEEE Transactions on Biomedical Engineering*, 50(9), 1108-1116.
- Jolliffe, I. T. (2002). *Principal Component Analysis* (2 ed.). New York: Springer.
- Karimi-Ghartemani, M., & Iravani, M. R. (2002). A nonlinear adaptive filter for online signal analysis in power systems: Applications. *IEEE Transactions on Power Delivery*, 17(2), 617-622.
- Kezunovic, M., & Liao, Y. (2002). A Novel Software Implementation Concept for Power Quality Study. *IEEE Transactions on Power Delivery*, 17(2), 544-549.
- Khan, A. K. (2001). Monitoring power for the future. *Power Engineering Journal*, 15(2), 81-85.
- Kim, C. H., & Aggarwal, R. (2001a). Wavelet Transforms in Power Systems - Part 1: General Introduction to the Wavelet Transforms. *Power Engineering Journal*,

- 14(2), 81-87.
- Kim, C. H., & Aggarwal, R. (2001b). Wavelet Transforms in Power Systems - Part 2: Examples of Application to Actual Power Systems Transients. *Power Engineering Journal*, 15(4), 193-202.
- Lathauwer, L. de, Moor, B. de, & Vandewalle, J. (2000). Fetal electrocardiogram extraction by blind source subspace separation. *IEEE Transactions on Biomedical Engineering*, 47(5), 567-572.
- Lee, T. W., Girolami, M., & Sejnowski, T. J. (1999). Independent component analysis using an extended infomax algorithm for mixed subgaussian and supergaussian sources. *Neural Computation*, 11(2), 417-441.
- Lee, T.-W., Lewicki, M., Girolami, M., & Sejnowski, T. (1999). Blind source separation of more sources than mixtures using overcomplete representations. *IEEE Signal Processing Letters*, 6(4), 87-90.
- Liao, H. W., & Niebur, D. (2003). Load profile estimation in electric transmission networks using independent component analysis. *IEEE Transactions on Power Systems*, 18(2), 707-715.
- Lima, M. A. A., Cerqueira, A. S., Ferreira, D. D., Duque, C. A., Ribeiro, M. V., & Seixas, J. M. (2008). Separação de Múltiplos Distúrbios de Qualidade de Energia Utilizando Análise de Componentes Independentes. In *CBA2008, XVII Congresso Brasileiro de Automática*.
- Lima, M. A. A., Ferreira, D. D., Cerqueira, A. S., Duque, C. A., Ribeiro, M. V., & Seixas, J. M. (2008). Separation and Recognition of Multiple PQ Disturbances Using Independent Component Analysis and Neural Networks. In *ICHQP2008, 13th IEEE International Conference on Harmonics and Quality of Power*.
- Lin, W. M., Wu, C. H., Lin, C. H., & Cheng, F. S. (2008). Detection and Classification of Multiple Power-Quality Disturbances With Wavelet Multiclass SVM. *IEEE Transactions on Power Delivery*, 23(4), 2575-2582.
- Makino, S., Araki, S., Mukai, R., & Sawada, H. (2004). Audio source separation based on independent component analysis. In *International Symposium on Circuits and Systems (ISCAS2004)* (p. 678-671).

- Mitianoudis, N., & Davies, M. E. (2003). Audio source separation of convolutive mixtures. *IEEE Transactions on Speech and Audio Processing*, 11(5), 489-497.
- Mitra, S. K. (1998). *Digital Signal Processing: A Computer-Based Approach*. McGraw-Hill.
- Neves, A. O., Attux, R. R. F., Suyama, R., Miranda, M. D., & Romano, J. M. T. (2006). Sobre critérios para equalização não-supervisionada. *Sba: Controle & Automação Sociedade Brasileira de Automática*, 17(3), 278-299.
- Oleskovicz, M., Coury, D. V., Carneiro, A. A. F. M., Arruda, E. F., Filho, O. D., & Souza, S. A. (2006). Estudo Comparativo de Ferramentas Modernas de Análise Aplicadas à Qualidade da Energia Elétrica. *SBA, Sociedade Brasileira de Automática*, 17, 331-341.
- Papoulis, A., & Pillai, S. U. (2002). *Probability, Random Variables and Stochastic Process* (Fourth Edition ed.). McGraw Hill.
- Pei, S.-C., & Zeng, Y.-C. (2006). A Novel Image Recovery Algorithm for Visible Watermarked Images. *IEEE Transactions on Information Forensics and Security*, 1(4), 543-550.
- Plumbey, M. D., Abdallah, S. A., Bello, J. P., Davies, M. E., Mont, G., & Sandler, M. B. (2002). Automatic music transcription and audio source separation. *Cybernetics and Systems*, 33(6), 603-627.
- Power Quality, I. S. C. C. . on. (1995). *Ieee recommended practice for monitoring electric power quality* (Technical Report No. IEEE Std 1159-1995). IEEE Standards Board.
- Rabi, B. J., Paraithimarkalaignan, T., & Arumugam, R. (2004). Harmonic elimination of inverters using blind signal separation. In *7th International Conference on Solid-State and Integrated Circuits Technology*.
- Ribeiro, M. V. (2005). *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.
- Sanchez-Poblador, V., Monte-Moreno, E., & Solé-Casal, J. (2004). ICA as a Preprocessing Technique for Classification. In *Proceedings of the Fifth International Workshop on Independent Component Analysis and Blind Signal*

*Separation*. Granada, Espanha.

- Santoso, S., Grady, W. M., Powers, E. J., Lamoree, J., & Bhatt, S. C. (2000). Characterization of Distribution Power Quality Events with Fourier and Wavelet Transforms. *IEEE Transactions on Power Delivery*, 15(1), 247-254.
- Santoso, S., Powers, E. J., Grady, W. M., & Parsons, A. C. (2000a). Power quality disturbance waveform recognition using wavelet-based neural classifier Part 1: Theoretical foundation. *IEEE Transactions on Power Delivery*, 15(1), 222-228.
- Santoso, S., Powers, E. J., Grady, W. M., & Parsons, A. C. (2000b). Power quality disturbance waveform recognition using wavelet-based neural classifier Part 2: Application. *IEEE Transactions on Power Delivery*, 15(1), 229-235.
- Trindade, R. M. (2005). *Sistema Digital de Detecção e Classificação de Eventos de Qualidade de Energia*. Dissertação de Mestrado, Faculdade de Engenharia da Universidade Federal de Juiz de Fora.
- Wong, C. S., Obradovic, D., & Madhu, N. (2003). ICA for Blind Equalization of Frequency Selective Channels. In *IEEE 13th Workshop on Neural Networks for Signal Processing* (p. 419-428).
- Yang, H. T., & Liao, C. C. (2001). A de-noising scheme for enhancing wavelet-based power quality monitoring system. *IEEE Transactions on Power Delivery*, 16(3), 353-360.
- Zarzoso, V., & Nandi, A. K. (2004). Improving mimo channel equalization with independent component analysis. In *6th IMA International Conference on Mathematics in Signal Processing* (p. 223-226). Cirencester, UK.
- Zhou, W., Zhou, J., Zhao, H., & Ju, L. (2005). Removing eye movement and power line artifacts from the EEG based on ICA. In *27th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (p. 6071-6020).



## Produção Científica

### **A.1 Artigos em Congressos**

M. A. A. Lima, A. S. Cerqueira, D. D. Ferreira, C. A. Duque, M. V. Ribeiro, J. M. de Seixas, “Separação de Múltiplos Distúrbios de Qualidade de Energia Utilizando Análise de Componentes Independentes,” *XVII Congresso Brasileiro de Automática (CBA 2008)*, Juiz de Fora-MG, Brasil, 2008.

M. A. A. Lima, D. D. Ferreira, A. S. Cerqueira, C. A. Duque, M. V. Ribeiro, J. M. de Seixas, “Separation And Recognition of Multiple PQ Disturbances Using Independent Component Analysis And Neural Networks,” *IEEE 13th International Conference on Harmonics and Quality of Power (ICHQP 2008)*, Wollongong, Austrália, 2008.