

**COMPRESSÃO DE DADOS PARA SINAIS DE DISTÚRBIOS  
NO AMBIENTE DAS REDES ELÉTRICAS INTELIGENTES**

**JORGE ANDRÉS CORMANE ANGARITA**

**TESE DE DOUTORADO EM ENGENHARIA DE SISTEMAS ELETRÔNICOS E  
AUTOMAÇÃO**

**DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**FACULDADE DE TECNOLOGIA  
UNIVERSIDADE DE BRASÍLIA**



**UNIVERSIDADE DE BRASÍLIA**  
**FACULDADE DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**COMPRESSÃO DE DADOS PARA SINAIS DE DISTÚRBIOS  
NO AMBIENTE DAS REDES ELÉTRICAS INTELIGENTES**

**JORGE ANDRÉS CORMANE ANGARITA**

**ORIENTADOR: FRANCISCO ASSIS DE OLIVEIRA NASCIMENTO, DR.**

**TESE DE DOUTORADO ENGENHARIA DE SISTEMAS  
ELETRÔNICOS E DE AUTOMAÇÃO**

**PUBLICAÇÃO: PPGEA.TD - 069/2013**

**BRASÍLIA/DF: MARÇO - 2013**



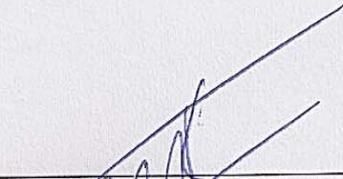
**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

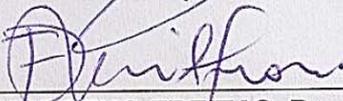
**COMPRESSÃO DE DADOS PARA SINAIS DE DISTÚRBIOS NO  
AMBIENTE DAS REDES ELÉTRICAS INTELIGENTES**

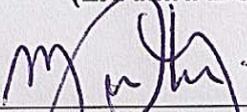
**JORGE ANDRÉS CORMANE ANGARITA**

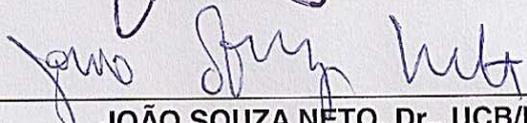
TESE DE DOUTORADO SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA ELÉTRICA DA  
FACULDADE DE TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA, COMO PARTE DOS  
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR.

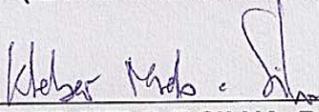
APROVADA POR:

  
\_\_\_\_\_  
FRANCISCO ASSIS DE OLIVEIRA NASCIMENTO, Dr., ENE/FT  
(ORIENTADOR)

  
\_\_\_\_\_  
FRANCISCO DAMASCENO FREITAS, Dr., ENE/FT  
(EXAMINADOR INTERNO)

  
\_\_\_\_\_  
MÁRIO OLESKOVICZ, Dr., EESC/USP  
(EXAMINADOR EXTERNO)

  
\_\_\_\_\_  
JOÃO SOUZA NETO, Dr., UCB/DF  
(EXAMINADOR EXTERNO)

  
\_\_\_\_\_  
KLEBER MELO E SILVA, Dr., ENE/FT  
(EXAMINADOR INTERNO)

Brasília, 22 de março de 2013.



## FICHA CATALOGRÁFICA

CORMANE, JORGE ANDRÉS ANGARITA

Compressão de dados para sinais de distúrbios no ambiente das redes elétricas inteligentes [Distrito Federal] 2013.

xv, 112p., 210 x 297 mm (ENE/FT/UnB, Doutor, Engenharia Elétrica, 2013).

Tese de Doutorado – Universidade de Brasília, Faculdade de Tecnologia.

Departamento de Engenharia Elétrica

1. Compressão de dados

2. Smart Grid

3. Alocação de bits

4. Formas de onda de distúrbios

I. ENE/FT/UnB

II. Título (série)

## REFERÊNCIA BIBLIOGRÁFICA

CORMANE, J.A.A. (2013). Compressão de dados para sinais de distúrbios no ambiente das redes elétricas inteligentes, Tese de Doutorado em Engenharia de Sistemas Eletrônicos e de Automação, Publicação PPGEA.TD 069/2013, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, 112p.

## CESSÃO DE DIREITOS

AUTOR: Jorge Andrés Cormane Angarita

TÍTULO: Compressão de dados para sinais de distúrbios no ambiente das redes elétricas inteligentes.

GRAU: Doutor

ANO: 2013

É concedida à Universidade de Brasília permissão para reproduzir cópias desta tese de doutorado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa tese de doutorado pode ser reproduzida sem autorização por escrito do autor.

---

Jorge Andrés Cormane Angarita

Faculdade de Tecnologia

Departamento de Engenharia Elétrica (ENE)

Universidade de Brasília (UnB)

Campus Darcy Ribeiro

CEP 70910-900 - Brasília - DF - Brasil



*Dedico esta tese, a Claudia, pelo amor e compreensão durante todos esses anos de união. Aos meus pais, Álvaro e Inés. Aos meus irmãos Álvaro Rafael e Juan David. Vocês são a razão de minha felicidade*



## AGRADECIMENTOS

*Um agradecimento especial ao meu Professor Orientador, Francisco Assis de Oliveira Nascimento, que, me deu a oportunidade de conhecer um universo de novas possibilidades.*

*Ao Professor Anésio de Leles Ferreira Filho pela sua incondicional amizade e colaboração.*

*A todos os professores do Departamento de Engenharia Elétrica da UnB que, de uma maneira ou de outra, acabaram por contribuir com minha formação acadêmica.*

*Aos colegas do GPDS, Alberto López Delis, Bruno Luigi Macchiavello Espinoza, Camilo Chang Dorea, Diogo Caetano Garcia, Edson Mintsu Hung, Fabiano Araujo Soares, Marcelo Villegas, Marcus Vinícius Chaffim Costa, Maria do Carmo dos Reis, Renan Utida Ferreira, Tiago Alves da Fonseca, pelo apoio e pela tolerância.*

*Aos colegas e alunos do laboratório de qualidade da energia elétrica.*

*Aos meus amigos, Margarita, Ivan, Alejandra, Jesus, Liliana, Jorge, Catalina, Juan Diaz, Juan Ruge, Juan Pablo, Edgar, Jones e Ênio.*

*A minha família pelo seu apoio.*



## **RESUMO**

### **COMPRESSÃO DE DADOS PARA SINAIS DE DISTÚRBIOS NO AMBIENTE DAS REDES ELÉTRICAS INTELIGENTES**

**Autor: Jorge Andrés Cormane Angarita**

**Orientador: Francisco Assis de Oliveira Nascimento, Dr.**

**Programa de Pós-graduação em Engenharia Elétrica**

**Brasília, 22 de março de 2013**

A necessidade de melhorar o desempenho do armazenamento e da transmissão das informações decorrentes monitoramento do estado do sistema elétrico de potência, faz com que a compressão de dados seja um tema de vital importância no cenário das redes elétricas inteligentes. Verificou-se que o tema apresenta particularidades e exigências específicas derivadas da operação das redes elétricas e da natureza dos fenômenos que nelas ocorrem.

O trabalho aborda o estado da arte na compressão de sinais, com o objetivo de propor novas técnicas que viabilizem a compressão eficiente das formas de onda de distúrbios. Sendo assim, as contribuições da tese distribuem-se em três técnicas híbridas de compressão de dados que combinam de forma eficiente algoritmos de compressão de dados com perdas e sem perdas, focando-se na estratégia de alocação dinâmica de bits no domínio da transformada. A saber: técnica 1, Codificação por transformadas com alocação dinâmica e inteligente de bits no espaço transformado (CTIA), que executa a alocação de bits segundo um conjunto de padrões vetoriais característicos de distribuição de energia; técnica 2, Codificação por transformadas com curvas de perfil espectral para alocação dinâmica de bits no espaço transformado (CTCA), que utiliza curvas de padrões de estimação da distribuição de energia; e técnica 3, Codificação por transformadas com abordagem dissociativa entre regime permanente e eventos transitórios (CTAD), que identifica e desagrega as características comportamentais do regime permanente e do estado transitório para a alocação de bits.

Os resultados de simulações com banco de sinais reais mostraram um bom desempenho dos algoritmos propostos no que tange a taxa de compressão de dados e a fidelidade da forma de onda reconstruída. Comparação de resultados com algoritmos relevantes encontrados na literatura científica indicam como promissoras as técnicas desenvolvidas e apresentadas neste trabalho.



## **ABSTRACT**

### **DATA COMPRESSION FOR ELECTRIC POWER DISTURBANCE WAVEFORMS IN THE SMART GRID ENVIRONMENTS**

**Author: Jorge Andrés Cormane Angarita**

**Advisor: Francisco Assis de Oliveira Nascimento, Dr.**

**Programa de Pós-graduação em Engenharia Elétrica**

**Brasília, 22th March 2013**

The necessity of improving the storage and the transmission of the information derived from the electrical power system monitoring, makes the data compression an important subject in the smart grids scenario. It was verified that this problem presents specific peculiarities and demands emerged from the grid operation and from the nature of the phenomenon that happen on it.

This work addresses the state of the art in signal compression with the purpose of proposing new techniques that enable an efficient compression of waveform disturbances. In this way, the contribution of this thesis is divided into three hybrid techniques of data compression, which combine in an efficient way lossy and lossless data compression algorithms. These proposals focused on the dynamic bit allocation strategy in transform domain. The proposed algorithms are: 1- Transform coding with dynamic and intelligent bit allocation, which executes the bit allocation according to a set of vector patterns proper of the energy distribution. 2- Transform coding with spectral profile curves for dynamic bit allocation, that uses estimation pattern curves from the energy distribution. 3- Transform coding with a dissociative approach between steady state and transients, which identifies and disaggregates the behavioral characteristics of these states for bit allocation.

The results of simulations using a database of real signals showed a good performance of the proposed algorithms with respect to the compression ratio and the fidelity of the reconstructed waveform. The results comparisons with relevant algorithms found in the literature indicate that the developed techniques presented in this work are promising in the context of signal compression.



# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
1.1	CONTEXTUALIZAÇÃO DO TRABALHO, JUSTIFICATIVA E RELEVÂNCIA DA TESE	1
1.2	REVISÃO BIBLIOGRÁFICA	4
1.2.1	ABORDAGEM I - CODIFICAÇÃO POR TRANSFORMADAS COM LIMITAÇÃO NO ESPAÇO TRANSFORMADO	5
1.2.2	ABORDAGEM II - CODIFICAÇÃO COM IDENTIFICAÇÃO E PARAMETRIZAÇÃO DE COMPONENTES ESTACIONÁRIAS E NÃO ESTACIONÁRIAS	7
1.2.3	ABORDAGEM III - MATCHING PURSUIT	8
1.2.4	ABORDAGEM IV - CODIFICAÇÃO POR TRANSFORMADAS COM APLICAÇÃO DIRETA DA CODIFICAÇÃO DE ENTROPIA NO ESPAÇO TRANSFORMADO	10
1.2.5	ABORDAGEM V - CODIFICAÇÃO COM SISTEMAS NEURO-FUZZY	10
1.2.6	RESUMO DA REVISÃO BIBLIOGRÁFICA	11
1.3	OBJETIVOS E CONTRIBUIÇÕES DA TESE	12
1.4	ORGANIZAÇÃO DO DOCUMENTO	14
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>15</b>
2.1	CONSIDERAÇÕES INICIAIS	15
2.2	COMPRESSÃO DE DADOS	15
2.2.1	COMPRESSÃO SEM PERDAS	18
2.2.1.1	CODIFICAÇÃO HUFFMAN	19
2.2.1.2	CODIFICAÇÃO ARITMÉTICA	20
2.2.1.3	CODIFICAÇÃO HUFFMAN VS. CODIFICAÇÃO ARITMÉTICA	20
2.2.2	COMPRESSÃO COM PERDAS	22
2.2.2.1	CODIFICAÇÃO POR TRANSFORMADAS	22
2.2.2.2	CODIFICAÇÃO DIFERENCIAL	23
2.2.2.3	QUANTIZAÇÃO VETORIAL	23
2.3	QUANTIZAÇÃO	24
2.3.1	QUANTIZAÇÃO BASEADA EM ALOCAÇÃO DE BITS	26
2.4	DICIONÁRIOS	27
2.4.1	ALGORITMO LINDE-BUZO-GRAY (LBG)	30
2.4.2	ALGORITMO K-MEANS	31
2.4.3	MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN (SOM)	32
2.5	BANCOS DE FILTROS	36

2.6	TRANSFORMADAS ORTOGONAIS .....	39
2.7	CONSIDERAÇÕES FINAIS .....	47
<b>3</b>	<b>MONITORAMENTO E ANÁLISE DE DISTÚRBIOS.....</b>	<b>49</b>
3.1	CONSIDERAÇÕES INICIAIS .....	49
3.2	OSCILOGRAFIA .....	49
3.3	QUALIDADE DA ENERGIA ELÉTRICA.....	51
3.3.1	DESCRIÇÃO DE DISTÚRBIOS TÍPICOS.....	53
3.4	ANÁLISE ESPECTRAL DOS DISTÚRBIOS .....	55
3.5	CONSIDERAÇÕES FINAIS .....	56
<b>4</b>	<b>ALGORITMOS PROPOSTOS .....</b>	<b>59</b>
4.1	CONSIDERAÇÕES INICIAIS .....	59
4.2	BASE DE DADOS DE DISTÚRBIOS.....	59
4.3	CRITÉRIOS DE AVALIAÇÃO DO DESEMPENHO .....	61
4.4	CODIFICAÇÃO POR TRANSFORMADAS COM ALOCAÇÃO DINÂMICA E INTELIGENTE DE BITS NO ESPAÇO TRANSFORMADO (CTIA) .....	64
4.4.1	ALGORITMO DE CODIFICAÇÃO .....	64
4.4.1.1	ALOCAÇÃO DINÂMICA VETORIAL E INTELIGENTE DE BITS .....	66
4.4.1.2	TREINAMENTO DO MAPA AUTO-ORGANIZÁVEL DE KOHONEN .....	69
4.4.2	ALGORITMO DE DECODIFICAÇÃO.....	70
4.4.3	SELEÇÃO DO QUANTIZADOR VETORIAL ADAPTATIVO .....	71
4.4.4	SELEÇÃO DA WAVELET .....	72
4.4.5	SELEÇÃO DO TAMANHO DA JANELA.....	74
4.4.6	RESULTADOS DE SIMULAÇÃO .....	76
4.5	CODIFICAÇÃO POR TRANSFORMADAS COM CURVAS DE PERFIL ESPECTRAL PARA ALOCAÇÃO DINÂMICA DE BITS NO ESPAÇO TRANSFORMADO (CTCA) .....	79
4.5.1	ALGORITMO DE CODIFICAÇÃO .....	80
4.5.2	CURVAS DE PERFIL ESPECTRAL .....	80
4.5.3	ALGORITMO DE DECODIFICAÇÃO.....	82
4.5.4	RESULTADOS DE SIMULAÇÃO .....	83
4.6	CODIFICAÇÃO POR TRANSFORMADAS COM ABORDAGEM DISSOCIATIVA ENTRE REGIME PERMANENTE E EVENTOS TRANSITÓRIOS (CTAD) .....	85
4.6.1	ALGORITMO DE CODIFICAÇÃO .....	86
4.6.1.1	ALGORITMO DE DETECÇÃO DE TRANSITÓRIOS.....	88
4.6.2	ALGORITMO DE DECODIFICAÇÃO.....	91
4.6.3	RESULTADOS DE SIMULAÇÃO .....	91
4.7	COMPARAÇÃO DE DESEMPENHO DOS ALGORITMOS .....	94
4.8	CONSIDERAÇÕES FINAIS .....	101

<b>5 CONCLUSÃO E TRABALHOS FUTUROS .....</b>	<b>103</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>112</b>



## LISTA DE FIGURAS

1.1	Diagrama de blocos do algoritmo de codificação por transformadas com limiarização dos coeficientes. (a). Codificador. (b). Decodificador. Fonte: O autor, 2012 .....	5
1.2	Diagrama ilustrativo e simplificado da técnica de compressão proposta em (RIBEIRO <i>et al.</i> , 2004). Fonte: (RIBEIRO <i>et al.</i> , 2004) (Modificado). .....	7
1.3	Diagrama ilustrativo e simplificado da técnica de compressão proposta em (RIBEIRO <i>et al.</i> , 2007). Fonte: (RIBEIRO <i>et al.</i> , 2007) (Modificado). .....	8
1.4	Representação gráfica da projeção ortogonal de $x[n]$ na direção de $g_\gamma[n]$ . Fonte: (TCHEOU <i>et al.</i> , 2007). .....	9
1.5	Forma de onda de um sinal senoidal amortecido. Fonte: (TCHEOU <i>et al.</i> , 2007). .....	9
2.1	Características da informação. Fonte: O autor, 2012. ....	18
2.2	Classificação dos métodos de compressão. Fonte: O autor, 2012. ....	19
2.3	Curva de operação dos métodos de compressão com perdas. Fonte: O autor, 2012. ....	22
2.4	(a) Quantização escalar. (b) Quantização vetorial. Fonte: O autor, 2012. ....	23
2.5	Mapeamento do espaço vetorial. Fonte:(GERSHO; GRAY, 1992). ....	25
2.6	Esquema para ilustrar o algoritmo de quantização vetorial com codificador do tipo Voronoi ou de vizinho mais próximo. Fonte:(GERSHO; GRAY, 1992). .	26
2.7	Alocação de bits para quantização. (a) Comprimento fixo. (b) Comprimento Variável. Fonte: O autor, 2012. ....	27
2.8	Tipos de aprendizado. (a) Supervisionado. (b) Não Supervisionado. Fonte: (BARRETO, 2002). ....	33
2.9	Arquitetura de uma rede competitiva. Conexões Excitatórias (linha cheia). Conexões Inibitórias (linha pontilhada). Fonte: (HAYKIN, 1999). ....	34
2.10	Mapeamento do espaço de entrada para uma grade bidimensional retangular. Fonte: (HAYKIN, 1999). ....	34
2.11	Diagrama de blocos de um sistema de análise e síntese para a modelagem de sinais. Fonte: (TCHEOU, 2011) .....	36
2.12	Banco de filtros de análise e síntese. (a) Bloco de Análise. (b) Bloco de Síntese. Fonte: (DINIZ <i>et al.</i> , 2010) (Modificado). ....	37
2.13	Sistema genérico de decomposição e reconstrução de sinais em múltiplas bandas baseado em bancos de filtros. Fonte: (DINIZ <i>et al.</i> , 2010) (Modificado). .....	37
2.14	Sistema de codificação e decodificação de duas bandas (M=2) usando filtros realizáveis. Fonte: (VAIDYANATHAN, 1993) (Modificado). ....	38

2.15	Transformada de Fourier de curta duração (TFCD). (a) Deslocamento de $g(t)$ no domínio do tempo. (b) Plano da resolução tempo-frequência. Fonte: (DINIZ <i>et al.</i> , 2010) (Modificado).....	40
2.16	Transformada wavelet (TW). (a) Processo de escalamento e deslocamento. $x(t)$ (linha cheia). $\psi_{s,\tau}(t)$ (linha pontilhada). (b) Plano da resolução tempo-frequência. Fonte: (DINIZ <i>et al.</i> , 2010) (Modificado).....	42
2.17	Análise Multiresolução (AMR). (a) Esquema de decomposição dos subespaços. (b) Decomposição no domínio da frequência. Fonte: (DINIZ <i>et al.</i> , 2010) (Modificado).....	44
2.18	Esquema de cálculo para a TDW para três níveis de decomposição. (a). Banco de filtros de análise. (b). Estrutura de organização dos coeficientes. Fonte: (DINIZ <i>et al.</i> , 2010) (Modificado).....	46
3.1	Descrição simplificada de uma rede de oscilografia. Fonte: O autor, 2012. ....	51
3.2	Responsabilidades dos agentes no que diz respeito à QEE. Fonte: (DUNGAN <i>et al.</i> , 2002) (Modificado).....	52
3.3	Interação Concessionaria-Consumidor. Fonte: (BOLLEN, 2000) (Modificado).	52
4.1	Formas de onda do distúrbio de tensão (Evento 21839).....	60
4.2	Formas de onda do distúrbio de corrente (Evento 21867). ....	61
4.3	Diagrama de blocos da CTAI. (a) Algoritmo de codificação. (b) Algoritmo de decodificação. ....	64
4.4	Cálculo da sequência $B[r]$ para $N=1024$ , $M=8$ e $Q=8$ . ....	66
4.5	Estratégia de alocação dinâmica vetorial e inteligente de bits. ....	67
4.6	Sequência $\hat{B}[r]$ para $N=1024$ , $M=8$ e $Q=8$ . ....	68
4.7	Estrutura dos dados compactados pelo algoritmo CTIA. ....	69
4.8	Esquema de janela deslizante.....	70
4.9	Tamanho do dicionário em termos da quantidade de vetores código. k-means (Barras preta). Redes SOM (Barra brancas). ....	71
4.10	Resultados da seleção da wavelet. Daubechies de 4 coeficientes (Db-4). Daubechies de 8 coeficientes (Db-8). Biortogonal 5/3 de 10 coeficientes (Bior-10). Daubechies de 20 coeficientes (Db-20). Biortogonal de 18 coeficientes (Bior-18). Coiflets de 30 coeficientes (Coif-30). Symlets de 16 coeficientes (Sym-16). Evento 21839. ....	73
4.11	Resultados da seleção da wavelet. Daubechies de 4 coeficientes (Db-4). Daubechies de 8 coeficientes (Db-8). Biortogonal 5/3 de 10 coeficientes (Bior-10). Daubechies de 20 coeficientes (Db-20). Biortogonal de 18 coeficientes (Bior-18). Coiflets de 30 coeficientes (Coif-30). Symlets de 16 coeficientes (Sym-16). Evento 21867. ....	74
4.12	Resultados da seleção do tamanho da janela para a wavelet Daubechies de 8 coeficientes. Evento 21839.....	75

4.13	Resultados da seleção do tamanho da janela para a wavelet Daubechies de 8 coeficientes. Evento 21867.....	75
4.14	Fase A (Linha Solida). Fase B (Linha Tracejada). Fase C (Linha Pontilhada). (a) Sinais Originais. (b) Sinais Reconstruídos. (c) Distorção dos três sinais. Evento 21839. ....	77
4.15	Fase A (Linha Solida). Fase B (Linha Tracejada). Fase C (Linha Pontilhada). (a) Sinais Originais. (b) Sinais Reconstruídos. (c) Distorção dos três sinais. Evento 21867. ....	77
4.16	Curvas de desempenho da técnica CTIA. Banco de sinais (linhas sólidas cinza). Sinal da fase A (Linha sólida preta). Sinal da Fase B (Linha tracejada preta). Sinal da Fase C (Linha pontilhada preta). Evento 21839.....	78
4.17	Curvas de desempenho da técnica CTIA. Banco de sinais (linhas sólidas cinza). Sinal da fase A (Linha sólida preta). Sinal da Fase B (Linha tracejada preta). Sinal da Fase C (Linha pontilhada preta). Evento 21867.....	79
4.18	Diagrama de blocos da CTCA.....	80
4.19	Curvas de alocação de bits. ....	82
4.20	Estrutura dos dados compactados pelo algoritmo CTCA. ....	82
4.21	Resultados da Simulação para $Q_{max}=15$ e $2<Q_{min}<15$ . ....	83
4.22	Resultados da Simulação para $2<Q_{max}<15$ e $Q_{min}=2$ . ....	84
4.23	Resultados da Simulação para $8<Q_{max}<15$ e $2<Q_{min}<9$ . ....	85
4.24	Diagrama de blocos da CTAD. Algoritmo de codificação. ....	87
4.25	Operação do algoritmo de codificação. ....	88
4.26	Diagrama de blocos do algoritmo de detecção de transitórios.....	89
4.27	Operação do algoritmo de detecção de transitórios. ....	90
4.28	Estrutura dos dados compactados pelo algoritmo CTAD. ....	90
4.29	Diagrama de blocos da CTAD. Algoritmo de decodificação. ....	92
4.30	Quantidade de bits para compressão por período da frequência fundamental para o Evento 21839 ( $Q_{FFTmax}=16$ e $Q_{TDWmax}=8$ ). Fundamental e Harmônicas (Barras Brancas). Distúrbio (Barras Azuis). ....	93
4.31	Quantidade de bits para compressão por período da frequência fundamental para o Evento 21867 ( $Q_{FFTmax}=16$ e $Q_{TDWmax}=8$ ). Fundamental e Harmônicas (Barras Brancas). Distúrbio (Barras Azuis). ....	94
4.32	Resultados da análise comparativa das técnicas de compressão (Evento 21839). 96	
4.33	Resultados da análise comparativa das técnicas de compressão (Evento 21867). 97	
4.34	Resultados da análise comparativa das técnicas de compressão (Evento 21839). 99	
4.35	Resultados da análise comparativa das técnicas de compressão (Evento 21867). 100	



## LISTA DE TABELAS

1.1	Velocidades de transmissão e capacidades de armazenamento de diferentes tipos de tecnologias .....	2
1.2	Sinopse da revisão bibliográfica .....	12
2.1	Descrição do algoritmo GLA. Fonte: (AGUNDIS, 2008). .....	29
2.2	Descrição do algoritmo LBG. Fonte: (DATA-COMPRESSION..., 2011).....	30
2.3	Descrição do algoritmo k-means. Fonte: (VIOLATO, 2010). .....	31
2.4	Descrição do algoritmo de treinamento para uma rede SOM. Fonte: (HAYKIN, 1999).....	35
3.1	Classificação dos tipos de oscilogramas. Fonte: Moreto & Rolim (2010).....	50
3.2	Principais fenômenos que causam distúrbios eletromagnéticos conforme classificado do IECs IEC 61000-2-5. Fonte: (IEC 61000-2-5, 2008), (IEEE STD 1159, 2009) (Modificado).....	54
3.3	Categorias e características típicas de fenômenos eletromagnéticos dos sistemas de potência. Fonte: (IEEE STD 1159, 2009) (Modificado).....	55
4.1	Descrição dos registros oscilográficos utilizados. ....	60
4.2	Medição de desempenho da técnica para $N=1024$ , $M=8$ e $Q=8$ . ....	76
4.3	Resultados de simulação da técnica CTAD para $Q_{FFTmax} = 16$ e $Q_{TDWmax} = 8$ . ....	91



## LISTA DE SÍMBOLOS

### Símbolos

$x[n]$	Segmento do sinal original
$s[n]$	Sequência do sinal em regime permanente
$u[n]$	Sequência de resíduo
$d[m]$	Sequência do transitório
$X[k]$	Coefficientes transformados
$X_s[k]$	Coefficientes transformados ajustados
$X_q[k]$	Coefficientes transformados quantizados
$X_u[k]$	Coefficientes transformados da sequência de resíduo
$X_d[k]$	Coefficientes transformados da sequência do transitório
$B[r]$	Sequência de quantizadores (Vetor de alocação de bits)
$B_{TDW}[r]$	sequência de quantizadores para os coeficientes da TDW (Vetor de alocação de bits)
$B_{TDW}[r]$	sequência de quantizadores para os coeficientes da FFT (Vetor de alocação de bits)
$Q$	Comprimento da palavra digital
$Q_{max}$	Comprimento máximo da palavra digital
$Q_{min}$	Comprimento mínimo da palavra digital
$N$	Tamanho da janela
$M$	Quantidade de subbandas
$X_{rms}$	Valor eficaz segmento do sinal original
$X_1$	Valor eficaz da componente fundamental
$O_s$	Quantidade de bits para representar o sinal original
$C_s$	Quantidade de bits para representar o sinal codificado
$N_c$	Número de amostras por ciclo da frequência fundamental
$\lambda$	Fator de escala
$\hat{x}[n]$	Estimativa do segmento do sinal codificado
$\hat{X}[k]$	Estimativa dos coeficientes transformados
$\hat{X}_s[k]$	Estimativa dos coeficientes transformados ajustados
$\hat{B}[r]$	Estimativa da sequência dos quantizadores (Vetor de alocação de bits)
$\hat{s}[n]$	Estimativa da sequência do sinal em regime permanente
$\hat{u}[n]$	Estimativa Sequência de resíduo
$\hat{d}[m]$	Estimativa Sequência do transitório
$\hat{X}_u[k]$	Estimativa Coeficientes transformados da sequência de resíduo
$\hat{X}_d[k]$	Estimativa Coeficientes transformados da sequência do transitório

## Siglas

A/D	Conversor Analógico Digital
AMR	Análise Multiresolução
ANEEL	Agência Nacional de Energia Elétrica
CIGRE	<i>Council on Large Electric Systems</i>
CTAD	Codificação por transformadas com abordagem dissociativa entre regime permanente e eventos transitórios
CTCA	Codificação por transformadas com curvas de perfil espectral para alocação dinâmica de bits no espaço transformado
CTCE	Codificação por transformadas com aplicação direta da decodificação de entropia no espaço transformado
CTIA	Codificação por transformadas com alocação dinâmica e inteligente de bits no espaço transformado
CTLC	Codificação por transformadas com limiarização no espaço transformado
DHT	Distorção Harmônica Total
DOE	<i>U.S. Department of Energy</i>
EPRI	<i>Electric Power Research Institute</i>
FC	Fator de compressão (do inglês <i>Compression Factor</i> )
FCR	Fator de Crista Relativo
FFT	Transformada Rápida de Fourier (do inglês <i>Fast Fourier Transform</i> )
IEC	<i>International Electrotechnical Commission</i>
GLA	<i>Generalized Lloyd algorithm</i>
GC	Ganho de compressão (do inglês <i>Compression Ratio</i> )
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
JPEG	Joint Photograph Experts Group
Kmeans	<i>k-means algorithm</i>
LBG	<i>Linde-Buzo-Gray algorithm</i>
LPC	Codificação Preditiva Linear (do inglês <i>Linear Predictive Coding</i> )
MATLAB	<i>Matrix Laboratory - The MathWorks, Inc.</i>
MDL	<i>Minimum Description Length</i>
MODEMS	contração dos termos, Modulador-Demodulador
MSE	Erro quadrático médio (do inglês <i>Mean Squared Error</i> )
MSNE	Erro quadrático médio normalizado (do inglês <i>Mean Squared Normalized Error</i> )
ONS	Operador Nacional do Sistema
PRODIST	Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional
QEE	Qualidade da Energia Elétrica

FEQ	Filtros Espelhados em Quadratura
RDP	Registrador digital de perturbação
RMS	Valor eficaz (do inglês <i>Root Mean Square</i> )
RNA	Redes neurais artificiais
SOM	Mapa auto-organizável de Kohonen (do inglês <i>Self-organizing map</i> )
SNR	Relação sinal ruído (do inglês <i>Signal to Noise Ratio</i> )
TICS	Tecnologias da informação e comunicação
TB	Taxa de bits (do inglês <i>Bit Rate</i> )
TDW	Transformada Discreta Wavelet
TFCD	Transformada de <i>Fourier</i> de curta duração



# Capítulo 1

## Introdução

### 1.1 CONTEXTUALIZAÇÃO DO TRABALHO, JUSTIFICATIVA E RELEVÂNCIA DA TESE

O aumento da demanda por energia elétrica e o crescente número de interligações entre os sistemas elétricos de potência tornam a operação uma missão cada vez mais complexa. No Brasil, o número de unidades consumidoras cresceu 47% com referência ao ano 2001, quando o país possuía 49,35 milhões de unidades consumidoras (ANEEL, 2012). Assim, visando aprimorar o fornecimento de energia elétrica, grande parte dos investimentos das empresas transmissoras e distribuidoras é destinada a fortalecer tecnologicamente sua infraestrutura operacional. A integração de tecnologias em torno das redes elétricas tem sido uma tendência natural do setor nas últimas décadas (LI *et al.*, 2010), cujo objetivo consiste em tornar as redes elétricas convencionais, redes mais modernas ou *inteligentes* no futuro (HEYDT, 2010).

O conceito de rede inteligente ou de "*Smart Grid*", é adotado com a intenção de melhorar o padrão de operação dos sistemas elétricos de potência. Para chamar uma rede elétrica de inteligente, é necessário acrescentar certo grau de inteligência em todas as áreas envolvidas (geração, transmissão, distribuição, etc.) (BOSE, 2010; RUSSELL; BENNER, 2010). Aspectos técnicos como a interoperabilidade entre tecnologias convencionais e emergentes, propõem toda classe de desafios interessantes para o setor elétrico, no que diz respeito à transição entre a rede convencional e a rede inteligente (LIGHTNER; WIDERGREN, 2010; ZHANG *et al.*, 2010; MOSLEHI; KUMAR, 2010; GINOT *et al.*, 2010; RAHIMI; IPAKCHI, 2010; MOLDERINK *et al.*, 2010). Algumas das iniciativas atuais são direcionadas a avaliar o impacto no desempenho da rede elétrica em função da mudança tecnológica de um componente específico de sua infraestrutura, por exemplo, os equipamentos de medição, quando da substituição progressiva dos medidores convencionais por medidores inteligentes (SRSM, 2012).

As novas condições operacionais sugeridas no ambiente das redes inteligentes apontam o intercâmbio de informações entre as áreas do sistema elétrico de potência, fazendo com que seja indispensável digitalizar, transmitir e armazenar as informações coletadas pelos

equipamentos que o monitoram continuamente.

Os registros relativos a distúrbios em grandezas como tensões e correntes antes, durante e depois do evento são armazenados em bancos de dados para análises de desempenho operacional e como prova diante possíveis reclamações dos consumidores ou requerimentos do órgão regulador (MORETO; ROLIM, 2010; GRZEIDAK *et al.*, 2011). Tais distúrbios são causados principalmente por condições ambientais adversas, falhas nos componentes do sistema, execução de manobras, ações mal intencionadas e conexão de cargas que deterioram a qualidade da energia elétrica (QEE) (COSTA, 2010; KEZUNOVIC, 2010).

Para se ter uma ideia da quantidade de informação gerada durante o monitoramento é proposto o exemplo a seguir. Uma rede elétrica possui 1000 medidores trifásicos que monitoram as grandezas: tensão e corrente. Os medidores digitalizam os sinais a uma taxa de amostragem de 15360 amostras/s e resolução de 16 bits.

A transmissão dos sinais coletados demanda canais de comunicação com velocidades maiores que 1.47 Gb/s, o que em termos de tecnologias de transmissão de dados corresponde a utilizar um canal de fibra ótica (vide tabela 1.1). Considerando que a duração típica de uma variação da tensão de curta duração (afundamento, elevação ou interrupção) encontra-se no intervalo de 0.5 ciclos a 1 min, segundo a caracterização dos fenômenos eletromagnéticos de sistemas de potências publicada em (IEEE STD 1159, 2009), serão necessários de 12.5 Mb a 88.2 Gb de memória para armazenar as formas de onda do distúrbio. O armazenamento pode ser feito por meio de diversas tecnologias como as mostradas na tabela 1.1.

Tabela 1.1: Velocidades de transmissão e capacidades de armazenamento de diferentes tipos de tecnologias

Transmissão		Armazenamento	
Tecnologia	Velocidade	Tecnologia	Capacidade
Linha discada	56 kb/s	Compact Disc (CD) <sup>1</sup>	700 Mb
Ethernet	10-100 Mb/s	Digital Versatile Disc (DVD) <sup>2</sup>	4.7-8.5 Gb
Cabo	70 Kb/s-150 Mb/s	Blu-ray Disc (BD) <sup>2</sup>	25-50 Gb
Rede elétrica	200 Mb/s	Solid-State Drives <sup>3</sup>	480 Gb
Bluetooth	1-24Mb/s	Hard Disk Drive (HDD) <sup>4</sup>	
Wi-Fi	11-600 Mb/s	External HDD	2 Tb
Fibra ótica	100 Mb/s-40 Gb/s	Internal HDD	6 Tb

O panorama apresentado tende a agravar-se nos próximos anos, levando em consideração que as tecnologias de supervisão fornecem cada vez mais informação em tempo quase

<sup>1</sup>2012. Maxell Corporation of America, Inc. <http://www.maxell-usa.com/>

<sup>2</sup>2012. Blu-ray Disc Association. <http://www.blu-raydisc.com>

<sup>3</sup>2012. Western Digital Corporation. External Storage. <http://www.wdc.com/>

<sup>4</sup>2012. Kingston Technology Corporation. <http://www.kingston.com>

real, incrementando o tráfego de dados pelos canais de comunicação (SILVA *et al.*, 2007). Além disso, o Sistema de Apoio à Decisão (SAD) da Agência Nacional de Energia Elétrica (ANEEL), com dados atualizados até fevereiro de 2012, mostra que o Brasil possui 72,70 milhões de unidades consumidoras de energia elétrica, das quais, a classe residencial (61,54 milhões) representa 84,6% do total. Os consumidores industriais somam 562,2 mil ligações. Comércio, serviços e outras atividades totalizam 5,24 milhões de unidades consumidoras. Ligações rurais perfazem 4,4 milhões, sem contar as unidades consumidoras rurais destinadas à aquicultura, com 97,2 mil ligações, e rurais irrigantes, com outras 68,3 mil. Também são tipos de consumidores o poder público, com 557,7 mil, iluminação pública, com 104,5 mil ligações, o serviço público, com 73,4 mil, e as unidades consideradas de consumo próprio, com 8,7 mil unidades (ANEEL, 2012).

A necessidade de capacidade de armazenamento e de velocidade de transmissão incrementa duas vezes mais rápido que a tecnologia disponível (SAYOOD, 2006). Não obstante, avanços tecnológicos expressivos possibilitam que a informação possa ser representada de forma mais eficiente, isso significa, menos espaço em memória de massa para armazenamento de bancos de dados específicos e, menor tempo de alocação de canal de comunicação para transmissão da informação de um ponto remoto até uma estação base. Para atender simultaneamente estas exigências são empregadas técnicas de compressão de dados de forma a complementar a infraestrutura de tecnologias da informação e da comunicação (TICS).

A área de compressão de dados foi objeto de grande desenvolvimento nas últimas quatro décadas. Na década de 70, a motivação foi a comunicação digital de voz por meio de canais de banda estreita (menor que 2400 bits por segundo). Para atingir este requisito, foram desenvolvidas técnicas de compressão de sinais de voz com ênfase em modelos paramétricos, como a Codificação Preditiva Linear (LPC, do inglês *Linear Predictive Coding*), que fez destaque pelo baixo esforço computacional associado a uma qualidade razoável de reprodução da voz, tal que se podia identificar o locutor em uma chamada telefônica digital.

Na década de 80 os MODEMS (contração dos termos, *Modulador - Demodulador*) fizeram sua aparição e tiveram grande penetração na comunicação de dados em redes discadas. As pesquisas focaram em codificadores de forma de onda baseados em técnicas de compressão sem perdas, cujo esforço computacional era alto, mas, apresentavam melhoras na qualidade "fidelidade" da forma de onda decodificada, aumentando a eficiência da largura de banda limitada do canal de comunicação. Inúmeras pesquisas podem ser encontradas na literatura científica da época com aplicações em voz, áudio, imagem e vídeo.

A década de 90 experimentou mudanças revolucionárias devido a fatores como, a popularização das máquinas digitais, a partir do surgimento de fabricantes de processadores de baixo custo; o grande avanço em termos da modelagem e da concepção tecnológica decorrente do aparecimento de ferramentas matemáticas como as transformadas wavelets; e o desenvolvimento de técnicas de aprendizado ou inteligência artificial como as redes neurais, lógica Fuzzy, algoritmos genéticos e outras que poderiam ser integradas de forma híbrida nas

técnicas de compressão de forma a inserir uma capacidade de inteligência nos algoritmos.

A última década trouxe para nossos lares grande parte dos recursos tecnológicos existente, tornando familiares termos como internet, TV digital, telefone celular, MP3, ZIP, AVI, JPEG e outros. Hoje a compressão de dados é vital para o mundo globalizado e é, no cenário das redes elétricas inteligentes, onde a compressão de dados também deverá ocupar papel de destaque, tanto ou mais do que ocupa nos sistemas de comunicações e multimídias.

Neste ponto é necessário diferenciar aplicações do segmento das tecnologias da informação e das comunicações das aplicações na digitalização dos processos das redes de energia elétrica. Do ponto de vista das comunicações, a principal meta é obter a melhor representação para uma dada largura de banda do canal de comunicação. Em outras palavras, o nível de distorção da informação codificada pode variar de acordo com a taxa de compressão oferecida pelo meio de comunicação (disponibilidade de bits por segundo). No segmento de redes de energia elétrica a fidelidade da forma de onda reconstruída após o processo de codificação constitui o parâmetro mais importante, portanto, a taxa de bits utilizada para representar a informação pode variar para se ajustar à fidelidade exigida para a representação da forma de onda a ser codificada.

É no contexto das redes elétricas inteligentes que o presente trabalho se contextualiza e se justifica, constituindo um tema de grande relevância e, ainda, muito pouco estudado quando comparados com técnicas orientadas à compressão, por exemplo, de imagem, vídeo, áudio, voz, etc. O tema apresenta particularidades e exigências específicas derivadas da operação das redes elétricas e da natureza dos fenômenos que nelas ocorrem. Como resultado desta investigação, são descritas nesta tese as técnicas de compressão de dados para sinais de distúrbios em redes elétricas desenvolvidas.

## **1.2 REVISÃO BIBLIOGRÁFICA**

O desenvolvimento de técnicas específicas de compressão de dados para sinais de distúrbios em sistemas elétricos de potência tem por objetivo proporcionar o armazenamento eficiente da informação e a transmissão rápida dos registros gerados pelas ocorrências durante a operação da rede elétrica. As primeiras técnicas surgiram quando o avanço da tecnologia possibilitou que os dados coletados pelos equipamentos de medição fossem disponibilizados em formato digital.

A revisão dos trabalhos que tratam sobre compressão de dados para sinais em sistemas elétricos de potência permitiu agrupar as técnicas de compressão em cinco categorias segundo a abordagem utilizada, a saber:

- Abordagem I - Codificação por transformadas com limiarização no espaço transformado (CTLC)

- Abordagem II - Codificação com identificação e parametrização de componentes estacionárias e não estacionárias
- Abordagem III - Matching Pursuit
- Abordagem IV - Codificação por transformadas com aplicação direta da codificação de entropia no espaço transformado
- Abordagem V - Codificação com sistemas neuro-fuzzy

### 1.2.1 Abordagem I - Codificação por transformadas com limiarização no espaço transformado

Os trabalhos contidos nesta abordagem são considerados variações da técnica padrão de codificação por transformadas ilustrada na figura 1.1.

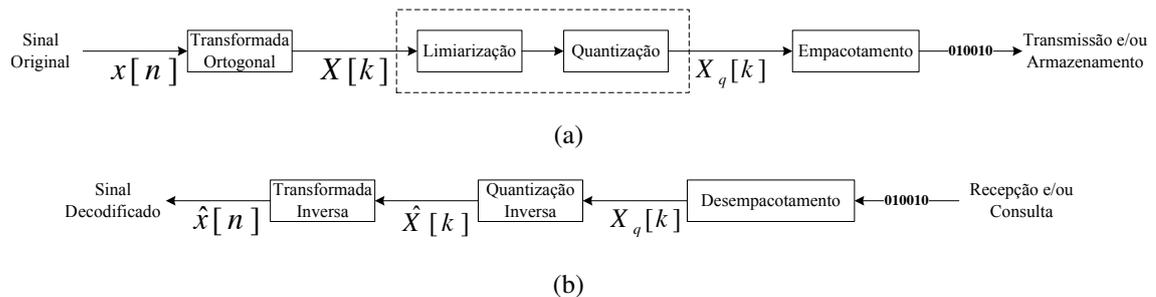


Figura 1.1: Diagrama de blocos do algoritmo de codificação por transformadas com limiarização dos coeficientes. (a). Codificador. (b). Decodificador. Fonte: O autor, 2012

No esquema da figura 1.1(a), a transformada ortogonal é aplicada para concentrar a energia do sinal  $x[n]$  em uma quantidade pequena de coeficientes. A sequência de coeficientes  $X[k]$  é submetida a um processo de limiarização onde os coeficientes mais relevantes são identificados e quantizados com uma quantidade fixa de bits, enquanto os outros coeficientes são descartados ou zerados. Os coeficientes quantizados  $X_q[k]$  são empacotados juntamente com a informação lateral e codificados usando um codificador de entropia de forma a eliminar a redundância ainda existente nos dados. O decodificador é ilustrado na figura 1.1(b).

O trabalho de Nascimento (1997) mostra que, os sinais são segmentados em janelas para efeito da aplicação das transformadas ortogonais (transformada discreta de Cosseno, transformada discreta de Hartley e as transformadas com Superposição). A limiarização é baseada na quantidade de energia dos coeficientes transformados. A quantização e codificação dos coeficientes foram executadas empregando um comprimento da palavra fixo. Um vetor contendo informação sobre os coeficientes selecionados é codificado com uma técnica de supressão de sequências repetidas (Run-Length) e adicionado como informação lateral do processo.

Em Wikinson & Cox (1996), Santoso *et al.* (1997), Hsieh *et al.* (1998) a variação do esquema mostrado nas figuras 1.1(a) e 1.1(a) consiste em utilizar a transformada discreta de Wavelet (TDW), embora Littler & Morrow (1999), Hamid & Kawasaki (2002) utilizem a transformada Wavelet Packet. Em geral, as transformadas Wavelet são usadas pela eficiência na representação de sinais submetidos a mudanças abruptas da faixa dinâmica do espectro de frequências.

Em Wikinson & Cox (1996), Santoso *et al.* (1997), Hsieh *et al.* (1998), Littler & Morrow (1999) o limiar corresponde a determinada porcentagem do máximo valor absoluto dos coeficientes em cada escala. Entretanto Hamid & Kawasaki (2002), empregam o critério *Minimum Description Length* (MDL) com intuito de selecionar o filtro da transformada Wavelet Packet e a quantidade de coeficientes a serem preservados para a reconstrução do sinal. O critério MDL oferece uma alternativa ao processo de limiarização e uma ajuda na seleção do filtro Wavelet. Na maioria dos trabalhos as estratégias usadas para selecionar o filtro Wavelet baseiam-se na busca do filtro que apresente o melhor desempenho na compressão, em outras palavras, é executada uma avaliação de desempenho para cada filtro Wavelet disponível em termos da relação taxa-distorção.

Formas de onda de eventos de QEE são compactados por Panda *et al.* (2002) usando a transformada Slantlet. A proposta de Dash *et al.* (2003) utiliza a transformada Wavelet Spline para compressão e a transformada *S* para análise e classificação dos eventos de QEE. Uma melhora de Dash *et al.* (2003) é feita por Meher *et al.* (2004) que aplica onde após a limiarização, uma rede neural de base radial para quantização escalar dos coeficientes transformados com aumento da taxa de compressão de dados

A estratégia apresentada por Gerek & Ece (2004), Gerek & Ece (2007) mostra uma representação bidimensional (2D) de sinais de eventos de QEE na qual, segmentos do sinal unidimensional (1D) são concatenados como se fossem linhas de uma matriz. A proposta aproveita a correlação nas duas dimensões da representação para obter maior eficiência na compressão por meio da aplicação da TDW-2D. Comparações de desempenho do algoritmo convencional usando as transformadas de Wavelet 1D e 2D foram executadas. O critério de avaliação é o nível de compactação da energia dos coeficientes.

Em Ning *et al.* (2011) o estudo aborda a compressão de dados fornecidos pelos aparelhos de medição fasorial para aplicações em redes inteligentes. A TDW também é utilizada em na redução do ruído branco dos dados. A partir deste momento quando refere-se à esta abordagem será utilizada a sigla CTLC.

Os conceitos de compressão com perdas, compressão sem perdas, alocação de bits, faixa dinâmica e comprimento da palavra digital são explicados no capítulo 2 do documento.

### 1.2.2 Abordagem II - Codificação com identificação e parametrização de componentes estacionárias e não estacionárias

As técnicas aqui agrupadas consistem em aproximar o sinal monitorado  $x[n]$  como a soma de um sinal estacionário com outro sinal não estacionário, tal e como se verifica na expressão (1.1). A compressão de cada um dos novos sinais é feita separadamente e de forma diferente.

$$x[n] = x_e[n] + x_{ne}[n] \quad (1.1)$$

Em Ribeiro *et al.* (2004) o sinal estacionário encontra-se associado à componente fundamental do sinal, uma vez que seus parâmetros, amplitude ( $\tilde{A}_0$ ), fase ( $\tilde{\theta}_0$ ) e frequência ( $\tilde{f}_0$ ) supõem-se invariantes no tempo. O sinal não estacionário, por sua vez, pode ser calculado como a diferença entre o sinal original e o sinal estacionário, e está associado a distúrbios, tais como, harmônicas ( $h[n]$ ), inter-harmônicas ( $i[n]$ ), transitórios ( $t[n]$ ) e ruído ( $r[n]$ ) cujos parâmetros variam no tempo e sua ocorrência é aleatória, tal e como se mostra em (1.2) e (1.3).

$$x_e[n] = f[n] \quad (1.2)$$

$$x_{ne}[n] = h[n] + i[n] + t[n] + r[n] \quad (1.3)$$

Nesse estudo, considera-se que fenômenos eletromagnéticos de regime permanente, tais como, distorções harmônicas e inter-harmônicas não apresentam comportamento estacionário. Para compressão do sinal não estacionário usa-se a abordagem I, enquanto que a componente fundamental é substituída pela estimativa dos seus parâmetros quantizados ( $\hat{A}_0$ ,  $\hat{\theta}_0$  e  $\hat{f}_0$ ), como se observa na figura 1.2 (RIBEIRO, 2005).

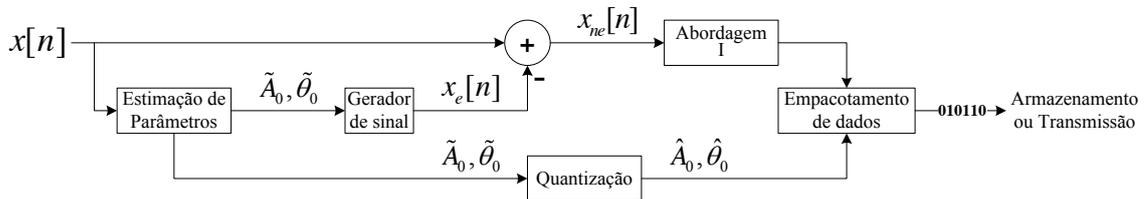


Figura 1.2: Diagrama ilustrativo e simplificado da técnica de compressão proposta em (RIBEIRO *et al.*, 2004). Fonte: (RIBEIRO *et al.*, 2004) (Modificado).

Uma versão melhorada de Ribeiro *et al.* (2004) é proposta em Ribeiro *et al.* (2007). Desta vez, verifica-se que a presença de componentes harmônicas de alta energia no sinal monitorado deteriora o desempenho do algoritmo. Para resolver esta dificuldade, os parâmetros das componentes harmônicas com alta energia ( $\tilde{A}_h$  e  $\tilde{\theta}_h$ ) são incluídos na representação do sinal estacionário, tal e como se apresenta nas equações (1.4) e (1.5).

$$x_e[n] = f[n] + h[n] \quad (1.4)$$

$$x_{ne}[n] = i[n] + t[n] + r[n] \quad (1.5)$$

Em Ribeiro *et al.* (2007) considera-se o emprego do critério MDL para determinar o filtro Wavelet, a escala de decomposição e as características do quantizador escalar dos parâmetros ( $\hat{A}_h$  e  $\hat{\theta}_h$ ), que minimiza o número de bits necessários para representar o sinal monitorado de acordo com o nível de distorção solicitado, tal e como se observa na figura 1.3.

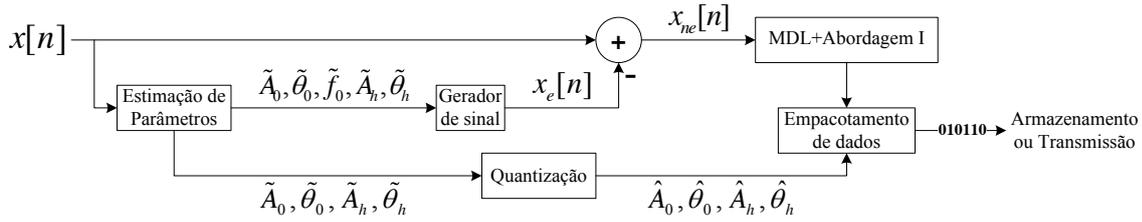


Figura 1.3: Diagrama ilustrativo e simplificado da técnica de compressão proposta em (RIBEIRO *et al.*, 2007). Fonte: (RIBEIRO *et al.*, 2007) (Modificado).

A técnica proposta por Zhang *et al.* (2011) emprega uma estratégia similar à citada em Ribeiro *et al.* (2007) onde, os fenômenos estacionários e não estacionários presentes no sinal são separados para compressão. A diferença entre as duas propostas consiste em que Zhang *et al.* (2011) faz uso do algoritmo da transformada discreta de Fourier interpolada para estimar os parâmetros (amplitude e fase) da componente fundamental e das componentes harmônicas.

As técnicas apresentadas levam em consideração a natureza do sinal e as características dos distúrbios eletromagnéticos no domínio do tempo, o que faz com que os resultados sejam melhores que na abordagem I. Não obstante, a complexidade computacional dos algoritmos aumenta de acordo com o método de estimação de parâmetros utilizado.

### 1.2.3 Abordagem III - Matching Pursuit

Nesse enfoque o sinal monitorado  $x[n]$  é aproximado como uma combinação linear de funções protótipo ( $g_\gamma[n]$ ) com  $M$  termos, cujos vetores de parâmetros ( $\gamma$ ) e pesos ( $\alpha$ ) são quantizados e codificados, resultando em uma expressão da forma:

$$\tilde{x}[n] = \sum_{i=1}^{M-1} \alpha_i g_{\gamma_i}[n] \quad (1.6)$$

A técnica apresentada em Tcheou *et al.* (2007) consiste em uma adaptação do algoritmo Matching Pursuit proposto por Mallat & Zhang (1993). O algoritmo realiza aproximações

sucesivas de sinais, de forma adaptativa, buscando em uma família de funções protótipo a melhor aproximação a cada iteração. Na figura 1.4 verifica-se que  $x[n]$  é decomposto na forma  $\langle x[n], g_\gamma[n] \rangle g_\gamma[n] + r[n]$  onde,  $r[n]$  é o resíduo da projeção de  $x[n]$  na direção de  $g_\gamma[n]$  e o  $\langle x[n], g_\gamma[n] \rangle$  representa o produto interno de  $g_\gamma[n]$  por  $x[n]$ . Em cada iteração, com o intuito de minimizar  $\|r[n]\|$ , escolhe-se o  $g_\gamma[n]$  tal que  $|\langle x[n], g_\gamma[n] \rangle|$  seja máximo. Em seguida, o resíduo  $r[n]$  é decomposto pela sua projeção na função que melhor o representa, como foi feito anteriormente. Essa projeção irá gerar um segundo resíduo, o qual sofrerá o mesmo procedimento, gerando um terceiro resíduo, e assim por diante.

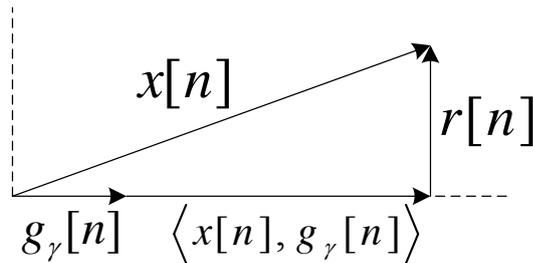


Figura 1.4: Representação gráfica da projeção ortogonal de  $x[n]$  na direção de  $g_\gamma[n]$ . Fonte: (TCHEOU *et al.*, 2007).

No caso da compressão de sinais de sistemas elétricos de potência, sugere-se uma família de funções protótipo do tipo senoidal amortecida representadas, pelos parâmetros amplitude ( $A$ ), defasagem angular ( $\phi$ ), decaimento ( $\rho$ ), frequência ( $f$ ), tempo de início ( $t_{ini}$ ) e fim ( $t_{fim}$ ) do transitório. A forma de onda e seus parâmetros são mostrados na figura 1.5.

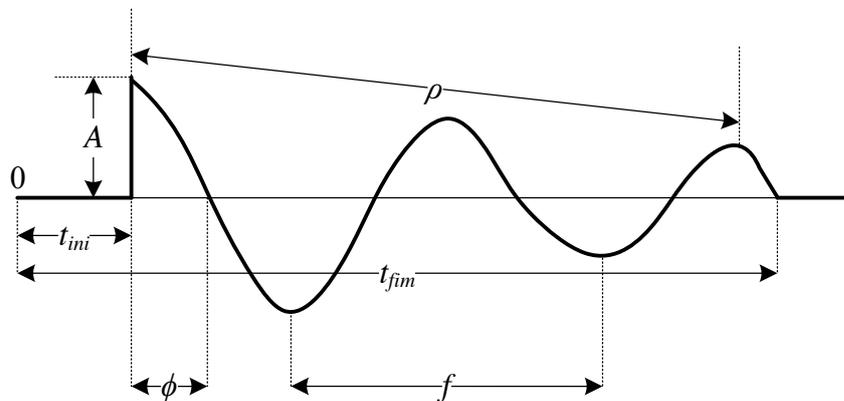


Figura 1.5: Forma de onda de um sinal senoidal amortecido. Fonte: (TCHEOU *et al.*, 2007).

A linha de raciocínio desenvolvida nos leva a verificar que o sinal monitorado é representado como uma combinação linear de senoides amortecidas selecionadas por apresentar a maior correlação com os padrões existentes dentro da família de funções protótipo. Os  $M$  coeficientes de ponderação e índices que identificam os vetores de parâmetros que definem as funções selecionadas compõem as informações a serem codificadas.

A técnica apresentada executa a decomposição do sinal em um conjunto de funções projetadas especificamente para representar um tipo de sinal, o que seria equivalente a criar

um tipo de transformada que objetiva resolver um problema em particular. A abordagem descrita exibe os melhores resultados quando a amplitude do sinal a ser codificada tem comportamento oscilatório e decrescente no tempo. A complexidade do algoritmo aumenta em função da quantidade e do comprimento das funções protótipo.

#### **1.2.4 Abordagem IV - Codificação por transformadas com aplicação direta da codificação de entropia no espaço transformado**

Considera-se que a representação esparsa da transformada de Wavelet, favorece a aplicação direta da codificação de entropia sobre os coeficientes quantizados. Em Huang & Jou (2004) emprega-se a transformada Wavelet Packet de forma a calcular as escalas de decomposição até atingir o menor valor da entropia. Em seguida, os coeficientes transformados são quantizados e codificados por meio de um codificador aritmético com o propósito de reduzir a redundância no conjunto de coeficientes. Em Hsieh & Huang (2003) é feita uma proposta similar a Huang & Jou (2004), contudo o codificador Huffman é utilizado como codificador de entropia. Comparações são feitas em Lorio & Magnago (2004) para algoritmos de compressão baseados na TDW e codificação de entropia.

O enfoque descrito corresponde à técnica de compressão de sinais de sistemas elétricos de potência mais simples de implementar porque não requer da definição de limiares para descartar coeficientes, nem está projetado para aproveitar a natureza do sinal. A complexidade computacional é baixa quando comparada com as outras abordagens. Nesta proposta, a distorção do sinal decodificado é causada principalmente pelo erro de quantização. O algoritmo apresenta desvantagens com relação às outras propostas, no que diz respeito ao ganho de compressão, devido ao fato de que a quantidade de bits para quantização é relativamente alta, tendo em vista que a faixa dinâmica dos coeficientes sofre poucas alterações com respeito aos valores originais. A partir deste momento quando refere-se à esta abordagem será utilizada a sigla CTEC.

#### **1.2.5 Abordagem V - Codificação com sistemas neuro-fuzzy**

A abordagem da compressão de dados usando técnicas de inteligência artificial baseia-se na codificação dos parâmetros ou pesos que representam o conhecimento adquirido durante o processo de aprendizado (treinamento).

Em Ibrahim & Morcos (2005), o sinal monitorado  $x[n]$  é aproximado por meio de um sistema de inferência fuzzy de arquitetura paralela distribuída (rede neural), de tal forma que algoritmos de aprendizado são usados para ajustar os parâmetros. O sistema é chamado de sistema de inferência Neuro-Fuzzy adaptativo.

A técnica implementada é o resultado da combinação de dois subsistemas de inferência fuzzy, um que identifica e aproxima o sinal em regime permanente, e outro que faz o mesmo

---

para o sinal na presença de distúrbios. Na etapa de treinamento, as formas de onda são apresentadas aos subsistemas para seu aprendizado. Após o treinamento, os subsistemas aprendem as formas de onda e são capazes de reproduzi-las com a precisão que demandam e sem a necessidade de armazenar quaisquer das amostras do sinal original.

O monitoramento da mudança do valor de cada amostra da forma de onda original permite a automação da técnica. Quando uma mudança brusca do valor da grandeza é detectada o sistema determina o ajuste dos seus parâmetros para garantir a representação do sinal. Os parâmetros associados com as funções de pertinência dos sistemas fuzzy logo após a identificação do sinal são codificados.

Nota-se que o desempenho da abordagem proposta é afetado diretamente pela frequência do distúrbio e, conseqüentemente, pela taxa de amostragem. Pode-se perceber que para baixas taxas de amostragem a técnica proposta apresenta resultados razoáveis, pois caso contrário o tempo de processamento começaria a tomar maior importância.

### **1.2.6 Resumo da revisão bibliográfica**

Foi apresentado um levantamento do estado da arte das técnicas de compressão de sinais aplicadas aos sistemas elétricos de potência. As propostas estudadas foram agrupadas pela semelhança no processamento dos sinais durante a compressão, resultando em cinco abordagens. Na tabela 1.2, apresenta-se uma sinopse da revisão bibliográfica efetuada, onde todos os trabalhos consultados são relacionados a uma das cinco abordagens.

Após a consulta bibliográfica, percebe-se que pouco tem sido mostrado em relação a utilizar comprimento da palavra variável na quantização dos coeficientes transformados, em outras palavras, há apenas uma proposta que opta por variar o número de intervalos de quantização, o que poderia ser considerado na mesma linha de raciocínio.

Visando preencher essa lacuna, propostas de técnicas de compressão de sinais baseadas em estratégias de alocação dinâmica de bits que garantam a preservação e representação adequada das características comportamentais dos sinais contidas no domínio da transformada serão desenvolvidas e avaliadas durante esta pesquisa.

Tabela 1.2: Sinopse da revisão bibliográfica

Abordagem	Descrição	Referência
I	Codificação por transformadas com limiarização no espaço transformado	Wikinson & Cox (1996)
		Nascimento (1997)
		Santoso <i>et al.</i> (1997)
		Hsieh <i>et al.</i> (1998)
		Little & Morrow (1999)
		Hamid & Kawasaki (2002)
		Panda <i>et al.</i> (2002)
		Dash <i>et al.</i> (2003)
		Meher <i>et al.</i> (2004)
		Gerek & Ece (2004)
Gerek & Ece (2007)		
Ning <i>et al.</i> (2011)		
II	Codificação com identificação e parametrização de componentes estacionárias e não estacionárias	Ribeiro <i>et al.</i> (2004)
		Ribeiro <i>et al.</i> (2007)
		Zhang <i>et al.</i> (2011)
III	Matching Pursuit	Tcheou <i>et al.</i> (2007)
IV	Codificação por transformadas com aplicação direta da codificação de entropia no espaço transformado	Hsieh & Huang (2003)
		Huang & Jou (2004)
		Lorio & Magnago (2004)
V	Codificação com sistemas neuro-fuzzy	Ibrahim & Morcos (2005)

### 1.3 OBJETIVOS E CONTRIBUIÇÕES DA TESE

Dentre as técnicas desenvolvidas nos últimos 30 anos, foram as de compressão de forma de onda por sub-banda, ou transformada ortogonal, as que apresentaram melhor desempenho para sinais multimídia (voz, áudio, imagem, vídeo e outros), apesar de exigirem maior esforço computacional quando comparadas com as técnicas de codificação paramétricas. Mais recentemente, técnicas baseadas na transformada Wavelet ganharam destaque pelo bom desempenho com respeito às métricas de fidelidade da forma de onda reconstruída e da taxa de bits para representação da informação. Nessa linha de raciocínio, o objetivo geral consiste em propor e desenvolver técnicas de compressão de dados eficientes para formas de ondas de distúrbios em sistemas elétricos de potência.

A proposta do trabalho abrange, também, a elaboração de estratégias de alocação dinâmica de bits no domínio da transformada que, em conjunto com técnicas de codificação de entropia, combinam de forma eficiente algoritmos de compressão de dados com perdas e sem

perdas. A finalidade da pesquisa visa melhorar os resultados quanto às métricas de avaliação de desempenho.

No processo de investigação que nos conduziu à construção de técnicas híbridas de compressão de dados, três abordagens foram desenvolvidas com base no estado da arte deste segmento de tecnologia:

1. **Codificação por Transformadas com Alocação Dinâmica e Inteligente de Bits no Espaço Transformado (CTIA):** Aplicação da transformada Wavelet, alocação de bits segundo padrões característicos de perturbações típicas que ocorrem nos sistemas de potência e codificação de entropia. Essa abordagem conduziu ao desenvolvimento de técnicas que utilizam um conjunto de padrões vetoriais de distribuição de energia no espaço transformado. Esses padrões levaram à integração de técnicas de quantização vetorial no espaço transformado que pode ser resolvido por meio do uso de técnicas clássicas de agrupamento de dados (*Clustering*) ou por meio de redes neurais artificiais.
2. **Codificação por Transformadas com Curvas de Perfil Espectral para Alocação Dinâmica de Bits no Espaço Transformado (CTCA):** Aplicação da transformada Wavelet, alocação dinâmica de bits segundo curvas de padrões de estimação da distribuição de energia no domínio da transformada e codificação de entropia. O domínio da transformada é segmentado em um conjunto de sub-bandas e a alocação de bits é feita de forma decrescente na medida em que a frequência é incrementada.
3. **Codificação por Transformadas com Abordagem Dissociativa entre Regime Permanente e Eventos Transitórios (CTAD):** Nesta técnica as características comportamentais do regime permanente e do estado transitório são identificadas e desagregadas. O regime permanente é tratado por meio do uso da transformada de Fourier, enquanto o estado transitório utiliza transformada Wavelet. A alocação dinâmica de bits também é realizada de forma diferenciada para os estados permanente e transitório. As informações de regime permanente e de estado transitório são empacotadas e também codificadas por técnica de codificação de entropia.

Resultados de simulações com banco de sinais reais são apresentados para todas as técnicas propostas. Avaliações de desempenho tendo como métrica o parâmetro descritor da fidelidade da forma de onda decodificada e a taxa de bits utilizados na representação dos sinais são mostrados. A análise comparativa entre as técnicas propostas e outras descritas na literatura científica também são apresentadas.

## 1.4 ORGANIZAÇÃO DO DOCUMENTO

A tese está dividida em cinco capítulos. O primeiro é constituído pela presente introdução. Os Capítulos 2 e 3 destinam-se, respectivamente, à revisão da literatura técnica e ao contexto de aplicação, necessária para o pleno entendimento dos algoritmos propostos no Capítulo 4.

No capítulo 2 serão tratados conceitos básicos em teoria da informação e processamento digital de sinais, tais como compressão de dados, processos de quantização, construção de dicionários, bancos de filtros e transformadas ortogonais.

O capítulo 3 está direcionado ao campo de aplicação do algoritmo de compressão. São explorados tópicos relevantes sobre oscilografia, qualidade da energia elétrica e comportamento espectral dos distúrbios típicos presentes nos sistemas elétricos de potência.

O Capítulo 4 apresenta as contribuições da tese, distribuídas por três algoritmos destinados à compressão das formas de onda. Também são apresentadas as métricas de avaliação objetivas para medir o desempenho do algoritmo de compressão. No final, são mostrados os resultados das simulações obtidos com o algoritmo proposto, além de comparações com resultados de outros trabalhos.

Por fim, o Capítulo 5 é destinado à apresentação das conclusões, bem como das propostas para trabalhos futuros. As publicações que resultaram da pesquisa desenvolvida também são listadas.

# Capítulo 2

## Fundamentação Teórica

### 2.1 CONSIDERAÇÕES INICIAIS

De forma geral, as técnicas de compressão sinais de sistemas elétricos de potência são baseadas na redução ou eliminação das interdependências e das redundâncias entre amostras, de forma que se possa diminuir a quantidade de informação necessária para transmitir ou armazenar. Para isso os algoritmos são divididos basicamente em três etapas: transformação, quantização e codificação entrópica.

A busca de uma abordagem que resulte no máximo de informação sobre o sinal, leva a pensar na conveniência de passar de uma representação do sinal no domínio original (tempo) para uma representação em um domínio mais adequado do ponto de vista da compressão (frequência, tempo-frequência ou tempo-escala). A mudança do domínio permite revelar as características intrínsecas do sinal diminuindo sua entropia, em razão de possuir a capacidade de concentrar a energia em um conjunto reduzido de coeficientes transformados. O processo de quantização tem por objetivo limitar o universo da representação dos coeficientes transformados a um conjunto reduzido de possibilidades. Após a quantização, pode-se ainda explorar a redundância estatística presente nos dados, usando as técnicas de codificação de entropia.

Visto que os algoritmos de compressão geralmente surgem a partir de uma combinação de técnicas de processamento de sinais, o presente capítulo trata das ferramentas teóricas necessárias que serão utilizadas no decorrer do trabalho.

### 2.2 COMPRESSÃO DE DADOS

Considera-se como compressão de dados ao conjunto de algoritmos ou técnicas cujo objetivo é criar uma representação compacta da informação, por meio da identificação de estruturas intrínsecas existentes nos dados. Os dados podem ser caracteres de um arquivo de texto, arranjos numéricos bidimensionais (imagens) ou unidimensionais (áudio e formas de onda), ou simplesmente sequências de números que são gerados por outros processos.

Com a intenção de facilitar ao leitor o entendimento do relato, um pequeno glossário de termos e algumas ilustrações relacionadas ao contexto da compressão de dados são apresentados a seguir.

- *Fonte*: termo usado para determinar o gerador ou a origem dos dados;
- *Alfabeto*: conjunto de símbolos gerados pela fonte dos dados;
- *Símbolo*: dado;
- *Mensagem*: sequência de símbolos (informação);
- *Código*: sequência binária que representa um símbolo do alfabeto;
- *Dicionário*: Conjunto de códigos;
- *Comprimento da palavra digital*: sequência de bits de tamanho fixo (8, 16, 32 ou 64 bits), processada como uma unidade em uma máquina;
- *Distorção*: Diferença entre os dados originais e os dados reconstruídos;
- *Faixa dinâmica*: relação entre os valores máximo e mínimo possíveis de uma quantidade variável;
- *Alocação de bits*: distribuição de bits para quantização;
- *Quantização*: operação que limita a faixa dinâmica da variável a um número finito de valores;
- *Redundância*: informação repetida;
- *Irrelevância*: informação cuja eliminação não afeta o conteúdo da mensagem;
- *Relação taxa-distorção*: relação entre a quantidade de bits da representação e sua qualidade depois da reconstrução.

É difícil indicar especificamente a origem da teoria sobre a compressão de dados. No percurso da história, o ser humano procurou estratégias que permitissem representar a informação de forma compacta ainda antes da existência dos computadores. Formas simples e intuitivas de compressão como o código Braille e o código Morse fizeram sua aparição no século 19. O código Braille é composto por grupos (ou células) de  $3 \times 2$  pontos cada, gravados em papel grosso. Cada um dos 6 pontos em um grupo pode ser plano ou elevado, o que sugere que o conteúdo de informação de um grupo é equivalente a 6 bits, resultando em 64 grupos possíveis. Letras, números e sinais de pontuação comuns em conjunto não usam todos os 64 códigos, razão pela qual os grupos restantes podem ser usados para codificar palavras e conjuntos de letras comuns (SALOMON, 2006). Morse aproveitou o fato de que

existam letras que são usadas com maior frequência no inglês do que outras para atribuir códigos de comprimento variável, o que resulta em menor tempo médio de transmissão da mensagem. As cartas enviadas por telégrafo são codificadas com pontos e traços. Ele atribuiu sequências curtas para as letras de maior frequência, tais como  $e$  ( $\cdot$ ) e  $a$  ( $\cdot-$ ), e sequências mais longas para letras menos frequentes, tal como  $q$  ( $- - \cdot-$ ) e  $j$  ( $\cdot - - -$ ). Em 1948, Claude E. Shannon conseguiu definir matematicamente a quantidade de informação contida em um experimento aleatório por meio de um parâmetro chamado de auto-informação, com esse resultado foi gerada uma base teórica para a compressão de dados (SAYOOD, 2006). Para ilustrar uma aplicação, considere o seguinte exemplo: seja  $A_k$ , os resultados de  $k$  experimentos aleatórios independentes e seja  $P(A_k)$  a probabilidade do evento  $A_k$  acontecer. Então, a auto-informação associada ao evento ( $i(A_k)$ ) é definida como,

$$i(A_k) = \log_b \left( \frac{1}{P(A_k)} \right) = -\log_b (P(A_k)) \quad (2.1)$$

No ponto de vista da compressão, a quantidade auto-informação pode ser interpretada como o comprimento ótimo do código que está dado por  $-\log_b (P(A_k))$ . Onde,  $b$  é o número de símbolos utilizados para construir os códigos de saída. Verifica-se, que o comprimento é maior quando a probabilidade do símbolo na mensagem é baixa, e vice-versa, o que gera uma relação entre a probabilidade do símbolo e o comprimento do código atribuído. As unidades da auto-informação são bits, nats, ou hartleys, dependendo se a base do logaritmo é 2,  $e$ , ou 10, respectivamente.

Uma medida do número médio de bits usado para representar a saída de uma fonte é conhecida como *taxa de codificação*. Entretanto, para um modelo de probabilidade dado, a *entropia* ( $H$ ) é a mínima taxa de codificação com que os símbolos da fonte podem ser codificados. A entropia é descrita pela equação (2.2).

$$H = E[i(A_k)] = \sum_{k=1}^M P(A_k) i(A_k) = - \sum_{k=1}^M P(A_k) \log_b (P(A_k)) \quad (2.2)$$

A entropia da fonte está associada com a informação contida no experimento aleatório, o que faz com que seja importante estimar corretamente as probabilidades para não afetar a eficiência da compressão com uma errada geração de códigos (representação binária). Shannon, demonstrou que a entropia é a menor taxa de codificação possível, alcançada pelo melhor esquema de compressão sem perdas. Neste contexto, o termo entropia refere-se ao valor esperado da informação contida na mensagem ( $E[i(A_k)]$ ). O resultado de um experimento aleatório oferece mais informação se a distribuição de probabilidade dos resultados é uniforme. Assim, dados que apresentam distribuição uniforme maximizam a entropia por não apresentar redundância (MACKAY, 2003; COVER; THOMAS, 2006).

Em geral, a maioria da informação que recebemos contém grande quantidade de redun-

dância (temporal, espacial ou espectral), que deve ser detectada, e em alguns casos, caracterizada pela técnica de compressão para sua remoção, tornando a informação mais propensa a erros, é dizer, menos confiável. Conclui-se, então, que a compressão e a confiabilidade da informação avançam em direções opostas e, que nenhuma técnica de compressão pode comprimir todos os tipos de dados (texto, imagem, áudio, vídeo, etc.) mantendo ganhos significativos (SALOMON, 2006).

Um algoritmo de compressão é considerado eficiente quando consegue subtrair a informação relevante e estatisticamente não redundante do total de dados, diminuindo a quantidade de bits da representação. A figura 2.1 ilustra os requisitos necessários para conseguir uma compressão de dados eficiente.

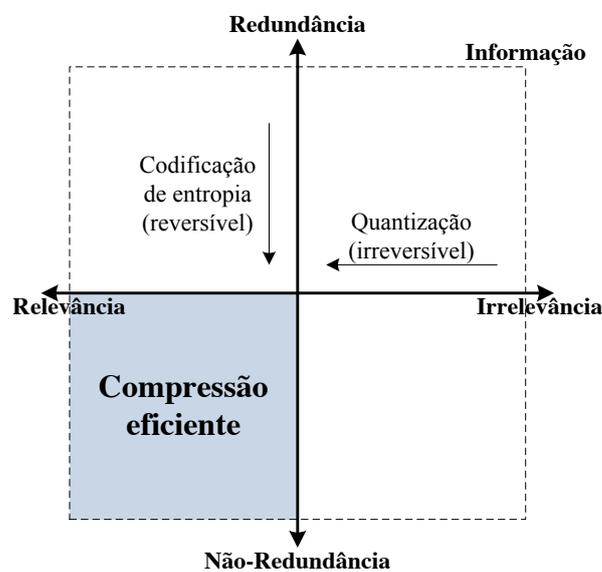


Figura 2.1: Características da informação. Fonte: O autor, 2012.

Os métodos de compressão de dados são classificados popularmente em dois grandes grupos, tal e como se ilustra na figura 2.2. A compressão sem perdas envolve algoritmos que permitem a reconstrução exata dos dados originais a partir dos dados comprimidos. Os métodos que pertencem a este grupo são considerados reversíveis pela preservação dos dados originais. Os métodos de compressão com perdas objetivam encontrar a melhor relação taxa-distorção para amenizar o impacto da perda de informação (SAYOOD, 2006).

### 2.2.1 Compressão sem perdas

A redução na taxa de codificação é obtida quando os dados originais possuem dependências ou propriedades estatísticas que podem ser aproveitadas para compressão. A exigência para que não haja perda de informação coloca a entropia como o limite do ganho de compressão a se obter (WIEGAND; SCHWARZ, 2011).

Os métodos de compressão sem perdas podem ser classificados em três categorias se-

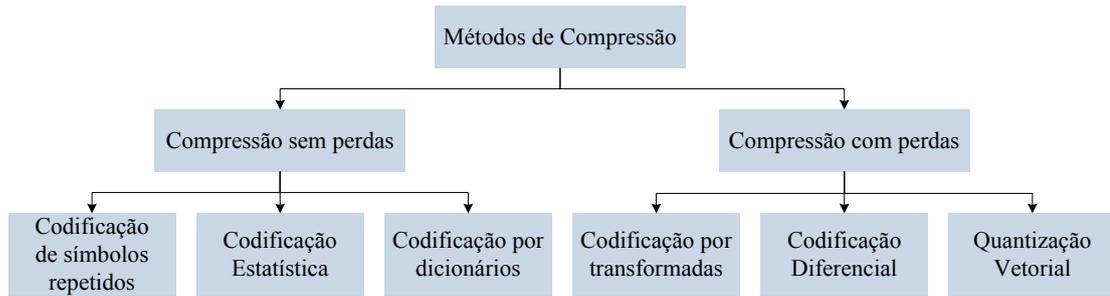


Figura 2.2: Classificação dos métodos de compressão. Fonte: O autor, 2012.

gundo sua operação. A primeira categoria corresponde aos métodos cuja abordagem é a substituição de sequências de símbolos repetidos por um único símbolo e sua contagem das ocorrências. A ideia por trás dessa abordagem para compressão de dados é a seguinte: se um símbolo  $s$  aparece  $n$  vezes consecutivas na sequência de dados, então, substituem-se as ocorrências pelo par  $ns$ . Por exemplo, substituir a sequência de zeros da sequência 625000000000 por 625@9, onde @ indica a ocorrência do símbolo zero no código. No caso do codificador *Run Length* as sequências de símbolos são mapeadas como pares  $(s, n)$ . Os métodos que pertencem a esta categoria empregam códigos de comprimento fixo na representação dos símbolos, além de utilizar um caracter especial para indicar quando o símbolo repetido aparece. Em contraste, os métodos estatísticos atribuem códigos de comprimento variável aos símbolos ou grupos de símbolos de acordo com sua probabilidade de ocorrência. Em outras palavras, avalia-se a frequência em que os símbolos aparecem na mensagem.

Os métodos estatísticos ou de codificação de entropia surgem como uma segunda categoria que visa a alocar uma quantidade variável de bits durante a codificação, aproximando o comprimento médio por símbolo ou grupo de símbolos ao valor da entropia. Para isso, uma tabela de códigos predefinida é ordenada de forma decrescente de acordo com o comprimento de cada código. Nesta tabela, os símbolos mais prováveis usam códigos de menor comprimento (menos bits) que os menos prováveis (mais bits). No entanto, existem estratégias para atribuir dinamicamente os códigos aos símbolos.

A codificação de Huffman e a codificação Aritmética são os métodos estatísticos mais utilizados pela sua eficiência, basicamente, tentam definir a atribuição ideal de códigos para alcançar a melhor compressão. Os codificadores de comprimento variável têm que satisfazer duas condições: atribuir códigos de mínimo comprimento médio e gerar códigos que possam ser decodificados de forma inequívoca.

### 2.2.1.1 Codificação Huffman

Gera-se um dicionário de códigos de comprimento variável não ambíguos, pois nenhum código pode ser o prefixo de outro código. O codificador gera uma árvore ordenada onde, os ramos são construídos recursivamente partindo dos símbolos menos prováveis. No início, os

dois símbolos menos prováveis são juntados em um nó cuja probabilidade é a soma das probabilidades dos dois símbolos. Os dois símbolos são identificados como os ramos 1 (menos provável) e 0 (mais provável) do nó. O processo continua de forma sucessiva considerando cada novo nó formado como um novo símbolo, até obter um único nó chamado de raiz. O código de cada símbolo corresponde à sequência binária obtida ao longo do caminho que vai desde o símbolo à raiz. Assim, quanto mais distante esteja o símbolo da raiz, maior será o comprimento do código.

#### 2.2.1.2 Codificação Aritmética

Baseia-se na premissa na qual, é mais eficiente designar um código para uma sequência em particular do que gerar um código para cada símbolo da sequência. O método gera um único identificador para cada sequência de símbolos a ser codificada. O rótulo corresponde a um número no intervalo  $[0, 1)$ , que se tornará um código binário para representar a sequência de símbolos.

O intervalo  $[0, 1)$  é dividido em tantos subintervalos quantos símbolos tenha a sequência, seguidamente, identificando-se o subintervalo correspondente ao primeiro símbolo da sequência. Para cada símbolo subsequente, divide-se o subintervalo atual em subintervalos proporcionais às probabilidades de cada símbolo, e encontra-se novamente o subintervalo que corresponde ao próximo símbolo, até obter um subintervalo para cada símbolo ao final do processo. À medida que o número de símbolos na mensagem aumenta, o intervalo usado para representá-la torna-se menor e o número de bits utilizados para representá-lo se torna maior.

#### 2.2.1.3 Codificação Huffman vs. Codificação Aritmética

Em geral, podemos verificar que é mais eficiente gerar códigos para grupos ou sequências de símbolos ao invés de gerar um código para cada símbolo de uma sequência. A codificação de grupos faz com que a redundância caia para valores aceitáveis. No entanto, esta abordagem nem sempre funciona. Por exemplo, quando se tenta obter os códigos de Huffman para sequências de símbolos de comprimento  $m$ .

Na codificação Huffman estendida, o comprimento médio por símbolo,  $lhc$ , é limitado pela entropia ( $H$ ) e pelo comprimento das sequências a serem representadas por um único código, tal e como se apresenta em (2.3).

$$H < lhc < H + 1/m, m > 0 \quad (2.3)$$

Já na codificação aritmética, o comprimento médio por símbolo,  $lac$ , é dado por,

$$H < lac < H + 2/m, m > 0 \quad (2.4)$$

Depois de observar os comprimentos médios por símbolo de cada método, verifica-se que há uma vantagem da codificação de Huffman sobre a codificação aritmética, em relação com a proximidade dos limites superiores de  $lhc$  e de  $lac$  ao valor da entropia, para um dado valor de  $m$ . Entretanto, na codificação de Huffman estendida é necessário gerar um dicionário com os códigos para todas as possíveis sequências de símbolos. Nesse caso, o tamanho do dicionário sofre um crescimento exponencial de acordo com  $k^m$ , onde,  $k$  é a quantidade de símbolos do alfabeto. Esse fato faz com que esta abordagem torne-se impraticável em termos dos requerimentos de memória para armazenamento do dicionário, no consumo de tempo na decodificação e, se houver uma leve modificação de alguma das probabilidades assumidas inicialmente, um grande impacto sobre a eficiência da codificação é provocado. Por outro lado, na codificação aritmética, gera-se apenas o código binário referente ao rótulo da sequência a ser codificada (ZAGHETTO, 2009). Notadamente, a codificação aritmética é apresentada como uma alternativa à codificação baseada em alfabeto estendido. Existe uma extensa literatura relacionada com a teoria e a implementação dos codificadores de entropia, como principais referências foram consultados (SAYOOD, 2006; SALOMON, 2006; PU, 2006; NELSON; GAILLY, 1995).

Conforme discutido anteriormente, observa-se que os resultados dos métodos de compressão estatísticos dependem do modelo estatístico dos dados, que por sua vez, corresponde à coleção de regras usadas para definir as probabilidades de cada símbolo e produzir um código apropriado com base nessas probabilidades.

Os métodos de compressão baseado em dicionário não usam um modelo estatístico, nem usam códigos de comprimento variável. Em vez disso, selecionam sequências de símbolos que são substituídas por índices associados a sequências similares contidas no dicionário. Logo depois os índices são codificados. Os dicionários são classificados em duas categorias segundo a forma como são atualizados.

- Estático, quando seus elementos são permanentes ou somente permite a adição de novas sequências (sem exclusões).
- Dinâmico ou adaptativo, seus elementos são atualizados de acordo com as sequências encontradas no fluxo de dados a ser codificado, permitindo a adição ou exclusão de sequências.

## 2.2.2 Compressão com perdas

Muitos dos sinais presentes no dia a dia contêm informações desnecessárias para uma dada finalidade. Por exemplo, os codificadores de áudio e de imagens aproveitam os limites fisiológicos dos órgãos do ser humano (ouvidos e olhos) para eliminar a informação perceptivamente irrelevante, localizada em bandas de frequências específicas. Já, a compressão de formas de onda é caracterizada pela perda irreversível de informação originada na representação digital dos fenômenos analógicos (vide figura 2.1) (JAYANT; NOLL, 1984). De forma geral, a compressão com perdas se faz útil quando a reconstrução exata dos dados não é indispensável (WIEGAND; SCHWARZ, 2011). Os métodos de compressão com esse enfoque são ajustados para diferentes níveis de qualidade por meio da regulação da distorção e da taxa de codificação, tal e como se ilustra na figura 2.3.

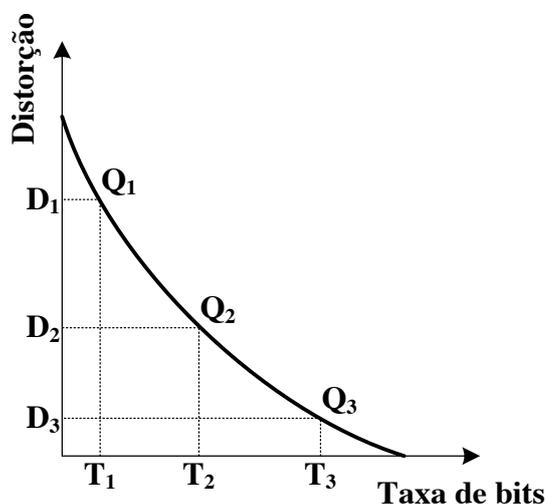


Figura 2.3: Curva de operação dos métodos de compressão com perdas. Fonte: O autor, 2012.

Na figura 2.3, observam-se os diferentes níveis de qualidade ( $Q_1 > Q_2 > Q_3$ ) para os quais opera a compressão sem perdas. Os níveis de qualidade são obtidos minimizando a distorção para uma dada taxa de codificação ou minimizando a taxa de codificação para atingir um nível de distorção determinado. A vantagem dos métodos de compressão com perda sobre os sem perda é que conseguem maior ganho de compressão, mantendo, no entanto, uma qualidade mínima em relação aos dados originais, conforme o objetivo que se pretende. Existem três tipos gerais de técnicas de compressão com perdas, elas são descritos a seguir.

### 2.2.2.1 Codificação por transformadas

Considera-se a aplicação de transformadas lineares uma técnica de compressão natural pela forma como a energia se concentra em poucos coeficientes durante o mapeamento entre domínios. No domínio da transformada, os coeficientes de interesse são isolados, quanti-

zados e codificados usando técnicas convencionais de compressão sem perdas, enquanto os restantes são descartados. A fidelidade da reconstrução dos dados depende dos níveis de quantização e da quantidade de coeficientes descartados.

### 2.2.2.2 Codificação diferencial

Baseia-se na predição do valor de cada amostra com base no valor da amostra anterior. Apenas são codificadas as diferenças entre um dado e seu vizinho imediatamente anterior (ou um valor de referência). A técnica é aplicada a sequências que não apresentam muita variação (alta correlação entre amostras). Portanto, a diferença entre os dois valores consecutivos é pequena e permite usar menos bits na representação.

### 2.2.2.3 Quantização vetorial

Em geral, a quantização corresponde ao mapeamento de um conjunto de valores em um conjunto de valores predefinidos. Por ser este um processo de aproximação, existe um erro associado ao processo ( $\varepsilon_q$ ) que deve ser minimizado para garantir a boa qualidade da nova representação. Portanto, considera-se uma boa quantização quando o erro de quantização tende a zero ( $\varepsilon_q \rightarrow 0$ ). Nas figuras 2.4(a) e 2.4(b) são ilustrados os dois tipos de quantização existentes.

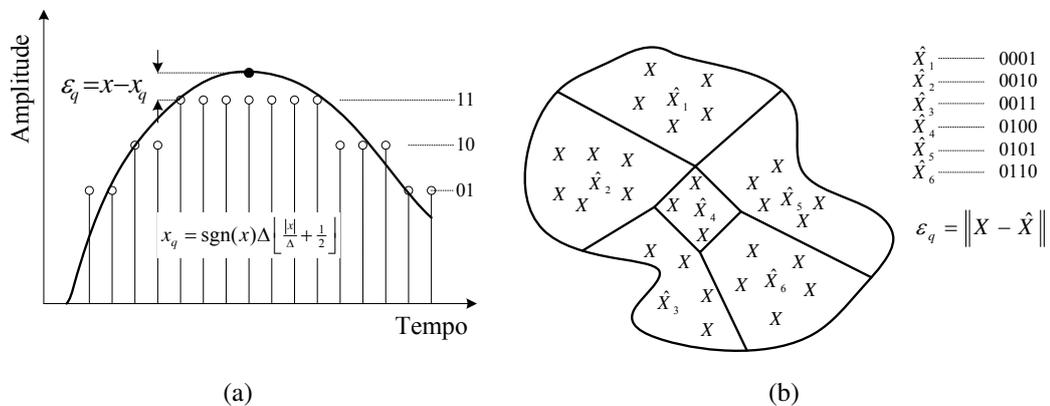


Figura 2.4: (a) Quantização escalar. (b) Quantização vetorial. Fonte: O autor, 2012.

Na quantização escalar (figura 2.4(a)), cada símbolo de entrada é tratado separadamente para produzir uma saída. Já na quantização vetorial (figura 2.4(b)), a sequência de símbolos de entrada é processada por blocos e representada em forma de vetores. As saídas do processo são outros vetores chamados de centróides, os quais representam todos os vetores agrupados em uma partição ou região do espaço.

Na quantização vetorial, os quantizadores são armazenados na forma de um vetor, onde o número de posições depende da quantidade de blocos gerados na sequência, de tal forma, que as sequências de dados estatisticamente semelhantes usam o mesmo vetor durante a

quantização, preservando as características comportamentais dos dados pela adaptabilidade do processo.

### 2.3 QUANTIZAÇÃO

A quantização escalar ( $Q$ ) pode ser interpretada como uma função que, para cada valor do domínio ( $x$ ), seleciona um número  $\hat{x}$ , tal que  $|x - \hat{x}|$  seja mínima, em outras palavras,  $x$  é representado pelo valor mais próximo de um conjunto de valores finitos predefinidos  $\mathcal{C} = \{\hat{x}_1, \hat{x}_2, \dots, \hat{x}_N\}$ , tal que  $\mathcal{C} \subset \mathfrak{R}$ . O conjunto de saída é chamado de dicionário (*Codebook*) e cada elemento do dicionário é chamado de código (*Codeword*). A taxa de codificação do dicionário de tamanho  $N$  corresponde a  $\lceil \log_2 N \rceil$ . Este parâmetro determina o número necessário de bits para representar o valor quantizado. Os intervalos de quantização  $R_i$  são representados pela expressão (2.5)<sup>1</sup>.

$$R_i \equiv \{x \in \mathfrak{R} | Q(x) = \hat{x}_i\} \quad (2.5)$$

Onde,  $\bigcup_i R_i = \mathfrak{R}$  e  $R_i \cap R_j \neq \emptyset$  para  $i \neq j$ . A quantização escalar pode ser decomposta em duas funções básicas, uma chamada de codificador  $\mathcal{E} : \mathfrak{R} \rightarrow \mathcal{J}$  onde  $\mathcal{J} = \{1, 2, 3, \dots, N\}$  e outra chamada de decodificador  $\mathcal{D} : \mathcal{J} \rightarrow \mathcal{C}$ . Portanto, se  $Q(x) = \hat{x}_i$ , então,  $\mathcal{E}(x) = i$ ,  $\mathcal{D}(i) = \hat{x}_i$  e  $Q(x) = \mathcal{D}(\mathcal{E}(x))$ .

O objetivo no projeto do quantizador escalar é determinar os níveis de resolução que limitam os intervalos de quantização de tal forma que a distância média seja mínima para uma quantidade fixa de níveis. Nota-se que esse problema não tem uma solução fechada, contudo, minimizando o erro quadrático médio (distorção) entre  $x$  e  $\hat{x}$  para  $i = \{1, 2, 3, \dots, N\}$  obtém-se uma solução aproximada. A expressão (2.6) descreve matematicamente o processo anterior, sendo  $d(x, Q(x))$  a função distorção e  $f(x)$  a distribuição de probabilidade dos dados de entrada.

$$\min_{\hat{x}_i \in \mathcal{C}} \{d(x, Q(x))\} = \min_{\hat{x}_i \in \mathcal{C}} \left\{ \sum_{i=1}^N \int_{R_i} (x - \hat{x})^2 f(x) dx \right\} \quad (2.6)$$

As condições necessárias para projetar um quantizador ótimo são alcançadas em dois passos. Primeiro, calcula-se o codificador assumindo que não é possível modificar o decodificador, o que é equivalente a encontrar a partição ótima dado o dicionário. O codificador ótimo deve ser aquele que mapeia as entradas nos níveis de resolução que produzem menor distorção ao respeito da entrada, em outras palavras, a  $i$ -ésima região da partição consiste no

<sup>1</sup>A maioria do conteúdo desta seção está baseado na referência (GERSHO; GRAY, 1992).

valor de entrada mais próximo a um valor de saída (condição do vizinho mais próximo).

$$R_i = \{x | d(x, \hat{x}_i) \leq d(x, \hat{x}_j) \forall i \neq j\} \quad (2.7)$$

A segunda condição consiste em calcular o decodificador ótimo para um codificador dado, usando o erro quadrático médio como medida de distorção.

A necessidade de trabalhar em espaços com um número maior de dimensões dá origem à quantização vetorial, que por sua vez é considerada uma extensão da quantização escalar para espaços vetoriais. Um vetor pode ser usado para descrever quase qualquer tipo de padrão, portanto, a quantização vetorial pode ser entendida como uma forma de reconhecimento de padrões onde se procura o padrão que apresente o melhor casamento ou similaridade.

Durante a quantização vetorial é feito um mapeamento do espaço euclidiano  $\mathfrak{R}^p$  onde, a entrada está definida para os vetores  $X \in \mathfrak{R}^p$ , e a saída corresponde ao conjunto finito de vetores  $\mathcal{C} = \{\hat{X}_1, \hat{X}_2, \dots, \hat{X}_N\}$ , tal que  $\mathcal{C} \subset \mathfrak{R}^p$ .  $\mathcal{C}$  é chamado de dicionário (Codebook) e os  $N$  vetores que compõem o dicionário são chamados vetores código (Codewords). Também é definida a taxa de codificação como  $\lceil \log_2 N/p \rceil$  onde,  $p$  é considerada a dimensão do dicionário. De forma geral, o espaço  $\mathfrak{R}^p$  é particionado em um conjunto de regiões limitadas pela interseção de hiperplanos de ordem  $p$  onde, todos os vetores  $X$  que estão localizados dentro de cada região são representados por um único vetor código  $\hat{X}_i$ , correspondente ao centróide da região.

$$R_i = \{X \in \mathfrak{R}^p | Q(X) = \hat{X}_i\} \quad (2.8)$$

Onde,  $\bigcup_i R_i = \mathfrak{R}^p$  e  $R_i \cap R_j \neq \emptyset$  para  $i \neq j$ . A figura 2.5 ilustra o mapeamento entrada-saída do espaço vetorial.

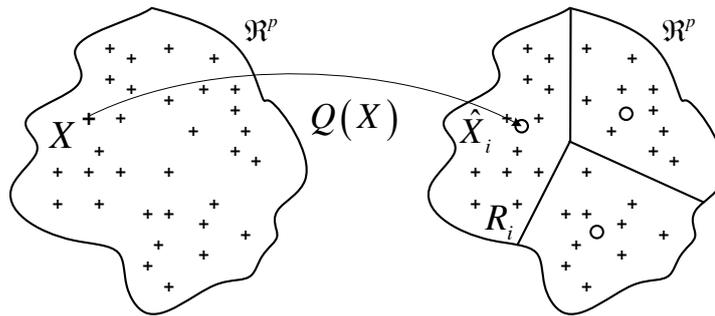


Figura 2.5: Mapeamento do espaço vetorial. Fonte:(GERSHO; GRAY, 1992).

Uma das principais características da quantização vetorial é representar um conjunto de dados através de um número mínimo de vetores código mantendo a dimensionalidade e as características estatísticas dos dados originais. A redução da quantidade de informação interpreta-se como uma diminuição da redundância no dicionário, originada no mapeamento estatístico. A figura 2.6 ilustra as duas etapas do algoritmo de quantização vetorial.

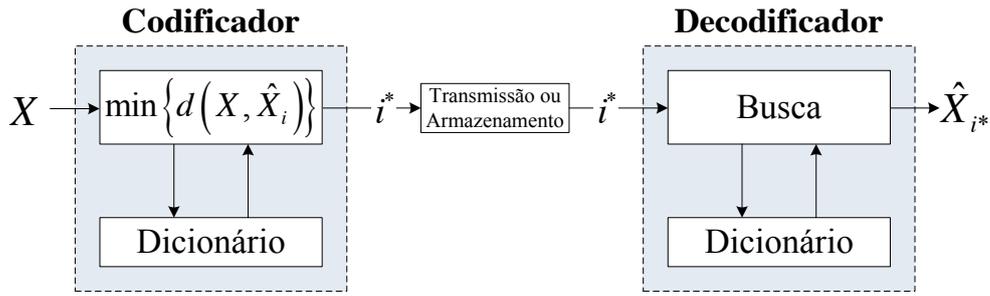


Figura 2.6: Esquema para ilustrar o algoritmo de quantização vetorial com codificador do tipo Voronoi ou de vizinho mais próximo. Fonte:(GERSHO; GRAY, 1992).

Na etapa de codificação, gera-se um ponteiro que identifica a região do espaço à qual o vetor de entrada  $X$  pertence. Enquanto, o decodificador recebe o ponteiro ( $i^*$ ) e inicia um processo de busca que seleciona o vetor de saída  $\hat{X}_{i^*}$ . A função de distorção comumente utilizada na quantização vetorial é a distância Euclidiana quadrática calculada por meio da expressão (2.9).

$$d(X, Q(X_i) = \hat{X}_i) = \|X - \hat{X}_i\|^2 \equiv (X - \hat{X}_i)^t (X - \hat{X}_i) \quad (2.9)$$

Como resultado do processo de quantização vetorial apenas um código binário que indica a posição do vetor escolhido é transmitido ou armazenado, obtendo uma representação compacta dos dados. Na prática, obtém-se o índice  $i^*$ , tal que a função distorção que calcula a distancia entre os dois vetores seja mínima (expressão (2.10)).

$$\hat{X}_{i^*} = \min_{\hat{X}_i \in \mathcal{C}} \left\{ d(X, \hat{X}_i) \right\} \quad (2.10)$$

O tipo de algoritmo exposto acima é chamado de Voronoi ou de vizinho mais próximo, e se caracteriza por determinar completamente o mapeamento do espaço  $\mathbb{R}^p$  através do dicionário e da medida de distorção. O objetivo do algoritmo é fazer a escolha do vetor código que apresente o melhor casamento, e em consequência, origine a menor distorção global.

### 2.3.1 Quantização baseada em alocação de bits

A quantização baseada em alocação de bits se fundamenta na relação entre o nível de qualidade desejada na representação dos dados e o gasto de bits requerido para atingir tal nível de qualidade, em outras palavras, está relacionada diretamente com o comprimento da palavra digital. Na figura (2.7) mostra-se a diferença entre os dois tipos de alocação de bits.

Quando usado comprimento da palavra fixo, os dados são representados com a mesma quantidade de bits, sem considerar a quantidade de informação que eles contêm, portanto, verifica-se na figura (2.7(a)) um gasto de bits desnecessário na quantização, particularmente

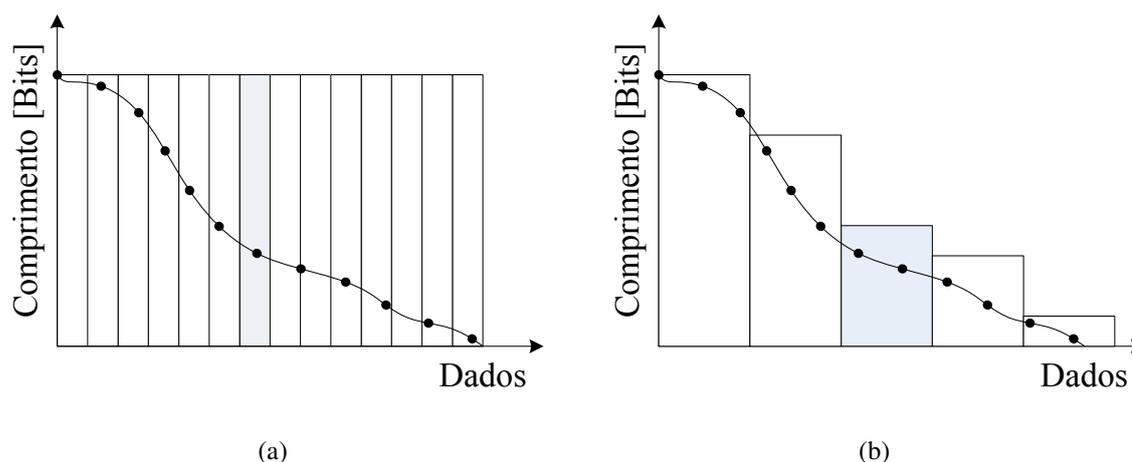


Figura 2.7: Alocação de bits para quantização. (a) Comprimento fixo. (b) Comprimento Variável. Fonte: O autor, 2012.

quando existem dados que fornecem pouca informação. Uma tática para contornar este problema é substituir os dados irrelevantes por zeros.

No caso, quando utilizado comprimento da palavra variável (vide figura 2.7(b)), a sequência dos dados é dividida em blocos uniformemente distribuídos. De acordo com os requerimentos da representação é alocada uma quantidade de bits para quantização dos elementos de cada bloco. A escolha do tamanho do bloco produz um impacto significativo na qualidade da reconstrução, especialmente quando a informação é muito diferente. Por exemplo, blocos longos reduzem a taxa de bits da informação lateral gerada, enquanto, blocos curtos podem mascarar algumas características importantes. Existem varias estratégias para estabelecer a relação de dependência entre comprimento da palavra e a quantidade de bits da representação. Uma delas é avaliar a relevância da informação fornecida pelos dados de cada bloco, de forma que depois da compressão os dados tenham a mínima distorção possível. Outras estratégias definem a alocação de bits baseando-se na relação taxa-distorção.

## 2.4 DICIONÁRIOS

Dado o crescente aumento da complexidade dos processos e da quantidade de informação coletada atualmente pelos sistemas de monitoramento, surge a necessidade de extrair a informação relevante (remoção da redundância) que facilite a manipulação e o entendimento dos dados. Para isso, são usadas técnicas focadas na identificação de padrões de comportamento e na definição de classes (HAN; KAMBER, 2006), que fazem com que nossas observações relevantes sejam geralmente de menor tamanho e dimensionalidade do que o conjunto de dados original (VIDAL, 2011).

A definição das classes é função da similaridade entre os dados, de forma que os da-

dos correspondentes a uma mesma classe devem mostrar um alto grau de homogeneidade, enquanto, dados pertencentes a classes diferentes devem apresentar um alto grau de heterogeneidade entre eles (DUDA *et al.*, 2001; PENA, 2002). Dessa forma, conjuntos de dados com tais características podem ser tratados coletivamente como uma entidade só e, em outras palavras, ao maximizar as similaridades dos dados, o conjunto das classes obtidas pode ser utilizado como dicionário, de forma que os dados pertencentes a uma classe são representados por um único protótipo ou centróide, mostrando assim, os primeiros indícios de compressão.

Os métodos de construção do dicionário podem ser classificados, basicamente, em métodos probabilísticos, métodos de agrupamento não supervisionado e métodos de estrutura dedicada.

- Os *métodos probabilísticos* tem como propósito obter uma aproximação do mínimo global do valor esperado da energia da distorção em um número finito de passos.
- Os *métodos de agrupamento não supervisionado* consistem em fazer agrupamentos de padrões estatisticamente similares, de modo que, ao final, cada grupo é representado por único padrão. Estes métodos têm sido os mais amplamente utilizados, principalmente pela simplicidade na implementação e pela rapidez na resposta, muito embora a sua convergência nem sempre seja para o mínimo global.
- Os *métodos de estrutura dedicada* baseiam-se na ideia de que muitas aplicações não necessitam de dicionários genéricos, mas podem se beneficiar de um dicionário constituído por um conjunto de funções paramétricas. Ao contrário dos dicionários genéricos, a vantagem dos dicionários paramétricos reside na breve descrição dos códigos. Isso é muito benéfico em termos de consumo de memória, velocidade de transmissão e diminuição da complexidade na implementação (TOSIC; FROSSARD, 2011).

Nesta etapa do trabalho o propósito principal é encontrar a localização ótima do vetor código no espaço de dados. Para isso, são projetados dois dicionários. Um deles baseia-se em métodos de agrupamento não supervisionado. Já para o segundo dicionário são utilizadas redes competitivas, e mais especificamente, os mapas Auto-Organizáveis de Kohonen (SOM) (KOHONEN, 1988). Em relação aos métodos de agrupamento não supervisionado geralmente são sugeridas variantes do algoritmo de *Lloyd generalizado*, como são, o algoritmo *Linde-Buzo-Gray* (LBG) (LINDE *et al.*, 1980) e o algoritmo *k-means* (DUDA *et al.*, 2001; PENA, 2002), que até o momento continuam sendo as referências mais comumente usadas para efeitos de comparação. Estes algoritmos fornecem soluções de tipo iterativas que convergem rapidamente.

Os algoritmos Linde-Buzo-Gray (LBG) e k-means são variantes do algoritmo *Generalized Lloyd Algorithm* (GLA) que a sua vez é a generalização para o caso vetorial do algoritmo de quantização escalar proposto por Lloyd em 1957 (LLOYD, 1957) e publicado depois pela

IEEE em 1982 (LLOYD, 1982). O algoritmo GLA é executado utilizando um conjunto de vetores de treinamento que caracterizam estatisticamente o espaço de interesse. Também é definido um dicionário inicial ( $\mathcal{C}^{(0)}$ ), tal que cada vetor código representa uma das partições iniciais do espaço. De forma iterativa o algoritmo constrói o dicionário em duas etapas bem definidas, as quais são apresentadas na tabela 2.1.

Tabela 2.1: Descrição do algoritmo GLA. Fonte: (AGUNDIS, 2008).

Partição do espaço $\mathbb{R}^p$		Cálculo dos centróides	
Passo	Operação	Passo	Operação
1	$k \leftarrow 0, d_{\text{média}}^{(0)}, d_{\text{relativa}}^{(0)}, \mathcal{C}^{(0)}, \xi$	8	Para $i = \{1, 2, \dots, N\}$
2	Para $j = \{1, 2, \dots, M\}$	9	Calcular $\hat{X}_i^{(k+1)}$
3	Para $i = \{1, 2, \dots, N\}$	10	próximo $i$
4	$d_i \leftarrow d(X_j, \hat{X}_i^{(k)})$	11	$k \leftarrow k + 1$
5	próximo $i$	12	Calcular $d_{\text{média}}^{(k)}, d_{\text{relativa}}^{(k)}$
6	$\hat{X}_{i^*} = \min_{\hat{X}_i \in \mathcal{C}} \{d(X, \hat{X}_i)\}$	13	Se $d_{\text{relativa}}^{(k)} > \xi$ , retorna para o passo 2
7	próximo $j$	14	Senão Terminar

Durante a primeira etapa, busca-se a partição ótima do espaço  $p$ -dimensional de modo que cada vetor  $X_j$  pertença a uma única região  $R_i^{(k)}$  associada ao vetor código  $\hat{X}_i^{(k)}$  mais próximo. O algoritmo utiliza a distância euclidiana quadrática  $d$  como medida de distorção. O cálculo do número de operações nesta etapa e segundo critério de distorção adotado, quando utiliza-se um dicionário de tamanho  $N$  de dimensão  $p$ , é igual a  $p$  subtrações,  $p$  multiplicações e  $p - 1$  somas. Assim sendo, como o conjunto de treinamento é de tamanho  $M$ , executam-se um total de  $MNp$  subtrações,  $MNp$  multiplicações e  $MN(p - 1)$  somas, para determinar a partição do espaço de dados. Na segunda etapa, tendo obtido uma nova partição, recalculam-se os centróides para cada nova região, gerando um conjunto de novos vetores código  $\hat{X}_i^{(k+1)}$ . Para calcular os novos centróides é utilizada a expressão (2.11). A quantidade de operações nesta etapa corresponde a  $Mp$  somas e  $Np$  divisões (PEREIRA *et al.*, 2009). O cálculo da quantidade de operações foi feita para cada iteração.

$$\hat{X}_i^{(k+1)} = \frac{\sum_{Q(X_j)=\hat{X}_i^{(k)}} X_j}{\sum_{Q(X_j)=\hat{X}_i^{(k)}} 1} \quad (2.11)$$

A distorção média  $d_{\text{média}}^{(k)}$  é calculada após cada iteração usando a expressão (2.12), onde, o  $Q^{(k)}$  é o mapeamento gerado na  $k$ -ésima iteração e  $\hat{X}_i^{(k)}$  corresponde à estimativa de  $X_j$  após a quantização.

$$d_{\text{média}}^{(k)} = \frac{1}{M} \sum_{j=1}^M d(X_j, Q^{(k)}(X_j)) = \frac{1}{M} \sum_{j=1}^M d(X_j, \hat{X}_j^{(k)}) \quad (2.12)$$

O algoritmo é executado iterativamente recalculando os centróides até que o critério de parada ou convergência seja satisfeito ( $d_{relativa}^{(k)} < \xi$ ). O critério de parada corresponde à variação relativa da distorção média entre duas iterações consecutivas. O algoritmo é penalizado quando a variação relativa da distorção converge assintoticamente para um valor constante  $\xi$ . Em outras palavras, o algoritmo se detém quando a variação entre os centróides atinge um valor prefixado. A variação relativa da distorção média na  $k$ -ésima iteração é expressa pela equação (2.13).

$$d_{relativa}^{(k)} = \frac{|d_{média}^{(k)} - d_{média}^{(k-1)}|}{d_{média}^{(k)}} \quad (2.13)$$

Na construção do dicionário usando o algoritmo iterativo GLA é importante destacar o papel do dicionário inicial. O algoritmo original propõe um dicionário inicial gerado de forma aleatória, mas também pode ser gerado heurísticamente. No entanto, estas duas propostas podem causar que vetores do dicionário inicial não sejam os vetores mais próximos de algum outro vetor do dicionário originando classes vazias (PAL *et al.*, 1993).

#### 2.4.1 Algoritmo Linde-Buzo-Gray (LBG)

O algoritmo LBG apresentado na tabela 2.2, resolve o problema do dicionário inicial de outra forma. Propõe inserir uma etapa que consiste em aumentar iterativamente o tamanho do dicionário inicial em valores iguais a potências de dois ( $N = 2^L, N < M$ ), até alcançar um nível aceitável de distorção.

Tabela 2.2: Descrição do algoritmo LBG. Fonte: (DATA-COMPRESSION..., 2011)

Passo	Operação	Passo	Operação
1	$\epsilon$	8	Algoritmo GLA
2	$N \leftarrow 1$	9	$d_{média}^* \leftarrow d_{média}^{(k)}$
3	Calcular $\hat{X}_1^*$ e $d_{média}^*$	10	Para $i = \{1, 2, \dots, N\}$
4	Para $i = \{1, 2, \dots, N\}$	11	$\hat{X}_i^{(*)} \leftarrow \hat{X}_i^{(k)}$
5	Calcular $\hat{X}_i^{(0)}$ e $\hat{X}_{N+i}^{(0)}, c^{(0)}$	12	próximo $i$
6	próximo $i$	13	Repetir os passos 4-8 até conseguir o tamanho do dicionário desejado
7	$N \leftarrow 2N$		

O algoritmo inicia com um dicionário  $\mathcal{C}^{(0)}$  de tamanho ( $N = 2$ ), os dois vetores são o resultado da aplicação da expressão (2.16) ao vetor  $\hat{X}_1^*$  que corresponde ao cálculo do centróide do conjunto de vetores de treinamento, como se expressa em (2.14). A distorção média  $d_{média}^*$  é calculada com a equação (2.15).

$$\hat{X}_1^* = \frac{1}{M} \sum_{j=1}^M X_j \quad (2.14)$$

$$d_{\text{m\u00e9dia}}^* = \frac{1}{M} \sum_{j=1}^M d(X_j, \hat{X}_1^*) \quad (2.15)$$

Se o dicion\u00e1rio inicial n\u00e3o satisfazer os crit\u00e9rios predeterminados, retorna ao in\u00edcio e divide cada vetor  $\hat{X}_i^*$  em dois vetores pr\u00f3ximos, aumentando o tamanho do dicion\u00e1rio inicial de  $N$  para  $2N$ , tal e como se expressa em (2.16), onde  $\epsilon$  \u00e9 o vetor perturba\u00e7\u00e3o. O algoritmo \u00e9 repetido at\u00e9 que o dicion\u00e1rio atinja um tamanho predeterminado ou at\u00e9 que o patamar de distor\u00e7\u00e3o relativa seja satisfeito.

$$\begin{aligned} \hat{X}_i^{(0)} &= (1 + \epsilon) \hat{X}_i^* \\ \hat{X}_{N+i}^{(0)} &= (1 - \epsilon) \hat{X}_i^* \end{aligned} \quad (2.16)$$

## 2.4.2 Algoritmo k-means

O algoritmo k-means apresentado na tabela 2.3, \u00e9 considerado uma das mais populares heur\u00edsticas usadas para agrupamento de dados ou quantiza\u00e7\u00e3o. Para executar o algoritmo \u00e9 necess\u00e1rio definir previamente o tamanho do dicion\u00e1rio inicial e os valores dos vetores c\u00f3digo que o constituem, o que significa, que desde o in\u00edcio \u00e9 prefixado o n\u00famero de regi\u00f5es nas quais se quer dividir o espa\u00e7o de dados (VIOLATO, 2010). A sele\u00e7\u00e3o dos vetores que comp\u00f5em o dicion\u00e1rio inicial pode ser feita de forma aleatoria, de forma a tomar os vetores mais distantes entre si, ou utilizando o conhecimento *a priori* das caracter\u00edsticas da informa\u00e7\u00e3o (PENA, 2002). Depois de definir o tamanho e as componentes do dicion\u00e1rio inicial, \u00e9 executado o algoritmo GLA. A aloca\u00e7\u00e3o de cada vetor nas classes \u00e9 feita de forma sequencial, ap\u00f3s calcular a dist\u00e2ncia entre cada vetor e os centr\u00f3ides gerando a matriz de similaridade.

Tabela 2.3: Descri\u00e7\u00e3o do algoritmo k-means. Fonte: (VIOLATO, 2010).

Passo	Opera\u00e7\u00e3o
1	$\mathcal{C}^{(0)}, \xi$
2	Algoritmo GLA
3	Repetir o passo 2 at\u00e9 o refinamento do c\u00e1lculo das coordenadas dos centr\u00f3ides

O problema da defini\u00e7\u00e3o do tamanho do dicion\u00e1rio inicial pode ser resolvido executando o algoritmo com dicion\u00e1rios de diferentes tamanhos at\u00e9 encontrar o dicion\u00e1rio que produza a melhor solu\u00e7\u00e3o. O crit\u00e9rio de converg\u00eancia pode ser um n\u00famero predeterminado de itera\u00e7\u00f5es ou ent\u00e3o a aus\u00eancia de altera\u00e7\u00f5es nos centr\u00f3ides. Contudo, o objetivo n\u00e3o \u00e9 mais identificar grupos, mas, sim, produzir uma representa\u00e7\u00e3o mais compacta dos dados (KANUNGO *et al.*, 2002).

### 2.4.3 Mapas Auto-Organizáveis de Kohonen (SOM)

Características como paralelismo, não linearidade, distributividade, conectividade, aprendizado e adaptação, fazem com que as redes neurais artificiais (RNAs) sejam uma ferramenta útil para resolver problemas de interesse comum na engenharia (HAYKIN, 1999). As RNAs são uma técnica computacional de modelagem inspirada na estrutura funcional do cérebro, com as quais se tenta reproduzir comportamentos de acordo com o conhecimento adquirido através da experiência. Da mesma forma, as RNAs podem apresentar comportamentos imprevisíveis, quando submetidas a ambientes diversos, criando assim suas próprias representações internas (SOUZA, 2005; ZUCHINI, 2003).

Os modelos neurais são um sistema de processamento em paralelo composto por várias unidades de processamento (neurônios) interligadas através de conexões sinápticas associadas a um parâmetro de ajuste (peso sináptico). Cada neurônio soma todas as contribuições e produz uma saída que pode ser enviada para si mesmo ou ainda para os outros neurônios. Estruturalmente, os neurônios são classificados em neurônios de entrada (recebem estímulos do meio externo), neurônios internos ou ocultos, e neurônios de saída (enviam estímulos ao meio externo). Esta estrutura possui a capacidade de adaptar-se ao meio e responder de forma autônoma em função de estímulos experimentados (informação). Cada neurônio recebe as conexões de outros neurônios e/ou dele mesmo, e executa as operações apenas sobre seus dados locais (conhecimento).

A maioria dos modelos neurais possui uma etapa de treinamento ou aprendizado, que consiste em um processo iterativo de ajuste de parâmetros. Ao final do treinamento, o conhecimento adquirido é representado por meio de uma matriz que contém a intensidade das conexões entre neurônios. Os pesos armazenados são ajustados de acordo com o comportamento dos padrões apresentados, permitindo à RNA desenvolver a capacidade de executar adequadamente o processamento desejado (HAYKIN, 1999). O aprendizado pode-se classificar pela presença ou ausência de realimentação explícita, tal e como se ilustra nas figuras 2.8(a) e 2.8(b). Uma realimentação explícita significa que em certos intervalos de tempo um agente externo indica a resposta desejada. No caso em que a realimentação não é explícita o aprendizado não é influenciado pelo agente externo.

No *aprendizado supervisionado*, o agente externo indica explicitamente um comportamento adequado para a RNA, visando direcionar o processo de treinamento. Em outras palavras, cada entrada apresentada à RNA vem acompanhada de uma resposta desejada e os pesos sinápticos da RNA são modificados no sentido tornar a saída a mais próxima possível daquela desejada. A minimização do erro é realizada progressivamente através de pequenos ajustes nos pesos a cada época de treinamento até atingir o patamar predeterminado, o que é equivalente a encontrar um mínimo na função de custo (erro quadrático médio). Caso novos dados sejam adicionados, um novo treinamento com o conjunto completo deve ser realizado.

Considera-se *aprendizado não supervisionado* quando para fazer modificações nos valo-

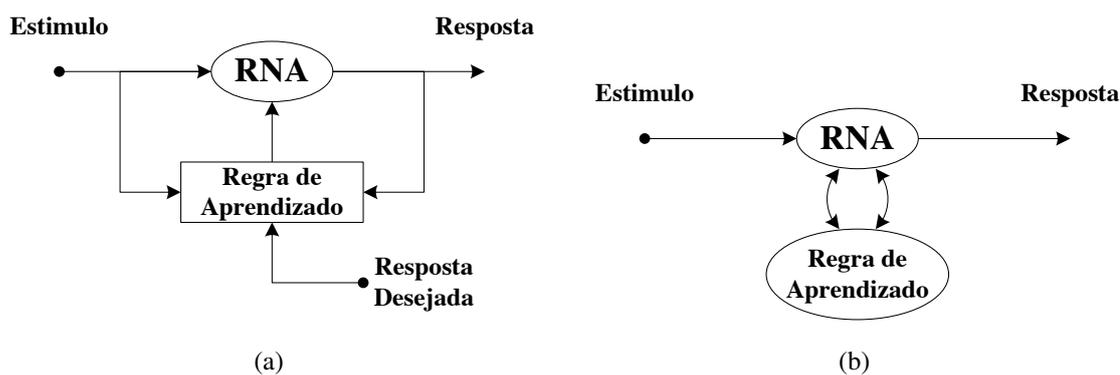


Figura 2.8: Tipos de aprendizado. (a) Supervisionado. (b) Não Supervisionado. Fonte: (BARRETO, 2002).

res das conexões sinápticas não são usadas informações sobre a resposta da RNA. A partir do momento em que a RNA reconhece as regularidades estatísticas dos dados, começa a desenvolver a capacidade para detectar similaridades entre os diferentes padrões, gerando representações internas que permitem construir novas classes ou grupos automaticamente. Neste esquema, somente os padrões de entrada estão disponíveis para a RNA. A estrutura do sistema de treinamento não supervisionado pode tomar uma variedade de formas diferentes, com conexões diretas entre as camadas de entrada e de saída, e conexões laterais entre os neurônios das diferentes camadas. O processo de treinamento consiste em modificar repetidamente o peso sináptico de todas as conexões do sistema em resposta às entradas. Este tipo de aprendizado se chama também descobridor de regularidades, ou redes auto-organizadas devido à propriedade básica de seu funcionamento (BARRETO, 2002).

Da figura 2.9, observa-se que no treinamento não-supervisionado, os neurônios recebem os mesmos estímulos e são interligados por meio de conexões excitatórias representadas por pesos distribuídos aleatoriamente ( $w_{ji}$ ). O esquema permite que os neurônios entrem na competição pelo direito de permanecerem excitados, portanto, os neurônios são inibidos por outros neurônios por meio de conexões inibitórias, de modo que a competição entre eles resulta na excitação de um único neurônio. Estímulos que possuem alguma semelhança tendem a excitar o mesmo neurônio na saída, portanto, a saída pode ser usada para representar a estrutura do espaço de entrada. Dentro da taxonomia das RNAs, e baseado no paradigma de aprendizagem e das regras de adaptação dos pesos, a rede de Kohonen é considerada um tipo de rede competitiva com aprendizado não supervisionado (HAYKIN, 1999).

A arquitetura dos SOM é motivada em estudos comportamentais do cérebro durante o aprendizado. Tem-se observado zonas do cérebro onde os neurônios interagem em função da distância entre eles, constituindo pequenos blocos de processamento na infraestrutura do sistema nervoso, de modo que, a informação captada pelos sentidos é representada internamente em forma de mapas bidimensionais. Este tipo de comportamento sugere que o cérebro possui a capacidade de construir organizações de neurônios a partir da informação obtida de ambientes externos (KOHONEN, 1982; VANHULLE, 2000).

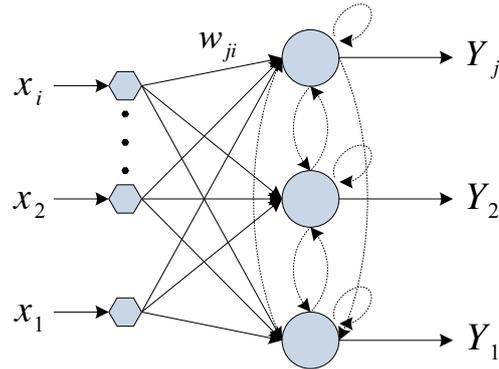


Figura 2.9: Arquitetura de uma rede competitiva. Conexões Excitatórias (linha cheia). Conexões Inibitórias (linha pontilhada). Fonte: (HAYKIN, 1999).

Os mapas auto-organizáveis de Kohonen são uns dos principais modelos de RNAs na atualidade e são utilizados em inúmeras aplicações (KASKI *et al.*, 1998; OJA *et al.*, 2002). A quantização vetorial é uma delas, e consiste em que cada neurônio representa uma das regiões ( $R_i \in \mathbb{R}^p$ ) nas quais está dividido o espaço  $\mathbb{R}^p$ , cujo centroide é o vetor código constituído pelos pesos das conexões desse neurônio. Inicialmente o algoritmo de aprendizado permite encontrar o vetor código mais próximo ao vetor de entrada, e assim determinar o neurônio vencedor. Após esta etapa é feito o ajuste dos pesos do neurônio vencedor aproximando o vetor código ao vetor de entrada (KOHONEN, 1988).

Matematicamente, o objetivo é representar um espaço contínuo por meio de um arranjo geométrico finito de unidades de processamento (neurônios). Para isso, é utilizada uma transformação não-linear ( $\Phi$ ) que executa o mapeamento das características entre os espaços. Dado o vetor de entrada, o SOM procede a identificar o neurônio que apresenta o melhor casamento (neurônio vencedor) no espaço de saída de acordo com o mapeamento proposto. Enquanto o vetor de pesos sinápticos do neurônio vencedor pode ser interpretado como as coordenadas da imagem do neurônio vencedor projetada no espaço de entrada. A figura 2.10 ilustra a relação entre o mapeamento característico e o vetor de pesos sinápticos do neurônio vencedor (HAYKIN, 1999).

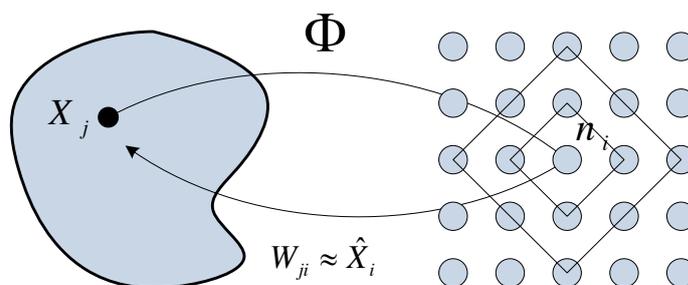


Figura 2.10: Mapeamento do espaço de entrada para uma grade bidimensional retangular. Fonte: (HAYKIN, 1999).

O algoritmo de treinamento para uma rede tipo SOM é descrito na tabela 2.4. Como passo inicial são definidos, a topologia da rede (geometria), o número de neurônios ( $N$ ), o raio inicial da vizinhança ( $\sigma^{(0)}$ ) e a taxa de aprendizado inicial ( $\eta^{(0)}$ ). Também, são gerados aleatoriamente os valores iniciais dos vetores de pesos  $W_{ji}^{(0)}$  da rede. O algoritmo é definido estrategicamente em dois processos: Competição e Cooperação.

Tabela 2.4: Descrição do algoritmo de treinamento para uma rede SOM. Fonte: (HAYKIN, 1999).

Passo	Operação
1	$N, \sigma_0, \eta_0, W_{ji}^{(0)}, \xi, k_{\max}$
2	Enquanto $k < k_{\max}$
3	Para $j = \{1, 2, \dots, M\}$ , Para $i = \{1, 2, \dots, N\}$
4	Calcular $d_{ji} \leftarrow d(X_j, W_{ji}), W_{ji} = \min_{W_{ji} \in \mathcal{E}} \{d_{ji}\}$
5	Calcular $d_{\text{lateral}}, \sigma(t), \eta(t), h(t), W_{ji}^{(k+1)}$
6	próximo $i$ , próximo $j$
7	Calcular $d_{\text{média}}, d_{\text{relativa}}$
8	Se $d_{\text{relativa}} > \xi$ , retorna para o passo 3, $k \leftarrow k + 1$
9	Senão $k \leftarrow k_{\max}$ , fim enquanto

Durante o processo de *competição*, é minimizada a função de custo (distância Euclidiana), visando escolher aquele neurônio que melhor represente o vetor de entrada. Dito neurônio é declarado o vencedor da competição e fica localizado no centro de uma vizinhança. No processo de *cooperação*, a interação entre o neurônio vencedor e sua vizinhança está determinada pela taxa de aprendizado  $\eta(t)$  e por uma função gaussiana unimodal  $h(t)$ , que depende da distancia lateral entre o neurônio vencedor e seus vizinhos. Avaliando a expressão (2.17), nota-se que a vizinhança  $h(t)$  possui o máximo valor quando  $d_{\text{lateral}} = 0$ , o que quer dizer que a interação é mais forte com ele mesmo. O tamanho da vizinhança diminui de forma simétrica com o aumento da distância lateral, mostrando que a interação com os vizinhos é menor. As equações (2.18) e (2.19) correspondem às funções que definem o raio da vizinhança e a taxa de aprendizado respectivamente. Onde,  $\tau_\sigma$  e  $\tau_\eta$  são as constantes de amortecimento.

$$h(t) = \exp \left\{ -\frac{d_{\text{lateral}}^2}{2\sigma(t)} \right\} \quad (2.17)$$

$$\sigma(t) = \sigma_0 \exp \left\{ -\frac{t}{\tau_\sigma} \right\} \quad (2.18)$$

$$\eta(t) = \eta_0 \exp \left\{ -\frac{t}{\tau_\eta} \right\} \quad (2.19)$$

Depois do calculo da vizinhança, o ajuste dos pesos sinápticos é o último passo na formação de um mapa auto-organizável. Em (KOHONEN, 1998), propõe-se uma regra recursiva

para ajuste dos pesos, inspirada nos estudos propostos em Hebb (1949), onde são relacionados a dinâmica da sinapse, o processo de aprendizado e a memória. A equação para a atualização dos pesos sinápticos da rede é apresentada em (2.20), na qual, o vetor de pesos associado ao neurônio vencedor fica com a maior parcela do ajuste e seus vizinhos experimentaram um ajuste baseado na função de vizinhança.

$$W_{ji}^{(k+1)} = W_{ji}^{(k)} + \eta(t)h(t)[X_j - W_{ji}^{(k)}] \quad (2.20)$$

O valores de  $\eta(t)$  e de  $h(t)$  controlam a intensidade com que os pesos sinápticos são alterados. Estes valores diminuem gradativamente com o transcorrer do treinamento de modo a garantir convergência e a estabilidade do mapa. A diminuição no número de vizinhos é importante para melhorar a correlação entre as direções de ajuste dos pesos de um número de neurônios. Para cada novo vetor de entrada apresentado à rede SOM durante o treinamento, somente o vetor de pesos associado ao neurônio vencedor deve ser modificado em função do estímulo da entrada, mantendo o conhecimento previamente aprendido.

## 2.5 BANCOS DE FILTROS

Os bancos de filtros são considerados uma ferramenta matemática que possibilita a modelagem da relação entrada-saída de um sistema por meio de um esquema de análise e síntese, como mostrado na figura 2.11. Com a ajuda dos bancos de filtros tenta-se descrever matematicamente e de forma suficientemente acurada os fenômenos intrínsecos dos sinais (OPPENHEIM; SCHAFER, 1999; MITRA, 2001; PROAKIS; MANOLAKIS, 1996).

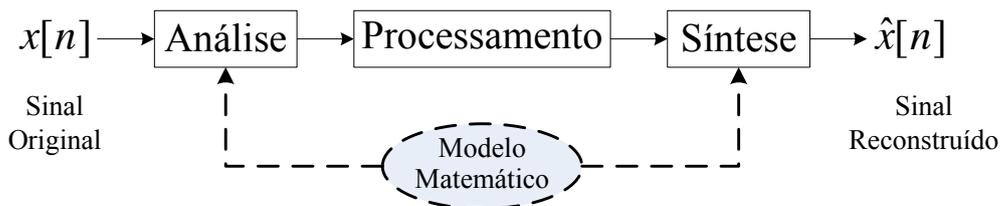


Figura 2.11: Diagrama de blocos de um sistema de análise e síntese para a modelagem de sinais. Fonte: (TCHEOU, 2011)

A análise corresponde ao processo de ajuste de um modelo a um sinal particular, e a síntese é responsável por reconstruir o sinal utilizando o modelo e a informação obtida durante a análise. De forma geral, os dados de análise podem ser processados para fins de supressão de ruído, filtragem, compressão, e modificação de sinais (VETTERLI; KOVACEVIC, 1995).

O bloco de análise está constituído por um conjunto de filtros configurados em paralelo onde sua resposta em frequência caracteriza-se por dividir o sinal em sub-bandas (VAIDYANATHAN, 1990). Por outro lado, o banco de filtros de síntese consiste em um conjunto de

filtros cujas saídas são combinadas para formar o sinal sintetizado. Ambos os casos são mostrados na figura 2.12.

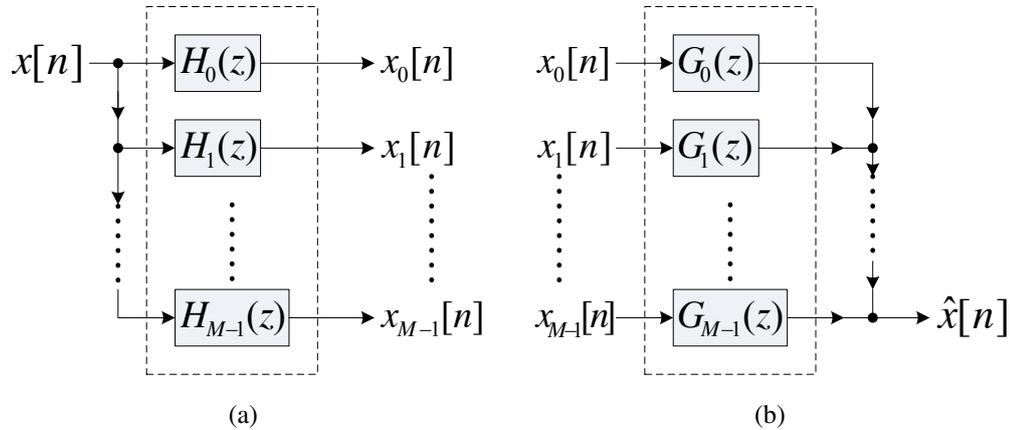


Figura 2.12: Banco de filtros de análise e síntese. (a) Bloco de Análise. (b) Bloco de Síntese. Fonte: (DINIZ *et al.*, 2010) (Modificado).

O banco de filtros de análise está constituído pelos filtros  $H_k(z)$ , para  $k = \{0, 1, \dots, M-1\}$ , que dividem o sinal  $x[n]$  em  $M$  sinais  $x_k[n]$  chamados de sub-bandas. Os filtros de síntese  $G_k(z)$ , são aqueles que combinam as  $M$  sub-bandas em um único sinal  $\hat{x}[n]$ . Dependendo do número de bandas utilizadas para decompor o sinal, os bancos de filtros são chamados de  $M$  bandas ( $M > 2$ ) e de duas bandas ( $M = 2$ ) (DINIZ *et al.*, 2004; DINIZ *et al.*, 2010).

Na figura 2.13 é ilustrada a decomposição e reconstrução do sinal em múltiplas bandas. No sistema de análise, o sinal é decomposto em  $M$  bandas de frequência por meio do banco de filtros  $H_k(z)$  e dizimado por um fator de dizimação  $M$ , onde as sub-bandas  $u_k[n]$  ocupam bandas de frequências diferentes. A largura de banda de cada filtro é  $\frac{\pi}{M}$ .

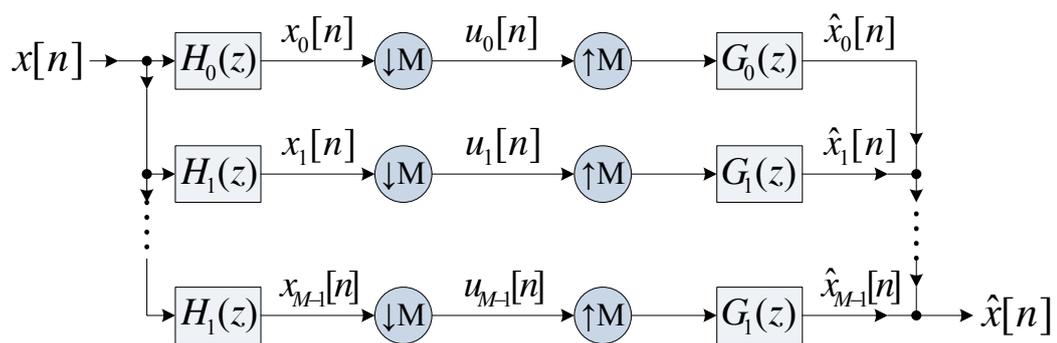


Figura 2.13: Sistema genérico de decomposição e reconstrução de sinais em múltiplas bandas baseado em bancos de filtros. Fonte: (DINIZ *et al.*, 2010) (Modificado).

O sistema de síntese tem como objetivo reconstruir o sinal original a partir da informação contida em cada sub-banda,  $u_k[n]$ . Os sistemas interpoladores recuperam a taxa do sinal original por inserção de amostras nulas. Após esta operação, são usados os filtros de síntese,  $G_k(z)$ , de forma a eliminar a superposição dos espectros (*aliasing*) devido à dizimação.

Os sinais resultantes  $\hat{x}_k[n]$ , são combinados por adição, de forma que  $\hat{x}[n]$ , seja uma boa estimativa de  $x[n]$ . Um esquema completo de codificação de sinais por sub-bandas baseado em um sistema análise-síntese é mostrado na figura 2.14.

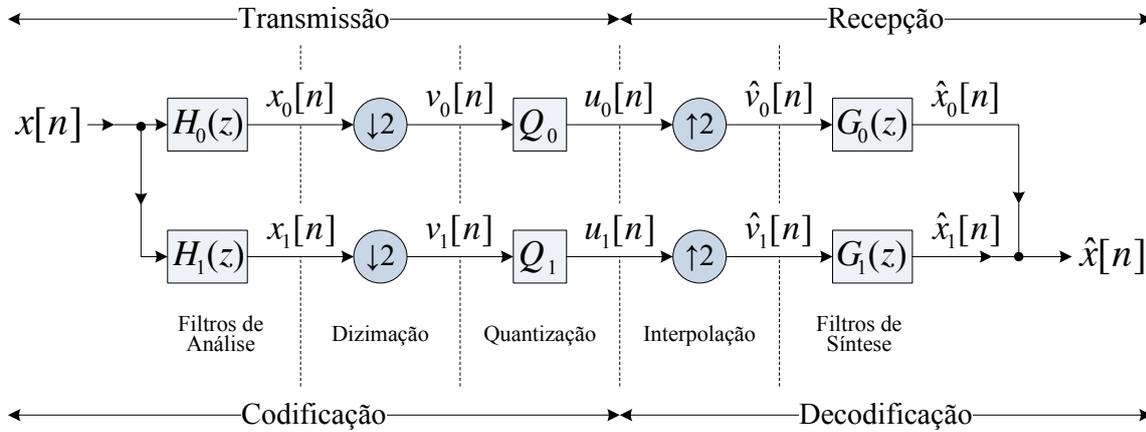


Figura 2.14: Sistema de codificação e decodificação de duas bandas ( $M=2$ ) usando filtros realizáveis. Fonte: (VAIDYANATHAN, 1993) (Modificado).

O sistema de análise é constituído por dois filtros realizáveis, um passa-baixas ( $H_0(z)$ ) e um passa-altas ( $H_1(z)$ ) com largura de banda aproximada de  $\frac{\pi}{2}$  e dizimadores com fator de 2. O sistema de síntese é formado por interpoladores com fator de 2 e filtros de reconstrução de características semelhantes. Verifica-se que após alocar um número específico de bits por amostra em cada sub-banda dependendo do conteúdo de energia, a reconstrução do sinal é executada usando os interpoladores e os filtros de síntese, de forma que as componentes de *aliasing* sejam canceladas mutuamente. Este resultado para  $M=2$  pode ser generalizado para um esquema de múltiplas bandas, onde o sinal pode ser dividido em  $M$  sub-bandas e cada uma delas é quantizada de forma independente (VAIDYANATHAN, 1990; VAIDYANATHAN, 1993; DINIZ *et al.*, 2004; DINIZ *et al.*, 2010).

O sistema exposto, utiliza um banco de filtros conhecido como banco de filtros espelhados em quadratura (FEQ). O filtro de análise passa-altas é projetado de forma a alternar os sinais da resposta ao impulso do filtro passa-baixas ( $H_1(z) = H_0(-z)$ ), onde a resposta de módulo do filtro passa-altas  $|H_1(e^{j\omega})|$  é a imagem espelhada da resposta do módulo do filtro passa-baixas  $|H_0(e^{j\omega})|$ , em relação à frequência de quadratura  $\frac{\pi}{2}$ .

Conhecidos  $H_0(z)$  e  $H_1(z)$  é possível cancelar completamente o *aliasing* escolhendo os filtros de síntese de forma que, os filtros passa-baixas e passa-altas sejam  $G_0(z) = H_1(-z)$  e  $G_1(z) = -H_0(-z)$  respectivamente. A escolha permite o cancelamento do *aliasing* por meio dos filtros de síntese, em vez de ser totalmente evitado localmente pelos filtros de análise, o que corresponde à ideia básica do banco de filtros FEQ (DINIZ *et al.*, 2004; DINIZ *et al.*, 2010).

## 2.6 TRANSFORMADAS ORTOGONAIS

Do ponto de vista matemático, um sinal  $x(t)$  que pertence ao espaço  $\Psi$  pode ser representado em termos de uma combinação linear de funções  $\{\psi_k(t)\}_{k \in \mathbb{Z}}$  de comprimento finito ou infinito pertencentes ao domínio de  $\Psi$ . Isto é,

$$x(t) = \sum_k a_k \psi_k(t), \quad k \in \mathbb{Z} \quad (2.21)$$

Se o conjunto de funções de base  $\{\psi_k(t)\}_{k \in \mathbb{Z}}$  for considerado completo, então, qualquer sinal  $x(t)$  pode ser expandido como definido em (2.21), e existirá um conjunto dual de funções de base  $\{\hat{\psi}_k(t)\}_{k \in \mathbb{Z}}$ , tal que, os coeficientes da expansão possam ser calculados pelo produto interno, no domínio de  $\Psi$ . Neste contexto, o produto interno da equação (2.22) é conhecido como equação de análise ou transformação. Do mesmo modo na expressão (2.21), considera-se o processo inverso conhecido como equação de síntese ou transformada inversa. As funções de base  $\hat{\psi}_k(t)$  e  $\psi_k(t)$  denominam-se de funções de análise e de síntese respectivamente.

$$a_k \equiv \langle x(t), \hat{\psi}_k(t) \rangle = \int_{-\infty}^{+\infty} x(t) \hat{\psi}_k^*(t) dt \quad (2.22)$$

A operação produto interno  $\langle \cdot, \cdot \rangle$  representa o grau de similaridade entre o sinal  $x(t)$  e a função de base dual  $\hat{\psi}_k(t)$ . Assim, quanto maior o valor do produto interno, maior a semelhança entre o sinal e a base de representação. Os coeficientes  $a_k$  indicam o valor da projeção do sinal sobre estas funções.

A escolha do conjunto de funções de análise e síntese torna-se um tópico importante, em razão das diferentes interpretações derivadas dos sinais a serem analisados. Por exemplo, para explorar de forma acertada e consistente um sinal estacionário ou um sinal cujas componentes de frequência não variam com o tempo, é desejável que as funções de base tenham resolução máxima no domínio da frequência, tal como acontece no caso da transformada de Fourier (TF). A expressão (2.23) corresponde à equação de análise da TF, onde se observa que para calcular o conteúdo espectral de  $x(t)$ , as funções de base se estendem por todo o domínio do tempo  $(-\infty, +\infty)$ .

$$a_k = \frac{1}{T} \int_{-\infty}^{+\infty} x(t) e^{-jk\Omega_0 t} dt \quad (2.23)$$

As funções exponenciais complexas harmonicamente relacionadas ( $e^{-jk\Omega_0 t}$ ) correspondem a impulsos localizados em  $k\Omega_0$  no domínio da frequência, e cujas amplitudes são os valores resultantes do produto interno que descrevem o comportamento do sinal nas frequências apontadas. Análises com a TF não são adequadas para sinais aperiódicos ou de suporte compacto, porque não apresentam característica de localização no tempo e não permitem o

cancelamento das funções de base fora do intervalo de análise, originando espalhamento da energia do espectro.

Em algumas aplicações é interessante caracterizar o comportamento de um sinal não estacionário no domínio do tempo e da frequência simultaneamente. Logo, as funções de base devem ser localizadas tanto no domínio do tempo quanto no domínio da frequência. Como representantes deste tipo de funções destacam-se as funções de Gabor, as quais, têm a forma  $(\psi(t) = g(t - \tau)e^{-jk\Omega_0 t})$  onde, a função  $g(t)$  é de suporte compacto e bem localizada em termos de tempo e frequência, como por exemplo, a função Gaussiana de média igual a zero (GABOR, 1946). As funções de Gabor são utilizadas como funções de base na transformada de Fourier de curta duração (TFCD). A expressão para a TFCD é apresentada em (2.24).

$$X(\Omega_0, \tau) = \int_{-\infty}^{+\infty} x(t)g(t - \tau)e^{-j\Omega_0 t} dt \quad (2.24)$$

Observa-se na equação (2.24) que os sinais exponenciais complexos são modulados pela função  $g(t - \tau)$ , para calcular o conteúdo espectral do sinal em determinado intervalo de tempo. Em outras palavras, a TFCD é equivalente ao cálculo da TF do produto  $x(t)g(t - \tau)$ , onde  $g(t)$  é utilizado para isolar os valores de  $x(t)$  em torno de  $t = \tau$  (DINIZ *et al.*, 2010). Da figura 2.15(a), observa-se que a janela (linha pontilhada) é deslocada pelo sinal (linha cheia) para determinar seu comportamento espectral, em torno do ponto  $X(\Omega = \Omega_0, t = \tau)$  no plano de resolução tempo-frequência (vide figura 2.15(b)), onde  $t \in [\tau - \sigma_t, \tau + \sigma_t]$  e  $\Omega \in [\Omega_0 - \sigma_\Omega, \Omega_0 + \sigma_\Omega]$ .

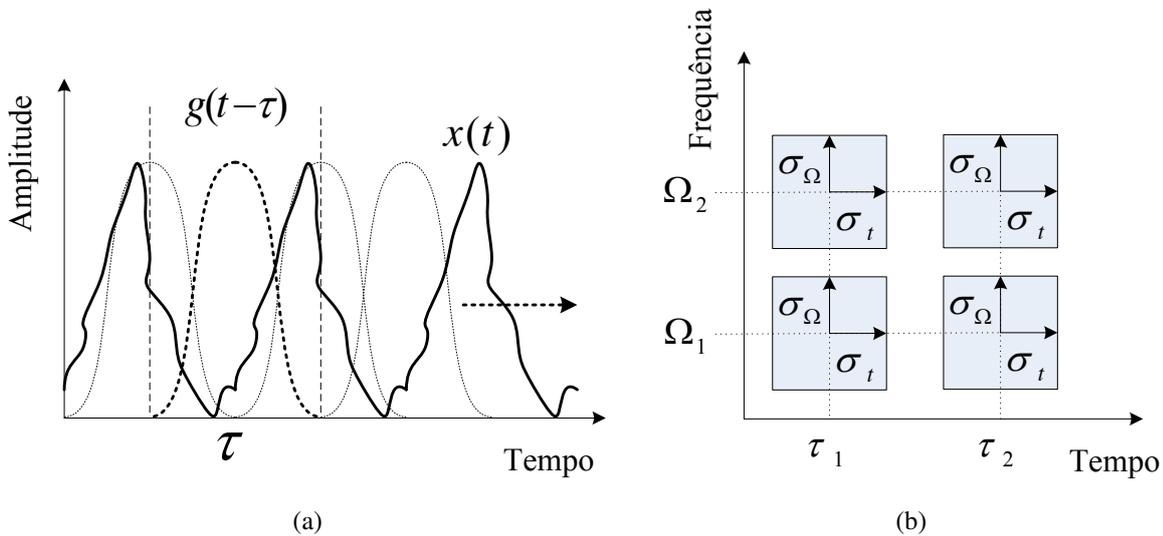


Figura 2.15: Transformada de Fourier de curta duração (TFCD). (a) Deslocamento de  $g(t)$  no domínio do tempo. (b) Plano da resolução tempo-frequência. Fonte: (DINIZ *et al.*, 2010) (Modificado).

As divisões no eixo horizontal representam o intervalo de tempo analisado e as divisões no eixo vertical representam as bandas de frequência. Verifica-se que a TFCD analisa

bandas de tamanho fixo, com duração e largura de banda constantes, e iguais a  $2\sigma_t$  e  $2\sigma_\Omega$  respectivamente (MALLAT, 1989).

A resolução de tamanho fixo da TFCD oferece uma grande desvantagem na análise de sinais altamente não estacionários (variações de frequência de diferente duração). Uma vez que a função  $g(t)$  é fixada, a sua resolução tempo-frequência também é fixada, e somente as características de tamanho comparável a  $g(t)$  podem ser analisadas. Com a alteração das dimensões da janela é necessário calcular novamente a TFCD para as novas condições. Em consequência, para melhorar a adaptação às características a serem analisadas precisa-se de uma resolução mais flexível. A transformada wavelet (TW) fornece essa propriedade permitindo fazer as análises com janelas de diferentes tamanhos (DINIZ *et al.*, 2004; DINIZ *et al.*, 2010).

As funções de base da TW são derivadas do deslocamento (translação) e do escalamento (dilatação/compressão) de uma função básica  $\psi(t)$  chamada de função wavelet mãe. A família de funções de base wavelet  $\psi_{s,\tau}(t)$  para um fator de escala  $s$  e uma translação  $\tau$ , é apresentada em (2.25). A wavelet mãe  $\psi(t)$  é uma função real, decrescente, oscilatória, com média zero e de suporte compacto.

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right), \quad \{s, \tau\} \in \mathfrak{R}, \quad s > 0 \quad (2.25)$$

Os parâmetros  $s$  e  $\tau$  estão associados à largura de banda e à janela de tempo a ser analisada respectivamente. A variação dos parâmetros provê de uma descrição tempo-frequência de  $x(t)$ , onde o centro da localização no tempo está situado em volta de  $\tau$ , com um espalhamento proporcional ao parâmetro  $s$ . Uma descrição do processo de escalamento e deslocamento é mostrada na figura 2.16.

Da figura 2.16(a) ressalta-se que a vantagem da TW sobre as outras transformadas consiste em que a banda de análise é completamente modulável e escalável, culminando em um conjunto de representações tempo-frequência para diferentes resoluções. O processo é realizado alterando a escala sistematicamente para cada janela de análise até percorrer o sinal completo. Da figura 2.16(b) destaca-se que nas regiões de alta frequência é necessária uma compressão no tempo, o que equivale a aumentar largura de banda na mesma proporção, caso contrario ocorre nas baixas frequências, onde é necessária uma dilatação (DINIZ *et al.*, 2010; MALLAT, 2001).

Conhecendo as características e os parâmetros das funções wavelet, apresenta-se a transformada wavelet contínua (TWC), cujas expressões (2.26) e (2.27) correspondem às equações de análise e síntese. Onde  $C_\psi$  é uma constante que depende de  $\psi(t)$ .

$$W(s, \tau) = \int_{-\infty}^{+\infty} x(t) \psi_{s,\tau}^*(t) dt \quad (2.26)$$

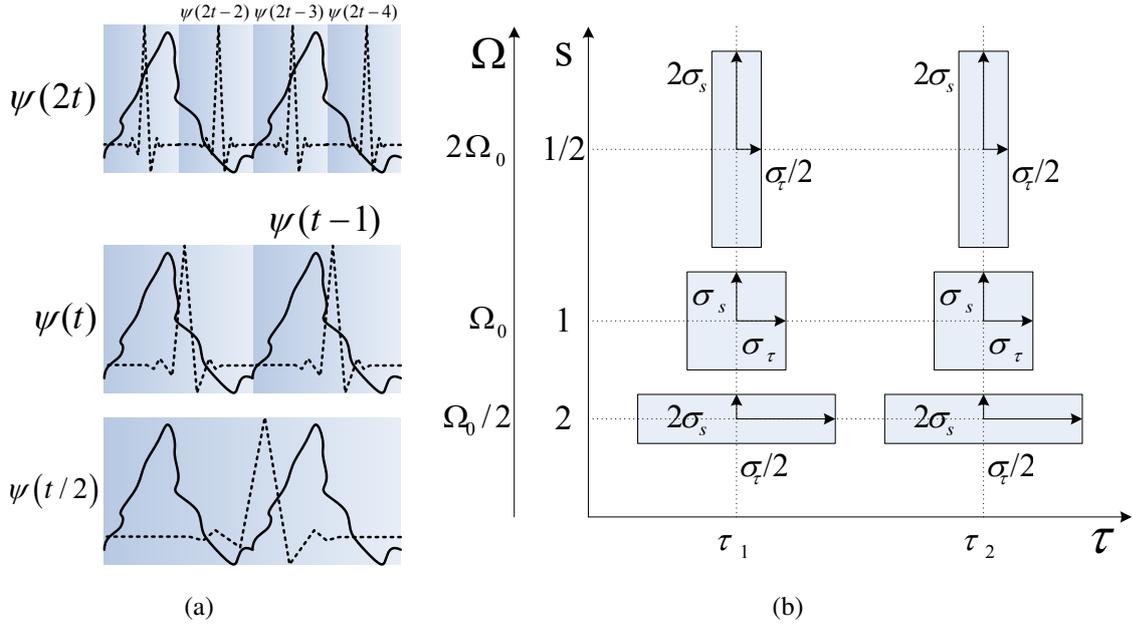


Figura 2.16: Transformada wavelet (TW). (a) Processo de escalamento e deslocamento.  $x(t)$  (linha cheia).  $\psi_{s,\tau}(t)$  (linha pontilhada). (b) Plano da resolução tempo-frequência. Fonte: (DINIZ *et al.*, 2010) (Modificado).

$$x(t) = C_{\psi}^{-1} \int_0^{+\infty} \frac{ds}{s^2} \int_{-\infty}^{+\infty} W(s, \tau) \psi_{s,\tau}(t) d\tau \quad (2.27)$$

A TWC faz um mapeamento bidimensional de uma função unidimensional, o que sugere que o sinal original pode ser recuperado a partir da aplicação da TWC apenas sobre uma grade discreta, em razão ao aumento da redundância após o mapeamento. Motivado pela implementação computacional, os parâmetros de escalamento e de deslocamento são discretizados ( $s = s_0^m, \tau = n\tau_0 s_0^m$ ,  $s_0 > 1 \forall \{m, n\} \in \mathbb{Z}$ ). A discretização de  $\tau$  corresponde a uma amostragem no tempo, então, a frequência de amostragem deve ser proporcional à largura de banda do sinal a ser amostrado, que por sua vez é inversamente proporcional à escala  $s$ . A versão discretizada da TWC é mostrada em (2.28), (2.29) e (2.30).

$$\psi_{m,n}(t) = s_0^{-m/2} \psi(s_0^{-m} t - n\tau_0) \quad (2.28)$$

$$W(m, n) = s_0^{-m/2} \int_{-\infty}^{+\infty} x(t) \psi_{m,n}^*(t) dt \quad (2.29)$$

$$x(t) = \sum_{m=-\infty}^{+\infty} \sum_{n=-\infty}^{+\infty} W(m, n) \psi_{m,n}(t) \quad (2.30)$$

Cada diferente valor de  $s_0$  pode levar a bases ortonormais diferentes. No entanto, usou-se uma representação diádica, onde os parâmetros  $s_0$  e  $\tau_0$  são 2 e 1 respectivamente. A discre-

tização logarítmica na base 2 do parâmetro de escala, pode ser interpretada como uma representação característica para cálculos computacionais, enquanto que o parâmetro de valor unitário implica considerar a mesma taxa de amostragem do sinal. É interessante observar na discretização proposta, que para cada incremento em  $m$ , a largura no domínio do tempo o dobra, e reduzindo para metade a largura no domínio da frequência. O índice  $m$  é denominado nível de decomposição da TW (BERGER, 2008).

Até este momento, somente tem-se considerado que as funções derivadas de  $\psi(t)$  formam uma base ortonormal. Em outras palavras, que a função wavelet e sua função dual são iguais ( $\psi(t) = \hat{\psi}(t)$ ). Em consequência, as equações de análise e síntese utilizam o mesmo conjunto de funções de base, como no caso da TF e TFCD. Existem alguns casos onde é possível usar dois conjuntos diferentes de funções Wavelets, um para a análise e outro para a síntese. Este caso refere-se a transformada de wavelet Biortogonal. A condição de biortogonalidade sugere que cada um dos conjuntos de funções de análise ( $\psi_{m,n}(t)$ ) e de síntese ( $\hat{\psi}_{m,n}(t)$ ) não são ortogonais, no entanto,  $\psi_{m,n}(t)$  e  $\hat{\psi}_{m,n}(t)$  são ortogonais entre eles. Isso pode ser verificado pela expressão

$$\langle \psi_{m,n}(t), \hat{\psi}_{k,l}(t) \rangle = \delta(m - k) \delta(n - l) \quad (2.31)$$

Após a discretização, a TWC torna-se a transformada discreta Wavelet (TDW). A equações (2.29), (2.32), (2.33) e (2.34) definem a TDW.

$$x(t) = \sum_{m=-\infty}^{+\infty} \sum_{n=-\infty}^{+\infty} W(m, n) \hat{\psi}_{m,n}(t) \quad (2.32)$$

$$\psi_{m,n}(t) = 2^{-m/2} \psi(2^{-m}t - n) \quad (2.33)$$

$$\hat{\psi}_{m,n}(t) = 2^{-m/2} \hat{\psi}(2^{-m}t - n) \quad (2.34)$$

A análise em multiresolução (AMR), consiste em fazer uma representação do sinal no domínio discreto utilizando taxas de amostragem diferentes (resoluções). O sinal é separado em bandas de frequências, estando cada banda relacionada a um nível de decomposição ou escala. A aproximação obtida para a maior escala (baixa frequência), conjuntamente com os detalhes obtidos nas escalas restantes, permitem a representação eficiente do sinal original. A idéia fundamental associada à AMR é a decomposição do sinal, em vários sinais mais simples, por aproximação em escalas sucessivas (níveis de detalhe). Considera-se  $\phi(t)$  uma função que gera um conjunto ortonormal de funções da forma  $\phi(t - n) \in V_0 \forall \{n \in \mathbb{Z}\}$ , e  $V_0$  como o espaço gerado por este conjunto. De forma análoga, define-se também  $V_m$  como o espaço gerado pelas funções  $2^{-m/2} \phi(2^{-m}t - n)$ . Seja  $V_j \forall \{j \in \mathbb{Z}\}$  o conjunto de subespaços fechados, onde pode-se interpretar que o aumento do valor de  $m$ , gera subespaços formados por conjuntos de funções ortonormais que apresentam uma resolução menor (DINIZ *et al.*, 2010).

Dada a expressão 2.35 observa-se que o espaço  $V_1$  (baixa resolução) está contido em  $V_0$  e este a sua vez encontra-se contido em  $V_{-1}$  (alta resolução). Verifica-se que todos os subespaços correspondem a versões escaladas por um fator de 2 do espaço original, isto é, o espaço de funções  $V_j$  gerado pelas funções de escala deve ser um subespaço do espaço de funções  $V_{j-1}$ .

$$\cdots \supset V_{-1} \supset V_0 \supset V_1 \supset V_2 \supset \cdots \quad (2.35)$$

Define-se  $W_j$  como o complemento ortogonal de  $V_j$  em  $V_{j-1}$  tal que,  $W_j \perp V_j$  e  $W_j \oplus V_j = V_{j-1}$ . Onde  $\oplus$  denota a operação de soma ortogonal, o que corresponde ao fechamento linear de dois espaços ortogonais. Interpreta-se  $W_j$  como nível de detalhe, acrescentado ao espaço  $V_j$  quando se passa para um espaço de resolução maior  $V_{j-1}$ . Da figura 2.17(a), observa-se que a transformada wavelet executa a decomposição de um sinal em espaços de diferentes resoluções ou tamanhos. Onde, os coeficientes transformados correspondem à projeção do sinal nos determinados espaços.

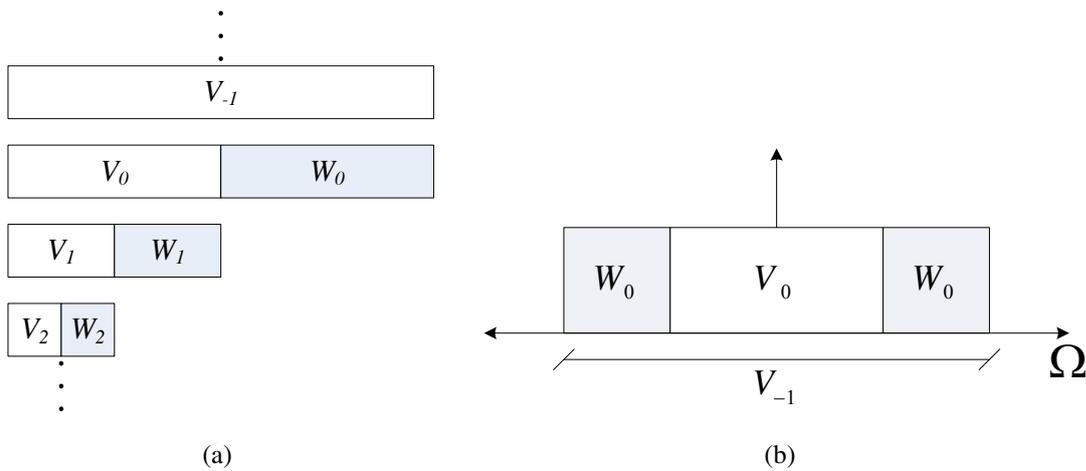


Figura 2.17: Análise Multiresolução (AMR). (a) Esquema de decomposição dos subespaços. (b) Decomposição no domínio da frequência. Fonte: (DINIZ *et al.*, 2010) (Modificado).

Da figura 2.17(b), constata-se que no domínio da frequência, o espaço  $V_{-1}$  tem o dobro da largura de banda de  $V_0$ , o que está relacionado diretamente com dobro da resolução do tempo.  $W_0$  é composto das funções que estão em  $V_{-1}$ , mas não em  $V_0$  e, portanto, está contido na região entre as bandas  $\phi(t-n)$  e  $\sqrt{2}\phi(2t-n)$ , que corresponde a banda passante de  $\psi(t-n)$  (DINIZ *et al.*, 2010). Verifica-se que os subespaços  $V_j$  são gerados pelas bases  $\phi_{j,n}(t) = 2^{-j/2}\phi(2^{-j}t-n)$  e os subespaços  $W_j$  por  $\psi_{j,n}(t) = 2^{-j/2}\psi(2^{-j}t-n)$ . A função  $\phi$  designa-se função base de escala, e a função  $\psi$  é a wavelet mãe para escala  $j$ . Ou seja, quaisquer funções  $f_j(t) \in V_j$  e  $g_j(t) \in W_j$  podem ser representadas por combinações lineares de  $\phi_{j,n}(t)$  e  $\psi_{j,n}(t)$ , respectivamente.

$$f_j(t) = 2^{-j/2} \sum_{n=-\infty}^{\infty} a_{j,n} \phi(2^{-j}t - n) \quad (2.36)$$

$$g_j(t) = 2^{-j/2} \sum_{n=-\infty}^{\infty} d_{j,n} \phi(2^{-j}t - n) \quad (2.37)$$

Onde,  $a_{j,n}$  e  $d_{j,n}$  são chamados de coeficientes dos filtros de escala e wavelet respectivamente. Considerando que  $f(t) \in V_0 \in V_{-1}$ , e  $g(t) \in W_0 \in V_{-1}$  as equações (2.36) e (2.37) podem ser expressas como,

$$\phi(t) = \sqrt{2} \sum_{n=-\infty}^{\infty} a_n \phi(2t - n) \quad (2.38)$$

$$a_n = \int_{-\infty}^{\infty} \phi(t) \phi(2t - n) dt \quad (2.39)$$

$$\psi(t) = \sqrt{2} \sum_{n=-\infty}^{\infty} d_n \phi(2t - n) \quad (2.40)$$

$$d_n = \int_{-\infty}^{\infty} \psi(t) \phi(2t - n) dt \quad (2.41)$$

Os coeficientes  $a_n$  e  $d_n$  são relacionados pela expressão  $d_n = (-1)^n a_{1-n}$ . Dada a possibilidade de representar sinais nos espaços da AMR através dos coeficientes dos filtros  $a_n$  e  $d_n$ , e considerando que os espectros das funções de escala e wavelet equivalem a filtros passa-baixas ( $H_{0n}$ ) e passa-altas ( $H_{1n}$ ), respectivamente, pode-se interpretar que cada escala da AMR equivale a um banco de filtros. Assim, a decomposição ortonormal de um sinal discreto pode ser associada a bancos de filtros em cada nível de resolução.

As equações (2.38), (2.39), (2.40) e (2.41) apresentam uma forma recursiva para o cálculo dos coeficientes da TDW. Os coeficientes  $a_n$  são chamados de coeficientes de aproximação e os coeficientes  $d_n$  são chamados de coeficientes de detalhe. Na prática, assume-se que um sinal discreto na sua escala de resolução original corresponde aos coeficientes de aproximação. Então, se o conjunto de filtros  $H_{0n}$  e  $H_{1n}$  são escolhidos de forma que tenham um número finito de coeficientes não nulos, ou seja, são filtros FIR, do inglês *Finite Impulse Response (FIR)*. A TDW pode ser calculada pelo banco de filtros da figura 2.18(a).

Após a filtragem, os coeficientes passam por um processo de dizimação, que consiste em remover um de cada dois coeficientes. O conjunto de coeficientes de aproximação, por sua vez, passam em seguida por uma nova divisão, de forma a gerar coeficientes sucessivamente. Como resultado, obtém-se um vetor com o mesmo tamanho do sinal de entrada, contendo os coeficientes de aproximação do último nível de decomposição, que possui baixa resolução, e os coeficientes de detalhe de todos os níveis de decomposição, de baixa e alta resolução. A representação gráfica do processo é mostrado na figura 2.18(b).

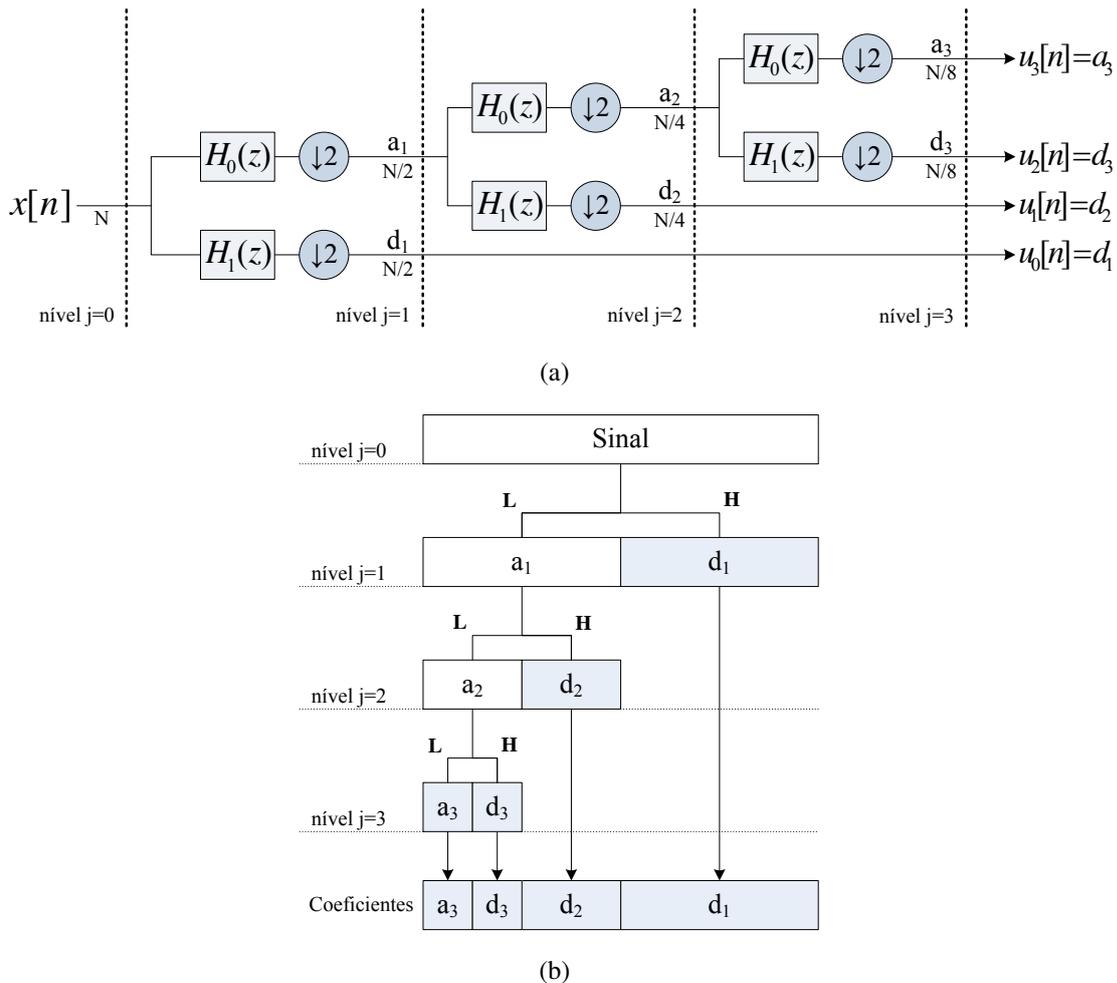


Figura 2.18: Esquema de cálculo para a TDW para três níveis de decomposição. (a). Banco de filtros de análise. (b). Estrutura de organização dos coeficientes. Fonte: (DINIZ *et al.*, 2010) (Modificado).

Para a reconstrução do sinal, aplica-se o procedimento inverso à decomposição chamado de transformada inversa. O banco de filtros de síntese para a reconstrução é projetado com uma estrutura FEQ. Como os coeficientes de aproximação e detalhe foram dizimados, não podem ser combinados diretamente para reconstruir o sinal. Portanto, devem ser reconstruídos separadamente, pela inserção de zeros entre os coeficientes, e depois combinados.

O algoritmo eficiente para calcular os coeficientes da TDW através da teoria de filtros foi desenvolvido como alternativa ao cálculo através do produto interno. O algoritmo é conhecido como, algoritmo piramidal ou de árvore, que é de fato um esquema clássico de codificação por sub-bandas. A grande vantagem deste algoritmo é que os coeficientes da transformada são calculados sem a necessidade do cálculo explícito da função wavelet. O que se projeta então é o banco de filtros utilizado, o qual determina a possibilidade da perfeita reconstrução do sinal.

As transformadas ortogonais correspondem a casos específicos dos bancos de filtros. Neste trabalho utilizou-se a transformada discreta de wavelets pela habilidade de representar

---

e analisar sinais com resoluções variáveis no tempo e na frequência. Para sinais digitais a implementação numérica da TDW pode ser considerada como um banco de filtros criticamente dizimados (VETTERLI; HERLEY, 1992).

## **2.7 CONSIDERAÇÕES FINAIS**

Neste capítulo foi apresentado, de forma concisa, o embasamento teórico que contribuiu na concepção do projeto dos algoritmos para compressão de sinais de sistemas elétricos de potência. Dada a sua importância para a concretização desta pesquisa, foram estudados os principais conceitos e definições relacionados aos temas: compressão de dados, quantização, construção de dicionários, bancos de filtros e transformadas ortogonais, fazendo ênfase na alocação dinâmica de bits, na quantização vetorial e nas redes de Kohonen. As informações usadas nesta tese são sustentadas por ampla e atual referência bibliográfica. Os conhecimentos adquiridos fornecem uma visão do objetivo da pesquisa e podem ser ligados facilmente a cada etapa do algoritmo onde foram utilizados.

No próximo capítulo, serão abordados temas relacionados com o comportamento dos sinais de tensão e corrente na presença de distúrbios gerados no sistema elétrico de potência. Mais especificamente no que diz respeito ao conteúdo espectral dos diferentes fenômenos eletromagnéticos e ao contexto onde poderão ser empregados os algoritmos.



# Capítulo 3

## Monitoramento e Análise de Distúrbios

### 3.1 CONSIDERAÇÕES INICIAIS

A interligação dos sistemas elétricos de potência traz vantagens como: a ampliação na disponibilidade de unidades de geração, o intercâmbio de energia entre regiões de diferentes sazonalidades, maior capacidade de reserva para as contingências, etc. Não obstante, incrementa-se a propagação de distúrbios pela rede, o que se considera uma desvantagem. Em consequência, a necessidade do monitoramento das redes elétricas cresce conforme aumenta a interligação dos sistemas elétricos de potência, demandando grande investimento em infraestrutura por parte das empresas do setor.

### 3.2 OSCIOLOGRAFIA

O aumento da demanda de energia elétrica durante o século XX trouxe consigo um crescimento na infraestrutura e na interligação dos sistemas de energia elétrica. Durante pouco mais da primeira metade do século, o setor elétrico experimentou grandes dificuldades operacionais pela falta de ferramentas adequadas que permitissem fazer a coleta de dados para as análises das ocorrências. A oscilografia nasceu pela necessidade de analisar o comportamento no domínio do tempo das grandezas tensão e corrente durante uma ocorrência (TCHEOU *et al.*, 2006).

Os oscilógrafos analógicos fizeram sucesso dos anos 20 até os anos 90. Eram equipamentos eletromecânicos que desenhavam as oscilações induzidas pelos fenômenos eletromagnéticos, por meio de uma agulha móvel acoplada a um rolo de papel em movimento. A partir desse momento, os registros gráficos viraram documentos e material de estudo para os analistas das operadoras, transmissoras e concessionárias. A evolução do oscilógrafo analógico se deu quando começou-se a utilizar como registro papel fotossensível gravado por sinais luminosos (BRITO *et al.*, 2009; SOUZA *et al.*, 2010). As limitações tecnológicas da época e os custos altos associados à aquisição, operação e manutenção dos oscilógrafos analógicos faziam do sistema de oscilografia um tópico importante no orçamento das empresas, sendo

então utilizados geralmente em sistemas elétricos prioritários (alta e extra-alta tensão). Os oscilogramas eram coletados localmente e enviados por meios de transporte convencionais ou fax para os centros de análise. Nesse sentido, o manuseio e o armazenamento apresentavam grande dificuldade devido à degradação dos registros ao passar do tempo, gerando perda de informação (TCHEOU, 2005). Os registros provenientes dos oscilógrafos são chamados de oscilogramas. Segundo Moreto & Rolim (2010), os oscilogramas podem ser classificados como se apresenta na tabela 3.1.

Tabela 3.1: Classificação dos tipos de oscilogramas. Fonte: Moreto & Rolim (2010).

<b>Tipo</b>	<b>Informação</b>	<b>Tempo de Registro</b>	<b>Taxa de Amostragem</b>
Curta Duração	Formas de onda	Da ordem de segundos	> 8 amostras por ciclo
Fasoriais	Módulo e ângulo	Da ordem de minutos	1 amostra por ciclo
Medição Contínua	Módulo e ângulo	Da ordem de horas ou dias	1 amostra por minuto

Os avanços tecnológicos conseguidos até a primeira metade da década de 80 permitiram superar as limitações da oscilografia analógica e deixaram o caminho livre para que os oscilógrafos digitais chegassem e se consolidassem nos últimos anos. Um tipo de oscilógrafo digital é conhecido como Registrador Digital de Perturbações (RDP), o qual exporta os dados das formas de onda coletadas em arquivos com diferentes formatos e no formato padrão (IEEE STD C37.111, 1999). Grande parte dos relés digitais utilizados em sistemas de proteção tem incorporados recursos de oscilografia. É importante destacar que a oscilografia tem o objetivo de tornar possível a análise posterior das ocorrências, diferentemente dos sistemas de proteção, que devem atuar em tempo real para garantir a confiabilidade do sistema (SILVA *et al.*, 2007).

O novo cenário do setor elétrico mundial contempla padrões de funcionamento com maiores níveis de exigência, que obrigam aos diferentes agentes do setor (geração, transmissão e distribuição) a se reestruturarem. Para cada um desses agentes, tornou-se importante o monitoramento e a documentação das ocorrências (eventos ou distúrbios) como uma forma de melhorar a operação do sistema (altos índices de qualidade) e garantir a competitividade entre as empresas do setor (LI *et al.*, 2010). Neste contexto, as informações obtidas pelos equipamentos de medição passaram a ocupar um papel de destaque. Os RDP possuem características de acesso remoto, o que faz possível a implementação das chamadas redes de oscilografia, que têm como objetivo concentrar a informação referente à oscilografia em único local da rede de dados. O tamanho da rede de oscilografia depende das dimensões da rede elétrica a ser monitorada (SILVA *et al.*, 2007; MORETO; ROLIM, 2010).

As redes de oscilografia provocam algumas dificuldades no que diz respeito ao armazenamento, transmissão e gerenciamento da grande quantidade de dados que são disponibilizados. Portanto, são desenvolvidas ferramentas computacionais que permitem a detecção, identificação, classificação e análise automática dos oscilogramas, com vistas à redução do

recurso físico e do tempo gasto pelos engenheiros analistas melhorando a operação. Uma descrição simplificada da operação de um sistema de oscilografia é ilustrada na figura 3.1.

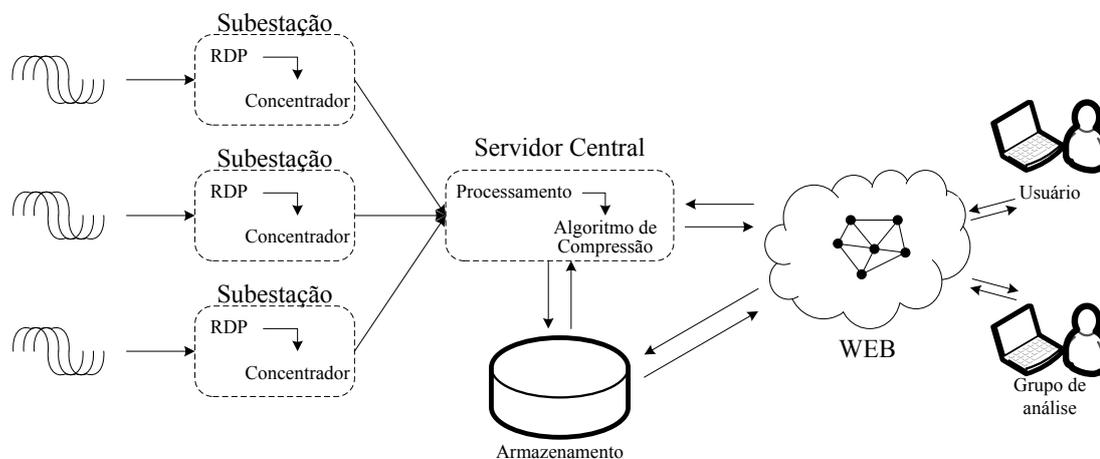


Figura 3.1: Descrição simplificada de uma rede de oscilografia. Fonte: O autor, 2012.

Na figura 3.1, observa-se que as informações coletadas pelos RDP, são concentradas em cada subestação, processadas e organizadas em registros padronizados para seu envio aos centros de armazenamento através de diferentes meios de comunicação (SILVA *et al.*, 2007). Na etapa de processamento, os distúrbios são detectados, identificados e classificados para evitar armazenar registros repetidos e separar as faltas dos distúrbios de QEE (MORETO; ROLIM, 2010). Nota-se que se fosse inserido um algoritmo de compressão entre as etapas de processamento e armazenamento, poder-se-ia reduzir o tempo de ocupação do canal para transmissão e o espaço para armazenamento, permitindo a conservação de informação valiosa do estado da rede elétrica e facilitando a consulta por parte dos interessados.

As informações decorrentes dos sistemas de oscilografia constituem os históricos da operação do sistema elétrico de potência, e são úteis na análise de equipamentos e do desempenho do sistema de proteção, na localização de faltas, na avaliação das ocorrências e dos distúrbios de QEE, e no auxílio dos processos que visem à isenção de responsabilidade da empresa pelas ocorrências (MORETO; ROLIM, 2010).

### 3.3 QUALIDADE DA ENERGIA ELÉTRICA

O tema da qualidade no fornecimento da energia elétrica tem ganhado muito interesse nos últimos anos devido à dependência existente entre as atividades desenvolvidas pelos seres humanos e a energia elétrica. Esta situação demanda a prestação de um serviço com níveis de qualidade adequados (DUNGAN *et al.*, 2002). Na figura 3.2 são definidos as responsabilidades de cada agente do setor elétrico. Destaca-se o compromisso entre os agentes para se conservar os níveis de emissividade e susceptibilidade dentro dos limites planejados.



Figura 3.2: Responsabilidades dos agentes no que diz respeito à QEE. Fonte: (DUNGAN *et al.*, 2002) (Modificado).

A Agência Nacional de Energia Elétrica (ANEEL) mediante PRODIST (2011), define que o tema da qualidade no fornecimento da energia elétrica pode ser dividido em dois aspectos, a saber:

- *Qualidade do Produto*, descreve as características dos distúrbios e estabelece os parâmetros e valores de referência relativos à conformidade de tensão em regime permanente.
- *Qualidade do Serviço*, está relacionada com os procedimentos relativos aos indicadores de continuidade e dos tempos de atendimento.

Unicamente será parte do escopo da pesquisa o que concerne à qualidade do produto, no que diz respeito à degradação dos parâmetros (frequência única e constante, e amplitude fixa) que definem as formas de onda dos sinais de tensão e corrente.

Os aspectos tratados anteriormente dizem respeito à qualidade da tensão e não sobre a qualidade da corrente. A razão disso é que tecnicamente pode ser exercido o controle sobre a tensão, enquanto a corrente é determinada pela solicitação das cargas. Nesse sentido, surge como complemento o termo *Power Quality*, que não tem relação com o produto da tensão pela corrente, mas, que avalia os desvios dos sinais de tensão e de corrente em relação a sua forma ideal e (BOLLEN, 2000). Uma descrição da relação entre o consumidor e a concessionária no contexto atual da QEE é mostrada por meio da figura 3.3.

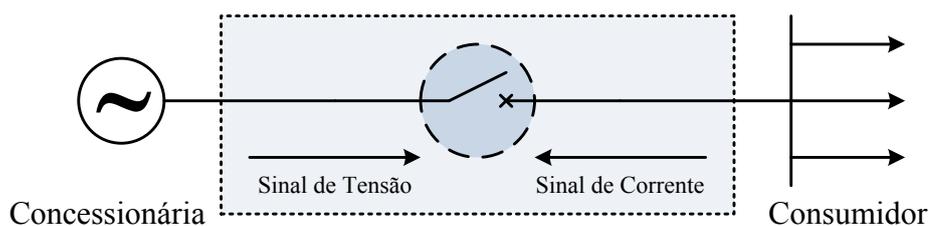


Figura 3.3: Interação Concessionária-Consumidor. Fonte: (BOLLEN, 2000) (Modificado).

---

Da figura 3.3 percebe-se que a qualidade da tensão está voltada para o que a concessionária entrega para o consumidor, enquanto que a qualidade da corrente está voltada para o que o consumidor solicita da concessionária (OLIVEIRA, 2008). Unicamente será parte do escopo da pesquisa o que concerne à qualidade do produto, no que diz respeito à degradação dos parâmetros (frequência única e constante, e amplitude fixa) que definem as formas de onda dos sinais de tensão e corrente.

### **3.3.1 Descrição de distúrbios típicos**

Problemas de QEE, distúrbios ou fenômenos eletromagnéticos são termos usados para descrever as variações dos parâmetros que caracterizam os sinais de tensão ou de corrente em torno de seu valor nominal. A razão mais importante para classificar ditas variações, consiste em que para cada tipo de distúrbio existem abordagens particulares.

Em documento oferecido pela *International Electrotechnical Commission* (IEC), os fenômenos eletromagnéticos são classificados tanto pela faixa de frequência quanto pela forma em que eles são introduzidos no sistema elétrico de potência. Na tabela 3.2 verifica-se a classificação dos principais fenômenos eletromagnéticos de acordo com a IEC 61000-2-5 (2008).

Tabela 3.2: Principais fenômenos que causam distúrbios eletromagnéticos conforme classificado do IECs IEC 61000-2-5. Fonte: (IEC 61000-2-5, 2008), (IEEE STD 1159, 2009) (Modificado)

<b>Grupo</b>	<b>Exemplos</b>
Fenômenos conduzidos de baixa frequência	Harmônicas, Interharmônicas Portadoras de Sinais Flutuações de Tensão Afundamentos e Interrupções de Tensão Desequilíbrio de Tensão Variações de Frequência Tensões de Baixa Frequência Induzidas CD em CA Redes
Fenômenos irradiados de baixa frequência	Campos Magnéticos Campos Elétricos
Fenômenos conduzidos de alta frequência	Ondas Contínuas Induzidas (tensão ou corrente) Transitórios Impulsivos Transitórios Oscilatórios
Fenômenos irradiados de alta frequência	Campos Magnéticos Campos Elétricos Campos Eletromagnéticos Ondas Contínuas Transitórios
Fenômenos de Descargas Eletrostáticas	—
Pulso Eletromagnético Nuclear	—

Destaca-se que na IEC 61000-2-5 (2008), não são definidos os valores de referência para os termos baixa frequência e alta frequência, embora sejam destinados para descrever o conteúdo espectral dos fenômenos listados nessas categorias. Outra classificação é disponibilizada pelo *Institute of Electrical and Electronics Engineers (IEEE)*. Neste caso os fenômenos eletromagnéticos são classificados pelo conteúdo espectral, duração e magnitude (IEEE STD 1159, 2009). As categorias apresentadas na tabela 3.3 são as mais usadas pela comunidade de QEE porque fornecem um nível maior de detalhe na descrição dos distúrbios. Nota-se na tabela 3.3, que quase a totalidade dos fenômenos descritos é direcionada aos sinais de tensão, no entanto, tais fenômenos também se manifestam nos sinais de corrente.

Tabela 3.3: Categorias e características típicas de fenômenos eletromagnéticos dos sistemas de potência. Fonte: (IEEE STD 1159, 2009) (Modificado).

Categorias	Conteúdo Espectral	Duração	Magnitude da Tensão
1 Transitórios			
1.1 Impulsivos			
1.1.1 Nanosegundo	> 5 ns	< 50 ns	
1.1.2 Microsegundo	> 1 $\mu$ s	50 ns – 1 ms	
1.1.3 Milisegundo	> 0,1 ms	> 1 ms	
1.2 Oscilatórios			
1.2.1 Baixa frequência	< 5 kHz	0,3 – 50 ms	0 – 4 pu
1.2.2 Média frequência	5 – 500 kHz	20 $\mu$ s	0 – 8 pu
1.2.3 Alta frequência	0,5 – 5 MHz	5 $\mu$ s	0 – 4 pu
2 Variações RMS de Curta Duração			
2.1 Instantâneas			
2.1.1 Afundamentos		0,5 – 30 ciclos	0,1 – 0,9 pu
2.1.2 Elevações		0,5 – 30 ciclos	1,1 – 1,8 pu
2.2 Momentâneas			
2.2.1 Interrupção		0,5 ciclos – 3 s	< 0,1 pu
2.2.2 Afundamento		30 ciclos – 3 s	0,1 – 0,9 pu
2.2.3 Elevação		30 ciclos – 3 s	1,1 – 1,4 pu
2.3 Temporárias			
2.3.1 Interrupção		>3 s – 1 min	< 0,1 pu
2.3.2 Afundamento		>3 s – 1 min	0,1 – 0,9 pu
2.3.3 Elevação		>3 s – 1 min	1,1 – 1,2 pu
3 Variações RMS de Longa Duração			
3.1 Interrupção contínua		> 1 min	0,0 pu
3.2 Subtensões		> 1 min	0,8 – 0,9 pu
3.3 Sobretensões		> 1 min	1,1 – 1,2 pu
3.4 Corrente de sobrecarga		> 1 min	
4 Desequilíbrio			
4.1 Tensão		regime permanente	0,5 – 2 %
4.2 Corrente		regime permanente	1,0 – 30 %
5 Distorção da forma de onda			
5.1 Componente DC		regime permanente	0 – 0,1 %
5.2 Harmônicas	0 – 9 kHz	regime permanente	0 – 20 %
5.3 Inter-Harmônicas	0 – 9 kHz	regime permanente	0 – 2 %
5.4 Cortes de tensão		regime permanente	
5.5 Ruído de banda larga		regime permanente	0 – 1 %
6 Flutuação de tensão	< 25 Hz	intermitente	0,1 – 7 % ou 0,2 – 2 Pst
7 Variação de frequência		< 10 s	$\pm$ 0,10 Hz

### 3.4 ANÁLISE ESPECTRAL DOS DISTÚRBIOS

Os sinais resultantes do monitoramento dos sistemas elétricos de potência podem ser divididos em seqüências estacionárias e não estacionárias.

A estacionariedade está associada ao comportamento da rede elétrica em regime permanente e aos distúrbios de QEE que não apresentam variações do conteúdo espectral no tempo. Isto é, no domínio da frequência os distúrbios de regime permanente são considerados de banda estreita e bem localizados no espectro porque concentram a energia do

sinal em poucas bandas de frequências. Neste caso, as frequências, as amplitudes e as fases das componentes, fundamental, harmônicas e inter-harmônicas, são monitoradas em baixas taxas.

A não estacionariedade está relacionada ao comportamento da rede na presença de um distúrbio. Quando um distúrbio acontece, a energia do sinal se espalha em direção às altas frequências, causando variações da faixa dinâmica das componentes características do regime permanente e o surgimento temporário de novas componentes dentro do espectro de frequências. Ditos argumentos, fazem com que cada distúrbio tenha uma assinatura espectral específica e todos eles juntos sejam considerados como distúrbios de banda larga. Uma forma de extrair a máxima informação do distúrbio consiste em coletar os sinais com equipamentos que operem a taxas de amostragem adequadas, tal que, os distúrbios de banda larga possam ser registrados com precisão, conforme aos limites teóricos estabelecidos no teorema de Nyquist (OPPENHEIM; SCHAFER, 1999).

A variação dos parâmetros do sinal (frequência, amplitude e fase) e de seu espectro em relação ao tempo, depende da natureza das cargas e das características topológicas e operacionais da rede. De forma que no estado transitório as variações dos parâmetros são causadas pelas alterações no fluxo de energia devido às mudanças de estado dos componentes do sistema durante as manobras (condução para não condução e vice-versa), às faltas, também como às condições atmosféricas adversas. Em geral, as redes elétricas podem experimentar vários tipos de distúrbios simultaneamente. A mistura das contribuições de cada um deles faz com que o comportamento do espectro de frequências do sinal monitorado apresente características muito diferentes e variantes no tempo, aumentando a complexidade nas análises. Destaca-se que qualquer distúrbio na tensão afeta diretamente o comportamento da corrente e vice-versa, visando atenuar as mudanças bruscas de energia.

Para fazer as análises dos sinais na presença de distúrbios, são necessárias técnicas que proporcionem representações adequadas dos comportamentos do sinal. As técnicas de análise mais utilizadas (Transformada de Fourier e Transformada de Wavelet) decompõem linearmente o sinal em uma base fixa, o que não permite muita flexibilidade na representação. Em ambos os casos, não é possível proceder à identificação correta de padrões a partir dos coeficientes da transformada, porque a informação fica diluída em todas as funções de base.

### **3.5 CONSIDERAÇÕES FINAIS**

Este capítulo apresentou o contexto de aplicação do algoritmo. Temas como oscilografia, qualidade da energia elétrica e análise espectral dos distúrbios mais comuns presentes nos sistemas elétricos de potência foram avaliados.

Comentou-se brevemente sobre a evolução dos sistemas de oscilografia nos sistemas elétricos de potência e da sua importância para os diferentes agentes vinculados ao setor

elétrico. Mostrou-se que a evolução tecnológica dos equipamentos de medição permite que os consumidores acompanhem com mais detalhe a qualidade da energia elétrica oferecida pelas concessionárias, gerando um ambiente propício para a interação entre o consumidor e a rede elétrica, onde o consumidor ganha cada vez mais participação.

Destaca-se a análise do comportamento espectral dos sinais elétricos considerados estacionários e não estacionários, enfatizando na presença de combinações de distúrbios tanto no regime permanente quanto no estado transitório, e suas variações espectrais no tempo, respectivamente. Os temas aqui tratados forneceram as bases para as interpretações dos diferentes resultados encontrados durante o projeto e a implementação dos algoritmos.

No próximo capítulo, são descritos os algoritmos propostos para a compressão de sinais de sistemas elétricos de potência, além dos resultados dos testes e das simulações desenvolvidas.



# Capítulo 4

## Algoritmos propostos

### 4.1 CONSIDERAÇÕES INICIAIS

Cada uma das técnicas de compressão é eficiente quando os dados possuem características favoráveis para o algoritmo. Infelizmente, muitos dos dados apresentam combinações de características, que às vezes, tornam mais difícil a escolha da técnica de compressão mais adequada.

Neste capítulo, são descritos algoritmos de codificação e decodificação que compõem as técnicas de compressão de dados propostas nesta pesquisa. Também são apresentados os resultados dos testes de avaliação de desempenho, dando ênfase às melhorias operacionais alcançadas, quando da utilização de comprimento da palavra variável na quantização no domínio da transformada. Na avaliação do desempenho dos algoritmos e no treinamento da rede neural utilizaram-se sinais reais de distúrbios disponíveis no *DOE/EPRI National Database Repository of Power System Events* (EPRI, 2011). Destaca-se que a totalidade da programação e simulação dos algoritmos de compressão, foi realizada aproveitando as bibliotecas de redes neurais, k-means, wavelets e os comandos básicos disponíveis em MATLAB (MATLAB, 2008).

### 4.2 BASE DE DADOS DE DISTÚRBIOS

Na base de dados do EPRI (2011), os registros oscilográficos são disponibilizados em formato IEEE COMTRADE (IEEE STD C37.111, 1999) e estão organizados de acordo com as causas dos distúrbios e com os locais de medição. Cada um deles, contém as formas de onda dos três sinais de tensão e de corrente além da corrente do neutro, sendo no total 7 sinais armazenados. Na maioria dos casos, as formas de onda contêm vários ciclos do sinal que descrevem o regime permanente nos instantes anteriores e posteriores ao distúrbio.

A tabela 4.1 exibe um resumo dos sinais selecionados para a execução desta pesquisa. Destaca-se, que as formas de onda correspondentes aos registros dos locais identificados como **site0002**, **site0003**, **site0011** e **site0012**, foram coletadas com uma taxa de amostragem

de 256 amostras por ciclo para uma frequência fundamental de 60 Hz (15360 amostras por segundo), e digitalizadas usando um comprimento da palavra de 16 bits por amostra.

Tabela 4.1: Descrição dos registros oscilográficos utilizados.

Local	Formas de Onda	
	$V_{3\phi}$	$I_{3\phi}$
Site0002	46	46
Site0002	1	1
Site0003	4	4
Site0011	8	0
Site0012	26	0
Total	85	51

As formas de onda de tensão e corrente usadas na comparação dos algoritmos pertencem aos registros da base de dados do EPRI (2011), chamados de **evento 21839** (figura 4.1) e **evento 21867** (figura 4.2), respectivamente. Observa-se que os dois conjuntos de sinais têm amostras antes (A), durante (B) e depois (C) do distúrbio. A figura 4.1 mostra um afundamento de tensão causado pela ocorrência de uma falta bifásica seguido de um desligamento nas fases de um transformador. Na figura 4.2, apresenta-se um transitório de corrente causado pela execução de manobras na rede elétrica.

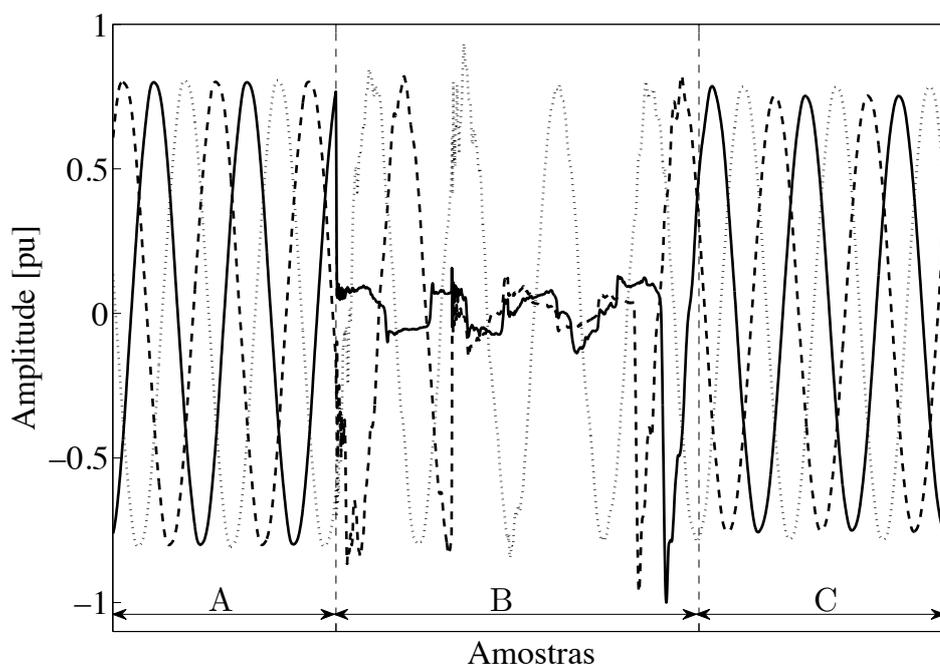


Figura 4.1: Formas de onda do distúrbio de tensão (Evento 21839).

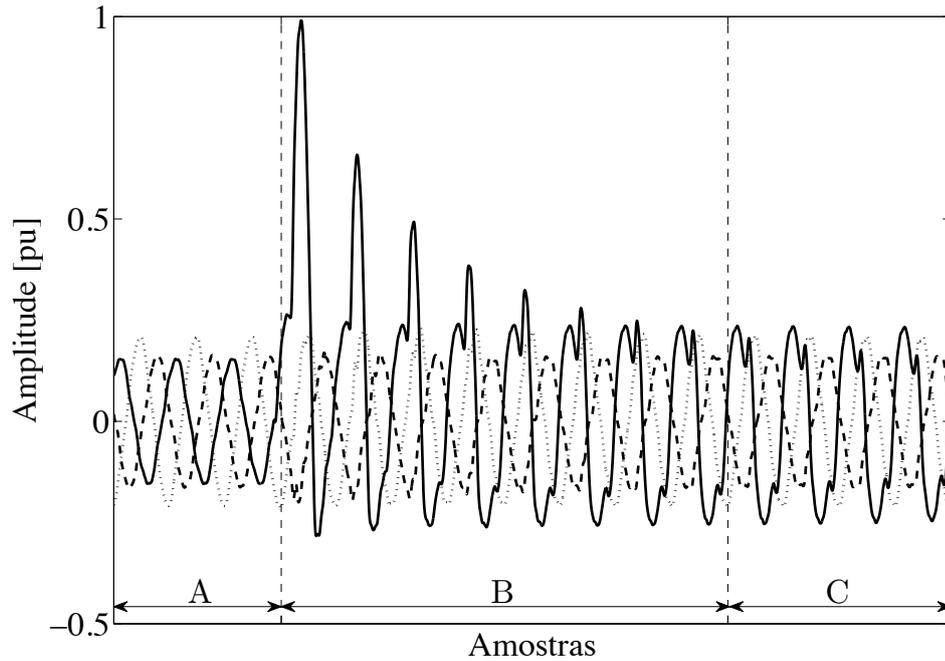


Figura 4.2: Formas de onda do distúrbio de corrente (Evento 21867).

### 4.3 CRITÉRIOS DE AVALIAÇÃO DO DESEMPENHO

Uma técnica de compressão pode ser avaliada de diferentes formas. Poderíamos calcular o grau de complexidade, a memória necessária para programá-la, a velocidade na execução para uma determinada máquina, o ganho de compressão e quão próxima a reconstrução da informação se assemelha à informação original (SAYOOD, 2006). Neste trabalho, estamos interessados basicamente nos dois últimos critérios, devido à perda de informação na quantização. Então, como podemos medir o desempenho da técnica de compressão em termos da qualidade do sinal reconstruído e da redução da quantidade de bits usada na representação dos dados? Com relação à qualidade, é calculada a diferença entre as sequências original e reconstituída, em outras palavras, é quantificada a distorção introduzida pela compressão. Com relação à quantidade de bits, é calculado o número de bits necessários para representar os dados antes e depois da compressão. Os critérios usados na medição do desempenho da técnica de compressão são descritos a seguir (SAYOOD, 2006; SALOMON, 2006; JAYANT; NOLL, 1984):

A relação sinal ruído (SNR) é computada por meio da equação (4.1), na qual  $x[n]$  e  $\hat{x}[n]$  correspondem às sequências original e reconstruída, respectivamente. O critério compara a energia da sequência original com a energia da sequência de distorção. Considera-se, que quanto maior o valor da relação sinal-ruído, menor é a distorção causada pela compressão. Enquanto, um valor próximo de zero indica que o sinal reconstruído não representa adequa-

damente a informação original.

$$SNR = 10 \log_{10} \left[ \frac{\sum_{n=0}^{N-1} x[n]^2}{\sum_{n=0}^{N-1} (x[n] - \hat{x}[n])^2} \right] \text{ [dB]} \quad (4.1)$$

O erro quadrático médio normalizado (MSNE) representa a energia média da perda de informação representada pela sequência de distorção. A expressão (4.2) corresponde à SNR com o sinal trocado. Este critério é utilizado por Meher *et al.* (2004), Ribeiro (2005), Ribeiro *et al.* (2007) e Tcheou *et al.* (2007), ao invés da relação sinal ruído.

$$MSNE = 10 \log_{10} \left[ \frac{\sum_{n=0}^{N-1} (x[n] - \hat{x}[n])^2}{\sum_{n=0}^{N-1} x[n]^2} \right] \text{ [dB]} \quad (4.2)$$

O ganho de compressão (GC) é definido em (4.3), como a razão entre a quantidade de bits usada para representar o sinal original ( $O_s$ ) e a quantidade de bits resultantes após a compressão ( $C_s$ ).

$$GC = \frac{O_s}{C_s} \quad (4.3)$$

O fator de compressão (FC) corresponde à redução da quantidade de bits necessária para representar o sinal original (4.4). É apresentado como uma percentagem da quantidade de bits dos dados originais.

$$CF = \left[ 1 - \frac{C_s}{O_s} \right] \cdot 100 \text{ [%]} \quad (4.4)$$

A taxa de bits (TB) é dada pela equação (4.5), na qual  $N$  corresponde a quantidade total de amostras da janela do sinal processado. Esta expressão fornece a quantidade média de bits necessária para representar uma única amostra.

$$TB = \frac{C_s}{N} \text{ [bits/amostra]} \quad (4.5)$$

Outra forma de avaliação proposta baseia-se no cálculo do erro quadrático médio (MSE), entre as sequências dos parâmetros de QEE calculados antes e depois do processo de com-

pressão. O MSE é definido na equação (4.6).

$$MSE = \frac{1}{N_c} \sum_{n=0}^{N_c-1} (\theta[n] - \hat{\theta}[n])^2 \quad (4.6)$$

Onde  $\theta$  é o parâmetro calculado para o sinal original,  $\hat{\theta}$  é o parâmetro calculado para o sinal reconstruído e  $N_c$  é o número de amostras por ciclo da frequência fundamental.

Os parâmetros de QEE usados neste trabalho são: a distorção harmônica total (DHT), o fator de crista relativo (FCR) e o valor quadrático médio ou valor eficaz (RMS) (IEEE STD 1159, 2009; IEC 61000-4-30, 2008; BOLLEN; GU, 2006). Os dois primeiros parâmetros são utilizados para quantificar a distorção da forma de onda do sinal, entretanto, os outro é utilizado para quantificar as variações da magnitude do sinal.

O valor eficaz (RMS) é uma medida estatística da magnitude de uma quantidade variável utilizada para medir os desvios do sinal em função do tempo.

$$RMS = \sqrt{\frac{1}{N_c} \sum_{n=0}^{N_c} (x[n])^2} \quad (4.7)$$

A distorção da forma de onda é interpretada como um desvio da forma de onda puramente senoidal, em regime permanente e na frequência fundamental. Ela é caracterizada principalmente pelo seu conteúdo espectral. O DHT é a medida da quantidade relativa de energia do sinal que não corresponde à componente fundamental, definindo a importância do conteúdo harmônico do sinal.

$$DHT = \sqrt{\left(\frac{X_{rms}}{X_1}\right)^2 - 1} \quad (4.8)$$

Onde  $X_1$  e  $X_{rms}$  correspondem ao valor eficaz da componente fundamental e do sinal original, respectivamente. O fator de crista é uma propriedade que indica o quanto o topo da forma de onda senoidal é distorcido. É definido como a razão entre o valor máximo da amplitude e o valor eficaz do sinal. De forma que para uma onda senoidal perfeita o fator de crista é igual a  $\sqrt{2}$ . Logo faz sentido dividir  $\frac{\max\{x[n]\}}{X_{rms}}$  por  $\sqrt{2}$  para obter um fator de crista relativo igual a 1 para uma onda senoidal perfeita. O fator de crista indica o quanto um sinal é desviado do seu equivalente em corrente contínua, enquanto o fator de crista relativo indica o quanto é o desvio do sinal de uma onda senoidal ideal.

$$FCR = \frac{1}{\sqrt{2}} \frac{\max\{x[n]\}}{X_{rms}} \quad (4.9)$$

#### 4.4 CODIFICAÇÃO POR TRANSFORMADAS COM ALOCAÇÃO DINÂMICA E INTELIGENTE DE BITS NO ESPAÇO TRANSFORMADO (CTIA)

A técnica proposta consiste na implementação de uma estratégia para a alocação dinâmica de bits, que utiliza um quantizador vetorial adaptativo baseado em redes de Kohonem. Os mapas auto-organizáveis de Kohonem mapeiam a envoltória do espectro de frequências gerando uma representação vetorial da quantidade de bits a ser alocada para os coeficientes na quantização, o que permite adaptar o comprimento da palavra às variações exibidas pelo espectro preservando suas características intrínsecas. A figura 4.3 apresenta o diagrama de blocos da técnica proposta.

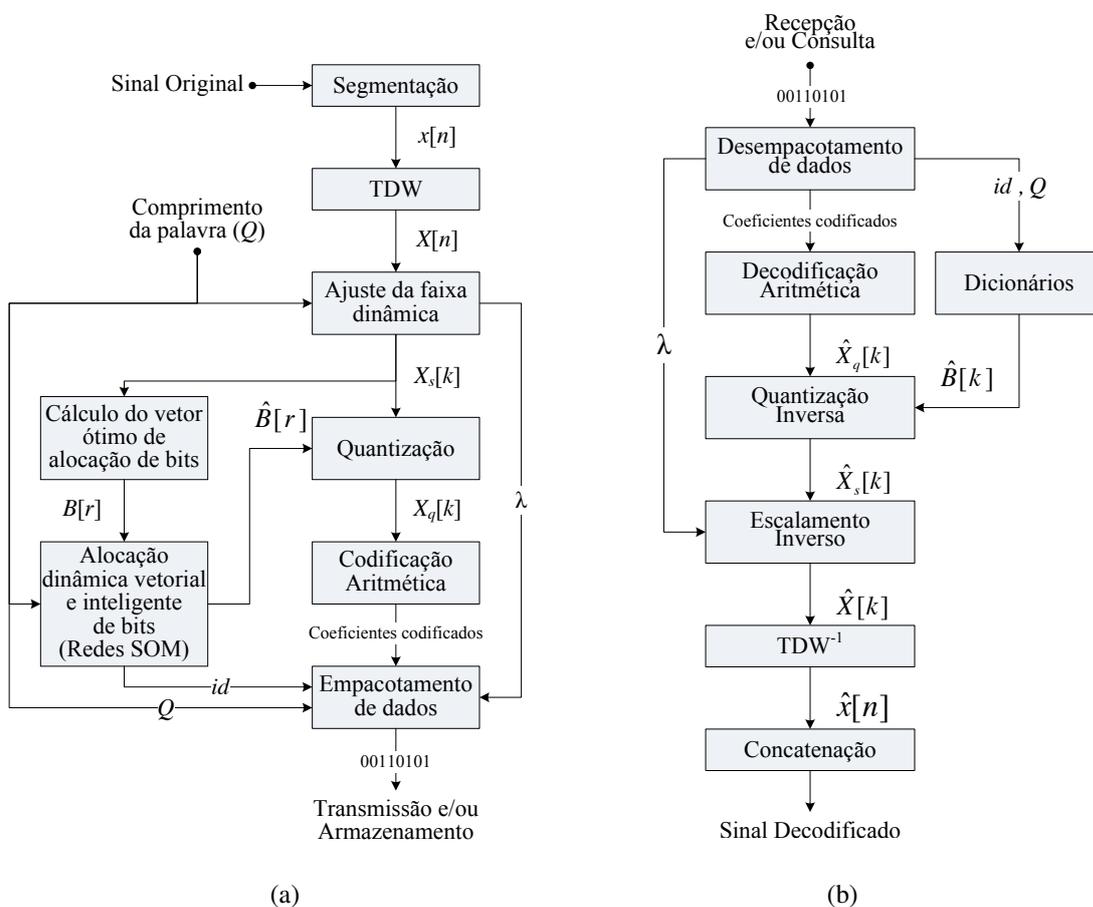


Figura 4.3: Diagrama de blocos da CTIA. (a) Algoritmo de codificação. (b) Algoritmo de decodificação.

##### 4.4.1 Algoritmo de codificação

O sinal coletado é segmentado em janelas de tamanho  $N$  amostras, sendo  $N$  uma potência inteira de dois, e denotadas como  $x[n]$ . Como transformada ortogonal, foi escolhida a TDW pela boa representação tempo-frequência de sinais submetidos a mudanças abruptas da faixa dinâmica, para diferentes resoluções. Para cada segmento aplica-se a TDW até o

último nível de resolução, o qual está determinado pelo tamanho da janela e pode ser calculado com a expressão  $\log_2(N)$ . A função da transformada ortogonal é concentrar a energia do sinal em poucos coeficientes transformados obtendo uma representação esparsa no domínio transformado. De forma geral, a transformada define o comportamento espectral de cada nível de resolução, fazendo com que os coeficientes localizados nos níveis de decomposição mais altos sejam representados com um comprimento da palavra digital maior que aqueles correspondentes aos baixos níveis de resolução, devido à característica da distribuição da energia no espaço transformado para esse tipo de sinais. De agora em diante, assume-se que os processos sejam executados para cada segmento  $x[n]$  do sinal original.

Após o cálculo dos coeficientes transformados  $X[k]$ , é efetuado o ajuste da faixa dinâmica do espectro, de tal forma que possam ser definidos os limites da representação numérica dos coeficientes. Nesse sentido, os coeficientes são escalonados por um fator de ajuste mostrado em (4.10), chamado de  $\lambda$ . O parâmetro  $Q$  em bits, representa o maior comprimento da palavra que será usado para obter a representação em ponto fixo (números inteiros) dos coeficientes transformados. Ele encontra-se definido para  $2 \leq Q \leq Q_o - 1$ , onde o limite inferior constitui a alocação de 2 bits. Um para representar o sinal, e outro para representar o módulo do coeficiente. O valor  $Q_o$  é o comprimento da palavra utilizado pelo equipamento de medição para digitalizar o sinal coletado.

$$\lambda = \frac{2^Q}{\max\{|X[k]|\}} , k = \{0, 1, \dots, N - 1\} \quad (4.10)$$

O fator  $\lambda$  permite ajustar a faixa dinâmica dos  $X[k]$  para o intervalo  $[-2^Q, 2^Q - 1]$ . Este artifício matemático pode ser interpretado como uma ferramenta que torna possível regular a relação taxa-distorção e, portanto, controlar a qualidade da reconstrução do sinal. A sequência dos coeficientes escalonados são descritos pela expressão (4.11) e chamados de  $X_s[k]$ .

$$X_s[k] = \lfloor \lambda X[k] \rfloor , k = \{0, 1, \dots, N - 1\} \quad (4.11)$$

A sequência  $X_s[k]$  é dividida uniformemente em  $M$  sub-bandas com o objetivo de construir uma representação vetorial que contenha a quantidade de bits necessária para representar os coeficientes dentro de cada uma das sub-bandas. O vetor resultante é chamado de vetor ótimo de alocação de bits  $\mathbf{B}$ , cuja dimensão corresponde ao total de sub-bandas.  $\mathbf{B}$  é representado como uma sequência na forma  $B[r]$ . Cada componente de  $B[r]$  corresponde ao comprimento da palavra necessário para representar em ponto fixo os coeficientes  $X_s[k]$ , dentro da  $r$ -ésima sub-banda. A sequência  $B[r]$  é calculada de acordo com a expressão

(4.12).

$$B[r] = \left\lceil \log_2 \left( \max \{ |X_s[k]| \}_{k=\left\{ \frac{N}{M}r, \frac{N}{M}r+1, \dots, \frac{N}{M}r+\frac{N}{M}-1 \right\}} \right) \right\rceil, \quad r = \{0, 1, \dots, M-1\} \quad (4.12)$$

Na figura 4.4, apresenta-se um exemplo ilustrativo do cálculo do vetor  $\mathbf{B}$  onde é utilizada uma janela de 1024 amostras ( $N = 1024$ ), dividida em oito sub-bandas ( $M = 8$ ) de 128 amostras ( $\frac{N}{M} = 128$ ) e um comprimento máximo de palavra de 8 bits ( $Q = 8$ ). As linhas pontilhadas verticais indicam os limites das 8 sub-bandas em que está dividido o segmento. As barras verticais de cor cinza expõem a quantidade de bits necessária para representar cada coeficiente de  $X_s[k]$  como número inteiro  $\lceil \log_2(\max\{|X_s[k]|\}) \rceil$ . As linhas cheias horizontais correspondem à sequência  $B[r]$ , que por sua vez, representa o envoltório do espectro. Verifica-se, que o envoltório está definido pela quantidade de bits que o coeficiente de maior amplitude de cada sub-banda necessita para ser representado corretamente. A sequência de zeros localizada na parte inferior das três últimas sub-bandas corresponde aos coeficientes de amplitude próxima de zero ( $|X_s[k]| \approx 0$ ). Contata-se também que o vetor ótimo de alocação de bits correspondente ao exemplo é a sequência  $B[r] = [8, 5, 5, 2, 4, 1, 0, 1]$ .

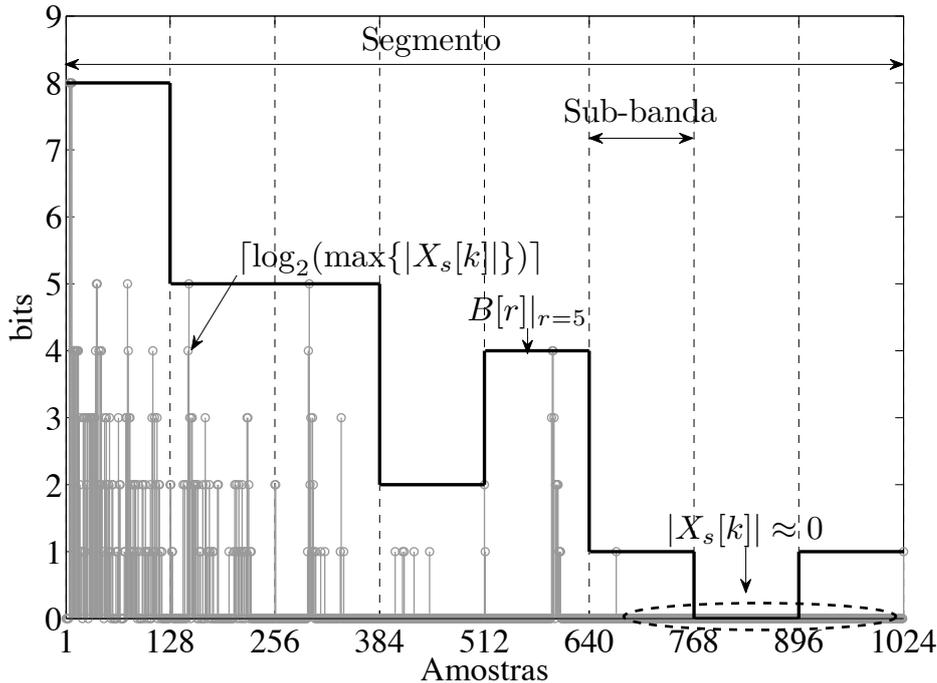


Figura 4.4: Cálculo da sequência  $B[r]$  para  $N=1024$ ,  $M=8$  e  $Q=8$ .

#### 4.4.1.1 Alocação dinâmica vetorial e inteligente de bits

Depois de calcular o vetor  $\mathbf{B}$ , se procede a seleção da rede SOM de acordo com o parâmetro  $Q$ . Foi construída e treinada uma rede SOM para cada valor de  $Q$ , com o objetivo

de manter a coerência entre a quantização e os limites da faixa dinâmica, ajustados previamente. Neste caso, se assume que os sinais coletados foram digitalizados com um conversor analógico-digital de 16 bits ( $Q_o = 16$ ). Portanto, foram construídas e treinadas um total de 14 redes SOM.

A sequência  $B[r]$ , é utilizada como padrão de entrada da rede SOM selecionada. Como saída, são obtidos a sequência  $\hat{B}[r]$  e o índice da sua posição dentro do da rede. A sequência  $\hat{B}[r]$  corresponde à representação do vetor  $\hat{\mathbf{B}}$ , que por sua vez, tem as mesmas dimensões de  $\mathbf{B}$  e representa sua melhor estimativa. Observa-se que o parâmetro  $Q$  é especificado como um parâmetro de entrada do algoritmo, tal e como se mostra na figura 4.3. Destaca-se que a rede neural determina o neurônio cujos pesos sinápticos estão associados à melhor estimativa de  $B[r]$ . Em outras palavras, o índice do neurônio selecionado fornece a posição da sequência  $\hat{B}[r]$  que apresenta o melhor casamento com  $B[r]$  dentro do SOM. Neste contexto a rede SOM executa as funções de um dicionário de vetores código que contem os quantizadores das sub-bandas. O processo descrito anteriormente é ilustrado na figura 4.5.

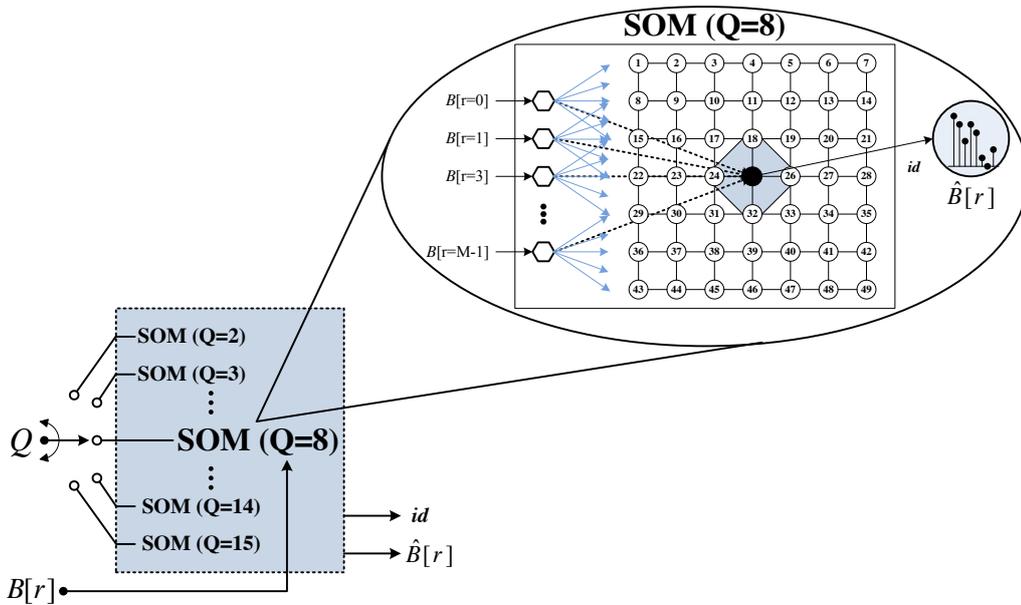


Figura 4.5: Estratégia de alocação dinâmica vetorial e inteligente de bits.

Os coeficientes  $X_s[k]$  de cada uma das sub-bandas são quantizados com cada elemento de  $\hat{B}[r]$ , sendo esses representados como um número inteiro no intervalo  $[-2^{\hat{B}[r]-1}, 2^{\hat{B}[r]-1}]$ .  $X_q[k]$  representa os coeficientes quantizados simplesmente pelo truncamento para a representação em ponto fixo, descartando-se a parte fracionária de  $X_s[k]$ . A operação de quantização é executada por meio da expressão (4.13).

$$X_q[k] = \left\lfloor \left\lceil \frac{X_s[k]}{\lambda} \hat{B}[r] \right\rceil \right\rfloor, \quad k = \left\{ \frac{N}{M}r, \frac{N}{M}r + 1, \dots, \frac{N}{M}r + \frac{N}{M} - 1 \right\} \quad e \quad r = \{0, 1, \dots, M - 1\} \quad (4.13)$$

Na figura 4.6 ilustra-se o resultado da quantização dos coeficientes do exemplo da figura 4.4 após a estimação do vetor  $\hat{B}[r]$ . As barras verticais de cor cinza expõem a quantidade necessária de bits ( $\log_2 \{|X_q[k]|\}$ ) para representar os coeficientes da sequência  $X_q[k]$ .

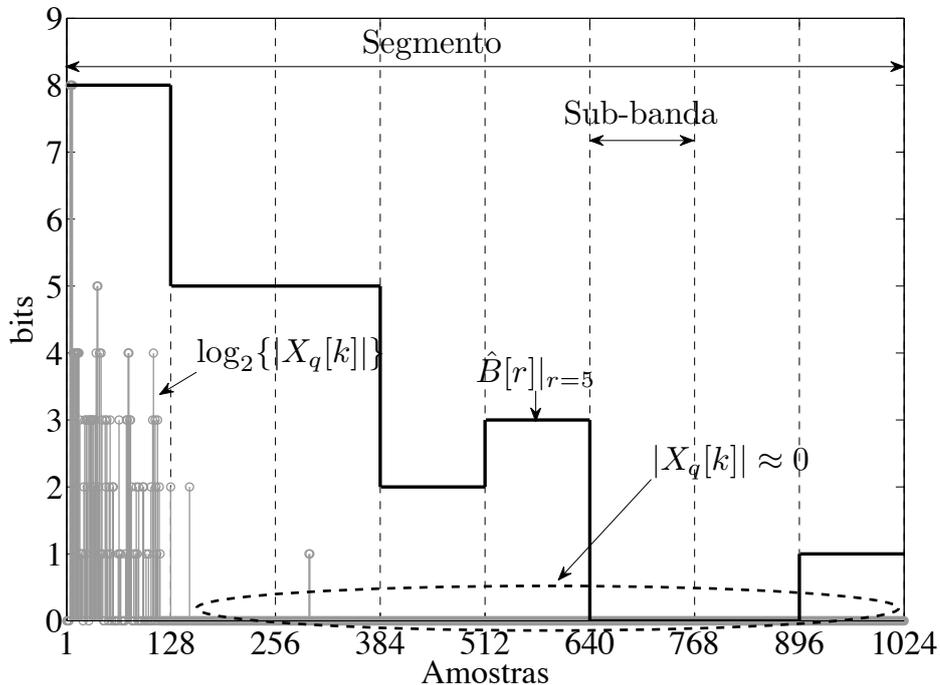


Figura 4.6: Sequência  $\hat{B}[r]$  para  $N=1024$ ,  $M=8$  e  $Q=8$ .

A sequência  $\hat{B}[r] = [8, 5, 5, 2, 3, 0, 0, 1]$  corresponde à estimativa da quantidade de bits especificada pela rede SOM, após receber o vetor  $B[r]$  como entrada. Isto significa que todos os coeficientes da primeira sub-banda são quantizados com 8 bits, os correspondentes à segunda com 5 bits e assim por diante até a última sub-banda. Deve-se considerar que quanto mais próxima de  $N$  seja a quantidade de sub-bandas, melhor é a alocação de bits dos coeficientes transformados. Contudo, o aumento do tamanho (dimensões) do vetor  $\mathbf{B}$  gera o aumento na complexidade computacional durante o treinamento da rede neural.

Verifica-se que o aumento da quantidade de coeficientes que apresentam amplitude nula, apesar de ser alocada uma quantidade de bits para representá-los. Isto significa que durante o processo de adaptação do comprimento da palavra, a faixa dinâmica da sub-banda que contem o coeficiente com maior energia se mantém fixa, enquanto, as faixas dinâmicas das outras sub-bandas experimentam novos ajustes da representação, causando que os coeficientes de menor energia sejam zerados. A redundância gerada pela sequência de zeros é minimizada na codificação de entropia melhorando a relação de compressão. O codificador aritmético foi o que apresentou melhor desempenho quando comparado com o codificador de Huffman, durante a avaliação de desempenho do algoritmo proposto. Esta conclusão é coerente com a justificativa teórica apresentada no capítulo 2 e com os resultados conseguidos por Huang & Jou (2004).

Os coeficientes codificados, o valor do parâmetro ( $Q$ ), o fator de escala ( $\lambda$ ) e o índice do

dicionário ( $id$ ) ainda são comprimidos pelo método de codificação de entropia. O empacotamento dos dados é realizado a cada segmento de sinal gerando um bloco de dados como ilustrado na figura 4.7. Os blocos são concatenados de forma a gerar um arquivo de dados compactado.



Figura 4.7: Estrutura dos dados compactados pelo algoritmo CTIA.

A informação lateral para cada segmento de sinal compactado utiliza no máximo 32 bits (4 bytes), onde até 12 bits são necessários para representar o ( $id$ ), 16 bits para quantizar o ( $\lambda$ ) e 4 bits para representar o ( $Q$ ) empregado.

A estratégia de alocação dinâmica vetorial e inteligente de bits permite a redução significativa da quantidade total de bits alocados para quantizar a sequência de coeficientes no domínio transformado. Os diferentes comprimentos da palavra digital se adaptam à forma do envoltório do espectro de frequências do segmento de sinal processado, e fazem com que os coeficientes com maior energia sejam representados com mais bits que aqueles que têm menor energia.

#### 4.4.1.2 Treinamento do mapa auto-organizável de Kohonen

O mapa auto-organizável de Kohonen é uma RNA com arquitetura auto-organizável que realiza um mapeamento não linear de um espaço de dimensão elevada em estruturas cuja dimensão topológica é inferior à original (duas dimensões neste caso), preservando as relações de vizinhança dos dados de entrada (KOHONEN, 1988; RZESZUTEK *et al.*, 2010). O treinamento não supervisionado do SOM garante a formação de classes ou agrupamentos a partir da detecção das similaridades entre as entradas, reduzindo a quantidade de padrões necessários para representar os sinais compactados, e melhorando o desempenho do algoritmo.

A quantidade de mapas, seu tamanho e quantidade de dados de treinamento são influenciados pelo parâmetro  $Q$ . O aumento do valor de  $Q$ , torna maior a variação da faixa dinâmica dos coeficientes e, por tanto, faz com que os valores das componentes de  $B[r]$  incrementem sua variação. Os mapas possuem uma topologia retangular (duas dimensões), devido ao fato de que o resultado final não difere quando comparado com outras topologias. Contudo, a topologia retangular apresentou o menor tempo de operação durante o treinamento, fazendo ele atrativo para executar as simulações. Em razão disto, construíram-se um total de 14 mapas para atender todas as possibilidades geradas pelo parâmetro  $Q$ . A quantidade de bits necessária para representar os índices transmitidos ao decodificador é calculada para cada mapa dependendo do seu tamanho.

Da base de dados do EPRI (2011), foram separados para treinamento das RNAs um total

de 60 registros de tensão e 36 de corrente, o que corresponde ao 70% do total dos registros. Considerando cada sinal monofásico como um sinal de treinamento, obtém-se um total de 180 sinais de tensão e 108 sinais de corrente. O restante (30%) dos registros foi utilizado como sinais de teste e validação. Os sinais de treinamento foram segmentados de forma que fosse detectada a maior quantidade de mudanças possíveis no sinal processado. De fato, a variabilidade dos dados de treinamento ajuda a melhorar a adaptabilidade do comprimento de palavra na presença de ocorrências. Para isso, foi utilizado um esquema de janela deslizante, onde o tamanho do passo de deslocamento da janela define a sensibilidade do esquema. Neste trabalho, considerou-se um passo de tamanho igual a 1/4 de ciclo (64 amostras) e uma janela de tamanho igual a 4 ciclos da fundamental (1024 amostras). O esquema é ilustrado na figura 4.8.

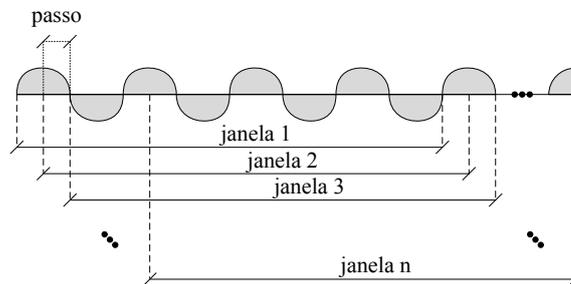


Figura 4.8: Esquema de janela deslizante.

A partir destes segmentos de sinais são calculados os vetores  $\mathbf{B}$  para cada valor de  $Q$ , que são utilizados como entradas para o treinamento das redes SOM. Contudo, muitas repetições dentro de cada conjunto de vetores foram detectadas e descartadas. Ao final, para um valor de  $Q = 15$ , por exemplo, obteve-se um conjunto de treinamento constituído de 6060 vetores. Um máximo de 250 épocas e uma variação incremental dos pesos inferior a  $10^{-6}$  foram estabelecidos como critérios de convergência no processo de treinamento. Na maioria dos casos as redes SOM atingiram o critério baseado na variação incremental dos pesos em torno de 60 épocas. Destaca-se que o tamanho do SOM é definido ao início do treinamento. Portanto, existe um compromisso entre o tamanho do dicionário e a qualidade do sinal reconstruído após a compactação.

#### 4.4.2 Algoritmo de decodificação

Primeiramente é realizado o desempacotamento dos dados de forma a se ter acesso à informação correspondente a cada segmento do sinal comprimido. Em seguida, a decodificação de entropia é aplicada obtendo-se os coeficientes quantizados  $X_q[k]$ . O fator de escala ( $\lambda$ ), o parâmetro  $Q$  e o índice do dicionário que informa o vetor  $\hat{\mathbf{B}}$ , são utilizados para realizar a quantização inversa e o escalonamento inverso respectivamente, obtendo-se  $\hat{X}[k]$ . Finalmente, é aplicada a TDW inversa. O sinal decodificado é obtido pela concatenação sucessiva de janelas de comprimento igual a  $N$  amostras. O diagrama de blocos que descreve

o decodificador é mostrado na figura 4.3(a).

#### 4.4.3 Seleção do quantizador vetorial adaptativo

Neste trabalho, o problema da quantização vetorial adaptativa foi resolvido mediante a construção de dois quantizadores com estratégias de adaptação diferentes. O primeiro, é baseado em um esquema de agrupamento não supervisionado (*Clustering*), implementado por meio do algoritmo "k-means". O segundo quantizador, é baseado em um esquema de tipo estrutura dedicada, implementado usando as redes de Kohonen.

Os critérios empregados de seleção do quantizador vetorial são: o desempenho da compressão e tamanho do dicionário. Os resultados dos testes mostraram que, o quantizador baseado em redes SOM possui um desempenho ligeiramente melhor que aquele baseado em k-means em termos da relação taxa-distorção. Nesse sentido, e com o objetivo de confirmar o resultado da aplicação do primeiro critério, encontrou-se que o dicionário do quantizador baseado em k-means, na média, apresenta maior tamanho que o outro quantizador, o que define a seleção do quantizador a favor de aquele baseado em redes SOM.

Na figura 4.9, observa-se que para cada valor de  $Q$ , o dicionário baseado em redes SOM possui na média um tamanho 35% menor que o baseado em k-means, o que pode ser interpretado como menor quantidade de informação a ser transmitida para o decodificador.

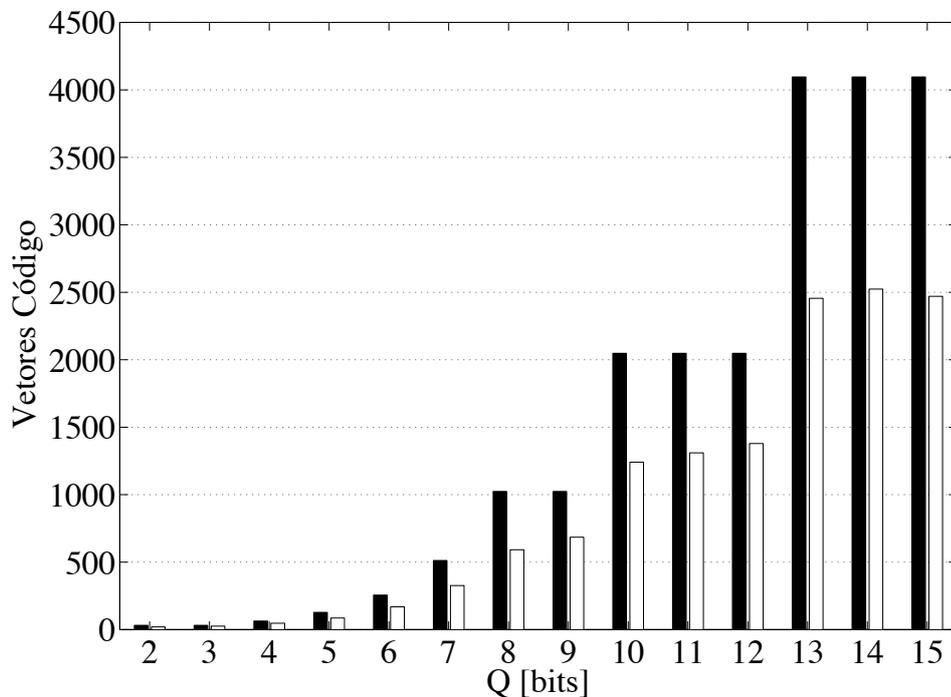


Figura 4.9: Tamanho do dicionário em termos da quantidade de vetores código. k-means (Barras preta). Redes SOM (Barra brancas).

O resultado da comparação mostra, que os dois quantizadores agrupam os padrões ca-

racterísticos presentes no espaço transformado, não obstante, as redes de Kohonem detectam as transições entre padrões, conseguindo acompanhar a variação da faixa dinâmica dos coeficientes transformados, por meio do mapeamento estatístico das características intrínsecas do espectro. No caso do algoritmo k-means, ao tentar, estabelecer padrões de transição, gera padrões estatisticamente não relevantes, o que faz com que o dicionário contenha padrões que talvez nunca sejam utilizados. Esse resultado faz com que com uma pouca quantidade de padrões, as redes de Kohonem apresentem os melhores resultados na representação e preservação do espectro em termos da fidelidade na reconstrução e da taxa de codificação. Outra contribuição foi tornar as redes de Kohonem aptas para codificar regiões de interesse.

#### 4.4.4 Seleção da wavelet

A dinâmica dos coeficientes transformados durante o distúrbio está determinada pela natureza do evento, o que faz com que cada distúrbio exiba sua própria assinatura espectral. Destaca-se também, que cada wavelet tem características diferentes, o que leva a afirmar que uma wavelet que representa bem um dado sinal de distúrbio, não é necessariamente a melhor opção para representar outro distúrbio. Assim, selecionar uma wavelet cuja representação no espaço transformado favoreça a compressão de todos os tipos de distúrbios não é tarefa fácil. Os trabalhos consultados durante a revisão bibliográfica não oferecem muitos detalhes sobre o processo de seleção da wavelet, o que sugere que não há uma metodologia consolidada para resolver esta questão. Neste estudo, a seleção da wavelet baseia-se nos resultados obtidos nas simulações da técnica de compressão com wavelets de diferentes ordens, pertencentes às famílias Symlets, Biorthogonal, Daubechies e Coiflets.

As figuras 4.10 e 4.11 mostram a relação sinal ruído versus o fator de compressão resultante da técnica de compressão para diferentes wavelets, quando os sinais de entrada são as formas de onda do evento 21839 e do evento 21867, respectivamente. Em ambas as figuras, os resultados incluem as melhores curvas obtidas para cada uma das famílias de wavelets citadas acima, como também, a curva para a wavelet Daubechies de 4 coeficientes (linha tracejada preta) usada em Wikinson & Cox (1996), Santoso *et al.* (1997), Hsieh *et al.* (1998), Littler & Morrow (1999), Ribeiro *et al.* (2004), Huang & Jou (2004), Lorio & Magnago (2004), Gerek & Ece (2004), Ning *et al.* (2011), Zhang *et al.* (2011) e a curva para a wavelet biortogonal 5/3 de 10 coeficientes (linha traço-ponto preta) usada em Gerek & Ece (2007).

Pode ser verificado que tanto a wavelet Daubechies de 4 coeficientes (linha tracejada preta), quanto a wavelet biortogonal 5/3 de 10 coeficientes (linha traço-ponto preta), não apresentam o melhor desempenho na compressão dos eventos 21839 e 21867, o que confirma a hipótese manifestada no primeiro paragrafo desta seção. Em (HAMID; KAWASAKI, 2002; RIBEIRO *et al.*, 2007), são usados critérios baseados na limiarização direta (HAMID; KAWASAKI, 2002) e estatística (RIBEIRO *et al.*, 2007) dos coeficientes transformados, o que vai em direção contrária à abordagem das propostas apresentadas nesta pesquisa.

Observa-se nas figuras 4.10 e 4.11, que a faixa de variação dos resultados para o evento 21839 está limitada entre 10 dB e 19 dB, enquanto a faixa de variação para o evento 21867 está definida entre 5 dB a 11 dB. Porém, encontrou-se que a faixa de variação dos resultados para cada família de wavelets está definida entre 7 dB e 11 dB. Este último resultado não está de acordo com os conseguidos por Gerek & Ece (2007), onde depois da execução de testes de desempenho da transformada wavelet. Observou-se também que os melhores resultados de cada família foram alcançados com wavelets de ordens maiores, contudo, maior quantidade de coeficientes implica em aumento na quantidade de operações executadas durante o cálculo da transformada. Portanto, apesar de que a wavelet Coiflet de 30 coeficientes apresenta os melhores resultados, ela envolve maior custo computacional, o que não seria muito interessante durante a implementação do algoritmo.

O resultado do teste mostrou que de todas as wavelets cujas curvas de resultados estiveram acima de 40 dB para a maioria das taxas de compressão, a wavelet Daubechies de 8 coeficientes (linha sólida preta) é aquela que possui menor quantidade de coeficientes, e por esta razão foi selecionada para testar as técnicas de compressão e comparar seus resultados.

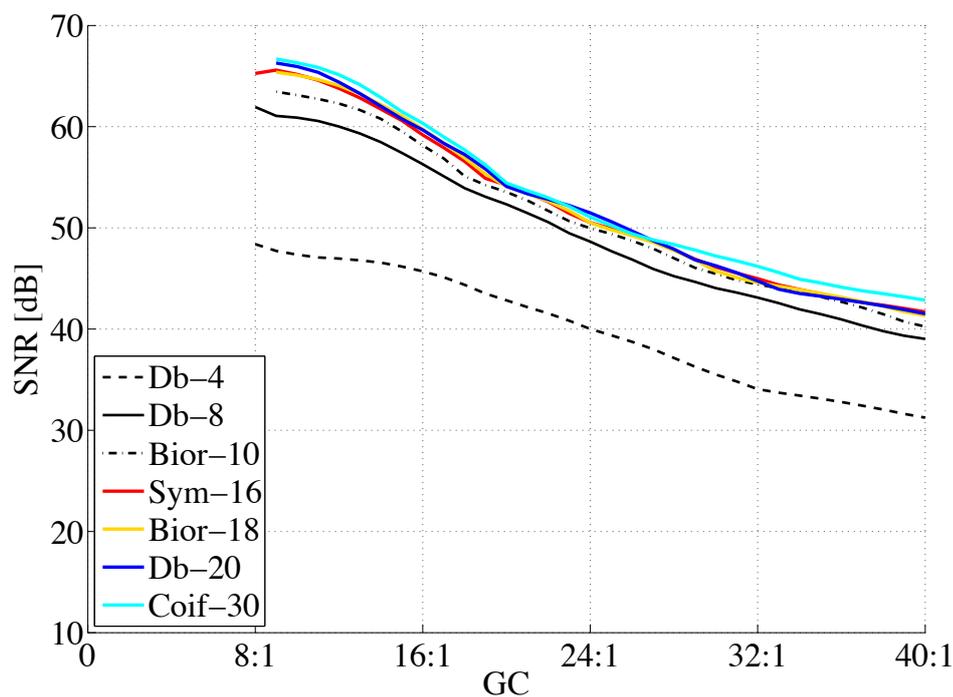


Figura 4.10: Resultados da seleção da wavelet. Daubechies de 4 coeficientes (Db-4). Daubechies de 8 coeficientes (Db-8). Biortogonal 5/3 de 10 coeficientes (Bior-10). Daubechies de 20 coeficientes (Db-20). Biortogonal de 18 coeficientes (Bior-18). Coiflets de 30 coeficientes (Coif-30). Symlets de 16 coeficientes (Sym-16). Evento 21839.

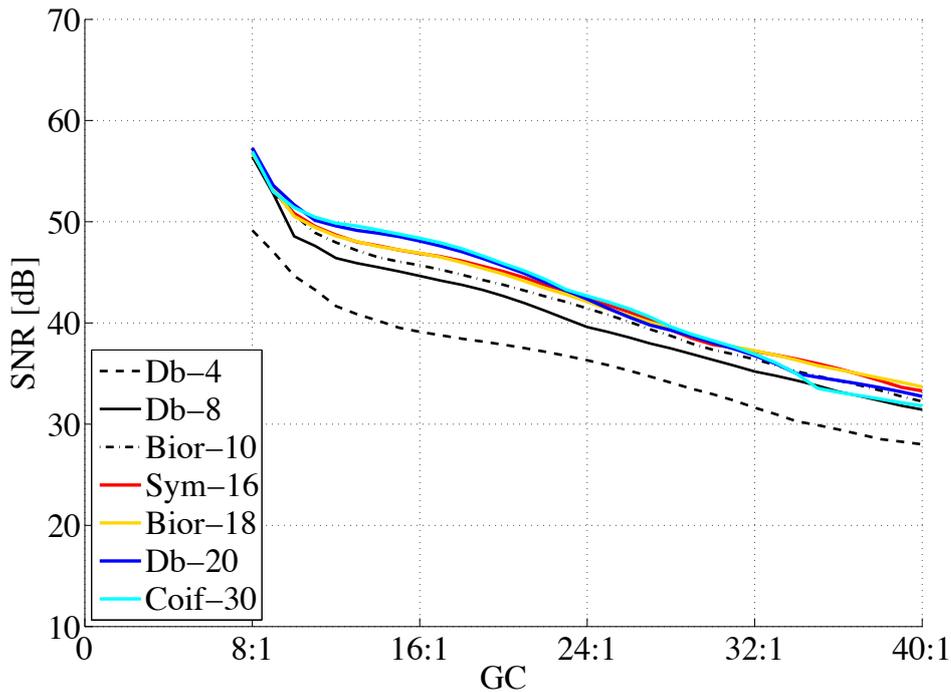


Figura 4.11: Resultados da seleção da wavelet. Daubechies de 4 coeficientes (Db-4). Daubechies de 8 coeficientes (Db-8). Biortogonal 5/3 de 10 coeficientes (Bior-10). Daubechies de 20 coeficientes (Db-20). Biortogonal de 18 coeficientes (Bior-18). Coiflets de 30 coeficientes (Coif-30). Symlets de 16 coeficientes (Sym-16). Evento 21867.

#### 4.4.5 Seleção do tamanho da janela

Simulações com janelas de diferentes tamanhos (256, 512 e 1024 amostras) para a wavelet Daubechies de 8 coeficientes foram realizadas. Os resultados mostram que o desempenho da técnica diminui conforme diminui a quantidade de amostras em cada janela. Observa-se nas figuras 4.12 e 4.13, a curva com a média dos resultados para a simulação da técnica com janelas de 256 amostras (linha traço-ponto), de 512 amostras (linha tracejada) e de 1024 amostras (linha sólida). Pode ser verificado, que a variação dos resultados para o evento 21839 está limitada entre 1 dB e 14 dB, enquanto a faixa de variação para o evento 21867 está definida entre 1 dB e 8 dB.

Os resultados mostrados anteriormente sugerem que desde o ponto de vista da compressão, a escolha do tamanho da janela afeta o desempenho da compactação de sinais de distúrbios, portanto, foi selecionada uma janela de 1024 amostras para simular as técnicas de compressão e comparar seus resultados. É importante destacar que uma janela com maior número de amostras favorece a compressão, pelo fato de que a quantidade de informação lateral necessária para decodificar cada janela, torna-se menor na medida em que aumenta o tamanho da janela, o que impacta diretamente no fator de compressão. Destaca-se também que algumas das técnicas empregadas estão baseadas na estatística do comportamento do sinal como, por exemplo, em janelas que contenham sinal em regime permanente que

apresentam poucas variações na forma de onda e menor espalhamento no espectro, o que culmina em menor quantidade de coeficientes de alta energia a serem codificados.

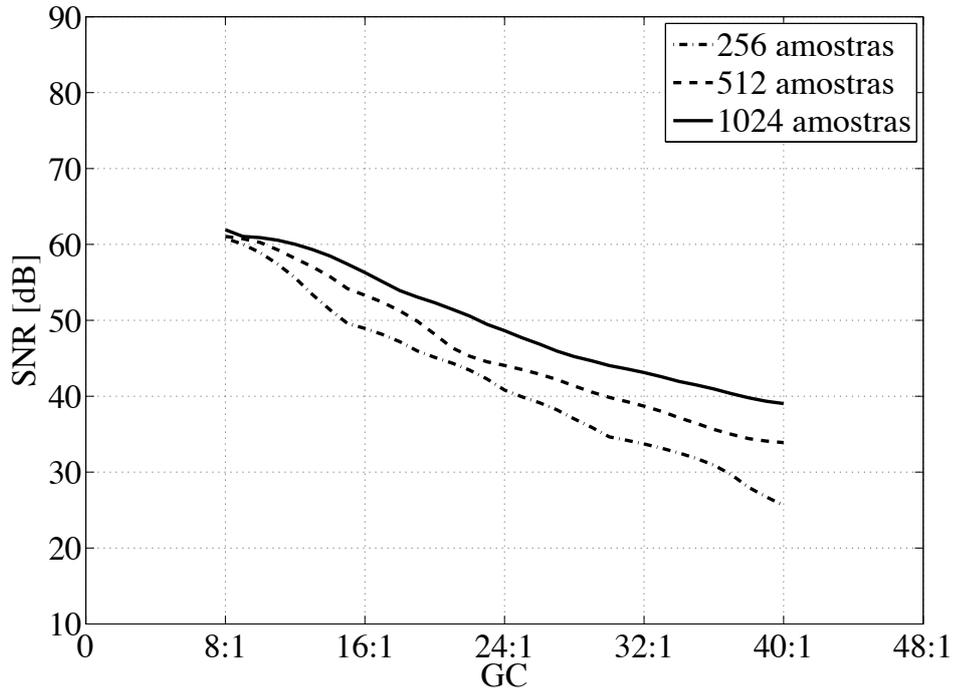


Figura 4.12: Resultados da seleção do tamanho da janela para a wavelet Daubechies de 8 coeficientes. Evento 21839.

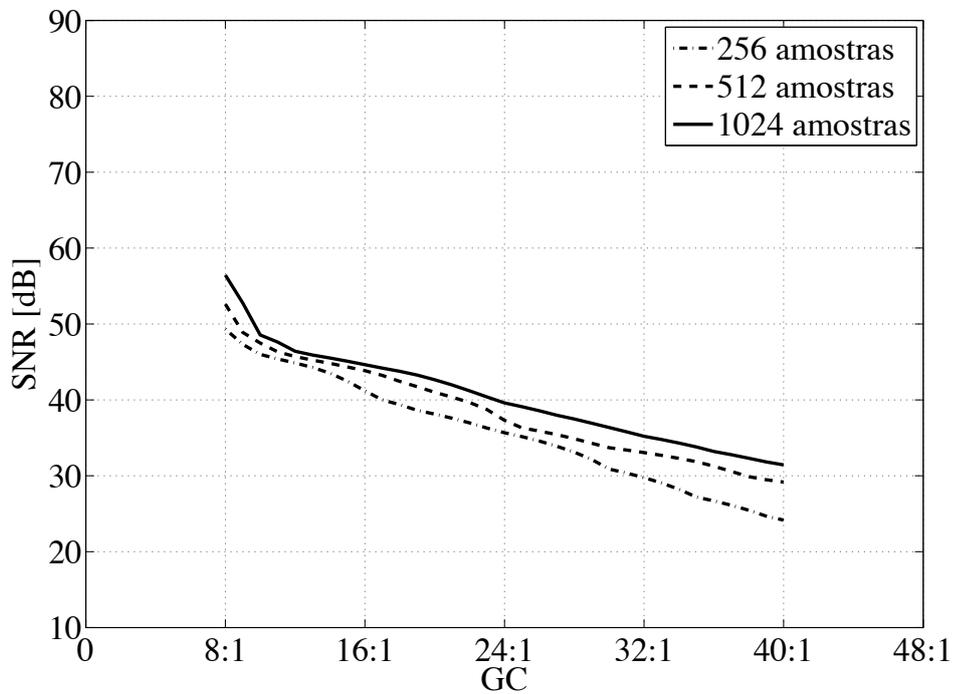


Figura 4.13: Resultados da seleção do tamanho da janela para a wavelet Daubechies de 8 coeficientes. Evento 21867.

A metodologia apresentada nas secções anteriores, foi realizada em todos os sinais de

distúrbios da base de dados, atingindo resultados similares. Sempre que não informado, os resultados apresentados correspondem à média dos resultados dos sinais indicados.

#### 4.4.6 Resultados de simulação

A técnica foi programada de forma a permitir codificar, ao mesmo tempo, os três sinais de tensão ou de corrente correspondentes a cada uma das fases de um sistema elétrico de potência trifásico. Os parâmetros utilizados nas simulações são definidos a seguir: janelas de comprimento de 1024 amostras ( $N=1024$ ), 8 sub-bandas de 128 coeficientes por banda ( $M=8$ ), o ajuste da faixa dinâmica para quantização foi especificado para comprimentos da palavra no intervalo  $2 \leq Q$  [bits]  $\leq 15$ .

Os resultados das simulações mostraram que o comprimento da palavra usado para quantizar os coeficientes transformados (8 bits) pode ser muito menor que o comprimento da palavra utilizado para representar o sinal original (16 bits), sem provocar erro significativo no sinal reconstruído. Esta afirmação pode ser verificada pela relação sinal-ruído exibida na tabela 4.2, onde cada um dos sinais reconstruídos apresenta um valor de  $SNR > 40$  dB, o que sugere que a energia do sinal original é  $10^4$  vezes maior que a energia da distorção. Em outras palavras, o nível de energia do sinal desejado é quatro ordens de grandeza maior que o nível da energia do erro gerado na compressão.

Tabela 4.2: Medição de desempenho da técnica para  $N=1024$ ,  $M=8$  e  $Q=8$ .

Parâmetros	Evento 21839			Evento 21867		
	Fase A	Fase B	Fase C	Fase A	Fase B	Fase C
GC	22,89:1	23,15:1	20,91:1	19,36:1	16,85:1	17,76:1
SNR	50,50	48,63	50,67	43,06	42,65	45,22
TB	0,699	0,691	0,765	0,827	0,949	0,901
MSNE	-50,50	-48,63	-50,67	-43,06	-42,65	-45,22
FC	95,63	95,68	95,22	94,83	94,07	94,37

O aumento do ganho de compressão ( $GC > 16$ ) revela uma redução na taxa de bits ( $TB < 1$ ), o que se interpreta como uma diminuição superior a 94% da quantidade de memória necessária para armazenar o sinal codificado, quando comparado com o sinal original. Valores similares foram observados nos resultados obtidos com sinais presentes na base de dados.

Nas figuras 4.14 e 4.15, são mostrados três segmentos das formas de onda dos eventos 21839 e 21867 antes e depois da compressão, respectivamente. Verifica-se que não há discrepância visual alguma entre os sinais originais e os sinais reconstruídos. Para evidenciar as alterações nas formas de onda causadas pela perda de informação, se faz necessário calcular a distorção entre o sinal original e o sinal reconstruído. Verifica-se, em ambos os casos, que o maior nível de distorção se apresenta onde os sinais experimentam mudanças bruscas de comportamento, o que em termos do domínio da transformada se traduz em uma maior

atividade na faixa dinâmica do espectro causada pela variação da energia do sinal.

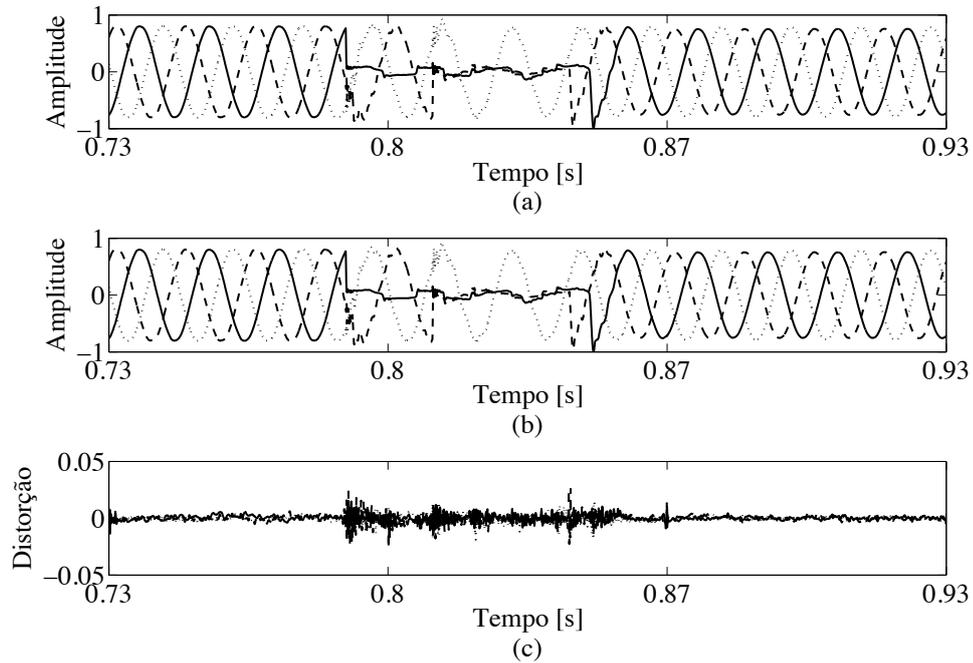


Figura 4.14: Fase A (Linha Solida). Fase B (Linha Tracejada). Fase C (Linha Pontilhada). (a) Sinais Originais. (b) Sinais Reconstruídos. (c) Distorção dos três sinais. Evento 21839.

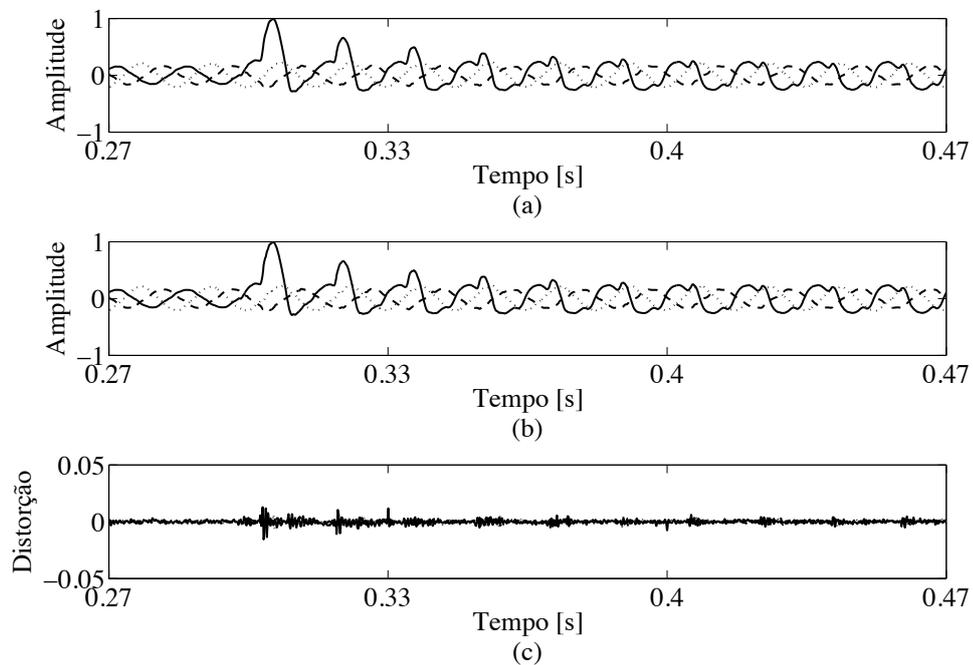


Figura 4.15: Fase A (Linha Solida). Fase B (Linha Tracejada). Fase C (Linha Pontilhada). (a) Sinais Originais. (b) Sinais Reconstruídos. (c) Distorção dos três sinais. Evento 21867.

Nas figuras 4.16 e 4.17, são mostrados os resultados da técnica de compressão em termos da SNR vs GC para o conjunto de sinais de teste que não foram utilizadas no treinamento

(linhas sólidas cinza). Os resultados incluem uma curva com os resultados de cada uma das fases dos eventos 21839 e 21867, respectivamente.

A variação do GC é alcançada modificando-se o parâmetro  $\lambda$  definido na equação (4.10). À medida que se diminui o valor de  $Q$ , o fator de compressão aumenta, e como resultado desse aumento, a SNR diminui até sair da faixa de operação útil ( $SNR > 40$  dB,  $0 < GC < 32$  ou  $0 < TB$  [bits/amostra]  $< 1$ ). A partir desse ponto, qualquer pequeno aumento no fator de compressão ocasiona uma grande deterioração do sinal reconstruído após a decodificação. Consideradas as condições de digitalização dos sinais e o grau de distorção na forma de onda, observa-se nas figuras 4.16 e 4.17, que o desempenho da técnica para a maioria dos casos presentes no banco de dados, mostra que ganhos de compressão altos são ainda obtidos com uma relação sinal-ruído alta.

Os resultados apresentados evidenciam que a alocação dinâmica vetorial e inteligente de bits associada com uma codificação de entropia eficiente pode ser muito vantajosa na compressão de sinais de distúrbios na faixa útil de operação. Adicionalmente, pode ser verificado que a técnica de compressão apresentou melhor desempenho para o conjunto de sinais de tensão que para o conjunto de sinais de corrente. Isto acontece devido ao fato dos distúrbios de corrente exibirem grande variação na faixa dinâmica do sinal associada a uma grande distorção na forma de onda.

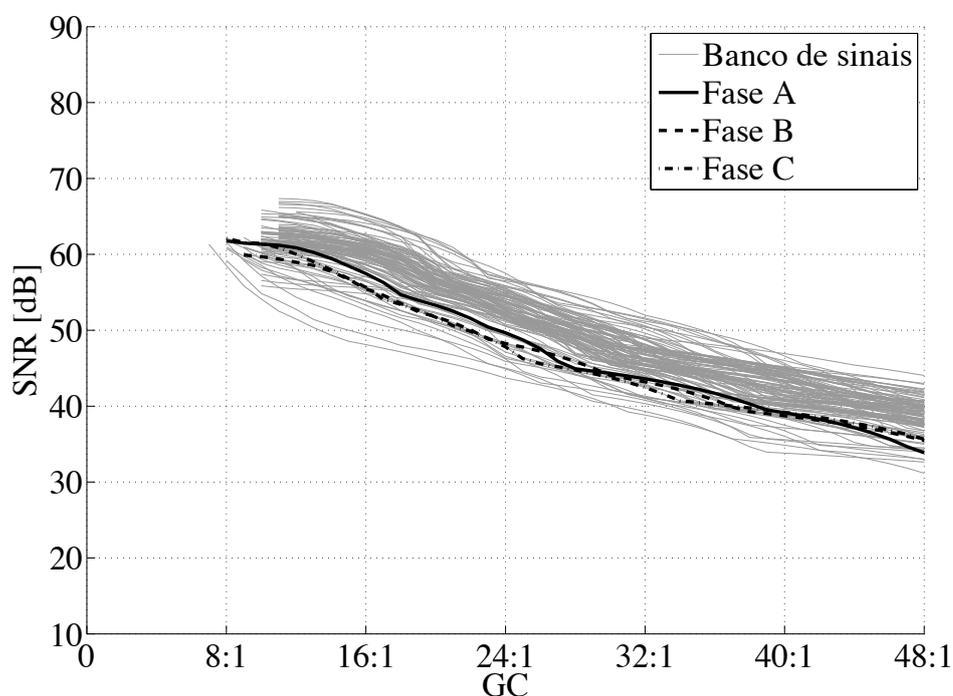


Figura 4.16: Curvas de desempenho da técnica CTIA. Banco de sinais (linhas sólidas cinza). Sinal da fase A (Linha sólida preta). Sinal da Fase B (Linha tracejada preta). Sinal da Fase C (Linha pontilhada preta). Evento 21839.

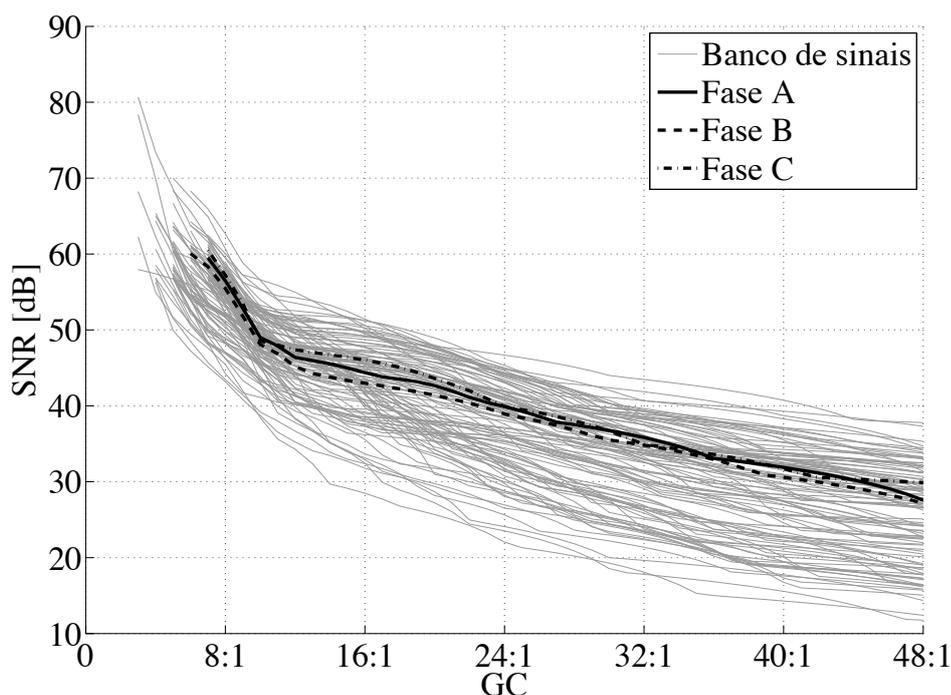


Figura 4.17: Curvas de desempenho da técnica CTIA. Banco de sinais (linhas sólidas cinza). Sinal da fase A (Linha sólida preta). Sinal da Fase B (Linha tracejada preta). Sinal da Fase C (Linha pontilhada preta). Evento 21867.

#### 4.5 CODIFICAÇÃO POR TRANSFORMADAS COM CURVAS DE PERFIL ESPECTRAL PARA ALOCAÇÃO DINÂMICA DE BITS NO ESPAÇO TRANSFORMADO (CTCA)

Em geral, os espectros dos sinais de tensão e corrente exibem comportamentos decrescentes, em função da organização dos coeficientes transformados. De forma que, aqueles que apresentam o módulo de maior amplitude estão localizados nas baixas frequências (parte esquerda do espectro), enquanto, os do módulo menor amplitude estão localizados nas altas frequências (parte direita do espectro). Nas bandas de transição, existem coeficientes que apresentam variações abruptas de amplitude.

Nesta técnica são geradas curvas de perfil espectral no domínio da transformada, cujos parâmetros aproximam a envoltória que define o número de bits para quantização dos coeficientes transformados. Para isso, são utilizadas funções básicas do cálculo selecionadas por serem funções estritamente decrescentes.<sup>1</sup> A técnica de compressão utiliza as curvas de perfil espectral como uma estratégia para estimar a quantidade de bits da representação e adaptar o comprimento da palavra à forma do espectro. Na figuras 4.18(a) e 4.18(b), apresenta-se o diagrama de blocos do algoritmo de codificação da técnica de compressão CTCA.

<sup>1</sup>Diz-se que a função real  $g(x)$  é decrescente em sentido estrito, em um intervalo  $I$ , quando, para todos os números reais  $x_1$  e  $x_2$ , onde  $x_2 > x_1$ , pertencentes ao intervalo  $I$ , se  $g(x_1) > g(x_2)$  (ANTON, 1999)

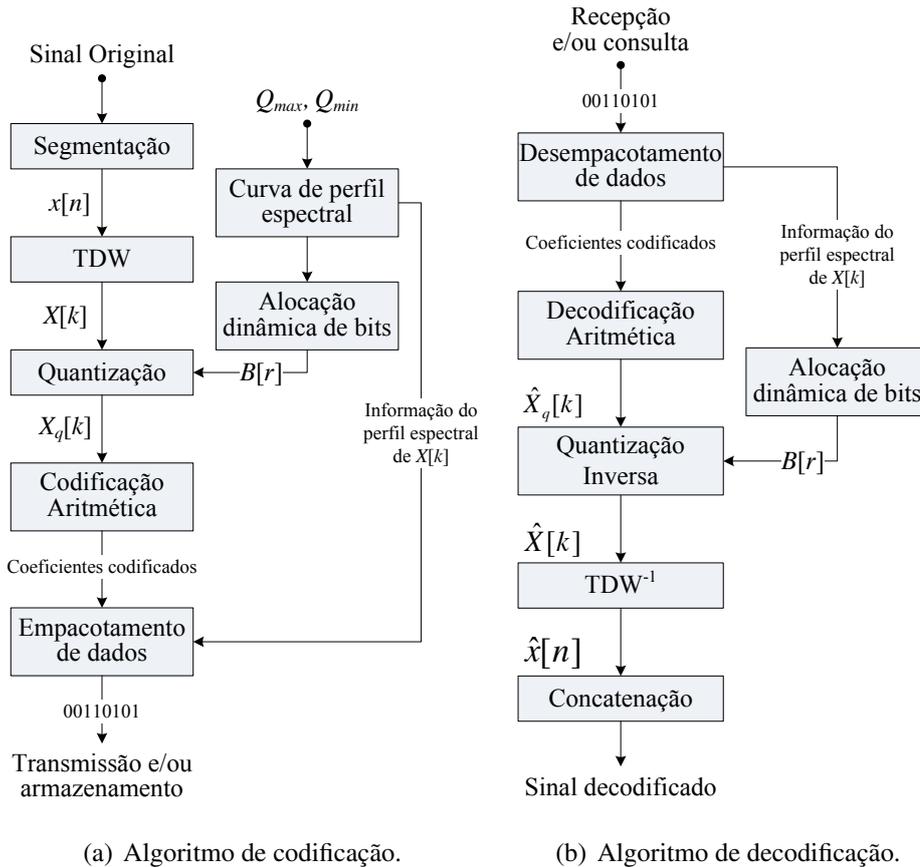


Figura 4.18: Diagrama de blocos da CTCA.

#### 4.5.1 Algoritmo de codificação

O procedimento de segmentação do sinal original e do cálculo da transformada wavelet, para cada um dos segmentos, apresenta as mesmas características que na técnica de compressão CTIA. A alocação de bits é feita com ajuda da sequência de quantizadores ( $B[r]$ ), cujos termos representam os bits alocados para os coeficientes de cada uma das  $M$  sub-bandas do espectro.  $B[r]$  pode ser interpretado como a versão discreta da curva de perfil espectral que define a quantidade de bits de quantização no domínio da transformada. O tipo de curva, além dos comprimentos da palavra  $Q_{max}$  e  $Q_{min}$  a serem utilizados na quantização, são predefinidos pelo usuário, e correspondem a uma entrada do algoritmo. Os coeficientes quantizados são logo codificados com um codificador aritmético.

#### 4.5.2 Curvas de perfil espectral

Nesta seção serão apresentadas as equações que descrevem matematicamente a função que define a sequência  $B[r]$ . Para descrever completamente uma função, além de especificar a regra que relaciona as entradas com as saídas, deve-se especificar seu domínio. Neste trabalho, o domínio foi definido como o conjunto de sub-bandas nas quais foi dividido o espectro. O contradomínio corresponde à faixa de variação do comprimento da palavra.

- Aproximação Linear da forma  $y = ax + b$ ,  $\{a, b\} \in \mathfrak{R}$  e  $a < 0$

Onde,  $a$  é o coeficiente angular e  $b$  é o coeficiente linear. A equação (4.14), descreve a reta que passa pelos pontos  $(0, Q_{max})$  e  $(M - 1, Q_{min})$ .

$$B[r] = \left[ \left( \frac{Q_{min} - Q_{max}}{M - 1} \right) r + Q_{max} \right], \quad r = \{0, 1, \dots, M - 1\} \quad (4.14)$$

- Aproximação Quadrática da forma  $y = b - ax^2$ ,  $\{a, b\} \in \mathfrak{R}$  e  $\{a, b\} > 0$

Onde, o parâmetro  $a$  corresponde à taxa de crescimento (ou decrescimento) da curva quadrática, enquanto, o parâmetro  $b$  é a assíntota superior. A equação (4.15), mostra o deslocamento do vértice da parábola  $g(x) = -ax^2$ , localizado na origem do sistema de coordenadas cartesianas, para o ponto  $(0, Q_{max})$ .

$$B[r] = \left[ Q_{max} - \left( \frac{Q_{max} - Q_{min}}{(M - 1)^2} \right) r^2 \right], \quad r = \{0, 1, \dots, M - 1\} \quad (4.15)$$

- Aproximação Exponencial da forma  $y = b \cdot a^{x/\tau}$ ,  $\{a, b\} \in \mathfrak{R}$ ,  $\tau > 0$ ,  $b > 0$  e  $0 < a < 1$

Onde, a constante  $a$  é o valor inicial de  $y$ , a constante  $b$  corresponde à taxa de crescimento positivo, e  $\tau$  é a constante de tempo que define os incrementos para  $y$ . A equação (4.16), descreve o comportamento geométrico da função, pelo fato da taxa de crescimento ser proporcional ao valor atual da função.

$$B[r] = \left[ Q_{max} \left( \frac{Q_{min}}{Q_{max}} \right)^{\frac{r}{M-1}} \right], \quad r = \{0, 1, \dots, M - 1\} \quad (4.16)$$

- Aproximação Sigmoidal da forma  $y = a + \frac{b - a}{1 + e^{-c(x-x_0)}}$ ,  $\{a, b, c\} \in \mathfrak{R}$ ,  $\{a, b\} > 0$  e  $c < 0$

Onde, o parâmetro  $a$  é a assíntota inferior,  $b$  é a assíntota superior, e  $c$  é a taxa de crescimento. A curva descrita pela equação (4.17) é uma função muito flexível, contudo precisa do ajuste de vários parâmetros.

$$B[r] = \left[ Q_{min} + \frac{Q_{max} - Q_{min}}{1 + e^{(r-r_0)}} \right], \quad r = \{0, 1, \dots, M - 1\} \quad (4.17)$$

A figura 4.19 apresenta um exemplo ilustrativo do cálculo da sequência  $B[r]$ , utilizando cada uma das curvas de perfil espectral propostas na técnica de compressão CTCA.

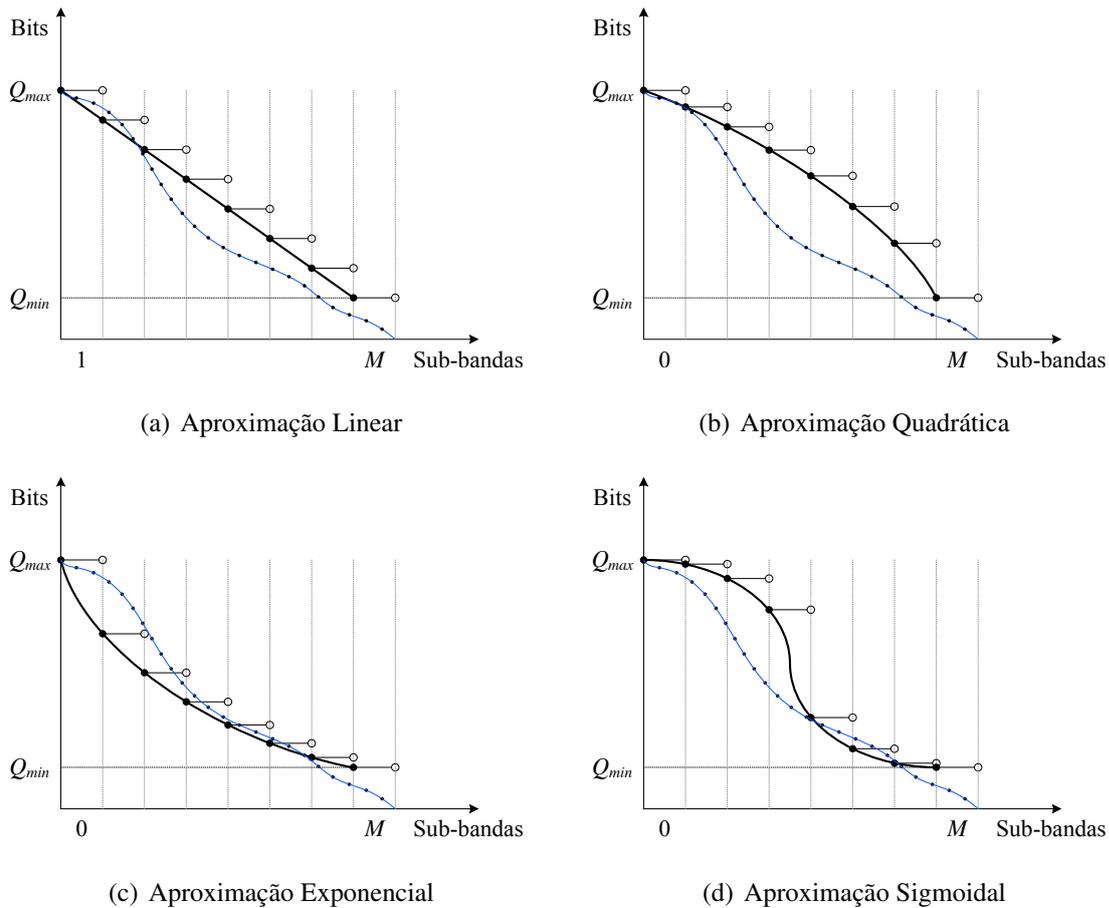


Figura 4.19: Curvas de alocação de bits.

Na figura 4.20, é ilustrada a estrutura dos dados compactados de cada segmento de sinal. O bloco de dados está formado pelos coeficientes codificados e pela correspondente informação associada à curva de perfil espectral que faz o mapeamento do espectro. Os blocos são concatenados de forma a gerar um arquivo de dados compactado.

Coeficientes TDW codificados	Curva de perfil da TDW, $Q_{max}, Q_{min}$
---------------------------------	---

Figura 4.20: Estrutura dos dados compactados pelo algoritmo CTCA.

### 4.5.3 Algoritmo de decodificação

O diagrama de blocos que descreve o algoritmo de decodificação da técnica de compressão CTCA é mostrado na figura 4.18(b). Após o desempacotamento dos dados, a informação do perfil espectral é usada na quantização inversa dos coeficientes resultantes da decodificação aritmética. Seguidamente à obtenção de  $\hat{X}_q[k]$ , é aplicada a transformada inversa obtendo como resultado  $\hat{X}[k]$ . Finalmente, o sinal decodificado é obtido pela concatenação

sucessiva de janelas de comprimento igual a  $N$  amostras.

#### 4.5.4 Resultados de simulação

Com o objetivo de medir o desempenho da alocação de bits usando cada uma das curvas, foram realizados simulações da técnica de compressão variando a faixa dinâmica, em outras palavras, variando os limites do comprimento da palavra ( $Q_{max}$  e  $Q_{min}$ ). Os parâmetros utilizados nas simulações são definidos a seguir: sinais trifásicos de tensão (Evento 21839), sinais trifásicos de corrente (evento 21867), janelas de comprimento de 1024 amostras ( $N=1024$ ), 8 sub-bandas de 128 coeficientes por banda ( $M=8$ ). As figuras 4.21, 4.22 e 4.23, mostram os resultados obtidos em cada uma das simulações descritas a seguir.

- Simulação para  $Q_{max}=15$  e  $2 < Q_{min} < 15$ .

Os resultados da figura 4.21, mostram que quando fixados 15 bits como comprimento máximo da palavra, é garantida a melhor representação dos coeficientes da primeira sub-banda, que por sua vez, são os coeficientes com as maiores amplitudes do espectro. Portanto, é obtida a melhor relação sinal ruído, em detrimento do ganho de compressão. As outras sub-bandas recebem uma quantidade de bits, de acordo com a variação do comprimento mínimo.

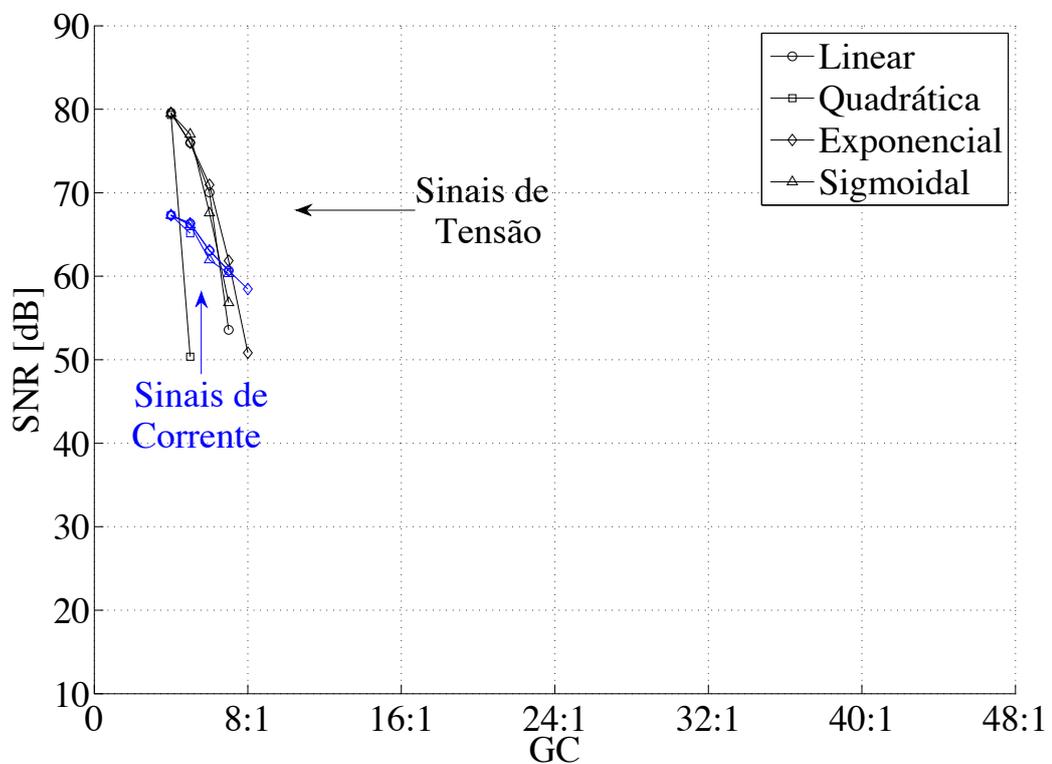


Figura 4.21: Resultados da Simulação para  $Q_{max}=15$  e  $2 < Q_{min} < 15$ .

- Simulação para  $2 < Q_{max} < 15$  e  $Q_{min} = 2$ .

A variação da faixa dinâmica dos coeficientes da primeira sub-banda, faz com que o nível da qualidade na reconstrução seja alterado, isto é, devido à mudança na quantidade de bits usada na representação dos coeficientes da sub-banda que contem a maior parcela da energia do sinal (vide figura 4.22).

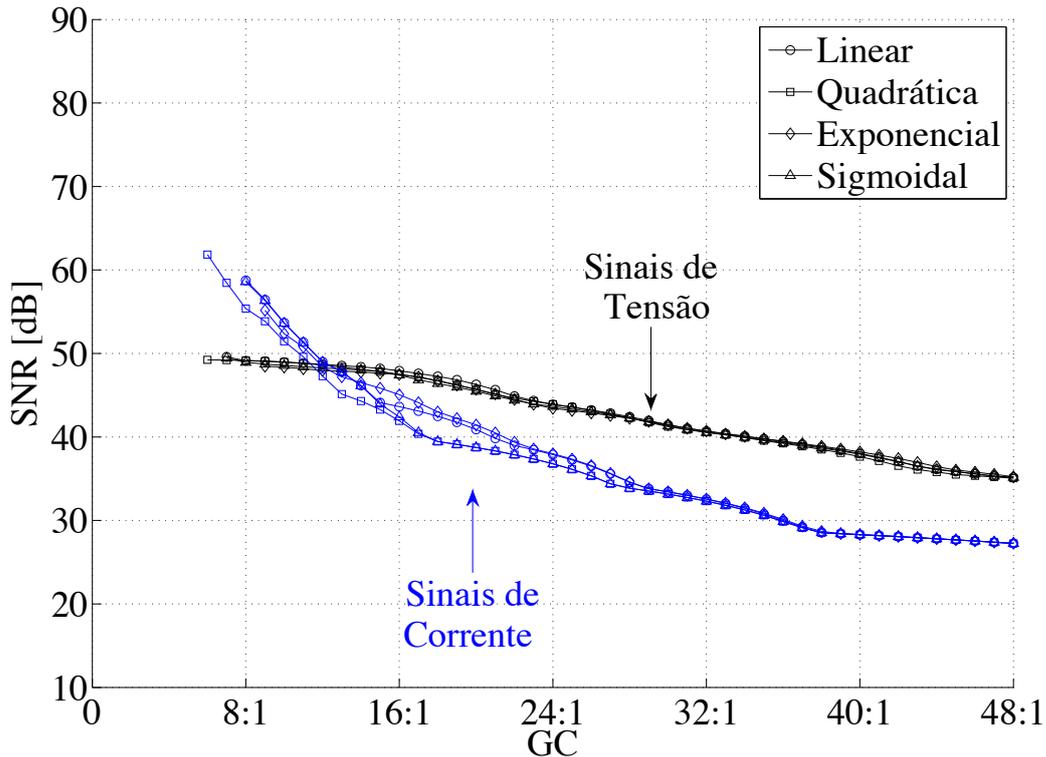


Figura 4.22: Resultados da Simulação para  $2 < Q_{max} < 15$  e  $Q_{min} = 2$ .

- Simulação para  $8 < Q_{max} < 15$  e  $2 < Q_{min} < 9$

Neste caso, é proposta a variação simultânea dos limites dos comprimentos da palavra. Para isso, deve-se cumprir que a diferença entre os valores de  $Q_{max}$  e  $Q_{min}$  seja constante e maior que zero. Foram realizadas simulações para  $1 < Q_{max} - Q_{min} < 13$ , cujo melhor resultado é mostrado na figura (4.23), onde o valor da diferença é de 6 bits. Na figura (4.23), pode ser verificado que tanto para os sinais de tensão, quanto para os sinais de corrente os resultados mostram o melhor compromisso entre o ganho de compressão e a relação sinal ruído.

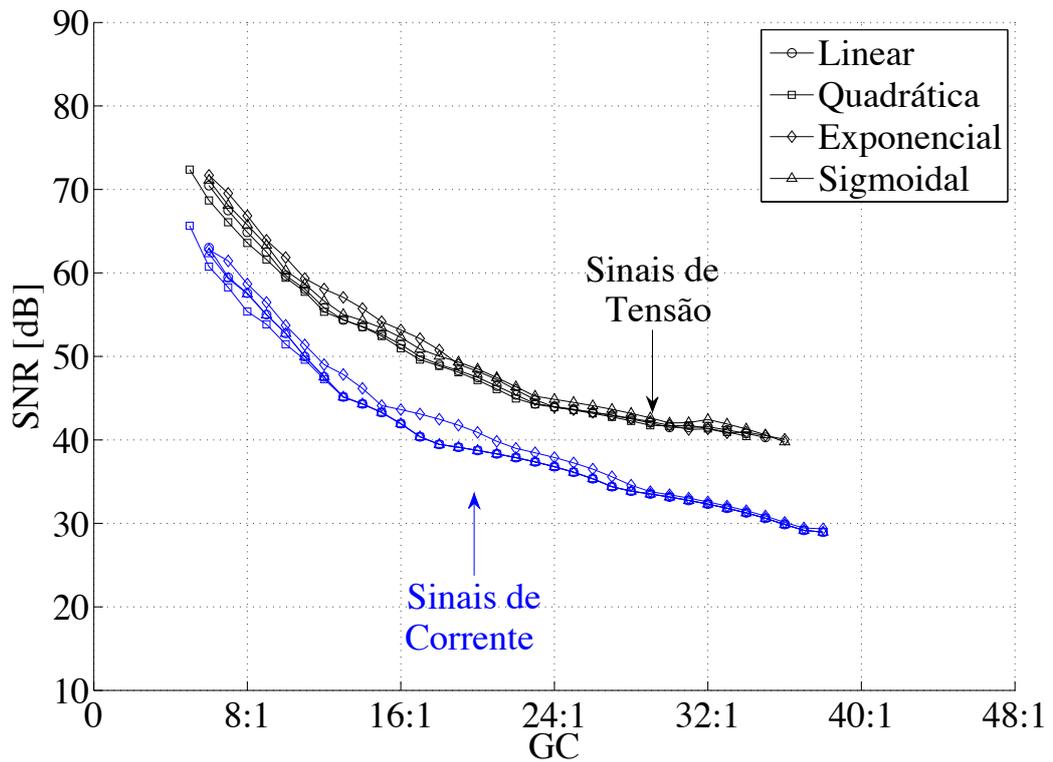


Figura 4.23: Resultados da Simulação para  $8 < Q_{max} < 15$  e  $2 < Q_{min} < 9$ .

#### 4.6 CODIFICAÇÃO POR TRANSFORMADAS COM ABORDAGEM DISSOCIATIVA ENTRE REGIME PERMANENTE E EVENTOS TRANSITÓRIOS (CTAD)

Na abordagem dissociativa assume-se, que os sinais coletados pelos equipamentos de medição ( $x[n]$ ) podem ser expressos matematicamente como uma soma das contribuições de vários fenômenos que afetam a QEE, tal e como se apresenta na equação (4.18) (RIBEIRO *et al.*, 2007; ZHANG *et al.*, 2011).

$$x[n] = f[n] + h[n] + i[n] + t[n] + v[n], \quad n = 0, \dots, N - 1 \quad (4.18)$$

onde, os sinais  $f[n]$ ,  $h[n]$ ,  $i[n]$ ,  $t[n]$  e  $v[n]$  representam, respectivamente, as componentes fundamental e harmônicas, as componentes inter-harmônicas, os transitórios e o ruído. De acordo com a IEEE Std 1159 (2009), os sinais  $f[n]$ ,  $h[n]$  e  $i[n]$ , são considerados fenômenos de regime permanente, mesmo que as componentes inter-harmônicas exibam baixas amplitudes em relação às componentes fundamental e harmônicas. Contudo, para efeitos desta técnica, somente  $f[n]$  e  $h[n]$  serão considerados fenômenos de regime permanente por apresentar a maior fracção da energia do sinal. Nesse sentido, podemos rescrever a equação (4.18) de forma que,  $x[n]$  possa ser dividida em uma sequência que contenha a energia do sinal em regime permanente ( $s[n]$ ) e uma outra que represente o resíduo (diferença) entre as

duas anteriores ( $u[n]$ ). A representação matemática que descreve estas análises é apresentada nas equações (4.19), (4.20) e (4.21).

$$x[n] = s[n] + u[n] + v[n], \quad n = 0, \dots, N - 1 \quad (4.19)$$

$$s[n] = f[n] + h[n], \quad n = 0, \dots, N - 1 \quad (4.20)$$

$$u[n] = i[n] + t[n], \quad n = 0, \dots, N - 1 \quad (4.21)$$

A abordagem explora a natureza do sinal, e faz uso paralelo de diferentes técnicas de compressão de dados que levam em consideração as características espectrais do sinal. O objetivo é melhorar o desempenho compactando  $s[n]$  e  $u[n]$  e removendo  $v[n]$ . O diagrama de blocos do algoritmo de codificação da técnica compressão CTAD é apresentado na figura (4.24).

#### 4.6.1 Algoritmo de codificação

O sinal  $x[n]$  é segmentado em janelas de tamanho ( $N$ ) igual à quantidade de amostras em um ciclo da frequência fundamental da rede elétrica, que por sua vez é uma potência inteira de dois. A seguir, é usada a transformada rápida de Fourier, do inglês *Fast Fourier Transform (FFT)*, para calcular as amplitudes e as fases das componentes do espectro. No domínio da frequência, os coeficientes associados às componentes fundamental e harmônicas ( $X_s[k]$ ), são identificados e separados do espectro para serem quantizados. A alocação de bits para quantização é feita por meio de uma curva de perfil espectral que caracteriza o comportamento dos coeficientes referidos acima, gerando um vetor de alocação de bits ( $B_{FFT}[r]$ ). Os comprimentos da palavra ( $Q_{FFTmax}$  e  $Q_{FFTmin}$ ) que determinam a curva de alocação são predefinidos pelo usuário e correspondem a uma entrada do algoritmo. Os coeficientes quantizados são logo codificados com um codificador aritmético.

A sequência de resíduo ( $u[n]$ ), é obtida por meio do cálculo da transformada inversa de Fourier, do inglês *Inverse Fast Fourier Transform (IFFT)*, para o restante dos coeficientes do espectro ( $X_u[k]$ ). Nesse sentido,  $u[n]$  está constituído pelos coeficientes que contem a energia das inter-harmônicas, transitórios e ruído que apresenta  $x[n]$ .

O comportamento aleatório de  $u[n]$ , faz com que sua natureza dinâmica possa ser bem representada com a TWD, contudo, é necessário entender que ainda é possível eliminar porções de  $u[n]$  que são irrelevantes para o cálculo da TDW, devido à pouca energia presente nas amostras. É por isso, que foram programadas as etapas de detecção e de segmentação da sequência de resíduo, cujo resultado consiste na extração das amostras que apresentam a maior energia ( $d[m]$ ), e no descarte automático das amostras restantes.

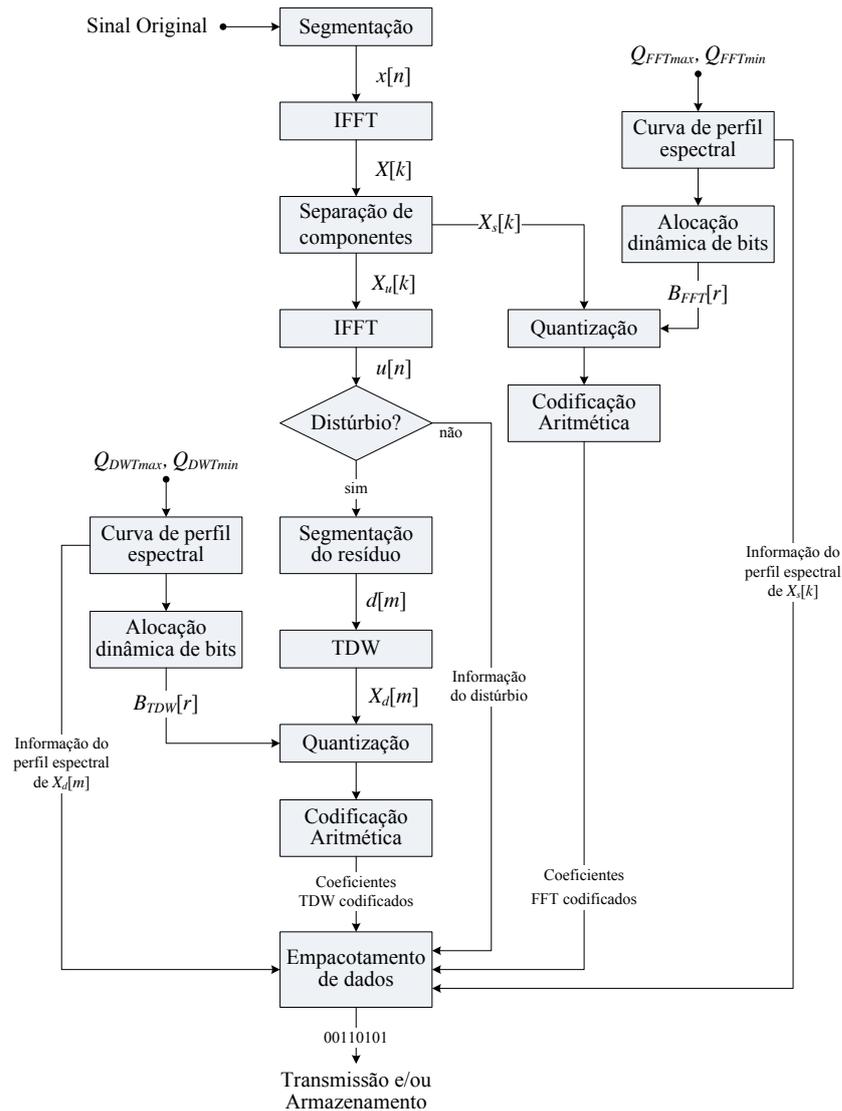


Figura 4.24: Diagrama de blocos da CTAD. Algoritmo de codificação.

A figura 4.25, ilustra a separação do sinal  $s[n]$  de  $x[n]$ . Em geral, observa-se que as janelas de  $u[n]$  que se superpõem ao sinal de regime permanente (1, 2, 3, 9, 10 e 11), apresentam menor variância que aquelas que se superpõem ao distúrbio (janelas 4, 5, 6, 7 e 8), isso porque durante a separação dos sinais a maior parte da energia foi retirada com as componentes fundamental e as componentes harmônicas. Assim, as janelas que contêm as amostras de baixa energia podem ser consideradas como ruído. A sequência de distúrbio ( $d[m]$ ) é determinada pelas janelas 4, 5, 6, 7 e 8, onde as amostras apresentam a maior variância de  $u[n]$ .

Durante a detecção é gerado um índice binário que estabelece a localização das janelas que fazem parte do sinal de distúrbio, garantindo que a informação do resíduo possa ser segmentada para favorecer a compressão. Na detecção são utilizadas janelas de tamanho igual a um ciclo da frequência fundamental, enquanto, a segmentação é executada em conjuntos de quatro janelas. Caso o número de janelas não seja múltiplo de quatro o ultimo grupo de

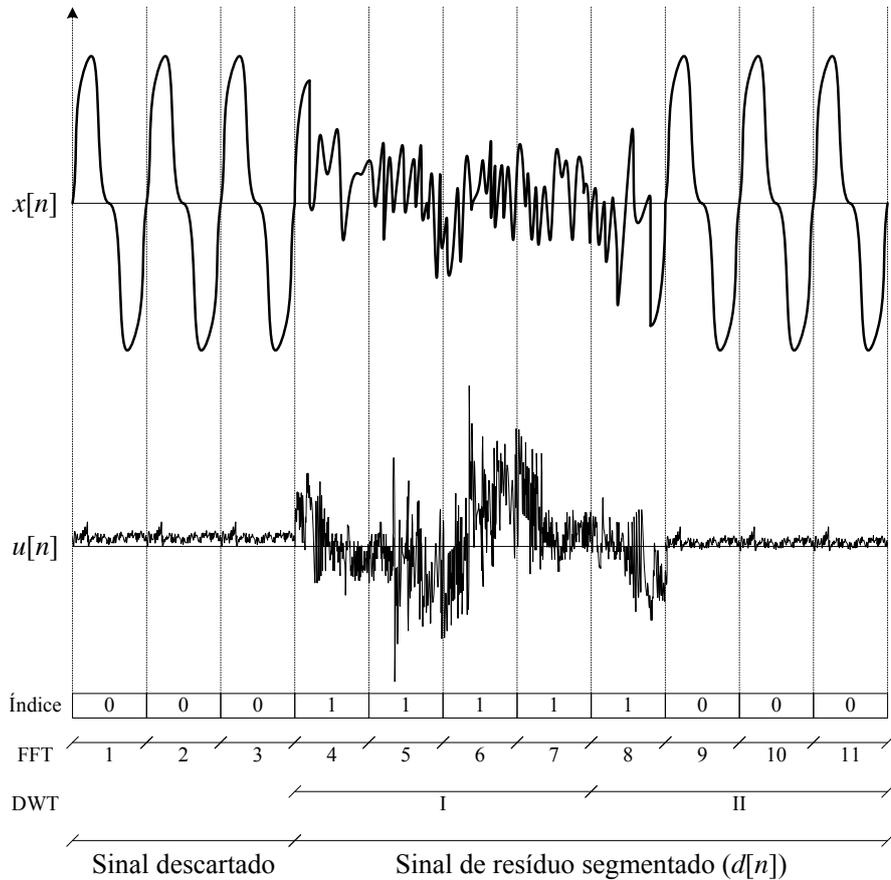


Figura 4.25: Operação do algoritmo de codificação.

janelas será completado com as janelas seguintes depois da ocorrência do distúrbio, tal e como se ilustra na figura 4.25.

Após estes estágios é calculada a TDW para a sequência  $d[m]$ . A quantização dos coeficientes  $X_d[m]$  é executada de forma similar ao caso dos coeficientes  $X_s[k]$ . Onde os comprimentos da palavra  $Q_{TDW_{max}}$  e  $Q_{TDW_{min}}$  são inseridos pelo usuário para calcular a curva de perfil espectral e produzir o vetor de alocação de bits ( $B_{TDW}[r]$ ).

#### 4.6.1.1 Algoritmo de detecção de transitórios

O algoritmo se fundamenta na quantificação da variação que experimenta a faixa dinâmica do sinal quando do passo do regime permanente (menor variação) ao estado transitório (maior variação) e vice-versa. Isso acontece analogamente com a largura de banda do sinal. Para detectar o transitório precisamos de estimar o comportamento em frequência a partir no conjunto de amostras do sinal no domínio do tempo. Portanto, vamos detectar distúrbios cujo espectro de frequência seja superior à décima terceira componente harmônica da frequência fundamental. Qualquer outra componente de frequência acima disto é considerada distúrbio. O raciocínio usado para determinar este valor, se alicerça na escolha da quantidade de

componentes harmônicas que permitem alcançar o máximo valor de referência para o DHT global, que no caso do PRODIST (2011) é de  $10\%^2$ . Esse patamar é atingido com as amplitudes máximas permitidas das primeiras seis componentes harmônicas, contudo, como nem sempre isso acontece, é essencial contar com uma quantidade mais conservadora de componentes harmônicas que contemple esta situação.

O módulo de  $u[n]$ , é comparado com um valor de referência ( $L$ ). Quando o módulo do valor do resíduo é maior ou igual ao valor prefixado, o contador é incrementado do zero e, quando satisfaz três vezes esta condição o distúrbio é confirmado. Caso contrário, o contador é decrementado de uma unidade, a cada duas amostras até o valor mínimo zero. Quando o distúrbio é confirmado pela primeira vez, automaticamente é armazenada uma variável com o número do segmento. O estado final do contador em cada segmento se converte no estado inicial do contador no segmento seguinte. O diagrama de blocos simplificado do algoritmo é ilustrado na figura 4.26.

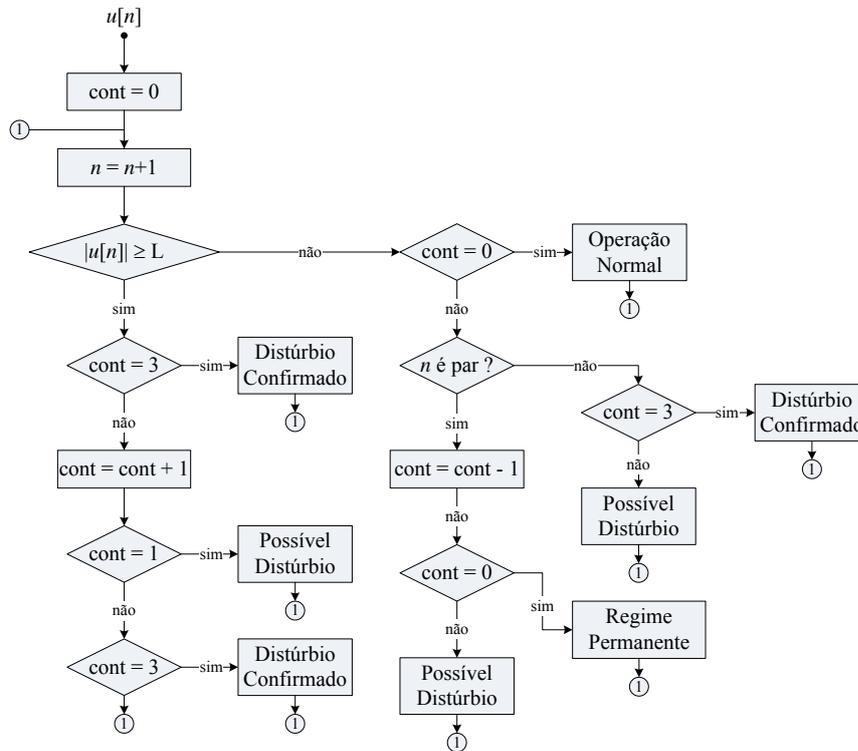


Figura 4.26: Diagrama de blocos do algoritmo de detecção de transitórios.

<sup>2</sup>A Agência Nacional de Energia Elétrica (ANEEL) e o Operador Nacional do Sistema Elétrico disponibilizam, respectivamente, documentos como PRODIST (2011) e o Procedimentos de Rede (2010), onde são apresentados valores de referência individuais e globais para a distorção harmônica total (DHT), para cada nível de tensão nominal do barramento ( $V_N$ ). Observa-se que o valor de DHT aumenta enquanto o  $V_N$  diminui, de forma que, os valores de DHT globais variam entre 3% para  $V_N < 1kV$  e 10% para  $69kV < V_N < 230kV$  (PRODIST, 2011). No caso do (PROCEDIMENTOS DE REDE, 2010), os valores de referência correspondem a 3% e 6% para níveis de tensão nominal de  $V_N 69kV$  e  $V_N < 69kV$ , respectivamente. Os valores de DHT estão em porcentagem da tensão fundamental. Outros documentos como CENELEC (2010), IEEE Std 1159 (2009) sugerem valores de referência similares.



de  $d[n]$  dentro de  $u[n]$ . Entretanto, sobre as curvas, são armazenados o tipo de curva e os comprimentos mínimo e máximo que as definem. Isto para cada uma das transformadas. Os blocos são concatenados de forma a gerar um arquivo de dados compactado.

Destaca-se, que a informação lateral tem uma relação direta com a capacidade de adaptação da técnica de compressão. Em outras palavras, para melhorar o mapeamento dos dados a técnica de compressão terá que utilizar uma maior quantidade de informação lateral.

#### 4.6.2 Algoritmo de decodificação

O desempacotamento, a decodificação e a quantização inversa dos dados são realizados simultaneamente de forma a se ter acesso à informação dos coeficientes de cada bloco compactado. Após a obtenção dos coeficientes  $\hat{X}_s[k]$  e  $\hat{X}_d[m]$ , são aplicadas as transformadas inversas de Fourier e wavelets, respectivamente. As informações sobre a localização do distúrbio em conjunto com  $\hat{d}[m]$ , são as entradas ao bloco encarregado pela localização temporal das janelas do distúrbio dentro da sequência da forma de onda do resíduo. A sequência  $\hat{u}[n]$  é constituída pela superposição localizada de  $\hat{d}[m]$  sobre uma sequência de zeros do mesmo comprimento de  $u[n]$ . Por fim, os sinais  $\hat{u}[n]$  e  $\hat{s}[n]$  são somados para obter o segmento decodificado. O sinal decodificado obtido pela concatenação sucessiva de segmentos de  $\hat{x}[n]$  com comprimento igual a  $N$  amostras. O diagrama de blocos que descreve o decodificador é mostrado na figura 4.29.

#### 4.6.3 Resultados de simulação

Para verificar o desempenho da técnica de compressão CTAD, foram simulados os sinais dos eventos 21839 e 21867. A tabela 4.3 apresenta o resumo dos resultados das simulações para os comprimentos de palavra  $Q_{FFTmax} = 16$  e  $Q_{TDWmax} = 8$ .

Tabela 4.3: Resultados de simulação da técnica CTAD para  $Q_{FFTmax} = 16$  e  $Q_{TDWmax} = 8$ .

Parâmetros	Evento 21839			Evento 21867		
	Fase A	Fase B	Fase C	Fase A	Fase B	Fase C
GC	18,81:1	18,32:1	17,78:1	26,10:1	19,80:1	21,41:1
SNR	58,65	58,51	64,45	46,69	45,22	49,67
TB	0,851	0,873	0,899	0,818	0,808	0,747
MSNE	-58,65	-58,51	-64,45	-46,69	-45,22	-49,67
FC	94,68	94,54	94,38	94,89	94,95	95,33

Em geral, observa-se que houve uma redução de 17 vezes na quantidade de bits utilizada para representar o sinal original. O que significa que a técnica CTDA gasta menos que um 1 bit por amostra para representar o sinal compactado. Em relação à qualidade na reconstrução, destaca-se que para as taxas de compressão citadas, a relação sinal ruído é maior que 45 dB,

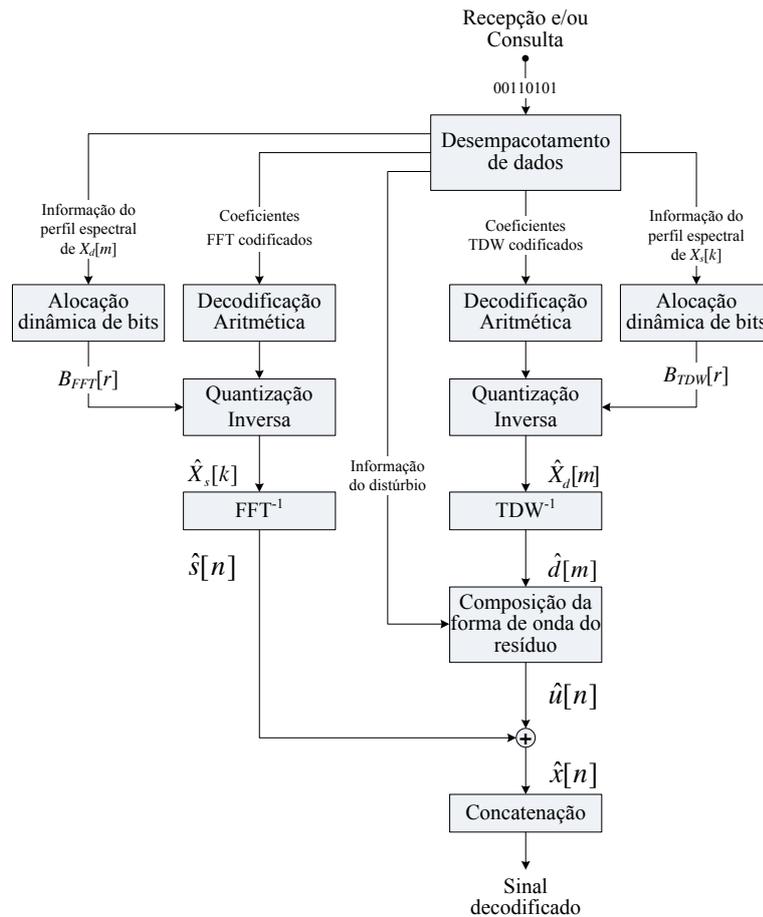


Figura 4.29: Diagrama de blocos da CTAD. Algoritmo de decodificação.

atingindo, assim, uma distorção da ordem de  $10^{-4}$  durante a compressão. Estes resultados são considerados razoáveis, dado que o maior comprimento da palavra utilizado corresponde à metade do comprimento da palavra utilizado para digitalizar o sinal original. Destaca-se que o menor fator de compressão alcançado durante as simulações foi do 94%.

Nas figuras 4.30 e 4.31, é mostrado o comportamento da técnica de compressão em termos da quantidade de bits por fase, resultante da compactação dos 60 ciclos do sinal de tensão (evento 21839) e dos 120 ciclos do sinal de corrente (evento 21867). Na figura 4.30, pode ser observado que a quantidade de bits para compressão da componente fundamental e das componentes harmônicas (barras brancas), não apresenta variação expressiva durante o regime permanente prévio (primeiros 45 ciclos) e posterior (últimos 7 ciclos) ao distúrbio. Durante o distúrbio, é incrementada significativamente a quantidade de bits para representação (barras azuis), devido à aparição de componentes de frequência adicionais (transitório) e ao aumento da faixa dinâmica das componentes sempre presentes.

No sinal de corrente mostrado na figura 4.31, o distúrbio apresenta diferentes durações em cada uma das três fases. Na fase A, o distúrbio inicia após 15 períodos do regime permanente, enquanto, as fases B e C iniciam um ciclo depois. Verifica-se que após o final do distúrbio, a quantidade de bits por período experimenta um acréscimo em relação ao valor

exibido antes do início do distúrbio, isto é, pelo fato de ter acontecido uma mudança das condições de operação da rede elétrica após o distúrbio, tal como mostrado na figura 4.2. Nos exemplos propostos, é mostrado que a técnica de compressão consegue acompanhar as mudanças do comportamento dos sinais pelo fato de explorar sua natureza do distúrbio.

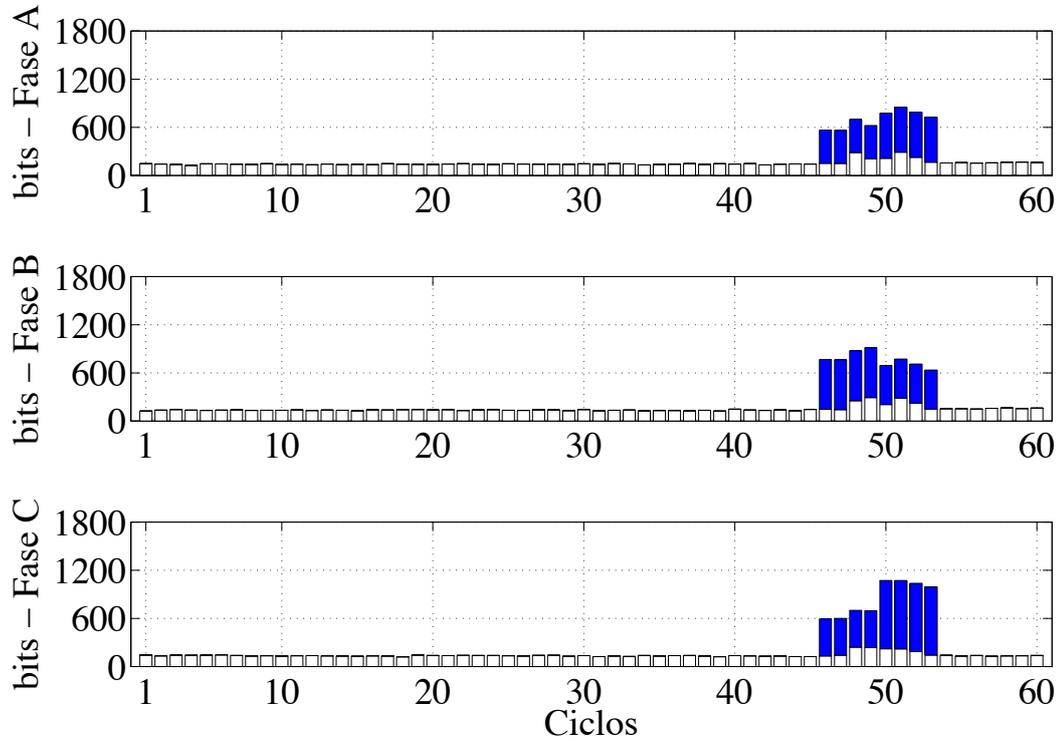


Figura 4.30: Quantidade de bits para compressão por período da frequência fundamental para o Evento 21839 ( $Q_{FFTmax}=16$  e  $Q_{TDWmax}=8$ ). Fundamental e Harmônicas (Barras Brancas). Distúrbio (Barras Azuis).

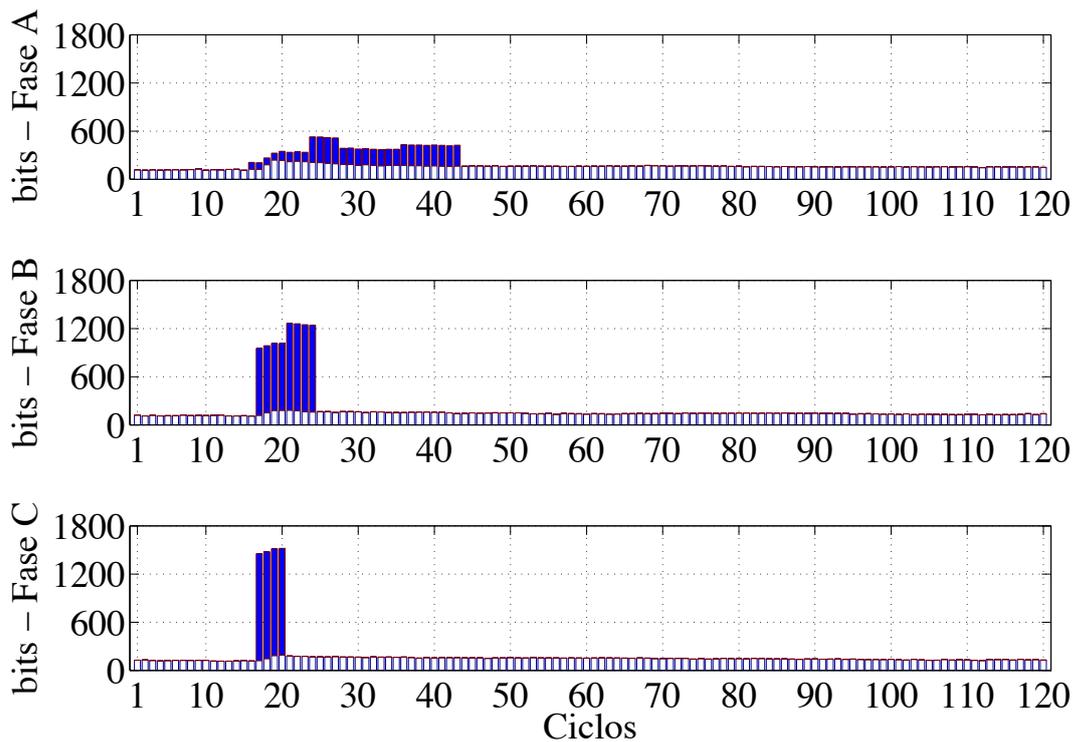


Figura 4.31: Quantidade de bits para compressão por período da frequência fundamental para o Evento 21867 ( $Q_{FFT_{max}}=16$  e  $Q_{TDW_{max}}=8$ ). Fundamental e Harmônicas (Barras Brancas). Distúrbio (Barras Azuis).

#### 4.7 COMPARAÇÃO DE DESEMPENHO DOS ALGORITMOS

Nas seções 4.4, 4.5 e 4.6 foram descritos os três algoritmos de compressão desenvolvidos durante a pesquisa. Os resultados de cada um dos algoritmos são também apresentados de forma independente, destacando as características específicas que fazem com que cada abordagem do problema da compressão de dados seja um caso particular. Nesta seção, é feita uma análise comparativa com as curvas que medem o desempenho dos algoritmos de compressão segundo duas métricas: o ganho de compressão e a relação sinal ruído.

Os dois sinais de distúrbio utilizados para os testes (figuras 4.1 e 4.2) foram submetidos a 5 técnicas de compressão, listadas a seguir: Codificação por transformadas com limiarização no espaço transformado (CTLC) Wikinson & Cox (1996), Nascimento (1997), Santoso *et al.* (1997), Hsieh *et al.* (1998), Littler & Morrow (1999), Hamid & Kawasaki (2002), Panda *et al.* (2002), Dash *et al.* (2003), Meher *et al.* (2004), Gerek & Ece (2004), Gerek & Ece (2007), Ning *et al.* (2011), Codificação por transformadas com aplicação direta da codificação de entropia no espaço transformado (CTEC) Hsieh & Huang (2003), Huang & Jou (2004), Lorio & Magnago (2004), Codificação por Transformadas com Alocação Dinâmica e Inteligente de Bits no Espaço Transformado (CTIA), Codificação por Transformadas com Curvas de Perfil Espectral para Alocação Dinâmica de Bits no Espaço Transformado (CTCA) e Codificação por Transformadas com Abordagem Dissociativa entre Regime Permanente e Eventos

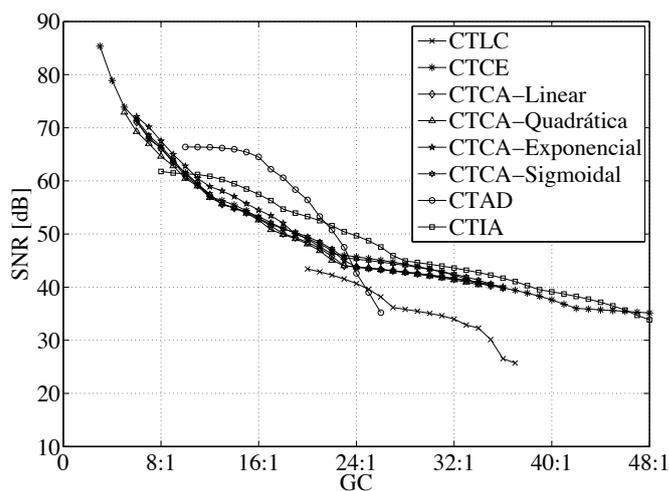
Transitórios (CTAD).

Neste trabalho, os valores de SNR superiores a 40 dB mostrados nas curvas de desempenho, são considerados bons resultados independentemente do ganho de compressão associado. Contudo, o ideal é que o ganho de compressão alcançado pelo algoritmo seja o melhor possível. Com esse nível de resolução, a forma de onda não apresenta distorção visível, em outras palavras, existe um perfeito ajuste na faixa dinâmica como também, se tem uma boa reprodução das pequenas amplitudes e das variações de largura espectrais, mostrando alto grau de fidelidade da representação da forma de onda decodificada quando comparada com a forma de onda original. De forma que, se este sinal fosse usado por um especialista para um diagnóstico baseado em uma inspeção visual, a perda de informação ocasionada pelo processo de compressão não teria impacto na sua decisão.

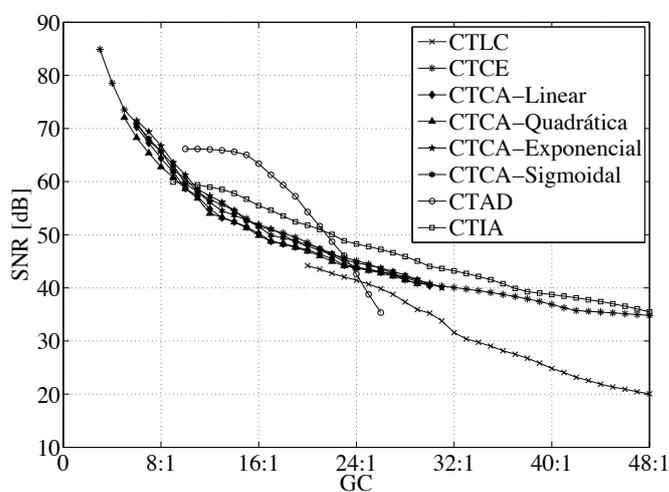
Já nas figuras 4.32(a), 4.32(b), 4.32(c), 4.33(a), 4.33(b) e 4.33(c) são comparados os desempenhos das 5 técnicas de compressão de sinais em termos dos valores de SNR e de GC, para cada uma das fases. Observado as figuras 4.32(a), 4.32(b) e 4.32(c), fica evidente que para baixos ganhos de compressão ( $GC=8:1$ ), as diferentes versões do algoritmo CTAC apresentam os melhores resultados, onde os valores máximos de taxa de bits e fator de compressão alcançados estão na ordem de 2 bits/amostra e 87,5%, respectivamente. Para ganhos de compressão entorno de  $GC=16:1$ , o algoritmo CTAD apresenta resultados superiores aos alcançados pelos outros métodos, atingindo taxas de bits desde 0,75 bits/amostra até 2 bits/amostra. Nestas condições o fator de compressão varia entre 93,75% e 95,83%. No caso de altos ganhos de compressão (valores próximos de  $GC=32:1$ ), o algoritmo que apresenta o melhor desempenho é o CTIA, conseguindo um fator de compressão de até 96,87% para uma taxa de bits de 0,5 bits/amostra.

Comparando as curvas obtidas, nas condições descritas nos parágrafos anteriores pode-se notar que a combinação entre as transformadas ortogonais, a codificação de entropia, e a alocação dinâmica de bits e no domínio da transformada melhora o desempenho do CTLC e do CTCE. Isto é um resultado muito interessante, pois demonstra que as estratégias propostas em cada caso são efetivas não apenas no contexto da alocação de bits, mas também quando usado com outras técnicas.

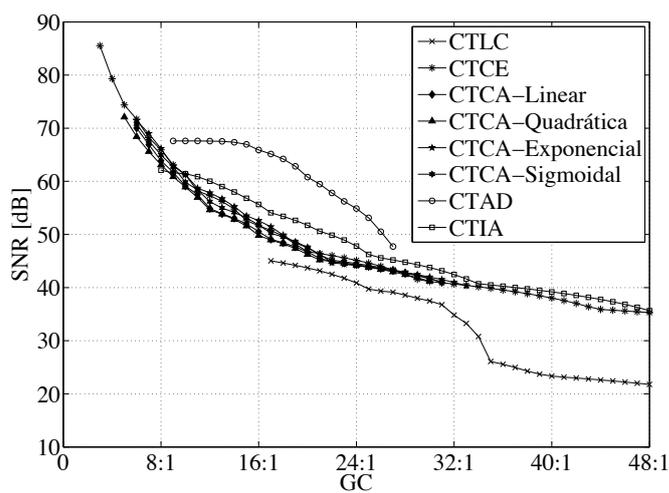
Em geral, as curvas das figuras 4.33(a), 4.33(b) e 4.33(c) mostram resultados similares aos ilustrados nas as figuras 4.32(a), 4.32(b) e 4.32(c), quando se compara o desempenho das cinco técnicas de compressão. Contudo, pode ser verificado que no distúrbio de corrente existe um número significativo de componentes harmônicas, o que favorece diretamente o desempenho do algoritmo CTAD pelo fato de ter uma arquitetura focada em sinais com alta distorção harmônica.



(a) SNR vs. GC do sinal da fase A

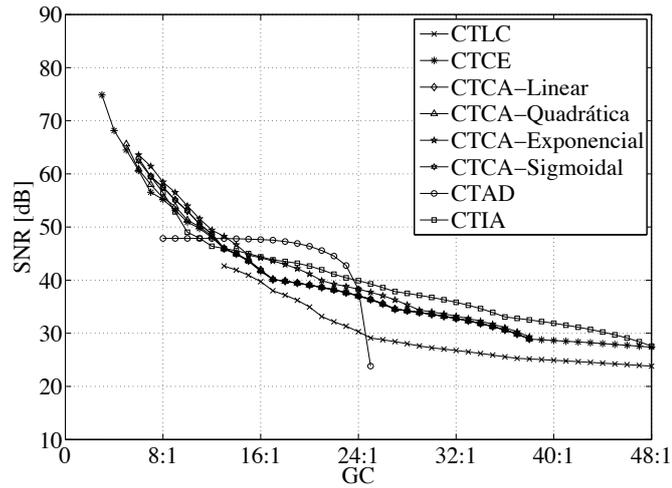


(b) SNR vs. GC do sinal da fase B

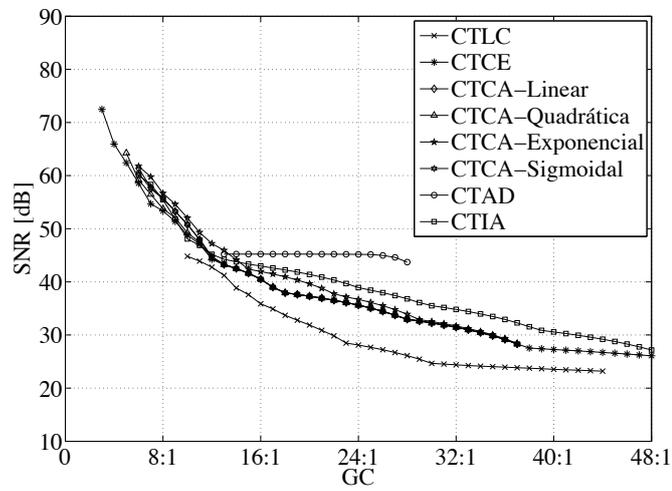


(c) SNR vs. GC do sinal da fase C

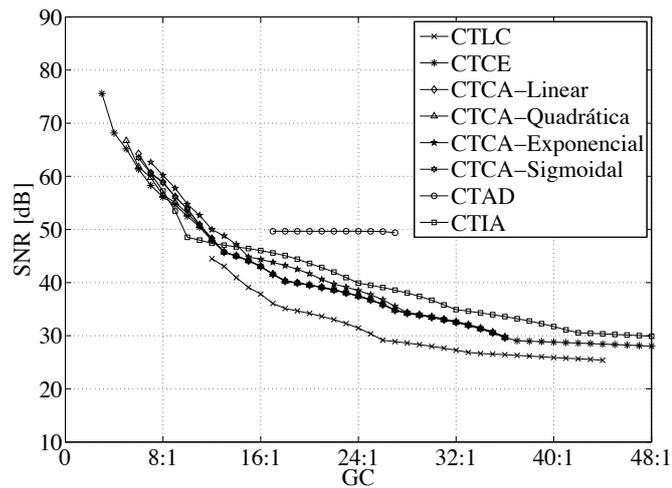
Figura 4.32: Resultados da análise comparativa das técnicas de compressão (Evento 21839).



(a) SNR vs. GC do sinal da fase A



(b) SNR vs. GC do sinal da fase B



(c) SNR vs. GC do sinal da fase C

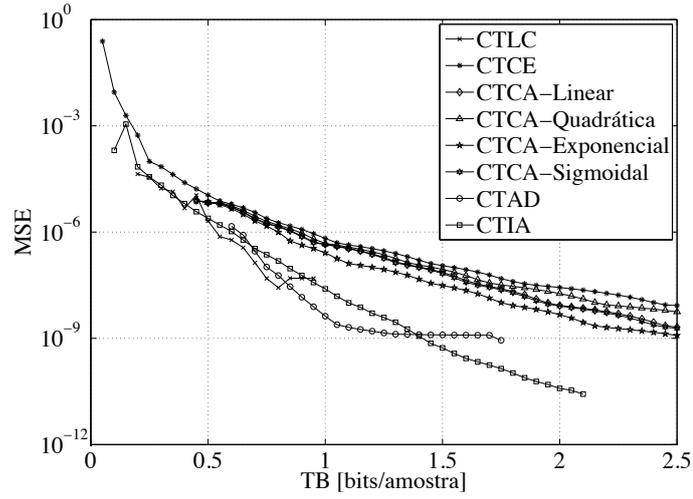
Figura 4.33: Resultados da análise comparativa das técnicas de compressão (Evento 21867).

A seguir são mostrados os resultados da avaliação do efeito da compressão no cálculo dos parâmetros de QEE. Para isso, é calculado o MSE de acordo com a expressão (4.6). As figuras 4.34(a), 4.34(b), 4.34(c), 4.35(a), 4.35(b) e 4.35(c), apresentam o comportamento do MSE em função da taxa de bits para os quatro parâmetros de QEE. Os resultados incluem uma curva com a média do erro dos parâmetros RMS, DHT, e FCR.

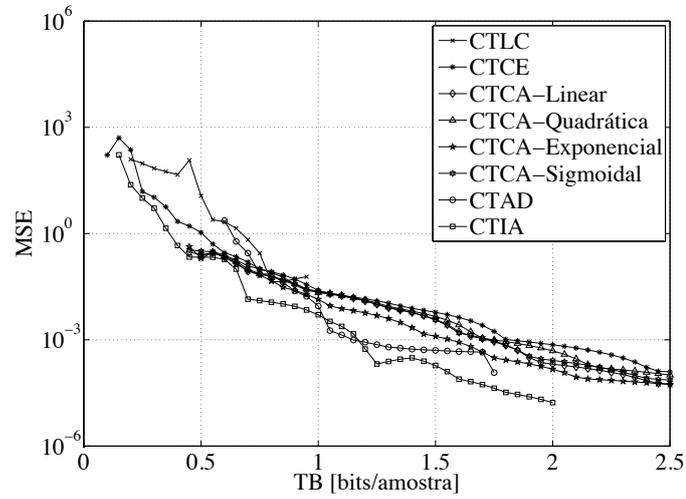
O MSE demonstra que os parâmetros de QEE calculados a partir dos sinais reconstruídos exibem valores muito próximos aos calculados a partir dos sinais originais, quando o algoritmo de compressão age dentro da faixa útil de operação ( $MSE < 10^{-3}$  e  $0 < TB < 2$ ) definida neste trabalho. Na avaliação geral dos resultados, nota-se que o valor do MSE admissível no cálculo dos parâmetros de QEE pode indicar o valor do fator de compressão ou a taxa de bits que permita selecionar o máximo comprimento da palavra que poderia ser usado na execução da técnica na condição de operação requerida.

Para os dois conjuntos de sinais de teste usado neste trabalho, uma relação de compressão no intervalo ( $16 \leq GC < 32$ ) é mais do que suficiente para satisfazer os critérios de relação sinal-ruído ( $SNR > 40$  dB) e se-obter um erro tolerável ( $MSE < 10^{-3}$ ) no cálculo dos parâmetros de QEE. O anterior indica que a técnica de compressão exposta aqui é capaz de prover alta relação de compressão com considerável confiabilidade e robustez, sem comprometer o processo de análise da informação.

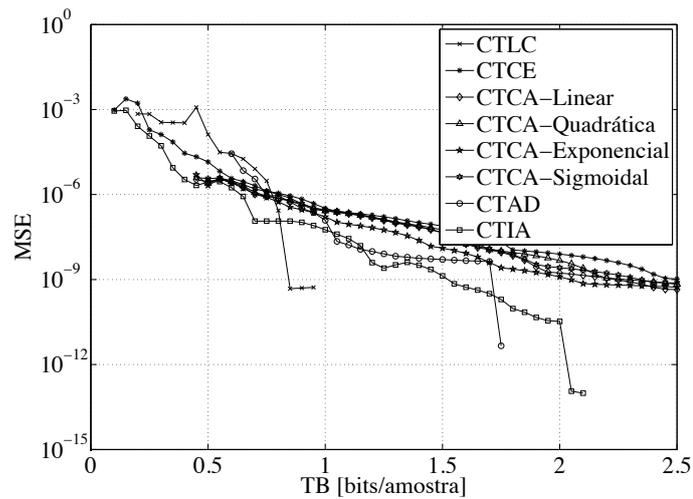
Vale ressaltar, que não foi possível reproduzir os resultados dos algoritmos publicados nos artigos consultados durante a revisão do estado da arte, por não disponibilizar as informações necessárias para sua programação, adicionalmente, tais algoritmos foram testados em conjuntos de diferentes dos sinais utilizados nesta tese, portanto, a comparação com os algoritmos propostos aqui não seria apropriada.



(a) MSE vs. TB para o RMS

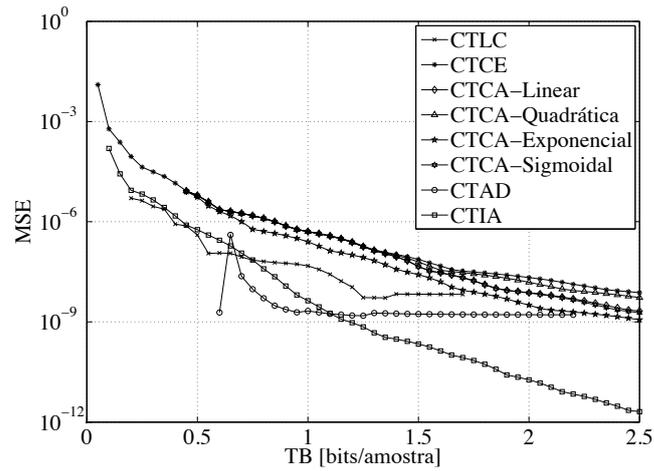


(b) MSE vs. TB para o DHT

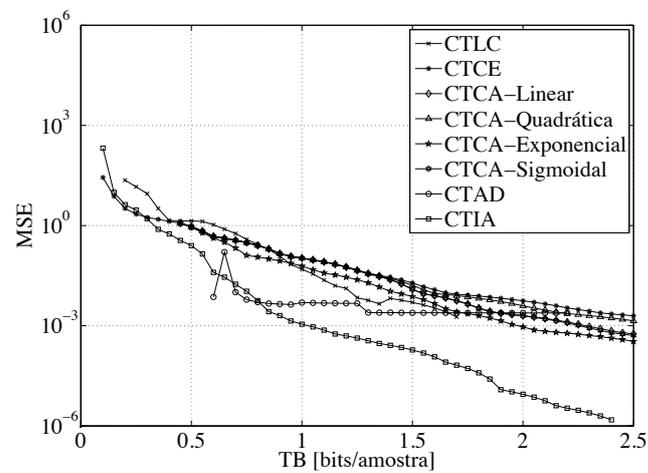


(c) MSE vs. TB para o FCR

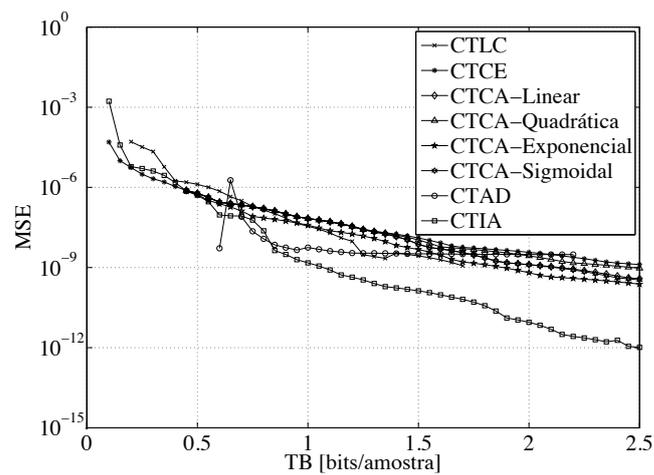
Figura 4.34: Resultados da análise comparativa das técnicas de compressão (Evento 21839).



(a) MSE vs. TB para o RMS



(b) MSE vs. TB para o DHT



(c) MSE vs. TB para o FCR

Figura 4.35: Resultados da análise comparativa das técnicas de compressão (Evento 21867).

## 4.8 CONSIDERAÇÕES FINAIS

Este capítulo discutiu três técnicas de compressão de dados para sinais de distúrbios em sistemas elétricos de potência, chamadas de CTIA, CTCA e CTAD. Inicialmente, efetuou-se a definição das métricas objetivas para avaliação de desempenho do algoritmo de compressão. Seguidamente, foram realizadas as descrições de cada algoritmo, ressaltando como suporte fundamental as estratégias híbridas que combinam transformada ortogonal, alocação de bits e codificação de entropia. Também foram apresentados os resultados particulares que evidenciam as características operacionais de cada abordagem, além dos principais resultados das análises comparativas obtidas a partir de testes executados com sinais reais. Os algoritmos de decodificação e outros processos relacionados com a execução dos algoritmos são também incluídos no capítulo.

De modo geral, pode-se dizer que para os sinais utilizados nos testes, o desempenho de cada algoritmo está relacionado com a faixa de operação em termos da relação sinal ruído e do ganho de compressão. Isto acontece porque em cada abordagem o ajuste na faixa dinâmica e a adaptação às variações de largura espectrais são feitas de forma diferente.

No caso do algoritmo CTCA, observa-se que as curvas de perfil espectral executam a adaptação do comprimento de palavra com base em uma regra prefixada, a qual define que a primeira e a última subbanda usam o máximo e o mínimo comprimento da palavra disponível, respectivamente. Os tamanhos dos comprimentos da palavra nas subbandas intermediárias variam em ordem decrescente. A estratégia baseia-se, na suposição que o espectro apresenta coeficientes organizados de forma decrescente segundo a amplitude, onde os coeficientes com pequenas amplitudes estão geralmente localizados nas altas frequências, enquanto, aqueles de grandes amplitudes ficam posicionados nas baixas frequências.

As características próprias do processo, fazem com que as representações obtidas apresentem boa qualidade na reconstrução e baixo ganho de compressão, causados essencialmente, pela fixação dos comprimentos da palavra e pela alocação desnecessária de bits, devido à que a regra de adaptação do comprimento da palavra não contempla as variações particulares no comportamento do espectro. É interessante notar, que a utilização das curvas apresenta melhores resultados quando os coeficientes possuem pouca variação da faixa dinâmica na transição das altas às baixas frequências.

O algoritmo CTIA apresenta o desempenho mais regular dentre as técnicas de compressão propostas. Neste algoritmo, o processo de adaptação do comprimento da palavra é considerado eficiente pelo fato das redes de Kohonen detectar as alterações dos padrões de distribuição de energia do espectro. Contudo, às vezes o mapeamento das variações abruptas da faixa dinâmica não favorece o compromisso entre a taxa de compressão e a distorção gerada pelo processo, pois também são alocados bits para representar algumas das variações espectrais que não possuem informação relevante, o que faz com que diminua o ganho de compressão sem mudança drástica na qualidade da reconstrução.

A codificação diferenciada das componentes harmônicas é o principal responsável pelo desempenho superior do algoritmo CTAD. Nesta técnica, é aproveitado o fato que a maior parte da informação está contida nas componentes fundamental e harmônicas dos sinais de tensão e de corrente, e que por sua vez, apresentam pouca variação dos seus parâmetros no tempo. Portanto, ganhos consideráveis são observados quando o sinal é constituído de várias componentes harmônicas e as mesmas são previamente calculadas e subtraídas do sinal original.

## Capítulo 5

### Conclusão e Trabalhos futuros

Este capítulo resume as conclusões obtidas como resultado desta pesquisa. As conclusões relevantes são destacadas e discutidas, bem como várias ideias para trabalhos futuros são propostas.

A presente tese propôs o desenvolvimento de três técnicas para a compressão de dados para sinais de distúrbios em sistemas de energia elétrica, cujo padrão principal é a adaptação do comprimento da palavra para quantização no domínio da transformada. Para viabilizar esta ideia, foram projetados algoritmos de codificação com arquiteturas que combinam estrategicamente transformadas ortogonais, com métodos de alocação de bits, e com codificação de entropia. Neste caso, destaca-se que os algoritmos aqui propostos privilegiam a qualidade da reconstrução da forma de onda em detrimento da quantidade de bits por amostra, embora outras aplicações demandem o contrário.

Verifica-se que para o banco de sinais testado, as técnicas de compressão descritas nesta tese possuem desempenho melhor do que os algoritmos baseados na wavelet padrão descritos na literatura (CTLTC e CTCE). Os algoritmos propostos alcançaram ganhos de compressão (GC) na faixa de 8:1 a 32:1 com uma relação sinal ruído (SNR) na faixa de 40 dB a 60 dB e de 40 dB a 50 dB para os sinais de tensão e de corrente, respectivamente. De forma a gerar uma classificação baseada nos resultados de desempenho, observa-se que o algoritmo CTIA apresenta os melhores resultados, enquanto, o algoritmo CTAD mostra resultados ligeiramente inferiores. Apesar que o algoritmo CTCA apresenta resultados inferiores às outras duas propostas, é ainda, muito competitivo em relação aos algoritmos padrão CTLTC e CTCE. Isso acontece por causa da forma em que os bits são alocados durante a quantização, possibilitando ao codificador adaptar-se às variações das características espectrais dos sinais.

Figuras de mérito como o valor eficaz, a distorção harmônica total, e o fator de crista relativo foram calculados a partir dos sinais de tensão e corrente. De forma geral, observa-se uma redução do MSE conforme aumenta a taxa de bits. Constata-se que o parâmetro DHT apresenta maior erro para taxas baixas de bits ( $TB < 1,5$ ), enquanto os que utilizam os parâmetros RMS e o FCR mostram bom desempenho para quaisquer das taxas utilizadas. Com base nos resultados, verificou-se que a distorção harmônica total é o parâmetro determinante da taxa de bits, em bits por amostra, abaixo da qual não se recomenda comprimir formas de

onda de distúrbios.

Para o conjunto de sinais de teste utilizado e considerando  $SNR > 40$  dB e o  $MSE < 10^{-3}$ , podem ser empregadas taxas de 1,5 bits/amostra para os algoritmos CTAD e CTIA, e de 2 bits/amostra para o algoritmo CTCA, sem comprometer o cálculo de qualquer dos parâmetros de QEE analisados. Este fato possibilita recomendar a compressão dos sinais de distúrbios a taxas acima de 1,5 bits/amostra, o que garante a preservação das características comportamentais dos sinais.

Os resultados indicam que as técnicas de compressão propostas aqui são capazes de prover ganhos de compressão a partir de 8:1 com considerável confiabilidade e robustez, sem comprometer o processo de análise das formas de onda comprimidas e evitando erros significativos na quantificação dos parâmetros de QEE.

As sugestões para possíveis desenvolvimentos e futuros temas de pesquisa, resultantes do trabalho desenvolvido, são listadas a seguir:

- Compressão de registros oscilográficos em formato binário que contenham, além das formas de onda, sinais dos canais digitais e medições fasoriais.
- Estudo de técnicas para detecção, identificação e classificação automática de distúrbios com base nas formas de onda compactadas.
- Associação entre a forma de onda do distúrbio e as possíveis causas do evento.
- Aprimorar as investigações sobre algoritmos adaptativos para a alocação de bits, no que diz respeito à técnica que faz abordagem dissociativa entre regime permanente e eventos transitórios.
- Estudo detalhado da melhor base ortogonal para representação de distúrbios na rede elétrica.

## REFERÊNCIAS BIBLIOGRÁFICAS

- AGUNDIS, A. **Diseño y experimentación de un cuantizador vectorial hardware basado en redes neuronales para un sistema de codificación de video**. Tese (Doutorado) — Departamento de Ingeniería Electrónica - Universidad Politécnica de Valencia, 2008.
- ANEEL: Agência nacional de energia elétrica. 2012. Disponível em: <<http://www.aneel.gov.br/>>. Acesso em: 01 ago. 2012.
- ANTON, H. **CALCULUS - A new horizon**. 6th. ed. [S.l.]: John Wiley & Sons, Inc., 1999.
- BARRETO, J. M. **Introdução às Redes Neurais Artificiais**. Florianópolis - SC, Abril 2002.
- BERGER, P. **Otimização de Desempenho de Algoritmos de Compressão de Sinais Biológicos Utilizando Redes Neurais Artificiais**. Tese (Doutorado) — Departamento de Engenharia Elétrica - Universidade de Brasília, 2008.
- BOLLEN, M. **Understanding Power Quality Problems: Voltage Sags and Interruptions**. [S.l.]: Wiley-Interscience, 2000.
- BOLLEN, M.; GU, I. **Signal Processing of Power Quality Disturbances**. [S.l.]: IEEE Press, 2006.
- BOSE, A. Smart transmission grid applications and their supporting infrastructure. **IEEE Transactions on Smart Grid**, v. 1, n. 1, p. 11–19, June 2010.
- BRITO, N.; SOUZA, B.; LEITÃO, J.; CAUPONI, S.; SILVA, S. Rede de oscilografia da chesf: Da concepção até o estado atual. In: **XIII ERIAC - Décimo Tercer Encuentro Regional Iberoamericano de CIGRÉ**. [S.l.: s.n.], 2009.
- CENELEC. **European Standard EN 50160:2010 - Voltage characteristics of electricity supplied by public distribution systems**. 2010. Disponível em: <<http://www.cenelec.eu/>>.
- COSTA, F. **Uma Técnica de Diagnóstico em Tempo Real de Distúrbios Transitórios Baseada na Transformada Wavelet para Uso em Registradores Digitais de Perturbação**. Tese (Doutorado) — Programa de pós-graduação em Engenharia Elétrica - Universidade Federal de Campina Grande, 2010.
- COVER, T. M.; THOMAS, J. A. **Elements of Information Theory**. 2nd. ed. [S.l.]: Wiley, 2006.

- DASH, P. K.; PANIGRAHI, B. K.; SAHOO, D. K.; PANDA, G. Power quality disturbance data compression, detection, and classification using integrated splinewavelet and s-transform. **IEEE Transactions on Power Delivery**, v. 18, n. 2, p. 595–600, November 2003.
- DATA-COMPRESSSION.COM. 2011. Último acesso em 01/07/2011. Disponível em: <<http://www.data-compression.com/vq.shtml/>>.
- DINIZ, P.; SILVA, E. da; NETTO, S. **Processamento Digital de Sinais: Projeto e Análise de Sistemas**. [S.l.]: Bookman, 2004.
- DINIZ, P.; SILVA, E. da; NETTO, S. **Digital Signal Processing: System Analysis and Design**. [S.l.]: Cambridge, 2010.
- DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. [S.l.]: Wiley-Interscience, 2001.
- DUNGAN, R.; MCGRANAGHAN, M.; SANTOSO, S.; BEATY, H. **Electrical Power Systems Quality**. 2nd. ed. [S.l.]: McGraw-Hill, 2002.
- EPRI. **DOE/EPRI National Database Repository of Power System Events**. 2011. Electric Power Research Institute, Inc. Último acesso em 01/07/2011. Disponível em: <<http://expertmonitoring.com/doelibrary/default.asp>>.
- GABOR, D. Theory of communication. **Journal of the institute of Electrical Engineering**, v. 93, n. 26, p. 429–457, 1946.
- GEREK, O.; ECE, D. 2-d analysis and compression of power-quality event data. **IEEE Transactions on Power Delivery**, v. 19, n. 2, p. 791–798, April 2004.
- GEREK, O.; ECE, D. Compression of power quality event data using 2d representation. **Elsevier - Electric Power Systems Research**, v. 78, p. 1047–1052, 2007.
- GERSHO, A.; GRAY, R. M. **Vector Quantization and Signal Compression**. [S.l.]: Kluwer Academic, 1992.
- GINOT, N.; MANNAH, M.; BATARD, C.; MACHMOUM, M. Application of power line communication for data transmission over pwm network. **IEEE Transactions on Smart Grid**, v. 1, n. 2, p. 178–185, September 2010.
- GRZEIDAK, E.; CORMANE, J.; FILHO, A. F.; NASCIMENTO, F. Qualidade da energia elétrica no contexto de smart grid. In: **Conferencia Brasileira sobre Qualidade da Energia Elétrica, 2011. IX CBQEE**. [S.l.: s.n.], 2011.
- HAMID, E.; KAWASAKI, Z. Wavelet-based data compression of power system disturbances using the minimum description length criterion. **IEEE Transactions on Power Delivery**, v. 17, n. 2, p. 460–466, April 2002.

- 
- HAN, J.; KAMBER, M. **Data Mining: Concepts and Techniques**. [S.l.]: Morgan Kaufmann Publishers, 2006.
- HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. [S.l.]: Pearson Prentice Hall, 1999.
- HEBB, D. O. **The Organization of Behavior**. [S.l.]: John Wiley, 1949.
- HEYDT, G. The next generation of power distribution systems. **IEEE Transactions on Smart Grid**, v. 1, n. 3, p. 225–235, December 2010.
- HSIEH, C.; HUANG, S. Disturbance data compression of a power system using the huffman coding approach with wavelet transform enhancement. In: **IEE Proceedings Generation, Transmission & Distribution**. [S.l.: s.n.], 2003.
- HSIEH, C.; HUANG, S.; HUANG, C. Data reduction of power quality disturbances a wavelet transform approach. **Elsevier - Electric Power Systems Research**, v. 47, p. 79–86, 1998.
- HUANG, S.; JOU, M. Application of arithmetic coding for electric power disturbance data compression with wavelet packet enhancement. **IEEE Transactions on Power Systems**, v. 19, n. 3, p. 1334–1341, August 2004.
- IBRAHIM, W.; MORCOS, M. Novel data compression technique for power waveforms using adaptive fuzzy logic. **IEEE Transactions on Power Delivery**, v. 20, n. 3, p. 2136–2143, July 2005.
- IEC 61000-2-5. **International Standard Electromagnetic compatibility (EMC) - Part 2-5: Environment - Description and classification of electromagnetic environments**. October 2008. Disponível em: <<http://www.iec.ch/searchpub/>>.
- IEC 61000-4-30. **International Standard Electromagnetic compatibility (EMC) - Part 4-30: Testing and measurement techniques - Power quality measurement methods**. October 2008. Disponível em: <<http://www.iec.ch/searchpub/>>.
- IEEE STD 1159. **Recommended Practice for Monitoring Electric Power Quality**. June 2009. Disponível em: <<http://standards.ieee.org/>>.
- IEEE STD C37.111. **Standard Common Format for Transient Data Exchange (COMTRADE) for Power Systems**. October 1999. Disponível em: <<http://standards.ieee.org/>>.
- JAYANT, N.; NOLL, P. **Digital Coding of Waveforms**. [S.l.]: Prentice-Hall, 1984.
- KANUNGO, T.; MOUNT, D. M.; NETANYAHU, N. S.; PIATKO, C. D.; SILVERMAN, R.; WU, A. Y. An efficient k-means clustering algorithm: Analysis and implementation.

- IEEE Transaction on Pattern Analysis and Machine Intelligence**, v. 24, n. 7, p. 9881–9892, July 2002.
- KASKI, M.; KANGAS, J.; KOHONEN, T. Bibliography of self-organizing map (som) papers: 1981-1997. **Neural Computing Surveys**, v. 1, p. 102–350, 1998.
- KEZUNOVIC, M. Smart fault location for smart grids. **IEEE Transactions on Smart Grid**, v. 2, n. 1, p. 11–22, March 2010.
- KOHONEN, T. Self-organized formation of topologically correct feature maps. **Biological Cybernetics**, v. 43, p. 59–69, 1982.
- KOHONEN, T. **Self-Organization and Associative Memory**. [S.l.]: Springer-Verlag, 1988.
- KOHONEN, T. The self-organizing map. **Neurocomputing**, v. 21, p. 1–6, May 1998.
- LI, F.; QIAO, W.; SUN, H.; WAN, H.; WANG, J.; XIA, Y.; XU, Z.; ZHANG, P. Smart transmission grid: Vision and framework. **IEEE Transactions on Smart Grid**, v. 1, n. 2, p. 168–177, September 2010.
- LIGHTNER, E.; WIDERGREN, S. An orderly transition to a transformed electricity system. **IEEE Transactions on Smart Grid**, v. 1, n. 1, p. 3–10, June 2010.
- LINDE, Y.; BUZO, A.; GRAY, R. M. An algorithm for vector quantizer design. **IEEE Transaction on Communications**, v. 28, n. 1, p. 84–95, January 1980.
- LITTLER, T.; MORROW, D. Wavelets for the analysis and compression of power system disturbances. **IEEE Transactions on Power Delivery**, v. 14, n. 2, p. 358–364, April 1999.
- LLOYD, S. Least squares quantization in pcm. **Bell Telephone Laboratories Paper**, 1957.
- LLOYD, S. Least squares quantization in pcm. **IEEE Transaction on Information Theory**, v. 28, n. 2, p. 129–137, March 1982.
- LORIO, F.; MAGNAGO, F. Analysis of data compression methods for power quality events. In: **Power Engineering Society General Meeting**. [S.l.: s.n.], 2004.
- MACKAY, D. **Information Theory, Inference, and Learning Algorithms**. 3rd. ed. [S.l.]: Cambridge University Press, 2003.
- MALLAT, S. Multifrequency channel decompositions of images and wavelets models. **IEEE Transactions on Acoustics, Speech and Signal Processing**, v. 37, n. 12, p. 2091–2110, 1989.
- MALLAT, S. **A wavelet tour of signal processing**. 2nd. ed. [S.l.]: Academic Press, 2001.

- 
- MALLAT, S.; ZHANG, Z. Matching pursuits with time-frequency dictionaries. **IEEE Transactions on Signal Processing**, v. 41, n. 12, p. 3397–3415, December 1993.
- MATLAB. **version 7.6.0.324 (R2008a)**. Natick, Massachusetts: The MathWorks Inc., 2008.
- MEHER, S.; PRADHAN, A.; PANDA, G. An integrated data compression scheme for power quality events using spline wavelet and neural network. **Elsevier - Electric Power Systems Research**, v. 69, p. 213–220, 2004.
- MITRA, S. **Digital Signal Processing: A Computer-Based Approach**. [S.l.]: McGraw-Hill, 2001.
- MOLDERINK, A.; BAKKER, V.; BOSMAN, M.; HURINK, J.; SMIT, G. Management and control of domestic smart grid technology. **IEEE Transactions on Smart Grid**, v. 1, n. 2, p. 109–119, September 2010.
- MORETO, M.; ROLIM, J. Análise automática de oscilografias em sistemas elétricos de potência. **Revista SBA: CONTROLE & AUTOMAÇÃO**, v. 21, n. 4, p. 347–362, June 2010.
- MOSLEHI, K.; KUMAR, R. A reliability perspective of the smart grid. **IEEE Transactions on Smart Grid**, v. 1, n. 1, p. 57–64, June 2010.
- NASCIMENTO, F. Data compression algorithm for transient recording system. In: **Proceedings of the IEEE International Symposium on Industrial Electronics, 1997. ISIE'97**. [S.l.: s.n.], 1997.
- NELSON, M.; GAILLY, J. **The Data Compression Book**. 2nd. ed. [S.l.]: M & T Books, 1995.
- NING, J.; WANG, J.; GAO, W.; LIU, C. A wavelet-based data compression technique for smart grid. **IEEE Transactions on Smart Grid**, v. 2, n. 1, p. 212–218, March 2011.
- OJA, M.; KASKI, S.; KOHONEN, T. Bibliography of self-organizing map (som) papers: 1998-2001 addendum. **Neural Computing Surveys**, v. 3, p. 1–156, 2002.
- OLIVEIRA, M. D. **Qualidade da Energia Elétrica: Notas de aula**. Brasília - DF, Agosto 2008.
- OPPENHEIM, A.; SCHAFER, R. **Discrete-Time Signal Processing**. [S.l.]: Prentice-Hall, 1999.
- PAL, N. R.; BEZDEK, J. C.; TSAO, E. C. K. Generalized clustering networks and kohonen's self organizing scheme. **IEEE Transaction on Neural Networks**, v. 4, n. 4, p. 549–557, July 1993.

- PANDA, G.; DASH, P. K.; PRADHAN, A. K.; MEHER, S. K. Data compression of power quality events using the slantlet transform. **IEEE Transactions on Power Delivery**, v. 17, n. 2, p. 662–667, April 2002.
- PENA, D. **Análisis de datos multivariantes**. [S.l.]: McGraw-Hill, 2002.
- PEREIRA, J. S.; CARVALHO, M. B. de; VEGA, A. S. de la. Acelerando a busca pelo elemento ótimo em algoritmos baseados em quantização vetorial. **ENGEVISTA**, v. 11, n. 2, p. 104–108, Dezembro 2009.
- PROAKIS, J.; MANOLAKIS, D. **Digital Signal Processing: Principles, Algorithms, and Applications**. [S.l.]: Prentice Hall, 1996.
- PROCEDIMENTOS DE REDE. **Procedimentos de Rede: Submódulo 2.8 Gerenciamento dos indicadores de desempenho da rede básica e dos barramentos dos transformadores de fronteira, e de seus componentes**. June 2010. Disponível em: <<http://www.ons.org.br/procedimentos/index.aspx>>.
- PRODIST. **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional. Módulo 8 - Qualidade da Energia Elétrica**. January 2011. Disponível em: <<http://www.aneel.gov.br/>>.
- PU, I. **Fundamental Data Compression**. [S.l.]: Elsevier, 2006.
- RAHIMI, F.; IPAKCHI, A. Demand response as a market resource under the smart grid paradigm. **IEEE Transactions on Smart Grid**, v. 1, n. 1, p. 82–88, June 2010.
- RIBEIRO, M. **Técnicas de Processamento de Sinais Aplicadas à Transmissão de Dados Via Rede Elétrica e ao Monitoramento da Qualidade de Energia**. Tese (Doutorado) — Faculdade de Engenharia Elétrica e de Computação - Universidade Estadual de Campinas, 2005.
- RIBEIRO, M.; PARK, S.; ROMANO, J.; MITRA, S. A novel mdl-based compression method for power quality applications. **IEEE Transactions on Power Delivery**, v. 22, n. 1, p. 27–36, January 2007.
- RIBEIRO, M.; ROMANO, J.; DUQUE, C. An improved method for signal processing and compression in power quality evaluation. **IEEE Transactions on Power Delivery**, v. 19, n. 2, p. 464–471, April 2004.
- RUSSELL, B. D.; BENNER, C. Intelligent systems for improved reliability and failure diagnosis in distribution systems. **IEEE Transactions on Smart Grid**, v. 1, n. 1, p. 48–56, June 2010.
- RZESZUTEK, R.; ANDROUTSOS, D.; KYAN, M. Self-organizing maps for topic trend discovery. **IEEE Signal Processing Letters**, v. 17, n. 6, p. 12–31, June 2010.

- 
- SALOMON, D. **Data Compression**. 4th. ed. [S.l.]: Springer, 2006.
- SANTOSO, S.; POWERS, E.; GRADY, W. Power quality disturbance data compression using wavelet transform methods. **IEEE Transactions on Power Delivery**, v. 12, n. 3, p. 1250–1257, July 1997.
- SAYOOD, K. **Introduction to Data Compression**. 3rd. ed. [S.l.]: Morgan Kaufman, 2006.
- SILVA, K.; SOUZA, B.; BRITO, N.; DANTA, K.; COSTA, F.; SILVA, S. Detecção e classificação de faltas a partir da análise de registros oscilográficos via redes neurais artificiais e transformada wavelet. **Revista SBA: CONTROLE & AUTOMAÇÃO**, v. 18, n. 2, p. 163–172, June 2007.
- SOUZA, B.; BRITO, N.; COSTA, F.; LEITÃO, J.; CAUPONI, S.; SILVA, S. da. Evolution of oscillograph - how did chesf transform data into information? **IEEE Latin America Transactions**, v. 8, n. 1, p. 45–50, March 2010.
- SOUZA, L. **Proposição e Avaliação de Algoritmos de Filtragem Adaptativa Baseados na Rede de Kohonen**. 2005.
- SRSM: Supplier requirement for smart metering - smart metering projects map. 2012. Disponível em: <<https://maps.google.com/maps/ms?msid=208141621543957618113-0000011362ac6d7d21187\msa=0>>. Acesso em: 01 ago. 2012.
- TCHEOU, M. **Análise e representação de sinais de oscilografia usando decomposições adaptativas redundantes**. 2005.
- TCHEOU, M. **Compressão de Sinais Usando Decomposições Atômicas com Base em Dicionários Redundantes**. Tese (Doutorado) — Instituto Alberto Luiz Coimbra de Pós-graduação e Pesquisa de Engenharia (COPPE) - Universidade Federal do Rio de Janeiro, 2011.
- TCHEOU, M.; LOVISOLO, L.; RODRIGUES, M.; SILVA, E. da; DINIZ, P.; MANTUANO, S.; RAMOS, M. Rede de oscilografia da chesf: Da concepção até o estado atual. In: **X SEPOPE - Simpósio de especialistas em planejamento da operação e expansão elétrica**. [S.l.: s.n.], 2006.
- TCHEOU, M.; LOVISOLO, L.; SILVA, E. da; RODRIGUES, M.; DINIZ, P. Optimum rate-distortion dictionary selection for compression of atomic decompositions of electric disturbance signals. **IEEE Signal Processing Letters**, v. 14, n. 2, p. 81–84, February 2007.
- TOSIC, I.; FROSSARD, P. Dictionary learning. **IEEE Signal Processing Magazine**, v. 28, n. 2, p. 27–38, March 2011.

- VAIDYANATHAN, P. Multirate digital filters, filter banks, polyphase networks, and applications: A tutorial. **Proceedings of the IEE**, v. 78, n. 1, p. 56–93, January 1990.
- VAIDYANATHAN, P. **Multirate Systems and Filter Banks**. [S.l.]: Prentice Hall, 1993.
- VANHULLE, M. M. **Faithful Representation and Topographic Maps: From Distortion to Information-Based Self-Organization**. [S.l.]: John Wiley, 2000.
- VETTERLI, M.; HERLEY, C. Wavelets and filter banks: theory and desing. **IEEE Trnasactions on Signal Processing**, v. 40, n. 9, p. 2207–2232, January 1992.
- VETTERLI, M.; KOVACEVIC, J. **Wavelets and Subband Coding**. [S.l.]: Prentice-Hall, 1995.
- VIDAL, R. Subspace clustering. **IEEE Signal Processing Magazine**, v. 28, n. 2, p. 52–68, March 2011.
- VIOLATO, R. **Estudo de Algoritmos de Quantização Vetorial Aplicados a Sinais de Fala**. 2010.
- WIEGAND, T.; SCHWARZ, H. **Source Coding: Part I of Fundamentals of Source and Video Coding**. [S.l.]: Foundations and Trends ®in sample, 2011.
- WIKINSON, W.; COX, M. Discrete wavelet analysis of power system transients. **IEEE Transactions on Power Systems**, v. 11, n. 4, p. 2038–2044, November 1996.
- ZAGHETTO, A. **Compressão de documentos compostos utilizando o H.264/AVC-INTRA**. Tese (Doutorado) — Programa de pós-graduação em Engenharia Elétrica - Universidade de Brasília, 2009.
- ZHANG, M.; LI, K.; HU, Y. A high efficient compression method for power quality applications. **IEEE Transactions on Instrumentation and Measurement**, v. 6, n. 6, p. 1976–1985, July 2011.
- ZHANG, P.; LI, F.; BHATT, N. Next-generation monitoring, analysis, and control for the future smart control center. **IEEE Transactions on Smart Grid**, v. 1, n. 2, p. 186–192, September 2010.
- ZUCHINI, M. **Aplicações de Mapas Auto-Organizáveis em Mineração de Dados e Recuperação de Informação**. 2003.