

Tese de Doutorado

*“Rede Neuro-Fuzzy-Wavelet para Detecção e
Classificação de Anomalias de Tensão em Sistemas
Elétricos de Potência”*

Fernando Cezar Vieira Malange

Orientador: Prof. Dr. Carlos Roberto Minussi

Ilha Solteira – SP
Abril/2010

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

“Rede Neuro-*Fuzzy-Wavelet* para Detecção e Classificação
de Anomalias de Tensão em
Sistemas Elétricos de Potência”

Fernando Cezar Vieira Malange

Orientador: Prof. Dr. Carlos Roberto Minussi

Tese apresentada à Faculdade de
Engenharia - UNESP – Campus de Ilha
Solteira, para obtenção do título de
Doutor em Engenharia Elétrica.

Área de Conhecimento: Automação.

Elaborada pela Seção Técnica de Aquisição e Tratamento da Informação
Serviço Técnico de Biblioteca e Documentação da UNESP - Ilha Solteira.

M237r Malange, Fernando Cezar Vieira.
Rede Neuro-Fuzzy-Wavelet para detecção e classificação de anomalias de tensão em sistemas elétricos de potência / Fernando Cezar Vieira Malange. Ilha Solteira : [s.n.], 2010
128 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2010

Orientador: Carlos Roberto Minussi

1. Rede neural ARTMAP Fuzzy. 2. Wavelets (Matemática). 3. Energia elétrica – Qualidade. 4. Sistemas elétricos de potência.



UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE ILHA SOLTEIRA
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA





CERTIFICADO DE APROVAÇÃO


TÍTULO: Rede Neuro-Fuzzy-Wavelet para Detecção e Classificação de Anomalias de Tensão em Sistemas Elétricos de Potência


AUTOR: FERNANDO CEZAR VIEIRA MALANGE
ORIENTADOR: Prof. Dr. CARLOS ROBERTO MINUSSI


Aprovado como parte das exigências para obtenção do Título de DOUTOR em ENGENHARIA ELÉTRICA, Área: AUTOMAÇÃO, pela Comissão Examinadora:


Prof. Dr. CARLOS ROBERTO MINUSSI
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Profa. Dra. ANNA DÍVA PLASENCIA LOTUFO
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Profa. Dra. MARA LÚCIA MARTINS LOPES
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. ARLAN LUIZ BETTIOL
Faculdade SATC - Curso de Engenharia Elétrica - Criciúma/SC


Prof. Dr. EDMARCIO ANTONIO BELATI
Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas / Universidade Federal do ABC - Santo André/SP

Data da realização: 26 de abril de 2010.

Ao meu avô “vô Chico”,
pelo grande homem que foi,
e à minha mãe Nair,
pela grande mulher que é.

Agradecimentos

Gostaria de agradecer a todos aqueles que de alguma maneira me apoiaram e me incentivaram no transcorrer deste trabalho. Inicialmente, agradeço à minha esposa Denizi, por seu amor, por seu apoio e, principalmente, pela sua presença em minha vida. Aos meus filhos Kauê e Tayná pelo orgulho que me proporcionam. À minha mãe, Nair, meus irmãos, Caio, Cristina e Meire, que sempre estiveram presentes nessa caminhada. Ao Prof. Dr. Carlos Roberto Minussi, meu orientador, pelo empenho e dedicação na orientação deste trabalho, sempre disposto a discutir e conversar, incentivando a alcançar o objetivo que traçamos juntos, mais do que um orientador um amigo e parceiro durante todo o processo de titulação, meus profundos e sinceros agradecimentos. À UNESP e ao Departamento de Engenharia Elétrica; em especial, a todos os professores que fizeram parte do meu crescimento profissional em especial as Prof^a Anna Diva e Prof^a Mara Lúcia pelas contribuições nesse trabalho; aos funcionários do laboratório Beto e Deoclécio, pela assistência e a todos colegas do departamento que por vezes nos ajudam mesmo que indiretamente. Ao CNPq pelo apoio financeiro através da bolsa de estudos.

Resumo

Muitos esforços têm sido despendidos para tentar sanar problemas relacionados com Qualidade da Energia Elétrica (QEE), principalmente na automação de processos e desenvolvimento de equipamentos de monitorização que possibilitem maior desempenho e confiabilidade a todo o Sistema Elétrico. Esta pesquisa apresenta um sistema eficiente de identificador/classificador automático de distúrbios chamado de Rede Neuro-*Fuzzy-Wavelet*. A estrutura básica dessa rede é composta por três módulos: o módulo de detecção de anomalias onde os sinais com distúrbios são identificados, o módulo de extração de características onde as formas de onda com distúrbio são analisadas, e o módulo de classificação que conta com uma rede neural ARTMAP *Fuzzy*, a qual indica qual o tipo de distúrbio sofrido pelo sinal. Os tipos de distúrbios incluem os isolados de curto prazo, tais como: afundamento de tensão (*sag*), elevação de tensão (*swell*), os distúrbios de longo prazo como distorção harmônica, bem como distúrbios múltiplos simultâneos como afundamento de tensão com distorção harmônica e elevação de tensão com distorção harmônica. A concepção do sistema de inferência (neural *wavelet* ARTMAP *fuzzy*) permite realizar a classificação dos referidos distúrbios de forma robusta e com grande rapidez na obtenção das soluções. Testes apontam para o alto desempenho dessa rede na detecção e classificação correta dos tipos de distúrbios de tensão analisados, 100% de acerto. A forma robusta e grande rapidez na obtenção dos resultados, possibilita sua aplicação em tempo real, visto que o esforço computacional, muito pequeno, é alocado, basicamente, na fase de treinamento. Somente uma pequena parcela de tempo computacional é necessária para a efetivação das análises. Além do mais, a metodologia proposta pode ser estendida para a realização de tarefas mais complexas como, por exemplo, a localização das fontes geradoras do distúrbio de tensão. Trata-se de uma importante contribuição na área de qualidade de energia, principalmente por ser uma atividade efetivamente carente de soluções na literatura especializada.

Palavras-chave: Rede Neural ARTMAP *Fuzzy*, *Wavelets*, Detecção e Classificação de Distúrbios de Tensão, Sistemas Elétricos de Potência.

Abstract

Many efforts have been spent to solve problems related to Power Quality (PQ), principally in process automation and developing monitoring equipments that can provide more reliability and behavior for the electrical system. This research presents an efficient automatic system to identify/classify disturbs by Fuzzy Wavelet Neural Network. The basic structure of this neural network is composed of three modules such as: module for detecting anomalies where the signals with disturbs are identified, module for extracting the characteristics where the wave forms with disturbs are analyzed, and the module of classification that contains a fuzzy ARTMAP neural network that shows the type of disturbs existing in the signal. The types of disturbs include the short term isolated ones which are: voltage dip (sag), voltage increasing (swell); the long term disturbs such as harmonic distortion as well as the multiple simultaneous ones like the voltage dip with harmonic distortion and voltage increasing with harmonic distortion. The inference system (neural wavelet ARTMAP fuzzy) allows executing the classification of the cited disturbs very fast and obtaining reliable results. This neural network provides high performance when classifying and detecting the voltage disturbs very fast with about 100% of accuracy. The speed in obtaining the results allows an application in real time due to a low computational effort, which is basically in the training phase of the neural network. A little time of the computational effort is spent for the analysis. Moreover the proposed methodology can be used for realizing more complex tasks, as for example the localization of the power sources of the voltage disturbs. It is a very important contribution in the power quality, mainly to be a needy activity for solutions on the specialized literature.

Keywords: ARTMAP-Fuzzy Neural Network, Wavelet, Voltage Disturbance Detection and Classification, Electrical Power Systems.

Lista de Figuras

<i>Figura 3.2.2. - Transitório proveniente do chaveamento de um banco de capacitores.</i>	<i>23</i>
<i>Figura 3.3.1. - Interrupção momentânea devido a um curto-circuito.....</i>	<i>26</i>
<i>Figura 3.3.2.1. - Forma de onda característica de afundamento de tensão. ...</i>	<i>27</i>
<i>Figura 3.3.2.2 - Afundamento de tensão ocorrido pela partida de um motor..</i>	<i>28</i>
<i>Figura 3.3.2.3. - Tolerâncias típicas de tensão para computadores (curva CBEMA).</i>	<i>29</i>
<i>Figura 3.3.2.4. - Curva ITIC - Tolerâncias típicas de tensão para equipamentos de tecnologia da informação.....</i>	<i>30</i>
<i>Figura 3.3.3. - Elevação de tensão devido a uma falta fase-terra.</i>	<i>32</i>
<i>Figura 3.5.2. - Vida útil de um transformador em função da distorção harmônica de corrente.</i>	<i>41</i>
<i>Figura 3.5.2.1. - Forma de onda de distorções harmônicas de 3ª e 5ª ordem.</i>	<i>41</i>
<i>Figura 3.5.2.2. - (a) Formas de ondas senoidal e componente harmônico. (b) Forma de onda da soma das ondas senoidal e componente harmônico.</i>	<i>42</i>
<i>Figura 3.5.2.3. - Diminuição da vida útil de capacitores sobre o efeito de distorção harmônica.</i>	<i>44</i>
<i>Figura 3.5.3. - Forma de onda com distorções inter-harmônicas.</i>	<i>46</i>
<i>Figura 3.5.4. - Típica forma de onda com distorção notching.....</i>	<i>47</i>
<i>Figura 3.5.5. - Forma de onda de tensão alternada senoidal com presença de ruído.</i>	<i>48</i>
<i>Figura 3.6. - Forma de onda com a presença de flutuação de tensão.</i>	<i>51</i>
<i>Figura 4.2.2. - Funções de pertinência nebulosa.</i>	<i>57</i>
<i>Figura 4.3. - Etapas de um sistema nebuloso.</i>	<i>58</i>
<i>Figura 5.1. - Algumas das principais redes neurais da família ART disponíveis na literatura especializada.....</i>	<i>62</i>
<i>Figura 5.1.2. - Arquitetura básica de uma rede ART.</i>	<i>64</i>
<i>Figura 5.2.1. - Arquitetura de uma rede ART1.....</i>	<i>67</i>
<i>Figura 5.3.1. - Arquitetura básica de uma rede ARTMAP.</i>	<i>72</i>
<i>Figura 5.3.2. - Rede ARTMAP Nebulosa.....</i>	<i>74</i>

<i>Figura 6.3.1. - Processo de filtragem de um sinal S.....</i>	<i>80</i>
<i>Figura 6.3.2. - Processo de diminuição do número de amostras do sinal.</i>	<i>81</i>
<i>Figura 6.4. - Técnica de decomposição da Análise Multirresolução.....</i>	<i>82</i>
<i>Figura 6.5.1. - Função wavelet de Haar.....</i>	<i>83</i>
<i>Figura 6.5.2. - Função wavelet de Daubechies.</i>	<i>84</i>
<i>Figura 6.5.3. - Função wavelet de Morlet.</i>	<i>85</i>
<i>Figura 6.5.4. - Função wavelet chapéu mexicano.....</i>	<i>85</i>
<i>Figura 6.5.5. - Função wavelet de Meyer.....</i>	<i>86</i>
<i>Figura 8.2. - Estrutura básica da Rede Neuro-Fuzzy-Wavelet.</i>	<i>92</i>
<i>Figura 8.2.1. - Forma de onda senoidal de tensão discretizada, considerando-se uma taxa de amostragem.....</i>	<i>93</i>
<i>Figura 8.3.1. - Arquitetura da rede ARTMAP Fuzzy que realiza a classificação dos sinais com distúrbios.</i>	<i>100</i>
<i>Figura 9.2.1. - Gráfico dos valores da WEN dos coeficientes de um sinal puro (sem distúrbio).....</i>	<i>111</i>
<i>Figura 9.2.2. - Gráfico dos valores da WEN dos coeficientes de um sinal com afundamento de tensão.....</i>	<i>111</i>
<i>Figura 9.2.3. - Gráfico dos valores da WEN dos coeficientes de um sinal com elevação de tensão.</i>	<i>111</i>
<i>Figura 9.2.4. - Gráfico dos valores da WEN dos coeficientes de um sinal com interrupção momentânea.</i>	<i>112</i>
<i>Figura 9.2.5. - Gráfico dos valores da WEN dos coeficientes de um sinal com distorção harmônica.</i>	<i>112</i>
<i>Figura 9.2.6. - Gráfico dos valores da WEN dos coeficientes de um sinal com distorção harmônica e afundamento de tensão</i>	<i>112</i>
<i>Figura 9.2.7. - Gráfico dos valores da WEN dos coeficientes de um sinal com distorção harmônica e elevação de tensão.....</i>	<i>113</i>

Lista de Tabelas

<i>Tabela 3.2.2 - Classificação dos fenômenos transitórios.</i>	24
<i>Tabela 3.3.3. - Classificação de VTCD's conforme o tempo de duração.</i>	34
<i>Tabela 3.4.3.1. - Classificação de VTLD's conforme o tempo de duração.</i>	38
<i>Tabela 3.4.3.2 - Classificação da Tensão de Atendimento.</i>	39
<i>Tabela 3.5.5. - Classificação de Distorção da Forma de Onda.</i>	49
<i>Tabela 3.6. - Classificação de Flutuação de Tensão.</i>	52
<i>Tabela 3.7. - Resumo dos tipos de distúrbios.</i>	52
<i>Tabela 8.3. - Vetores de saída (binários) correspondentes às classes de sinais com distúrbio.</i>	102
<i>Tabela 9.1. - Modelos de distúrbios de tensão.</i>	105
<i>Tabela 9.2.1. - Exemplo de valores normalizados e codificados de sinais com distúrbios.</i>	110
<i>Tabela 9.2.2. - Exemplo de valores de sinais com distúrbios subtraídos dos valores do sinal puro.</i>	110
<i>Tabela 9.2.3. - Exemplo de valores de coeficientes com representação de valor positivo ou negativo.</i>	113
<i>Tabela 9.2.4. - Exemplo de vetores de entrada representando os sinais com distúrbios que foram detectados.</i>	114
<i>Tabela 9.2.5. - Exemplo de alguns vetores da matriz W_a (padrões de entrada) que representam os sinais com distúrbios.</i>	114
<i>Tabela 9.2.6. - Exemplo de alguns valores da matriz W_b (padrões de saída) que representam os tipos de distúrbios.</i>	114
<i>Tabela 9.2.7. - Exemplo de alguns valores da matriz W_{ab} que representam o neurônio vencedor da ressonância adaptativa.</i>	115
<i>Tabela 9.2.8. - Exemplo do relatório com o resultado da classificação de distúrbio.</i>	115

Tabela 9.2.9. - Resultados da simulação. 116

SUMÁRIO

1. INTRODUÇÃO	10
1.1. <i>Objetivo do trabalho</i>	13
1.2. <i>Contribuição do trabalho</i>	13
1.3. <i>Organização do trabalho</i>	14
2. ESTADO DA ARTE	15
2.1. <i>Introdução</i>	15
2.2. <i>Definição do Problema</i>	15
2.3. <i>Análise das Principais Referências Bibliográficas</i>	17
3. QUALIDADE DE ENERGIA ELÉTRICA	20
3.1. <i>Introdução</i>	20
3.2. <i>Fenômenos Elétricos Transitórios</i>	21
3.2.1. <i>Transitórios Impulsivos</i>	21
3.2.2. <i>Transitórios Oscilatórios</i>	23
3.3. <i>Variações de Tensão de Curta Duração</i>	24
3.3.1. <i>Interrupção de Curta Duração</i>	25
3.3.2. <i>Afundamento de Tensão de Curta Duração</i>	26
3.3.3. <i>Elevação de Tensão de Curta Duração</i>	32
3.4. <i>Variações de Tensão de Longa Duração</i>	34
3.4.1. <i>Interrupções Sustentadas</i>	35
3.4.2. <i>Afundamentos de Tensão Sustentados</i>	36
3.4.3. <i>Elevações de Tensão Sustentadas</i>	37
3.5. <i>Distorções da Forma de Onda</i>	39
3.5.1. <i>Distorção do Nível de Corrente Contínua (CC)</i>	40
3.5.2. <i>Distorção Harmônica</i>	40
3.5.3. <i>Distorção Inter-harmônica</i>	45
3.5.4. <i>Notching</i>	46

3.5.5. Ruídos Elétricos	48
3.6. FLUTUAÇÕES OU OSCILAÇÕES DE TENSÃO	49
3.7. RESUMO DOS TIPOS DE DISTÚRBIOS	52
4. LÓGICA FUZZY	55
4.1. Introdução	55
4.2. Conjuntos Nebulosos e Operadores Lógicos	56
4.3. Sistemas Nebulosos	58
5. REDES NEURAIAS ARTIFICIAIS	59
5.1. Introdução	59
5.2. Rede Neural Artificial	59
5.1. Redes ART	61
5.1.1 - Principais Características e Fundamentos	62
5.1.2 - Estrutura da Rede Neural ART	63
5.2 - Rede Neural ART1, ART2 e ART Fuzzy	66
5.2.1 - Rede Neural ART1	66
5.2.2 - Rede Neural ART2	69
5.2.3 - Rede Neural ART Fuzzy	70
5.3 - Rede Neural ARTMAP e ARTMAP Fuzzy	72
5.3.1 - Rede Neural ARTMAP	72
5.3.2 - Rede ARTMAP Fuzzy	74
6. TRANSFORMADA WAVELET	77
6.1. Introdução	77
6.2. Wavelet	77
6.2.1. Transformada Wavelet	78
6.3. Transformada Wavelet Discreta	80
6.4. Análise Multirresolução	82
6.5. Famílias Wavelets	83

7. NORMA ENTROPIA WAVELET	88
7.1. <i>Introdução</i>	88
7.2. <i>Norma Entropia Wavelet – WEN</i>	89
8. REDE NEURO-FUZZY-WAVELET	91
8.1. <i>Introdução</i>	91
8.2. <i>Sistema Proposto</i>	91
8.2.1. <i>Módulo de Detecção</i>	93
8.2.2. <i>Módulo de Extração de Características</i>	95
8.2.3. <i>Módulo de Classificação</i>	97
8.3. <i>Estímulos de Entrada-Saída da Rede Neural ARTMAP Fuzzy</i>	100
9. APLICAÇÃO	104
9.1. <i>Fase de Treinamento</i>	104
9.2. <i>Simulação e Resultados</i>	109
10. CONCLUSÕES E SUGESTÃO PARA TRABALHOS FUTUROS	118
10.1. <i>Conclusões</i>	118
10.2. <i>Sugestão para Trabalhos Futuros</i>	119
11. REFERÊNCIAS	Erro! Indicador não definido.
Apêndice A - Fluxograma de Aprendizagem da Rede ARTMAP Fuzzy	126
Apêndice B - Artigos Publicados e Submetido Relacionados com a Pesquisa de Doutorado	128

CAPÍTULO 1

INTRODUÇÃO

O conceito de Qualidade da Energia Elétrica (QEE) (BOLLEN, 2000) vem sofrendo alterações em consequência do constate avanço tecnológico. Há alguns anos, a principal preocupação com a QEE concentrava-se na qualidade de serviço, ou seja, na duração e no número de interrupções da tensão. Atualmente, parâmetros como a amplitude e frequência da tensão, desequilíbrio de tensão e distorção harmônica assumem elevada importância no contexto da QEE (ALLEN, et al., 2005). São fenômenos que, embora sempre tenham existido, têm despertado particular interesse. A baixa qualidade da energia elétrica é causada normalmente por distúrbios como interrupção momentânea, distorção harmônica, afundamento e elevação de tensão dentre outros, que conseqüentemente podem causar danos e/ou falhas em equipamentos.

De maneira geral, os distúrbios de qualidade de energia se manifestam como deformidades nas formas de onda da tensão. Estas deformidades, frequentemente referidas como problemas de QEE, afetam significativamente indústrias, comércio e usuários domésticos em diversos aspectos.

Uma abordagem possível para amenizar esse problema é a incorporação de métodos e equipamentos capazes de monitorar e reconhecer tais distúrbios.

A detecção e a classificação são temas importantes para o desenvolvimento da próxima geração de equipamentos de monitorização de QEE. Basicamente, deve-se usar técnicas de processamento de sinais para extrair características específicas dos sinais elétricos, seguidos pelo emprego de uma técnica para classificar os distúrbios detectados.

Contudo estas técnicas devem preservar aspectos como o baixo esforço computacional e eficiência de classificação para ser considerado adequado para implementação em sistemas de classificação de distúrbios em tempo real.

Diversas são as metodologias aplicadas para resolução desse problema como serão mencionadas, a seguir, no capítulo 2. A princípio, a mais adequada solução encontrada na literatura especializada foi a proposta por Uyar (UYAR et al., 2008) que combina a Transformada *Wavelet* Discreta – TWD (*DWT – Discrete Wavelet Transform*) (GRAPS, 1995) na fase de extração de características com a rapidez e confiabilidade de uma Rede Neural Artificial (RNA) (HAYKIN, 1994) para classificação dos distúrbios.

As RNA's são concepções em *hardware* e/ou *software* que possuem mecanismos de funcionamento similar ao cérebro humano. Essas redes possuem capacidade de aprendizado e podem realizar generalizações, de acordo com o conhecimento acumulado e, por isso, são usadas em reconhecimento de padrões.

A partir do modelo de um neurônio artificial proposto por McCulloch e Pitts (McCULLOCH; PITTS, 1943), foram desenvolvidas várias concepções de RNA, porém, com resultados pouco significativos. Contudo, após os anos 70, principalmente com o advento da rede de Hopfield (WERBOS, 1974), do algoritmo retropropagação (*backpropagation*) (WASSERMAN, 1989) e, sobretudo, pelo avanço da microeletrônica, a partir dos anos 80, tornou-se possível a idealização dessas estruturas de rede em *hardware* de modo eficiente.

A metodologia empregada por Uyar (2008) enfrenta as deficiências inerentes à utilização da RNA *Multi Layer Perceptron* (MLP) com treinamento baseado no algoritmo retropropagação (*backpropagation*). A MLP é uma rede neural artificial compostas por várias camadas de neurônios dispostos em paralelo e funções de ativação contínuas. Já o algoritmo retropropagação tem por finalidade o aprendizado supervisionado (regra baseada no binômio estímulo de entrada-saída) da RNA, assim, pode-se executar tarefas como reconhecimento de padrões, diagnósticos complexos, previsão, etc.

Esta estrutura é considerada, dentro da literatura especializada, um *benchmark* em termos de precisão, sendo que o treinamento da rede não possui um algoritmo flexível. Logo, apesar deste algoritmo fornecer bons resultados, não existe a possibilidade de melhorar em demasia seu funcionamento, pois o algoritmo retropropagação possui convergência geralmente lenta, sendo que em alguns casos é não-convergente, existe o problema dos

mínimos locais, contando, ainda, com um custo computacional relativamente alto observado na fase de treinamento da rede.

Com a evolução das Redes Neurais Artificiais, tal deficiência pode ser suprimida com o uso de uma RNA mais sofisticada como a ARTMAP *Fuzzy* (CARPENTER, et al., 1992). Esta rede faz parte de um conjunto de propostas baseadas na teoria da ressonância adaptativa (*Adaptive Resonance Theory - ART*) (CARPENTER; GROSSBERG, 1987a) destinadas, principalmente, à classificação de padrões binários e/ou analógicos, com treinamento supervisionado ou não-supervisionado.

Logo, a idéia básica é o desenvolvimento de um sistema neural para a detecção e classificação de distúrbios de tensão em um sistema elétrico de potencia, que é um problema que exige precisão e rapidez de resposta. Neste sentido, é proposto um sistema de inferência, uma Rede Neuro-*Fuzzy-Wavelet* (RNF W), composta de uma rede neural ARTMAP *Fuzzy*, que supre totalmente tais requisitos, principalmente com relação à velocidade de resolução.

A fim de tornar o sistema ainda mais completo e eficiente, foi implementado um módulo para a detecção de sinais com distúrbios. Adaptado de um modelo de inferência de corrente (AL-JUFOUT, 2006), nesse módulo é realizado a inferência, de maneira aproximada, da amplitude da tensão da forma de onda, proporcionando a detecção de distúrbios com extrema rapidez e eficiência. Assim, juntamente com a utilização da Transformada *Wavelet* Discreta (TWD) e com a rede ARTMAP *Fuzzy* é, aparentemente, a melhor solução para resolução desse problema.

Nesta tese de doutorado constata-se a eficiência dessa metodologia através do alto índice de acerto na detecção e classificação dos sinais elétricos com distúrbio e propõe-se sua implementação, tendo em vista que é uma arquitetura plástica e de funcionamento com tempo de execução baixíssimo, sendo, portanto, compatível com aplicações *on-line*.

1.1. Objetivo do trabalho

O objetivo deste trabalho é desenvolver um sistema de inferência capaz de realizar automaticamente a detecção de formas de ondas com distúrbios de forma rápida e eficiente, através da análise da amplitude da tensão da forma de onda. Utilizando a Transformada Wavelet Discreta (TWD) na extração de características do sinal com anomalia e, posteriormente, a rede ARTMAP Fuzzy na classificação dos tipos de distúrbios. Com esta estrutura, aplicá-lo à resolução do problema de detecção e classificação de distúrbios de tensão em um sistema elétrico de potencia.

A principal vantagem deste sistema é a redução do tamanho dos dados a serem analisados e a redução do espaço alocado em memória, já que serão analisados apenas os sinais comprovadamente com distúrbios, bem como, o reconhecimento das principais características deste sinal sem perder as características do sinal original. Além do fato da rede apresentar a característica de estabilidade e plasticidade, inerentes às redes neurais da família ART, que propiciam uma rápida solução do referido problema.

1.2. Contribuição do trabalho

A contribuição deste trabalho consiste no desenvolvimento de um sistema de inferência (rede *Neuro-Fuzzy-Wavelet*) capaz de realizar a detecção de formas de ondas de tensão com anomalias e classificá-las automaticamente.

A estrutura desta rede é uma inovação dentre os sistemas de detecção/classificação de distúrbios e apresenta os seguintes atributos:

- O tamanho do banco de dados (quantidade de padrões de treinamento) não acarreta problemas de convergência do treinamento;
- Tempo de treinamento muito reduzido;
- Precisão dos resultados superior às metodologias clássicas disponíveis na literatura;

1.3. Organização do trabalho

Após as considerações iniciais (Introdução), é descrita a seguir, de forma breve, como esse trabalho está organizado.

No capítulo 2 apresenta-se, de maneira um pouco mais detalhada, a definição do problema e a análise das principais propostas na literatura sobre o problema da detecção e classificação de distúrbios de tensão (estado da arte).

No capítulo 3 são abordados conceitos de Qualidade de Energia Elétrica, os principais tipos de distúrbios relacionados com esta pesquisa, suas origens e principais consequências.

No capítulo 4 aborda-se a teoria da Lógica *Fuzzy*.

O capítulo 5 é reservado para a apresentação dos principais conceitos e arquitetura das Redes Neurais Artificiais.

No capítulo 6 discorre-se sobre a teoria da transformada *wavelet*.

No capítulo 7 é apresentado o conceito de norma entropia *wavelet*.

O capítulo 8 mostra a estrutura da Rede *NEURO-FUZZY-WAVELET* e seu funcionamento.

No capítulo 9 é descrito como foi realizado o treinamento da rede e apresentados os testes e os resultados da aplicação.

No capítulo 10 apresentam-se as conclusões sobre a pesquisa e sugestões para trabalhos futuros; e

No capítulo 11 são relacionadas as referências bibliográficas utilizadas.

CAPÍTULO 2

ESTADO DA ARTE

2.1. INTRODUÇÃO

Neste capítulo, apresenta-se o estado da arte em relação ao problema dos distúrbios de qualidade de energia (KUNDUR, 1994) em sistemas elétricos de potência. Neste contexto, são abordadas as publicações sobre métodos de detecção e classificação de distúrbios de tensão, baseadas em várias técnicas usais na literatura especializada. Tratam-se da análise de sensibilidade, autoproblema (análise de autovalor e autovetor), bifurcação, método direto de Lyapunov, bem como métodos em que são usados conceitos da inteligência artificial (redes neurais, lógica *fuzzy*, etc.).

2.2. DEFINIÇÃO DO PROBLEMA

Atualmente, a necessidade de energia elétrica de qualidade para as indústrias, comércio e serviços tem provocado a regulação do conceito de Qualidade de Energia Elétrica. O objetivo é reduzir os danos e a interrupção do fornecimento de energia aos consumidores, dispositivos ou processos. Basicamente, são usados quatro parâmetros para medir e caracterizar a forma de onda da tensão fornecida: frequência, amplitude, simetria e formato da onda. Esses parâmetros podem sofrer alterações que afetam sensivelmente a qualidade de energia.

A origem de tal alteração pode ser a instalação elétrica, agentes externos ou em consequência da operação de cargas específicas (BOLLEN, 2000). Essa alteração da onda senoidal é usualmente transmitida para o sistema elétrico e a responsabilidade de possíveis

danos causados aos consumidores é geralmente proveniente das empresas de distribuição e dos usuários.

O interesse em monitorar o sistema de energia torna-se, assim, muito grande. Após a forma de onda da tensão e/ou da corrente serem lidos e armazenados, faz-se necessária a realização de uma análise de tais grandezas. As fontes e as causas dos distúrbios devem ser conhecidas antes de se tomarem as medidas adequadas. Assim, o registro do monitoramento das formas de onda dos distúrbios (oscilografias) é essencial. Infelizmente, a gravação do monitoramento dos dados cria um volume muito grande de informação a serem analisados devendo-se confiar na inspeção visual.

Reconhecendo esta realidade, muitos pesquisadores têm proposto sistemas automatizados para classificação de distúrbios de qualidade de energia (ver seção 2.3.). Vários dos sistemas propostos utilizam Transformada de *Fourier* (FT – *Fourier Transform*) ou Transformada *Wavelet* (WT – *Wavelet Transform*) para extração de características e Redes Neurais Artificiais (RNA) ou Lógica *Fuzzy* (FL – *Fuzzy Logic*) para classificação. O principal benefício da Lógica *Fuzzy* é que a representação do conhecimento é explícita usando simplesmente a relação “*if-then*”. Contudo, sua utilização é limitada, pois os distúrbios de qualidade de energia, principalmente transitórios, são muito difíceis de serem descritos por conhecimentos artificiais.

Algumas pesquisas têm mostrado a maior eficiência na utilização da WT sobre a FT nesse tipo de problema, já que a análise de todos os coeficientes que compõem a transformada *wavelet* de um determinado sinal, permite identificar com boa fidelidade, tanto efeitos do sinal que ocorrem instantaneamente, quanto aqueles que se manifestam em determinadas frequências. Características que não podem ser obtidas através de outras transformadas ou sistemas de expansão, como a Transformada de Fourier e as Transformadas de Fourier Janeladas.

Outros trabalhos apontam alguns inconvenientes no uso de algumas concepções de RNA's, como a necessidade de um grande número de ciclos de treinamento e retreinamento para cada nova classe a ser classificada, inviabilizando a sua implementação em tempo real.

2.3. Análise das Principais Referências Bibliográficas

Considerando-se que, neste trabalho, será abordado o problema das anomalias de tensão, esta análise restringirá às principais referências que fazem uso de conceitos e métodos associados a esta modalidade de estudo.

O diagnóstico das anomalias de tensão, em sistemas elétricos, causadas por distúrbios, pode ser abordado usando-se métodos clássicos, como, por exemplo: transformada de Fourier, transformada rápida de Fourier (BRIGHAM, 1988) e (HEYDT et al., 1999). Mais recentemente passou a ser usada, de forma intensa, metodologias baseadas na transformada *wavelet* (BOLLEN, 2000), (DAUBECHIES, 1992) e (MALLAT, 1998). Neste contexto, encontra-se um grande número de soluções (BOLLEN, 2000), (CHILUKURI; DASH, 2004), (HEE STARZYK, 2006) e (SANTOSO et al., 1996). O uso de técnicas alternativas de inteligência artificial tem sido, também, intensificado nos últimos 10 anos, entre as quais se destacam as redes neurais (GHOSH; LUBKEMAN, 1995, SANTOSO et al., 2000, TONG et al., 2006) e lógica nebulosa (*fuzzy*) (CHILUKURI; DASH, 2004, DASH et al., 2000 e LIAO; LEE, 2004); foram empregadas regras de vizinhança; em (CHILUKURI; DASH, 2004) e (GAOUDA, 2001) foi desenvolvido um algoritmo baseado em WT com Análise Multirresolução (AMR) e Lógica *Fuzzy*; em (LI; WU, 2006) demonstram-se a viabilidade do uso de séries temporais não-lineares para a detecção e identificação de tais distúrbios. Em (TIWARI; SHUKLA, 2002) foi usada a WT com Lógica *Fuzzy*; em (LIAO; LEE, 2004) foi desenvolvido um sistema *fuzzy* para classificação; em (WANG; MAMISHEV, 2004) usaram uma representação otimizada de tempo-frequência; em (ABDEL-GALIL et al., 2005) são usados modelos de Markov; (AXELBERG et al., 2007) se apoiaram na técnica SVM (Support Vector Machine) (VAPNIK, 1995); em (GERMEN et al., 2005) foi usada uma RNA SOM - *Self Organizing Map*; He e Starzyk em (HE et al., 2006) foi utilizada a Transformada *Wavelet* em conjunto a uma rede com aprendizado auto-organizável; e (TONG et al., 2006) tratam da detecção e classificação de distúrbios através de uma RNA *wavelet* autoadaptativa.

Diversos tipos de algoritmos de redes *wavelets* têm sido considerados no problema de detecção de distúrbios de tensão. Porém, informações, tanto de tempo, quanto de frequência são fornecidas somente pela Análise Multirresolução (AMR) (MALLAT, 1998). A adaptação do modelo de inferência de corrente proposto por Al-Jufout em (AL-JUFOUT, 2006) onde o processo de detecção é realizado inferindo-se, de maneira aproximada, a

amplitude da tensão da forma de onda, proporcionou a detecção de sinais com distúrbios com extrema rapidez e eficiência.

Dentre os sistemas propostos vários utilizam Transformadas de Fourier (FT) ou Transformada *Wavelet* (WT) e Redes Neurais Artificiais (RNA) ou Lógica *Fuzzy* (FL) para classificação dos distúrbios. Tais assuntos serão tratados em capítulos posteriores. A Transformada *Wavelet* é uma poderosa ferramenta matemática que propicia a extração das características da forma de onda com distúrbios em problema de QEE, especialmente usando a função Daubechies (DAUBECHIES, 1992).

A grande maioria das propostas de metodologias para classificação de anomalia de tensão por redes neurais empregam, como técnica de treinamento, o algoritmo retropropagação (*backpropagation*) (WERBOS, 1974). Por simplicidade de denominação esta rede é chamada, nesta pesquisa, de Rede Neural Retropropagação ou simplesmente RNR. O algoritmo retropropagação é um procedimento de adaptação de pesos da rede neural baseado no método do gradiente descendente (WIDROW; LEHR, 1990). Sabe-se que as RNR's, mesmo sendo consideradas uma referência em termos de precisão, apresentam um desempenho muito baixo, quando se refere à convergência do processo de treinamento. Existem diversos casos em que não se obtém a convergência do processo de treinamento, principalmente quando se trabalha com grande volume de pares (entrada e saída da rede neural) de vetores padrões.

O sistema de análise (extração de características e classificação) do sinal com distúrbio proposto nesta pesquisa é constituído por um módulo *wavelet* combinado com um módulo ART-descendente, conhecido por ARTMAP (CARPENTER; GROSSBERG, 1987a). Nas arquiteturas neurais ART-descendentes não se observam estas dificuldades. Isto porque as redes neurais ART exibem a característica de estabilidade e de plasticidade. A estabilidade é a garantia que se pode obter, sempre, uma solução. Por sua vez, a plasticidade é a capacidade intrínseca da rede neural de realizar o treinamento de forma incremental. Assim, uma vez concluído o treinamento, se houver disponibilidade de novos padrões a serem armazenados na matriz de pesos da rede neural, não há necessidade de reiniciar o treinamento como efetivado comumente em relação às RNR's, rede de Kohonen (GERMEN et al., 2005), etc. Portanto, trata-se de um mecanismo de treinamento continuado.

Outro ponto relevante refere-se à grande rapidez na obtenção de soluções, podendo-se observar, a partir de simulações realizadas, ganhos superiores a 100 vezes. Ou

seja, uma rede neural ART-descendente é mais do que cem vezes mais rápida. A utilização da lógica *fuzzy* aliada a arquitetura ARTMAP torna a rede propícia para classificar tanto entradas binárias como analógicas. Assim a rede neural ARTMAP *fuzzy* mostra-se a mais adequada e eficiente para a aplicação-alvo desta pesquisa.

CAPÍTULO 3

QUALIDADE DE ENERGIA ELÉTRICA

3.1. Introdução

Para que a energia elétrica possa atender, de maneira satisfatória, aos diversos processos em que esteja envolvida, é de extrema importância que, ao ser gerada, a concessionária a mantenha com o melhor grau de qualidade e confiabilidade possíveis, atendendo aos padrões recomendados e aceitos pelos órgãos que regulam e fiscalizam o setor. Entretanto, devido a uma série de fatores inerentes ao sistema, tais como, transporte, controle e utilização, a qualidade da energia elétrica entregue aos consumidores, sobretudo sob o ponto de vista da qualidade da tensão, pode apresentar distorções significativas, podendo prejudicar e até impossibilitar a sua utilização.

O conceito de Qualidade da Energia Elétrica está associado a um conjunto de distúrbios que podem ocorrer no suprimento elétrico oferecido aos consumidores. Tais distúrbios podem ter origem e/ou manifestar-se em diferentes pontos de uma rede elétrica, tanto dentro de uma instalação consumidora, como fora dela (DUGAN et al., 1996).

Um distúrbio de Qualidade da Energia Elétrica pode ser formulado como qualquer desvio ou alteração manifestada na magnitude, forma de onda ou frequência destas grandezas, que resulte na falha ou operação indevida de instalações, aparelhos ou equipamentos (BOLLEN, 2000).

Os distúrbios elétricos relacionados com a Qualidade da Energia, geralmente, são divididos em categorias levando-se em conta o seu tempo de duração, seu conteúdo espectral e também a sua amplitude típica no sistema. Assim, serão apresentados ao longo deste capítulo, os principais tipos de distúrbios relacionados com essa pesquisa, assim como, suas

origens e principais consequência. Desta forma, estarão subdivididas em transitórios, variações de tensão de curta duração, variações de tensão de longa duração, distorções na forma de onda e flutuação de tensão.

3.2. Fenômenos Elétricos Transitórios

Os transitórios eletromagnéticos são as manifestações ou respostas elétricas locais ou nas adjacências, provenientes de alterações súbitas nas condições operacionais de um sistema de energia elétrica. Normalmente, um fenômeno transitório tem uma duração muito pequena, mas de grande importância, uma vez que os equipamentos presentes nos sistemas elétricos estarão submetidos a grandes solicitações de tensão e ou corrente (DUGAN et al., 1996).

Os fenômenos transitórios podem ser classificados em duas subcategorias que são os transitórios impulsivos, causados por descargas atmosféricas, e os transitórios oscilatórios, causados por chaveamentos. Os quais serão vistos a seguir.

3.2.1. Transitórios Impulsivos

Normalmente causado por descargas atmosféricas, um transitório impulsivo pode ser definido como uma alteração repentina nas condições de regime permanente da tensão, corrente ou em ambas. Tendo como principal característica a apresentação de impulsos unidirecionais em polaridade positiva ou negativa e nível de frequência bastante diferenciado com relação a frequência da rede elétrica (DUGAN et al., 1996). A Figura 3.2.1. ilustra uma corrente típica de um transitório impulsivo proveniente de uma descarga atmosférica.




FIGURA 3.2.1. - FORMA TÍPICA DE ONDA DE CORRENTE TRANSITÓRIA IMPULSIVA. FONTE: DUGAN ET AL., 1996.

Os transitórios impulsivos são definidos, geralmente, por um tempo de subida e outro de descida do impulso, ou podem ser expressos pelo seu conteúdo espectral. Para exemplificar, um impulso transitório tendo como parâmetros $2 \times 50\mu\text{s}$ e 1.000V , o que significa que o mesmo atinge seu valor máximo de 1.000V em um tempo de $2\mu\text{s}$ e, posteriormente, decai até a metade de seu valor máximo (500V) no tempo de $50\mu\text{s}$.

Como estes transitórios são causados por descargas atmosféricas, é fundamental a observação do nível da tensão no ponto de ocorrência da descarga. Uma descarga diretamente na fase geralmente causa uma alta sobretensão próxima ao ponto de incidência na linha, podendo provocar, além de um transitório impulsivo, uma falta acompanhada de afundamento de tensão e interrupção.

As descargas que fluem ao longo do condutor terra também podem gerar altas sobretensões transitórias. Os principais problemas causados por estas correntes no sistema de aterramento são:

- A elevação do potencial do nó-terra (ou simplesmente terra) local em relação a outros terras podendo levar a falhas e danos equipamentos eletrônicos sensíveis conectados entre duas referências de terra, como, por exemplo, um computador conectado à linha telefônica através de um *modem*.
- A indução de altas tensões nos condutores fase quando as correntes passam pelos cabos a caminho do terra.

A onda de tensão ao percorrer a linha, partindo do ponto de incidência até as subestações abaixadoras para a tensão de distribuição, é consideravelmente atenuada tendendo

a suprimir os efeitos, provenientes das descargas atmosféricas ocorridas em nível de transmissão, aos consumidores ligados em nível de baixa tensão. No entanto, os consumidores atendidos em nível de transmissão e localizados próximos do ponto de incidência, estarão sujeitos as consequências destes efeitos (OLIVEIRA, 2000).

3.2.2. Transitórios Oscilatórios

Um transitório oscilatório possui como característica uma alteração súbita nas condições de regime permanente da tensão e/ou corrente contendo valores de polaridade positiva e negativa. Os tipos de transitórios oscilatórios podem ser definidos em função do conteúdo espectral, duração e magnitude da tensão. Podem ser decorrentes do corte de corrente indutiva, do chaveamento de bancos de capacitores e transformadores, da energização de linhas, da eliminação de faltas, etc. (BOLLEN, 2000). A Figura 3.2.2. ilustra o resultado da simulação da energização de um banco de 600kVAr e tensão de 13,8kV.




Figura 3.2.2. - Transitório proveniente do chaveamento de um banco de capacitores.

Os transitórios oscilatórios de baixa frequência são frequentemente encontrados em sistemas de subtransmissão e distribuição de energia e são causados por vários tipos de eventos. O mais frequente é a energização de bancos de capacitores, que geralmente, resulta

em oscilações de tensão com frequência entre 300 e 900Hz, com magnitude máxima por volta de 2,0 pu, sendo valores típicos de 1,3 a 1,5 pu com uma duração entre 0,5 e 3 ciclos dependendo das características de amortecimento do sistema (DUGAN et al., 1996).

Também podem ser encontrados nos sistemas de distribuição transitórios oscilatórios com frequências menores do que 300Hz, os quais estão associados, normalmente, aos fenômenos de ferro-ressonância e energização de transformadores.

Os transitórios oscilatórios de alta frequência são geralmente o resultado de uma resposta do sistema a um transitório impulsivo, isto é, podem ser causados por descargas atmosféricas ou por chaveamento de circuitos indutivos.

A desenergização de cargas indutivas pode gerar impulsos de alta frequência. Apesar de serem de curta duração, estes transitórios podem interferir na operação de cargas eletrônicas. Filtros de alta frequência e transformadores isoladores podem ser usados para proteger as cargas contra este tipo de transitório (DUGAN et al., 1996).

O *Institute of Electrical and Electronics Engineers (IEEE)* define os fenômenos transitórios conforme mostrado na Tabela 3.2.2.

Tabela 3.2.2 - Classificação dos fenômenos transitórios. Fonte: IEEE Std. 1159-1995.

Categoria Transitório	Duração Típica	Magnitude Típica
Impulsivo		
Nanossegundos	< 50 ns	
Microssegundos	50 ns - 1ms	
Milissegundos	> 1ms	
Oscilatório		
Baixa frequência	0,3 - 50 ms	0 - 4 pu
Média frequência	20 μ s	0 - 8 pu
Alta frequência	5 μ s	0 - 4 pu

3.3. Variações de Tensão de Curta Duração

As variações de tensão de curta duração (VTCD's) podem ser caracterizadas, dependendo da duração, por alterações instantâneas, momentâneas ou temporárias. Tais variações de tensão são causadas, normalmente, em razão de falta, energização de grandes

cargas as quais requerem altas correntes de partida ou por falhas intermitentes nas conexões de cabos do sistema. Dependendo do local da falta e das condições do sistema, a falta pode causar tanto um afundamento de tensão temporário (*sag*, em inglês), como uma elevação de tensão (*swell*, em inglês), ou ainda uma interrupção completa do sistema elétrico (DUGAN et al., 1996).

3.3.1. Interrupção de Curta Duração

Segundo indicação do *IEEE* (IEEE, Std 1159-1995), uma interrupção de curta duração (*Outage Voltage*, em inglês) ocorre quando a tensão de suprimento decresce para um valor menor que 0,1 pu por um período de tempo não superior a 1 minuto. Este tipo de interrupção pode ser causado por faltas no sistema de energia, falhas de equipamentos e mau funcionamento de sistemas de controle.

A duração de uma interrupção, causada por uma falta no sistema da concessionária, é determinada pelo tempo de operação dos dispositivos de proteção. Religadores programados para operar instantaneamente, geralmente limitam a interrupção a tempos inferiores a 30 ciclos. Religadores temporizados podem originar interrupções momentâneas ou temporárias, dependendo da escolha das curvas de operação do equipamento (OLIVEIRA, 2000).

Observa-se na Figura 3.3.1. uma forma de onda típica de interrupção momentânea com duração de aproximadamente seis ciclos e, logo a seguir, há o restabelecimento normal da energia elétrica.




Figura 3.3.1. - Interrupção momentânea devido a um curto-circuito.

Algumas vezes, as interrupções são precedidas por um afundamento de tensão quando são ocasionadas por faltas no sistema supridor. O afundamento de tensão ocorre no período de tempo entre o início de uma falta e a operação do dispositivo de proteção do sistema.

3.3.2. Afundamento de Tensão de Curta Duração

Os afundamentos de tensão (subtensão) destacam-se como as mais significantes formas de alterações que se manifestam nas redes elétricas. Tal destaque se justifica pelo fato dos afundamentos de tensão, tanto de curta como de longa duração, serem os que mais notadamente se fazem presentes na operação dos complexos elétricos (BOLLEN, 2000).

A norma IEEE (*Institute of Electrical and Electronics Engineering*) (IEEE, Std 1159-1995) define afundamento de tensão como “Um decréscimo entre 0,1 e 0,9 pu do valor eficaz da tensão nominal, com duração entre 0,5 ciclo e 1 minuto”. Segundo esta norma, um afundamento de tensão com intensidade menor do que 0,1 pu é considerado interrupção.

De acordo com os procedimentos de rede elaborados pelo ONS (Operador Nacional do Sistema Elétrico) (ONS, 2000), entende-se por variação de tensão de curta duração: “Um desvio significativo da amplitude da tensão por um curto intervalo de tempo”.

Assim, os afundamentos de tensão de curta duração ou simplesmente sag (do inglês *voltage sag* ou *voltage dip*) são caracterizados por uma redução no valor eficaz da tensão, entre 0,1 e 0,9 pu, na frequência fundamental, com duração entre 0,5 ciclo e 1 minuto.

Um típico afundamento de tensão, resultante de uma falta fase-terra com uma subtensão de 45% em seis ciclos, aproximadamente, é apresentado na Figura 3.3.2.1.




Figura 3.3.2.1. - Forma de onda característica de um afundamento de tensão.

Afundamentos de tensão com período inferior a 10ms e abaixo de 10% não são levadas em consideração. Isto se explica pelo fato de que os distúrbios com período de duração abaixo de 10ms são considerados como transitórios e, quedas de tensão de curta duração menores que 10% são toleradas pela maioria dos equipamentos elétricos (BOLLEN, 2000).

Este tipo de distúrbio está associado, principalmente, a curtos-circuitos ocorridos nas redes de distribuição. Mas pode também ser causado pela energização de grandes cargas, partida de grandes motores e pela corrente inrush de um transformador (OLIVEIRA, 2000).

As características do afundamento de tensão diante de uma determinada falta dependem de vários fatores como: a natureza da falta, sua posição relativa a outros consumidores ligados na rede e o tipo de filosofia de proteção adotada no sistema.

A Figura 3.3.2.2. ilustra o afundamento de tensão causado pela partida de um motor de indução, apresentando um decréscimo no valor eficaz da tensão.

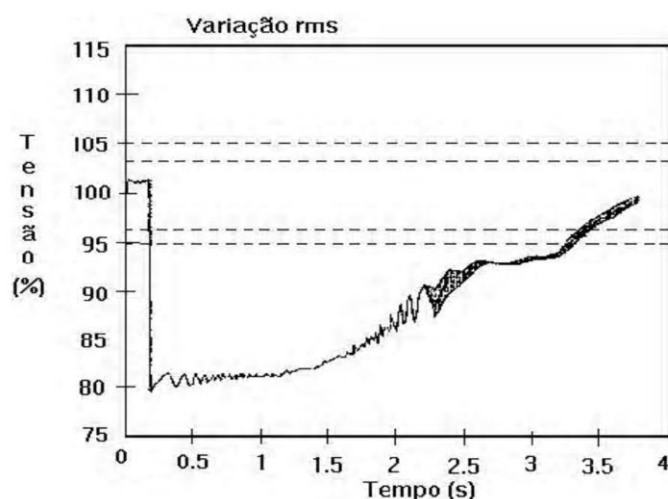


Figura 3.3.2.2 - Afundamento de tensão ocorrido pela partida de um motor. Fonte: DUGAN et al., 1996.

Durante a partida de um motor de indução, este absorve uma corrente de 6 a 10 vezes a corrente nominal, resultando em uma queda significativa na tensão de suprimento. Observa-se neste caso, que a tensão, apresentada em seu valor eficaz, cai rapidamente para 0,8 pu e, num período de aproximadamente 3 segundos, retorna ao seu valor nominal (DUGAN et al., 1996).

Como consequência deste tipo de distúrbio tem-se principalmente a má operação de equipamentos eletrônicos, em especial os sistemas computadorizados, que tem sido alvo de preocupações em órgãos de pesquisa em QEE. Entretanto, determinar os níveis de sensibilidade de tais equipamentos torna-se uma tarefa difícil, em consequência ao grande número de medições necessárias para a coleta de dados além das dificuldades de se ter equipamentos de medição em condições reais de campo (OLIVEIRA, 2000).

Como os computadores são muito sensíveis no que se refere aos afundamentos de tensão, uma vez que os dados armazenados na memória podem ser totalmente perdidos em condições de subtensões indesejáveis, foram realizados estudos pela *Computer and Business Electronics Manufacturers Association* – CBEMA a fim de serem estabelecidos limites em termos da qualidade da energia a ele suprida. Como resultado foi adotada a curva de suportabilidade. As curvas CBEMA, como são conhecidas, fornecem limites de tolerância para equipamentos eletrônicos (especificamente computadores), em função da magnitude da tensão e da duração do distúrbio.

Estas curvas aparecem na norma IEEE (IEEE Std. 446-1995) como “prática recomendada para sistemas de alimentação de emergência, em aplicações industriais e comerciais” e são mostradas na Figura 3.3.2.3.

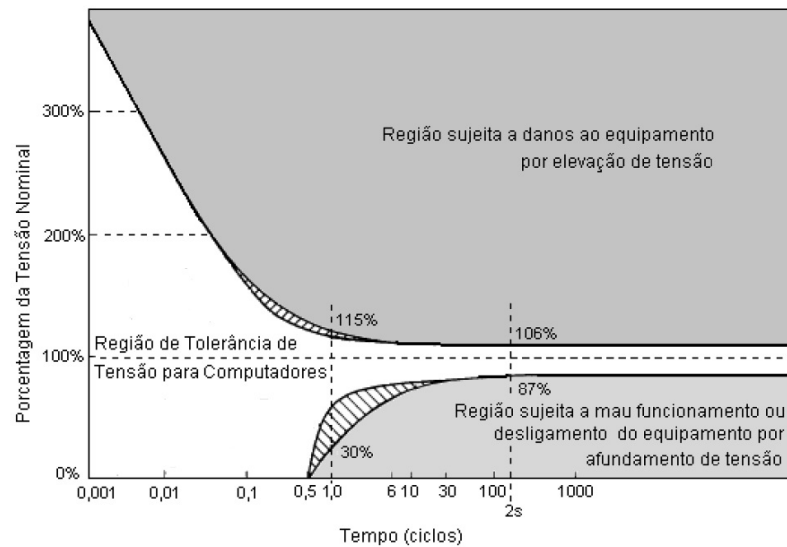


Figura 3.3.2.3. - Tolerâncias típicas de tensão para computadores (curva CBEMA).
Fonte: norma IEEE 446.

Na ilustração, acima, os níveis de tensão abaixo, ou acima do valor nominal representam os limites dentro dos quais um computador típico pode resistir a distúrbios de afundamentos ou elevações de tensão sem apresentar falhas. Nota-se que a sensibilidade de um computador é demasiadamente dependente do período de duração do distúrbio.

Para equipamentos de tecnologia da informação, foi definida pelos fabricantes a curva ITIC, mostrada na figura 3.3.2.4.

As curvas definem um “envelope” dentro do qual deve estar o valor da tensão suprida ao equipamento. Ou seja, quando os limites forem violados, o sistema de alimentação ininterrupta deve atuar, no sentido de manter a alimentação dentro de valores aceitáveis.

Em outras palavras, se a tensão de alimentação estiver dentro dos limites não devem ocorrer mau funcionamento do equipamento alimentado. Violações dos limites podem, então, provocar falhas, que devem ser evitadas.

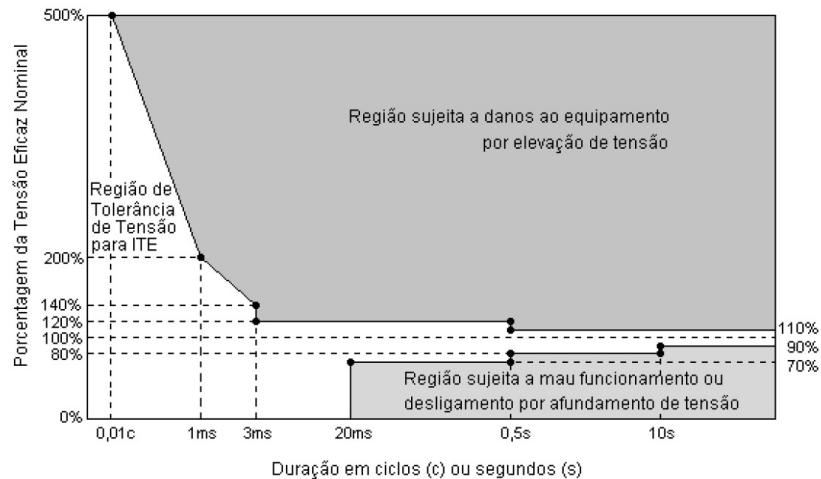


Figura 3.3.2.4. - Curva ITIC - Tolerâncias típicas de tensão para equipamentos de tecnologia da informação.

Segundo Dugan (DUGAN et al., 1996) existem diversas medidas que podem ser adotadas por parte de consumidores, concessionárias e fabricantes de equipamentos no sentido de diminuir o número e a severidade dos afundamentos de tensão de curta duração. Algumas destas medidas são:

- Utilização de transformadores ferro-ressonantes, conhecidos também como CVT's (Constant Voltage Transformers) que são capazes de controlar a maioria das condições de afundamento de tensão. Estes equipamentos são utilizados fundamentalmente para cargas com potências constantes e de baixos valores. Transformadores ferroressonantes são basicamente transformadores de relação de transformação 1:1, altamente excitados em suas curvas de saturação, fornecendo assim uma tensão de saída que não é significativamente afetada pelas variações da tensão de entrada.
- Utilização de UPS's (*Uninterruptible Power Supply*). Os tipos básicos de UPS's operam fundamentalmente nas operações *on-line* (em operação) e *stand-by* (em espera). São dispositivos que podem ser usados para períodos de interrupção acima de 15 minutos de duração. A UPS híbrida, que corresponde a uma variação de UPS *stand-by*, também pode ser usada para interrupções de longa duração.
- Utilização de conjuntos de motor-gerador (M-G). Existindo em uma grande variedade de potências e configurações, são capazes de suprir uma saída constante. A inércia do volante faz com que o rotor do gerador mantenha a rotação caso ocorra a falta de energia.

- Utilização de um dispositivo magnético supercondutor de armazenamento de energia. Tal dispositivo utiliza um magneto supercondutor para armazenar energia da mesma maneira que um UPS utiliza baterias. Os projetos na faixa de 1 a 5MJ são chamados de micro-SMES (*Superconducting Magnetic Energy Storage*). Sua principal vantagem é o pequeno espaço físico necessário para armazenar o magneto, quando é comparado ao espaço utilizado pelas baterias.
- Utilização de métodos de partida de motores. Dentre os mais utilizados pode-se citar os seguintes métodos de partida (OLIVEIRA, 2000):
 - Partida suave (*Soft Started*);
 - Partida por meio de autotransformadores;
 - Partida por meio de resistência e reatância;
 - Partida por meio de enrolamento parcial;
 - Partida pelo método estrela-triângulo.

Tais práticas podem ser definidas como adicionamento de religadores de linha, eliminação das operações rápidas de religadores e/ou disjuntores, adicionamento de sistemas do tipo *Network* e aprimoramento do projeto dos alimentadores. Práticas que podem reduzir o número e a duração das interrupções momentâneas e dos afundamentos de tensão, mas por si só, não garante a eliminação por completo das faltas nos sistemas das concessionárias.

Adoção de medidas de prevenção contra faltas no sistema da concessionária. Tais medidas devem incluir atividades como colocação de pára-raios de linha, manutenção dos isoladores, blindagem de cabos, modificação do espaçamento entre condutores, melhorias no sistema de aterramento e até a poda de árvores.

A redução do número de curtos-circuitos é uma maneira extremamente eficiente no tocante ao melhoramento da qualidade do fornecimento, bem como a solução mais óbvia. Esta medida não só diminui a frequência dos afundamentos, mas também reduz a frequência de longas interrupções. Um curto-circuito não só gera afundamentos, mas também causa danos a equipamentos e prejuízos aos consumidores. Infelizmente, nem sempre a solução mais óbvia é a melhor, pois para se evitar um curto-circuito muitas vezes devem-se adotar medidas extremamente dispendiosas, onde seus custos podem ultrapassar as consequências das falhas causadas aos equipamentos ou prejuízos as empresas.

3.3.3. Elevação de Tensão de Curta Duração

Uma elevação de tensão (sobretensão) de curta duração também conhecida por *swell* é definida como um aumento entre 1,1 e 1,8 pu na tensão eficaz, considerando-se a frequência do sistema, com duração entre 0,5 ciclo a 1 minuto (IEEE, Std 1159-1995).

As elevações de tensão, assim como os afundamentos de tensão, estão geralmente associadas com as condições de falta no sistema, principalmente na ocorrência de um curto-circuito fase-terra, sendo que nestas condições nas fases não defeituosas ocorrem uma elevação de tensão. Esta elevação de tensão pode atingir num sistema a quatro fios multiterrados, valores próximos a 1,25 pu (OLIVEIRA, 2000).

A Figura 3.3.3. ilustra uma forma de onda característica contendo elevação de tensão característica, que poderia ter sido ocasionado por uma falta fase-terra, apresentando, aproximadamente, uma sobretensão de 40% por um período de seis ciclos.




Figura 3.3.3. - Elevação de tensão devido a uma falta fase-terra.

Este tipo de distúrbio também pode estar associado à saída de grandes blocos de cargas ou à energização de grandes bancos de capacitores. Contudo, com uma incidência pequena se comparada com as sobretensões provenientes de faltas fase-terra nas redes de transmissão e distribuição (DUGAN et al., 1996).

O nível de severidade de uma elevação de tensão durante uma condição de falta está associado ao local de ocorrência da falta, da impedância do sistema e do aterramento. A duração da elevação de tensão está diretamente ligada aos ajustes dos dispositivos de proteção, à natureza da falta seja ela permanente ou temporária e a sua localização na rede elétrica.

Em situações de elevação de tensão provenientes de saídas de grandes cargas ou energização de grandes bancos de capacitores, o tempo de duração das sobretensões depende da resposta dos dispositivos reguladores de tensão das unidades geradoras, do tempo de resposta dos transformadores de *tap* variável e da atuação dos dispositivos compensadores que porventura existam no sistema (DUGAN et al., 1996).

Dependendo da frequência de ocorrência do distúrbio pode-se ter como consequência das elevações de tensão de curta duração em equipamentos algum tipo de falha dos componentes. Como nos computadores, controladores eletrônicos e outros dispositivos eletrônicos que podem apresentar falhas imediatas durante um distúrbio de elevação de tensão. Outros dispositivos e equipamentos como transformadores, dispositivos de chaveamento, cabos, Transformadores de Potencial (TP's), Transformadores de Correntes (TC's), máquinas rotativas e barramentos, podem ter uma redução significativa em sua vida útil.

Um aumento na tensão em um período de curta duração em alguns relés pode resultar em má operação dos mesmos, enquanto outros podem não ser afetados. Uma elevação de tensão em um banco de capacitores pode causar sérios danos ao equipamento. Aparelhos de iluminação podem ter um aumento da luminosidade e dispositivos de proteção contra surto, podem sofrer danos irreparáveis quando submetidos a elevações de tensão que excedam suas taxas de *MCOV* (*Maximum Continuous Overvoltage*) (DUGAN et al., 1996).

A principal preocupação acerca deste tipo de distúrbio recai sobre os equipamentos eletrônicos, uma vez que estas elevações de tensão podem danificar os componentes internos destes equipamentos, acarretando falhas ou má operação, ou em casos extremos, à sua completa inutilização. Ressaltando que a resistência a distúrbios de um equipamento não depende apenas da magnitude da elevação de tensão, mas também do seu período de duração, conforme ilustrado anteriormente na Figura 3.3.2.3., a qual mostra a tolerância de microcomputadores às variações de tensão.

As variações na tensão classificadas como de curta duração (VTCD's) são geralmente as responsáveis pela maioria das interrupções de produtividade em processos industriais, caracterizadas por elevações, faltas, e principalmente afundamentos de tensão ocorridos durante alguns instantes de tempo. O *Institute of Electrical and Electronics Engineers* (IEEE) define as VTCD's como desvios no valor eficaz da tensão, de duração máxima equivalente a 1 minuto.

A Tabela 3.3.3., a seguir, classifica os distúrbios de variação de tensão de curta duração, segundo o tempo de duração e magnitudes típicas.

Tabela 3.3.3. - Classificação de VTCD's conforme o tempo de duração. Fonte: IEEE Std. 1159-1995.

Categoria (VTCD)	Duração Típica	Magnitude Típica
Instantânea		
Interrupção	0,5 - 30 ciclos	< 0,1 pu
Afundamento	0,5 - 30 ciclos	0,1 - 0,9 pu
Elevação	0,5 - 30 ciclos	1,1 - 1,8 pu
Momentânea		
Interrupção	30 ciclos - 3 seg.	< 0,1 pu
Afundamento	30 ciclos - 3 seg.	0,1 - 0,9 pu
Elevação	30 ciclos - 3 seg.	1,1 - 1,4 pu
Temporária		
Interrupção	3 seg. - 1min.	< 0,1 pu
Afundamento	3 seg. - 1min.	0,1 - 0,9 pu
Elevação	3 seg. - 1min.	1,1 - 1,2 pu

3.4. Variações de Tensão de Longa Duração

As variações de tensão de longa duração podem ser caracterizadas como desvios que ocorrem no valor eficaz da tensão, na frequência do sistema, com duração superior a 1 minuto (DUGAN et al., 1996).

Estas variações de tensão de longa duração podem abranger os afundamentos de tensão, as elevações de tensão ou as interrupções sustentadas. Geralmente são causadas por variações de carga e operações de chaveamento no sistema (OLIVEIRA, 2000).

Os índices que caracterizam variações de tensão de longa duração encontram-se definidos na Resolução 505 da ANEEL (ANEEL, 2001) e são descritos sucintamente a seguir.

3.4.1. Interrupções Sustentadas

Quando a tensão de suprimento permanece em zero por um período de tempo superior a 1 minuto, a variação de tensão de longa duração é considerada uma interrupção sustentada.

As interrupções sustentadas podem ocorrer por causa da manutenção programada ou não. A maioria delas ocorrem de forma não programada e as principais causas são falhas nos disjuntores, queima de fusíveis, falha de componentes de circuito alimentador, dentre outras. Já o caso de interrupção sustentada planejada, ocorre geralmente para execução da manutenção geral da rede, tanto como em serviços como troca de cabos e postes, mudança de *tap* do transformador, alteração dos ajustes de equipamentos de proteção, como em diversos outros.

Tanto na interrupção de natureza sustentada ou inesperada, o sistema elétrico deve ser projetado e operado de forma a garantir que:

- O número de interrupções seja mínimo;
- Uma interrupção dure o mínimo possível; e
- O menor número possível de consumidores sejam afetados.

A consequência de uma interrupção sustentada é o desligamento dos equipamentos, exceto para aquelas cargas protegidas por sistemas *no-breaks* ou por outras formas de armazenamento de energia e requerem a intervenção da concessionária para reparar o sistema e restaurar o fornecimento de energia.

3.4.2. Afundamentos de Tensão Sustentados

Um afundamento de tensão ou subtensão sustentado é caracterizado por um decréscimo no valor eficaz da tensão a valores menores que 0,9 pu com período de duração maior que 1 minuto, considerando-se a frequência do sistema.

Estes distúrbios são decorrentes principalmente do carregamento excessivo dos circuitos alimentadores, os quais são submetidos a determinados níveis de corrente que, interagindo com a impedância da rede, dão origem a quedas de tensão acentuadas (DUGAN et al., 1996).

Outros fatores que contribuem para as subtensões são: a conexão de cargas à rede elétrica, o desligamento de bancos de capacitores ocasionando o excesso de reativo transportado pelos circuitos de distribuição, o que limita a capacidade do sistema no fornecimento de potência ativa e ao mesmo tempo eleva a queda de tensão. (BOLLEN, 2000).

Dentre os problemas causados por afundamentos de tensão de longa duração, destacam-se:

- Redução da potência reativa fornecida por bancos de capacitores ao sistema;
- Elevação do tempo de partida das máquinas de indução, o que contribui para a elevação de temperatura dos enrolamentos;
- Possibilidade de interrupção da operação de equipamentos eletrônicos, tais como computadores e controladores eletrônicos;
- Redução de índice de iluminação para os circuitos de iluminação incandescente; e
- Aumento nos valores das correntes em um motor de indução quando alimentado por uma tensão inferior à nominal. Causando um sobreaquecimento reduzindo, assim, a expectativa de vida útil da mesma.

As opções para melhorar a regulação de tensão são:

- Instalação de capacitores *shunt* para propiciar a redução da corrente do circuito;

- Instalação de cabos com maiores bitolas para a redução a impedância da linha;
- Instalação de reguladores de tensão para elevar o nível da tensão;
- Instalação de capacitores em série para evitar a queda de tensão indutiva;
- Instalação de compensadores estáticos de reativos, com os mesmos objetivos que os capacitores, para mudanças bruscas de cargas; e
- Substituição do transformador de serviço para um com maior capacidade, acarretando a redução da impedância da linha.

3.4.3. Elevações de Tensão Sustentadas

Uma elevação de tensão de longa duração ou sobretensão sustentada é caracterizada por um aumento no valor eficaz da tensão acima de 1,1 pu, tipicamente valores entre 1,1 e 1,2 pu, por um período de duração maior que 1 minuto. Tais distúrbios podem ser o resultado do desligamento de grandes cargas ou da energização de um banco de capacitores, assim como a conexão errônea de taps de transformadores que também podem causar elevações de tensão (DUGAN et al., 1996).

Com o intuito de melhorar o perfil da tensão, e amenizar os problemas normalmente são tomadas algumas providencias tais como:

- Instalação de bancos de capacitores fixos nos sistemas de distribuição das concessionárias, suprindo, assim, a energia reativa.
- Instalação de bancos de capacitores nas indústrias, normalmente fixos, para correção do fator de potência ou mesmo para elevação da tensão nos circuitos internos da instalação. Nos horários de pico, quando há grandes solicitações de carga, a potência reativa fornecida por estes bancos auxilia a atuação do sistema. No entanto, fora do horário de pico, principalmente no período noturno, tem-se um excesso de reativo injetado no sistema, o qual se manifesta por uma elevação da tensão.

Quanto as consequências das elevações de tensão de longa duração, estas podem resultar em falha dos equipamentos, como:

- Dispositivos eletrônicos podem sofrer danos durante condições de sobretensões. Embora transformadores, disjuntores, cabos, transformadores de correntes, transformadores de potenciais e máquinas rotativas, normalmente não apresentem falhas imediatas, tais equipamentos quando submetidos a elevações de tensão sustentadas podem ter as suas vidas úteis reduzidas.
- Relés de proteção também poderão apresentar falhas de operação durante as elevações de tensão. A potência reativa fornecida pelos bancos de capacitores aumentará com o quadrado da tensão durante uma condição de sobretensão, enquanto que a iluminação poderá também ser aumentada em tal condição (BOLLEN, 2000).

Dentre algumas opções para a solução de tais problemas, destaca-se a troca de bancos de capacitores fixos por bancos automáticos, tanto em sistemas de concessionárias como em sistemas industriais e a instalação de compensadores estáticos de reativos, possibilitando um controle maior do nível da tensão (OLIVEIRA, 2000).

As variações na tensão classificadas como de longa duração (VTLD's), com tempo superior a 1 minuto, são classificadas segundo o IEEE de acordo com a Tabela 3.4.3.1.

Tabela 3.4.3.1. - Classificação de VTLD's conforme o tempo de duração. Fonte: IEEE Std. 1159-1995.

Categoria (VTLD)	Duração Típica	Magnitude Típica
Interrupção Sustentada	1 minuto	0 pu
Subtensão Sustentada	1 minuto	0,8 - 0,9 pu
Sobretensão Sustentada	1 minuto	1,1 - 1,2 pu

A Tabela 3.4.3.2. mostra os valores de fornecimento de energia de acordo com a classe de tensão que o consumidor está ligado determinado pela ANEEL em sua resolução 505 de 26 de novembro de 2001.

Tabela 3.4.3.2 - Classificação da Tensão de Atendimento. Fonte: ANEEL 2001.

Classificação de Tensão de Atendimento	Faixa de variação da Tensão de Leitura (TL) em relação à Tensão Contratada (TC)		
	Tensão Nominal > 1 kV e < 69 kV	Tensão Nominal \geq 69 kV e < 230 kV	Tensão Nominal \geq 230 kV
Adequada	$0,93 TC \leq TL \leq 1,05 TC$	$0,95 TC \leq TL \leq 1,05 TC$	$0,95 TC \leq TL \leq 1,05 TC$
Precária	$0,90 TC < TL < 0,93 TC$	$0,90 TC \leq TL < 0,95 TC$ ou $1,05 TC < TL \leq 1,07 TC$	$0,93 TC \leq TL < 0,95 TC$ ou $1,05 TC < TL \leq 1,07 TC$
Crítica	$TL < 0,90 TC$ ou $TL > 1,05 TC$	$TL < 0,90 TC$ ou $TL > 1,07 TC$	$TL < 0,93 TC$ ou $TL > 1,07 TC$

3.5. Distorções da Forma de Onda

A distorção da forma de onda é definida como um desvio, em regime permanente, da forma de onda puramente senoidal, na frequência fundamental, e é caracterizada principalmente pelo seu conteúdo espectral.

Existem cinco tipos principais de distorções da forma de onda (DUGAN et al., 1996):

- Distorção do Nível de Corrente Contínua (CC);
- Distorção Harmônica;
- Distorção Interharmônica;
- Notching; e
- Ruídos.

Tais tipos de distorções serão descritos na sequência.

3.5.1. Distorção do Nível de Corrente Contínua (CC)

A presença de tensão ou corrente contínua (CC) em um sistema elétrico de corrente alternada (CA) é denominado "*DC offset*", e pode ocorrer como o resultado da operação ideal de retificadores de meia-onda. O nível CC em redes de corrente alternada pode levar à saturação de transformadores, resultando em perdas adicionais e redução da vida útil do equipamento. Podendo, também, causar corrosão eletrolítica dos eletrodos de aterramento e de outros conectores (DUGAN et al., 1996).

3.5.2. Distorção Harmônica

Anteriormente à década de 80 não existiam maiores preocupações com distorções harmônicas. A utilização das cargas com características não-lineares eram pequenas e os equipamentos eram mais resistentes aos efeitos provocados por distorções harmônicas.

Mais recentemente, com o rápido desenvolvimento da eletrônica de potência e a utilização de métodos que buscam o uso mais racional da energia elétrica, o conteúdo harmônico presente nos sistemas tem se elevado, causando uma série de efeitos indesejáveis em diversos equipamentos ou dispositivos, comprometendo a qualidade e o próprio uso racional da energia elétrica. O problema é ainda agravado com a utilização de equipamentos e cargas mais sensíveis à QEE (BOLLEN, 2000).

É mostrado na Figura 3.5.2., a seguir, um perfil da vida útil de um transformador de corrente que se estabelece através de seus enrolamentos.

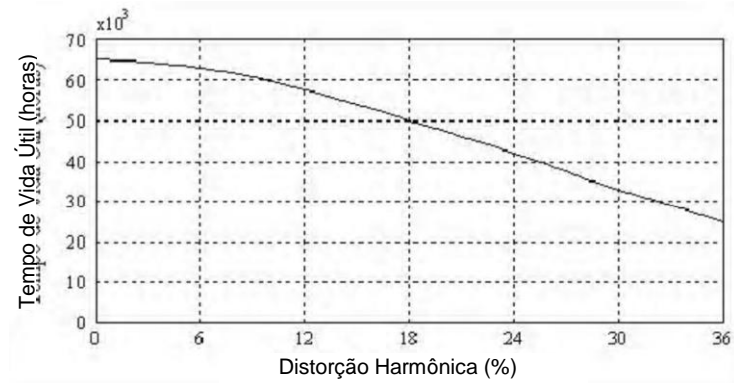


Figura 3.5.2. - Vida útil de um transformador em função da distorção harmônica de corrente.
Fonte: BOLLEN, 2000.

Os resultados mostrados na figura acima consideram que os componentes harmônicos, para cada situação, são superpostos a uma corrente fundamental igual à nominal do equipamento (OLIVEIRA, 2000).

Harmônicos ou componentes harmônicos são tensões ou correntes senoidais de frequências múltiplas inteiras da frequência fundamental na qual opera o sistema de energia elétrica. Estes harmônicos distorcem as formas de onda da tensão e corrente e são oriundos de equipamentos e cargas com características não-lineares instalados no sistema de energia (DUGAN et al., 1996). Na Figura 3.5.2.1. é mostrado um exemplo de forma de onda distorcida por harmônicos.




Figura 3.5.2.1. - Forma de onda com distorções harmônicas de 3ª e 5ª ordem.

Tecnicamente, um componente harmônico é o componente de uma onda periódica cuja frequência é um múltiplo inteiro da frequência fundamental (no caso da energia elétrica,

de 60 Hz). Como elucidação, são mostradas na Figura 3.5.2.2., na ilustração (a), duas curvas: uma onda senoidal normal, representando uma corrente de energia "pura", e outra onda menor, representando um componente harmônico. Na outra, ilustração (b), é possível verificarmos o resultado da soma das duas curvas (senoidal normal e componente harmônico). Tal curva resultante mostra bem a distorção harmônica da curva de tensão, na presença de harmônicos.

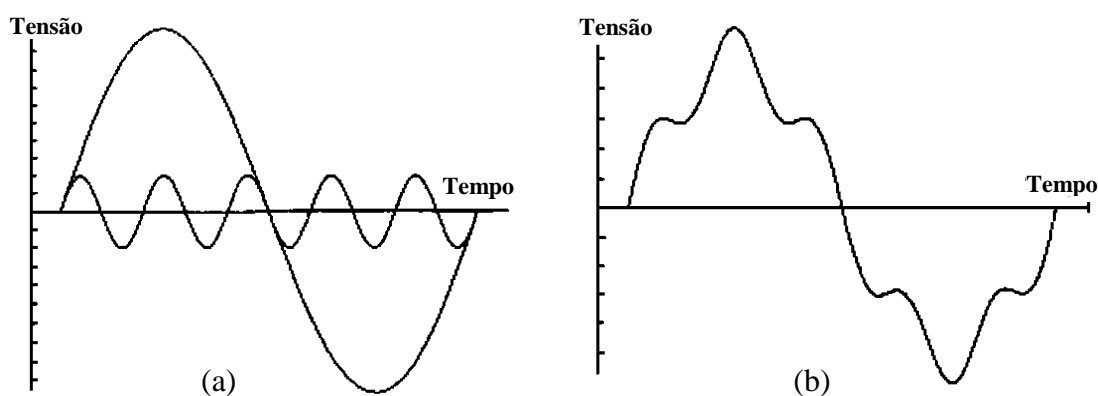


Figura 3.5.2.2. - (a) Formas de ondas senoidal e componente harmônico. (b) Forma de onda da soma das ondas senoidal e componente harmônico.

Os componentes harmônicos de ordem elevada são desprezíveis para análise dos sistemas de potência.

A distorção harmônica vem contra os objetivos da qualidade do suprimento promovido por uma concessionária de energia elétrica, a qual deve fornecer aos seus consumidores uma tensão puramente senoidal, com amplitude e frequência constantes. Entretanto, o fornecimento de energia a determinados consumidores que causam deformações no sistema supridor, prejudica não apenas o consumidor responsável pelo distúrbio, mas também outros conectados à mesma rede elétrica.

Dentre os vários tipos de cargas elétricas com características não-lineares, que causam as distorções harmônicas estão:

- Computadores;
- Circuitos de iluminação com lâmpadas de descarga;
- Motores CC controlados por retificadores;

- Motores de indução controlados por inversores com comutação forçada;
- Motores síncronos controlados por cicloconversores;
- Processos de eletrólise através de retificadores não-controlados;
- Fornos a arco;
- Fornos de indução de alta frequência;
- Fornos de indução controlados por reatores saturados;
- Cargas de aquecimento controladas por tiristores;
- Compensadores estáticos tipo reator saturado;
- Velocidade dos motores CA controlados por tensão de estator;
- Reguladores de tensão a núcleo saturado;
- Eletrodomésticos com fontes chaveadas, etc.

As distorções harmônicas podem causar muitos danos a todos os usuários. Porém, nas indústrias podem causar maiores prejuízos como a perda de produtividade, e de vendas motivadas por paradas de produção causadas por inesperadas falhas em motores e acionadores. Segundo (DUGAN et al., 1996), outros tipos de prejuízo que os harmônicos podem causar são:

- Acionamentos/Fontes: operações errôneas devido a múltiplas passagens por zero, e falha na comutação de circuitos;
- Capacitores: queima de fusíveis, e redução da vida útil;
- Motores: redução da vida útil, e impossibilidade de atingir potência máxima;
- Fusíveis/Disjuntores: operação falsa/errônea, e componentes danificados;
- Transformadores: aumento de perdas, causando redução de capacidade e diminuição da vida útil;
- Medidores: possibilidade de medições errôneas e de maiores contas;
- Telefones: interferências;

- Máquinas Síncronas: sobreaquecimento das sapatas polares, causado pela circulação de correntes harmônicas nos enrolamentos amortecedores;
- Carregamento exagerado do circuito de neutro, principalmente em instalações que agregam muitos aparelhos eletrônicos e possuem malhas de terra mal projetadas.

Porém, os principais problemas causados por distorções harmônicas se dão junto a bancos de capacitores, que podem originar condições de ressonância, caracterizando uma sobretensão nos terminais das unidades capacitivas (OLIVEIRA, 2000).

Na Figura 3.5.2.3., é mostrado o gráfico com a diminuição da vida útil dos capacitores causados pelo aquecimento causado pelos harmônicos.

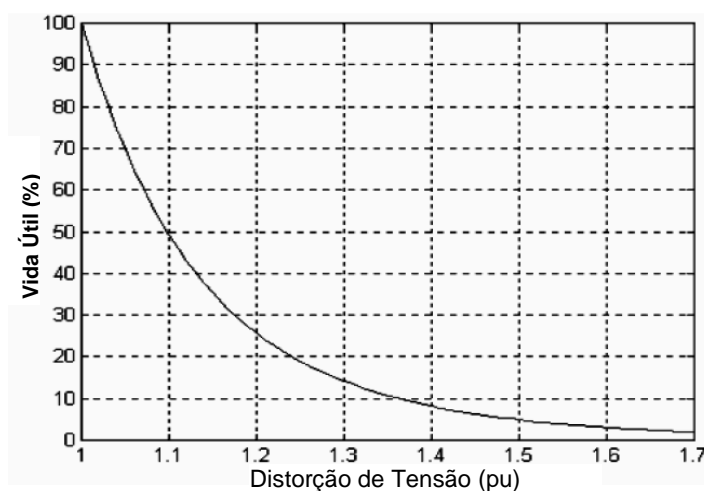


Figura 3.5.2.3. - Diminuição da vida útil de capacitores sobre o efeito de distorção harmônica.
Fonte: DUGAN et al., 1996.

Mesmo sem uma condição de ressonância, um capacitor é sempre um caminho de baixa impedância para as correntes harmônicas, e estará constantemente sujeito à sobrecarga e sobreaquecimento excessivo. Em decorrência desta sobretensão, tem-se uma degradação do isolamento das unidades capacitivas, e causando muitas vezes, a queima dos capacitores.

Com isso, consumidores conectados ao mesmo ponto deste distúrbio, ficam submetidos a tensões perigosas, correndo os mesmos riscos, independentemente de não serem portadores de cargas poluidoras em sua instalação.

Os efeitos deste distúrbio podem ser minimizados com a utilização de:

- Filtros de harmônicos;
- Reatores de linha;
- Melhorias na fiação e no aterramento; e
- Transformadores de isolamento.

3.5.3. Distorção Inter-harmônica

Os inter-harmônicos são definidos pela IEC-1000-2-1 como sendo componentes de frequência não múltiplas inteiras da frequência fundamental observada entre duas ordens harmônicas consecutivas, tanto para formas de onda de tensão como para formas de onda de corrente. A presença destes componentes faz com que o sinal seja periódico não em um ciclo de frequência, mas com um ciclo dependente de todas as frequências que o compõem.

Os inter-harmônicos podem ser encontrados em redes de diferentes classes de tensão e são diferenciados dos harmônicos de rede por possuírem frequência múltiplas não inteiras da fundamental (50 – 60 Hz). Podem aparecer como frequências discretas ou como uma larga faixa espectral.

As principais fontes deste tipo distúrbio são:

- Conversores estáticos de potência;
- Motores de indução filtros ativos;
- Drivers lineares de motores ou dispositivos à base de arco voltaico; e
- Cicloconversores.

Os cicloconversores podem ser vistos como casos especiais de circuitos conversores estáticos de frequência que fornecem em sua saída uma tensão CA uma frequência diferente da entrada. Tais dispositivos efetuam a conversão da tensão CA/DC através de um retificador e depois DC/CA através de um inversor. A tensão DC é modulada pela frequência de saída gerando correntes inter-harmônicas na entrada do dispositivo que acabam por contaminar a rede (BOLLEN, 2000). As recomendações e análises para inter-harmônicas são as mesmas das harmônicas.

Os sinais carrier (sinal superposto ao sinal de tensão utilizado para transmissão de informações) em linhas de potência também podem ser considerados como inter-harmônicos (DUGAN et al., 1996).

Inter-harmônicos com frequência inferior a frequência dos SEP são denominados sub-harmônicos e são geralmente tratados separadamente, já que suas presenças causam problemas específicos.

Na Figura 3.5.3. é mostrada uma típica forma de onda sobre a influência de inter-harmônico.




Figura 3.5.3. - Forma de onda com distorções inter-harmônicas.

Os inter-harmônicos, como os harmônicos de rede, afetam o funcionamento dos mais diversos equipamentos e dispositivos eletrônicos em praticamente todas as áreas da atividade humana. Seus efeitos podem ser minimizados com as mesmas precauções.

3.5.4. Notching

Notching ou Cunha de Tensão representa o afundamento abrupto da tensão que ocorre em cada alternância, podendo ou não cair a zero ou mudar de sinal. É causada basicamente por conversores de energia trifásicos que proporcionam curto-circuito

momentâneo entre fases, por exemplo, na comutação entre braços de um retificador de onda completa a diodos.

Tal distúrbio de tensão também pode ser causado pela operação normal de equipamentos de eletrônica de potência quando a corrente é comutada de uma fase para outra, podendo ser detectado através do conteúdo harmônico da tensão afetada.

As componentes de frequência associadas com os notching's são de alto valor e, desta forma, não podem ser medidas pelos equipamentos normalmente utilizados para análise harmônica (DUGAN et al., 1996).

A Figura 3.5.4 mostra a forma com que o *notching* se manifesta.




Figura 3.5.4. - Típica forma de onda com distorção notching.

Este tipo de distúrbio pode ter efeitos como:

- Má operação de equipamentos mais sensíveis;
- Perda ou alteração de dados digitais; e
- Impacto econômico por parada de produção.

Podendo ser evitados com a separação dos circuitos e a substituição dos equipamentos geradores.

3.5.5. Ruídos Elétricos

Basicamente, os ruídos elétricos ou *Noises* (do inglês) consistem de uma distorção indesejada no sinal elétrico que não pode ser classificado como distorção harmônica ou como transitório. Os ruídos são distorções na tensão senoidal, através da superposição de um sinal de alta frequência (da ordem de MHz).

Podem ser classificados em dois tipos de ruídos:

- Ruído de Modo Comum – *Common Mode Noise*: Diferença da tensão que ocorre entre o condutor neutro e terra.
- Ruído de Modo Normal – *Normal Mode Noise*: Diferença da tensão que ocorre entre o condutor fase e neutro.

Ruído pode ser definido como um sinal elétrico indesejado, contendo uma larga faixa espectral com frequências inferiores a 200 kHz, as quais são superpostas às tensões ou correntes de fase, ou encontradas em condutores de neutro, como mostrado na Figura 3.5.5.




Figura 3.5.5. - Forma de onda de tensão alternada senoidal com presença de ruído.

Os ruídos em um sistema de potência podem ser causados por equipamentos de eletrônica de potência, circuitos de controle, equipamentos a arco, retificadores a estado sólido e fontes chaveadas e, via de regra, estão relacionados com aterramentos mal feitos ou impróprios.

A amplitude típica de um ruído é inferior a 1% da tensão fundamental, possuindo uma faixa de frequência e nível de amplitude dependendo da fonte que produz o ruído e das características do sistema (IEEE, Std. 1159, 1995).

Tal distúrbio pode causar mau funcionamento e/ou queima de equipamentos eletrônicos tais como microcomputadores e controladores programáveis, assim como a perda ou alteração de dados digitais.

O problema pode ser minimizado, com as seguintes medidas:

- Utilização de filtros e transformadores isoladores;
- Separação física da fonte geradora e prejudicada;
- Aterramento correto e equalização de potenciais, entre outros.

As distorções da forma de onda podem ser classificadas, segundo a magnitude de tensão, conforme mostra a tabela 3.5.5.

Tabela 3.5.5. - Classificação de Distorção da Forma de Onda. Fonte: IEEE Std. 1159-1995

Distorção da Forma de Onda	Duração Típica	Magnitude de Tensão Típica
Desvio do Nível CC	Regime Permanente	0 - 0,1 %
Distorção Harmônica	Regime Permanente	0 - 20 %
Inter-harmônico	Regime Permanente	0 - 2 %
Corte de Tensão (<i>Notching</i>)	Regime Permanente	
Ruído Elétrico	Regime Permanente	0 - 1 %

3.6. FLUTUAÇÕES OU OSCILAÇÕES DE TENSÃO

As flutuações de tensão correspondem a variações sistemáticas dos valores eficazes da tensão de suprimento dentro da faixa compreendida entre 0,95 e 1,05 pu (IEEE Std. 1159-1995). Tais flutuações são geralmente causadas por cargas industriais e se manifestam de diferentes formas, tais como:

- Flutuações Aleatórias: A principal fonte destas flutuações são os fornos a arco, onde as amplitudes das oscilações dependem do estado de fusão do material e do nível de curto-circuito da instalação.
- Flutuações Repetitivas: Dentre as principais causas destes tipos de flutuações estão:
 - Máquinas de solda;
 - Laminadores;
 - Elevadores de minas; e
 - Ferrovias.
- Flutuações Esporádicas: A fonte causadora destas flutuações é a partida direta de grandes motores.

Os principais efeitos nos sistemas elétricos, resultados das oscilações causadas pelos equipamentos mencionados anteriormente são oscilações de potência e torque das máquinas elétricas, queda de rendimento dos equipamentos elétricos, interferência nos sistemas de proteção, e cintilação luminosa (*flicker*, em inglês).

O fenômeno mais comumente causado pelas flutuações de tensão é a cintilação luminosa, sendo o mais perceptível ao olho humano pelo seu desconforto visual causado. A intensidade deste fenômeno está diretamente associada à duração do distúrbio (ciclo de operação) e à amplitude das oscilações.

O fenômeno de cintilação luminosa, ou efeito *flicker* é basicamente a existência de pequenas, mas repetitivas quedas de tensão que são causadas por elevadas cargas que solicitam altas correntes por breves, mas repetitivos, períodos de tempo e é constatado através da impressão visual resultante das variações do fluxo luminoso de lâmpadas, principalmente as do tipo incandescentes.

Na faixa de frequências de operação de 0 a 30 Hz, o olho humano é extremamente sensível às variações da emissão luminosa das lâmpadas, sendo que a máxima sensibilidade do olho é em torno de 10 Hz.

Uma forma de onda típica contendo flutuação de tensão é mostrada, a seguir, na Figura 3.6.




Figura 3.6. - Forma de onda com a presença de flutuação de tensão.

Como a variação da potência elétrica associada ao fenômeno de cintilação é bastante baixa (da ordem de 0,3% da potência nominal da lâmpada) pode-se suspeitar que o efeito de cintilação também possa ser provocado pela simples variação do conteúdo harmônico de uma carga do tipo não-linear. Nesse caso, o fenômeno ocorreria mesmo sendo a tensão fundamental constante.

Entre as causas deste distúrbio podemos citar as cargas com ciclo variável, nas linhas que alimentam fornos a arco, máquinas de solda e onde cargas pesadas são manobradas constantemente.

As medidas efetivas para eliminação desse problema incluem:

- Separar cabos de cargas pesadas, alimentando cada carga pesada por um transformador individual;
- Divisão das cargas;
- Aumento dos tempos de atraso nos sistemas de controle automáticos;
- Redução da taxa de repetição do ciclo de trabalho; e
- Distribuição racional das operações que requerem pulsos de demanda, junto com a instalação de um compensador estático de potência reativa.

As flutuações de tensão são classificadas, segundo a magnitude de tensão, conforme mostra a Tabela 3.6.

Tabela 3.6. - Classificação de Flutuação de Tensão. Fonte: IEEE Std. 1159-1995.

Categoria	Duração Típica	Magnitude de Tensão Típica
Flutuação de Tensão	Intermitente	0,1 - 7 %

3.7. RESUMO DOS TIPOS DE DISTÚRBIOS

É apresentada, a seguir, a Tabela 3.7 contendo os tipos de distúrbios abordados nesta seção. Apresentam-se, ainda suas principais causas, efeitos e algumas soluções.

Tabela 3.7. - Resumo dos tipos de distúrbios.

Distúrbio	Descrição	Principais Causas	Principais Efeitos	Algumas Soluções
Fenômenos Transitórios				
Transitórios Impulsivos	- Alteração repentina nas condições de regime permanente da tensão, corrente ou em ambas.	- Descargas atmosféricas; - Chaveamento de cargas.	- Excitação de circuitos ressonantes; - Redução da vida útil de motores, geradores, transformadores, etc.	- Filtros; - Supressores de surto; - Transformadores isoladores.
Transitórios Oscilatórios	- Alteração súbita nas condições de regime permanente da tensão e/ou corrente contendo valores de polaridade positiva e negativa.	- Corte de corrente indutiva; - Chaveamentos de capacitores, linhas, cabos, cargas e transformadores.	- Mau funcionamento de equipamentos controlados eletronicamente, conversores de potência, etc.; - Redução da vida útil de motores, geradores, transformadores, etc.	- Filtros; - Supressores de surto; - Transformadores isoladores.
Variação de Tensão				
Interrupção (<i>outage</i>)	- Curta duração: tensão decresce para um valor menor que 0,1 pu por um período menor que 1 minuto. - Longa duração (sustentada): Interrupção por mais de 1 minuto.	- Curto-circuito; - Descargas atmosféricas; - Manutenção na rede, programada ou não.	- Queda do sistema; - Falha de equip. eletrônicos e de iluminação; - Danificação de componentes; - Desligamento de equipamentos; - Interrupção do processo produtivo ;	- UPS; - Geradores de emergência (interrupções de longa duração)

Subtensão (<i>sag</i>) e Sobretensão (<i>swell</i>)	<ul style="list-style-type: none"> - Variação de tensão de curta duração (VTCD): meio ciclo até 3 segundos. - Variação de tensão de longa duração (VTLD): Interrupção por mais de 1 minuto. 	<ul style="list-style-type: none"> - Partida de grandes equipamentos; - Curtos-circuitos; - Falha em equipamentos ou manobras da concessionária; - Variações de cargas; - Chaveamento de banco de capacitores; - Equipamentos e fiação sobrecarregados; - Utilização imprópria de transformadores; - Fiação subdimensionada ou conexões mal feitas. 	<ul style="list-style-type: none"> - Redução de índice de iluminação para os circuitos de iluminação incandescente; - Perda de dados e erros de processamento; - Desligamento e danos de equipamen.; - Oscilações e sobreaquecimento em motores e lâmpadas; - Redução de vida útil ou de eficiência de equipamentos; - Falha de operação de dispositivos. 	<ul style="list-style-type: none"> - UPS; - Reguladores de tensão; - Instalação de compensadores estáticos de reativos, como os capacitores, para mudanças bruscas de cargas; - Verificação de conexões e fiações elétricas; - Transferência de equipamentos para outros circuitos.
Distorções da Forma de Onda				
Nível de Corrente Contínua (CC).	<ul style="list-style-type: none"> - Presença de tensão ou corrente CC em um sistema elétrico CA. 	<ul style="list-style-type: none"> - Operação ideal de retificadores de meia onda, etc. 	<ul style="list-style-type: none"> - Saturação de transformadores; - Corrosão eletrolítica de eletrodos de aterramento e de outros conectores. 	
Harmônicos	<ul style="list-style-type: none"> - Alteração do padrão normal de tensão, causada por frequências múltiplas da fundamental (50-60Hz). 	<ul style="list-style-type: none"> - UPS, reatores eletrônicos, inversores de frequência, retificadores e outras cargas não-lineares. 	<ul style="list-style-type: none"> - Sobreaquecimento de cabos e equipam. - Diminuição da performance de motores; - Operação errônea de disjuntores, relés e fusíveis; - Danos de capacitores, etc. 	<ul style="list-style-type: none"> - Filtros de harmônicas; - Reatores de linha; - Melhorias na fiação e no aterramento; - Transformadores de isolamento.
Inter-harmônicos	<ul style="list-style-type: none"> - Componentes de frequência não múltiplos inteiros da frequência fundamen. observadas entre duas ordens harmônicas consecutivas. 	<ul style="list-style-type: none"> - Conversores estáticos de potência; - Cicloconversores; - Motores de indução; - Equipamentos a arco, etc. 	<ul style="list-style-type: none"> - Interferência na transmissão de sinais <i>carrier</i>; - Indução de <i>flicker</i> visual no <i>display</i> de equipamentos. 	<ul style="list-style-type: none"> - O mesmo dos harmônicos.
<i>Notching</i>	<ul style="list-style-type: none"> - Afundamento abrupto da tensão que ocorre em cada alternância podendo ou não cair a zero ou mudar de sinal. 	<ul style="list-style-type: none"> - Conversores de energia trifásicos que proporcionam curto-circuito momentâneo entre fases; - Equipamentos de eletrônica de potência quando a corrente é comutada de uma fase para outra. 	<ul style="list-style-type: none"> - Má operação de equipamentos mais sensíveis; - Perda ou alteração de dados digitais; - Impacto econômico por parada de produção. 	<ul style="list-style-type: none"> - Separação dos circuitos; - Substituição dos equipamentos geradores.
Ruídos	<ul style="list-style-type: none"> - Sinal indesejado de alta frequência que altera o padrão normal de tensão (onda senoidal). 	<ul style="list-style-type: none"> - Interferência de ondas de rádio e TV; - Operação de equip. eletrônicos; - Chaveamento de equip. eletrônicos de potência; - Radiações eletromagnéticas. 	<ul style="list-style-type: none"> - Travamentos, perda de dados e erros de processamento; - Recepções distorcidas (áudio e vídeo); - Distúrbios em equipamentos eletrônicos. 	<ul style="list-style-type: none"> - UPS; - Transformadores de isolamento; - Filtros de linha; - Aterramento das instalações.

Flutuação ou Oscilação de tensão				
Aleatórias, Repetitivas e Esporádicas.	- Variação sistemática da tensão dentro da faixa de 0,95 e 1,05pu.	- Máquinas de solda; - Laminadores; - Elevadores de minas; - Ferrovias; - Partida direta de grandes motores.	- Cintilação luminosa (flicker); - Oscilações de potência e torque das máquinas elétricas; - Queda de rendimento dos equipamentos elétricos; - Interferência nos sistemas de proteção	- Separação de cabos de cargas pesadas; - Divisão das cargas; - Aumento dos tempos de atraso nos sistemas de controle automáticos; - Redução da taxa de repetição do ciclo de trabalho; - Distribuição racional das operações; - Compensador estático de potência reativa.

CAPÍTULO 4

LÓGICA FUZZY

4.1. Introdução

Neste capítulo serão abordados somente os conceitos estritamente usados nesta tese. A teoria completa pode ser acompanhada em outras referências, por exemplo, (ROSS, 2004). O número de textos (livros, artigos, etc.), disponibilizados na literatura é bastante volumoso e diversificado. Assim, visando a objetividade, o conteúdo aqui apresentado constitui a medida justa, sem excesso ou falta, de informações necessárias à compreensão do sistema *neuro-fuzzy-wavelet* proposto para a realização da detecção e classificação de distúrbios de tensão em sistemas elétricos de potência.

A lógica *fuzzy* (ZADEH, 1965) ou lógica nebulosa (teoria das possibilidades) pode ser a base para geração de técnicas poderosas para a solução de problemas, com uma vasta aplicabilidade, especialmente, nas áreas de controle e tomada de decisão, pois pode representar informações imprecisas. Diferentemente da lógica clássica, onde uma proposição lógica tem dois extremos ou “completamente verdadeiro” ou “completamente falso”, na lógica *fuzzy*, uma premissa varia em grau de verdade de 0 a 1, o que a torna parcialmente verdadeira ou parcialmente falsa.

Assim, a “força” da lógica *fuzzy* provém da sua habilidade em inferir conclusões e gerar respostas baseadas em informações vagas, ambíguas, incompletas ou imprecisas (DASH et al., 2000). Neste aspecto, os sistemas de base *fuzzy* têm habilidade de raciocinar de forma semelhante aos humanos.

A lógica *fuzzy* encontra aplicações nas mais diversas áreas, como por exemplo: inteligência artificial, reconhecimento de padrão, otimização, processamento de imagens, tomada de decisões, etc.

4.2. Conjuntos Nebulosos e Operadores Lógicos

Um conjunto nebuloso A em X , coleção de objetos, é definido como sendo o conjunto de pares ordenados:

$$A = \{(x, \mu_A(x)) \mid x \in X\}$$

Sendo, $\mu_A(x)$ o valor da função de pertinência do conjunto nebuloso A correspondente ao elemento x .

Os operadores usados na lógica *fuzzy* são *and* (\wedge), *or* (\vee) e *not* (\neg). São conhecidos como operadores de relação. Na lógica nebulosa eles são usados para definir o grau máximo e mínimo de pertinência dos conjuntos (CARPENTER et al., 1992) Assim, tem-se:

$$A \wedge B = \min(A, B)$$

$$A \vee B = \max(A, B)$$

$$\neg A = 1 - A$$

Sendo:

\wedge : operador que representa a interseção dos dois conjuntos ($A \cap B$);

\vee : operador que representa a união dos dois conjuntos ($A \cup B$)

\neg : operador que representa o complemento de um conjunto (A') como representado na Figura 4.2.1.




Figura 4.2.1. - Representação dos conjuntos *fuzzy*. (a) Conjunto A, (b) Conjunto B, (c) Conjuntos $A \cap B$ e $A \cup B$.

A função de pertinência pode ser definida como sendo uma representação gráfica da magnitude de participação de cada entrada. Ela associa um peso para cada valor de entrada processada, definindo, assim, uma superposição funcional entre as entradas e determinando uma resposta para a saída.

As funções de pertinência nebulosas podem ter diferentes formas associadas com cada entrada e resposta de saída. A mais utilizada é a função de pertinência triangular. No entanto, outras funções de pertinência (trapezoidal, gaussiana e exponencial), podem ser também usadas de acordo com a preferência ou experiência do projetista. O grau de pertinência é determinado pela projeção vertical do parâmetro de entrada do eixo horizontal no limite mais alto da função de pertinência, o qual tem valores compreendidos entre 0 e 1 (KARTALOPOULOS, 1996), como mostrado na Figura 4.2.2.

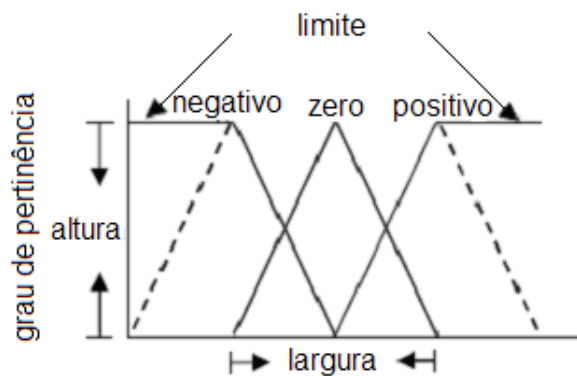


Figura 4.2.2. - Funções de pertinência nebulosa.

4.3. Sistemas Nebulosos

Os problemas complexos, normalmente, exigem soluções complexas que necessitam de tempo e esforço proporcional ao grau de complexidade. Os sistemas nebulosos empregam soluções simples para resolver estes tipos de problemas, pois, em vez de controlar e/ou modelar um processo através do uso de relações complicadas entre as variáveis, o sistema nebuloso leva em conta o controle e/ou modelagem do processo através do uso de um conjunto simples de vários tipos de regras de senso comum (LOESCH; SARI, 1996).

O controle nebuloso segue as etapas mostradas a seguir (Figura 4.3.).

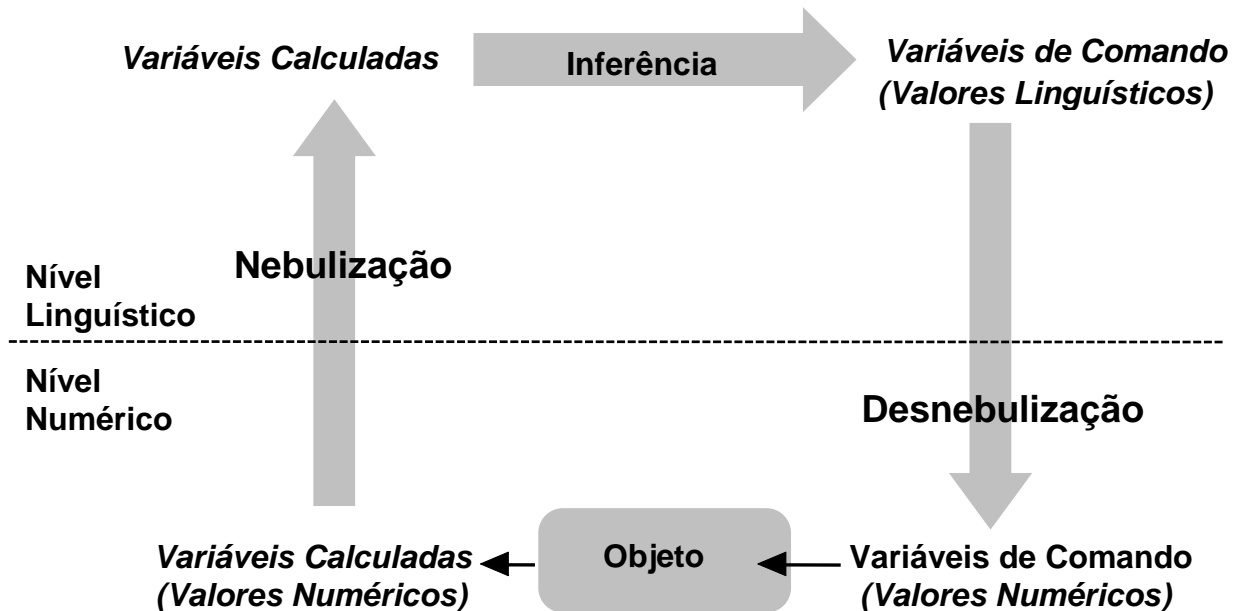


Figura 4.3. - Etapas de um sistema nebuloso.

A teoria de conjuntos nebulosos tem sido agregada aos sistemas de redes neurais, chamadas de redes nebulosas ou sistemas neuro-*fuzzy*, aumentando, assim, a capacidade de aprendizado através de interface com dados numéricos (SILVEIRA et al., 2003). Informações imprecisas, vagas, incertas, qualitativas, comunicações verbais, capacidade de aprendizado e formulação de estratégias de tomadas de decisão, são características humanas. Portanto, a teoria *fuzzy* e as redes nebulosas são frequentemente referidas como “inteligentes”, em consequência do fato de emularem a inteligência humana.

CAPÍTULO 5

REDES NEURAIS ARTIFICIAIS

5.1. Introdução

Neste capítulo será apresentada uma revisão sobre redes neurais artificiais, sendo abordado os principais conceitos envolvendo os modelos artificiais, mas sobretudo, dando ênfase às redes ART-descendentes que são a base da rede ARTMAP *Fuzzy*. Tal destaque se fundamenta no fato desta rede ser utilizada no processo de classificação dos distúrbios detectados. Assim, serão abordados os seus principais conceitos, sua estrutura e funcionamento.

5.2. Rede Neural Artificial

Rede Neural Artificial (RNA) é uma vertente da Inteligência Artificial que são inspiradas na própria natureza das redes de neurônios e sinapses biológicas. Elas aparecem para a computação como um novo paradigma de programação, baseada em exemplos, não necessitando de algoritmo explícito, aproveitando a potencialidade das RNA's como entidades flexíveis à generalização, efetivando inferências corretas mesmo para dados não vistos, anteriormente, pela rede. Elas são um paradigma computacional que insere o paralelismo em seu processamento, onde cada neurônio pode ser considerado uma entidade que executa certo processamento (VIEIRA et al., 2003).

Do ponto de vista estrutural, as redes neurais podem ser classificadas como estática, dinâmica ou *fuzzy*, constituída ainda de uma única camada ou múltiplas camadas. Além disso, algumas diferenças computacionais surgem também quando se trata da maneira

com que são feitas as conexões existentes entre os neurônios. Estas conexões podem ser estritamente no sentido de ida, no sentido de ida e volta, lateralmente conectadas, topologicamente ordenadas ou híbridas (CARPENTER; GROSSBERG, 1992).

As redes neurais têm sua arquitetura, basicamente, organizada em camadas, com unidades que podem estar conectadas às unidades da camada anterior ou posterior. Usualmente, as camadas são classificadas em três grupos: camada de entrada, onde os padrões são apresentados à rede; camadas intermediárias ou escondidas, onde é feita a maior parte do processamento através das conexões ponderadas; e, camada de saída, onde o resultado final é concluído e apresentado (CARPENTER; GROSSBERG, 1987a).

Outra maneira de classificação das redes ocorre pela arquitetura em que foram implementadas. Neste caso, elas podem ser classificadas como redes não-recorrentes ou *feedforward* de camada única, redes não-recorrentes ou *feedforward* multicamadas e redes recorrentes.

A principal propriedade das redes neurais é a habilidade de aprender e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes de valores aplicados a seus pesos (conexões sinápticas) que corresponde ao treinamento. Esse treinamento pode ser da seguinte forma (WERBOS, 1974):

- Treinamento Supervisionado: Consiste no ajuste de pesos de uma rede neural para fornecer saídas desejadas, considerando-se o conjunto de padrões de entrada.
- Treinamento Não-Supervisionado: Consiste no ajuste de pesos de uma rede neural levando-se em conta somente o conjunto de padrões de entrada.
- Treinamento Híbrido: Combina treinamento supervisionado e treinamento não-supervisionado. Parte dos pesos são ajustados através do treinamento supervisionado, enquanto outros são obtidos através de treinamento não-supervisionado.

O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas. Existem diversos algoritmos para efetuar a aprendizagem de redes neurais artificiais (Regra de Hebb, Retropropagação, etc.). Assim como, vários tipos de

RNA's (MLP - *Multi Layer Perceptron*, SOM - *Self Organizing Map*, ART, etc.) e suas variações sendo utilizadas nas mais variadas aplicações.

5.1. Redes ART

Os modelos neurais ART (*Adaptive Resonance Theory*) (CARPENTER; GROSSBERG, 1987a) englobam uma grande variedade de redes neurais artificiais baseadas na neurofisiologia, e são definidas, em relação ao seu algoritmo de treinamento, em termos de equações diferenciais detalhadas e consideradas como modelos plausíveis dos neurônios biológicos.

Esse tipo de rede neural foi proposta inicialmente por Stephen Grossberg, nos anos 70, que desenvolveu na Teoria da Ressonância Adaptativa (ART) (GROSSBERG, 1976), um número de hipóteses sobre os princípios que governam os sistemas neurais biológicos. Foi uma resposta para as questões sobre o dilema “estabilidade x plasticidade”. Mostrando como um sistema treinado pode permanecer adaptativo a cada nova informação e ainda permanecer estável em resposta a informações irrelevantes, preservando seu conhecimento já adquirido e ao mesmo tempo sendo flexível o suficiente para armazenar novas informações.

Esse dilema é resolvido com um mecanismo de vigilância que administra a inclusão de novas entradas em cada grupo. Uma regra de similaridade, que define onde agrupar um padrão é determinado por um grau de semelhança entre um padrão previamente armazenado.

Em uma rede baseada na teoria da ressonância adaptativa, as informações são trocadas entre as camadas da rede. O treinamento é realizado quando ocorre ressonância da atividade neural, ou seja, quando um padrão já treinado é apresentado e a rede o reconhece; e quando um novo padrão de entrada é apresentado e a rede percebe que o padrão constitui uma nova informação e, então, entra em estado ressonante para memorizá-lo.

Essa teoria serviu de base para o trabalho de Carpenter e Grossberg (CARPENTER; GROSSBERG 1987a) que desenvolveram três classes de arquiteturas ART: ART1, ART2, e ART3. Essas são implementações neurais de algoritmos auto-organizáveis de padrões. Apresenta-se na Figura 5.1, um organograma da família das redes neurais ART e descendentes.

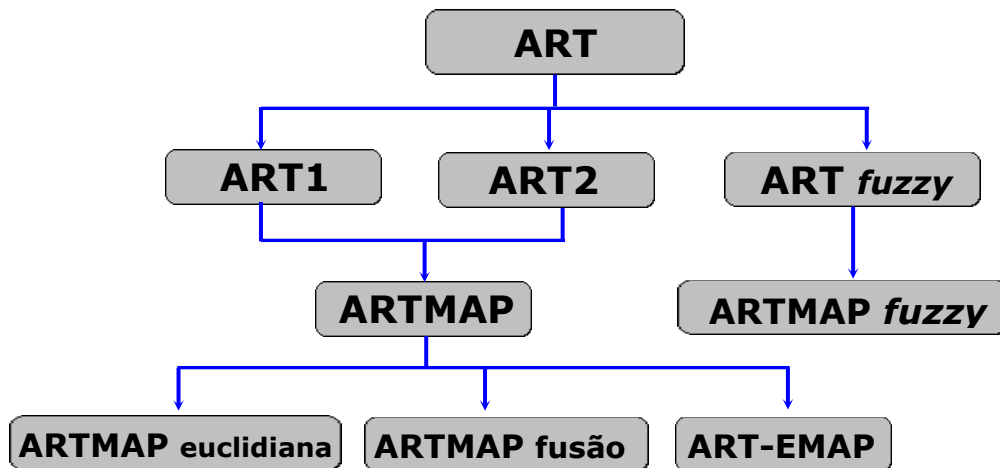


Figura 5.1. - Algumas das principais redes neurais da família ART disponíveis na literatura especializada.

Várias pesquisas estão sendo realizadas no sentido de melhorar as propriedades de generalização destas arquiteturas, tornando-as mais eficientes tanto no sentido de rapidez de processamento da rede quanto de precisão de resultados, visando adaptar-se aos problemas que pretendem resolver e maximizar o seu desempenho.

5.1.1 - Principais Características e Fundamentos

Na atividade de reconhecimento de padrões, quando uma certa entrada não se assemelha a nenhum dos agrupamentos (*clusters*) existentes, um novo cluster é criado para tal entrada. Essa característica pode comprometer a estabilidade da rede, ou seja, quando uma nova aprendizagem ocorre, os padrões já treinados anteriormente são prejudicados podendo ocorrer a perda da capacidade de reconhecer os padrões antigos.

A rede ART é um sistema que auto-organiza padrões de entrada em categorias de reconhecimento, mantendo um equilíbrio entre as propriedades de plasticidade e de estabilidade. A propriedade da plasticidade define a habilidade da rede em criar novas categorias de reconhecimento, quando padrões estranhos estimulam a rede ART. A propriedade da estabilidade é responsável pela capacidade em agrupar padrões similares na mesma categoria de reconhecimento.

Esse problema pode ser resolvido com um mecanismo de vigilância que administra a inclusão de novas entradas em cada grupo. Uma regra de similaridade, que define onde agrupar um padrão é determinada por um grau de semelhança entre um padrão previamente armazenado.

A rede ART é um sistema de aprendizagem competitivo não-supervisionado que auto-organiza categorias em resposta a sequências arbitrárias de padrões de entrada, em tempo real, para reconhecimento de padrões. Tendo como característica importante a combinação de padrões, onde o padrão de entrada atual é comparado com uma representação de categoria selecionada.

No treinamento, um padrão é inserido na rede através da camada de entrada, codificado e passado para a camada de saída com as conexões de pesos da rede de filtragem adaptativa. Nela inicia-se a dinâmica do sistema com o treinamento competitivo.

As redes neurais da família ART apresentam algumas dificuldades operacionais: razoável sensibilidade aos parâmetros da rede (parâmetro de vigilância, etc.) e a precisão das análises. Os efeitos da sensibilidade paramétrica têm sido resolvidos, ou atenuados, através do emprego de novas concepções de treinamento e de arquitetura das redes neurais ART (CARPENTER et al., 1991a). Igualmente, várias propostas têm sido apresentadas na literatura especializada visando sanar o problema da imprecisão. Grande parte da imprecisão decorre em consequência, principalmente, do mecanismo de escolha de categorias e do teste de vigilância que necessita de aperfeiçoamento.

5.1.2 – Estrutura da Rede Neural ART

A arquitetura da rede ART é formada por dois subsistemas principais: o subsistema de atenção e o subsistema de orientação, os quais atuam em um mecanismo de *reset* (Figura 5.1.2.). Estes subsistemas, juntos, implementam a verificação de similaridade, entre o padrão apresentado e um padrão já representado por algum neurônio já treinado, e habilita ou não o treinamento ou retreinamento de um determinado neurônio (CARPENTER et al., 1991a).

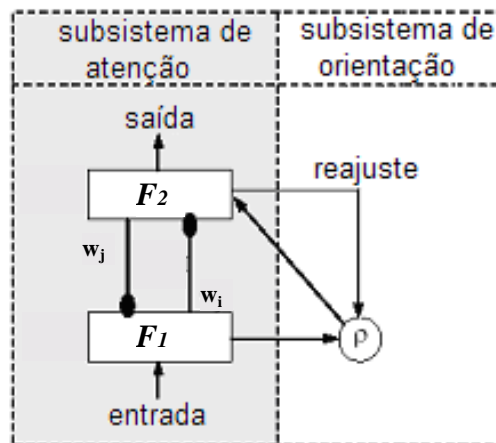


Figura 5.1.2. - Arquitetura básica de uma rede ART.

O subsistema de atenção consiste de dois campos de neurônios: F_1 , que processa os dados de entrada e F_2 , que agrupa os padrões de treinamento em categorias de reconhecimento, em que cada campo pode consistir de várias camadas de neurônios. Tais campos são conectados com pesos de conexão do tipo *feedforward* (w_i) e *feedback* (w_j) que são responsáveis pelo armazenamento das informações através de um processo que envolve a escolha da categoria, critério de equalização e treinamento. O subsistema de orientação é controlado por um parâmetro de vigilância (ρ), que determina se um padrão de entrada pode ser incluído em uma das categorias existentes. Os neurônios da camada F_2 , camada que representa as categorias de reconhecimento, são de dois tipos: comprometidos e descomprometidos (ou livres). Os nós comprometidos são aqueles que armazenam as informações dos padrões já apresentados à rede, representando categorias reais, e os nós descomprometidos são os nós vazios que representam a memória “em branco” da rede (CARPENTER et al., 1991a).

O processo de classificação da rede ART consiste de quatro fases principais: reconhecimento, comparação, busca e treinamento (GROSSBERG, 1976), como a seguir:

Reconhecimento: Cada neurônio do campo F_1 (camada de entrada) recebe sinais de baixo para cima do vetor de entrada e de cima para baixo do campo F_2 (camada de saída, que representa a categoria ativa). A atividade é calculada e o vetor resultante é comparado com todos os vetores de pesos já armazenados na rede (memória) para encontrar o que mais se assemelha ao padrão de entrada atual. O neurônio do campo F_2 , com maior valor de ativação, é

selecionado como provável categoria para armazenar o novo padrão. O neurônio selecionado envia ao campo F_1 seu protótipo;

Comparação : Nesta fase acontece um mecanismo de reajuste, que é responsável por testar a similaridade entre o vetor de entrada e o vetor de comparação, z , que é o vetor resultante da atividade calculada no campo F_1 mediante o vetor protótipo dado pelo campo F_2 após a fase de reconhecimento. A maneira pela qual se define de que modo a comparação irá ocorrer é definida por um parâmetro chamado *vigilância* (ρ), que determina se um padrão de entrada pode ser incluído em uma das categorias existentes. Se o valor da comparação for maior do que ρ , então o padrão de entrada é incluído na categoria ativa, caso contrário, a rede entra em fase de busca;

Busca : Durante esta fase, a rede procura um novo neurônio do campo F_2 para representar o vetor de entrada atual. O neurônio da camada de saída rejeitado na fase de comparação anterior é desabilitado nesta seleção. O vetor de entrada é rerepresentado, e a rede entra novamente na fase de comparação, que termina com o teste no mecanismo de reajuste para determinar a similaridade entre o novo protótipo escolhido e o vetor de entrada atual. Este processo é repetido, desabilitando neurônios da camada de saída, até encontrar um neurônio de saída que melhor se assemelhe ao vetor de entrada corrente, dentro dos limites do parâmetro de vigilância ρ . Se nenhum neurônio de saída for encontrado, o vetor de entrada é então considerado de uma classe desconhecida, sendo alocado um neurônio de saída que não esteja associado ainda a nenhuma categoria para representá-lo;

Treinamento : O algoritmo de aprendizado da rede ART é não-supervisionado e pode ser ativado a qualquer momento, permitindo que a rede aprenda novos padrões continuamente.

Há dois tipos de treinamento para a rede neural ART: aprendizado rápido e aprendizado lento. No aprendizado rápido, os pesos de conexão são ajustados para seus valores ótimos em poucos ciclos, geralmente em apenas um ciclo de treinamento. No

aprendizado lento, os pesos são ajustados lentamente em vários ciclos de treinamento, possibilitando um ajuste melhor dos pesos da rede aos padrões de treinamento (GROSSBERG, 1976).

As redes ART são muito sensíveis a variações em seus parâmetros durante o treinamento. O parâmetro mais crítico é o parâmetro de vigilância (ρ) que controla a resolução do processo de classificação. Se ρ assume um valor baixo, a rede permite que padrões não muito semelhantes sejam agrupados na mesma categoria de reconhecimento, criando poucas classes, e se for atribuído um valor alto (muito próximo a um), pequenas variações nos padrões de entrada levarão à criação de novas classes.

5.2 – Rede Neural ART1, ART2 e ART Fuzzy

Como a rede ART não é capaz de solucionar todos os problemas (generalidade) é necessário o desenvolvimento (adaptação) de redes específicas. São redes conhecidas como ART-descendentes, dentre elas estão:

5.2.1 - Rede Neural ART1

A arquitetura ART1 foi desenvolvida para realizar agrupamentos de padrões binários, por Carpenter e Grossberg (CARPENTER; GROSSBERG, 1987b), realizando o treinamento não-supervisionado. A partir de então, a arquitetura ART1 tornou-se o mais famoso modelo da família ART, em termos de pesquisa relacionada e aplicações. Sua principal característica é o uso de dados binários como entradas da rede.

Segundo os autores, a arquitetura simplificada da rede neural ART1 envolve três grupos de neurônios: um campo de processamento de entrada F_1 , as unidades de agrupamento camada F_2 , e um mecanismo para controlar o grau de similaridade de padrões colocados no mesmo agrupamento, chamado *reset*. A camada F_1 consiste de duas partes: o registro de

entrada e a interface. A interface, parte superior da camada de entrada chamada de F_{1b} , combina os sinais do registro de entrada e da camada F_2 para efetuar a análise de similaridade entre o sinal de entrada com o vetor de peso do neurônio que foi selecionado como um candidato para o aprendizado. Pode-se chamar de *registro de entrada* da camada F_1 como F_{1a} . A Figura 5.2.1., a seguir, mostra essa arquitetura.




Figura 5.2.1. - Arquitetura de uma rede ART1.

Para controlar a similaridade dos padrões colocados no mesmo agrupamento, há dois grupos de conexões (cada um com os seus próprios pesos) entre cada neurônio da interface do campo de entrada e cada neurônio da camada de ressonância. A camada F_{1b} está conectada à camada F_2 pelos pesos *bottom-up*. O peso *bottom-up* na conexão da i -ésima unidade da camada F_1 para a j -ésima unidade da camada F_2 é designada a_{ij} . A camada F_2 é conectada à camada F_{1b} pelos pesos *top-down*; o peso *top-down* na conexão da i -ésima unidade da camada F_2 para a j -ésima unidade da camada F_{1b} é designada d_{ij} .

A camada F_2 é uma camada competitiva: a unidade de agrupamento contendo a maior entrada de rede se torna a candidata para aprender o padrão de entrada. As ativações de todas as unidades F_2 são estabelecidas em zero. Nesta fase, as unidades de interface combinam a informação da entrada e das unidades da camada F_2 .

A efetivação do aprendizado e consequente incorporação do vetor de entrada ao neurônio candidato escolhido em F_2 depende da similaridade entre um vetor descendente e o vetor de entrada. Esta decisão é tomada pela unidade de *reset*, baseado nos sinais recebidos pelas camadas F_{1a} e F_{1b} . Se o neurônio candidato não é efetivamente escolhido como representativo da categoria do vetor de entrada, é inibido e um novo neurônio de F_2 é

selecionado como novo candidato ao aprendizado. Esta é a terceira fase do treinamento de uma rede ART, chamada etapa de busca.

Finalmente, nota-se que para cada fase do treinamento é requerida uma resposta distinta de cada um dos neurônios das camadas F_{1b} e F_2 . Para que os mesmos consigam distinguir como desempenhar a tarefa adequadamente, existem duas unidades suplementares dotadas de pesos binários (0 para sinal inibitório e 1 para sinal excitatório) e não-atualizáveis que atuam como mecanismos de controle para estas repostas, chamadas Neurônio C_1 e Neurônio C_2 . A unidade C_1 determina o fluxo de dados para a camada F_{1b} , e a unidade C_2 determina o fluxo de dados e habilita os neurônios da camada F_2 . Assim, cada neurônio de F_{1b} e F_2 nas redes ART possui três fontes pelas quais pode ser recebido um sinal:

- F_{1b} pode receber sinais de F_{1a} (sinal de entrada), F_2 (sinal descendente) e da unidade de controle Neurônio C_1 ;
- F_2 pode receber sinais de F_{1b} (sinal ascendente), da unidade de *reset* e da unidade de controle Neurônio C_2 .

A diferença entre o padrão de entrada e o neurônio mais representativo define se haverá aprendizagem ou não. Se o neurônio vencedor não tiver permissão para aprender, este é inibido e um novo neurônio é selecionado como possível candidato.

A estratégia de operação estabelece que primeiro deva haver uma competição entre os nós da camada de saída, usando o princípio usado nas redes multiplicativas, até que somente um nó permaneça ativo. O nó vencedor envia por sua vez um sinal de realimentação para a camada de entrada, possibilitando a esta uma nova ativação. Esta ativação, criada pelo nó vencedor, é chamada de geração de hipótese. É, então, comparada (teste da hipótese gerada) com o sinal de entrada.

Caso a diferença encontrada não exceda um valor predefinido, o nó vencedor é rotulado como o representante do padrão de entrada e este é agrupado ao padrão armazenado. Se a diferença calculada na comparação, entre o valor de entrada e o gerado pelo nó vencedor, exceder um determinado limiar, definido *a priori* através de um parâmetro. Então, o nó vencedor não pode representar a classe a qual pertence o vetor de entrada. Como consequência, o nó vencedor pode ser retirado da lista de nós que possam ser representantes.

Nessa fase, duas atitudes possíveis podem ser tomadas: a primeira baseada na existência de algum nó vencedor ainda na lista de nós, o que permite o ciclo ser recommençado

com a ativação da camada de saída através dos sinais enviados pelos nós da camada de entrada; e a segunda opção, isto é, a de não existir mais nenhum nó que possa ainda ser um nó vencedor. Se isto acontecer deve-se considerar a criação de um novo nó na topologia e fazer aprender o padrão de entrada através da mudança de seus pesos.

5.2.2 - Rede Neural ART2

A rede neural ART2 é uma extensão da rede ART1 para manipular padrões com valores reais (dados contínuos). Essa arquitetura também foi desenvolvida por Carpenter e Grossberg (CARPENTER; GROSSBERG, 1987b). Sua arquitetura pode ser considerada como sendo a mesma da ART1, onde a camada F_1 da rede é constituída de duas partes: uma parte destinada à leitura dos vetores de entrada F_{1a} e outra destinada à interface entre estes vetores e a própria rede F_{1b} .

Esta interface combina sinais recebidos, tanto da leitura dos vetores, quanto da camada F_2 , para efeito de comparação da similaridade entre o sinal de entrada com o vetor de pesos do neurônio selecionado como candidato ao aprendizado. Estes nós podem ser considerados nós auxiliares que pré-processam as entradas, através de uma combinação de operações de normalização dos dados. Isso torna o modelo ART2 adequado ao processamento e classificação de dados analógicos.

Os parâmetros utilizados no algoritmo de treinamento de uma rede ART2, bem como seus respectivos papéis no modelo, são:

- t : número de ciclos do treinamento, ou a quantidade de vezes que um padrão deve ser apresentado à rede até que seja obtida sua classificação;
- n : número de unidades de entrada (camadas F_{1a} e F_{1b});
- m : número de unidades de *cluster* (camada F_2);
- a e b : pesos fixos na camada F_1 ;
- c : peso fixo utilizado no teste de *reset*;
- d : ativação da unidade F_2 vencedora;

- e : parâmetro introduzido para prevenir divisão por zero quando a norma de um vetor de dados de entrada é nula, sendo que seu valor deve ser qualquer número inteiro positivo;
- β : taxa de aprendizagem, sendo que $0 < \beta < 1$; seu valor indica o grau em que os novos padrões pertencentes a cada *cluster* terão na atualização de seus pesos no próximo ciclo de treinamento;
- ρ : parâmetro de vigilância, sendo que $0 < \rho < 1$; este parâmetro determina quantos *clusters* serão formados, em uma razão direta ao valor adotado, o que significa que este parâmetro define o grau de variação entre cada *cluster*.

Pode-se sintetizar que a função do algoritmo da rede ART2 é a de buscar entre os padrões armazenados, correspondentes a cada classe, aquele que melhor se aproxima do padrão que é apresentado na entrada.

Segundo os autores (CARPENTER; GROSSBERG, 1987b) uma desvantagem da rede ART2 é que exemplares categóricos podem mudar com o aprendizado, ou seja, quando um grupo é aceito para receber uma nova entrada seus pesos são modificados e ele passa a ser mais similar ao novo padrão e menos parecido com os padrões aprendidos anteriormente.

5.2.3 - Rede Neural ART Fuzzy

A rede ART nebulosa é uma generalização da rede ART1, essencialmente com a mesma estrutura. A generalização é alcançada usando as operações da teoria de conjuntos nebulosos ao invés das operações da teoria de conjuntos naturais.

Esse tipo de rede tem a arquitetura composta por três camadas:

- F_0 : camada de entrada que é um campo de pré-processamento de neurônios, onde os valores do vetor (linha) de entrada são apresentados à rede após serem normalizados, se necessário, para evitar a proliferação de categorias. Assim, trabalha-se com números binários ou entre 0 e 1. É realizada ainda a codificação de complemento a fim de se preservar a amplitude da informação;

- F_1 : camada de comparação que recebe entradas de F_0 e de F_2 e realiza o teste de vigilância da categoria escolhida para se verificar se houve ressonância (critério de vigilância aceito) ou *reset* e escolha de uma nova categoria;
- F_2 : camada de reconhecimento que armazena as categorias. Nessa camada encontram-se os pesos a serem atualizados e onde são armazenados os resultados.

A camada F_1 possui $2N$ nós (neurônios), enquanto a camada F_2 possui um número variável de nós para acomodar os padrões de entrada em categorias de reconhecimento e realizar o treinamento.

Um modelo da arquitetura da rede ART nebulosa é mostrada na Figura 5.2.2., a seguir:

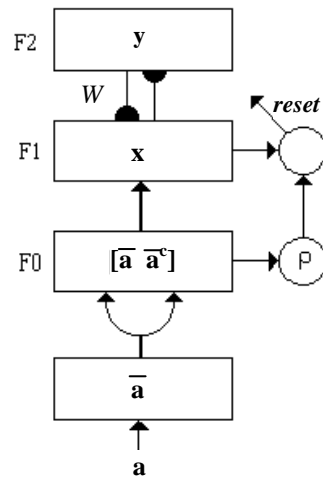


Figura 5.2.2. - Rede neural ART Nebulosa.

Nesta rede, o operador de interseção, que descreve a dinâmica da rede ART, é substituído pelo operador nebuloso $AND(\wedge)$ da teoria de conjuntos nebulosos, na escolha, busca e treinamento, levando a uma versão mais poderosa de rede.

Essa generalização tem como objetivo melhorar o desempenho da rede no que se refere, principalmente, ao tempo de execução do treinamento e no processamento de dados analógicos.

5.3 – Rede Neural ARTMAP e ARTMAP *Fuzzy*

Outros tipos de rede ART-descendente que utilizam a combinação de diferentes redes e incorporam alguns outros conceitos, são:

5.3.1 - Rede Neural ARTMAP

A arquitetura ARTMAP, introduzida mais recentemente, é considerada como uma rede mais sofisticada. É designada para treinar e realizar o mapeamento entre dois espaços de vetores, usando o treinamento supervisionado e auto-organizável.

É um sistema com aprendizado supervisionado capaz de auto-organizar o reconhecimento estável de categorias em respostas aos padrões de entrada arbitrários. É composta por dois módulos ART, foi a primeira arquitetura baseada na teoria da ressonância adaptativa apropriada para a tarefa de classificação, apresentando treinamento supervisionado (CARPENTER et al., 1991b).

Esse tipo de rede é composta por duas sub-redes, ART_a, que recebe e processa um determinado padrão de entrada apresentado, e ART_b, que constitui a resposta desejada para o padrão apresentado à rede que são interligadas por um módulo de memória associativa, denominado Inter-ART, que realiza o mapeamento, como visto na Figura 5.3.1.

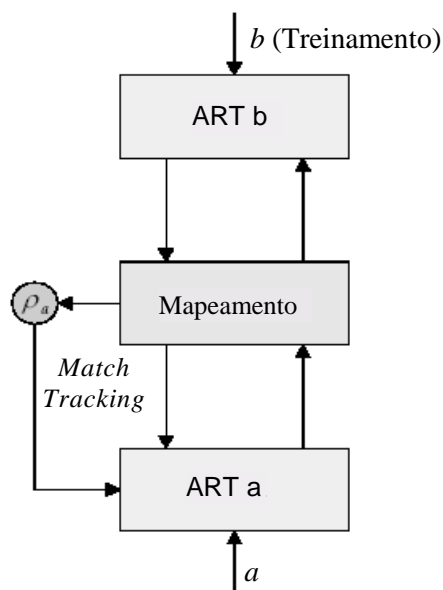


Figura 5.3.1. - Arquitetura básica de uma rede ARTMAP.

O módulo inter-ART é responsável pela verificação se há casamento da entrada (ART_a) e da saída (ART_b). Todas as matrizes de pesos são iniciadas com valores iguais a 1, ou seja, todas as atividades encontram-se inativas. Estas atividades são ativadas à medida que ocorre ressonância entre os padrões de entrada e de saída.

O módulo ART_a aprende a classificar os padrões de entrada apresentados em sua camada e o módulo ART_b desenvolve categorias referentes aos padrões de saída desejado.

Toda vez que os pares de entrada, associados aos módulos ART_a e ART_b , são confirmados, de acordo com o teste do match tracking (processo auto-regulador que maximiza a generalização e minimiza os erros), o par de treinamento será confirmado nas matrizes de pesos, caso contrário deve-se buscar um outro padrão de entrada, até que o critério seja satisfeito.

Após poucas apresentações do conjunto de treinamento, a rede se auto-organiza e obtém a saída esperada para cada entrada sem necessariamente efetuar todo processo de busca.

Baseada na observação que o treinamento da rede ARTMAP leva a diferentes pesos adaptativos e diferentes categorias de reconhecimento para diferentes ordenações de um dado conjunto de treinamento, introduz-se uma estratégia de votação (CARPENTER et al., 1992). A estratégia de votação usa um sistema ARTMAP que é treinado diversas vezes com diferentes ordenações para o mesmo conjunto de treinamento. A predição final é dada pelas soluções geradas com maior frequência. Como o conjunto de elementos que fazem predições errôneas varia de uma simulação para a próxima, esta estratégia cancela muitos erros que ocorrem na fase de análise (diagnóstico).

As primeiras redes ARTMAP foram utilizadas para classificar vetores de entradas binários, com cada elemento do vetor indicando a presença ou ausência de uma dada característica.

5.3.2 – Rede ARTMAP *Fuzzy*

A rede ARTMAP *Fuzzy* se diferencia da rede neural ARTMAP pela utilização em seus cálculos da teoria do conjunto nebuloso. Sendo capaz de aprender categorias estáveis em resposta a padrões de entradas tanto analógicos como binários.

Destinada à aproximação de funções não-lineares multidimensionais para classificar vetores de entrada cujos elementos assumem valores nebulosos, entre 0 e 1, indicando o nível de presença de cada característica.

Esta rede é composta por dois módulos ART_a nebuloso e ART_b nebuloso, que possuem a mesma estrutura da rede neural ART Nebulosa, exceto que na ART_a nebulosa inclui um campo de mapeamento controlando o treinamento de um mapa associativo de categorias de reconhecimento da ART_a para categorias de reconhecimento da ART_b (Figura 5.3.2.). O campo de mapeamento controla a regra match tracking, que aumenta o parâmetro de vigilância da rede ART_a por uma quantia mínima necessária para corrigir um erro preditivo (MARCHIORI et al., 2002).

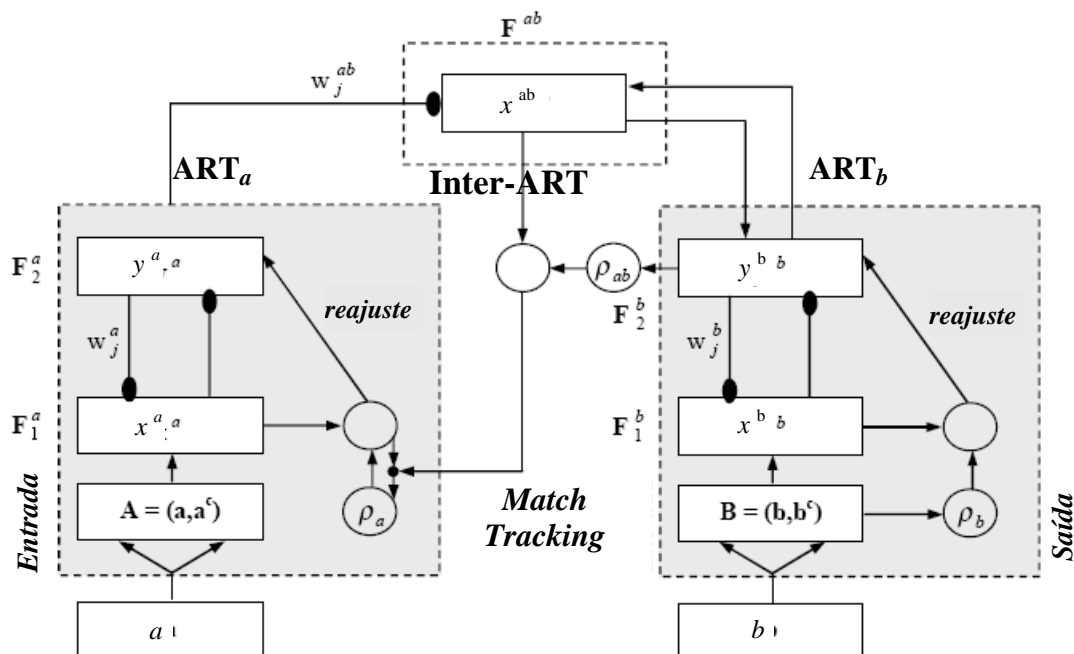


Figura 5.3.2. - Rede ARTMAP Nebulosa.

Como já mencionado, o algoritmo de aprendizado das redes ARTMAP, é supervisionado, pois possui um sistema de conexão entre os dois módulos ART (*Inter-ART*), que combinam os parâmetros de entrada com os parâmetros de saída através do *match tracking*. Tal algoritmo segue basicamente os seguintes passos:

- Passo 1: Normalizar os vetores de entrada ART_a e de saída ART_b , se necessário: Inicialmente, todos os valores dos neurônios devem ser normalizados se não estiverem entre 0 e 1;
- Passo 2: Codificar os vetores dos módulos ART_a e ART_b : Um novo padrão de entrada deve sofrer uma codificação complementar preliminar para se preservar a amplitude da informação;
- Passo 3: Iniciar os pesos e parâmetros dos módulos ART_a , ART_b e Inter-ART: deve-se iniciar os pesos (valor 1 = todas as categorias desativadas), taxa de treinamento (β entre 0 e 1), parâmetro de escolha ($\alpha > 0$) e parâmetro de vigilância (ρ_a , ρ_b e ρ_{ab} entre 0 e 1);
- Passo 4: Escolha da categoria para os módulos ART_a e ART_b : Se mais de um neurônio está ativo, é escolhido aquele com o maior índice de ordenação (maior valor).
- Passo 5: Teste de vigilância dos módulos ART_a e ART_b : A ressonância ocorre se é satisfeito o critério de vigilância. Caso contrário, se o critério de vigilância falhar para a categoria escolhida, ocorre o *reset* e um novo índice é escolhido (retornar ao passo 4). O processo de busca se repete até que o índice escolhido satisfaça o teste de vigilância.
- Passo 6: *Match tracking* (teste de ressonância) entre os módulos ART_a e ART_b : Verificação se houve casamento da entrada com a saída. Se não houver casamento deve-se procurar outro índice que satisfaça o teste;
- Passo 7: Adaptação dos pesos: O vetor (camada $F2$) dos módulos ART_a , ART_b e inter-ART são atualizados com os novos pesos.
- Passo 8: Repetir passos 4 à 7 para todos os pares a serem treinados.

O algoritmo da rede ARTMAP *Fuzzy* se difere da ARTMAP pelo uso do operador nebuloso “ \wedge ” no lugar do operador de interseção “ \cap ”, assim como ocorre nas redes ART.

De uma forma mais simples é apresentado, no Apêndice A, o fluxograma que estabelece os procedimentos do algoritmo ARTMAP nebuloso.

CAPÍTULO 6

TRANSFORMADA *WAVELET*

6.1. Introdução

A teoria *Wavelet* é um recurso matemático desenvolvido para várias aplicações e que tem sido usada como uma eficiente ferramenta para a análise de sinais através de processamento de sinal multirresolução, decomposição de sinais e expansão *wavelet*. É aplicada em diferentes áreas da engenharia em consequência da sua eficiente capacidade de analisar sinais discretos. O início da aplicação das *wavelets* na área de processamento de sinais pode ter sido quando da apresentação do algoritmo de Mallat (MALLAT, 1998).

Nesta tese será abordado os principais conceitos *wavelets* relacionados ao processamento e análise de formas de ondas de tensão e, obviamente, não será esgotado o assunto, será enfatizado o suficiente para compreensão do funcionamento do sistema proposto.

6.2. Wavelet

Wavelets em inglês significam ondas pequenas e *ondelettes* em francês possuem determinadas propriedades que as tornam adequadas a servirem de base para a decomposição de outras funções, assim como para a decomposição usando séries de Fourier servem de base

senos e co-senos. A diferença em relação à análise de Fourier é que a análise *wavelet* é feita segundo a escala e não segundo a frequência.

Os algoritmos usados no domínio *wavelet* processam dados em diferentes escalas e resoluções, permitindo que sejam visto tanto o global quanto os detalhes de um sinal. Se olharmos para um sinal com uma “janela grande”, notaremos características totais. Da mesma forma, se olharmos para um sinal com uma “janela pequena”, notaremos pequenas características. O resultado da análise *wavelet* é ver a floresta e as árvores (GRAPS, 1995). Ou seja, o sinal e seus detalhes.

6.2.1. Transformada *Wavelet*

Uma das características da transformada *wavelet* é que ela usa o conceito de janelas deslizantes com regiões de tamanhos variáveis. Sendo grande, ou seja, usando longos intervalos de tempo, quando queremos maior precisão na informação de baixa frequência, e pequenas regiões quando queremos informação de alta frequência, levando assim a uma ótima resolução em todo tipo de frequência. O uso de *wavelet* no estudo de problemas de qualidade de energia é muito apropriado porque muitos distúrbios ligados a um sistema de alimentação de energia são transitórios não-estacionários (MALLAT, 1998).

A transformada *wavelet* decompõe uma função definida no domínio do tempo em outra função, definida no domínio do tempo e no domínio da frequência. Isso ocorre através da decomposição da função em diferentes escalas em diferentes níveis de resolução com a utilização de uma função modelo.

A transformada *wavelet* é definida como:

$$W(a,b) = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{|a|}} \Psi^* \left(\frac{t-b}{a} \right) dt \quad (6.2.1)$$

Sendo uma função de dois parâmetros reais, a e b . Se definirmos $\psi_{a,b}(t)$ como:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \quad (6.2.2)$$

Podemos reescrever a transformada como o produto interno das funções $f(t)$ e $\psi_{a,b}(t)$:

$$W(a,b) = \langle f(t), \psi_{a,b}(t) \rangle = \int_{-\infty}^{\infty} f(t) \psi_{a,b}(t) dt \quad (6.2.3)$$

A função $\psi(t)$ que equivale a $\psi_{1,0}(t)$ é chamada de *wavelet* mãe (do inglês *mother wavelet*) enquanto que as outras funções $\psi_{a,b}(t)$ são chamadas de *wavelets* filhas. O parâmetro b indica que a função $\psi(t)$ foi transladada no eixo t de uma distância equivalente a b , sendo então um parâmetro de translação. Já o parâmetro a causa uma mudança de escala, aumentando (se $a > 1$) ou diminuindo (se $a < 1$) a *wavelet* formada pela função. O parâmetro a é conhecido como parâmetro de escala (GRAPS, 1995).

Uma das mais importantes aplicações da transformada *wavelet* (WT - *Wavelet Transform*) é a habilidade de processar e manipular dados em parâmetros compactados chamados de recursos ou características (*features*). Um sinal contém muitos dados e podem ser compactados em alguns parâmetros, chamados de coeficientes *wavelet* que caracterizam o comportamento do sinal (SANTOSO et al., 1996).

Calcular os coeficientes *wavelet* para cada escala possível é um processo muito longo e dispendioso computacionalmente, além de ser gerada uma grande quantidade de dados. Embora a transformada *wavelet* contínua seja de grande interesse teórico, principalmente para a obtenção e a compreensão das propriedades matemáticas das funções *wavelets*, a sua discretização é necessária para aplicações práticas (HERNANDES; WEISS, 1996).

6.3. Transformada *Wavelet* Discreta

A discretização é necessária em razão da redundância encontrada na equação (6.2.2) já que os parâmetros a , b da transformada variam continuamente. Desse processo de discretização dá origem à Transformada *Wavelet* Discreta – TWD (*DWT – Discrete Wavelet Transform*). Na transformada *wavelet* discreta apenas os parâmetros da transformada contínua são discretizados, ou seja, o parâmetro de escala a e o parâmetro de translação b .

Usando-se a TWD, é possível uma análise muito mais eficiente, pois se escolhe apenas um conjunto de escalas e posições para realização dos cálculos, sendo que as escalas e as posições são escolhidas em potências de dois (TIWARI; SHUKLA, 2002).

Na Análise *Wavelet*, em suas formas Contínua e Discreta, falamos de aproximações e detalhes. As aproximações são os componentes de baixa frequência do sinal. Os detalhes são os componentes de alta frequência do sinal. Para inúmeros sinais, o conteúdo a baixa frequência é a parte mais importante. É isto que dá ao sinal a sua identidade. O conteúdo de alta frequência, por outro lado, mostra a característica do sinal. Considerando a voz humana, se removermos os conteúdos de alta frequência, a voz soa diferente, mas o discurso continua a ser perceptível. No entanto, se removermos o conteúdo de baixa frequência, o discurso deixa de ser perceptível (MALLAT, 1998).

O processo de filtragem é mostrado de forma simplificada na Figura 6.3.1., considerando-se apenas o primeiro nível de filtragem.




Figura 6.3.1. - Processo de filtragem de um sinal S .

O sinal original S passa através de dois filtros complementares, o filtro Passa Baixa e o filtro Passa Alta, que fornecem como saída dois outros sinais, o sinal de

Aproximação (**A**) e o sinal de Detalhe (**D**), respectivamente. Porém, se utilizarmos esse processo em um sinal digital real, teremos duas vezes mais a quantidade de dados em relação aos dados iniciais. Assim, supondo que o sinal original **S** consista de 1.000 amostras de dados, os sinais de aproximação (**A**) e os de detalhes (**D**) oriundos do sinal original terão 1.000 amostras cada um, totalizando, então, 2.000 amostras.

Para amenizar este problema, deve-se introduzir um operador para diminuir o número de amostras, nesse operador, conhecido como *downsampling*, são considerados os dados de forma alternada, ou seja, considera-se o primeiro dado, rejeita-se o segundo, e assim por diante (BURRUS, 1998). A Figura 6.3.2. ilustra o processo de filtragem com e sem a utilização do operador *downsampling*.




Figura 6.3.2. - Processo de diminuição do número de amostras do sinal.

O processo da direita da figura acima, que inclui a diminuição de amostras, produz os coeficientes **cD** e **cA** referentes a Transformada *Wavelet* Discreta.

O processo de decomposição pode ser iterado, com sucessivas aproximações a serem decompostas, de forma que um sinal seja dividido em muitos componentes de baixa resolução. Isto é chamado de “árvore de decomposição *Wavelet*”. A partir do momento em que o processo de análise é iterativo, em teoria pode ser continuado de forma indefinida. Na realidade, a decomposição pode ser efetuada até que os detalhes individuais consistam numa amostra simples ou *pixel* (no caso de imagens). Na prática, deve ser selecionado um número de níveis baseado na natureza do sinal, ou num critério viável como a entropia (MISITI et al., 1997).

Os componentes podem ser conjugados, no sinal original, sem perda de informação referentes ao sinal original. Este processo é chamado “reconstrução” ou “síntese”. A manipulação matemática que atua na reconstrução é chamada “transformada inversa discreta *wavelet*” (*IDWT – Inverse Discrete Wavelet Transform*). Para sintetizar um sinal, este é reconstruído a partir dos coeficientes *wavelet* (HE; STARZYK, 2006).

A análise *wavelet* é feita pela aplicação sucessiva da transformada *wavelet* com diversos valores, representando a decomposição do sinal original em diversos componentes localizados no tempo e na frequência, de acordo com estes valores. Cada *wavelet* possui melhor ou pior localização nos domínios da frequência e do tempo, por isso a análise pode ser feita com *wavelets* diferentes de acordo com o resultado desejado (DAUBECHIES, 1996).

6.4. Análise Multirresolução

A Análise Multirresolução (AMR) decompõe um espaço de funções em subespaços. Desse modo, cada função é decomposta em pedaços (projeções) que, formalmente, consiste de uma sequência de sucessivos espaços de aproximação, sendo que cada espaço é uma resolução distinta.

A técnica consiste na decomposição do sinal a ser analisado em dois outros sinais. O sinal de aproximação (proveniente do filtro passa baixa) é novamente decomposto resultando em dois outros novos sinais, detalhado e atenuado, em níveis de frequência diferentes, fornecendo informações no domínio da frequência e do tempo (DAUBECHIES, 1996). Esta técnica de análise é ilustrada na Figura 6.4., onde o sinal $f(x)$ é submetido ao processo de decomposição em AMR.

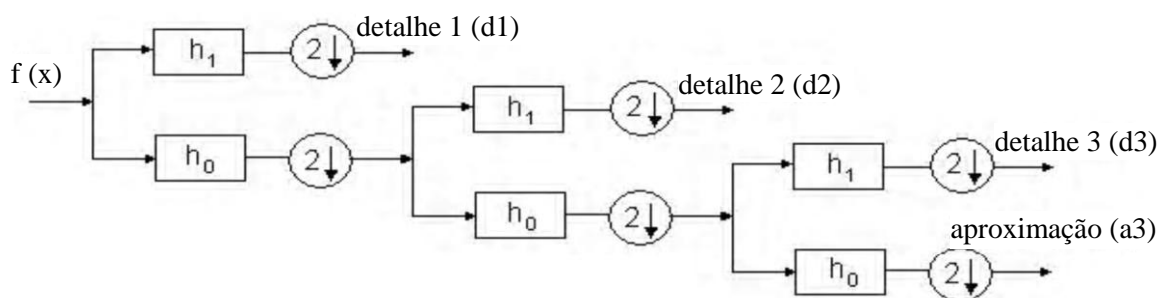


Figura 6.4. - Técnica de decomposição da Análise Multirresolução.

A Transformada *Wavelet* Discreta (TWD) fornece uma representação de sinais precisa no domínio tempo-frequência, gerando poucos coeficientes com mínima perda de informação, por causa da sua capacidade potencial de oferecer alto grau de correlação com o sinal a ser decomposto, ou com o padrão a ser reconhecido. Este atributo depende fundamentalmente da escolha da função *wavelet* a ser usada para cada tipo específico de

padrão. Um método eficiente para aplicar este esquema usando filtros foi desenvolvido por Mallat (MALLAT, 1998). Inspirado nos resultados de Mallat, Y. Meyer construiu a primeira *wavelet* não-trivial (suave) (MEYER, 1993).

O procedimento de funcionamento da análise *wavelet* é adotar uma função *wavelet* protótipo, chamado de “análise *wavelet*” ou “*wavelet* mãe”.

6.5. Famílias *Wavelets*

Existem inúmeras funções (famílias) *wavelets*. Normalmente, a função *wavelet* mãe recebe o nome do seu criador existindo, atualmente, inúmeras *wavelets* mãe citadas na literatura. O uso de cada uma delas está associado ao tipo de aplicação. Regras de construção de *wavelets* são propostas por vários pesquisadores, segundo as restrições e necessidades de cada aplicação específica.

As famílias *wavelets* mais conhecidas e empregadas são:

- **Haar:** A *wavelet* Haar é a primeira e a mais simples função *wavelet*. É uma função escala, função inicial para se construir uma *wavelet*. A *wavelet* é construída através de operações de mudança de escala e translação aplicada à função. Ela é descontínua e representa uma função com degrau um (Figura 6.5.1.). As *wavelets* de Haar não são continuamente diferenciáveis, o que de certo modo limita suas aplicações.




Figura 6.5.1. - Função *wavelet* de Haar.

- **Daubechies:** Ingrid Daubechies, uma das personalidades mais brilhantes na pesquisa e desenvolvimento das *wavelets*, construiu uma família que é chamada de “*wavelets* ortonormais suportadas compactamente”, diferente de todos os exemplos de bases *wavelets* ortonormais (com exceção da base de *Haar*) que consistem de funções de suporte infinito, como mostrado na Figura 6.5.2. Dessa forma torna a análise *wavelet* discreta possível.

Quando se pretende que as *wavelets* tenham suporte compacto, isto é, que sejam definidas sobre um intervalo limitado, é necessário que apenas um número finito de coeficientes de filtro seja diferente de zero. As *wavelets* de Daubechies são organizadas em diferentes famílias, cada uma das quais caracterizadas por um número diferente de coeficientes não-nulos.

As famílias *wavelets* são definidas com valores compreendidos entre 2 e 10. Sendo assim, dada uma família com um determinado valor N , qualquer polinômio de grau igual ou inferior a $N - 1$ pode ser representado de uma forma exata pela combinação linear da função escala e de todas as suas translações inteiras.




Figura 6.5.2. - Função wavelet de Daubechies.

- **Symlets:** São *wavelets* quase simétricas, propostas por Daubechies como uma modificação à família *db* (*daubechies*). As propriedades das duas famílias *wavelets* são similares (DAUBECHIES, 1992).

- **Morlet:** Função pertencente à família das *wavelets* não-ortogonais. A *wavelet* de Morlet não possui função escala e é explicitada por uma função Gaussiana modulada (*shifted*), levemente ajustada (MORLET, 1984), como exemplo mostrado na Figura 6.5.3.




Figura 6.5.3. - Função wavelet de Morlet.

- **Chapéu Mexicano (Mexican hat):** Esta *wavelet* não tem função escala e é derivada de uma função que é proporcional à segunda derivada da função densidade de probabilidade Gaussiana (MALLAT, 1998). Modelo da função mostrado na figura abaixo (Figura 6.5.4.).




Figura 6.5.4. - Função wavelet chapéu mexicano.

- **Meyer:** Meyer construiu a primeira *wavelet* trivial diferente da *wavelet* de Haar, que é continuamente diferenciável, ou seja, uma base *wavelet* suave ortonormal. A *wavelet* de Meyer e a função escala são definidas no domínio da frequência como mostrado na Figura 6.5.5., a seguir (MEYER, 1993).




Figura 6.5.5. - Função wavelet de Meyer.

- **Biorthogonal:** Esta família *wavelet* apresenta uma propriedade de fase linear, que é extremamente importante na reconstrução de sinais e imagens. O processo usa duas *wavelets*, uma para decomposição e uma outra para a reconstrução, em vez de uma única *wavelet*. É uma função onde a transformada *wavelet* é inversível, mas não necessariamente ortogonal. Com isso, possibilita um grau de liberdade adicional, a construção de funções *wavelet* simétrica (MALLAT, 1998).

Na literatura, diferentes famílias *wavelets* têm sido usadas para decompor sinais distorcidos e para extrair suas características. Mais detalhes da discussão sobre estas características das famílias *wavelets* podem ser encontradas em (DAUBECHIES, 1992).

As transformadas *wavelet* são empregadas numa vasta gama de aplicações, substituindo com frequência a tradicional transformada de Fourier. Diversas áreas da física viram esta mudança de paradigma, incluindo a dinâmica molecular, astrofísica, localização de matriz de densidade, geofísica sísmica, óptica, turbulência e mecânica quântica. Esta mudança também vem ocorrendo no processamento de imagem, análises de pressão sanguínea, ritmo cardíaco e eletrocardiograma, análise de DNA e de proteínas, climatologia, processamento de sinais em geral, reconhecimento de voz, computação gráfica e análise multifractal.

No processamento de sinais a transformada *wavelet* é uma ferramenta onde a grande vantagem sobre as técnicas clássicas de Fourier é o fato de suas funções bases (*wavelets*) não pertencerem a um espaço de funções com número finito de soluções, isto é, existem, teoricamente, infinitas possibilidades de se projetar *wavelets* com propriedades especiais, voltadas para aplicações específicas. As funções moduladoras da transformada *wavelet* podem ser expandidas ou comprimidas com o objetivo de se obter uma correlação mais forte entre o sinal processado e essas funções, evidenciando assim mais detalhes no domínio transformado (DAUBECHIES, 1992).

Assim, a transformada *wavelet* pode ser vistas como mecanismo para decompor ou quebrar sinais nas suas partes constituintes, permitindo analisar os dados em diferentes domínios de frequências com a resolução de cada componente ligado à sua escala, e também como uma técnica de janelamento instantânea, muito útil no processamento de sinais não-estacionários (RIOUL; VETTERLI, 1991)

CAPÍTULO 7

NORMA ENTROPIA *WAVELET*

7.1. Introdução

Entropia é um conceito comum a várias áreas. Em termodinâmica, entropia é uma medida para quantificar o grau de desequilíbrio do estado do sistema. Em matemática, a entropia é usada para medir a incerteza de problemas. Enquanto na Ciência da Informação, entropia é a média da incerteza da fonte de informação. Assim, pode-se dizer que entropia é uma medida de irregularidades de estados como o desequilíbrio, incerteza. Como um método para medir, a entropia aparece como uma ferramenta ideal para quantificar a ordenação dos sinais não-estacionários (ZHANG et al., 2004).

Como os sinais com distúrbios em problemas de qualidade de energia têm o desequilíbrio, são não-estacionário, com diferentes componentes de frequências, a norma entropia é utilizada para extrair importantes características de sinais com diferentes distúrbios.

Assim, será apresentado neste capítulo o conceito de norma entropia *wavelet*, que tem função fundamental na extração de características dos sinais com distúrbios na rede *neuro-fuzzy-wavelet*.

7.2. Norma Entropia Wavelet – WEN

A norma entropia de um sinal com distúrbio $\mathbf{U} = \left\{ \begin{matrix} \rightarrow \\ \leftarrow \end{matrix} \mathbf{U}_j, j=1,2,\dots,N \right\}$, pode ser obtida pela seguinte equação:

$$\mathbf{NE} = \sum_{j=1}^N |\mathbf{U}_j|^P \quad (7.2.1)$$

Sendo:

j : pontos do sinal U ;

P : é o nível de energia com variação de $1 \leq P \leq 2$.

Nesta pesquisa foi usado o cálculo da norma entropia aplicado ao método da TWD. Assim, o cálculo da norma entropia dos coeficientes detalhe e aproximação, obtidos em cada nível de decomposição, a partir da TWD e a AMR de diferentes sinais com distúrbios são representados por WEN (*Wavelet Entropy Norm*).

Os valores da norma entropia para os coeficientes detalhe e aproximação, obtidos em cada nível de decomposição, são calculados para extração de características importantes, resultando em um número real. As características extraídas desse processo permitem distinguir um tipo de distúrbio dos demais sendo calculados pelas expressões:

$$Wd_j = \frac{1}{N_j} \sum_n |d_j[n]|^P, \quad Wa_j = \frac{1}{N_j} \sum_n |a_j[n]|^P, \quad j = 1, 2, \dots, H \quad (7.2.2)$$

Podendo ser representadas como:

$$\mathbf{W}_{sinal} = [\mathbf{Wd}_1 \dots \mathbf{Wd}_H, \mathbf{Wa}_H] \quad (7.2.3)$$

Sendo:

H : número total de níveis de decomposição;

d_H : é último nível do coeficiente detalhe;

a_H : é último nível do coeficiente aproximação.

O vetor da norma entropia *wavelet* que representa as características normalizadas de cada nível de decomposição ($d_1, \dots, d_{12}, a_{12}$), de cada sinal, é identificado por:

$$\Delta W_{sinal} = [Wd_1 \dots, Wd_{12}, Wa_{12}] \quad (7.2.4)$$

Sendo que:

Wd_1 : média entropia do coeficiente detalhe do primeiro nível;

Wd_{12} : média entropia do último nível de detalhe;

Wa_{12} : média entropia do último nível de aproximação.

Como nos distúrbios, no contexto da QEE, o valor da norma entropia é muito semelhante em alguns distúrbios como nos casos de *sag* e *outage*, então, um sinal puro é usado como referência para distinguir esses distúrbios entre si. Assim, o vetor que representa a WEN será dado por:

$$\Delta WEN = \Delta W_{sinal} - \Delta W_{sinal\ puro} \quad (7.2.5)$$

Onde o vetor $\Delta W_{sinal\ puro}$ representa as características *wavelets* normalizadas do sinal puro. Utilizando-se a equação (7.2.4), pode ser representado por:

$$\Delta W_{sinal\ puro} = [Wd_{sinal\ puro1}, \dots, Wd_{sinal\ puro12}, Wa_{sinal\ puro12}] \quad (7.2.6)$$

Assim, o vetor da norma entropia *wavelet* (ΔWEN) que representa as características de cada sinal com distúrbio é usado, após sua normalização e codificação de complemento, como entrada do módulo de classificação.

CAPÍTULO 8

REDE NEURO-FUZZY-WAVELET

8.1. Introdução

Neste capítulo apresenta-se um esquema ilustrativo do sistema proposto (rede neuro-*fuzzy-wavelet*), bem como o funcionamento de seus módulos, para a detecção e classificação de distúrbios de tensão de sistemas de energia elétrica, que é abordado nesta pesquisa de doutorado.

A rede proposta é um método que combina o uso da transformada *wavelet* e redes neurais artificiais (ARTMAP *Fuzzy*). Esse método pode ser definido como sendo uma rede neural empregada para detectar distúrbios em um sinal de tensão, extrair características das formas de ondas com distúrbio e classificar o tipo de distúrbios de tensão que o sinal de entrada sofreu. Ou seja, após um sinal ser lido pela rede a mesma indicará se o sinal é puro ou, se sofreu algum distúrbio, qual é o tipo.

8.2. Sistema Proposto

A estrutura básica da Rede Neuro-*Fuzzy-Wavelet* (RNFW) é composta por três módulos principais: o módulo de detecção de anomalias (distúrbios), o módulo de extração de características onde as formas de onda são analisadas através do cálculo da Transformada *Wavelet* Discreta (TWD), Análise Multirresolução (AMR) e Norma Entropia *Wavelet* (WEN)

e o módulo de classificação de distúrbios que conta com uma rede neural ARTMAP *Fuzzy* que indica qual o tipo de distúrbio presente no sinal. Tal estrutura é mostrada na Figura 8.2.

O processo de funcionamento da rede se resume na leitura do sinal de entrada passando pelo módulo de detecção de anomalias. Se for detectado algum distúrbio, é realizado o cálculo dos coeficientes *wavelet* e suas respectivas médias de entropia, resultando em um vetor que contém características próprias do distúrbio (assinaturas). Este vetor resultante é utilizado como entrada do módulo de classificação após ser pré-processado via processo de normalização e codificação, visando colocá-lo num formato adequado para a rede neural ARTMAP *Fuzzy*. Esta rede, então, fará a classificação do tipo de anomalia que o sinal de entrada sofreu de forma rápida e precisa definindo, então, qual o distúrbio que ocorreu no sistema (camada de saída).

Para representar os distúrbios considerados neste trabalho (afundamento de tensão, elevação de tensão, interrupção, etc.), usa-se na camada de saída da rede uma codificação binária de 3 bits.

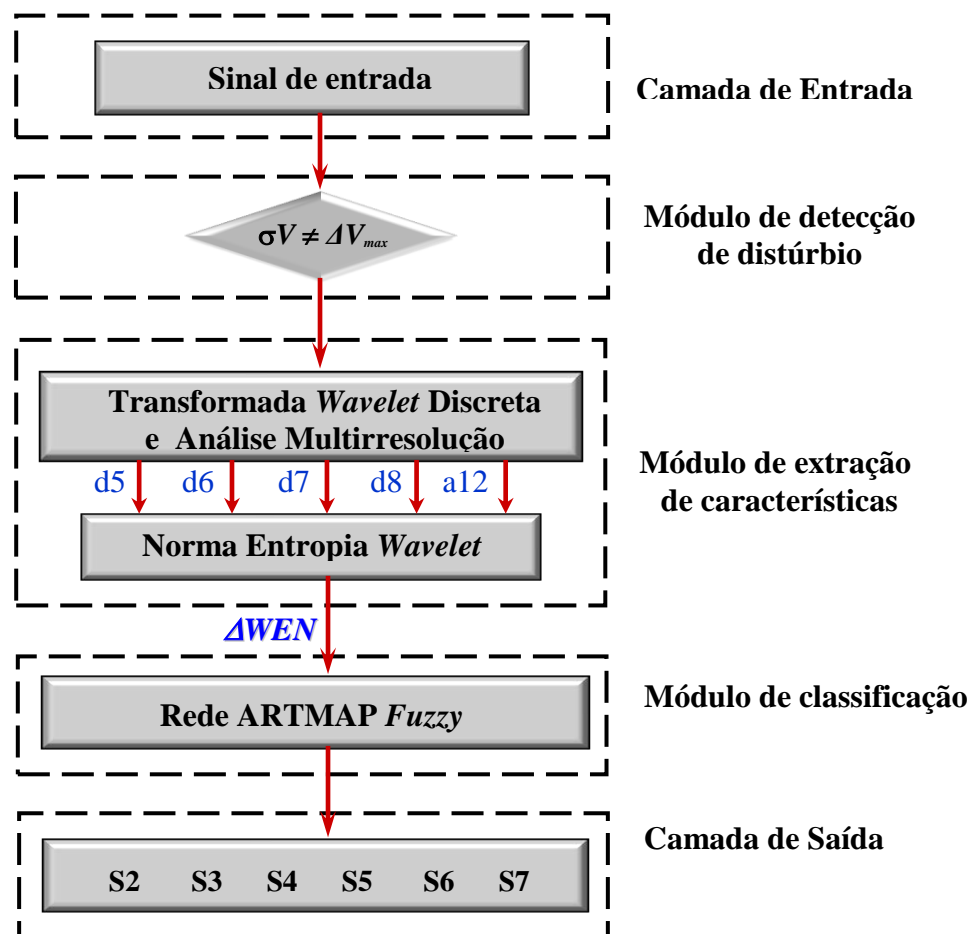


Figura 8.2. - Estrutura básica da Rede Neuro-Fuzzy-Wavelet.

8.2.1. Módulo de Detecção

A forma de onda de tensão é constantemente analisada a fim de se detectar algum tipo de anormalidade na rede. Esse processo é realizado inferindo-se, de maneira aproximada, a amplitude máxima da tensão da forma de onda (Figura 8.2.1.), baseado no modelo de inferência de corrente proposto por Al-Jufout (AL-JUFOUT, 2006), que, de modo similar, realiza a detecção de defeitos de curto-circuito, como se mostra a seguir:

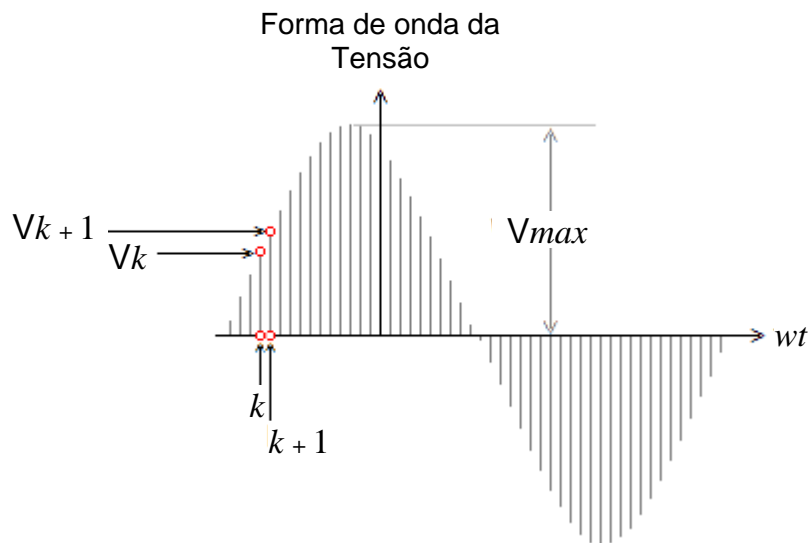


Figura 8.2.1. - Forma de onda senoidal de tensão discretizada, considerando-se uma taxa de amostragem m .

A amplitude máxima da tensão pode ser obtida através da equação:

$$V_{max} = \left| \frac{V_k}{\text{sen} \{ \tan^{-1}(\Phi) \}} \right| \quad (8.2.1.1)$$

sendo:

$$\Phi = \frac{V_k \text{sen}(w\Delta t)}{V_{k+1} - V_k \text{cos}(w\Delta t)} ;$$

$$\Delta t = t_{k+1} - t_k ;$$

k : tempo discreto;

w : velocidade da onda = $2 \pi f$;

f : frequência (Hz).

Calculam-se os valores de V_{max} para $i = 1, 2, \dots, L$; usando-se a equação (8.2.1.1), sendo L um número arbitrado considerando-se as amostragens de interesse (e.g., 3 vezes em 1 ciclo).

Assim, tem-se:

$$V_{med} = \frac{\sum_{i=1}^L V_{max}^i}{\sqrt{2} L} \quad (8.2.1.2)$$

e:

$$\sigma V = \left| V_{med} - V_{referência} \right| \quad (8.2.1.3)$$

Em que:

V_{max}^i : valor de V_{max} calculado a partir da equação (8.2.1.1) baseando-se na onda de tensão (Figura 8.2.1.);

V_{med} : média aritmética dos L valores eficazes da forma de onda de tensão;

$V_{referência}$: valor eficaz de referência correspondente à tensão nominal;

σV : índice de normalidade de tensão da forma de onda.

As L estimativas de V_{max} são adotadas visando reduzir a imprecisão de V_{med} , isto porque as medidas das tensões podem conter ruído. Assim, pode-se definir que para uma forma de onda perfeitamente senoidal, o valor da amplitude calculada usando-se a equação (8.2.1.1) é exatamente igual à tensão nominal. Porém, quando houver qualquer anormalidade na tensão, haverá um reflexo na amplitude, ou seja, uma discrepância em relação ao valor real ($V_{referência}$). Desse modo, adaptando-se as equações (8.2.1.2) e (8.2.1.3), obtém-se o resultado da normalidade do sinal.

A Detecção de distúrbios é realizado, então, através da comparação do índice de normalidade com o parâmetro de normalidade:

$$\sigma V \neq \Delta V_{max} \quad (8.2.1.4)$$

Que se traduz no seguinte critério:

Se $\sigma V = \Delta V_{max}$, indica que não existe anormalidade relevante na tensão;

Se $\sigma V \neq \Delta V_{max}$, indica a existência de anormalidade na tensão.

Sendo que:

σV : valor calculado através da equação (8.2.1.3) e tomando-se $V_{referência}$ como sendo a tensão nominal eficaz; e

ΔV_{max} : parâmetro empírico, levando-se em conta a experiência com o problema de anomalia de tensão.

Com essa adaptação, esse método é implementado para a detecção de anormalidades de tensão na rede.

8.2.2. Módulo de Extração de Características

Uma vez detectada alguma anormalidade de tensão, há a necessidade de classificar o tipo de distúrbio detectado na rede. A extração de características do sinal ajuda a distinguir um tipo de distúrbio de outros. É a chave para o reconhecimento de padrões, sendo o componente mais importante no desenvolvimento de sistemas de classificação inteligentes, acarretando que o melhor classificador tenha baixo desempenho se as características não forem bem escolhidas.

Nesta pesquisa foi cogitado, num primeiro momento, o uso dos conceitos de lógica *fuzzy* de modo semelhante ao apresentado para faltas de curto-circuito, incluindo-se a técnica de *wavelets* para extração das características. Contudo, como as anormalidades de tensão, em alguns casos, são bem mais sutis, se comparado ao impacto produzido por uma falta de curto-circuito, ainda que no evento curto-circuito haja também um grande efeito sobre a tensão do sistema, optou-se por um procedimento que combina o uso da transformada e norma entropia *wavelets* e redes neurais artificiais. A rede neural é empregada como forma de extrair o conhecimento das anormalidades de tensão, baseado num processo de treinamento prévio.

Nesse módulo, sendo determinado que o sinal de entrada contém algum tipo de distúrbio, o mesmo é decomposto e, assim, obtido os coeficientes *wavelets* através da análise multirresolução. Desses coeficientes são calculadas as médias entropias *wavelet* (WEN), que resultará em um vetor contendo as características que identificam cada tipo de distúrbio.

Utilizando-se a Transformada *Wavelet* Discreta (TWD), é possível uma análise muito mais eficiente do sinal, pois se escolhe apenas um conjunto de escalas e posições para realização dos cálculos.

A escolha da *wavelet* mãe foi baseada em testes de desempenho de classificação de vetores de características extraídas de diferentes famílias *wavelets* (ARRUDA et al., 2002). Tal teste aponta um desempenho um pouco melhor obtido com o filtro *wavelet* Biorthogonal, porém os filtros *wavelet* Daubechies (DAUBECHIES, 1996) são mais indicados para serem utilizados na análise de sinais discretos por serem mais vantajosos, considerando o tamanho menor do filtro e o tempo de resposta, fundamental para aplicações em tempo real.

A decomposição *wavelet* do sinal é realizada por 12 níveis utilizando-se o filtro Daubechies de quarta ordem (db_4), sendo mais indicado para nossa proposta por ter mais vantagens em termos do menor tamanho do filtro e do tempo de resposta para aplicações em tempo real. É gerado, assim, os níveis de detalhe ($d_1, d_2, d_3, \dots, d_{12}$) que contêm os coeficientes de baixa frequência e o nível de aproximação (a_{12}) com os coeficientes de alta frequência através da análise multirresolução (AMR).

A seguir, os valores da norma entropia para coeficientes de detalhe e aproximação obtidos em cada nível de decomposição a partir da WT e AMR de diferentes distúrbios são calculadas para extração de características importantes, como descrito no Capítulo 7, resultando em um número real. Com as características extraídas desta forma é possível distinguir um distúrbio de outro.

Como tipos diferentes de distúrbios possuem características similares em alguns níveis de decomposição e atentando para o fator da complexidade computacional, o vetor resultante das características de cada forma de onda com distúrbio é formado, apenas, pelos valores da norma entropia *wavelet* dos coeficientes de detalhe d_5 , d_6 , d_7 e d_8 e do coeficiente de aproximação a_{12} que pode ser expresso por:

$$\Delta WEN = [Wd_5, Wd_6, Wd_7, Wd_8, Wa_{12}] \quad (8.2.2.1)$$

Assim, o vetor da norma entropia *wavelet* (ΔWEN) que representa a característica de cada distúrbio será pré-processado através da normalização e da codificação do complemento, conforme se pode observar no algoritmo apresentado na seção 5.3.2., visando colocá-lo num formato adequado, e usado como entrada do módulo de classificação.

8.2.3. Módulo de classificação

Conforme foi amplamente argumentado e exposto neste capítulo, a escolha da rede neural para a classificação dos distúrbios recaiu sobre a arquitetura ARTMAP *Fuzzy* por razões de eficiência, ou seja, trata-se de uma rede neural que é estável e plástica.

A teoria de ressonância é um fenômeno bastante observado na natureza, em especial, é um dos principais mecanismos empregados pelo cérebro humano. Todo o processo de reconhecimento ocorre por um processo de observação de verossimilhança (ressonância). Com estas qualidades, as redes neurais da família ART se destacam em relação às demais redes disponíveis na literatura especializada. A estabilidade está associada à garantia da obtenção de soluções. A plasticidade, por sua vez, refere-se à capacidade de incluir novos padrões sem a necessidade de reiniciar todo o processo de treinamento, como é comumente observado na maioria das redes neurais disponíveis na literatura.

Outra importante característica refere-se à grande velocidade de realização do treinamento e o diagnóstico correspondente, tornando-a um sistema adequado para aplicação em tempo real, como é o objetivo deste projeto. Nos casos de operações anormais o sistema deverá fornecer as análises precisas informando o tipo de distúrbios apresentado, buscando estabelecer as estratégias para contornar tais problemas com o objetivo de dar continuidade ao fornecimento de energia de qualidade.

A utilização da arquitetura ARTMAP *Fuzzy*, além da obtenção de respostas rápidas e confiáveis, permite que se projete (formatação) o dado de entrada e de saída contendo a maior diversidade possível. Deste modo, pode-se desenvolver uma estrutura que tenha a capacidade de realizar a classificação considerando-se um grande número de distúrbios de tensão.

A rede neural ARTMAP *Fuzzy* (CARPENTER et al., 1992) é uma rede supervisionada, ou seja, o treinamento é realizado baseado em estímulos de entrada e de saída. É composta por dois módulos ART *Fuzzy*: ART_a e ART_b interconectados através de módulo de memória associativa inter-ART, F_{ab}, que possui um mecanismo auto-regulador denominado *match tracking*. Este mecanismo possui a incumbência de realizar o “casamento” entre a entrada e a saída da rede neural.

Os parâmetros utilizados normalmente no processamento da rede ARTMAP *Fuzzy* são: parâmetro de escolha ($\alpha > 0$), taxa de treinamento ($\beta \in [0,1]$) e parâmetros de vigilância (ρ_a, ρ_a e $\rho_{ab} \in [0,1]$). Inicialmente, todos os pesos possuem valor igual a 1, indicando que não existe nenhuma categoria ativa.

As matrizes de pesos associada à rede ART_a referente aos padrões de entrada (w^a), associada à rede ART_b referente aos padrões de saída (w^b) e associada ao módulo Inter-ART (w^{ab}) possuem a seguinte dimensão:

- w^a possui dimensão = (N_a x M_a);
- w^b possui dimensão = (N_b x M_b);
- w^{ab} possui dimensão = (N_a x N_b).

Sendo:

N_a : número de pares de entrada;

N_b : número de pares de saída;

M_a : número de componentes dos vetores de entrada;

M_b : número de componentes dos vetores de saída.

A ativação das categorias (atualização das matrizes de pesos) ocorrerá à medida que acontecer a ressonância entre os padrões de entrada com os padrões de saída. Ou seja, quando os pares de entrada associados aos módulos ART_a e ART_b (referentes, respectivamente, às categorias J e K ativas) forem confirmados de acordo com o teste do *match tracking*.

Salientando a importância dos parâmetros de vigilância, que controlam a resolução do processo de classificação, sendo que as redes ART são muito sensíveis a variação desses parâmetros. Se para ρ é definido um valor muito baixo, a rede permitirá que padrões pouco semelhantes sejam agrupados na mesma categoria de reconhecimento, levando à interpretação de que quase tudo é igual, criando, assim, poucas classes. E se para ρ for atribuído um valor alto, por exemplo, igual a 1, pequenas variações do padrão de entrada significarão categorias distintas, ou seja, só pertencerão a mesma categoria padrões exatamente iguais, levando à criação de muitas classes.

Para realizar esse processo, os resultados do módulo de extração de características são pré-processados visando colocá-los num formato adequado para a rede neural ARTMAP *Fuzzy*, via processo de normalização e codificação, ou seja, o valor de cada componente de tais vetores deve atender o intervalo $[0, 1]$, conforme descrito no algoritmo de treinamento apresentado na seção 5.3.2.

8.3. Estímulos de Entrada-Saída da Rede Neural ARTMAP Fuzzy

A arquitetura ARTMAP Fuzzy (Figura 8.3.1.), além da obtenção de respostas rápidas e confiáveis, permite que se formatem os dados de entrada e de saída para conter a maior diversidade possível. Pode-se, assim, usar uma estrutura que possua a capacidade de realizar as análises considerando-se um grande número de distúrbios de tensão.




Figura 8.3.1. - Arquitetura da rede ARTMAP Fuzzy que realiza a classificação dos sinais com distúrbios.

Como visto, a rede neural ARTMAP Fuzzy é formada por dois módulos ART Fuzzy (ART_a e ART_b para receberem, respectivamente, os dados de entrada e de saída da rede neural) além do módulo inter-ART. Nessa pesquisa, o vetor de entrada da rede ART_a, correspondente aos sinais com distúrbio, é representado pelo vetor $\mathbf{a} = [a_1 \cdots a_M]$, M-dimensional, normalizado da seguinte forma:

$$\bar{\mathbf{a}} = \frac{\mathbf{a}}{|\mathbf{a}|} \quad (8.3.1.1)$$

Sendo:

$\bar{\mathbf{a}}$: vetor de entrada normalizado;

$$|\mathbf{a}| : \sum_i a_i \quad (8.3.1.2)$$

Os vetores de entrada da rede neural podem ser expressos por:

$$\mathbf{a} = [\bar{\mathbf{a}} \bar{\mathbf{a}}^c] \equiv [\bar{a}_1 \dots \bar{a}_M \bar{a}_1^c \dots \bar{a}_M^c] \quad (8.3.1.3)$$

Onde:

$$\bar{\mathbf{a}} = [\lambda_i], \quad i = 1, 2, \dots, 5;$$

sendo:

$$\lambda_i = \left| \frac{WEN_i}{WEN_{max}} \right|;$$

$$WEN_{max} = \max \{ |WEN_1| \quad |WEN_2| \quad \dots \quad |WEN_5| \} .$$

E:

$$\bar{\mathbf{a}}^c \text{ (complemento de } \bar{\mathbf{a}} \text{)} = \Omega_i = [0 \text{ ou } 1], \text{ para } i = 1, 2, \dots, 5.$$

Os componentes do complemento Ω_i , que é uma codificação binária, são assim definidos:

- se $sgn(WEN_i)$ for “-” (negativo), então, $\Omega_i = 0$;
- se $sgn(WEN_i)$ for “+” (positivo), então, $\Omega_i = 1$;

Sendo sgn , o sinal do elemento do vetor.

Assim, o vetor de entrada \mathbf{a} será um vetor 10-dimensional.

Os vetores de saída \mathbf{b} , correspondente ao conjunto de distúrbios é definido usando-se uma codificação binária para as grandezas de saída de 3 *bits*, e são definidos com mostra a Tabela 8.3.

Tabela 8.3. - Vetores de saída (binários) correspondentes às classes de sinais com distúrbio.

Tipo de distúrbio	Classe	Vetor de Saída b
Afundamento de tensão	S_2	001
Elevação de tensão	S_3	010
Interrupção momentânea	S_4	011
Harmônico	S_5	100
Harmônico e afundamento de tensão	S_6	101
Harmônico e elevação de tensão	S_7	111

A rede ARTMAP realiza o processamento de duas redes ART (ART_a e ART_b), sendo que após a ressonância ser confirmada em cada módulo ART, tem-se:

- J = categoria ativa para a rede ART_a ;
- K = categoria ativa para a rede ART_b .

Através do processo *match tracking* verifica-se se a categoria ativa no ART_a corresponde ao vetor de saída desejada apresentado no ART_b . O critério de vigilância é dado por (CARPENTER et al., 1992):

$$\frac{|y^b \wedge w_{JK}^{ab}|}{|y^b|} \geq \rho_{ab} \quad (8.3.1.4)$$

Sendo:

y^b = vetor saída do ART_b (padrão de atividade F_2^b).

Se a equação (8.3.1.4) não for satisfeita, é feito um incremento mínimo (ϵ) no parâmetro de vigilância da rede ART_a , suficiente apenas para excluir a atual categoria e selecionar outra categoria, que se tornará ativa e entrará novamente no processo até que tal equação seja satisfeita.

Com a ressonância confirmada, os pesos dos módulos ART_a e ART_b , são atualizados em suas respectivas matrizes (w^a e w^b). A adaptação dos pesos para o módulo Inter-ART é efetuada da seguinte forma:

$$w_{JK}^{ab} = 1 \quad \text{para } k = K;$$

$$w_{JK}^{ab} = 0 \quad \text{para } k \neq K.$$

Trata-se, por conseguinte, de um sistema de inferência bastante econômico e eficiente. Também, com a utilização do módulo ARTMAP *Fuzzy* pode-se, posteriormente, agregar um dispositivo que contemple o treinamento continuado fazendo com que o sistema seja aperfeiçoado continuamente.

CAPÍTULO 9

APLICAÇÃO

Neste capítulo serão apresentados os resultados encontrados no teste da aplicação da rede *neuro-fuzzy-wavelet* na detecção e classificação de distúrbios de tensão em sistemas elétricos de potência.

O método proposto tem grande potencial para melhorar o desempenho dos equipamentos de monitoramento automático de anomalias de tensão *on-line* com grande desempenho na classificação. Os experimentos abordados compreenderam estudos e simulações considerando-se os padrões do sistema brasileiro de distribuição de energia elétrica e são expostos a seguir.

9.1. Fase de treinamento

As formas de ondas dos sinais puro e com distúrbios foram geradas por um algoritmo desenvolvido no programa MATLAB – *The Language of Technical Computing*, versão 7.2. A vantagem na geração dessas ondas é enorme em relação a outros métodos como a utilização de um banco de dados de distúrbios. É possível, neste método, escolher quantos e quais os melhores dados (forma de onda e coeficientes) que irão representar um tipo de sinal, compondo uma gama de nuances de distúrbios difíceis de serem encontrados em bancos de dados e simuladores de redes elétricas.

Os dados de entrada da rede *Wavelet ARTMAP Fuzzy* foram gerados baseados no modelo de equação de (ABDEL-GALIL et al., 2005) e (HE; STARZYK, 2006), onde sete classes (*S1* a *S7*) identificam os diferentes tipos de distúrbios de tensão: afundamento, elevação, interrupção momentânea, distorção harmônica, distorção harmônica com afundamento, distorção harmônica com elevação e também o sinal puro (sem distúrbio).

A Tabela 9.1. mostra os modelos para geração dos sinais, com os tipos de distúrbios, as sete classes, as equações matemáticas e seus parâmetros.

Tabela 9.1. - Modelos de distúrbios de tensão.

Distúrbio	Classe	Equação	Parâmetros
Sinal Puro	<i>S1</i>	$f(t) = sen(\omega t)$	Gerais: $t1 \leq t2$; $u(t) = 1$ se $t \geq 0$ e $u(t) = 0$ se $t < 0$.
Afundamento de tensão (<i>sag</i>)	<i>S2</i>	$f(t) = A(1 - \alpha(u(t-t_1) - u(t-t_1))) sen(\omega t)$	$0,1 \leq \alpha \leq 0,9$.
Elevação de tensão (<i>swell</i>)	<i>S3</i>	$f(t) = A(1 + \alpha(u(t-t_1) - u(t-t_1))) sen(\omega t)$	$0,1 \leq \alpha \leq 0,8$.
Interrupção momentânea (<i>outage</i>)	<i>S4</i>	$f(t) = A(1 - \alpha(u(t-t_1) - u(t-t_1))) sen(\omega t)$	$\alpha < 0,1$.
Harmônico	<i>S5</i>	$f(t) = A(\alpha_1 sen(\omega t) + \alpha_3 sen(3\omega t) + \alpha_5 sen(5\omega t) + \alpha_7 sen(7\omega t))$	$0,05 \leq \alpha_3 \leq 0,15$; $0,05 \leq \alpha_5 \leq 0,15$; $0,05 \leq \alpha_7 \leq 0,15$.
Harmônico e <i>sag</i>	<i>S6</i>	$f(t) = A(1 - \alpha(u(t-t_1) - u(t-t_1)))\alpha_1 sen(\omega t) + \alpha_3 sen(3\omega t) + \alpha_5 sen(5\omega t)$	$0,1 \leq \alpha \leq 0,9$; $0,05 \leq \alpha_3 \leq 0,15$; $0,05 \leq \alpha_5 \leq 0,15$.
Harmônico e <i>swell</i>	<i>S7</i>	$f(t) = A(1 + \alpha(u(t-t_1) - u(t-t_1)))\alpha_1 sen(\omega t) + \alpha_3 sen(3\omega t) + \alpha_5 sen(5\omega t)$	$0,1 \leq \alpha \leq 0,8$; $0,05 \leq \alpha_3 \leq 0,15$; $0,05 \leq \alpha_5 \leq 0,15$.

No algoritmo desenvolvido é possível a seleção das melhores formas de ondas, sendo admissível a seleção do tipo do distúrbio, ou seja, variação entre as 6 classes (*S2* a *S7*), variação nos distúrbios como a definição da amplitude entre 0,1 até 0,9 pu (afundamento de 10% a 90%) para *sag*, de 0,09 até 0 pu para *outage* e entre 0,1 até 0,8 pu (elevação de 10% a 90%) para *swell*; além do tempo de duração do distúrbio (quantidade de ciclos).

Das formas de ondas geradas, foram usadas 200 das consideradas “melhores amostras” para treinamento da rede e outras 200 para a fase de testes. Tanto na fase de

treinamento, como nos testes de eficiência, as amostras possuem a seguinte característica básica:

- 256 pontos/ciclo, sendo possível, assim, o cálculo de até a 127ª ordem dos harmônicos;
- Frequência nominal de 60 Hz, que é o padrão brasileiro;
- Os distúrbios simulados possuem duração de 7 ciclos.

Para efeitos didáticos, nessa pesquisa, foram considerados os harmônicos fundamentais, os de 3ª, 5ª e 7ª ordem; e para a os distúrbios simultâneos “harmônico e *sag*” e “harmônico e *swell*” é considerado até o harmônico de 5ª ordem. Um conjunto de exemplos de formas de ondas indicado na Figura 9.1. mostra algumas características desses tipos de distúrbios de tensão.




Figura 9.1. – Exemplos de formas de ondas: S1: tensão normal (sinal puro), S2: afundamento de tensão (*sag*), S3: elevação de tensão (*swell*), S4: interrupção momentânea (*outage*), S5: harmônico, S6: harmônico e *sag* e S7: harmônico e *swell*.

Após análise dos cálculos do índice de normalidade ($\sigma\Delta$) de vários distúrbios e do sinal puro, o parâmetro de normalidade utilizado foi o intervalo de valores entre 0,29 e 0,30. Assim o módulo de detecção acusa a anormalidade do sinal que possuir o índice de normalidade fora desse intervalo de valores (maiores ou menores) implicando no envio da forma de onda desse sinal para o próximo módulo da rede (Extração de Características).

Também foi utilizado o programa MATLAB (*wavelet toolbox*) para executar a análise multirresolução e também para calcular a norma entropia *wavelet*. Cada um dos sinais escolhido é decomposto com o filtro *Wavelet* Daubechies (db_4) por 12 níveis. Então, baseado nas características extraídas com a equação de ΔWEN mostrada em (8.2.2.1) e com a definição dos tipos de características a serem analisados, um conjunto 5-dimensional de características é definido. Essa dimensão descreve as características relevantes de cada tipo de distúrbio.

Assim, o tamanho total do conjunto de vetores é de 5×1.200 , sendo 5 a quantidade dos coeficientes de decomposição referentes aos detalhes (d_5, \dots, d_8) e mais o de aproximação (a_{12}) e 1.200 são os 200 casos de cada uma das 6 classes de distúrbio (S_2 à S_7).

Após a definição dos vetores característicos dos distúrbios ΔWEN , estes vetores são usados como entrada da RNA. Como característica da rede ARTMAP *Fuzzy*, esses vetores, representados por linha que é a forma padrão, são codificados, normalizados e identificados com o tipo de distúrbio a que se referem (neurônio de saída da rede) como mostrado na seção 8.3..

A rede ARTMAP *Fuzzy* que conta com a estrutura e algoritmo já mencionados anteriormente (seção 5.3.2) fará o “casamento” entre os dados de entrada da rede (vetor ΔWEN) com os vetores de saída (tipo de distúrbio) predefinidos, como mostrado na Tabela 8.3..

Os parâmetros utilizados no processamento da rede ARTMAP *Fuzzy* são:

- parâmetro de escolha ($\alpha = 0,01$);
- taxa de treinamento ($\beta = 1$) – treinamento rápido;
- parâmetro de vigilância da rede ART_a ($\rho a = 0,99$);
- parâmetro de vigilância da rede ART_b ($\rho b = 0,9$);
- parâmetro de vigilância do módulo inter-ART ($\rho ab = 0,99$);

Inicialmente, todos os pesos possuem valor igual a 1, indicando assim, que não existe nenhuma categoria ativa. Assim, as Matrizes de Pesos são iniciadas da seguinte forma:

$$\circ \mathbf{W}^a \text{ (padrões de entrada)} = \begin{pmatrix} 1 & 1 & 1 & \dots & 1 \\ 1 & 1 & 1 & \dots & 1 \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & 1 & 1 & \dots & 1 \end{pmatrix}, \text{ dimensão} = 1200 \times 20.$$

$$\circ \mathbf{W}^b \text{ (padrões de saída)} = \begin{pmatrix} 1 & 1 & 1 & \dots & 1 \\ 1 & 1 & 1 & \dots & 1 \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & 1 & 1 & \dots & 1 \end{pmatrix}, \text{ dimensão} = 1200 \times 6.$$

$$\circ \mathbf{W}^{ab} \text{ (matriz inter-ART)} = \begin{pmatrix} 1 & 1 & 1 & \dots & 1 \\ 1 & 1 & 1 & \dots & 1 \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & 1 & 1 & \dots & 1 \end{pmatrix}, \text{ dimensão} = 1200 \times 1200.$$

Como visto na seção anterior, o vetor de entrada da rede ART_a é representado pelo vetor \mathbf{a} , 10-dimensional, e o vetor de entrada da rede ART_b (que corresponde à saída desejada, referente ao padrão de entrada da rede ART_a) é representado pelo vetor \mathbf{b} , que é 3-dimensional como mostrado na Tabela 8.3..

A apresentação dos pares de vetores padrões (entrada/saída) ocorreu de forma aleatória (ou pseudoaleatória), após as devidas normalizações e codificação dos complementos, desta maneira, o treinamento torna-se mais parecido com o sistema biológico. Desse modo, temos o treinamento da rede ocorrendo de forma muito rápida tornando-a pronta para a fase de simulação.

9.2. Simulação e resultados

Realizado o treinamento da rede neural testes puderam ser efetivados. Os resultados serão mostrados a seguir.

Tanto na fase de treinamento como na fase de simulação o equipamento (computador) utilizado conta com a seguinte característica:

- Propriedades da Placa Mãe:
 - Fabricante: Intel Corporation;
 - Produto: D915GAV;
- Propriedades do processador:
 - Fabricante: Intel;
 - Versão: Intel(R) Pentium(R) 4;
 - Clock externo: 200 MHz;
 - Clock (speed): 2800 MHz.
- Propriedades do cache:
 - Tipo: Interna;
 - Tamanho: 1024 KB.
- Propriedades do módulo de memória:
 - Socket: CH A DIMM0;
 - Tipo: DIMM, SDRAM;
 - Tamanho: 1024 MB;
 - Velocidade: 400 MHz.
- Sistema operacional: Microsoft Windows XP Professional;
 - Service Pack do Sistema Operacional: Service Pack 2.

Como exemplo, a seguir são mostrados alguns valores dos tipos de sinais. Assim a tabela 9.2.1. mostra um exemplo do cálculo da Transformada *Wavelet* Discreta de cada um dos tipos de sinais, como já mencionado anteriormente ($S1$ = Sinal sem distúrbio, $S2$ = Sinal com afundamento de tensão, $S3$ = Sinal com elevação de tensão, ...).

Os sinais foram decompostos até o 12º nível utilizando-se a função *db4*, assim é mostrado os valores da TWD dos coeficientes detalhe d_1 à d_{12} , e o coeficiente aproximação a_{12} .

Tabela 9.2.1. - Exemplo de valores normalizados e codificados de sinais com distúrbios.

Sinal	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10	d11	d12	a12
S1	0,0004	0,0056	0,0441	0,1102	0,9633	42,0410	818,0800	1149,0000	4,2448	4,2739	6,1131	25,5880	109,5900
S2	0,0219	0,1158	-0,0070	-0,0081	-0,0606	-2,1108	-39,1140	-51,6970	-0,4881	-0,2307	-0,1947	-0,3081	-14,9750
S3	0,0000	0,0006	0,0780	0,0181	0,0076	2,0108	38,5143	48,5190	0,2328	1,3086	1,2642	0,9067	34,5391
S4	0,0001	-0,0030	-0,0400	-0,0194	-0,1564	-11,0290	-232,4000	-302,5000	-0,3289	-0,5306	0,2290	-0,6417	-88,4020
S5	0,0585	1,0189	28,3960	935,2600	2008,9000	2364,6000	106,8900	326,2100	29,1960	53,2690	89,1090	317,4000	6112,0000
S6	0,0582	0,9194	26,4560	889,2000	1911,9000	2249,6000	63,3670	259,0100	26,3360	48,9340	81,0880	294,3300	5096,8000
S7	0,0595	1,1314	30,4880	985,0400	2113,5000	2488,5000	153,6300	398,7800	32,5640	57,9630	97,8820	342,7100	7205,8000

Quando algum sinal com distúrbio é detectado pelo módulo de detecção, os valores dos seus coeficientes, resultantes da TWD, são calculados e subtraídos dos valores dos respectivos coeficientes do sinal puro com o intuito de se obter uma melhor diferenciação entre os tipos de distúrbios. A tabela 9.2.2. exemplifica alguns valores resultantes dessa operação.

Tabela 9.2.2. - Exemplo de valores de sinais com distúrbios subtraídos dos valores do sinal puro.

Sinal	d1	d2	d3	d4	d5	d6	d7	d8	d9	d10	d11	d12	a12
S2	0,0215	0,1102	-0,0511	-0,1183	-1,0239	-44,1518	-857,1940	-1200,6970	-4,7329	-4,5046	-6,3078	-25,8961	-124,5650
S3	-0,0004	-0,0050	0,0339	-0,0921	-0,9557	-40,0302	-779,5657	-1100,4810	-4,0120	-2,9653	-4,8489	-24,6813	-75,0509
S4	-0,0003	-0,0086	-0,0841	-0,1296	-1,1197	-53,0700	-1050,4800	-1451,5000	-4,5737	-4,8045	-5,8841	-26,2297	-197,9920
S5	0,0581	1,0133	28,3519	935,1498	2007,9367	2322,5590	-711,1900	-822,7900	24,9512	48,9951	82,9959	291,8120	6002,4100
S6	0,0578	0,9138	26,4119	889,0898	1910,9367	2207,5590	-754,7130	-889,9900	22,0912	44,6601	74,9749	268,7420	4987,2100
S7	0,0591	1,1258	30,4439	984,9298	2112,5367	2446,4590	-664,4500	-750,2200	28,3192	53,6891	91,7689	317,1220	7096,2100

Para melhor visualização é mostrado, na sequência, gráficos de valores obtidos pelo cálculo da *WEN* de um sinal puro e da subtração de valores da *WEN* de sinais com distúrbios da *WEN* do sinal puro. Salientando que o coeficiente 13 que aparece nos gráficos refere-se ao coeficiente de aproximação (a_{12}).




Figura 9.2.1. - Gráfico dos valores da WEN dos coeficientes de um sinal puro (sem distúrbio).

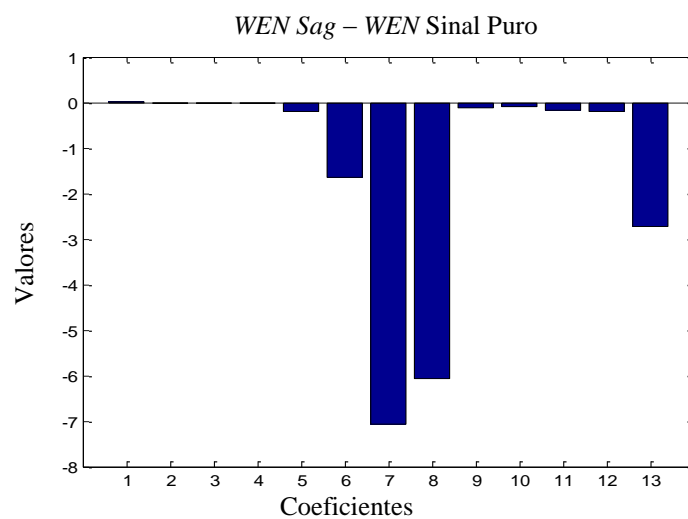


Figura 9.2.2. - Gráfico dos valores da WEN dos coeficientes de um sinal com afundamento de tensão.

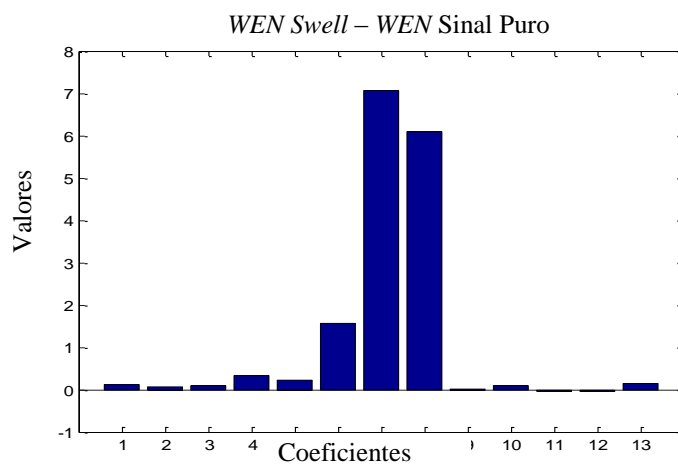


Figura 9.2.3. - Gráfico dos valores da WEN dos coeficientes de um sinal com elevação de tensão.

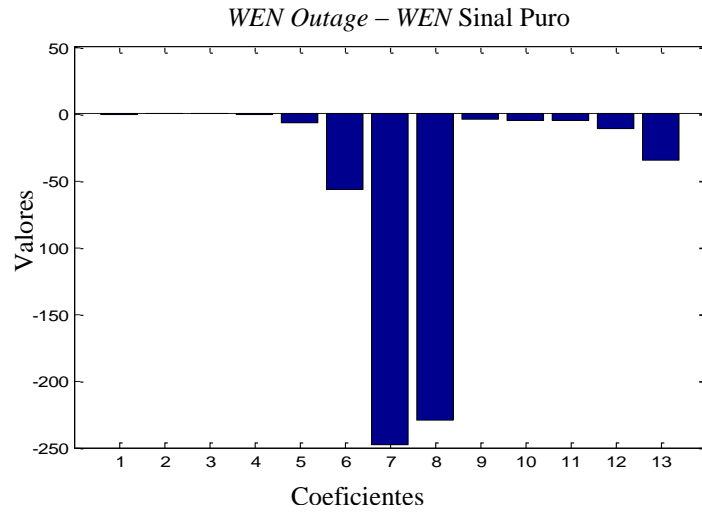


Figura 9.2.4. - Gráfico dos valores da WEN dos coeficientes de um sinal com interrupção momentânea.

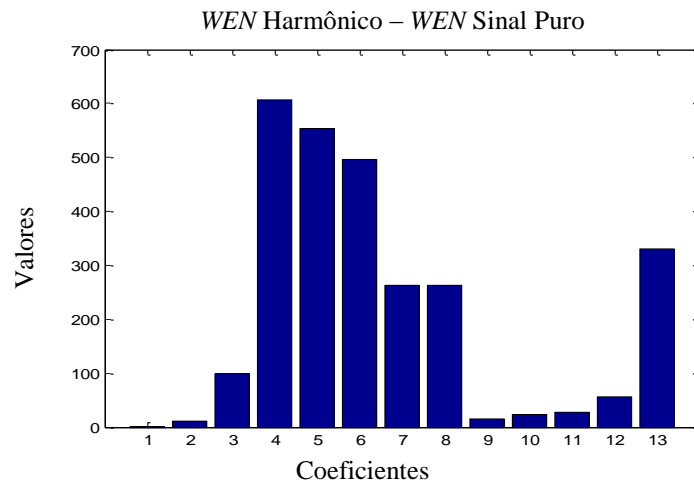


Figura 9.2.5. - Gráfico dos valores da WEN dos coeficientes de um sinal com distorção harmônica.

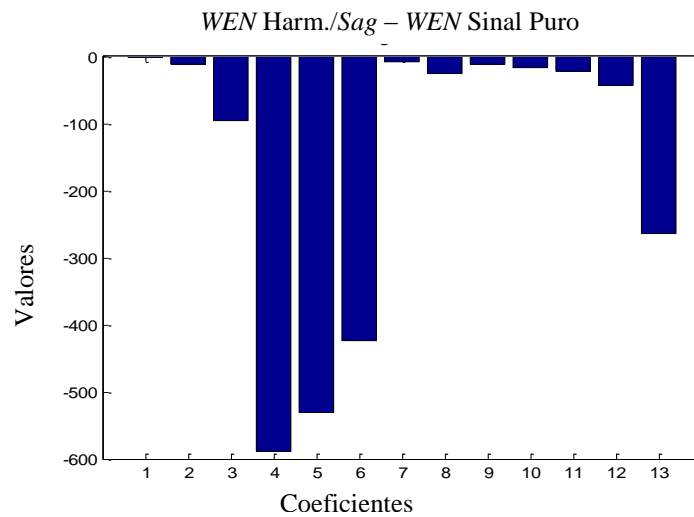


Figura 9.2.6. - Gráfico dos valores da WEN dos coeficientes de um sinal com distorção harmônica e afundamento.




Figura 9.2.7. - Gráfico dos valores da WEN dos coeficientes de um sinal com distorção harmônica e elevação de tensão.

Como os coeficientes d_5 , d_6 , d_7 , d_8 e a_{12} , possuem características mais significantes e com a intenção de se reduzir o tamanho dos dados a serem processados, apenas esses coeficientes, após serem normalizados, são utilizados. Para diferenciação de valores positivos e negativos é realizada a codificação desses valores, acrescentando-se o valor 0 (zero) para valores negativos e 1 (um) para valores positivos. Como exemplo é mostrado na tabela 9.2.3. a representação desses valores.

Tabela 9.2.3. - Exemplo de valores de coeficientes com representação de valor positivo ou negativo.

Sinais	d_5	d_6	d_7	d_8	a_{12}	Sinal de d_5	Sinal de d_6	Sinal de d_7	Sinal de d_8	Sinal de a_{12}
S2	0,0002	0,0332	1,0000	0,7667	0,0153	0	0	0	0	0
S3	0,0013	0,0414	1,0000	0,7549	0,2892	0	0	0	0	0
S4	0,0005	0,0365	1,0000	0,7683	0,2922	0	0	0	0	0
S5	0,3287	0,3869	0,0534	0,0175	1,0000	1	1	0	0	1
S6	0,3751	0,4414	0,0508	0,0124	1,0000	1	1	0	0	1
S7	0,2933	0,3453	0,0553	0,0213	1,0000	1	1	0	0	1

Em seguida, para evitar a proliferação das categorias estes valores são normalizados, como mostrado na tabela 9.2.4. Sendo estes os vetores que serão utilizados como entrada da rede ARTMAP *Fuzzy*.

Tabela 9.2.4. - Exemplo de vetores de entrada representando os sinais com distúrbios que foram detectados.

S2	0,0006	0,0195	0,3623	0,4789	0,1387	0,0000	0,0000	0,0000	0,0000	0,0000
S3	0,0002	0,0058	0,1065	0,1411	0,0408	0,1411	0,1411	0,1411	0,1411	0,1411
S4	0,0002	0,0174	0,3663	0,4768	0,1393	0,0000	0,0000	0,0000	0,0000	0,0000
S5	0,0484	0,0570	0,0026	0,0079	0,1474	0,1474	0,1474	0,1474	0,1474	0,1474
S6	0,0464	0,0546	0,0015	0,0063	0,1485	0,1485	0,1485	0,1485	0,1485	0,1485
S7	0,0437	0,0514	0,0032	0,0082	0,1489	0,1489	0,1489	0,1489	0,1489	0,1489

A codificação de complemento é realizada a fim de se preservar a amplitude das informações, gerando um vetor que contém as principais características do sinal com distúrbio. Essa codificação de complemento é realizada pela própria rede ARTMAP *Fuzzy*, que armazenará (atualizará) estes vetores na matriz de padrões de entrada (W^a), tornando-a apta a verificar com qual categoria de distúrbio cada vetor tem ressonância. Um exemplo de vetores com codificação de complementos é mostrado na tabela 9.2.5..

Tabela 9.2.5. - Exemplo de alguns vetores da matriz W^a (padrões de entrada) que representam os sinais com distúrbios.

S2	0,0006	0,0195	0,3623	0,4789	0,1387	0,0000	0,0000	0,0000	0,0000	0,0000	0,9994	0,9805	0,6377	0,5211	0,8613	1,0000	1,0000	1,0000	1,0000	1,0000
S3	0,0002	0,0058	0,1065	0,1411	0,0408	0,1411	0,1411	0,1411	0,1411	0,1411	0,9998	0,9942	0,8935	0,8589	0,9592	0,8589	0,8589	0,8589	0,8589	0,8589
S4	0,0002	0,0174	0,3663	0,4768	0,1393	0,0000	0,0000	0,0000	0,0000	0,0000	0,9998	0,9826	0,6337	0,5232	0,8607	1,0000	1,0000	1,0000	1,0000	1,0000
S5	0,0484	0,0570	0,0026	0,0079	0,1474	0,1474	0,1474	0,1474	0,1474	0,1474	0,9516	0,9430	0,9974	0,9921	0,8526	0,8526	0,8526	0,8526	0,8526	0,8526
S6	0,0464	0,0546	0,0015	0,0063	0,1485	0,1485	0,1485	0,1485	0,1485	0,1485	0,9536	0,9454	0,9985	0,9937	0,8515	0,8515	0,8515	0,8515	0,8515	0,8515
S7	0,0437	0,0514	0,0032	0,0082	0,1489	0,1489	0,1489	0,1489	0,1489	0,1489	0,9563	0,9486	0,9968	0,9918	0,8511	0,8511	0,8511	0,8511	0,8511	0,8511

A matriz W^b (padrões de saída) que representa o conjunto de distúrbios com codificação de complemento, que é realizada pela própria rede ARTMAP *Fuzzy*, é exemplificado na tabela a seguir.

Tabela 9.2.6. - Exemplo de alguns valores da matriz W^b (padrões de saída) que representam os tipos de distúrbios.

S2	0.0000	0.0000	1.0000	1.0000	1.0000	0.0000
S3	0.0000	1.0000	0.0000	1.0000	0.0000	1.0000
S4	0.0000	1.0000	1.0000	1.0000	0.0000	0.0000
S5	1.0000	0.0000	0.0000	0.0000	1.0000	1.0000
S6	1.0000	0.0000	1.0000	0.0000	1.0000	0.0000
S7	1.0000	1.0000	1.0000	0.0000	0.0000	0.0000

Alguns valores da matriz W^{ab} (módulo Inter-ART) que contém os pesos resultantes da ressonância adaptada dos vetores da matriz de entrada W^a e da matriz de saída W^b , denominado módulo Inter-ART, que indicam qual o neurônio vencedor podem ser vistos na tabela 9.2.7..

Tabela 9.2.7. - Exemplo de alguns valores da matriz W^{ab} que representam o neurônio vencedor da ressonância adaptativa.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	...	1197	1198	1199	1200
1	1,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	...	0,0000	0,0000	0,0000	0,0000
2	0,0000	1,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	...	0,0000	0,0000	0,0000	0,0000
3	0,0000	0,0000	1,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	...	0,0000	0,0000	0,0000	0,0000
4	0,0000	0,0000	0,0000	1,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	...	0,0000	0,0000	0,0000	0,0000
5	0,0000	0,0000	0,0000	0,0000	1,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	...	0,0000	0,0000	0,0000	0,0000
6	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	...	1,0000	1,0000	1,0000	1,0000
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮		⋮	⋮	⋮	⋮
1199	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	...	1,0000	1,0000	1,0000	1,0000
1200	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	...	1,0000	1,0000	1,0000	1,0000

Finalizando a exemplificação, a rede ARTMAP Fuzzy, fornece um relatório contendo os neurônios vencedores do módulo ART_a representando os sinais com distúrbio, os neurônios vencedores do módulo ART_b representando os tipos de distúrbios e o resultado da classificação (codificação binária predefinida). Como pode ser observado na a tabela 9.2.8..

Tabela 9.2.8. - Exemplo do relatório com o resultado da classificação de distúrbio.

Exemplo	Neurônio vencedor sobre F2a	Neurônio vencedor sobre F2b	Codificação de saída
Sinal S2	1	1	0 0 1
Sinal S3	2 ou 3	2	0 1 0
Sinal S4	4 ou 5	3	0 1 1
Sinal S5	6 ou 7	4	1 0 0
Sinal S6	8	5	1 0 1
Sinal S7	9 ou 10	6	1 1 1

O tempo total de execução da rede ARTMAP *Fuzzy*, abrangendo as fases de treinamento e simulação foi menos de 1 (um) segundo, tempo que pode ser considerado excelente comparado com outros tipos de rede neural artificial. Tempo que sugere uma eficiência enorme considerando que o computador utilizado está longe de ter uma configuração voltada para um alto desempenho de processamento, comparados aos computadores mais atuais.

O resultado alcançado na simulação da classificação dos sinais puros e com distúrbios atingiu a taxa de 100%, ou seja, a rede conseguiu identificar os 200 sinais puros, detectar e classificar corretamente todos os outros 1.200 (mil e duzentos) tipos de distúrbios, distribuídos nas seis categorias predefinidas, que lhe fora apresentado, conforme mostra a tabela 9.2.9.

Tabela 9.2.9. - Resultados da simulação.

Tipo de sinal	Classe	Número de amostras	Detecção	Classificação
Sinal Puro	<i>S1</i>	200	100 %	-
Afundamento de tensão	<i>S2</i>	200	100 %	100 %
Elevação de tensão	<i>S3</i>	200	100 %	100 %
Interrupção momentânea	<i>S4</i>	200	100 %	100 %
Harmônico	<i>S5</i>	200	100 %	100 %
Harmônico e afundamento de tensão	<i>S6</i>	200	100 %	100 %
Harmônico e elevação de tensão	<i>S7</i>	200	100 %	100 %
Total		1.400	100 %	100%

A arquitetura ARTMAP *Fuzzy*, além da obtenção de respostas rápidas e precisas, possibilitou a formatação dos dados de entrada e de saída para conter a maior diversidade possível. Contendo, assim, uma estrutura com capacidade de realizar análise de sinais considerando-se um grande número de distúrbios de tensão.

Considerando-se os tipos de distúrbios simulados, o desempenho do sistema neural proposto foi excelente. Espera-se que o desempenho seja mantido com o aumento do número de distúrbios a serem analisados, visto que a diversidade de distúrbios de tensão é bastante grande, mas seu grande potencial foi demonstrado.

Com a inclusão de um dispositivo que contemple o treinamento continuado e com o passar do tempo, pode-se almejar a obtenção de soluções para inúmeros tipos de distúrbio com esse nível de precisão.

CAPÍTULO 10

CONCLUSÕES E SUGESTÃO PARA TRABALHOS FUTUROS

10.1. Conclusões

Nessa pesquisa o desenvolvimento de um modelo moderno e eficiente de detector/classificador automático de anomalias de tensão através de uma rede *Neuro-Fuzzy-Wavelet* foi proposto. A classificação dos distúrbios é realizada através da execução da extração de características e análise das formas de onda, com anomalia, através da Transformada *Wavelet* Discreta (TWD) e da Norma Entropia *Wavelet*, sendo que a classificação dos distúrbios de tensão é executada por meio de uma RNA, ou seja, usando a concepção neural ARTMAP *Fuzzy*.

Muitas vezes, várias aplicações práticas, incluindo classificação de distúrbios de tensão, exigem uma grande capacidade computacional para lidar com a complexidade ou limitações de tempo-real. Frequentemente computadores tradicionais não podem alcançar rapidamente essa capacidade, ou eles são muito caros ou nem sempre podem ser disponibilizados.

A principal vantagem do método proposto é a redução do tamanho dos dados a serem analisados e o reconhecimento das principais características do sinal sem perder as características do sinal original. Além da redução do espaço alocado em memória, já que serão analisados apenas os sinais comprovadamente com distúrbio e a pequena necessidade de pré-processamento, que propiciam uma rápida solução do referido problema.

Mencionando, ainda, a absoluta eficiência na classificação das anomalias dos sinais gerados, 100% de acerto, ínfimo tempo gasto com o treinamento da rede e a alta velocidade de processamento, inerentes ao uso do algoritmo ARTMAP *Fuzzy*.

Os resultados dos testes apontam para o enorme potencial na implementação dessa rede em um sistema de monitoramento de distúrbios. Trata-se de um resultado de grande relevância no contexto dos sistemas elétricos de potência, tendo em vista a carência de resultados concretos neste sentido.

Assim, a concepção desse sistema de inferência (*neuro-fuzzy-wavelet*) permite realizar a detecção e classificação de distúrbios de forma robusta e com grande rapidez na obtenção do resultado, possibilitando sua aplicação em um sistema de tempo real, visto que todo esforço computacional (muito pequeno) é alocado, basicamente, na fase de treinamento. Somente uma pequena parcela de tempo computacional é necessária para a efetivação das análises.

10.2. Sugestão para Trabalhos Futuros

Os resultados produzidos nesta pesquisa podem ser considerados satisfatórios (no contexto da precisão e da rapidez na obtenção das soluções), conforme argumentado anteriormente. Porém, sugerem-se algumas melhorias e procedimentos que podem ser implementados com o propósito de tornar esta metodologia mais eficiente:

- Inclusão de um dispositivo que contemple o treinamento continuado (MARCHIORI, et al., 2010), permitirá contemplar outros tipos de distúrbios tais como *flicker*, *notching*, impulsivos e outros, a fim de serem analisados com esse mesmo nível de precisão;
- Inclusão de um dispositivo, agregado ao sistema aqui proposto, para localização da fonte de geração dos distúrbios de tensão.

CAPÍTULO 11

REFERÊNCIAS

ABDEL-GALIL, T.K.; EL-SAADANY, E.F.; YOUSSEF, A.M.; and SALAMA, M.M.A. Disturbance classification using hidden Markov models and vector quantization. *IEEE Transactions on Power Delivery*, New York, v.20, n.3, 2005.

AL-JUFOUT, S. A. Online condition-monitoring of electrical power system imbalance. *Internacional Journal of Energy Technology and Policy*, [S. l.], v.5, n.6, p.684-691, 2007.

ALLEN, D. E.; APOSTOLV, A. and KREISS, D. Automated analysis of power system events, *IEEE Power & Energy magazine*, New York, v.3, n.5, p.48-55, 2005.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL. Resolução Normativa ANEEL n° 505. 11 p., 26 de novembro de 2001.

ARRUDA, E. F. D.; FILHO, O. D.; COURY, D. V.; CARNEIRO, A. A. F. M. Um estudo das famílias wavelets aplicadas à qualidade da energia elétrica. *In: CONGRESSO BRASILEIRO DE AUTOMÁTICA – CBA, 14., 2002, Natal. Anais... Natal: [s.n.], 2002, p.1749-1754.*

AXELBERG, P. G. V.; IRENE, Y. H. G.; BOLLEN, M. H. J. Support vector machine for classification of voltage disturbances. *IEEE Transactions on Power Delivery*, [S.l.], v.22, n.3, p.1297-1303, 2007.

BOLLEN, M. H. J. *Understanding power quality problems: voltage sags and interruptions*. New York: IEEE , 2000. 543 p.

BRIGHAM, E. *Fast Fourier transform and its applications*. Upper Saddle River: Prentice-Hall, 1988. 448 p.

BURRUS, C. S.; GOPINATH, R. A.; GUO, H. *Introduction to wavelets and wavelet transforms: a primer*. New Jersey: Prentice Hall, 1998. 268 p.

CARPENTER, G. A.; GROSSBERG, S. A Massively parallel architecture for a self-organizing neural pattern recognition machine. *Computer Vision, Graphics and Image Processing*, New York, v.37, p.54-115, 1987a.

CARPENTER, G. A.; GROSSBERG, S. ART2: Self-organizing of stable category recognition codes for analog input patterns. *Applied Optics*, New York, v.26, p.4919-4930, 1987b.

CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. *Neural Networks*, New York, v.4, n.1, p.759-771, 1991a.

CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: supervised real-learning and classification of non-stationary data by a self-organizing neural network. *Neural Network*, New York, v.4, n.5, p.565-588, 1991b.

CARPENTER, G. A.; GROSSBERG, S.; MARKUZON, N.; REYNOLDS, J. H.; ROSEN, D. B. Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps. *IEEE Transactions on Neural Networks*, New York, v.3, n.5, p.689-715, 1992.

CARPENTER, G. A.; GROSSBERG, S. A self-organizing neural network for supervised learning, recognition and prediction. *IEEE Communications Magazine*, New York, v.30, n.9, p.38-49, 1992.

CHILUKURI, M.V.; DASH, P.K. Multiresolution S-transform-based fuzzy recognition system for power quality events. *IEEE Transactions on Power Delivery*, New York, v.19, n.1, p.323-330, 2004.

DASH, S.K.; MISHRA, S.; SALAMA, M. M. A.; LIEW, A. C. Classification of power system disturbances using a fuzzy expert system and a Fourier linear combiner. *IEEE Transactions on Power Delivery*, New York, v.15, n.2, p.472-477, 2000.

DAUBECHIES, I. *Ten Lectures on wavelets, society for industrial and applied mathematics*. Philadelphia, [s.n.], 1992. 357 p.

DAUBECHIES, I. Where do wavelets come from? A personal point of view. *Proceedings of IEEE Special Issue on Wavelets*, New York, v.84, n.4, p.510-513, 1996.

DUGAN, R. C.; MC GRANAGHAN, M. F.; BEATY, H. W. *Electrical power systems quality*. New York: McGraw-Hill, 1996. 265 p.

GAOUDA, A. M.; KANOUN, S. H.; SALAMA, M. M. A. On-line disturbance classification using neighbor rule. *Electric Power System Research*, Lausanne, v.57, n.1, p.1-8, 2001.

GERMEN, E.; ECE, D. G.; GEREK, Ö. N. Self organizing map (SOM) approach for classification of power quality events. *IEEE Transactions on Power Delivery*, New York, v.3696, p.403-408, 2005.

GHOSH, A. K.; LUBKEMAN, D. L. The classification of power system disturbance waveforms using a neural network approach. *IEEE Transactions on Power Delivery*, New York, v.10, p.109-115, 1995.

GRAPS, A. An Introduction to wavelets. *IEEE Computational Science and Engineering*, Los Alamitos, v.2, p.1-18, 1995.

GROSSBERG, S. Adaptive pattern classification and universal recoding, I: parallel development and coding of neural feature detectors. *Biological Cybernetics*, New York, v.23, n.3, p. 121-134, 1976.

HAYKIN, S. *Neural networks: A comprehensive foundation*. Upper Saddle River: Prentice-Hall, 1994. 768 p.

HE, H.B.; STARZYK, J.A. A Self-organizing learning array system for power quality classification based on wavelet transform. *IEEE Transactions on Power Delivery*, New York, v.21, n.1, p.286-295, 2006.

HERNANDES, E.; WEISS, G. *A First course on wavelet*. Boca Raton: CRC, 1996. v.26, 489p.

HEYDT, G. T. et al. Applications of the windowed FFT to electric power quality assessment. *IEEE Transactions on Power Delivery*, New York, v.14, n.4, p.1411-1416, 1999.

AMERICAN NATIONAL STANDARDS INSTITUTE. *ANSI/IEEE Std 944-1986: recommended practice for the application and testing of uninterruptible power supplies for power generating stations*. New York, 1986.

AMERICAN NATIONAL STANDARDS INSTITUTE. *ANSI/IEEE Std 446-1995: recommended for emergency and stand-by power systems for industrial and commercial applications*. New York: Orange Book, 1995.

INSTITUTE OF ELECTRICAL AND ELECTRONIC ENGINEERS-IEEE. *Std 1159-1995*: recommended practice for monitoring electric power quality. New York: IEEE. 1995. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=475495>>. Acesso em: 24 jul. 2009.

INSTITUTE OF ELECTRICAL AND ELECTRONIC ENGINEERS-IEEE. *Std 1250-1995*: guide for service to equipment sensitive to momentary voltage disturbance. New York: IEEE. 1995. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=467536>>. Acesso em: 24 jul. 2009

KARTALOPOULOS, S. V. *Understanding neural network and fuzzy logic*. New York: IEEE, 1996. 232 p.

KUNDUR, P. *Power system stability and control*. New York: McGraw-Hill, 1994. 1176 p.

LI, Z.Y.; WU, W.L. Detection and identification of power disturbance signals based on nonlinear time series. In: IEEE WORLD CONGRESS ON INTELLIGENT CONTROL AND AUTOMATION, 6., 2006, Dalian, *Preceding...* [S.l.; s.n.], 2006. p.7646-7650.

LIAO, Y.; LEE, J.B. A fuzzy-expert system for classifying power quality disturbances. *Int. J. Electric Power & Energy System*, Oxford, v.26, n.3, p.237-250, 2004.

LOESCH, C.; SARI, S. T. *Redes neurais artificiais: fundamentos e modelos*. Blumenau: FURB, 1996. 166 p.

MALLAT, S. *A Wavelet tour of signal processing wavelet analysis & its applications*. Los Angeles: Academic Press-Elsevier, 1998. 577 p.

MARCHIORI, S. C.; MINUSSI, C. R., LOTUFO, A. D. P. Rede neural ARTMAP nebulosa para análise de estabilidade transitória de sistemas de energia elétrica. *Revista da Sociedade Brasileira de Redes Neurais - Learning and Nonlinear Models*, Rio de Janeiro, v.1, n.1, p.61-78, 2002.

MARCHIORI, S. C.; SILVEIRA, M. C. G.; LOTUFO, A. D. P.; MINUSSI, C. R., LOPES, M.L.M. Neural network based an adaptive resonance theory with continuous training for multi-configuration transient stability analysis of electric power systems. *Applied Soft Computing*, Bedford, 2010. (In press).

McCULLOCH, W.; PITTS, W. A. A logical calculus of the ideas imminent in nervous activity. *Bulletin of Mathematical Biophysics*, New York, v.5, p.114-133, 1943.

MEYER, Y. *Wavelets algorithms & applications*. 2.ed. Philadelphia: Society for Industrial and Applied Mathematics-SIAM, 1993. 133 p.

MISITI, M.; MISITI, Y.; OPPENHEIM, G.; POGGI, J. M. *Wavelet toolbox: user's guide*. Natick: The Math Works, 1997. 626 p.

MORLET, J.; GOUPILLAUD, P.; GROSSMAN, A. Cycle-octave and related transforms in seismic signal analysis. *Geoexploration*, Amsterdam, v.23, p.85-102, 1984.

OLIVEIRA, J. C. D. *Projeto SIDAQEE qualidade da energia elétrica: definição e análise dos itens de qualidade*. Uberlândia: Universidade Federal de Uberlândia, 2000. 47 p.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO - ONS. *Procedimentos de rede - padrões de desempenho da rede básica: Submódulo 2.2*. [S.l.: s.n., 2000?]. Disponível em: <www.ons.org.br>. Acesso em: 04 jun. 2008.

RIOUL, O.; VETTERLI, M. Wavelets and signal processing. *IEEE Signal Processing Magazine*, New York, v.8, p.14-38, 1991.

ROSS, T. J. *Fuzzy Logic with engineering applications*. 2.ed. Hobo Ken: John Wiley, 2004. 650 p.

SANTOSO, S.; POWERS, E. J.; GRADY, W. M.; HOFMANN, P. Power quality assessment via wavelet transform analysis. *IEEE Transactions on Power Delivery*, New York, v.11, n.2, p.924-930, 1996.

SANTOSO, S.; POWERS, E. J.; GRADY, W. M.; PARSONS, A. C. Power quality disturbance waveform recognition using wavelet-based neural classifier. I. Theoretical foundation. *IEEE Transactions on Power Delivery*, New York, v.15, n.1, p.222-228, 2000.

SILVEIRA, M. C. G; LOTUFO, A. D. P; MINUSSI, C. R. Transient stability analysis of electrical power systems using a neural network based on fuzzy ARTMAP. *Electric Power Systems Research*, Lausanne, v.3, p.7, 2003.

TIWARI, A.K.; SHUKLA, K. K. Wavelet transform based fuzzy inference system for power quality classification. *Lecture Notes in Computer Science*, Berlin, v.2275, p.1386-1394, 2002.

TONG, W.M.; SONG, X.L.; ZHANG, D.Z. Recognition and classification of power quality disturbances based on self-adaptive wavelet neural network. *Lecture Notes in Computer Science*, Berlin, v.1228, p.385-393, 2006.

UYAR, M.; YILDIRIMA, S.; GENCOGLUB, M. T. An effective wavelet-based feature extraction method for classification of power quality disturbance signals. *Electric Power Systems Research*, Lausanne, v.78, p.1747-1755, 2008.

VAPNIK, V. N. *The Nature of statistical learning theory*. Springer: New York, 1995. 314p.

VIEIRA, R. C.; TENÓRIO, M. B.; ROISENBERG, M.; BORGES, P. S. S. Comparação entre redes neurais artificiais e rough sets para classificação de dados. In: BRAZILIAN CONFERENCE ON NEURAL NETWORKS, v. 6, 2003, São Paulo, *Anais...* São Paulo: [S.n.], 2003. p.175-178.

WANG, M.; MAMISHEV, A.V. Classification of power quality events using optimal time-frequency representations. *IEEE Transactions on Power Delivery*, New York, v.19, n.3, p.1488-1503, 2004.

WASSERMAN, P. D. *Neural computing: theory and practice*. [S.l.]: Van Nostrand Reinhold, 1989. 230 p.

WERBOS, P. J. *Beyond regression: new tools for prediction and analysis in the behavioral sciences*. 1974. Thesis (Master) - Harvard University, Cambridge, 1974.

WIDROW, B.; LEHR, M. A. 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. *Proceedings of the IEEE*, New York, v.78, n.9, p.1410-1442, 1990.

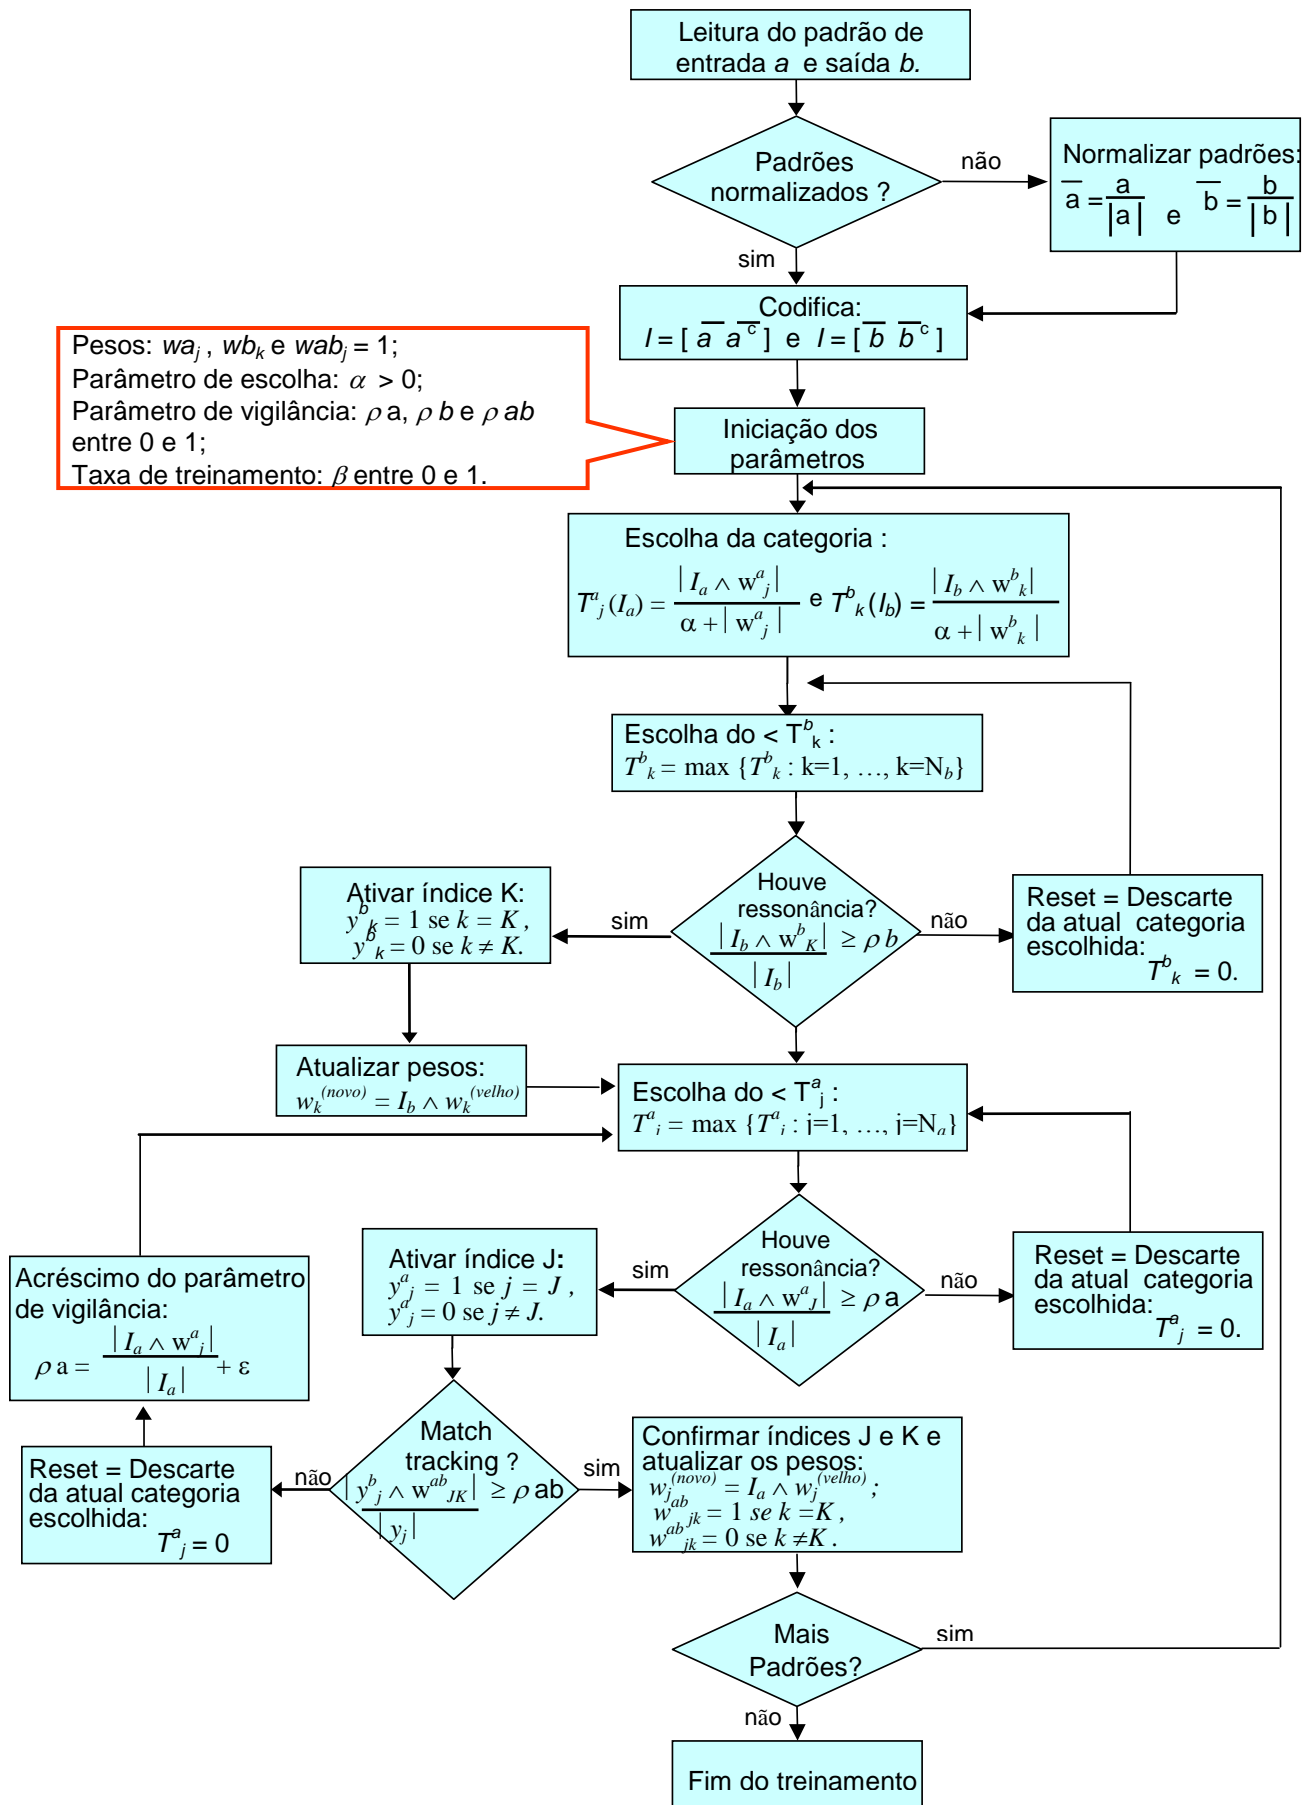
ZADEH, L. A. Fuzzy sets. *Information and Control*, New York, v.8, n.1, p.338-353, 1965.

ZHANG, G.; RONG, H.; HE, L.; JIN, W. Entropy feature extraction approach for radar emitter signals. In: INTERNATIONAL CONFERENCE ON INTELLIGENT MECHATRONICS AND AUTOMATION, 1., 2004, Chengdu. *Proceeding...* [S.l.: s.n.], 2004. p.621-625.

Apêndice A

Fluxograma de aprendizagem da rede ARTMAP *Fuzzy*

Para uma compreensão mais facilitada é apresentado, a seguir, o Fluxograma que estabelece os procedimentos do algoritmo de aprendizagem da rede ARTMAP *Fuzzy*.

Fluxograma do algoritmo de aprendizagem da rede ARTMAP *Fuzzy*.

Apêndice B

Artigos Publicados e Submetido Relacionados com esta Pesquisa de Doutorado

1. Malange, Fernando C. V. e Minussi, C. R. Rede Neural ARTMAP-*Fuzzy* e Transformada *Wavelet* para detecção e classificação de distúrbios de tensão em sistemas de Energia Elétrica, *Congresso Brasileiro de Redes Neurais / Inteligência Computacional*, 9. Ouro Preto, 2009.
2. Malange, Fernando C. V. e Minussi, C. R. Rede Neural Artmap-*Fuzzy* e Transformada *Wavelet* Para Detecção e Classificação de Distúrbios de Tensão em sistemas de Energia Elétrica, *Learning & Nonlinear Models (L&NLM)*, *Revista da Sociedade Brasileira de Redes Neurais (SBRN)*, *Brazilian Regional Interest Group of the IEEE Neural Network Council*, ‘Qualis A’ na CAPES, ISSN:1676-2789, v.7, n.1, 2009.
3. Malange, Fernando C. V. e Minussi, C. R. Rede Neuro-Fuzzy-Wavelet para Detecção e Classificação de Anomalias de Tensão em Sistemas Elétricos de Potência. *The 8th Latin-American Congress on Electricity Generation And Transmission – CLAGTEE*. Ubatuba, Art. 515, 2009.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)