



Universidade Federal de Campina Grande
Centro de Engenharia Elétrica e Informática
Programa de Pós-Graduação em Engenharia Elétrica

Tese

*Um Localizador de Falhas de Alta Impedância
a partir de Dados Reais Utilizando
Inteligência Artificial*

José Antônio Cândido Borges da Silva

Campina Grande - Paraíba - Brasil

©José Antônio Cândido Borges da Silva, Março de 2016.

José Antônio Cândido Borges da Silva

***Um Localizador de Falhas de Alta Impedância
a partir de Dados Reais Utilizando
Inteligência Artificial***

*Tese apresentada à Coordenação do
Programa de Pós-graduação em Engenharia
Elétrica da Universidade Federal de Campina
Grande, em cumprimento parcial às exigências
para obtenção do Grau de Doutor em Ciências no
Domínio da Engenharia Elétrica.*

Área de Concentração: Processamento da Energia

Prof. Washington Luiz Araújo Neves, Ph.D.

Orientador

Prof. Benemar Alencar de Souza, D.Sc.

Orientador

Campina Grande - Paraíba - Brasil

Março de 2016.

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL DA UFCG

S586l Silva, José Antônio Cândido Borges da.
Um localizador de faltas de alta impedância a partir de dados reais utilizando inteligência artificial / José Antônio Cândido Borges da Silva. – Campina Grande, 2016.
135 f. : il.

Tese (Doutorado em Engenharia Elétrica) – Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, 2016.
"Orientação: Prof. Dr. Washington Luiz Araújo Neves e Prof. Dr. Benemar Alencar de Souza".
Referências.

1. Faltas de Alta Impedância. 2. Transformada Wavelet. 3. Redes Neurais Artificiais. 4. Sistemas de Distribuição.
I. Neves, Washington Luiz Araújo. II. Souza, Benemar Alencar de. III. Título.

CDU 621.316(043.2)

**"UM LOCALIZADOR DE FALTAS DE ALTA IMPEDÂNCIA EM SISTEMAS DE
DISTRIBUIÇÃO UTILIZANDO INTELIGÊNCIA ARTIFICIAL"**

JOSÉ ANTÔNIO CÂNDIDO BORGES DA SILVA

TESE APROVADA EM 11/03/2016



BENEMAR ALENCAR DE SOUZA, D.Sc., UFCG
Orientador(a)



WASHINGTON LUIZ ARAÚJO NEVES, Ph.D., UFCG
Orientador(a)



JOSÉ ROBERTO SANCHES MANTOVANI, Dr, FEIS-UNESP
Examinador(a)

LUCIANE NEVES CANHA, Dr., UFSM
Examinador(a)



RONALDO RIBEIRO BARBOSA DE AQUINO, D.Sc, UFPE
Examinador(a)



EDSON GUEDES DA COSTA, D.Sc., UFCG
Examinador(a)



NUBIA SILVA DANTAS BRITO, D.Sc., UFCG
Examinador(a)

CAMPINA GRANDE - PB

A Juliana, minha querida esposa,
ao meu amado filho Davi Antônio,
à minha iluminada mãe Zeni
DEDICO.

*“Nós somos o que fazemos repetidamente, a excelência não é um feito,
e sim, um hábito.”*

(Aristóteles)

Agradecimentos

Meus sinceros agradecimentos:

- Primeiramente a Deus, por tudo que tem me dado em minha existência.
- Ao povo brasileiro que contribui com o pagamento de seus impostos, tendo proporcionado que a Capes tenha parcialmente dado suporte financeiro.
- Aos meus pais Severino e Maria José, meus irmãos Francisco de Assis e Inez, minha avó Lia (*in memoriam*), todos os outros avós falecidos, meus tios, tias, sobrinhos, primos e primas por representarem muito em minha vida.
- À minha esposa Juliana pelo carinho, companheirismo, contínua cobrança e incentivo para a finalização desse trabalho; além de ter me dado a razão do meu viver: meu filho Davi Antônio.
- Aos meus sogros e cunhados, por me proporcionarem uma segunda família.
- À Energisa pelo apoio técnico e financeiro durante o Projeto que resultou nessa Tese.
- À Coordenação de Pós-Graduação de Engenharia Elétrica (Copele) da Universidade Federal de Campina Grande (UFCG), incluindo os funcionários Pedro, Ângela, Felipe e Eleonora.
- Ao Instituto Federal de Educação, Ciência e Tecnologia da Paraíba (IFPB) pelo apoio e por me proporcionar um ambiente salutar de trabalho.
- Aos companheiros de trabalho no Tribunal Regional Eleitoral (TRE-PB), especialmente no NATT-CG.

- Aos professores, orientadores e amigos Benemar Alencar de Souza e Washington Luiz Araújo Neves, pelo contínuo estímulo e incentivo, compreensão e confiança em mim depositadas e por suas importantes sugestões no desenvolvimento deste trabalho. Destaco também a paciência nesses anos, desde os tempos da Graduação.
- Ao Professor Edson Guedes da Costa por ter me proporcionado a chance de fazer parte do Grupo de Sistemas Elétricos através de minha primeira Bolsa de Iniciação Científica, ter participado da minha banca e de forma bem especial, por ter efetuados as cobranças mais duras para que esse estágio fosse alcançado.
- À Professora Núbia Brito pelas valiosas contribuições para a Tese, na participação da banca, assim como pela convivência nos Projetos de Pesquisa e Desenvolvimento e no ambiente do Laboratório de Alta Tensão.
- Ao Professor Damásio Fernandes pela salutar convivência desde os tempos do Laboratório de Alta Tensão, e por sempre poder contar nos momentos de dúvidas.
- Aos Professores e amigos George Rossany, Karcus Marcelus e Tarso Vilela por sempre me darem suporte técnico e pessoal quando precisava.
- Aos ex-colegas de doutorado e hoje professores da UFCG George Acioli e Jaidilson Jó pela amizade cultivada.
- Aos alunos do Laboratório de Alta Tensão Jalberth e Filipe pela gentil cessão de um computador com maior capacidade de memória para agilizar as simulações.
- Aos amigos e colegas do longo período de doutorado: Franklin, Luciano, Estácio, Ângelo, Helon, Diana, Kleber, Ronimack, Fabiano, pela amizade e convivência no dia-a-dia.

- A Wellinsílvio Santos pelas discussões acerca do tema e pelo trabalho conjunto realizado no Projeto de Pesquisa e Desenvolvimento com a Energisa.
- A Flávio Bezerra Costa, pela amizade de mais de 20 anos, além das inúmeras e infindáveis discussões a respeito do tema.
- Aos membros da banca examinadora José Roberto Sanches Mantovani, Ronaldo Ribeiro Barbosa de Aquino e Luciane Neves Canha, pelas sugestões e críticas construtivas.

Sumário

LISTA DE FIGURAS	VIII
LISTA DE TABELAS	X
RESUMO.....	XII
ABSTRACT	XIII
CAPÍTULO 1 INTRODUÇÃO	1
1.1 MOTIVAÇÃO E RELEVÂNCIA DA PROPOSTA DE TESE	1
1.2 OBJETIVO E CONTRIBUIÇÕES DA TESE.....	4
1.3 ORGANIZAÇÃO DO TEXTO	6
CAPÍTULO 2 FUNDAMENTAÇÃO TEÓRICA	8
2.1 FALTAS DE ALTA IMPEDÂNCIA (FAI).....	8
2.2 REDES NEURAIS ARTIFICIAIS.....	10
2.2.1 Modelo e Estrutura dos Neurônios	11
2.2.2 Redes MLP.....	13
2.2.3 Redes SOM	21
2.3 FUNDAMENTOS DA TRANSFORMADA <i>WAVELET</i>	24
2.3.1 Transformada <i>Wavelet</i> Contínua.....	25
2.3.2 Transformada <i>Wavelet</i> Discreta.....	28
2.3.3 Transformada <i>Wavelet</i> Discreta Redundante	33
2.3.4 Análise da Energia das Componentes dos Sinais.....	35
CAPÍTULO 3 REVISÃO BIBLIOGRÁFICA.....	37
3.1 DETECÇÃO DAS FAI	37
3.1.1 Transformada <i>Wavelet</i> e Redes Neurais Artificiais	38
3.1.2 Outras Contribuições	44
3.2 LOCALIZAÇÃO DAS FAI EM SISTEMAS DE DISTRIBUIÇÃO	47
3.3 ENSAIOS EXPERIMENTAIS COM AS FAI	55
CAPÍTULO 4 METODOLOGIA DESENVOLVIDA	57

4.1	LOCALIZADORES PROPOSTOS.....	58
4.2	MODELAGEM DO ALIMENTADOR UTILIZADO.....	61
4.3	MODELAGEM DAS FAI.....	65
4.3.1	Panorama.....	66
4.3.2	Procedimento Experimental.....	68
4.3.3	Modelo de FAI Adotado.....	74
4.4	BASES DE DADOS.....	77
4.4.1	Construção Automatizada.....	78
4.4.2	Pré-processamento.....	80
4.5	IMPLEMENTAÇÕES.....	82
4.5.1	Estruturas de RNA.....	82
4.5.2	<i>Software</i> AnFAI.....	87
CAPÍTULO 5 ANÁLISE DOS RESULTADOS.....		89
5.1	PARTICULARIDADES DAS SIMULAÇÕES.....	89
5.2	REDES TREINADAS.....	92
5.3	RESULTADOS DA MLP LOCALIZADORA.....	94
5.3.1	Dados Reais.....	110
5.3.2	Inicializações da Rede.....	111
5.4	RESULTADOS DA SOM.....	113
CAPÍTULO 6 CONCLUSÕES E PERSPECTIVAS DE TRABALHOS FUTUROS.....		120
6.1	CONCLUSÕES.....	120
6.2	PERSPECTIVAS DE TRABALHOS FUTUROS.....	122
REFERÊNCIAS BIBLIOGRÁFICAS.....		124
APÊNDICE A PUBLICAÇÕES REALIZADAS.....		134

Lista de Figuras

Figura 2.1. Forma de onda de uma FAI (Adaptado de (COSTA et al, 2015)).....	10
Figura 2.2. Modelo não-linear de um neurônio (Adaptado de (HAYKIN, 1999)).....	11
Figura 2.3. Estrutura MLP (<i>Multilayer Perceptron</i>) (Adaptado de (HAYKIN, 1999)).....	14
Figura 2.4. Topologia do mapa de Kohonen (LIRA, 2012).....	22
Figura 2.5. <i>Wavelet</i> Chapéu Mexicano (Fonte: Próprio Autor).....	28
Figura 2.6. TWD direta: (a) bloco da TWD direta; (b) três estágios da TWD direta. (Adaptado de (SILVA, 2009)).....	29
Figura 2.7. TWD inversa: (a) bloco da TWD inversa; (b) três estágios da TWD inversa (Adaptado de (SILVA, 2009)).....	32
Figura 3.1. Equivalente para análise de faltas para o método de Takagi. (a) Circuito pré-falta. (b) Circuito de falta. (c) Circuito pós-falta (Superposição de (a) e (b)) (Adaptado de (TAKAGI et al, 1981)).....	48
Figura 4.1. Localizador de FAI (Fonte: Próprio Autor).....	58
Figura 4.2. Localizador de seção do alimentador (Fonte: Próprio Autor).....	60
Figura 4.3. Disposição física dos condutores das fases do alimentador (UFCEG, 2010).....	61
Figura 4.4. Estrutura dos postes (UFCEG, 2010).....	61
Figura 4.5. Diagrama unifilar do alimentador Boa Vista (UFCEG, 2010).....	62
Figura 4.6. Alimentador BVA 21L3 (UFCEG, 2010).....	69
Figura 4.7. <i>Layout</i> do último ensaio (UFCEG, 2010).....	70
Figura 4.8. <i>Layout</i> da estrutura montada (Adaptado de (UFCEG, 2010)).....	70
Figura 4.9. Superfícies de contato para realização dos ensaios (Fonte: Próprio Autor).....	71
Figura 4.10. Técnico manobrando o condutor (Fonte: Próprio Autor).....	71
Figura 4.11. Visão geral da estrutura de abrigo no ponto de medição remoto (UFCEG, 2010).....	72
Figura 4.12. FAI ocorrendo na grama (Fonte: Próprio Autor).....	72
Figura 4.13. Registrador RPV-304. (a) Vista Frontal. (b) Vista Superior (UFCEG, 2010).....	73
Figura 4.14. Modelo proposto por SANTOS (2011).....	75
Figura 4.15. Processo de cálculo de: (a) Valor absoluto da tensão referente a FAI; (b) Valor absoluto da corrente referente a FAI; (c) Valor da resistência em relação ao tempo. (SANTOS, 2011).....	76

Figura 4.16. Processo de janelamento dos sinais de corrente (Adaptado de (SILVA, 2004)).	82
Figura 4.17. <i>Wavelet</i> Daubechies 4 (Fonte: Próprio Autor).	83
Figura 4.18. <i>Wavelet</i> Daubechies 48 (Fonte: Próprio Autor).	83
Figura 4.19. <i>Wavelet</i> Haar (Fonte: Próprio Autor).	84
Figura 4.20. Resposta em frequência das <i>wavelets</i> utilizadas (Fonte: Próprio Autor).	84
Figura 4.21. Interface do <i>software</i> AnFAI (UFCEG, 2010).	88
Figura 4.22. Configuração do método de detecção de FAI (UFCEG, 2010).	88
Figura 5.1. Tensão na subestação com a ocorrência de uma FAI (Fonte: Próprio Autor).	90
Figura 5.2. Corrente na subestação com a ocorrência de uma FAI e os resultados da Transformada <i>Wavelet</i> (Fonte: Próprio Autor).	90
Figura 5.3. Energia dos coeficientes <i>wavelet</i> das correntes (Fonte: Próprio Autor).	91
Figura 5.4. Análise da energia dos CW para FAI de carregamentos diferentes (Fonte: Próprio Autor).	92
Figura 5.5. Evolução do treinamento das RNA – Daubechies 4 (Fonte: Próprio Autor).	93
Figura 5.6. Evolução do treinamento das RNA – Daubechies 48 (Fonte: Próprio Autor).	93
Figura 5.7. Evolução do treinamento das RNA – Haar (Fonte: Próprio Autor).	94
Figura 5.8. Média de acertos – 100% de carregamento (Fonte: Próprio Autor).	109
Figura 5.9. Mediana dos acertos – 100% de carregamento (Fonte: Próprio Autor).	110
Figura 5.10. Exemplo de uma FAI real na areia (Fonte: Próprio Autor).	110
Figura 5.11. Acerto das SOM – Areia (Fonte: Próprio Autor).	114
Figura 5.12. Erro quadrático das SOM – Areia (Fonte: Próprio Autor).	115
Figura 5.13. Acerto das SOM – Calçamento (Fonte: Próprio Autor).	115
Figura 5.14. Erro quadrático das SOM – Calçamento (Fonte: Próprio Autor).	116
Figura 5.15. Acerto das SOM – Grama (Fonte: Próprio Autor).	116
Figura 5.16. Erro quadrático das SOM – Grama (Fonte: Próprio Autor).	117
Figura 5.17. Acerto das SOM – Terra (Fonte: Próprio Autor).	117
Figura 5.18. Erro quadrático das SOM – Terra (Fonte: Próprio Autor).	118
Figura 5.19. Mapa Neural da SOM para a base de dados testada (Fonte: Próprio Autor).	119

Lista de Tabelas

Tabela 3.1. Desempenho do método de detecção de FAI no local de falta.....	44
Tabela 3.2. Síntese - Detecção de FAI.....	46
Tabela 3.3. Síntese - Localização de FAI.....	54
Tabela 4.1. Síntese da Localização.....	59
Tabela 4.2. Parâmetros dos cabos utilizados.....	62
Tabela 4.3. Comprimentos dos trechos do alimentador Boa Vista.....	63
Tabela 4.4. Cargas instaladas no alimentador Boa Vista.....	64
Tabela 4.5. Representação de $R_2(t)$ para as diversas superfícies.....	77
Tabela 4.6. Informações de localização das barras.....	81
Tabela 4.7. Variáveis de simulação e cenários de falta.....	85
Tabela 4.8. Descrição das variáveis de entrada das RNA.....	86
Tabela 5.1. Síntese do treinamento das RNA.....	92
Tabela 5.2. Tempo de treinamento das RNA.....	94
Tabela 5.3. Areia - Rede 12-1.....	96
Tabela 5.4. Areia - Rede 12-50-1.....	97
Tabela 5.5. Areia - Rede 12-50-20-1.....	98
Tabela 5.6. Calçamento - Rede 12-1.....	99
Tabela 5.7. Calçamento - Rede 12-50-1.....	100
Tabela 5.8. Calçamento - Rede 12-50-20-1.....	101
Tabela 5.9. Grama - Rede 12-1.....	102
Tabela 5.10. Grama - Rede 12-50-1.....	103
Tabela 5.11. Grama - Rede 12-50-20-1.....	104
Tabela 5.12. Terra - Rede 12-1.....	105
Tabela 5.13. Terra - Rede 12-50-1.....	106
Tabela 5.14. Terra - Rede 12-50-20-1.....	107
Tabela 5.15. Síntese dos resultados - Melhor caso.....	108
Tabela 5.16. Resultados FAI Reais - Areia Seca.....	111
Tabela 5.17. Resultados FAI Reais - Areia Molhada.....	111

Tabela 5.18. Resultados com as inicializações.	112
Tabela 5.19. Inicializações da RNA com melhor resultado.....	112
Tabela 5.20. Relação do fator k com as dimensões da SOM.....	113

Resumo

Em função da topologia radial dos sistemas de distribuição de energia elétrica, um grande número de consumidores pode permanecer sem fornecimento de energia após a atuação do sistema de proteção. Assim, a obtenção de uma estimativa do local de ocorrência da falta representa uma etapa importante na redução do tempo de interrupção de energia aos consumidores. Há uma classe de distúrbios denominada faltas de alta impedância (FAI), que normalmente ocorrem quando há contato de um condutor energizado do circuito da rede primária com uma superfície de alto valor resistivo, a exemplo de árvores, vias públicas ou construções. Nesse caso, nem mesmo o sistema de proteção é sensibilizado. As FAI apresentam características próprias, como assimetria e não-linearidade. Diante do estado da arte, a tese que se propõe tem como objetivo desenvolver um algoritmo para realizar a localização de FAI em sistemas de distribuição utilizando Redes Neurais Artificiais (RNA) e a Transformada *Wavelet*. A localização proposta é realizada em duas etapas, com a utilização de duas classes de RNA: *perceptrons* de múltiplas camadas (MLP - *Multilayer Perceptron*) para localização da extensão, e os mapas auto-organizáveis (SOM - *Self Organizing Maps*) para determinação do setor do alimentador. Os dados de entrada utilizados são as correntes de cada fase, assim como a energia dos coeficientes *Wavelet*. Para modelagem das FAI, realizaram-se ensaios em um alimentador real, com a queda de um cabo em algumas superfícies. Os resultados indicam uma precisão em torno de 90%, evidenciando a possibilidade da utilização da Inteligência Artificial ao problema.

Palavras Chave: Faltas de Alta Impedância, Transformada *Wavelet*, Redes Neurais Artificiais, Sistemas de Distribuição.

Abstract

Due to the radial power distribution systems topology, a large number of consumers may remain without power supply after the operation of the protection system. Thus, an estimation of the fault occurrence place represents an important step in reducing outage time for consumers. There is a disturbance type known as High Impedance Faults (HIF), which usually occur when there is a drop or energized conductor contact of the primary circuit network with a high value resistive surface, like trees, roads or buildings. In this case, the protection system is not sensitized. The HIF have specific characteristics, such as asymmetry and nonlinearity. The goal here is to develop an algorithm to perform the HIF location in distribution systems using Artificial Neural Networks (ANN) and *Wavelet* Transform. The proposed location is performed in two steps, using two ANN classes: MLP - Multilayer Perceptron, for extension of the location and SOM - Self Organizing Maps, to determine the sector feeder. The used input data are the phase currents, as well as the energy of the *wavelet* coefficients. For HIF modeling, field tests were carried out. The results indicated an accuracy of around 90%, indicating the possibility of using Artificial Intelligence to the problem.

Keywords: High Impedance Faults, *Wavelet* Transform, Artificial Neural Networks, Distribution Systems.

Capítulo 1

Introdução

1.1 Motivação e Relevância da Proposta de Tese

O setor elétrico brasileiro vem enfrentando desde a última década um processo de reestruturação, englobando transformações técnicas e administrativas desde a entrada em vigor da Lei 10.848/2004. Essa mudança evidenciou fatores diversos, dentre os quais a valorização da qualidade e continuidade de serviço na distribuição de energia elétrica. Estudos em sistemas de potência indicam que a frequência e a duração das interrupções de serviço são os indicadores de qualidade mais relacionados com a satisfação dos clientes. Nesse cenário, o desenvolvimento de novas soluções para automação do restabelecimento de energia tem recebido atenção crescente. Assim, é cada vez mais importante a monitoração de qualquer perturbação que venha a ocorrer no sistema e a identificação correta de todos os detalhes, como tipo e localização.

A ocorrência de faltas em sistemas de distribuição de energia elétrica está relacionada à variedade de situações adversas às quais esses sistemas estão inerentemente susceptíveis, o que influencia diretamente na confiabilidade, segurança e qualidade do serviço oferecido. Nesse contexto, os sistemas de proteção devem atuar para extinguir o defeito de forma rápida e confiável, para

que só então, as equipes de manutenção possam repará-lo e o fornecimento de energia possa ser restabelecido, sendo de importância vital para uma operação eficiente. Além de facilitar a manutenção e os reparos necessários no sistema elétrico, a localização precisa das faltas fornece informações úteis em estudos de proteção.

O diagnóstico de faltas em sistemas de potência é uma das linhas de pesquisa atuais do Grupo de Sistemas Elétricos da UFCG. Podem ser citados projetos de Pesquisa e Desenvolvimento em conjunto com concessionárias de transmissão e distribuição da região, que resultaram em *softwares* e outros produtos relacionados ao diagnóstico de distúrbios:

- Implantação de técnicas de inteligência artificial para identificação e análise de ocorrências no sistema elétrico (Companhia Hidro Elétrica do São Francisco (Chesf) – 2002 a 2004);
- Classificação de distúrbios no sistema elétrico baseada nas wave-nets (Chesf – 2004 a 2006);
- Sistema de detecção e localização de faltas de alta impedância em redes de distribuição (Energisa Paraíba – 2009 a 2010).

Também há relevantes trabalhos acadêmicos na área (SANTOS et al, 2013; SILVA, 2009; COSTA, 2010). Dentre os distúrbios que puderam ser diagnosticados, podem ser citadas as faltas francas, as faltas de alta impedância, assim como os afundamentos de tensão.

Nos sistemas de distribuição de energia elétrica, a localização das faltas é tarefa mais difícil quando comparada aos sistemas de transmissão, em decorrência das várias ramificações existentes. Uma classe especial de faltas a que os sistemas de distribuição estão susceptíveis são as FAI, a exemplo de curtos-circuitos decorrentes da queda de cabos, que expõem a população ao risco de choques elétricos. Estima-se que entre 30-50% dos distúrbios com quedas de condutores sejam FAI (AUCOIN & JONES, 1996). No Brasil, ocorre uma média de 53,6 mortes por ano resultante de rompimentos de cabos energizados (OLIVEIRA JÚNIOR, 2006). Nesse caso, a corrente de falta apresenta uma amplitude baixa se

comparada com a resultante de faltas francas, que são faltas com impedância próximo a zero. Outra característica importante é a sua não-linearidade, ou seja, uma corrente não-senoidal provocada pela presença de harmônicas.

Uma grande preocupação é o fato de que, devido às suas características particulares, as FAI podem não ser detectadas pelos dispositivos de proteção, confundindo-se com acréscimos de cargas ou chaveamentos de banco de capacitores no sistema. O problema se agrava em redes de distribuição rurais, nas quais os alimentadores são de grande extensão e percorrem longos trechos desabitados. Diante do exposto, conclui-se que para o completo diagnóstico de uma FAI, há uma sequência encadeada de passos em que a falha de alguma fase prejudicará as fases precedentes: modelagem, detecção e localização. A modelagem é citada como um passo inicial devido à dificuldade em avançar nos demais estudos sem uma modelagem eficiente.

No decorrer do texto serão discutidas características das FAI, como não-linearidade, assimetria e intermitência. Um modelo ôhmico ou composto de resistências e indutâncias não é tecnicamente suficiente para descrever uma FAI. O levantamento da característica $V \times I$ (tensão \times corrente) é fundamental, assim como o desenvolvimento de um modelo que a reproduza fielmente (SANTOS, 2011; NAM et al, 2001; EMANUEL et al, 1990).

A maior dificuldade no diagnóstico das FAI é a sua detecção. Há determinadas situações, com o rompimento dos condutores energizados e contato com superfícies em que o arco elétrico é insignificante de tal forma, que a variação de corrente é imperceptível. Dessa forma, a proteção não é sensibilizada; sendo impossível detectar a falta (SANTOS et al, 2013).

Um aspecto importante que tem facilitado o uso de localizadores de faltas é a ampliação e, principalmente, a modernização das redes de oscilografia. O uso dos Registradores Digitais de Perturbação (RDP) no sistema elétrico foi expandido, facilitando o desenvolvimento de *softwares* para o Processamento Digital dos Sinais de corrente e tensão obtidos. Dentre as aplicações dos *softwares* desenvolvidos, pode ser citada a localização de faltas.

As técnicas de Inteligência Artificial estão consolidadas nas aplicações em sistemas de potência, destacando-se o uso das RNA (MORETO, 2005; SILVA, 2004; SILVA et al, 2013; MICHALIK et al, 2008). Tais técnicas vêm sendo aplicadas em problemas de classificação de padrões, previsão de séries temporais e monitoramento de para-raios (LIRA, 2012). Essa diversidade de aplicações se deve ao fato de apresentarem alta capacidade de aprendizado e generalização (desde que haja um processo de treinamento adequado), além de velocidade e robustez no diagnóstico.

O trabalho proposto faz parte de uma linha de pesquisa denominada Diagnóstico de Distúrbios em Sistemas de Potência, que vem sendo desenvolvida desde 2002 pelo Grupo de Sistemas Elétricos da UFCG. Além disso, o projeto de tese esteve vinculado ao Projeto de Pesquisa e Desenvolvimento intitulado “Sistema de Detecção e Localização de Falhas de Alta Impedância em Redes de Distribuição” desenvolvido pelo Grupo Energisa/PB com a UFCG (UFCG, 2010). Na ocasião, foi desenvolvido um *software* responsável por detectar e localizar FAI nos alimentadores da concessionária. Ao final, houve a implantação do mesmo no sistema da Energisa/PB (Subestação Catolé - Campina Grande) na forma de um projeto piloto, para a coleta automática de registros oscilográficos em um dos alimentadores da empresa.

1.2 Objetivo e Contribuições da Tese

O objetivo geral da Tese de Doutorado é o desenvolvimento de uma metodologia para localização de FAI em alimentadores de distribuição utilizando dados obtidos **apenas** na subestação. Espera-se obter a distância de ocorrência do distúrbio (em relação à subestação), além do setor no alimentador, tendo em vista que os sistemas de distribuição apresentam bastante ramificações. O alimentador testado foi dividido em 7 setores. A localização dar-se-á utilizando-se RNA treinadas com dados incluindo a energia de seus coeficientes *Wavelet* das correntes de falta. A localização precisa da FAI, proporciona maior eficiência na solução do

problema (pois as equipes de manutenção não se deslocariam exaustivamente à procura), com intervalos menores no suprimento de energia elétrica. Não se pode desprezar o fator segurança, em que evitar-se-ia exposição da população ao contato com cabos energizados.

Os objetivos específicos da Tese são:

1. Propor um localizador de simples operação, tendo em vista que não será necessária a instalação de mais pontos de observação. A coleta dos dados se dá apenas na subestação.
2. Avaliar se a utilização das correntes de falta no domínio do tempo, mescladas com a Energia dos coeficientes *Wavelet* (energia dos transitórios) é adequada para a localização de FAI.
3. Avaliar se as redes tipo *perceptron* de múltiplas camadas (MLP - *Multilayer Perceptron*) são apropriadas e precisas para determinação da distância. Testar algumas configurações.
4. Avaliar se os mapas auto-organizáveis (SOM - *Self Organizing Maps*) são convenientes para determinar o setor do alimentador em que ocorreu a falta. Testar algumas configurações.
5. Verificar se a metodologia proposta funciona com dados reais.
6. Identificar quais *Wavelets* são mais apropriadas para o caso em questão.

Dentre os trabalhos que compuseram a Revisão Bibliográfica para a Tese, em nenhum encontrou-se aplicação da SOM para o diagnóstico de faltas de qualquer espécie em Sistemas de Distribuição. COSTA (2010) utilizou a Transformada *Wavelet* apenas para detecção das FAI, sem a fase de localização.

Para modelagem do alimentador e da falta com elevado grau de fidelidade aos dados reais, ensaios de campo foram realizados em um alimentador real da concessionária Energisa/PB. As FAI foram provocadas em diversas superfícies, como: areia, brita, asfalto, grama e calçamento. Vale ressaltar que não foram simples ensaios de provocação das faltas, com o cabo energizado tocando as superfícies. Os ensaios foram realizados em um alimentador real em condições normais de operação.

Para desenvolvimento das RNA utilizadas, assim como extração das energias dos coeficientes *Wavelet* das correntes, foram utilizados os respectivos *Toolboxies Neural Networks* e *Wavelet* do Matlab®.

O desempenho da metodologia será avaliado através de bases de dados desenvolvidas a partir do modelo de alimentador real considerado, englobando diversos pontos de falta, fatores de carregamento, superfícies, dentre outras variáveis. A plataforma de simulação escolhida para modelagem do sistema de distribuição será o ATP - *Alternative Transients Program* - (LEUVEN EMTP CENTER, 1987).

As contribuições desta Tese para o estado da arte são:

- Utilização da energia dos transitórios gerados com a ocorrência da FAI (energia dos coeficientes *Wavelet*) para localizar a falta. Há de se ressaltar que em determinados casos a variação da corrente suprida pela subestação é quase imperceptível, o que não ocorre quando a grandeza observada é a energia dos coeficientes *Wavelet*.
- Adoção de um tipo de RNA com treinamento não-supervisionado (mapas auto-organizáveis). Dessa forma, mesmo com modificações na configuração do sistema (acréscimo de carga, troca de transformador, expansão), a rede neural manterá sua capacidade de generalização.
- Utilização do algoritmo proposto a alimentadores com diferentes perfis, tendo em vista que as faltas que vierem a ocorrer passem a fazer parte do conjunto de treinamento das RNA adotadas.

1.3 Organização do Texto

Um breve resumo de cada capítulo é descrito a seguir:

No Capítulo 2 desenvolve-se a Fundamentação Teórica necessária para implementação do método de localização. São abordados os conceitos de FAI, RNA e Transformada *Wavelet*, assim como suas aplicabilidades em Sistemas de Potência.

No Capítulo 3 é apresentada uma revisão concisa da literatura sobre FAI, englobando seus conceitos, modelagem, detecção e localização.

O Capítulo 4 é dedicado a explicitar a metodologia desenvolvida e testada durante os estudos. Inicia-se com a descrição dos experimentos de campo para posterior modelagem das faltas, construção das bases de dados para avaliação do método, estrutura das RNA e todo processo de pré-processamento dos dados. Os resultados obtidos, com as devidas análises são apresentados no Capítulo 5.

No Capítulo 6 apresentam-se as conclusões e contribuições da Tese, além das limitações dos estudos realizados e perspectivas de trabalhos futuros.

Capítulo 2

Fundamentação Teórica

O cerne do Capítulo 2 é a base teórica necessária à implementação do método de localização de FAI. Alguns aspectos qualitativos deste tipo de falta serão discutidos, assim como os fundamentos de Redes Neurais e Transformada *Wavelet*.

2.1 Faltas de Alta Impedância (FAI)

Nos sistemas de distribuição de energia elétrica, as FAI são motivo de preocupação constante, principalmente em redes de distribuição aéreas. Um condutor elétrico ao se romper ou tocar uma superfície de alto valor resistivo, não mantém inicialmente um contato firme com a superfície em questão, provocando geralmente o aparecimento de arcos elétricos. Se o contato com a superfície de alto valor resistivo for firme, há a ocorrência de FAI sem o centelhamento inicial. Uma FAI pode expor a população ao risco de choques elétricos e comprometer a integridade dos equipamentos do sistema, podendo inclusive, provocar inúmeros danos às propriedades privadas.

Os problemas decorrentes das FAI se devem aos níveis de corrente associados, normalmente insuficientes para sensibilizar a operação dos

dispositivos de proteção. De modo geral, as FAI podem ser confundidas com transitórios oscilatórios decorrentes do chaveamento de cargas no sistema e, por conseguinte, não sensibilizam os relés de proteção.

Conforme AUCOIN (1985), quando há ocorrência de FAI devido às quedas de condutores, a taxa de falhas nos dispositivos de detecção de sobrecorrente é superior a 30%. Pelas descrições iniciais das características, é notório que o problema de detecção e localização de uma FAI não se assemelha a uma simples “percepção” da existência de sobrecorrente.

Conforme MASA (2012), a maioria das ocorrências de FAI é monofásica. Observou-se também que na maioria das vezes é visível a existência do arco elétrico na forma de onda da corrente de uma FAI. Esse tipo de falta apresenta valor de corrente constante quando a mesma está próxima ao zero, consistindo em um indício de extinção e reignição do arco.

Na busca pela minimização das durações das interrupções e dos custos operacionais, pesquisas que conduzam a diagnósticos rápidos e confiáveis das FAI constituem-se em tema atual e de importância crescente. Em MORETO (2005), são elencadas de forma objetiva e precisa as características principais de uma FAI:

- **Assimetria**: a corrente de falta apresenta amplitudes diferentes para os semiciclos positivos e negativos. Conforme EMANUEL et al (1990), a amplitude do semiciclo positivo é maior pelo fato do arco ser menor. A ruptura do dielétrico facilitada no semiciclo positivo devido a substâncias que ao serem aquecidas funcionam como uma “mancha catódica”.
- **Não-linearidade**: a curva característica de tensão por corrente é não-linear, obtida por ensaios de campo e laboratório por EMANUEL et al (1990), NAM et al (2001), SOLÍS et al (2007) e UFCG (2010).
- **Buildup**: a amplitude da corrente de falta cresce gradativamente, atingindo seu valor máximo em algumas dezenas de ciclos. Tal característica é devido a acomodação física do cabo (SANTOS, 2011), em que será estabelecida a impedância de contato final da FAI.

- ***Shoulder***: períodos em que o *buildup* é estacionado e até mesmo atenuado por alguns ciclos (NAM et al, 2001).
- ***Intermitência***: períodos em que o cabo energizado perde o contato com o solo, ocorrendo extinção da corrente (NAKAGOMI, 2006 apud SANTOS, 2011).

Na Figura 2.1 está exemplificada a forma de onda de corrente de uma FAI.

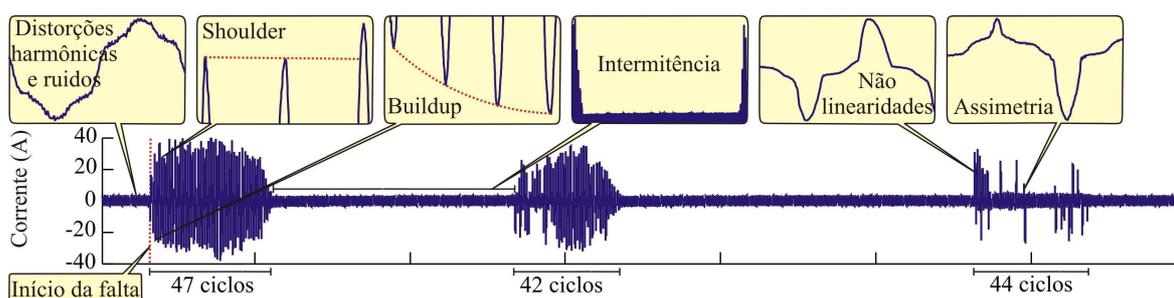


Figura 2.1. Forma de onda de uma FAI (Adaptado de (COSTA et al, 2015)).

2.2 Redes Neurais Artificiais

As pesquisas com RNA iniciaram pelo reconhecimento de que o cérebro humano processa informações de uma forma inteiramente diferente do computador digital. O cérebro é um computador altamente complexo, não-linear e paralelo (HAYKIN, 1999). Na sua forma geral, uma rede neural é uma estrutura projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse. Na Tese, foram utilizadas duas classes de RNA: uma para determinação da distância da falta à subestação e outra para identificação da seção no alimentador (tendo em vista que nos sistemas de distribuição há muitas ramificações). Em termos gerais, uma RNA contém uma camada de entrada, uma camada de saída e uma ou mais camadas ocultas. Cada camada possui uma ou várias unidades de processamento, denominadas **neurônios**. Os neurônios podem estar dispostos em estruturas interligadas por um grande número de conexões (sinapses). Geralmente, essas conexões são associadas aos pesos, que servem como fator de ponderação das entradas recebidas pelas unidades de rede (SILVA, 2004).

2.2.1 Modelo e Estrutura dos Neurônios

O neurônio é a unidade de processamento fundamental para a operação de uma RNA. Seu diagrama de blocos, que forma a base para a modelagem das RNA, é ilustrado na Figura 2.2. A informação de entrada é recebida através de um conjunto de ligações ponderadas pelos pesos sinápticos. Um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} (o primeiro índice indica o neurônio em questão, enquanto o segundo refere-se à sinapse). Os sinais de entrada ponderados pelos respectivos pesos sinápticos são somados; com a saída do neurônio sendo definida pela função de ativação, que limita o intervalo permissível de amplitude do sinal de saída a um valor finito. No modelo também está incluso o *bias*, que aumenta ou diminui a entrada líquida da função de ativação.

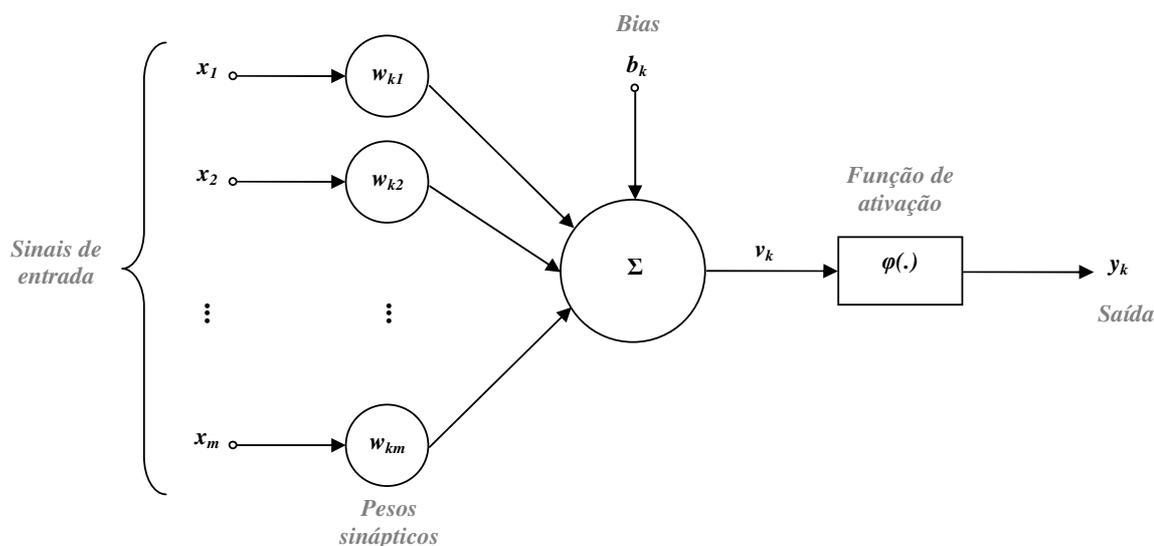


Figura 2.2. Modelo não-linear de um neurônio (Adaptado de (HAYKIN, 1999)).

Matematicamente, o neurônio é assim definido:

$$u_k = \sum_{j=1}^m w_{kj} x_j, \quad (2.1)$$

$$v_k = u_k + b_k, \quad (2.2)$$

$$y_k = \varphi(v_k). \quad (2.3)$$

Existem três tipos básicos de função de ativação:

1. Função limiar ou degrau unitário, definida por:

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \Rightarrow y_k = \begin{cases} 1 & \text{se } v_k \geq 0 \\ 0 & \text{se } v_k < 0 \end{cases}. \quad (2.4)$$

2. Função linear por partes, definida por:

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq \frac{1}{2} \\ v & \text{se } \frac{1}{2} > v > -\frac{1}{2} \\ 0 & \text{se } v \leq -\frac{1}{2} \end{cases}. \quad (2.5)$$

3. Função sigmoide, cujo gráfico tem a forma de s. As funções sigmoides constituem a forma mais comum de funções de ativação usadas na construção de RNA, definida por:

$$\varphi(v) = \frac{1}{1 + e^{-av}}. \quad (2.6)$$

A constante a é conhecida como parâmetro de suavidade da função sigmoide, sendo sempre maior que zero. Com o valor de a tendendo ao infinito, a função torna-se a função limiar.

A estrutura dos neurônios está intimamente relacionada com o algoritmo de aprendizagem usado para treinar a rede. Quanto à estrutura, as redes neurais podem ser classificadas em:

- **Redes de camada única** - É a forma mais simples de redes em camadas, em que há uma camada de entrada de nós fonte que se projeta sobre uma camada de saída de neurônios, mas não vice-versa. A camada única se refere à camada de saída.

- **Redes com múltiplas camadas** – Se distinguem pela presença de uma ou mais camadas ocultas. A função dos neurônios ocultos é intervir entre a entrada externa e a saída da rede de maneira eficiente. Os nós fonte da camada de entrada da rede fornecem os respectivos elementos do padrão de ativação, que constituem os sinais de entrada aplicados aos neurônios na segunda camada. Os sinais de saída da segunda camada são utilizados como entradas para a terceira camada, e assim sucessivamente.
- **Redes recorrentes** – Caracterizadas pela existência de laços de realimentação.

2.2.2 Redes MLP

Para determinação da distância de ocorrência das FAI para a subestação, foram utilizadas redes com múltiplas camadas, normalmente conhecidas como *perceptrons* de múltiplas camadas (MLP – *multilayer perceptron*), cuja estrutura é apresentada na Figura 2.3. A razão dessa escolha foi o fato de ser uma arquitetura de fácil implementação e por ser bastante difundida na linha de pesquisa na qual o trabalho se enquadra. O treinamento utilizado geralmente para esse tipo de rede é conhecido como algoritmo de retropropagação do erro (*backpropagation*), utilizado em aproximadamente 80-90% das aplicações práticas (MAZÓN et al, 2000), e que consiste de dois passos através das diferentes camadas da rede:

- **Propagação** – Um vetor de entrada é aplicado à rede, e seu efeito se propaga camada por camada, produzindo uma resposta nas camadas de saída. Durante esse passo os pesos sinápticos são mantidos fixos.
- **Retropropagação** – Os pesos sinápticos são ajustados de acordo com uma regra de correção de erro. A resposta real da rede é subtraída da resposta desejada, gerando um sinal de erro, que é propagado através da rede em direção contrária às conexões sinápticas.

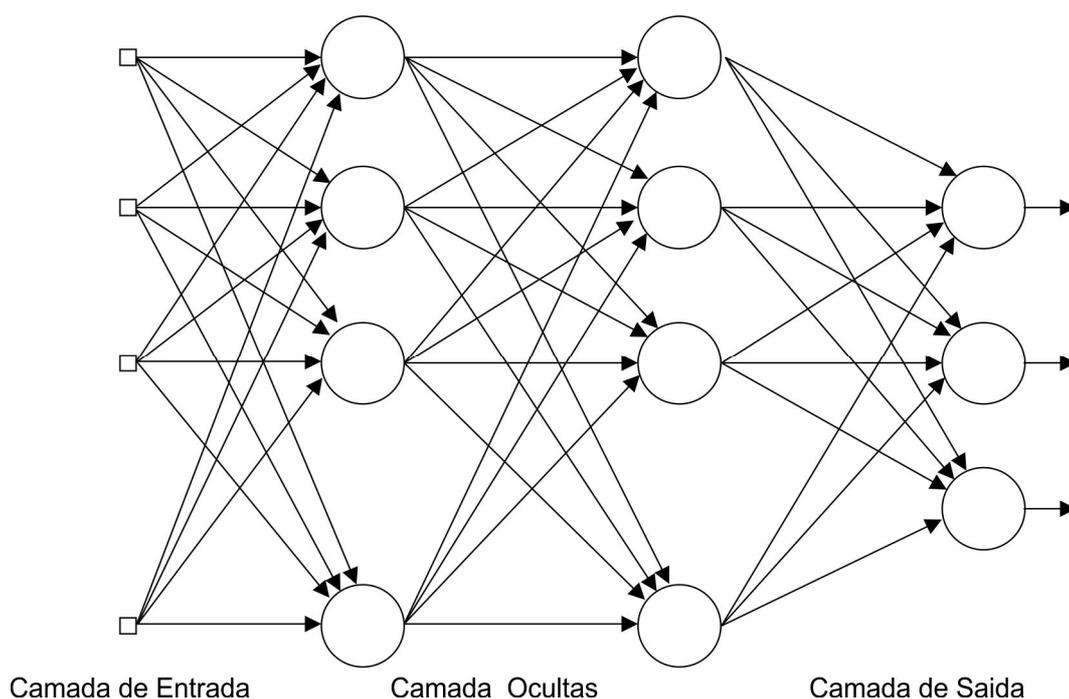


Figura 2.3. Estrutura MLP (*Multilayer Perceptron*) (Adaptado de (HAYKIN, 1999)).

O sinal de erro na saída do neurônio j , na iteração n é definido por:

$$e_j(n) = d_j(n) - y_j(n). \quad (2.7)$$

Em que:

$e_j(n)$ - Sinal de erro na saída no neurônio.

$d_j(n)$ - Saída desejada no neurônio.

$y_j(n)$ - Saída real no neurônio.

O valor instantâneo da energia para o neurônio j é definido como $\frac{1}{2} e_j^2(n)$.

Da mesma forma, o valor instantâneo do erro $E(n)$ é obtido somando-se as energias de todos os neurônios da camada de saída. Tem-se então:

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n), \quad (2.8)$$

em que o conjunto C inclui todos os neurônios da camada de saída. Sendo N o número total de padrões contidos no conjunto de treinamento. O erro médio é obtido somando-se as energias totais para todos os n e normalizando em relação ao conjunto N . É obtida a seguinte expressão:

$$E_{med} = \frac{1}{N} \sum_{n=1}^N E(n). \quad (2.9)$$

O objetivo do processo de aprendizagem é ajustar os pesos sinápticos da rede de forma a minimizar E_{med} . O algoritmo de retropropagação aplica uma correção $\Delta w_{ji}(n)$ ao peso $w_{ji}(n)$, proporcional à derivada parcial $\partial E(n)/\partial w_{ji}(n)$. O gradiente pode ser calculado com o auxílio da regra da cadeia:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)}. \quad (2.10)$$

Diferenciando-se ambos os membros da equação (2.8) em relação a $e_j(n)$, da equação (2.7) em relação a $y_j(n)$, da equação (2.3) em relação a $v_j(n)$, e da equação (2.1) em relação a $w_{ji}(n)$ obtêm-se:

$$\frac{\partial E(n)}{\partial e_j(n)} = e_j(n), \quad (2.11)$$

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1, \quad (2.12)$$

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi_j'(v_j(n)), \quad (2.13)$$

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = x_i(n). \quad (2.14)$$

Aplicando-se as equações (2.11), (2.12), (2.13) e (2.14) em (2.10) obtêm-se:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = -e_j(n) \varphi_j'(v_j(n)) x_i(n). \quad (2.15)$$

A correção $\Delta w_{ji}(n)$ aplicada a $w_{ji}(n)$ é definida por HAYKIN (1999):

$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)}, \quad (2.16)$$

em que η é o parâmetro da taxa de aprendizagem do algoritmo de retropropagação, que tem por função regular a velocidade de convergência. Vale salientar que os pesos sinápticos são corrigidos no passo da retropropagação. Aplicando-se a equação (2.15) em (2.16):

$$\Delta w_{ji}(n) = \eta \delta_j(n) x_j(n), \quad (2.17)$$

em que $\delta_j(n)$ é o gradiente local, que aponta para as modificações necessárias nos pesos sinápticos, e é definido por:

$$\delta_j(n) = -\frac{\partial E(n)}{\partial v_j(n)}. \quad (2.18)$$

Na prática, o aprendizado mediante aplicação do algoritmo de retropropagação resulta das apresentações de um determinado conjunto de padrões de treinamento para a rede. Cada apresentação do conjunto de treinamento inteiro é denominada **época**. O processo de aprendizagem é mantido em uma base de época em época até os pesos e os valores dos *bias* se estabilizarem e o erro médio quadrático convergir. A aprendizagem por retropropagação pode ocorrer de duas formas básicas:

- **Modo Sequencial** – A atualização dos pesos é realizada após a apresentação de cada padrão de treinamento. Cada época consiste de N vetores de treinamento, com as grandezas de entrada e as saídas desejadas. A cada vetor de treinamento é feito o ajuste dos pesos e dos níveis de *bias*. As equações mostradas anteriormente nesse capítulo referem-se a esse modo.
- **Modo por lote (*batch*)** – O ajuste dos pesos é realizado após a apresentação de todos os padrões de treinamento que formam uma época. O conjunto de treinamento pode ser dividido em subconjuntos denominados lotes.

Para o modo de treinamento por lote, o valor de reajuste dos pesos a cada padrão apresentado à rede é calculado da mesma forma que no modo sequencial. Contudo, os pesos sinápticos só são atualizados ao final da época de treinamento, utilizando-se a média aritmética de todos os reajustes calculados para todos os padrões da época.

No reajuste sequencial uma época de treinamento é composta por apenas um padrão, já que o reajuste é feito a cada padrão, enquanto que no reajuste por lote uma época é formada pelo conjunto de padrões de um lote. O modo sequencial de treinamento é preferível por requerer menor armazenamento local

para cada conexão sináptica, também por ser mais fácil de implementar. Além disso, visto que os parâmetros são apresentados à rede de forma aleatória, o treinamento tem natureza estocástica. Desta forma é menos provável que o algoritmo fique preso em um mínimo local. Devido a natureza estocástica, é mais difícil estabelecer as condições teóricas para convergência. O uso do treinamento por lote fornece uma estimativa precisa do vetor de gradiente, garantindo uma convergência mais simples para um mínimo local.

A escolha dos padrões a serem apresentados à rede durante a etapa de treinamento é de extrema importância. Eles devem ser representativos, de modo que não sejam escassos, pois dessa forma a rede não adquire capacidade de generalização. Tampouco o tamanho da base de dados deve ser excessivo, ocasião em que também não haverá capacidade de generalização (a rede irá “decorar” os resultados). Nas tarefas de classificações de padrões, é comum tornar aleatória a ordem em que os padrões são apresentados à rede de uma época para a seguinte. Idealmente, a aleatoriedade garante que os padrões sucessivos apresentados, raramente pertençam à mesma classe e sim que eles sejam radicalmente diferentes.

Um aspecto relevante na etapa de treinamento é a precaução com o treinamento excessivo de forma que os reajustes efetuados nos pesos ao invés de reduzir o erro gradativamente, passem a aumentar a cada iteração, o que pode fazer com que o algoritmo nunca venha a convergir. Neste ponto, a rede perde a capacidade de generalização e passa a aprender especificamente o conjunto de treinamento apresentado; ou porque a arquitetura da rede é inadequada para aquela aplicação, ou o conjunto de treinamento não consegue retratar de forma representativa o conhecimento que deve ser adquirido. Tal fato pode ocorrer quando a base de dados escolhida não foi representativa suficiente para haver generalização das saídas desejadas.

O treinamento de uma RNA pode ser encarado como um problema de otimização, em que se deseja minimizar o erro referente aos pesos sinápticos. Os métodos mais utilizados são os de gradiente conjugado e quasi-Newton. Também pode-se aplicar a teoria dos mínimos quadrados. HAGAN & MENHAJ (1994)

sugeriram a adoção do método de Levenberg-Marquardt, que pode ser interpretado como uma combinação entre a lei de ajuste do método do gradiente e a lei de ajuste do método de Newton. Trata-se de um método considerado mais robusto em relação aos que utilizam gradiente descendente ou conjugado; porém requer maior esforço computacional.

Seja w o vetor de pesos correspondente a cada camada da rede. De acordo com o método de Newton, a correção para cada camada é dada por:

$$\Delta w = -[\nabla^2 E_{med}(w)]^{-1} \nabla E_{med}(w), \quad (2.19)$$

em que $\nabla^2 E_{med}(w)$ é a matriz Hessiana, e $\nabla E_{med}(w)$ o gradiente. Como $E_{med}(w)$, de acordo com (2.9), é escrita como uma função quadrática tem-se:

$$\nabla E_{med}(w) = J^T(w)e(w), \quad (2.20)$$

$$\nabla^2 E_{med}(w) = J^T(w)J(w) + S(w), \quad (2.21)$$

em que $J(w)$, a matriz Jacobiana, e $S(w)$ são escritos da forma:

$$J(w) = \begin{bmatrix} \frac{\partial e_1(w)}{\partial w_1} & \frac{\partial e_1(w)}{\partial w_2} & \dots & \frac{\partial e_1(w)}{\partial w_n} \\ \frac{\partial e_2(w)}{\partial w_1} & \frac{\partial e_2(w)}{\partial w_2} & \dots & \frac{\partial e_2(w)}{\partial w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(w)}{\partial w_1} & \frac{\partial e_N(w)}{\partial w_2} & \dots & \frac{\partial e_N(w)}{\partial w_n} \end{bmatrix}, \quad (2.22)$$

$$S(w) = \sum_{i=1}^N e_i(w) \nabla^2 e_i(w). \quad (2.23)$$

A modificação de Levenberg-Marquardt para o método de Gauss-Newton é a adição da matriz $S(w)$, que também pode ser expressa por μI . A cada autovalor do produto $J^T(w)J(w)$, é adicionado um μ . Uma vez que a matriz $J^T(w)J(w)$ é definida positiva e portanto o autovalor mínimo possível é zero, qualquer valor positivo de μ será suficiente para restaurar a matriz aumentada e produzir uma direção descendente de busca. É importante observar que, quanto maior for o valor de μ , menor é a influência da informação de segunda ordem e mais este algoritmo se aproxima de um método de primeira ordem.

Outros algoritmos de treinamento foram testados, na tentativa de se obter uma atualização apropriada e eficiente dos pesos da rede. O que torna muitas estratégias de treinamento algumas vezes não eficazes, é que a atualização Δw_{ji} dos pesos não depende apenas do valor adaptado do coeficiente de aprendizagem, mas também do valor da derivada parcial. Assim, o efeito de uma adaptação do coeficiente de aprendizagem pode ser drasticamente distorcido pela variação do comportamento da derivada. À medida que se aproxima dos pontos de mínimos da função erro, a tendência da derivada parcial é ter seu valor diminuído até zerar. Dessa forma, tem-se nessa etapa do processo uma convergência mais lenta; que poderia ser acelerada com a adoção de um passo fixo de atualização. Há a necessidade de se adotar procedimentos de diminuição do passo caso a derivada parcial apresente mudança de sinal.

Na tentativa de solucionar esse problema, RIEDMILLER & BRAUN (1993) propuseram um algoritmo de treinamento denominado RPROP (*Resilient Propagation*), derivado do algoritmo tradicional de retropropagação. A diferença existente é que no RPROP a atualização dos pesos é realizada fazendo-se uso apenas do sinal da derivada parcial da função de erro, e não de seu valor. O valor da atualização dos pesos é calculado pela avaliação do sinal da derivada parcial de uma iteração para outra, o que melhora o processo de aprendizagem e faz com que a convergência se torne mais rápida (SOUZA et al, 2004).

Desta forma, quando os sinais do gradiente forem os mesmos, considerando duas iterações sucessivas, significa que se pode incrementar a taxa de aprendizado em virtude de se estar relativamente distante de um ponto de mínimo (gradiente nulo) da função erro. Caso contrário, se os sinais do gradiente forem diferentes, significa então que o ponto de mínimo da função foi ultrapassado, implicando na redução da taxa de aprendizagem a fim de se convergir suavemente para o mesmo (SILVA et al, 2010).

Para alcance do objetivo, no RPROP cada peso tem seu próprio valor de atualização Δ_{ij} . Este valor varia durante o processo de aprendizagem baseado no

comportamento da função de erro E , de acordo com a seguinte regra de aprendizagem:

$$\Delta_{ij}(t) = \begin{cases} \eta^+ \cdot \Delta_{ij}(t-1) & \text{se } \frac{\partial E}{\partial w_{ij}}(t-1) \cdot \frac{\partial E}{\partial w_{ij}}(t) > 0 \\ \eta^- \cdot \Delta_{ij}(t-1) & \text{se } \frac{\partial E}{\partial w_{ij}}(t-1) \cdot \frac{\partial E}{\partial w_{ij}}(t) < 0 \\ \Delta_{ij}(t-1) & \text{se } \frac{\partial E}{\partial w_{ij}}(t-1) \cdot \frac{\partial E}{\partial w_{ij}}(t) = 0 \end{cases} \quad (2.24)$$

Então sempre que a derivada do peso correspondente w_{ij} muda de sinal, significa que a última atualização foi muito alta e o algoritmo saltou para um mínimo local. Assim, o valor da atualização Δ_{ij} é diminuído pelo fator η^- . Se a derivada mantiver o sinal, o valor de atualização é ligeiramente aumentado com o objetivo de acelerar a convergência nas regiões superficiais.

Quando o valor de atualização para cada peso estiver adaptado, é seguida uma regra simples: se a derivada é positiva, o erro aumenta e o peso é diminuído pelo valor de atualização; se a derivada é negativa o valor de atualização é somado:

$$\Delta w_{ij}(t) = \begin{cases} -\Delta_{ij}(t) & \text{se } \frac{\partial E}{\partial w_{ij}}(t) > 0 \\ \Delta_{ij}(t) & \text{se } \frac{\partial E}{\partial w_{ij}}(t) < 0 \\ 0 & \text{se } \frac{\partial E}{\partial w_{ij}}(t) = 0 \end{cases} \quad (2.25)$$

Existe uma exceção, que ocorre quando a derivada parcial muda de sinal, ou seja, quando o passo anterior foi tão grande que o mínimo desaparece, sendo o procedimento de atualização o seguinte:

$$\Delta w_{ij}(t) = -\Delta w_{ij}(t-1), \quad \text{se } \frac{\partial E}{\partial w_{ij}}(t-1) \cdot \frac{\partial E}{\partial w_{ij}}(t) < 0. \quad (2.26)$$

2.2.3 Redes SOM

Grande parte das estruturas de RNAs existentes necessita de um conjunto de padrões de entradas e saídas para que possam ser devidamente treinadas. Os ajustes de seus parâmetros livres são realizados a partir das apresentações sucessivas dessas amostras de treinamento, configurando-se assim numa aprendizagem supervisionada. Porém, em determinadas situações, apenas o conjunto de padrões de entrada está disponível, sendo amostras com informações relevantes sobre o comportamento do sistema em que foram extraídas.

Outra arquitetura implementada na Tese diz respeito aos mapas auto organizáveis (SOM - *Self Organizing Maps*) de Kohonen (KOHONEN, 1982), cujo aprendizado é não-supervisionado. Dessa forma, a rede busca similaridades apenas nos padrões de entrada, agrupando os de características semelhantes formando classes denominadas *clusters*. Uma rede não-supervisionada deve descobrir por si só padrões, características, regularidades, correlações ou categorias embutidas nos dados de entrada e codificá-las na saída. A ideia para adoção da SOM para determinação do setor do alimentador em que ocorre a FAI veio do fato desse tipo de rede ser considerado um classificador. Nas mais variadas áreas são observadas as aplicações desse tipo de rede neural:

- **Marketing:** Pesquisa de mercado para segmentação do público alvo, através de dados como idade, perfil e classe social (MARQUES, 2008);
- **Biologia:** Determinação da espécie de flor a partir de dados como: o comprimento e a largura da sépala e da pétala (FRANK & ASUNCION, 2011);
- **Economia:** A partir do perfil dos clientes, determinar que tipo de investimento deve ser realizado na Bolsa de Valores (PINHO, 2008).

O mapa auto organizável representa uma arquitetura capaz de projetar dados de dimensão alta em um *array* de dimensão inferior, possuindo topologia básica de duas camadas, sendo elas: a camada de entrada I, responsável por “ler” o vetor de entrada e apresentar à rede as informações que serão classificadas; e a

camada de saída U que forma uma resposta, apresentados na Figura 2.4 (LIRA, 2012). Os neurônios de entrada estão totalmente conectados aos neurônios de saída, que na Figura citada é bidimensional.

Os mapas topológicos informam como estarão organizados espacialmente os neurônios da rede frente ao comportamento de seus vizinhos, sendo que normalmente são formados por uma (*array*) ou duas (*grade*) dimensões. Dimensões maiores raramente são escolhidas.

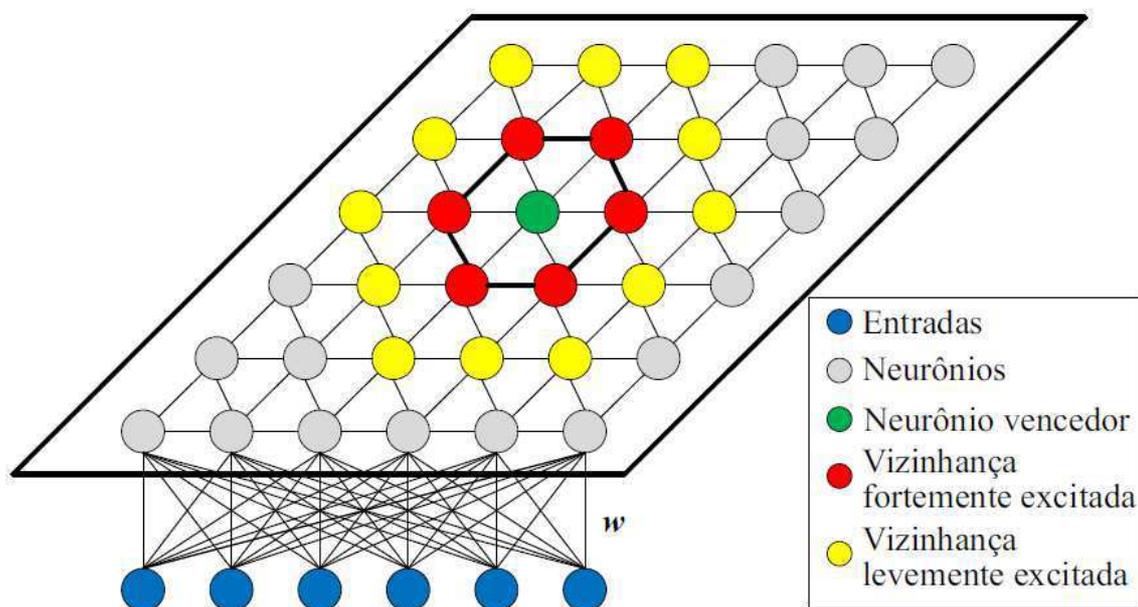


Figura 2.4. Topologia do mapa de Kohonen (LIRA, 2012).

O processo de classificação não-supervisionada da região do alimentador em que a falta ocorreu (ramificação) baseia-se no princípio de que o algoritmo computacional é capaz de identificar por si só as classes dentro do conjunto de dados obtidos dos registradores.

A aprendizagem da SOM é considerada competitiva. Este tipo de aprendizagem é caracterizada por manter apenas uma unidade de saída (neurônio) ativa por vez: o neurônio da camada de saída que venceu a competição, ou seja, o que foi mais excitado com as características da amostra do vetor de dados apresentado. Esse processo ocorre devido à capacidade do método de aprendizagem em detectar similaridades, regularidades e correlações entre os padrões do conjunto de entrada. Em determinado instante, um único neurônio

representará de maneira ótima a informação recebida pela camada de entrada, tendo, juntamente com seus vizinhos, seus pesos sinápticos reajustados para melhor responder ao estímulo recebido.

A rede SOM permite que características estatísticas intrínsecas do vetor de entrada estimule determinada região do mapa neural da rede. Vetores com características semelhantes sempre irão sensibilizar a mesma região do mapa. Esta característica é denominada de distribuição de probabilidade codificada por localização. A unidade vencedora é normalmente aquela com maior soma linear ponderada pelos pesos $w(t)$ das entradas para um dado vetor de entrada $x(t)$. Para obtenção dos pesos da rede é determinado o vetor de pesos mais próximo ao vetor de entrada $w(t)$, analogamente, mais semelhante à entrada utilizando os conceitos da distância euclideana:

$$\|x(t) - w_v(t)\| = \min_j \|x(t) - w_j(t)\|, \quad (2.27)$$

em que v é o índice do neurônio vencedor.

Definido o arranjo espacial dos neurônios para o mapa, é necessária a especificação do critério de vizinhança interneurônios que indique como estarão cooperando em relação aos seus vizinhos. Um critério de vizinhança consiste em especificar um raio de abrangência R , que será utilizado pelos neurônios visando definir seus respectivos vizinhos. Assim, para um determinado neurônio, seus vizinhos serão todos que estiverem a uma distância máxima que seja menor ou igual a R .

Considerando que um neurônio j venceu a competição frente à apresentação de uma amostra, tanto o seu vetor de pesos, quanto de seus vizinhos serão ajustados. Todavia, os neurônios que estão na vizinhança do neurônio vencedor serão ajustados com taxas menores àquelas usadas para o ajuste do vetor de pesos do neurônio vencedor.

Após o neurônio vencedor ter sido encontrado, as unidades no mapa são então, atualizadas. A regra de ajuste dos pesos tem a seguinte forma:

$$w_j(t+1) = w_j(t) + \beta(t)h_{j_v}(t)[x(t) - w_j(t)], \quad (2.28)$$

em que $\beta(t)$ é a taxa de aprendizagem representada por uma função decrescente em relação a t ; $h_{jv}(t)$ é a função vizinhança cujo valor depende da unidade vencedora $v(t)$, das outras unidades j e do instante t . Normalmente, $h_{jv}(t)$ tem a forma de uma função com valor máximo em $j = v(t)$ e decrescente à medida que se distancia do nó vencedor.

A taxa de aprendizagem pode ser ponderada por uma função do tipo Gaussiana, em que quanto maiores forem as distâncias dos neurônios vizinhos em relação ao neurônio vencedor, menores serão os seus ajustes.

Resumindo, três aspectos devem ser levados em conta para a configuração de um mapa auto-organizável de Kohonen:

- Definição do grid de neurônios.
- Delimitação dos conjuntos de vizinhança.
- Especificação do critério de ajuste do vetor de pesos do neurônio vencedor e seus vizinhos.

2.3 Fundamentos da Transformada *Wavelet*

O conceito básico das *Wavelets* é derivado da transformada de Haar, proposta em 1910. Porém, apenas na década de 80 houve uma formulação matemática, particularmente por DAUBECHIES (1992), MALLAT (1989) e MEYER (1990). O marco decisivo na história das *Wavelets* foi o trabalho de GROSSMAN & MORLET (1984), no qual os autores propuseram a TWC - Transformada *Wavelet* Contínua (COSTA, 2010).

A Transformada *Wavelet* constitui uma ferramenta moderna que permite a unificação de um grande número de técnicas de análise e processamento, como análise de imagens, algoritmo piramidal de Laplace e modelagem de sistemas variantes no tempo (OLIVEIRA, 2007). Ela inclui a Série de Fourier e a Transformada de Fourier, por exemplo, como casos particulares. Desse modo, é habilitada à análise de sinais não estacionários. A ferramenta efetua transformação

dos sinais no domínio do tempo, a partir de sua decomposição em vários outros com diferentes níveis de resolução.

É inevitável a comparação ou mesmo associação da Transformada de Fourier ao se trabalhar com *Wavelet*. Por que a análise de Fourier é falha para alguns casos? Em que a Transformada *Wavelet* irá otimizar a análise? Tem-se que uma das deficiências da análise via Transformada de Fourier é representar um “comportamento global médio” do sinal. Não há menção a aspectos locais dos sinais; todo o sinal é levado em consideração. A representação fornece um “espectro médio”. O trabalho em questão versa sobre FAI, um tipo de distúrbio imprevisível, em que a natureza da corrente de fase pode ser consideravelmente modificada (no sentido estatístico).

2.3.1 Transformada *Wavelet* Contínua

Um sinal ou função $f(t)$ pode ser mais bem representado se expresso como uma decomposição linear dada por (BURRUS, 1998):

$$f(t) = \sum_l a_l \psi(t). \quad (2.29)$$

Em que:

a_l – coeficientes reais.

$\psi(t)$ – conjuntos de funções reais em t .

Se a representação (2.29) é única, o conjunto $\psi(t)$ é denominado base para a classe de funções que podem ser expressas. Se a base é ortogonal implica que:

$$\langle \psi_k(t), \psi_l(t) \rangle = \int \psi_k(t) \psi_l(t) dt = 0 \quad k \neq l, \quad (2.30)$$

com os coeficientes sendo calculados por um produto interno:

$$a_k = \langle f(t), \psi_k(t) \rangle = \int f(t) \psi_k(t) dt. \quad (2.31)$$

Para a decomposição *Wavelet*, um sistema com dois parâmetros é construído de forma que (2.29) possa ser escrita da seguinte forma:

$$f(t) = \sum_k \sum_j a_{j,k} \psi_{j,k}(t), \quad (2.32)$$

$\psi_{j,k}(t)$ são as funções *Wavelet* mãe que geralmente formam uma base ortogonal.

O conjunto da expansão dos coeficientes $a_{j,k}$ é denominado Transformada *Wavelet* Discreta (TWD) de $f(t)$. A expansão *Wavelet* não é única. Existem inúmeros sistemas *Wavelet* que podem ser adotados efetivamente, porém todos precisam seguir três características gerais:

1. A *Wavelet* é um conjunto de decomposição bidimensional (geralmente uma base) para alguma classe de sinais de uma ou mais dimensões.
2. A decomposição *Wavelet* fornece uma localização tempo-frequência do sinal. Isto significa que maior parte da energia do sinal é bem representada por uma pequena decomposição dos coeficientes $a_{j,k}$.
3. Os cálculos dos coeficientes a partir do sinal podem ser feitos eficientemente.

Existem três características adicionais específicas para as decomposições *Wavelet*.

1. Todas as funções *Wavelet* de primeira geração são obtidas a partir da *Wavelet* mãe $\psi(t)$ pelos fatores de escala e translação, a serem definidos em (2.34).

$$\psi_{j,k}(t) = 2^{j/2} \psi(2^j t - k) \quad j, k \in \mathbb{Z}. \quad (2.33)$$

O tempo é parametrizado por k , e a frequência por j .

2. Se um conjunto de sinais pode ser representado por uma soma ponderada de $\psi(t-k)$, então um conjunto maior (inclusive o original) pode ser representado por uma soma ponderada de $\psi(2t-k)$.
3. Os coeficientes de baixa resolução podem ser calculados a partir dos coeficientes de alta resolução por um algoritmo denominado banco de filtros.

Dado um sinal ou uma função $f(t)$, a Transformada *Wavelet* contínua é definida como:

$$W_f(a,b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt, \quad (2.34)$$

sendo: $(a,b) \in (\mathbb{R}^*, \mathbb{R})$ e $f(t) \in L^2(\mathbb{R})$; a e b são respectivamente os fatores escala e translação; $W_f(a,b)$ os coeficientes *Wavelet* contínuos da função $f(t)$, e $\psi(t)$ a função *Wavelet* mãe.

A função *Wavelet* mãe deve satisfazer algumas propriedades básicas, sendo a mais importante a condição de admissibilidade:

$$\Gamma = \int_{-\infty}^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < \infty, \quad (2.35)$$

em que $\Psi(t)$ é a Transformada de Fourier da *Wavelet* mãe.

Decorrente de (2.35), as *Wavelets* são funções oscilatórias de valor médio zero, ou seja:

$$|\Psi(\omega)|_{\omega=0}^2 = 0 \Leftrightarrow \int_{-\infty}^{\infty} \psi(t) dt = 0. \quad (2.36)$$

A decomposição *wavelet* considera a decomposição da forma de onda analisada em sinais $\Psi(t)$ que constituem novos conjuntos de análise. Esta nova “base” é composta por sinais oscilatórios e “curta duração”, e não sinais *ab aeterno* (como os sinais periódicos e infinitos que formam a base na Transformada de Fourier).

As *Wavelets* também devem apresentar energia finita:

$$\int_{-\infty}^{\infty} \psi^2(t) dt < \infty. \quad (2.37)$$

As operações de escalonamento e translação da *Wavelet* mãe originam novas funções, denominadas de *Wavelets* filhas. Tais funções são oscilatórias, de valor médio zero e possuem a mesma energia da mãe.

Um exemplo clássico de *Wavelet* mãe é a função Chapéu Mexicano, cujo gráfico está traçado na Figura 2.5 obedecendo à equação (2.38):

$$\psi(t) = (1 - t^2) \cdot e^{-\frac{t^2}{2}}. \quad (2.38)$$

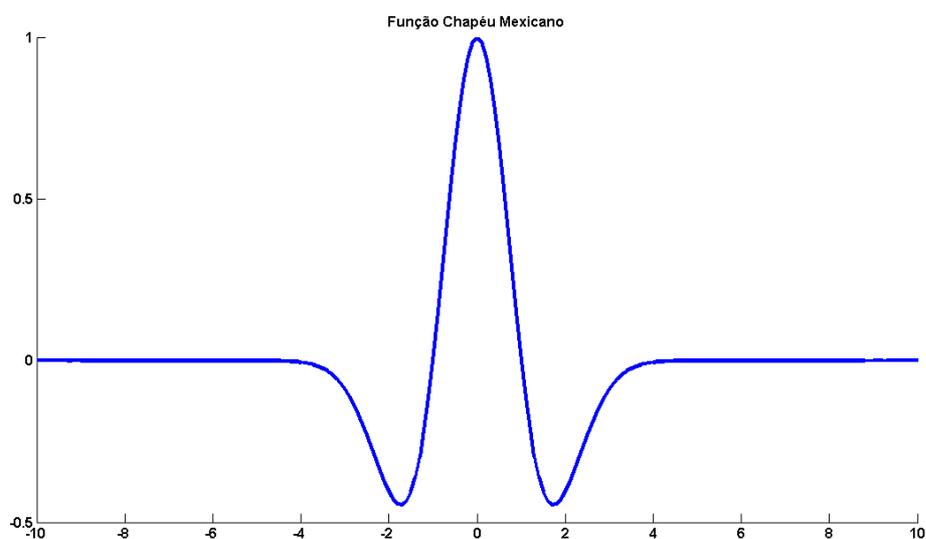


Figura 2.5. *Wavelet* Chapéu Mexicano (Fonte: Próprio Autor).

2.3.2 Transformada *Wavelet* Discreta

De um modo geral, as transformadas contínuas são primordialmente empregadas na dedução de propriedades das transformações. Formas discretas são atraentes do ponto de vista de implementação computacional. A discretização ocorre apenas nos domínios dos parâmetros (variáveis de escala e translação), não na variável independente.

A Transformada *Wavelet* Discreta pode ser interpretada como um banco de filtros, proposto por MALLAT (1989), representado na Figura 2.6 (b) para o caso da transformada direta. Assim, em um estágio (escala) m , um sinal discreto é decomposto em duas componentes: os coeficientes de aproximação $c_{m+1}(n)$ e os coeficientes de detalhes $d_{m+1}(n)$ (que representam as saídas de um filtro passa-baixa $h(n)$ e de outro passa-alta $g(n)$) que podem ser vistos na Figura 2.6 (a), seguidos por uma sub-amostragem por dois. Dessa forma, cada sinal terá a metade de amostras do sinal original, e a soma das amostras das saídas de aproximação e detalhes terá o número de amostras do sinal a ser analisado.

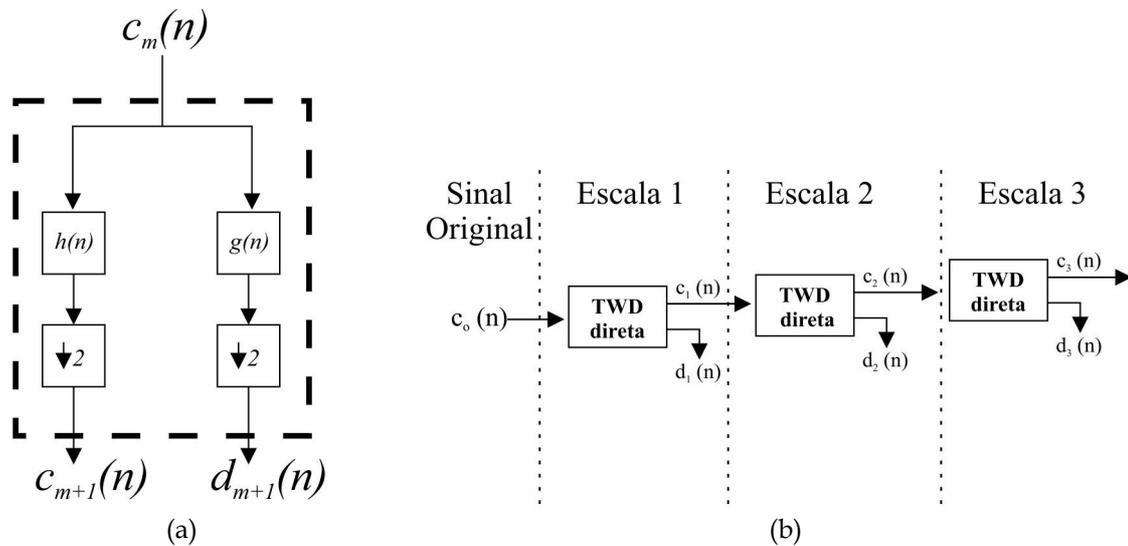


Figura 2.6. TWD direta: (a) bloco da TWD direta; (b) três estágios da TWD direta. (Adaptado de (SILVA, 2009)).

A saída do filtro $h(n)$ pode ser interpretada como uma aproximação do sinal $c_m(n)$, contendo componentes de baixa frequência, enquanto que a saída de $g(n)$ representa os detalhes do sinal $c_m(n)$, contendo componentes de alta frequência. Na próxima escala, o sinal $c_{m+1}(n)$ é decomposto em mais uma aproximação $c_{m+2}(n)$ e nos detalhes $d_{m+2}(n)$. Matematicamente, $c_{m+1}(n)$ e $d_{m+1}(n)$ são representados por:

$$c_{m+1}(n) = \sum_l h(l-2n)c_m(l), \quad (2.39a)$$

$$d_{m+1}(n) = \sum_l g(l-2n)c_m(l), \quad (2.39b)$$

com $l=2n+k$, $k \in \mathbb{Z}$.

Quando aplicadas recursivamente, essas equações definem a Transformada *Wavelet* rápida. As equações (2.39) representam a TWD direta. Ao final do processo de decomposição, devido ao processo de sub-amostragem (em que $\downarrow 2$ significa que o número de amostras será reduzido à metade após a decomposição), obtém-se um vetor de coeficientes *wavelet* de comprimento igual ao número de amostras do sinal original. Conforme PERCIVAL & WALDEN (2000), os coeficientes dos filtros satisfazem as condições a seguir:

$$\sum_{l=0}^{L-1} h_l = 0, \sum_{l=0}^{L-1} h_l^2 = 1, \sum_{l=-\infty}^{\infty} h_l h_{l+2n} = 0, \quad (2.40a)$$

$$\sum_{l=0}^{L-1} g_l = \sqrt{2}, \sum_{l=0}^{L-1} g_l^2 = 1, \sum_{l=-\infty}^{\infty} g_l g_{l+2n} = 0, \quad (2.40b)$$

em que $n \in \mathbb{Z}^*$ e $l = 0, 1, 2, \dots, L-1$. L é o número de coeficientes dos filtros, cujos valores dependem da *wavelet* mãe escolhida. Vale salientar que os filtros são espelhados em quadratura (DAUBECHIES, 1992 apud COSTA, 2010):

$$h_l = (-1)^l h_{L-1-l}, \quad (2.41a)$$

$$g_l = (-1)^{l+1} g_{L-1-l}. \quad (2.41b)$$

Os valores dos coeficientes g_l e h_l dos filtros escala e *wavelet*, respectivamente, dependem da *wavelet* mãe adotada.

Nas aplicações envolvendo discretização de sinais, há uma frequência mínima de amostragem, denominada frequência de Nyquist, correspondente a duas vezes o valor da componente de frequência mais elevada presente no sinal amostrado (OPPENHEIM & SCHAFFER, 1989). Assim, para que possa ser reconstruído, um sinal com frequência de amostragem f_s possui como banda máxima um espectro de frequência de 0 a $f_s/2$ Hz. Pelo fato dos filtros digitais g e h serem filtros espelhados em quadratura, os coeficientes de aproximação na primeira escala possuem espectro de frequência variando de 0 a $f_s/4$ Hz, enquanto que os coeficientes *wavelet*, nesta escala, possuem banda de passagem de $f_s/4$ a $f_s/2$ Hz. Nota-se que para as demais escalas a disposição de frequência seguirá a mesma lógica: a metade inferior da banda conterá os coeficientes de aproximação, enquanto os coeficientes *wavelet* ocuparão a metade superior.

Os espectros de frequência dos coeficientes de aproximação e *wavelet* em uma escala genérica j são dados, respectivamente, pelos intervalos das expressões (2.42):

$$\left[0, \frac{f_s}{2^{j+1}} \right], \quad (2.42a)$$

$$\left[\frac{f_s}{2^{j+1}}, \frac{f_s}{2^j} \right]. \quad (2.42b)$$

Em suma, a partir da Figura 2.6 e Equações (2.42) pode-se afirmar que um sinal discreto X pode ser representado em função da sua versão aproximada da j -ésima escala S_j acrescida de várias componentes detalhadas D_k (SILVA, 2009):

$$X = S_j + \sum_{k=1}^j D_k . \quad (2.43)$$

A resolução máxima, ou seja, a máxima j -ésima escala possível de ser determinada é dada por:

$$j_{\max} = \text{int} \left[\log_2 \left(\frac{N}{L} \right) + 1 \right], \quad (2.44)$$

em que o resultado do operador *int* retorna a parte inteira e N o número de amostras do sinal.

Para um sinal discreto X com N amostras, os vetores de coeficientes *wavelet* W_1 e de coeficientes escala V_1 do primeiro nível de resolução podem ser calculados de acordo com (2.45):

$$V_1 = A_1 X , \quad (2.45a)$$

$$W_1 = B_1 X . \quad (2.45b)$$

Há de se ressaltar que N deve ser uma potência de 2, além da existência do processo de sub-amostragem. Assim, os vetores dos coeficientes *wavelet* e escala terão $N/2$ amostras. As matrizes A_1 e B_1 possuirão, dessa forma, a ordem $(N/2) \times N$:

$$A_1 = \begin{bmatrix} g_0 & g_1 & g_2 & g_3 & \cdots & g_{L-1} & 0 & 0 & 0 & 0 & \cdots & 0 & 0 \\ 0 & 0 & g_0 & g_1 & g_2 & g_3 & \cdots & g_{L-1} & 0 & 0 & \cdots & 0 & 0 \\ 0 & 0 & 0 & 0 & g_0 & g_1 & g_2 & g_3 & \cdots & g_{L-1} & \cdots & 0 & 0 \\ \vdots & \ddots & \vdots & \ddots & \vdots & \vdots \\ g_2 & g_3 & \cdots & g_{L-1} & 0 & 0 & 0 & 0 & \cdots & 0 & 0 & g_0 & g_1 \end{bmatrix}, \quad (2.46a)$$

$$B_1 = \begin{bmatrix} h_0 & h_1 & h_2 & h_3 & \cdots & h_{L-1} & 0 & 0 & 0 & 0 & \cdots & 0 & 0 \\ 0 & 0 & h_0 & h_1 & h_2 & h_3 & \cdots & h_{L-1} & 0 & 0 & \cdots & 0 & 0 \\ 0 & 0 & 0 & 0 & h_0 & h_1 & h_2 & h_3 & \cdots & h_{L-1} & \cdots & 0 & 0 \\ \vdots & \ddots & \vdots & \ddots & \vdots & \vdots \\ h_2 & h_3 & \cdots & h_{L-1} & 0 & 0 & 0 & 0 & \cdots & 0 & 0 & h_0 & h_1 \end{bmatrix}. \quad (2.46b)$$

Analisando-se as matrizes de (2.46), conclui-se que A_1 e B_1 são formadas a partir de deslocamentos circulares das suas primeiras linhas. São aplicados dois

deslocamentos de uma linha para outra, o que representa o processo de decimação das amostras do sinal X .

A reconstrução do sinal realizada através da TWD inversa é também calculada a partir da estrutura de banco de filtros, de forma semelhante a decomposição, mas agora na ordem reversa (Figura 2.7(b)) a partir de um processo de sobreamostragem (em que $\uparrow 2$ significa que o número de amostras será duplicado). Matematicamente ela é representada por:

$$c_{m+1}(n) = \sum_l [h(l-2n)c_m(l) + g(l-2n)d_m(l)], \quad (2.47)$$

com $l=2n+k$, $k \in \mathbb{Z}$.

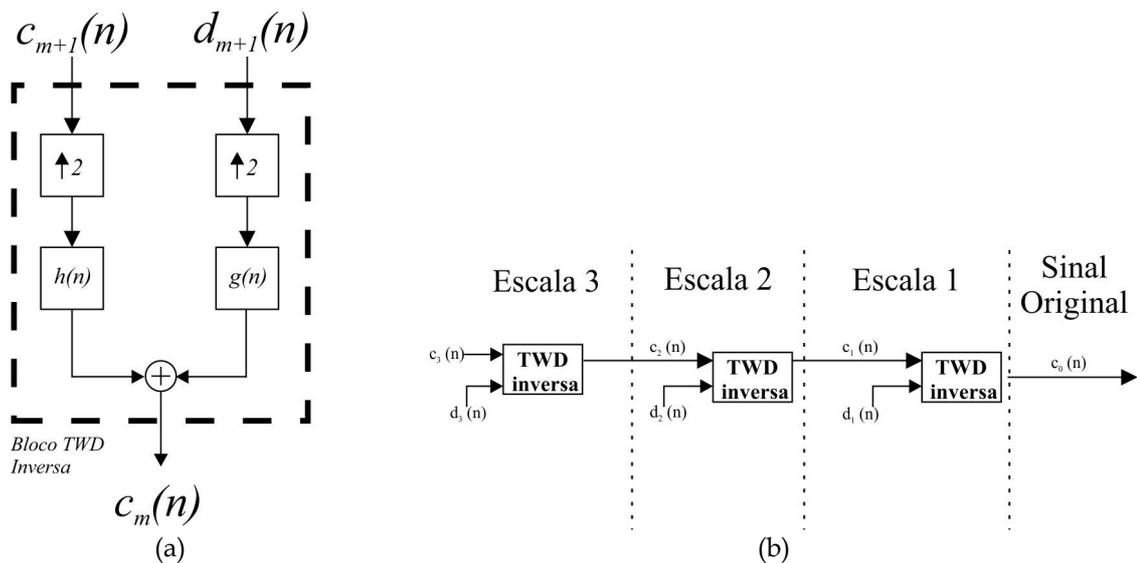


Figura 2.7. TWD inversa: (a) bloco da TWD inversa; (b) três estágios da TWD inversa (Adaptado de (SILVA, 2009)).

Levando-se em consideração o processo de sub-amostragem ($\downarrow 2$) utilizado na TWD direta e o de sobreamostragem ($\uparrow 2$) na TWD inversa, a relação entre o índice do coeficiente *wavelet* e a amostra do sinal original à qual ele está relacionado é 2^n , com n sendo o número da escala de resolução. Por exemplo, a vigésima amostra de um sinal está relacionada ao décimo coeficiente *wavelet* de detalhe da primeira escala de resolução e ao quinto da segunda escala.

2.3.3 Transformada *Wavelet* Discreta Redundante

Para justificar a adoção da Transformada *Wavelet* Discreta Redundante – TWDR, alguns detalhes serão antecipados. Utilizou-se uma RNA para localização, com a base de dados de entrada sendo formada pelas amostras das correntes de fase, além da energia dos coeficientes *wavelet* da fase com falta.

Dessa forma, há 4 vetores formando a base de dados de entrada: correntes (fases A, B e C) e a energia dos coeficientes *wavelet*. Para o treinamento correto e aprendizagem da RNA, tais vetores precisam ter as mesmas dimensões. Sabe-se que com a TWD, uma consequência é o processo de sub-amostragem (número de amostras cai pela metade), assim como a obrigatoriedade do número de amostras ser uma potência de 2. Com a adoção da TWDR, não há sub-amostragem, o número de amostras dos coeficientes é o mesmo das correntes de fase; sendo mais prática a utilização das técnicas de Inteligência Artificial.

Conforme estudos de SILVA (2009) e COSTA (2010), as demais diferenças relevantes entre a TWD e TWDR são citadas a seguir:

- A TWDR é uma transformada invariante no tempo.
- A TWDR é uma transformada não-ortogonal, já a TWD é ortonormal.
- A TWDR pode ser aplicada a qualquer número de amostras, enquanto que a TWD requer que este número seja uma potência de dois.

Os coeficientes \tilde{g}_l dos filtros escala e \tilde{h}_l dos filtros *wavelet* da TWDR são obtidos dos correspondentes filtros da TWD (PERCIVAL; WALDEN, 2000):

$$\tilde{g}_l = g_l / \sqrt{2}, \quad (2.48a)$$

$$\tilde{h}_l = h_l / \sqrt{2}. \quad (2.48b)$$

Os coeficientes dos filtros satisfazem as condições a seguir:

$$\sum_{l=1}^L \tilde{h}_l = 0, \quad \sum_{l=1}^L \tilde{h}_l^2 = \frac{1}{2}, \quad \sum_{l=-\infty}^{\infty} \tilde{h}_l \tilde{h}_{l+2n} = 0, \quad (2.49a)$$

$$\sum_{l=1}^L \tilde{g}_l = 1, \quad \sum_{l=1}^L \tilde{g}_l^2 = \frac{1}{2}, \quad \sum_{l=-\infty}^{\infty} \tilde{g}_l \tilde{g}_{l+2n} = 0. \quad (2.49b)$$

em que $n \in \mathbb{N}^*$ (conjunto dos números naturais, excluindo-se o zero) e $l = 0, 1, 2, \dots, L-1$. L é o número de coeficientes dos filtros, cujos valores dependem da *wavelet* mãe escolhida. Os filtros também são espelhados em quadratura de forma semelhante à TWD:

$$\tilde{h}_l = (-1)^l \tilde{h}_{L-1-l}, \quad (2.50a)$$

$$\tilde{g}_l = (-1)^{l+1} \tilde{g}_{L-1-l}. \quad (2.50b)$$

Por analogia, todo raciocínio referente ao algoritmo piramidal para cálculo da TWD, assim como a reconstrução do sinal, podem ser empregados para a TWDR. Um sinal discreto X pode ser representado em função da sua versão aproximada da j -ésima escala \tilde{S}_j acrescida de várias componentes detalhadas \tilde{D}_k :

$$X = \tilde{S}_j + \sum_{k=1}^j \tilde{D}_k. \quad (2.51)$$

O número máximo de níveis de resolução da TDWR, ou seja, a máxima j -ésima escala possível de ser determinada é dada por:

$$j_{\max} = \text{int} \left[\log_2 \left(\frac{N-1}{L-1} \right) + 1 \right], \quad (2.52)$$

em que o resultado do operador *int* retorna a parte inteira, N o número de amostras do sinal e L o número de coeficientes dos filtros escala e *wavelet*.

Os cálculos para determinação dos vetores de coeficientes *wavelet* \tilde{W}_1 e coeficientes escala \tilde{V}_1 de um sinal discreto X com de N amostras para a TWDR são bastante semelhantes ao caso da TWD. A ausência da decimação nas amostras é o mais relevante. Tal processo em algumas circunstâncias é tido como indesejável por inserir determinadas redundâncias nos sinais decompostos. Porém, no trabalho em questão trata-se de um efeito útil; tendo em vista que será feita a utilização do mesmo conjunto de amostras janeladas como entradas para as RNA. Os coeficientes do primeiro nível de resolução são dados de acordo com (2.52):

$$\tilde{V}_1 = \tilde{A}_1 X, \quad (2.53a)$$

$$\tilde{W}_1 = \tilde{B}_1 X. \quad (2.53b)$$

Nesse caso, as matrizes \tilde{A}_1 e \tilde{B}_1 serão matrizes quadradas de ordem N:

$$\tilde{A}_1 = \begin{bmatrix} \tilde{g}_0 & \tilde{g}_1 & \tilde{g}_2 & \tilde{g}_3 & \cdots & \tilde{g}_{L-1} & 0 & 0 & 0 & 0 & \cdots & 0 & 0 \\ 0 & \tilde{g}_0 & \tilde{g}_1 & \tilde{g}_2 & \tilde{g}_3 & \cdots & \tilde{g}_{L-1} & 0 & 0 & 0 & \cdots & 0 & 0 \\ 0 & 0 & \tilde{g}_0 & \tilde{g}_1 & \tilde{g}_2 & \tilde{g}_3 & \cdots & \tilde{g}_{L-1} & \cdots & 0 & \cdots & 0 & 0 \\ \vdots & \ddots & \vdots & \ddots & \vdots & \vdots \\ \tilde{g}_1 & \tilde{g}_2 & \tilde{g}_3 & \cdots & \tilde{g}_{L-1} & 0 & 0 & 0 & \cdots & 0 & 0 & 0 & \tilde{g}_0 \end{bmatrix}, \quad (2.54a)$$

$$\tilde{B}_1 = \begin{bmatrix} \tilde{h}_0 & \tilde{h}_1 & \tilde{h}_2 & \tilde{h}_3 & \cdots & \tilde{h}_{L-1} & 0 & 0 & 0 & 0 & \cdots & 0 & 0 \\ 0 & \tilde{h}_0 & \tilde{h}_1 & \tilde{h}_2 & \tilde{h}_3 & \cdots & \tilde{h}_{L-1} & 0 & 0 & 0 & \cdots & 0 & 0 \\ 0 & 0 & \tilde{h}_0 & \tilde{h}_1 & \tilde{h}_2 & \tilde{h}_3 & \cdots & \tilde{h}_{L-1} & \cdots & 0 & \cdots & 0 & 0 \\ \vdots & \ddots & \vdots & \ddots & \vdots & \vdots \\ \tilde{h}_1 & \tilde{h}_2 & \tilde{h}_3 & \cdots & \tilde{h}_{L-1} & 0 & 0 & 0 & \cdots & 0 & 0 & 0 & \tilde{h}_0 \end{bmatrix}. \quad (2.54b)$$

As linhas de \tilde{A}_1 e \tilde{B}_1 são formadas por deslocamentos circulares dos termos da primeira linha, ou seja, dos coeficientes dos filtros *wavelet* e escala. O deslocamento se dá N vezes até que o termo de índice 11 torne-se de índice NN.

2.3.4 Análise da Energia das Componentes dos Sinais

Na Tese, optou-se por utilizar a energia dos coeficientes *wavelet* da fase com falta. Conforme COSTA (2010), a energia dos coeficientes fornece fortes indicadores sobre a ocorrência de distúrbios em sistemas de transmissão. No trabalho, foram realizadas simulações para comprovar se o raciocínio pode ser estendido para FAI em sistemas de distribuição.

Aplicando-se o Teorema de Parseval em (2.47), tem-se que a energia de um sinal pode ser decomposta em função da energia dos coeficientes *wavelet* e de detalhes de primeira escala (PERCIVAL; WALDEN, 2000):

$$\sum_{k=1}^{k_f} |i(k)|^2 = \sum_{k=1}^{k_f} |c_1(k)|^2 + \sum_{k=1}^{k_f} |d_1(k)|^2. \quad (2.55)$$

Em que:

$$\sum_{k=1}^{k_f} |i(k)|^2 - \text{Energia da Corrente } i.$$

$$\sum_{k=1}^{k_f} |c_1(k)|^2 - \text{Energia dos Coeficientes de Aproximação de Primeira Escala.}$$

$$\sum_{k=1}^{k_t} |d_1(k)|^2 - \text{Energia dos Coeficientes } \textit{Wavelet} \text{ de Primeira Escala.}$$

k_t - Número de amostras do sinal.

Utilizou-se as energias janeladas em um ciclo, ou seja, o número de amostras para um ciclo de 60 Hz da corrente (para um sinal com frequência de amostragem de 15360 Hz, foram 256 amostras). O termo “janelada”, deve-se à janela de um ciclo, ou seja, o vetor de energias tem k_t-1 elementos a menos que o sinal original. O primeiro valor de energia só existe quando houverem k_t pontos do sinal. À medida que se analisa todo o sinal, as amostras mais antigas são substituídas pelas mais recentes; de modo a manter uma janela constante.

Capítulo 3

Revisão Bibliográfica

O capítulo é iniciado com uma breve revisão sobre a aplicação das ferramentas utilizadas na Tese: Transformada *Wavelet* e Redes Neurais Artificiais, enfatizando a detecção das FAI. Na sequência, serão abordados alguns trabalhos no tema de localização de FAI, evidenciando técnicas com suas características, particularidades, dificuldades e limitações encontradas no diagnóstico do evento. Finalizando o capítulo, será apresentado um panorama sobre a realização de ensaios de laboratório e campo objetivando a modelagem e diagnóstico das FAI.

3.1 Detecção das FAI

Na década de 70 iniciaram-se as pesquisas para obtenção de maior domínio sobre o fenômeno das FAI, sem maiores progressos. AUCOIN (1985) contribuiu significativamente no tema ao discutir o assunto, evidenciando os aspectos técnico, operacional e econômico. Apontaram-se indícios de que o caminho indicado para o diagnóstico seria o monitoramento das componentes “fora” dos 60 Hz. Ainda não havia especificação da ferramenta a ser adotada para monitoramento dessas componentes. Vale salientar que a Transformada *Wavelet* consiste em uma dessas técnicas.

3.1.1 Transformada *Wavelet* e Redes Neurais Artificiais

Dentre as ferramentas utilizadas recentemente para diagnóstico de faltas e demais distúrbios nos sistemas elétricos, destacam-se a Transformada *Wavelet* (TW) e a utilização de RNA (COSTA, 2010; SILVA, 2009; OLESKOVICZ et al, 2009; SILVA 2004). O trabalho de SILVA et al (2007) foi um dos primeiros do Grupo de Sistemas Elétricos da UFCG a apresentar resultados com a mescla das duas técnicas para a classificação de faltas. Na ocasião, o diagnóstico foi realizado em sistemas de transmissão. Na presente seção serão abordados trabalhos que compuseram o Estado da Arte da Tese, procurando na medida do possível comparar com o que foi desenvolvido. Mesmo sendo a localização o cerne da pesquisa, é possível comparar as metodologias em função das técnicas envolvidas, dados utilizados, dentre outros aspectos correlatos.

Em 1996, MOMOH & RIZY, iniciaram os estudos aplicando as duas técnicas, com dados gerados em laboratório. A frequência de amostragem utilizada pelos autores foi de 62,5 kHz; o que não é tão realizável em termos práticos. Neste trabalho de Tese, os dados para a modelagem das FAI foram obtidos em ensaios de campo em um alimentador de uma concessionária local.

A técnica proposta por BUTLER & MOMOH (2000) também utiliza RNA, em que os dados de entrada são as correntes trifásicas de cada ramo do alimentador. Além da detecção, é realizada a classificação da falta entre baixa e alta impedância. Obteve-se um acerto de 92%. Ao contrário do trabalho desenvolvido na Tese, não há evidências de que existam dados reais no modelo ou dados para treinamento da RNA.

LAZKANO et al (2001) propuseram um método de detecção baseado na extinção e reignição do arco elétrico. A TW foi utilizada para decompor o sinal de corrente de neutro no início do alimentador. Combinando as propriedades de tempo e frequência, critérios foram escolhidos com o intuito de detectar os arcos decorrentes de FAI. Foram utilizados apenas dados simulados num sistema teste de 20 kV. Diferentes tipos de superfícies e situações climáticas foram

considerados. Para assegurar que não ocorram falsos alertas de FAI, foram registradas também correntes em condições normais. Os dados foram analisados a cada 32 ciclos da corrente de neutro. Para os casos de correntes de falta acima de 2 A, 100% das FAI foram detectadas com sucesso. Em testes com a situação de operação normal, nenhum caso de falso alarme foi verificado. Considerando-se todos os casos, um total de 99,5% das FAI foi detectado com sucesso. Na Tese desenvolvida, os sinais das correntes trifásicas foram decompostos. As correntes das fases foram escolhidas por considerar que carregam consigo informações correlatas às faltas, como o carregamento, por exemplo.

YANG et al (2004) propuseram um método para detecção e classificação de FAI baseado na TW em conjunto com as RNA, após atingirem o objetivo com a aplicação das técnicas para faltas francas. A extração de características e o esquema de detecção propostos são baseados na Transformada *Wavelet* Ortonormal. A FAI é detectada e classificada usando-se os coeficientes de detalhe da primeira escala, obtidos com a *wavelet* mãe Daubechies 10 (DAUBECHIES, 1992). A frequência de amostragem utilizada foi de 3840 Hz.

O valor do coeficiente *wavelet* da 1ª escala referente ao instante inicial da falta é obtido e dividido pelo valor em regime permanente, obtendo-se assim o coeficiente de variação de cada corrente e tensão de forma normalizada. Assim, tem-se as entradas da RNA utilizada (3 coeficientes de corrente mais 3 coeficientes de tensão), do tipo MLP. Foi utilizado em sua etapa de treinamento o algoritmo *backpropagation*, de forma idêntica à adotada na Tese. A arquitetura da RNA contou com 6 entradas e 3 saídas; em que a primeira saída indica se houve falta ou não, a seguinte indica se houve algum chaveamento ou uma falta, e a última faz a distinção da fase onde houve a falta. Foram usadas RNA com camadas ocultas de números distintos e a taxa de acerto variou entre 98 a 100%. Uma ressalva a ser feita é que não foi levado em conta o carregamento do sistema, assim como a realização de ensaios em determinadas superfícies. Os coeficientes de detalhes são importantes sim, mas o sinal no domínio no tempo não deve ser desprezado (através das tensões ou correntes de fase, pode-se inferir o nível de carregamento,

amortecimento dos transitórios, dentre outros aspectos). No desenvolvimento da Tese em questão, levou-se em consideração além dos coeficientes de detalhes, o sinal em sua forma original (domínio do tempo). Os mesmos autores utilizaram na metodologia um ano depois (YANG et al, 2005) a *wavelet* mãe Daubechies 20 (DAUBECHIES, 1992), com uma frequência de amostragem de 6 kHz e a realização em terrenos como areia, asfalto e gramado, com os terrenos molhados e secos. A corrente de neutro foi decomposta até a 4ª escala, o que é uma escolha complicada quando se trabalha com dados reais. Com as limitações técnicas na aquisição e processamento dos dados, um nível de detalhamento até a 4ª escala apresenta grande risco de não se constituir em um dado fiel, tendo em vista a inserção de ruídos assim como uma resposta em frequência inadequada. O nível de acerto caiu para 76%, o que evidencia a dificuldade de se transportar para a prática os resultados simulados, quando se trata do fenômeno de FAI.

SEDIGHI et al (2005) propuseram um método de detecção de FAI combinando a TW com reconhecimento de padrões através de técnicas estatísticas. A base de dados utilizada no artigo é composta por dados reais. No trabalho, o sinal medido foi a corrente no início do alimentador, assim como proposto na Tese. A *wavelet* mãe usada foi a *rbior3.1*, aplicada às correntes de falta. Os coeficientes de detalhe da 1ª e 2ª escalas foram escolhidos para a extração de características, já que neles estão contidos os componentes de alta frequência do sinal. Além das FAI, outras classes de distúrbios estudadas no trabalho foram os transitórios comuns e as correntes de fuga nos isoladores. Utilizou-se um Classificador *Bayseano* (nomenclatura devido ao teorema de probabilidade de Bayes) para classificação do evento. Seu algoritmo tem como objetivo calcular a probabilidade que uma amostra desconhecida pertença a cada uma das classes possíveis. Chegou-se a uma taxa de acerto de 96,7% para a detecção de FAI. Trabalho semelhante foi desenvolvido alguns anos antes por THUKARAM et al (2002) em que são utilizadas regras de decisão para classificar se determinado evento é ou não FAI, detectando-se a fase que apresente valores anormais no fluxo de potência.

Um método para detecção de FAI com as técnicas citadas também foi desenvolvido por MOKHTARI & AGHATERHANI (2005). O método é composto de duas etapas: extração de características e detecção. A extração de características é baseada na *wavelet* mãe Daubechies 4 (DAUBECHIES, 1992); enquanto que a etapa de detecção é realizada por uma RNA de três camadas. As características são extraídas a partir da decomposição da corrente no início do alimentador; obtendo-se as três primeiras escalas de detalhe (d_1 , d_2 , d_3). Dividiu-se o primeiro período de d_1 em quatro intervalos iguais e a energia contida nesses intervalos mais a energia contida em d_2 e d_3 formaram as seis características usadas no método como entradas da RNA. A função de base da RNA é linear e suas funções de ativação são do tipo *tansig* (tangente hiperbólica). Durante a fase de treinamento foram usados 110 casos de FAI e de transitórios de chaveamento. Para o teste foram usados 3200 casos de FAI, 2000 casos de chaveamento de capacitores e 1700 casos de chaveamentos de cargas.

MICHALIK et al (2006) desenvolveram outro método mesclando TW e RNA, utilizando apenas dados simulados. A técnica baseia-se na aplicação da TW nas componentes de sequência zero das tensões e correntes no pós-falta, em que a detecção é verificada pela defasagem entre os coeficientes *wavelet* da tensão e corrente de neutro. A estrutura que verifica se houve essa defasagem é uma RNA do tipo MLP, em que os dados de entrada são as 3 últimas amostras da TWC da tensão e corrente de neutro. O alimentador foi modelado como circuito pi no ATP, o que já reduz o nível de realidade da implementação. No aprimoramento da técnica, MICHALIK et al (2008) introduziram dados reais nos estudos, obtidos de registradores. A tensão e corrente de neutro ainda são utilizadas na RNA, porém para utilização em dois algoritmos: o primeiro utilizando a potência aparente, o outro utilizando potência ativa. O sinal da potência determina a existência ou não do distúrbio (no trabalho, potência negativa indica condição normal, potência positiva indica distúrbio). Os resultados mostraram-se satisfatórios utilizando-se janelas mínimas de 40 amostras.

ELKALASHY et al (2007) utilizaram a TWD para obtenção dos coeficientes de detalhe de 3ª escala das tensões e correntes residuais (resultados das somas). O método foi desenvolvido para detecção de faltas causadas pela inclinação das árvores. Para determinação da existência da falta, é realizada a soma dos coeficientes durante um ciclo; caso essa soma seja positiva, indica-se a existência de FAI. A *wavelet* mãe utilizada foi a Daubechies 14 (DAUBECHIES, 1992), com o sistema tendo sido modelado no ATPDraw. A proposta não é revestida de senso prático, tendo em vista a frequência de amostragem simulada (100 kHz) e a necessidade de haver registradores para obtenção das oscilografias em cada ramificação do alimentador. Os autores procederam algumas modificações no trabalho; e em ELKALASHY et al (2008) nota-se a inserção de experimentos de laboratório para avaliação das características das FAI ocasionadas por quedas de condutores sobre árvores. Nota-se a prioridade dos eventos provocados que envolvam as árvores, devido ao contingente de florestas na Escandinávia (Norte da Europa, região do estudo). As FAI foram modeladas na TACS e o modelo utilizado para o alimentador foi de parâmetros dependentes da frequência. Os resultados não são claros no artigo, tampouco a aplicabilidade prática em que se recomenda a utilização até de coeficientes da 4ª escala, ocasião em que se pode obter mais ruídos do que a TW do sinal de falta, pois é referente a uma restrita banda que é uma pequena parte do sinal de aproximação de 1ª escala.

COSTA (2010) já indicava a utilização das energias dos coeficientes *wavelet* para detecção e análises mais apuradas de distúrbios em sistemas de potência. Na ocasião, a técnica foi utilizada para detecção de afundamentos de tensão, faltas evolutivas (inclusive determinando os instantes inicial e final) em Sistemas de Transmissão. SALIM et al (2008) também utilizaram a técnica para sistemas de distribuição, em que se comparava as energias normalizadas dos coeficientes *wavelet* (CW) das correntes trifásicas com um limiar. Caso o limiar fosse ultrapassado, havia distúrbio. Apenas há de se ressaltar que não foram testadas FAI para o trabalho em questão. Ampliando os estudos iniciados em 2010 e contando com os dados do Projeto de P&D Energisa/UFCEG, COSTA et al (2011)

desenvolveram um método para detecção de FAI utilizando as energias dos coeficientes de detalhes. Através da análise dos registros oscilográficos obtidos experimentalmente do alimentador em operação normal, notou-se que os coeficientes CW das tensões e correntes referentes ao regime permanente apresentam valores aleatórios, com distribuição normal. Baseando-se nos valores da média e do desvio padrão desses coeficientes, COSTA et al (2011) desenvolveram o método. Inicialmente, são calculados os CW das tensões e correntes das fases A, B, C e neutro (W_{VAj} , W_{VBj} , W_{VCj} , W_{VNj} , W_{IAj} , W_{IBj} , W_{ICj} , W_{INj}), nas três primeiras escalas ($j = 1, 2$ e 3), totalizando 24 sinais. Em seguida, considerando-se o período de 1 s do regime permanente, calculam-se dois limiares para todos os CW: um inferior e outro superior, em função da média e do desvio padrão, denominados de limiares de regime permanente¹.

O processo de detecção é iniciado, amostra por amostra, até o fim do registro. Caso nenhuma FAI seja detectada, reajustam-se os valores dos limiares². Caso haja detecção³, o método precisa confirmar sua ocorrência⁴. Isso é realizado avaliando: se os CW ultrapassarem os limiares de regime permanente por um período mínimo de um segundo (60 ciclos), a FAI é confirmada. Caso contrário, é um distúrbio transitório (UFCCG, 2010). A detecção das FAI é realizada de forma independente para cada um dos CW das tensões e correntes, das três primeiras escalas. Os instantes inicial e final da FAI, no entanto, engloba os instantes inicial e final individuais de todos os registros. Para avaliar o desempenho do método, foram utilizados os dados obtidos nos ensaios, indicados na Tabela 3.1.

¹ Levando em consideração que o nível dos ruídos pode mudar conforme o carregamento do sistema, o método utiliza limiares adaptativos.

² Os limiares são reajustados a cada segundo, exceto quando uma FAI é detectada. Neste caso, os limiares permanecem constantes até o final do fenômeno.

³ Uma FAI é detectada caso um dos CW das tensões e/ou correntes, das três primeiras escalas, ultrapasse os limiares de regime permanente.

⁴ Isso é necessário, pois, normalmente, uma FAI não é eliminada pelo sistema de proteção.

Tabela 3.1. Desempenho do método de detecção de FAI no local de falta.

Ensaio	Número de Faltas	Acerto na Detecção
Asfalto	Seco	2
	Molhado	5
Areia	Seca	2
	Molhada	5
Calçamento	Seco	10
	Molhado	2
Brita	Seca	2
	Molhada	2
Grama	Seca	3
	Molhada	2
Terra seca	2	2
Árvore	5	0

Fonte: (UFCCG, 2010).

3.1.2 Outras Contribuições

A análise da 3ª componente harmônica das correntes de fase mostrou-se como um possível indicador de FAI, conforme os resultados obtidos por EMANUEL et al (1990). Para identificação das faltas foram desenvolvidos detectores de aumento de amplitude e de deslocamento do ângulo da 3ª harmônica de corrente de uma fase com relação às demais. A *Norton Research and Development* utilizou como indicador de FAI o ângulo de fase da corrente de falta de 3º harmônico com relação à tensão fundamental. Em função das características das FAI, de ser um distúrbio não-estacionário e aleatório, a estimação de harmônicos não fornece detalhes tão precisos quanto os fornecidos pela TW.

CHRISTIE et al (1993) desenvolveram um detector cujo funcionamento era baseado no monitoramento do aumento repentino da energia das correntes de fase. Assim como EMANUEL et al (1990), desenvolveram um arranjo experimental em laboratório para os estudos. No artigo em questão, a corrente de carga era da ordem de 10 A. Para separar a corrente pura de falta (ordem de grandeza bem menor que a corrente de carga) utilizou-se um filtro rejeita-faixa sintonizado em 60 Hz, seguido de um passa-faixa entre 2-10 kHz. Algumas limitações foram verificadas, como o fato da mudança de carga se efetuar em ritmo mais lento que a ocorrência dos arcos de falta. Ressalta-se também um

problema que permanece até os dias de hoje (com a limitação de frequência de amostragem dos equipamentos e suas próprias respostas em frequência), que é o fato das altas frequências não se propagarem em cargas ou trechos de natureza capacitiva. Notou-se que as componentes de alta frequência presentes nos arcos são similares às componentes verificadas nas FAI. Foram verificados alguns casos de falso positivo, com os arcos intermitentes devido à vegetação.

SANTOS et al (2013) realizaram um levantamento comparativo das técnicas de detecção, apontando perspectivas futuras. Dentre as técnicas citadas, está a teoria das ondas viajantes, baseada na propagação de ondas transitórias originadas pelo próprio distúrbio. Esse tipo de análise em alimentadores com inúmeras derivações laterais é complexa, dificultando a localização a partir de informações obtidas apenas na subestação (HIZAM et al, 2002).

Em LOPES et al (2011) é apresentada uma técnica de detecção e localização de FAI baseada no monitoramento de componentes de alta frequência por meio da transformada de Park ($Tdq0$). O algoritmo é auto-adaptativo às condições operacionais do SDEE e pode ser aplicado em tempo real. Os objetivos foram alcançados para taxas de amostragem típicas de RDP comerciais. Ressalte-se apenas que a localização das FAI foi indicada em determinada região do alimentador, não se constituindo em objetivo a determinação do ponto exato.

Na Tabela 3.2 a seguir é apresentada uma síntese do Estado da Arte para a Detecção de FAI.

Tabela 3.2. Síntese - Detecção de FAI.

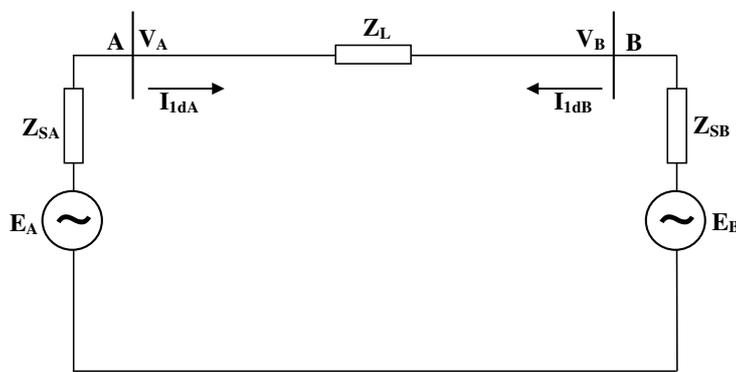
Técnicas Utilizadas	Trabalho	Particularidades
TW/RNA	MOMOH & RIZY (1996)	✓ Dados gerados em laboratório. ✓ Frequência de amostragem de 62,5 kHz.
	YANG et al (2004)	✓ <i>Wavelet</i> mãe - Daubechies 10. ✓ Entradas - CW das tensões e correntes.
	YANG et al (2005)	✓ <i>Wavelet</i> mãe - Daubechies 20. ✓ Decomposição até a 4ª escala dos CW.
	MOKHTARI & AGHATERHANI (2005)	✓ CW de 1ª, 2ª e 3ª escalas das correntes. ✓ <i>Wavelet</i> mãe - Daubechies 4.
	MICHALIK et al (2006)	✓ Apenas dados simulados. ✓ Defasagem entre os CW da tensão e corrente de neutro.
	MICHALIK et al (2008)	✓ Inserção de dados reais em MICHALIK et al (2006). ✓ Algoritmos de potência.
RNA	BUTLER & MOMOH (2000)	✓ Entradas - correntes trifásicas de cada ramo. ✓ 92% de acerto.
TW	LAZKANO et al (2001)	✓ Corrente do neutro. ✓ 99,5% de acerto.
	SEDIGHI et al (2005)	✓ Classificador <i>Bayseano</i> . ✓ CW de 1ª e 2ª escalas das correntes.
	ELKALASHY et al (2007)	✓ CW de 3ª escala para tensões e correntes residuais. ✓ Elevada frequência de amostragem - 100 kHz.
	ELKALASHY et al (2008)	✓ FAI em árvores. ✓ CW de 4ª escala das correntes.
	SALIM et al (2008), COSTA et al (2011)	✓ Energia dos CW das correntes.
Harmônicos	EMANUEL et al (1990)	✓ 3º harmônico das correntes de fase. ✓ Defasagem da tensão/corrente.
Energia	CHRISTIE et al (1993)	✓ Aumento repentino da energia das correntes. ✓ Determinação da corrente pura de falta por filtragem.
Ondas Viajantes	HIZAM et al (2002)	✓ Propagação de ondas transitórias originadas pelo próprio distúrbio.
Transformada de Park	LOPES et al (2011)	✓ Monitoramento das componentes de alta frequência. ✓ Determinação da região no alimentador.

Fonte: Próprio Autor.

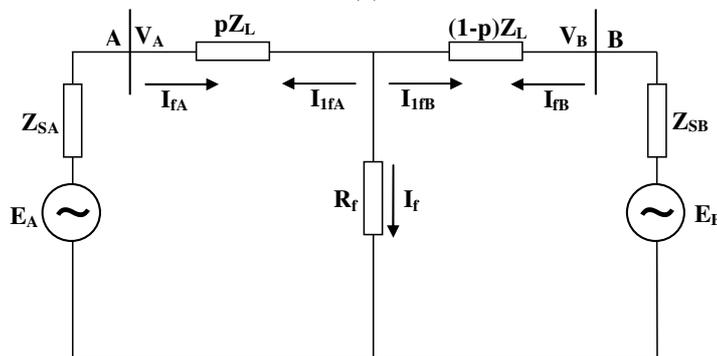
3.2 Localização das FAI em Sistemas de Distribuição

A detecção e classificação das faltas para sistemas de distribuição podem ser realizadas pela análise das formas de onda de tensão e corrente, de forma análoga ao que é feito para os sistemas de transmissão (SILVA, 2004). Contudo, as aproximações de localizações de falta em linhas de transmissão não são totalmente adequadas para alimentadores com muitas ramificações. A complexidade estrutural do sistema de distribuição pode resultar em indicações ambíguas para a localização, pois mais de uma possibilidade pode ser encontrada (TANG et al, 2000). Além disso, a pequena quantidade de amostras do sinal medido, a incerteza sobre os valores de resistência de falta, a heterogeneidade da linha, a incerteza sobre a carga e o desbalanceamento entre as fases podem dificultar a localização.

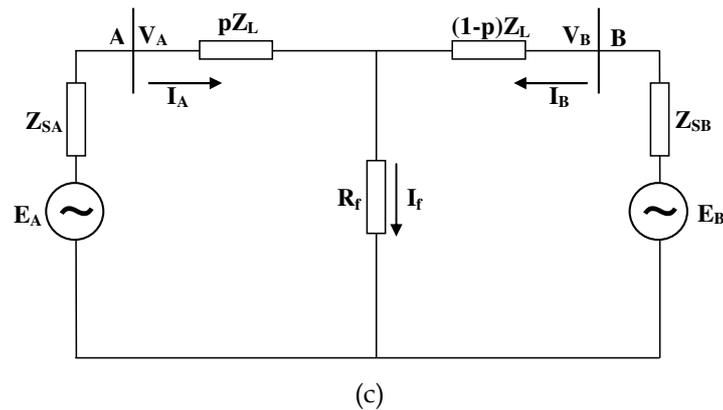
Um algoritmo concebido para utilização em sistemas de transmissão, com aplicação estendida para alimentadores de distribuição, é o desenvolvido por TAKAGI et al (1981, 1982). Os cálculos apresentados são referentes à Figura 3.1.



(a)



(b)



(c)
 Figura 3.1. Equivalente para análise de faltas para o método de Takagi. (a) Circuito pré-falta. (b) Circuito de falta. (c) Circuito pós-falta (Superposição de (a) e (b)) (Adaptado de (TAKAGI et al, 1981)).

Em que:

V_A, V_B - Tensão nos terminais A e B (terminal local e remoto respectivamente).

I_A, I_B - Corrente pós-falta nos terminais A e B.

I_{1dA}, I_{1dB} - Corrente pré-falta nos terminais A e B.

I_{fA}, I_{fB} - Corrente de falta nos terminais A e B. $I_{fi} = I_i - I_{1di}$.

I_{1fA}, I_{1fB} - Componente da corrente de falta em direção aos terminais A e B.

R_f - Resistência de falta.

Z_L - Impedância de surto da linha de transmissão.

Z_{SA}, Z_{SB} - Impedância da fonte nos terminais A e B.

Tomando como referência a Figura 3.1 e o modelo de linha adotado; obtêm-se as expressões que determinam a corrente e tensão de falta, dadas a seguir:

$$V_f = V_A \cosh(\gamma d) - Z_C I_A \sinh(\gamma d), \quad (3.1)$$

$$I_{1fA} = \frac{V_{fA}}{Z_C} \sinh(\gamma d) - I_{fA} \cosh(\gamma d). \quad (3.2)$$

Em que:

γ - Constante de propagação da linha.

Z_C - Impedância característica da linha de transmissão.

Uma alternativa simples para resolução é fazer as seguintes considerações: $\tanh(\gamma d) = \gamma d$ e $\angle I_{1fA} = \angle I_{fA}$. As aproximações são válidas para linhas curtas, cuja

extensão não exceda 100 km. Sendo: $Z_L = \gamma Z_c$, a distância de ocorrência da falta d pode ser encontrada pela seguinte expressão:

$$d = \frac{\text{Im}(V_A I_{fA}^*)}{\text{Im}(Z_L I_A I_{fA}^*)}. \quad (3.3)$$

A expressão (3.3) é uma aproximação eficiente para linhas curtas. Quando o comprimento da linha de transmissão ultrapassa os 100 km, é necessária uma correção na distância de falta, dada por:

$$d_2 = d_1 - \frac{\beta^2 d_1^3}{3}. \quad (3.4)$$

Em que:

d_1 - Distância calculada por (3.3).

d_2 - Distância corrigida.

β - Parte Imaginária de γ .

MORETO (2005) comprovou em seus estudos que o método de TAKAGI et al (1981, 1982) apresenta resultados aceitáveis em faltas francas, mesmo sendo uma adaptação de um método concebido para sistemas de transmissão. Porém, para FAI devidamente modeladas os erros chegam a 60%, inviabilizando qualquer tentativa de aplicação. A consideração da linha sem perdas aplicada no método é crítica, tendo em vista que em sistemas de distribuição a resistência do alimentador não pode ser desprezada. Apesar de alguns resultados desfavoráveis para FAI, há de se enaltecer o método, tendo em vista o pioneirismo de utilização.

Em JENSEN et al (1998) foi apresentado um método para localização de FAI, tendo em vista a escassez de técnicas na época da publicação. Foram utilizados apenas dados simulados no EMTP, a modelagem da FAI limitou-se a apenas uma resistência de 500 Ω , foi utilizado um alimentador relativamente curto (1550 m) sem ramificações modelado como circuito pi. Os dados utilizados foram as tensões e correntes trifásicas, amostradas a 25 kHz, para o posterior cálculo das componentes simétricas. A existência ou não de FAI e seu tempo de início foi determinado pela comparação da corrente de neutro com zero; o que pode causar

falsos positivos para sistemas desbalanceados. Com a falta detectada, foi determinado um vetor incremento de corrente (diferença entre as correntes no pós e pré-falta) a ser aplicado a uma RNA para determinar a localização.

URIARTE (2003) propôs uma modelagem para detecção e localização das FAI, dividindo-as em dois tipos. O primeiro tipo é provocado quando um condutor energizado se parte e cai na terra. A corrente para este tipo de falta geralmente é pequena. O segundo tipo de falta considerado foi quando há contato físico entre o condutor energizado com objetos vizinhos. Para este caso, a corrente de falta pode atingir valores da ordem de 100 A. Escolheu-se o modelo proposto por NAM et al (2001) para as FAI, que não contempla a característica da intermitência. Na Tese, buscou-se adotar um modelo que contemplasse a FAI em todas as suas características. Para o método proposto, utilizou-se basicamente o comportamento da 3ª harmônica da corrente, o que pode não ser confiável na prática devido a característica não-estacionária das FAI verificada na prática.

COSER & ROLIM (2004) utilizaram RNA para localização de faltas, considerando situações para baixas e altas impedâncias. Os dados de entrada eram as componentes de frequência fundamental das formas de onda de tensão e corrente (amplitude e fase), pré e pós-falta. O conceito de baixa e alta impedância se limitou apenas ao valor atribuído ao modelo resistivo, ou seja, o modelo adotado não apresentou nenhuma das características principais de uma FAI. Método similar foi proposto por FANUCCHI et al (2013), com os dados de corrente amostrados a 15360 Hz. O sistema permite a classificação dos eventos em três classes: FAI, Energização de Transformadores e Chaveamento de Bancos de Capacitores. Uma inovação foi o uso das Redes de Função de Base Radial (RBF), que possuem apenas uma camada escondida e uma de saída. O sinal é propagado da entrada para a camada intermediária, que possui uma função de ativação do tipo Gaussiana. Há também a propagação da camada intermediária para a de saída, com uma função de ativação do tipo linear. A modelagem das FAI não considerou as suas características básicas. Os resultados apresentaram uma taxa de acerto alta, porém a metodologia não foi testada com casos reais.

MORETO (2005) propôs um algoritmo de localização de faltas utilizando RNA. O método necessita de uma classificação prévia, tendo em vista que foi treinada uma RNA para faltas fase-fase e outra para faltas fase-terra. Dos sinais analisados, foi extraído um conjunto de características que permitiram a identificação tanto de faltas francas quanto FAI. Os dados de entradas das RNA foram os módulos dos fasores fundamentais de corrente e tensão, da 3ª harmônica de corrente, além das diferenças angulares entre a componente fundamental da tensão e as componentes fundamental e de 3ª harmônica da corrente. As conclusões dos estudos de EMANUEL et al (1990) que balizaram tal decisão. Foram utilizadas apenas simulações, sem incorporação de dados reais à base de dados; o modelo de FAI utilizado foi de EMANUEL et al (1990) sem a utilização de experimentos para ajustes e o alimentador utilizado foi de 14 barras, sem ramificações, com os trechos modelados como circuitos RL em série no ATP. O algoritmo é capaz de determinar o instante inicial de ocorrência, o tipo de falta, assim como estimar sua localização geográfica. A localização da FAI foi possível com precisão aceitável, porém há de se convir que as condições de simulação, dados e modelos utilizados não apresentavam forte caracterização real. Para que os resultados sejam confiáveis, são necessários alguns ajustes nos modelos de carga, falta, alimentadores para provimento de maior aplicabilidade prática.

FLAUZINO (2007) desenvolveu um localizador de FAI utilizando como dados de entrada as tensões e correntes trifásicas, para posterior cálculo das componentes simétricas. Optou-se na Tese pela não adoção das tensões pelo fato das mesmas sofrerem pouquíssimos impactos com a ocorrência das FAI. Há 10 Sistemas Fuzzy para as variadas determinações do diagnóstico: um para a detecção da FAI, um para a identificação do envolvimento de cada fase do sistema trifásico, além de 3 para as estimações das localizações (um em cada fase) mais 3 para estimação da resistência de falta.

SPATTI (2011) desenvolveu um sistema completo de diagnóstico de faltas em sistemas de distribuição, envolvendo as etapas de detecção, identificação da fase e localização. São utilizados para cumprimento dos objetivos os sinais de

tensão e corrente trifásicos, que são pré-processados utilizando-se uma ferramenta estatística denominada Análise por Componentes Principais. Com a técnica, os dados de entrada têm suas dimensões reduzidas, com a conseqüente redução do esforço computacional. Após essa etapa, é aplicada a Transformada de Fourier. Para efetuar as etapas do diagnóstico, são utilizadas Redes Neurais MLP. Os resultados obtidos foram superiores a 97% para detecção e identificação da fase. Vale salientar que o sistema não é exclusivo para FAI, e que as mesmas foram modeladas como resistências. Aliado ao fato da Transformada de Fourier não ser a mais adequada para sinais não-estacionários, o método requer mais testes com sinais reais de FAI. Comparando-se com a Tese desenvolvida, o objetivo de SPATTI não foi determinar o ponto de ocorrência das faltas, mas o ramal no alimentador. Outro fator preocupante é que são utilizados 4 módulos de Redes Neurais para a localização, totalizando mais de 200 RNA treinadas, apresentando um erro médio de 7%.

ALI et al (2012) propuseram um método para localização da seção do alimentador com FAI, utilizando a Transformada *Wavelet* Discreta. A técnica foi testada para um alimentador real de 38 barras. É criado um ranking para cada barra em função da soma dos coeficientes *wavelet* do sinal de tensão para 2 ciclos de falta. A *wavelet* mãe utilizada foi a Daubechies 4, com uma taxa de amostragem de 6,4 kHz. Em relação ao método há algumas ressalvas práticas: o número de ciclos analisados, tendo em vista que as características das FAI estão presentes em até 40 ciclos; o modelo das FAI adotado (resistivo, com valores entre 60 e 100 Ω); os níveis de detalhes dos coeficientes utilizados (1ª, 2ª e 3ª escalas) que talvez mais atrapalhem do que ajudem em função da possibilidade de serem confundidos com ruídos; e finalmente a escolha dos sinais de tensão em detrimento dos de corrente.

SARLAK & SHAHRTASH (2013) propuseram um localizador de FAI a ser fixado nos postes dos sistemas de distribuição de energia elétrica, necessitando de vários pontos de medição. É realizada a identificação e localização das FAI por meio do reconhecimento de padrões do campo magnético medido na vizinhança do condutor energizado, utilizando os sinais de correntes. O processamento e a

classificação do sinal são realizados aplicando-se o gradiente morfológico de multi-resolução e máquina de vetores suporte, respectivamente. A localização fornece a barra na qual se encontra a falta. A metodologia foi testada com dados reais e simulados. Os resultados mostram que o método é capaz de discriminar com sucesso faltas de alta impedância de outros transitórios semelhantes.

BAKAR et al (2014) apresentaram um localizador de FAI utilizando a TWD, em que as informações são extraídas das oscilografias de tensão, medidas na subestação, as quais são comparadas com um banco de dados previamente definido por simulações. Por causa da única medida realizada e múltiplas ramificações, é produzido um conjunto com os possíveis locais da falta. O problema é solucionado aplicando-se uma análise classificatória, gerando uma lista das seções mais prováveis até as menos prováveis. A metodologia foi verificada em um sistema de distribuição real simulado no *software* PSCAD/EMTDC. Considerando-se os resultados obtidos, observa-se a simplicidade da metodologia, uma vez que somente as tensões da subestação principal são utilizadas, tornando possível sua implementação em tempo real. A produção de um conjunto com possíveis locais de falta, ao invés de apenas um, desperta incerteza no método, assim como a não-utilização das correntes de falta.

HOSSAIN et al (2014) também utilizaram as tensões para localizar FAI, modeladas como resistivas. A localização é feita pela comparação das tensões obtidas em vários pontos do alimentador, com um perfil de tensão esperado. A seleção dos perfis e padrões de tensão mais apropriados são realizadas pelo método da Seção Dourada. Na Tabela 3.3 a seguir é apresentada uma síntese do Estado da Arte para a Localização de FAI.

IURINIC et al (2015) desenvolveram equações analíticas para determinação da distância à subestação em função dos parâmetros da falta. Dentre as características, há a corrente apenas de falta, que é estimada pelo método de mínimos quadrados. O modelo adotado foi o de EMANUEL et al (1990), que não contempla a característica da intermitência. Reiterando, na Tese utilizou-se o de SANTOS et al (2011), que contempla todas as propriedades. A metodologia foi

testada para um alimentador relativamente menor (um alimentador do IEEE de 13 barras), apresentando erros de localização entre 9 e 17%.

VIANNA et al (2016) propõem a divisão do alimentador em região, com a posterior localização da área de ocorrência da FAI, a partir da análise da corrente de sequência zero. Foram efetuados testes em um simulador de tempo real, obtendo-se resultados que indicaram sucesso. Como limitações, há o modelo de FAI (resistência ôhmica) e a adoção de um alimentador real para as simulações.

Tabela 3.3. Síntese – Localização de FAI.

Técnicas	Trabalho	Particularidades
Cálculos matemáticos	TAKAGI et al (1981, 1982)	✓ Adaptado de sistemas de transmissão. ✓ Inviável para FAI.
	HOSSAIN et al (2014)	✓ Comparação das tensões de falta com um perfil padrão. ✓ Método da Seção Dourada.
RNA	JENSEN et al (1998)	✓ Diferença entre as correntes no pré e pós-falta. ✓ FAI – resistência de valor elevado.
	COSER & ROLIM (2004)	✓ Fundamental da tensão e corrente no pré e pós-falta. ✓ Nenhuma alusão às características das FAI.
	MORETO (2005)	✓ Fundamental e harmônicos de tensão e corrente (amplitude e fase). ✓ RNA para faltas fase-fase e fase-terra. ✓ Falta de detalhes práticos nas modelagens.
	SPATTI (2011)	✓ Transformada de Fourier das tensões e correntes. ✓ Erro médio de 7%.
	FANUCCHI et al (2013)	✓ Eventos: FAI, Energização de Transformadores e Chaveamento de Bancos de Capacitores. ✓ Utilização das Redes de Função de Base Radial.
Harmônicos	URIARTE (2003)	✓ 3ª harmônica da corrente. ✓ Não contempla a característica não-estacionária das FAI.
Lógica Fuzzy	FLAUZINO (2007)	✓ Tensões e correntes – Componentes simétricas. ✓ 10 Sistemas Fuzzy – identificar o envolvimento de cada fase do sistema e outros detalhes.
TW	ALI et al (2012)	✓ Ranking para cada barra em função da soma dos CW da tensão. ✓ 1ª, 2ª e 3ª escalas.
	BAKAR et al (2014)	✓ Comparação da TW da tensão com um banco de dados. ✓ Lista com possíveis locais de falta.
Campo Magnético	SARLAK & SHAHRTASH (2013)	✓ Sinais de corrente. ✓ Vários pontos de medição.

Fonte: Próprio Autor.

3.3 Ensaios Experimentais com as FAI

Uma característica importante do trabalho é o respaldo e aplicabilidade prática. Foram realizados ensaios para coleta de dados reais que subsidiaram a modelagem, detecção e localização das FAI, em um alimentador em pleno funcionamento (com todas as suas cargas). Além das dificuldades relatadas na modelagem, detecção e localização das FAI, notam-se também os obstáculos para a construção de uma base de dados prática mais volumosa. Para se obter 1000 sinais, por exemplo, seriam necessários dias e até meses de exaustivos ensaios com o alimentador fora de operação; ou através da obtenção de dados oscilográficos dos registradores das subestações.

EMANUEL et al (1990) implementaram um arranjo experimental para observação de FAI em um solo arenoso. Conectou-se um condutor em série com um fusível de 10 A (conectado a uma das fases apenas) no final de um alimentador de 13,8 kV e aproximadamente 6 km de extensão. Como citado anteriormente, seu objetivo era a avaliação da influência dos harmônicos das correntes nas características das FAI. O modelo desenvolvido no trabalho foi uma consequência dos resultados.

CHRISTIE et al (1993) também trabalharam com dados experimentais no trabalho para detecção de FAI, porém os ensaios foram realizados em laboratório. O aparato experimental consistiu de uma bacia de plástico, contendo uma camada de 10 cm de areia sobre um plano de cobre (para emular o efeito da terra). Sobre esse aparato um cabo energizado era derrubado. A tensão aplicada variou na faixa de 100-600 V, tendo sido colocada uma carga de 40 Ω em paralelo com o arranjo. Não foi observada a presença de corrente com a areia seca. À medida que se molhava o solo, surgia uma corrente em torno de 200 mA (valor RMS). Observou-se um efeito: à medida que a corrente de falta crescia, o solo tornava-se mais seco; provocando diminuição da corrente.

NAM et al (2001) também realizaram experimentos para ajuste do modelo proposto. Escolheu-se um alimentador de uma companhia sul-coreana de 22,9 kV,

10 km de extensão e 100 MVA de capacidade. Para aquisição dos dados utilizaram uma frequência de amostragem de 10 kHz. O arranjo experimental foi conectado ao final do alimentador, foram utilizadas a brita e concreto como superfícies e as medições foram realizadas no ramo de ocorrência da falta.

No trabalho de SEDIGHI et al (2005), dados reais foram obtidos a partir de experimentos realizados em um alimentador real no Irã de 20 kV e 19,5 km de extensão, porém sem cargas instaladas. A frequência de amostragem foi de 24,67 kHz. Sete tipos de superfície foram utilizados: asfalto, cimento e solo molhados ou secos e uma árvore; em duas localizações distintas. Três testes foram realizados em cada tipo de superfície numa determinada localização, chegando-se ao total de 42 sinais de correntes.

SOLÍS et al (2007) realizaram vários ensaios em laboratório para complementarem uma base de dados reais cedidos pela *Comisión Federal de Electricidad*, do México. Os experimentos foram realizados com tensão de 13,8 kV, colocando-se um cabo energizado com as superfícies utilizadas: concreto, grama e terra. Os dados foram coletados com uma frequência de amostragem de 1920 Hz, para depois efetuar-se uma filtragem passa-baixas para redução dos ruídos. As medições foram obtidas através de um relé de sobrecorrente instalado próximo ao local da falta.

DAS & BAYOUMI (2007) e ELKALASHY et al (2007) também realizaram ensaios para validação de suas técnicas.

Capítulo 4

Metodologia Desenvolvida

Após a discussão dos assuntos que fundamentaram a Tese, assim como um relato do que já foi desenvolvido na área; serão apresentados inicialmente no Capítulo 4 os localizadores de FAI propostos (local e setor). Como etapa posterior, serão discutidas as atividades meio para se atingir os objetivos. Toda etapa do pré-processamento será destacada, incluindo as modelagens do alimentador, construção das bases de dados e configuração das RNA. Será discutido todo procedimento experimental para levantamento das características das faltas para algumas superfícies, objetivando a modelagem das FAI. Serão evidenciadas as vantagens do processo assim como as limitações de ordem prática.

4.1 Localizadores Propostos

O sistema proposto para determinação do local da FAI está esquematizado na Figura 4.1 a seguir.

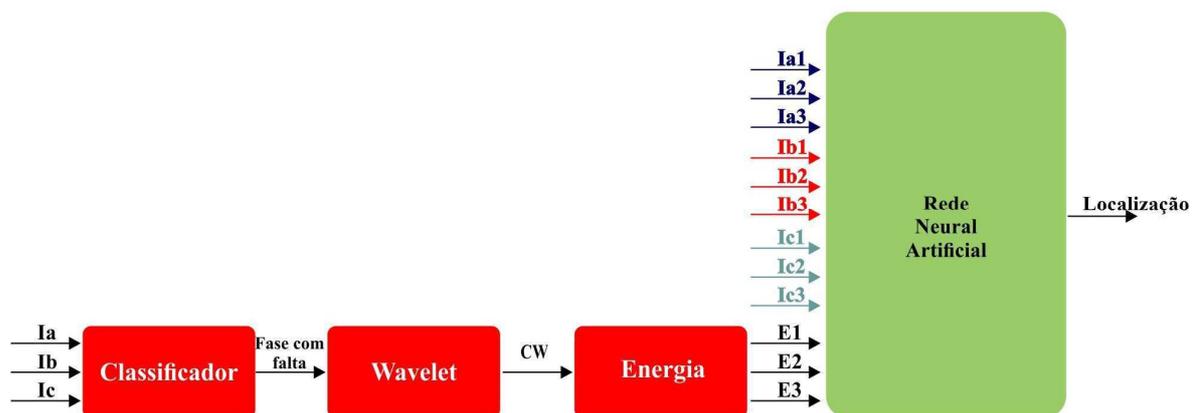


Figura 4.1. Localizador de FAI (Fonte: Próprio Autor).

A localização será provida por uma RNA com 12 entradas e uma saída (que indicará o local de ocorrência). Dessa forma, em qualquer teste ou implementação, a RNA deverá ter a configuração: 12-X-1, em que X é o número de neurônios nas camadas ocultas. Para determinação da melhor configuração, treinamentos são efetuados com a modificação no número de neurônios e a posterior verificação do percentual de acertos.

Para que o localizador funcione, é necessário que se identifique a fase que está submetida a uma FAI. Assim, há a necessidade de um classificador para determiná-la. Não foi escopo da Tese o desenvolvimento do classificador, de modo que em todas as simulações das FAI ocorreram na fase A. O bloco foi inserido para melhor compreensão da metodologia. Toda a etapa de processamento para determinação da distância e setor é realizada a partir dos dados completos obtidos dos registros, ou seja, é um sistema para funcionamento *off-line*, pois o tempo de processamento é relativamente maior que o necessário para atuação da proteção.

Conforme os estudos de COSTA (2010), a energia dos coeficientes *wavelet* fornecem fortes indicadores para caracterização e diagnósticos de distúrbios em sistemas de potência. É importante dispor dos dados das correntes não apenas da fase com falta, mas também das outras fases do sistema, pois assim tem-se uma ideia do carregamento e indiretamente, da localização. Formando o vetor de entrada da RNA, adotou-se também a energia dos CW da corrente da fase com falta., que fornecem informações relevantes sobre os transitórios ocorridos.

Das 12 entradas da RNA, 9 são de amostras das correntes (3 de cada fase). Essas amostras são sequenciais, obtidas a partir do registro. Por exemplo, amostras 11, 12 e 13. Como será explicado adiante, previamente haverá um processo de janelamento das amostras para treinamento das RNA. As outras 3 entradas do localizador são amostras da energia dos CW da corrente com FAI. A energia será calculada **apenas** para uma das fases (com falta). Para esse propósito, há um bloco *Wavelet*, em que se escolhe a *wavelet* mãe a ser aplicada aos sinais de corrente. Nota-se que apenas os coeficientes de detalhes são utilizados, porque constituem a metade superior da banda de frequência (faixa em que se encontram os transitórios). A partir dos CW é determinada a energia dos transitórios da FAI.

Na Tabela 4.1 a seguir é apresentada uma síntese da localização em função das variáveis utilizadas.

Tabela 4.1. Síntese da Localização.

Corrente de Carga	Energia Wavelet	Localização
Baixa	Baixa	Inconclusiva
Baixa	Alta	Início do Alimentador
Alta	Baixa	Final do Alimentador
Alta	Alta	Inconclusiva

Fonte: Próprio Autor.

Explicando-se a Tabela 4.1, tem-se que as situações ditas como inconclusivas não significam impossíveis. São situações em que a localização será fornecida pela RNA, que através da capacidade de generalização adquirida no treinamento irá analisar as variáveis de entrada e determinar um local. As situações em que se torna mais fácil estimar grosseiramente uma localização estão

nas segunda e terceira linhas da Tabela. Para uma corrente de carga relativamente baixa, se a energia dos transitórios da corrente de falta vista na subestação é relativamente alta, significa que houve pouco amortecimento dos transitórios ao longo do alimentador. Dessa forma, pode-se concluir que o ponto de falta está no início do alimentador, próximo à subestação. Situação dual ocorre para uma situação em que há uma corrente de carga elevada, com a energia dos respectivos transitórios da corrente da FAI relativamente baixa. Isso significa que houve amortecimento dos transitórios ao longo do alimentador, configurando-se em faltas distantes da subestação. As afirmações da Tabela 4.1 apenas podem ser feitas para eventos que foram detectados como FAI.

Na Figura 4.2 a seguir é apresentado o localizador de seção proposto, utilizando uma SOM.

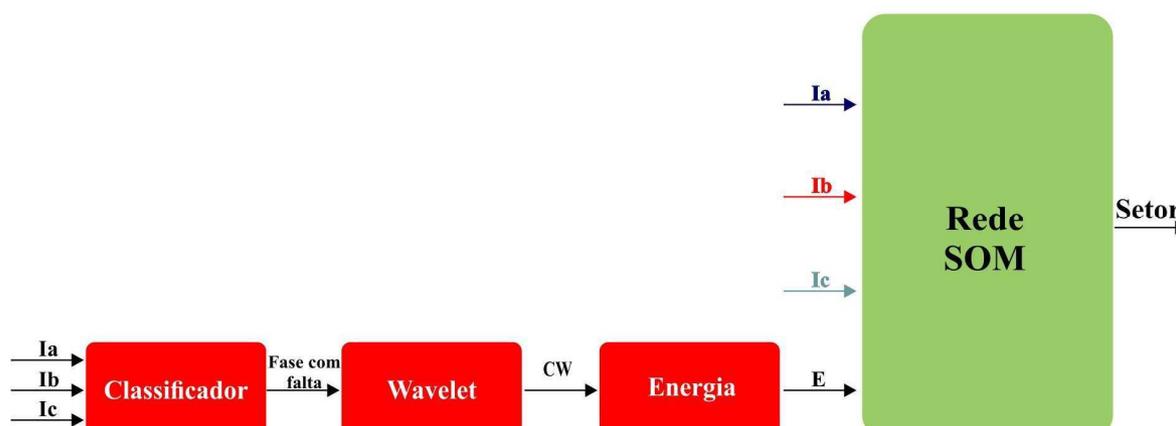


Figura 4.2. Localizador de seção do alimentador (Fonte: Próprio Autor).

Para se localizar a seção do alimentador, é utilizada uma estrutura mais simples que a apresentada na Figura 4.1. Conforme exposto no Capítulo 2, a SOM não apresenta camada de saída. Os vetores das grandezas envolvidas (correntes nas três fases e energia) são diretamente apresentados à grade construída. Como diferença em relação à estrutura anterior, não houve o processo de janelamento da base de dados. No treinamento, a cada instante de amostragem, são apresentadas as amostras com os respectivos resultados esperados (denominados rótulos) para prover o processo de clusterização.

4.2 Modelagem do Alimentador Utilizado

Para realização das simulações, foi modelado no ATP o alimentador correspondente ao local de realização dos ensaios de campo; denominado Boa Vista (21L3), localizado na cidade de mesmo nome. A disposição física dos condutores das fases na cruzeta do alimentador utilizada para obtenção dos parâmetros está ilustrada na Figura 4.3. A estrutura dos postes está ilustrada na Figura 4.4. É relevante ressaltar que se procurou minimizar o desequilíbrio entre as correntes nas fases, em função de não estarem regularmente espaçadas na cruzeta, dispondo os condutores formando o espaçamento equilátero equivalente. Para cálculo da distância entre os vértices, e por consequência, entre as fases utilizou-se a raiz cúbica do produto entre a distância entre as fases. Dessa forma, as tensões e correntes ficam os mais equilibrados possíveis, sem comprometer a eficiência das simulações.

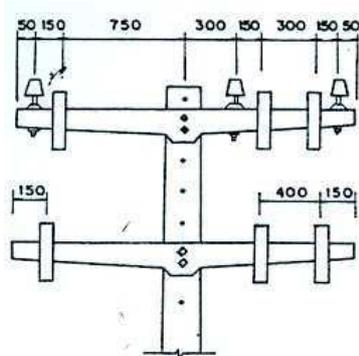


Figura 4.3. Disposição física dos condutores das fases do alimentador (UFCCG, 2010).

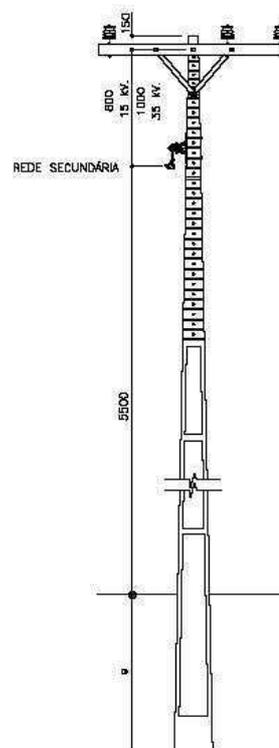


Figura 4.4. Estrutura dos postes (UFCCG, 2010).

O diagrama unifilar do alimentador Boa Vista é apresentado na Figura 4.5, e na Tabela 4.2 estão relacionados os tipos de cabos que compõem o alimentador (com seus parâmetros). Na Tabela 4.3 podem ser encontrados os comprimentos dos trechos e na Tabela 4.4 estão os cabos e as cargas instaladas. Seu comprimento acumulado é de aproximadamente 32 km.

Foram fornecidos pela Energisa os dados do alimentador geo-referenciado, assim como as cargas distribuídas ao longo dos transformadores. Foi necessário um pré-processamento, agrupando as cargas distribuídas ao longo do alimentador em 90 barras, com a intenção de se obter uma modelagem mais eficiente, procurando concentrar cargas em vários pontos. Há de se ressaltar, que com a simplificação obtida com a adoção de 90 barras não há comprometimento dos resultados. O fato é explicado porque cargas de pontos bastante próximas ao longo do alimentador foram concentradas em uma única barra.

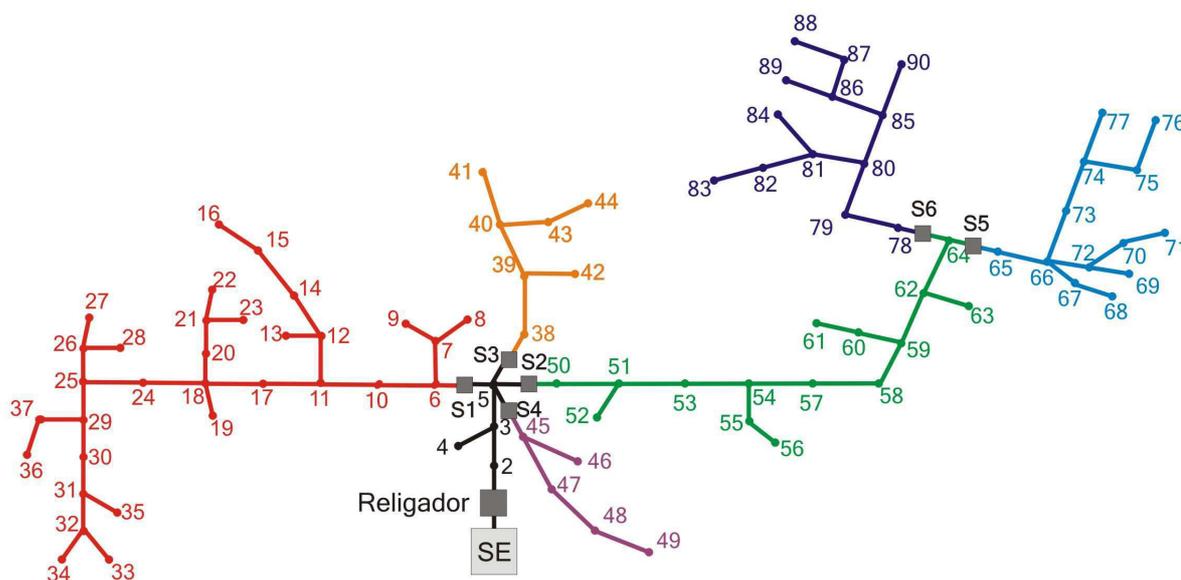


Figura 4.5. Diagrama unifilar do alimentador Boa Vista (UFCEG, 2010).

Tabela 4.2. Parâmetros dos cabos utilizados.

Número	Cabo	Resistência(Ω/km)	Reatância(Ω/km)	Diâmetro(cm)
0	336,4 - MC	0,1696	0,3766	1,883
1	4/0 - CAA	0,27408	1,452427	1,431
2	4 - CA	1,35705	0,4705	0,635

Fonte: (UFCEG, 2010).

Tabela 4.3. Comprimentos dos trechos do alimentador Boa Vista.

DE	PARA	Comprimento (m)	DE	PARA	Comprimento (m)
SE BVA	1	430	45	46	600
1	2	430	45	47	2000
2	3	900	47	48	2000
3	4	1900	48	49	2400
3	5	1500	5	50	1300
5	6	1000	50	51	1500
6	7	2000	51	52	1200
7	8	1000	52	54	1200
7	9	1000	54	55	1000
6	10	1500	55	56	1000
10	11	1500	54	57	2000
11	12	1500	57	58	2000
12	13	1500	58	59	1200
12	14	1800	59	60	2000
14	15	1800	60	61	2000
15	16	2000	59	62	1100
11	17	1700	62	63	2500
17	18	1700	62	64	1100
18	19	2000	64	65	2000
18	20	1500	65	66	2000
20	21	1500	66	67	1400
21	22	1000	67	68	1400
21	23	1200	72	69	1200
18	24	1300	72	70	1800
24	25	1200	70	71	1800
25	26	1000	66	72	1200
26	27	500	66	73	2500
26	28	600	73	74	2500
25	29	1300	74	75	2000
29	30	1500	75	76	2500
30	31	1500	74	77	2100
31	32	1200	64	78	2000
32	33	1000	78	79	2000
32	34	1000	79	80	2300
31	35	1100	80	81	1500
37	36	1500	81	82	2000
29	37	1500	82	83	2000
5	38	2000	81	84	1500
38	39	1500	80	85	2400
39	40	1000	85	86	3000
40	41	1600	86	87	1600
39	42	1200	87	88	3000
40	43	1100	86	89	1200
43	44	1000	85	90	2000
5	45	2000	45	46	600

Fonte: (UFCG, 2010).

Tabela 4.4. Cargas instaladas no alimentador Boa Vista.

BARRA	Carga (kVA)	BARRA	Carga (kVA)
1	0	46	20
2	0	47	15
3	75	48	25
4	285	49	15
5	502,5	50	1245
6	35	51	150
7	10	52	20
8	15	53	0
9	30	54	0
10	15	55	10
11	30	56	5
12	5	57	0
13	10	58	0
14	10	59	20
15	10	60	80
16	20	61	315
17	30	62	35
18	15	63	45
19	40	64	30
20	15	65	60
21	15	66	45
22	35	67	25
23	30	68	5
24	30	69	10
25	15	70	15
26	15	71	25
27	15	72	10
28	5	73	25
29	60	74	25
30	10	75	15
31	10	76	25
32	15	77	25
33	15	78	100
34	5	79	20
35	15	80	90
36	35	81	5
37	15	82	15
38	360	83	15
39	0	84	75
40	0	85	30
41	55	86	10
42	20	87	25
43	20	88	5
44	15	89	5
45	45	90	5

Fonte: (UFCG, 2010).

A modelagem do sistema foi realizada considerando:

- Linhas trifásicas a parâmetros distribuídos e constantes com a frequência.
- Trechos compostos pelo cabo 4-CA (Tabela 4.1).
- Fator *skin* para os cabos de 0,33.
- Resistividade da terra de 150 Ω .m.
- Modelo de impedância constante para as cargas (circuito RL).
- Religador e chaves seccionadoras como chaves simples.
- As chaves seccionadoras inseridas têm as seguintes características:
 - Chave S_1 - Entre as barras 5 e 6;
 - Chave S_2 - Entre as barras 5 e 50;
 - Chave S_3 - Entre as barras 5 e 38;
 - Chave S_4 - Entre as barras 5 e 45;
 - Chave S_5 - Entre as barras 64 e 65;
 - Chave S_6 - Entre as barras 64 e 78.
- Cargas conectadas entre cada fase de cada barra e a terra.
- Fator de potência médio de 0,955.
- Configuração do alimentador para obtenção dos parâmetros conforme Figuras 4.3 e 4.4 e Tabelas 4.2 e 4.3.

4.3 Modelagem das FAI

Para obtenção de um modelo adequado para estudo das FAI, é necessário um estudo detalhado de suas características. Para ser mais completo, o modelo deve conter informações sobre a influência do surgimento do arco elétrico no ponto da falta. Os indícios do estado da arte são na direção que a maioria das pesquisas se baseia nos modelos que usam diodos ou associação de impedâncias não-lineares. O modelo desenvolvido deve contemplar as propriedades elencadas no Capítulo 2: não-linearidade, assimetria, *buildup*, *shoulder* e intermitência.

Para determinação do modelo, foram realizados ensaios de campo com a provocação de FAI, relatados a seguir. Não se constituiu escopo do trabalho o desenvolvimento do modelo, porém o mesmo foi concebido com os dados colhidos para a presente Tese. O Projeto de P&D no qual estava inserida a Tese, também teve outras frentes de trabalho: detecção das FAI em tempo real e o desenvolvimento de um modelo fiel às características da região.

4.3.1 Panorama

Decidiu-se pela realização dos ensaios experimentais após o convencimento que dados da literatura, características VxI, equações prontas não seriam adequadas ao propósito; tendo em vista as diferentes realidades técnicas e geográficas dos locais.

Vale salientar que até a realização dos ensaios, se dispunha apenas de materiais bibliográficos elencados no Capítulo 3.3, com a descrição de etapas a serem cumpridas em campo. Tratam-se de ensaios realizados em diferentes condições, com diferentes alimentadores em diferentes regiões (alguns realizados em laboratório). Assim, o planejamento inicial de obtenção dos dados para modelagem foi atingido após a realização de quatro ensaios. Esta etapa foi de notável importância, contribuindo de forma decisiva na compreensão do fenômeno, no aperfeiçoamento dos procedimentos experimentais e na habilitação da equipe na execução desse tipo de experimento. Dispenderam-se 6 meses no planejamento e execução das tentativas. Os testes foram realizados em seis tipos de superfícies. Pequenas áreas dispostas paralelamente e revestidas de grama, calçamento de concreto, asfalto, areia grossa, além da terra nua e arbusto foram empregados para a ocorrência de faltas monofásicas. A seguir os ensaios estão sintetizados.

1º Ensaio

- Realizado em Campina Grande em um alimentador urbano.
- Alimentador com alta capacidade de curto-circuito.
- Transtornos à população (por exemplo, em determinados instantes durante os ensaios um shopping ficou sem energia elétrica).
- Inexperiência da equipe nesse tipo de ensaio prejudicou o seu êxito.

2º Ensaio

- Realizado em uma fazenda localizada cerca de 10 km da subestação da cidade de Boa Vista-PB (distante 38 km de Campina Grande), assim como o 3º e 4º ensaios.
- Alimentador rural com baixa capacidade de curto-circuito. Caso houvesse algum imprevisto, poucos clientes seriam afetados.
- Problema relativo ao gatilhamento do sistema de aquisição de dados. A grandeza escolhida foi a corrente. Assim, a gravação dos dados só era realizada quando a corrente estivesse acima de determinado nível, escolhido acima dos ruídos e interferências existentes nas medições. Entretanto, em determinados momentos a corrente de curto foi da ordem de grandeza do ruído, fazendo com que o sistema de aquisição ignorasse o sinal.
- Realização de vários testes aleatórios em tempos variados (não obedecendo uniformidade temporal no início, duração e intervalo entre ensaios consecutivos), o que dificultou a análise e caracterização dos resultados obtidos.

3º Ensaio

- Sequências rígidas de teste com intervalos de tempo bem definidos.
- Utilização de dois RDP para aquisição dos dados: um na subestação e outro no local dos ensaios.
 - O RDP da subestação para capturar o nível de atenuação dos transitórios causados devido à distância de monitoramento. Sua localização está em consonância com as técnicas propostas (que utilizam apenas dados da subestação).
 - O RDP do local dos ensaios teve como objetivo obter as tensões e correntes do evento, para posteriormente, identificar o comportamento das FAI e desenvolver um modelo mais preciso.
- Os registros gravados no ponto de ocorrência não forneceram elementos que pudessem caracterizar bem as faltas. As correntes observadas foram da ordem de grandeza dos ruídos.

4º Ensaio

- Superfícies foram molhadas, com as primeiras faltas sendo provocadas no asfalto (superfície de maior resistência).
- Mudança do RDP remoto para um local mais próximo da falta que a subestação.

Como consideração final a respeito das baterias de ensaios, é necessário dizer que os procedimentos que se mostraram acertados e satisfatórios nos ensaios anteriores foram mantidos para os seguintes.

4.3.2 Procedimento Experimental

Como exposto anteriormente, o alimentador BVA 21L3 foi escolhido em virtude de a resistência acumulada da subestação ao local da falta ter um valor considerável, evitando-se a ocorrência de uma falta franca indesejada. A análise do solo da fazenda revelou uma elevada resistividade, confirmando a característica

física do solo do local. O valor obtido, seguindo o modelo desenvolvido por ENDRENYI (1963) foi de $25,62 \Omega \cdot m$ na primeira camada, de profundidade até 2,16 m. A resistividade da segunda camada (infinita) foi de $143,47 \Omega \cdot m$. A resistência acumulada do condutor é aproximadamente 20Ω e as faltas francas esperadas para esse ponto são de 284 A. Na Figura 4.6 está ilustrada a disposição geográfica do alimentador BVA 21L3, com o local dos ensaios.

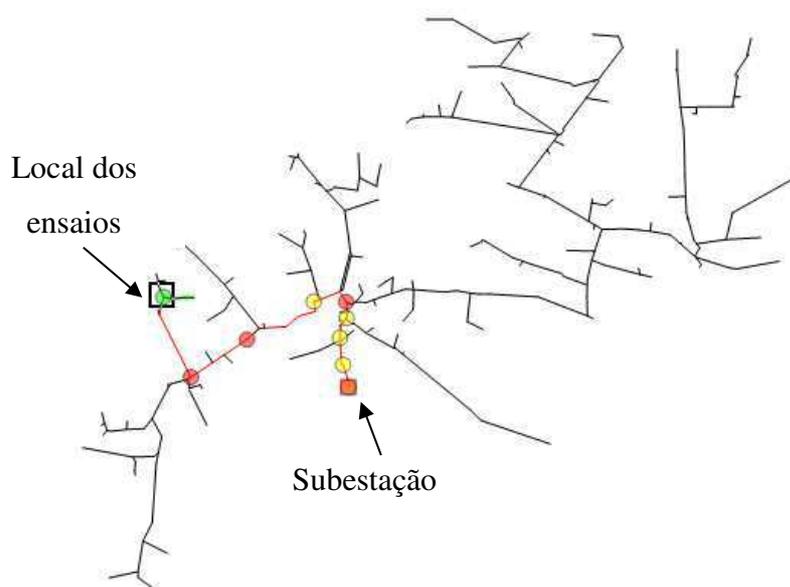


Figura 4.6. Alimentador BVA 21L3 (UFCCG, 2010).

O *layout* do ensaio é verificado na Figura 4.7 (UFCCG, 2010). A hipótese inicial seria alocar um RDP fixo no ponto 05, com o outro variando entre os pontos 01 a 04. Entretanto, devido às dificuldades de ordem técnica e operacional, decidiu-se por instalar o medidor remoto apenas nos pontos 02 e 04. O ponto 02 estava a cerca de 1 km do local do ensaio (ponto 01), enquanto que o ponto 04 estava a aproximadamente 11 km. O RDP instalado no local do ensaio foi conectado a um transformador de potencial (TP) e um transformador de corrente (TC) para medição dos sinais.

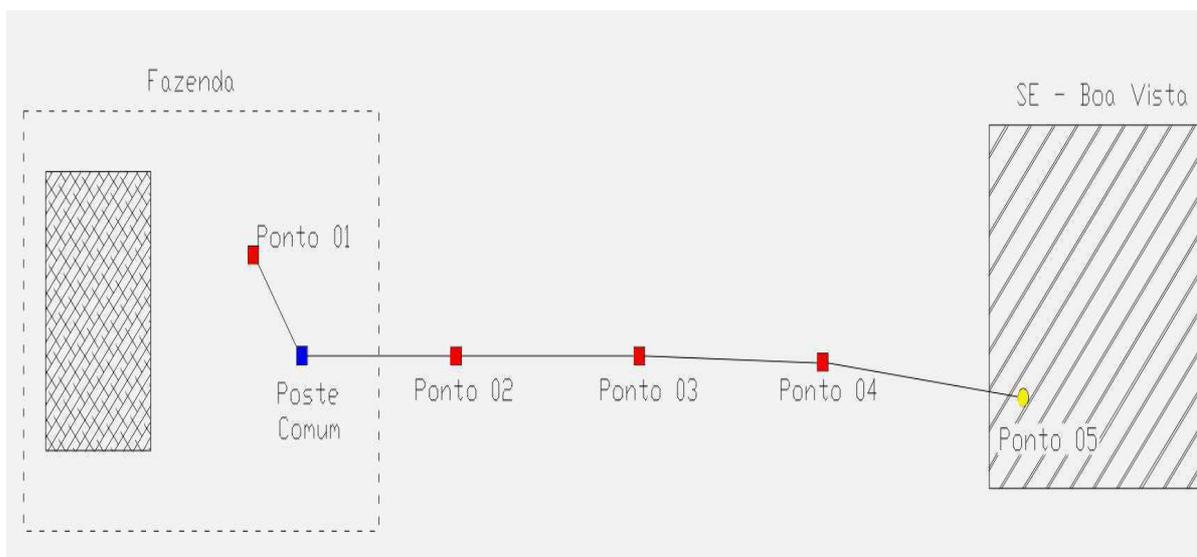


Figura 4.7. *Layout* do último ensaio (UFCCG, 2010).

Na Figura 4.8 está o *layout* esquemático da estrutura experimental montada. É possível visualizar o poste de transição de dois metros implantado próximo às superfícies de contato, no qual foram instalados TP e o TC. São também evidenciadas as superfícies de contato, o andaime (plataforma isolante) para o técnico manipular o cabo energizado e o abrigo do ponto de medição. Na Figura 4.9 tem-se uma fotografia do arranjo experimental.



Figura 4.8. *Layout* da estrutura montada (Adaptado de (UFCCG, 2010)).



Figura 4.9. Superfícies de contato para realização dos ensaios (Fonte: Próprio Autor).

Um cabo energizado com 13,8 kV vindo de um poste comum foi conectado a um dos isoladores do poste de transição. A outra extremidade do cabo foi conectada a um isolador em série com uma vara de manobra, que foi manipulada pelo técnico em linha viva (Figura 4.10). Maiores detalhes dos ensaios podem ser vistos na Figura 4.11, o abrigo do ponto remoto de medição e na Figura 4.12 a ocorrência de uma FAI na grama.



Figura 4.10. Técnico manobrando o condutor (Fonte: Próprio Autor).



Figura 4.11. Visão geral da estrutura de abrigo no ponto de medição remoto (UFCCG, 2010).



Figura 4.12. FAI ocorrendo na grama (Fonte: Próprio Autor).

Um detalhe de grande importância na realização dos ensaios foi o RDP utilizado: o RPV-304 da Reason Tecnologia, visto na Figura 4.13. Dentre as principais características, podem ser citadas as 16 entradas analógicas e 64 digitais, a frequência de amostragem de 15360 Hz e a banda passante de 0 a 3 kHz. Nota-se que grande parte dos transitórios não é possível de ser medida com a frequência de amostragem utilizada (conforme o Critério de Nyquist, poder-se-iam detectar transitórios até 7680 Hz).



Figura 4.13. Registrador RPV-304. (a) Vista Frontal. (b) Vista Superior (UFCEG, 2010).

Após a instalação do RDP, realizou-se sua configuração de forma a possibilitar a medição, gravação e visualização dos eventos gerados nos ensaios. Sintetizando, os passos experimentais seguidos foram os seguintes:

- Isolamento e sinalização da área do ensaio com fitas e cones, visando evitar o trânsito de pessoas e animais no momento da FAI.
- Instalação de um elo fusível 1H no poste comum, de onde se derivou a fase submetida ao curto. Como o fusível 1H possui um tempo de atuação bastante curto, mesmo para correntes relativamente pequenas, esperava-se evitar níveis elevados de corrente de curto-circuito e assim, proteger o resto do sistema elétrico conectado àquele ramal.
- Posicionamento do andaime e eletricitista em frente à superfície para que o contato do cabo se desse da forma mais uniforme possível. Com o eletricitista devidamente posicionado e com cabo suspenso através do bastão isolante, foi dado o comando para fechamento do elo fusível e conseqüentemente, energizar o cabo de alta tensão.
- Configuração final e sincronização dos RDP utilizados.

- Comando para o gatilho dos RDP e para a aproximação e contato do cabo energizado com a superfície, por período de aproximadamente 30 s. Caso o elo fusível não rompesse nesse período, o cabo era afastado da superfície para extinguir a FAI.
- Após a extinção da FAI, os dados obtidos foram submetidos a uma análise prévia de conformidade, com o objetivo de garantir a significância dos resultados. Após a análise, repetiu-se o teste pelo menos, cinco vezes com a finalidade de garantir a consistência dos resultados.

Após a realização do quarto ensaio, os objetivos previamente planejados foram atingidos: a aquisição de dados de tensão e corrente para modelagem das FAI para cada superfície (RDP local), e para teste das metodologias de detecção e localização (RDP remoto).

4.3.3 Modelo de FAI Adotado

O modelo adotado para as simulações foi o de SANTOS (2011), desenvolvido com os mesmos dados utilizados na Tese. Foi uma das etapas do Projeto de Pesquisa e Desenvolvimento intitulado “Sistema de Detecção e Localização de Falhas de Alta Impedância em Redes de Distribuição” desenvolvido pelo Grupo Energisa/PB com a UFCG. O objetivo de SANTOS (2011) foi a obtenção de um modelo que além de representar a característica da intermitência (não representadas na maioria dos modelos), também pudesse ser adequado à realidade dos sistemas operados na região (e todas suas características de superfície, como resistividade e umidade do solo, dos arbustos, temperatura, dentre outros).

São utilizadas no modelo proposto duas resistências variantes no tempo (RVT), em série e controladas pela TACS no ATP, além de uma chave simples controlada pela TACS (CSCT), que foi acrescida de forma a dar início e simular a descontinuidade da corrente de falta (Figura 4.14).

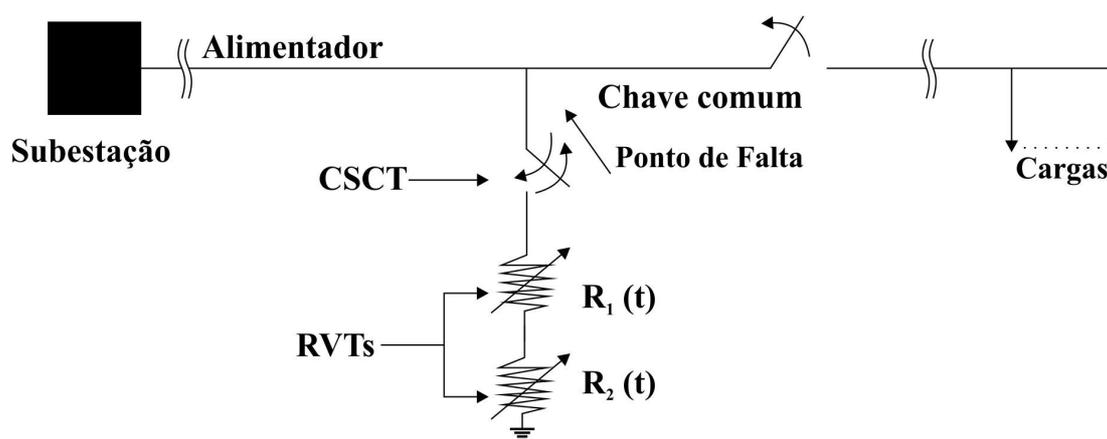


Figura 4.14. Modelo proposto por SANTOS (2011).

A resistência $R_1(t)$ representa as características de não-linearidade e assimetria da FAI, atuando nos regimes transitório e permanente; enquanto que $R_2(t)$ representa os fenômenos de *buildup* e *shoulder*.

Para ajustar os parâmetros do modelo, formas de onda reais das tensões e correntes obtidas no local de aplicação de falta dos ensaios de campo foram utilizadas. Dentre as oscilografias obtidas nos ensaios em cada solo, apenas uma foi escolhida como referência para ser usada na parametrização do modelo computacional daquela superfície de contato (SANTOS, 2011).

O modelo foi o escolhido para as simulações do trabalho por ter sido construído no desenvolvimento de um projeto em que o trabalho de localização de FAI estava inserido. Pesou também na escolha o fato de representar fielmente as características das superfícies e do sistema utilizado nas simulações.

Os valores de R_1 e R_2 foram ajustados considerando apenas valores correspondentes a um ciclo do regime permanente na condição de FAI. Além disso, para simplificar a implementação do modelo no ATP, apenas 32 amostras do ciclo selecionado foram consideradas. A corrente correspondente a uma tensão no intervalo de falta foi calculada conforme equação:

$$i(t) = \begin{cases} i_n + \frac{i_{n+1} - i_n}{v_{n+1} - v_n} \cdot \Delta v, & v_n < v(t) < v_{n+1} \\ i_n, & v(t) = v_n \end{cases} \quad (4.1)$$

Sendo: $\Delta v = v(t) - v_n$; v_n e i_n são a tensão e a corrente da curva característica na amostra n , respectivamente.

O valor de R_1 foi estimado conforme equação (SANTOS et al, 2011):

$$R_1(t) = \frac{v(t)}{i(t)} = \frac{v(t)}{i_n + \frac{i_{n+1} - i_n}{v_{n+1} - v_n} \cdot (v(t) - v_n)} \quad (4.2)$$

O valor de R_2 foi calculado considerando apenas o valor absoluto máximo da tensão e corrente. O processo é ilustrado na Figura 4.15 e descrito a seguir:

- Obtenção da resistência total $R(\tau_k)$, dividindo $v(\tau_k)$ por $i(\tau_k)$.
- Obtenção de $R_2(\tau_k)$ subtraindo $R_1(\tau_k)$ de $R(\tau_k)$.
- Obter $R_2(t)$ usando o método dos mínimos quadrados para uma regressão polinomial, utilizando um polinômio do tipo: $a_8t^8 + a_7t^7 + a_6t^6 + a_5t^5 + a_4t^4 + a_3t^3 + a_2t^2 + a_1t + a_0$.

Sendo τ_k o instante em que a tensão e a corrente alcançam seus valores máximos, no k -ésimo semiciclo.

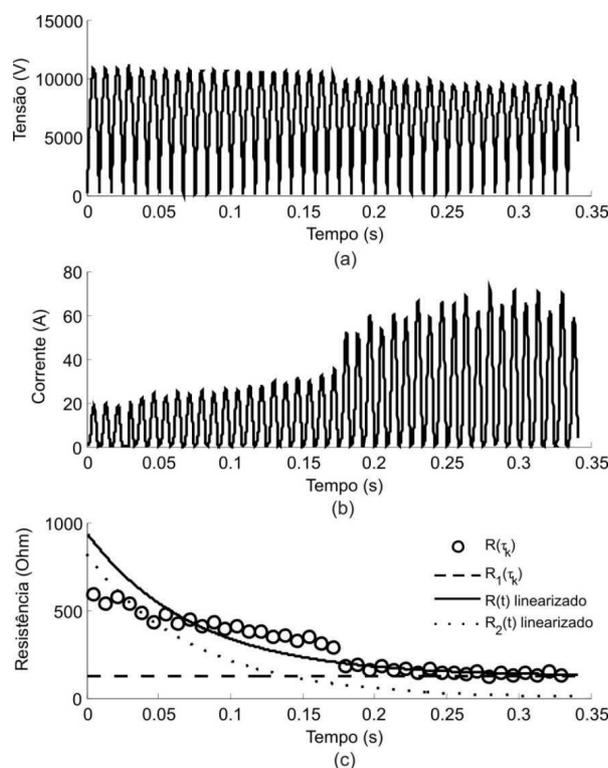


Figura 4.15. Processo de cálculo de: (a) Valor absoluto da tensão referente a FAI; (b) Valor absoluto da corrente referente a FAI; (c) Valor da resistência em relação ao tempo. (SANTOS, 2011).

Os valores de $R_2(t)$ obtidos, que foram utilizados nas simulações do presente trabalho estão na Tabela 4.5:

Tabela 4.5. Representação de $R_2(t)$ para as diversas superfícies.

	Areia	Asfalto	Brita	Calçamento	Grama	Terra
a_8	$6,91.10^{11}$	$3,05.10^{12}$	$7,08.10^7$	$4,75.10^9$	$3,63.10^{10}$	0
a_7	$-5,77.10^{11}$	$-2,86.10^{12}$	$-1,71.10^8$	$-7,95.10^9$	$-3,34.10^{10}$	0
a_6	$2,01.10^{11}$	$1,12.10^{12}$	$1,70.10^8$	$5,30.10^9$	$1,28.10^{10}$	0
a_5	$-3,79.10^{10}$	$-2,27.10^{11}$	$-9,12.10^7$	$-1,84.10^9$	$-2,61.10^9$	$-3,17.10^6$
a_4	$4,14.10^9$	$2,92.10^{10}$	$2,84.10^7$	$3,63.10^8$	$3,09.10^8$	$2,75.10^6$
a_3	$-2,65.10^8$	$-2,11.10^9$	$-5,25.10^6$	$-4,06.10^7$	$-2,13.10^7$	$-8,32.10^5$
a_2	$9,45.10^6$	$8,49.10^7$	$5,65.10^5$	$2,47.10^6$	$8,27.10^5$	$1,05.10^5$
a_1	$-1,74.10^5$	$-1,71.10^6$	$-3,35.10^4$	$-7,75.10^4$	$-1,72.10^4$	$-6,89.10^3$
a_0	$1,73.10^3$	$1,41.10^4$	$1,05.10^3$	$1,34.10^3$	$2,12.10^2$	$5,13.10^2$

Fonte: (SANTOS, 2011).

4.4 Bases de Dados

Após a coleta dos dados e modelagem das FAI, para validação das técnicas de localização tornou-se necessária a construção de uma base de dados relativamente extensa no ATP, tendo em vista que experimentalmente sua obtenção mostra-se inviável (ajustar diversos níveis de demanda, ângulos de incidência, dentre outras características). A base de dados que compôs o conjunto de padrões para treinamento, validação e teste de todas as RNA envolvidas foi construída de forma automatizada e será abordada em detalhes nas seções posteriores. As variáveis de simulação escolhidas referentes às FAI foram: superfície de contato, local de aplicação da FAI, ângulo de incidência de FAI e condição de operação do sistema (demanda).

Os padrões da base foram subdivididos em três subconjuntos disjuntos denominados de conjuntos de treinamento, validação e teste. Essa divisão previne o sobre-treinamento da rede, situação em que é perdida sua capacidade de generalização, fazendo com que apenas “decore” o conjunto de treinamento apresentado. O conjunto de treinamento é utilizado para escolher o modelo da rede que melhor se adapta. O processo de treinamento é interrompido a cada determinado número de épocas, calculando-se o erro médio quadrático para o conjunto de validação. Se o erro atual for menor que o erro para as iterações anteriores, as alterações na configuração da RNA são armazenadas, seguindo-se este procedimento até se atingir um valor mínimo do erro para a fase de treinamento. O conjunto de teste é utilizado para testar o desempenho da rede na tarefa considerada. Após o aprendizado, a RNA deve ser capaz de localizar corretamente as faltas que foram apresentadas durante as fases de treinamento e validação da rede, e ainda ser capaz de generalizar para os casos pertencentes ao conjunto de teste formado por casos diferentes dos apresentados até então.

4.4.1 Construção Automatizada

A base de dados utilizada para treinamento, validação e teste das RNA foi gerada por um processo automatizado. Vale salientar que se trata de uma base determinística. O primeiro passo foi a formação de um arquivo de entrada modelo .atp para cada superfície de falta. O tempo de simulação utilizado foi de 0,5 s (equivalente a 30 ciclos), com um passo de 0,1 μ s. A simulação das faltas é iniciada a partir da condição de pré-falta, durando 10 ciclos nessa condição. Os demais 20 ciclos da simulação ocorrem com a FAI aplicada. Vale salientar que a aplicação da falta se deu com o fechamento de uma chave simples, colocando o modelo desenvolvido de FAI entre a fase A do local de falta (barra) escolhido e o terra.

No ATP, os parâmetros referentes às variáveis de simulação, são ajustados no corpo do arquivo de entrada conforme as variáveis específicas para cada cenário de falta. Como os dados fornecidos pelo ATP não obedecem à formatação IEEE COMTRADE fez-se uso da rotina MODELS.

Para obtenção dos dados das simulações, adotou-se a seguinte metodologia:

- Extração dos valores de tensão e corrente fornecidos pelo ATP no início do alimentador na frequência de amostragem de 15360 Hz (mesma frequência dos RDP).
- Criação de um arquivo com os dados convertidos para um formato similar ao IEEE COMTRADE.

Ao final, obtêm-se os dados correspondentes a um dado tipo de falta. Para construir a Base de Dados é necessário unir as diversas situações de falta, que são obtidas a partir da combinação das variáveis de simulação. Para isso, concentraram-se as variáveis de cada caso no início do arquivo (.atp), fazendo-se uso da função \$PARAMETER⁵ do ATP.

Mediante a criação de um arquivo para processamento em lote (.bat), a simulação de todos os casos definidos nos arquivos .atp foi realizada automaticamente (SILVA, 2004; SANTOS. 2011). No processo automatizado cada arquivo é nomeado de forma sistemática, de modo a conter em seu nome informações do RDP, tipo, localização, superfície, demanda, além do ângulo de incidência. Um exemplo de arquivo da base automatizada é o seguinte:

RDP(S)_fAT__BAR10_ARE_C25_a88.atp

Todos os dados estão presentes no nome do arquivo:

- RDP(S) - RDP instalado na subestação;
- fAT - Tipo de falta - AT (fase A - terra);
- BAR10 - Local da falta - Barra 10 do alimentador;
- ARE - Superfície de falta - Areia;
- C25 - Carregamento (25%);
- a88 - Ângulo de incidência da falta (88°).

Baseando-se na \$PARAMETER, utilizou-se uma rotina desenvolvida em Matlab® para gerar qualquer cenário desejado nas simulações.

⁵ Função que transforma as constantes de cada caso em variáveis de simulação.

4.4.2 Pré-processamento

Cada cenário considerado na geração da base de dados possui um arquivo de dados no padrão COMTRADE. No entanto, devido a particularidades de algumas implementações, necessitou-se adicionar colunas nos arquivos que compõem a base de dados; incluindo, informações de local de falta, distância, harmônicos, energia dos CW, dentre outros. Na Tabela 4.6 a seguir estão as informações referentes a cada barra que foram inseridas na base de dados, no que diz respeito à distância acumulada desde a subestação e a seção do alimentador que está localizada a barra (de S1 a S6 e SE).

Para apresentação dos padrões de entrada às RNA, as grandezas foram normalizadas pelos seus máximos valores, acrescidos de 10%, com o intuito de que os mesmos permaneçam no intervalo $[-1, 1]$. O acréscimo de 10% é uma margem de segurança para manter os padrões de entrada da rede no intervalo unitário, mesmo quando houver alguma sobretensão ou sobrecorrente de valor maior que o encontrado nos subconjuntos das bases.

Em todas as implementações, optou-se por adotar uma sequência de amostras das variáveis de entrada para as RNA. Um método de janelamento dos arquivos de dados simulados foi empregado, agrupando os dados obtidos nos padrões a serem apresentados às RNA (Figura 4.16). O janelamento consistiu em agrupar n amostras consecutivas das grandezas escolhidas para cada implementação (tensões e/ou correntes de fase, tensões e/ou correntes de sequência zero, harmônicos, energia dos CW) em um único vetor de entrada. A janela de dados é tida como móvel, já que percorre todo o arquivo, deslocando-se ao passo de uma amostra.

Tabela 4.6. Informações de localização das barras.

BARRA	SEÇÃO	Distância (m)	BARRA	SEÇÃO	Distância (m)
1	SE	430	46	S4	5860
2	SE	860	47	S4	7260
3	SE	1760	48	S4	9260
4	SE	3660	49	S4	11660
5	SE	3260	50	S2	4560
6	S1	4260	51	S2	6060
7	S1	6260	52	S2	7260
8	S1	7260	53	S2	7060
9	S1	6260	54	S2	8260
10	S1	5760	55	S2	9260
11	S1	7260	56	S2	10260
12	S1	8760	57	S2	10260
13	S1	10260	58	S2	12260
14	S1	10560	59	S2	13460
15	S1	12360	60	S2	15460
16	S1	14360	61	S2	17460
17	S1	8960	62	S2	14560
18	S1	10660	63	S2	17060
19	S1	12660	64	S2	15660
20	S1	12160	65	S5	17660
21	S1	13660	66	S5	19660
22	S1	14660	67	S5	21060
23	S1	14860	68	S5	22460
24	S1	11960	69	S5	22060
25	S1	13160	70	S5	22660
26	S1	14160	71	S5	24460
27	S1	14660	72	S5	20860
28	S1	14760	73	S5	22160
29	S1	14460	74	S5	24660
30	S1	15960	75	S5	26660
31	S1	17460	76	S5	29160
32	S1	18660	77	S5	26760
33	S1	19660	78	S6	17660
34	S1	19660	79	S6	19660
35	S1	18560	80	S6	21960
36	S1	17460	81	S6	23460
37	S1	15960	82	S6	25460
38	S3	5260	83	S6	27460
39	S3	6760	84	S6	24960
40	S3	7760	85	S6	24360
41	S3	9360	86	S6	27360
42	S3	6802	87	S6	28960
43	S3	8860	88	S6	31960
44	S3	9860	89	S6	28560
45	S4	5260	90	S6	26360

Fonte: Próprio Autor.

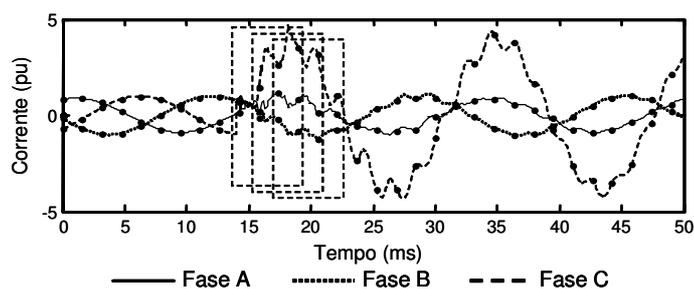


Figura 4.16. Processo de janelamento dos sinais de corrente (Adaptado de (SILVA, 2004)).

Durante o treinamento, devido à similaridade dos padrões de entrada, pode ocorrer uma tendência no reajuste dos pesos que provoque a perda da capacidade de generalização da RNA. Para contornar essa situação, realiza-se uma mistura aleatória dos padrões na base de dados, proporcionando um treinamento mais eficaz (SILVA, 2004).

4.5 Implementações

4.5.1 Estruturas de RNA

Para implementação das RNAs, a ferramenta computacional escolhida foi o *Neural Network Toolbox* do Matlab®. A mesma base de dados gerada foi organizada de duas formas, de modo a treinar as redes MLP e SOM, tendo em vista que conforme as Figuras 4.1 e 4.2 necessitam de um número diferente de entradas. Para definição das arquiteturas, algumas simulações foram realizadas, modificando-se o número de camadas ocultas e de seus neurônios. Também foram variados os tamanhos dos subconjuntos de treinamento, teste e validação.

Sobre as *wavelet* mãe adotadas, tem-se nas Figuras 4.17, 4.18 e 4.19 a seguir suas representações gráficas. Na Figura 4.20 é apresentada a resposta em frequência normalizada de 1ª escala para cada uma (em que 2π corresponde à frequência de amostragem).

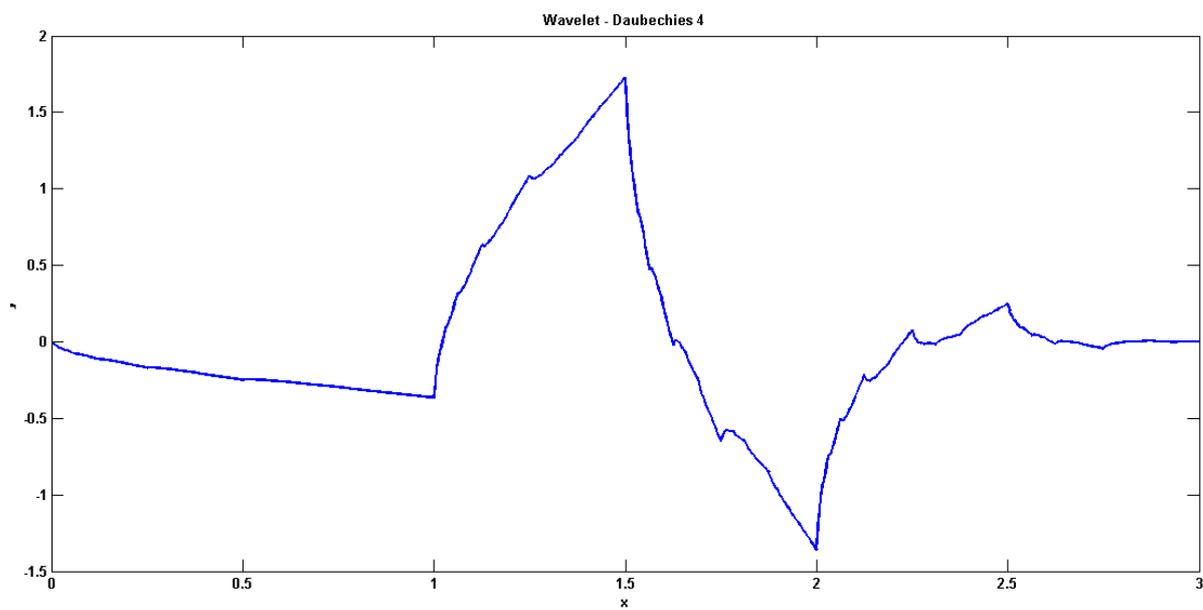


Figura 4.17. *Wavelet* Daubechies 4 (Fonte: Próprio Autor).

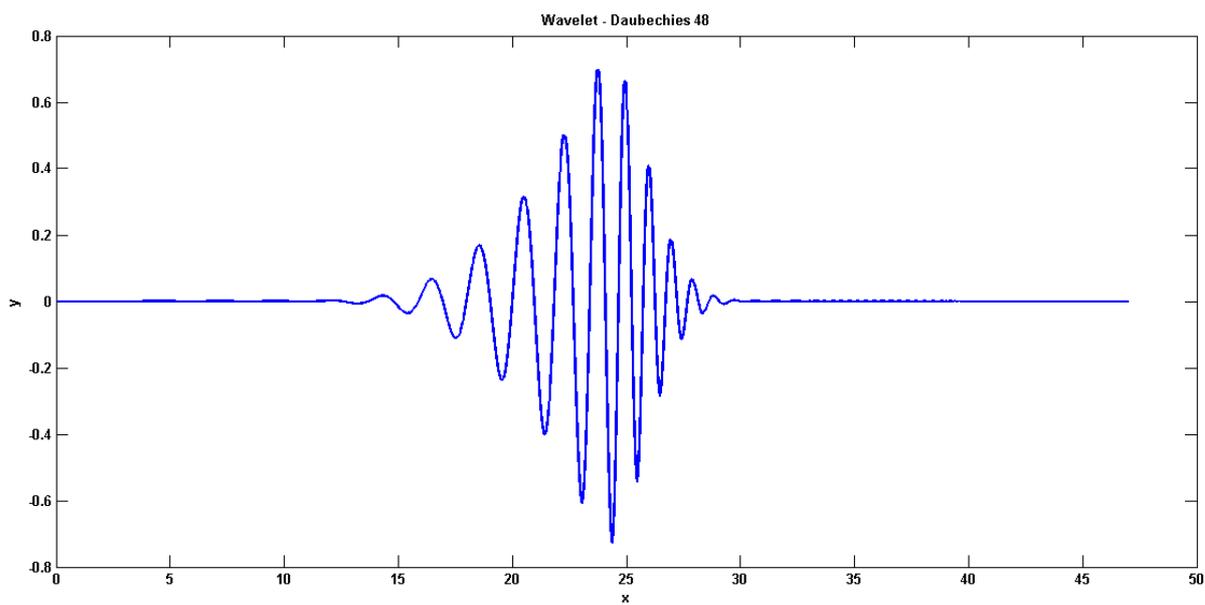


Figura 4.18. *Wavelet* Daubechies 48 (Fonte: Próprio Autor).

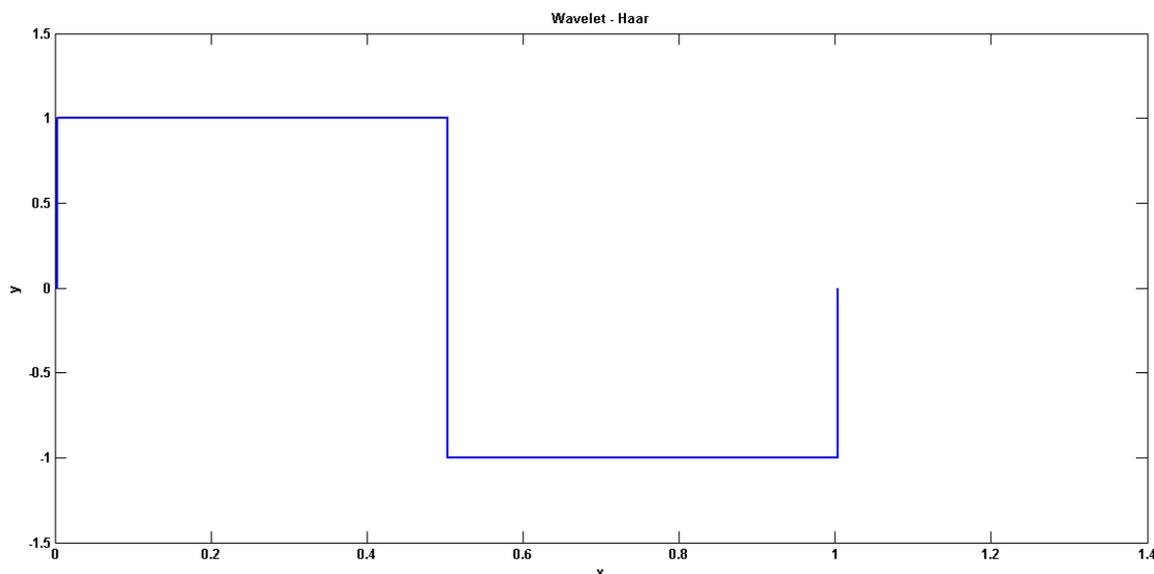


Figura 4.19. *Wavelet* Haar (Fonte: Próprio Autor).

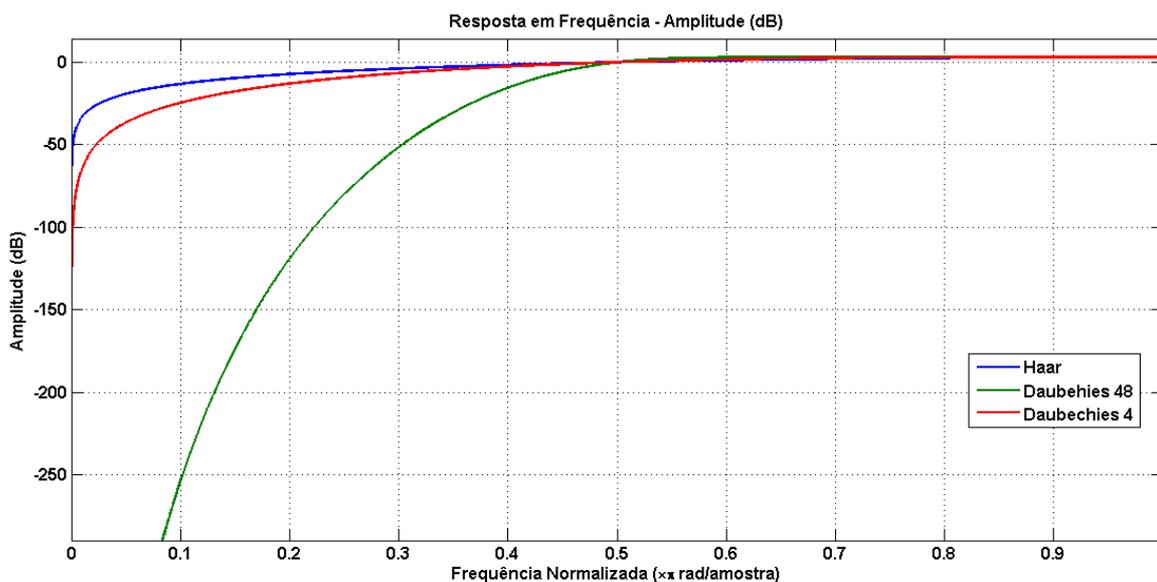


Figura 4.20. Resposta em frequência das *wavelets* utilizadas (Fonte: Próprio Autor).

Analisando-se a Figura 4.20, é notado que para $0,5\pi$ o ganho para os três filtros *wavelet* é 0 dB, ou seja, o sinal permanece o mesmo para essa frequência (equivalente a um quarto da frequência de amostragem). Na parte passa-altas, há um discreto ganho sobre o sinal para os três filtros, que apresentam respostas semelhantes. É relevante apontar que as *wavelets* Haar e Daubechies 4 “invadem” a parte passa-baixas de forma mais intensa que a Daubechies 48. Conclui-se que,

mesmo atenuadas, as componentes de baixa frequência do sinal original influenciam no cálculo dos coeficientes *wavelet*.

A base de dados construída para as simulações contou com 1200 cenários de falta, sendo 300 para cada superfície. Indiretamente fazem parte da base de dados as *wavelet* mãe adotadas (no caso em questão, três). Porém, a adoção de cada *wavelet* não modifica os cenários de falta, apenas a forma de apresentação às RNA. Um resumo da base está na Tabela 4.7. Verifica-se que as barras escolhidas para as simulações contemplam todos os setores do alimentador.

Tabela 4.7. Variáveis de simulação e cenários de falta.

VARIÁVEIS DE SIMULAÇÃO	ESPECIFICAÇÃO
Tipo de falta	AT
Carregamento (%)	25, 50, 75, 100
Ângulo de incidência (°)	88, 89, 90, 91, 92
Local de falta (Barra)	2, 4, 10, 23, 30, 35, 44, 49, 50, 56, 63, 68, 76, 83, 86
Local de falta (km)	0,86; 3,66; 5,76; 15,96; 18,56; 9,86; 11,66; 4,56; 10,26; 17,06; 29,16; 27,46; 27,36
<i>Wavelet</i> mãe	Haar, Daubechies 4 e Daubechies 48
Superfície de contato	Areia, grama, terra e calçamento

Fonte: Próprio Autor.

4.5.1.1 Rede MLP

Como citado anteriormente, a rede MLP foi a escolhida para fornecer a localização das FAI. Antes do processo de treinamento, foi realizada a normalização para cada componente individual em função dos seus valores máximos para manter os dados no intervalo [-1, 1].

É importante frisar que para obtenção das energias foi aplicada a Transformada *Wavelet* Discreta Redundante (TWDR), pelo fato de não haver a decimação. Assim, tanto as correntes, quanto os coeficientes terão o mesmo número de amostras. Na Tabela 4.8 são apresentadas as 12 entradas para a RNA.

Tabela 4.8. Descrição das variáveis de entrada das RNA

VARIÁVEIS	SIGNIFICADO	ENTRADAS
Ia	Corrente na fase A	3
Ib	Corrente na fase B	3
Ic	Corrente na fase C	3
E _{Ia}	Energia das CW da corrente Ia	3
TOTAL		12

Fonte: Próprio Autor.

Para execução das etapas de treinamento, validação e teste da RNA, a base de dados foi subdividida da seguinte forma: 56% para o treinamento, 24% para a validação e 20% para o teste. Essa divisão foi obtida após alguns testes com bases menores. Adotou-se 30000 épocas para a etapa de treinamento e pelo algoritmo de treinamento RPROP. A saída das RNA são as distâncias normalizadas da subestação ao ponto de ocorrência da FAI no alimentador utilizado, em função da máxima distância do alimentador à subestação, de modo que os comprimentos sempre se situem no intervalo [0, 1].

A função de ativação escolhida para a camada oculta foi a tangente hiperbólica (*tansig*), para limitar a saída dos neurônios ao intervalo [-1,1]; enquanto que para as camadas de saída utilizou-se a função sigmoide (*logsig*), para limitar a saída dos neurônios ao intervalo [0,1]. O conjunto de teste foi dividido em arquivos, para os quais foram calculadas as energias dos CW, janelados os dados e apresentados à RNA treinada.

Os critérios de parada adotados, utilizando-se o comando *trainParam* do *Toolbox* foram:

- Número máximo de épocas - 30000;
- Mínimo gradiente - 1e-9;
- Erro mínimo - 0;
- Número de épocas para parada por validação - 100.

O treinamento é encerrado quando ocorrer qualquer um dos critérios elencados. O último (parada por validação) diz respeito à tolerância do número de

épocas sem haver aprendizado da RNA. Dessa forma, após 100 épocas “decorando” a base de dados, não há nada mais a ser aprendido.

4.5.1.2 Rede SOM

Para a rede SOM, a base de dados não foi apresentada de forma janelada. O vetor de entrada é composto por 4 grandezas (I_a , I_b , I_c , e E_{1a}) e um rótulo (as regiões do alimentador: SE, S1, S2, S3, S4, S5 e S6). Os cenários de falta foram os mesmos para a MLP. As grandezas de entrada foram normalizadas em relação aos respectivos valores máximos.

Variou-se o tamanho da grade desde 10x10 até 80x80, avaliando-se a taxa de acertos na localização, além do erro de quantização no mapa neural. Optou-se por adotar uma grade com elementos hexagonais, com função de vizinhança Gaussiana. O modo de treinamento escolhido foi o por lote (*batch*).

4.5.2 Software AnFAI

O *software* **AnFAI** foi um dos produtos resultantes do Projeto de P&D desenvolvido pelo Grupo de Sistemas Elétricos da UFCG com a Energisa (UFCG, 2010). Trata-se de uma ferramenta de análise de registros oscilográficos baseada na TW, incluindo as etapas de detecção e localização de FAI. Atualmente, o *software* encontra-se instalado em subestações piloto do Sistema da Energisa. Os registros são arquivos contendo as informações de estado dos equipamentos de proteção e os sinais de tensão e corrente do sistema monitorado. Vale ressaltar que o desenvolvimento do *software* não foi objeto do trabalho do doutorado, portanto, não foi realizado por este autor; tendo sido apenas o método empregado para localização dos distúrbios. Na Figura 4.21 é apresentada a interface do **AnFAI**.

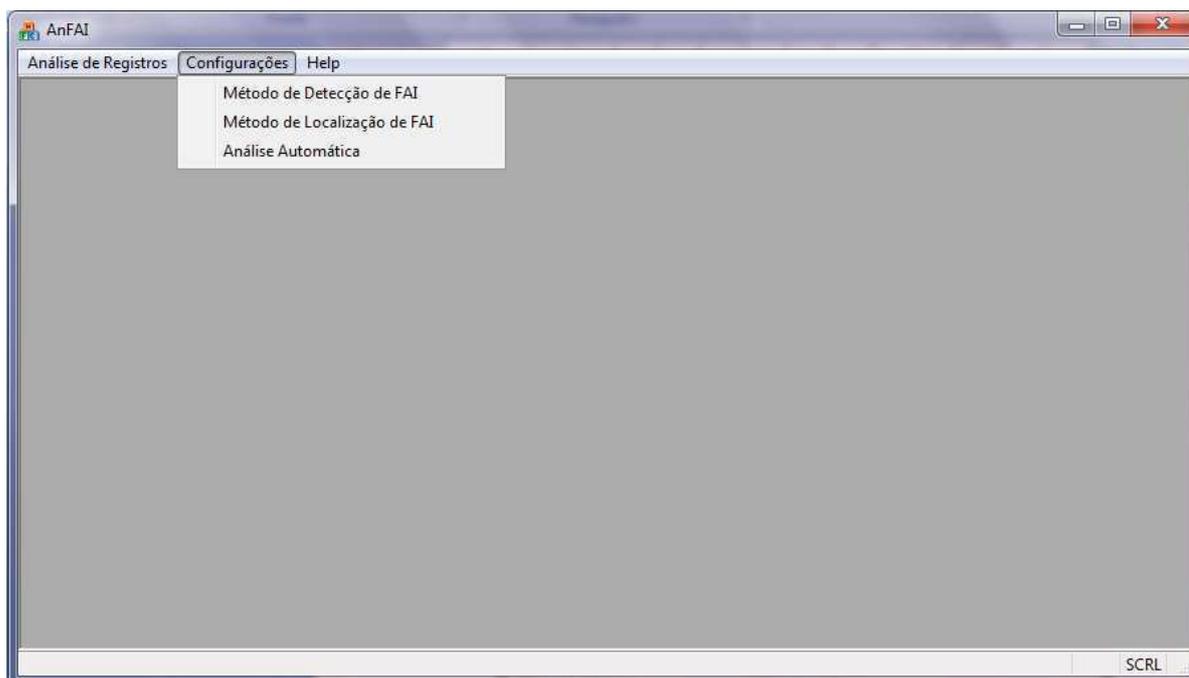


Figura 4.21. Interface do *software* AnFAI (UFCEG, 2010).

Os menus apresentados na Figura 4.21 são os seguintes:

- **Método de detecção de FAI** – Detalhado na Figura 4.22, propicia ao usuário escolher quais grandezas trifásicas deseja analisar para detectar a FAI.

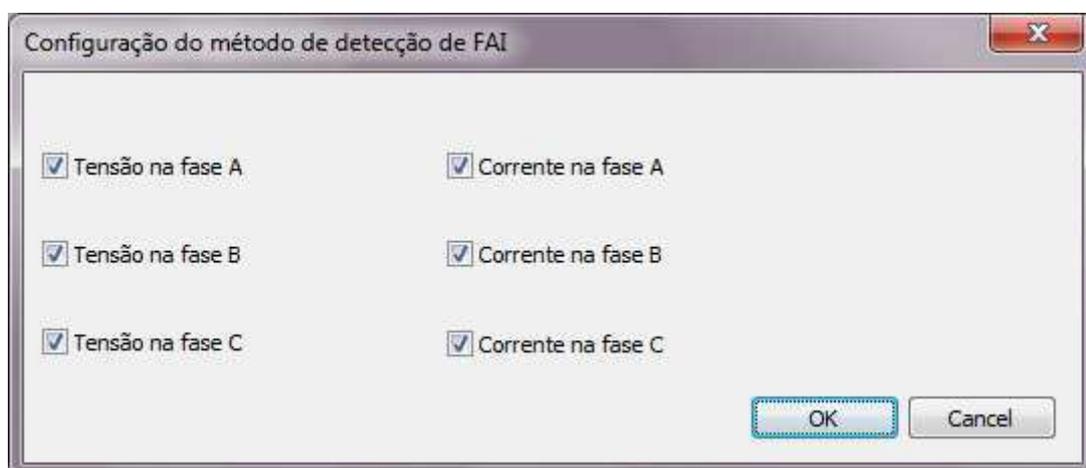


Figura 4.22. Configuração do método de detecção de FAI (UFCEG, 2010).

- **Método de localização da FAI** – através desse submenu o usuário irá escolher a arquitetura da RNA que será usada para o método de localização.
- **Análise Automática** – nessa opção o usuário configura onde ficarão as pastas que são criadas na execução do *software*.

Capítulo 5

Análise dos Resultados

Neste capítulo são apresentados os resultados obtidos, oriundos das implementações detalhadas no Capítulo 4. Inicialmente são apresentados alguns detalhes das simulações, evidenciando a importância dos coeficientes *wavelet* no diagnóstico. Em seguida, são descritos os acertos na localização em tabelas, assim como os parâmetros de treinamento das RNA. Será mostrado um teste para a RNA treinada com dados reais. O capítulo é finalizado com os resultados obtidos para a SOM.

5.1 Particularidades das Simulações

Na Figura 5.1 são apresentadas as tensões trifásicas na subestação com a ocorrência de uma FAI na barra 23, localizada a uma distância de 14,86 km. A superfície foi a areia. O tempo de simulação foi de 0,5 s, com a falta ocorrendo no final do 10º ciclo (0,166 s). É imperceptível a mudança na tensão em qualquer das fases, até mesmo nos instantes próximos a ocorrência. Assim, justifica-se a não utilização das tensões para a obtenção dos objetivos.

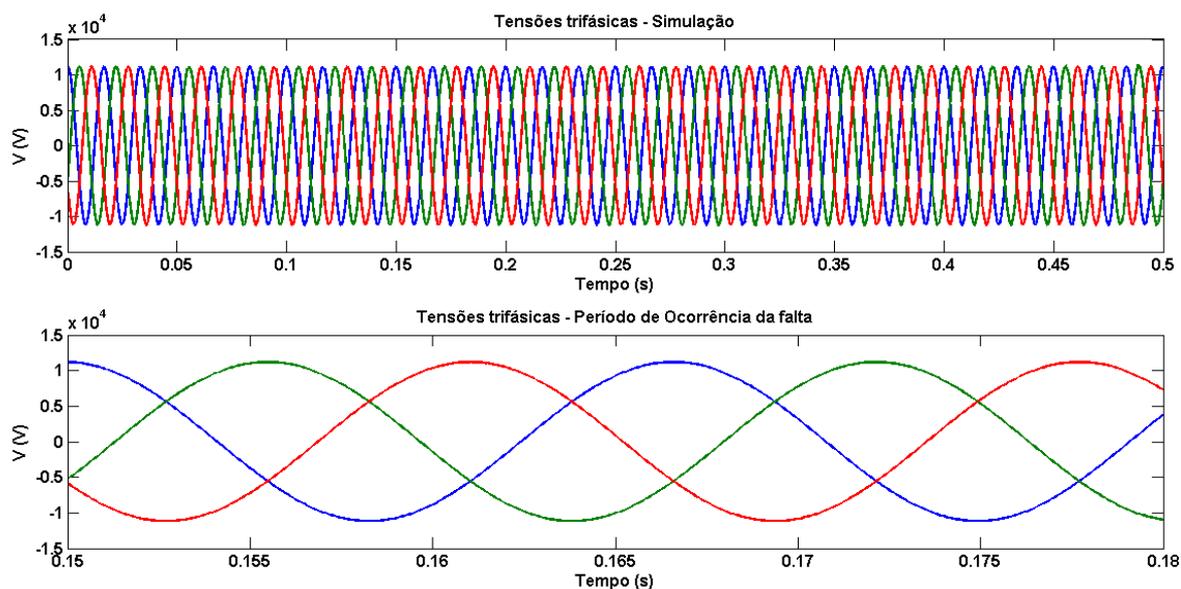


Figura 5.1. Tensão na subestação com a ocorrência de uma FAI (Fonte: Próprio Autor).

Na Figura 5.2 está apresentado o comportamento da corrente na fase A, medida na subestação (não confundir com a corrente no local de falta). Há uma pequena variação de amplitude, quase imperceptível. Na Figura também estão os coeficientes de aproximação (como o próprio nome descreve, aproximadamente a corrente original) e os coeficientes *wavelet*. É notada uma variação nos coeficientes de detalhes na ocorrência da falta.

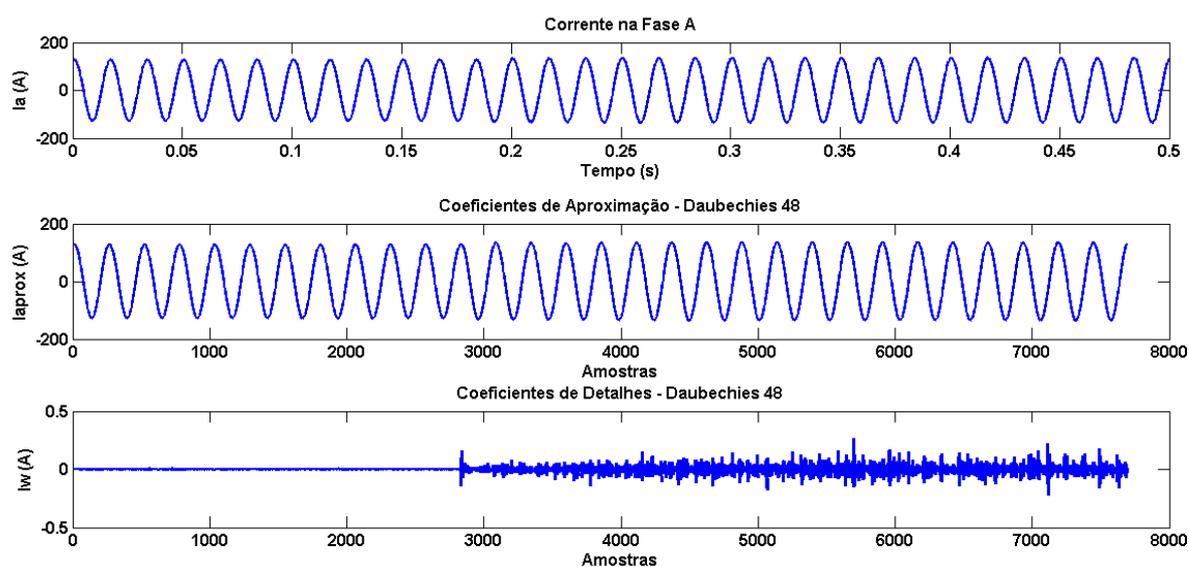


Figura 5.2. Corrente na subestação com a ocorrência de uma FAI e os resultados da Transformada *Wavelet* (Fonte: Próprio Autor).

Na Figura 5.2 há indícios de que os CW podem ser determinantes para a detecção e localização de uma FAI. Porém, a variação pode ser considerada discreta. Através das energias dos CW vistas na Figura 5.3, a ocorrência da falta é clara. De maneira quase instantânea com a ocorrência, há um aumento considerável da energia dos CW. Comparando-se as *wavelets*, a energia com a Haar é maior. Tal fato pode ser explicado pela Figura 4.20, em que está a resposta em frequência. A energia é maior pois há a influência de muitas componentes de baixa frequência no cálculo. Fato inverso ocorre para a Daubechies 48, que apresenta grande atenuação para as frequências baixas.

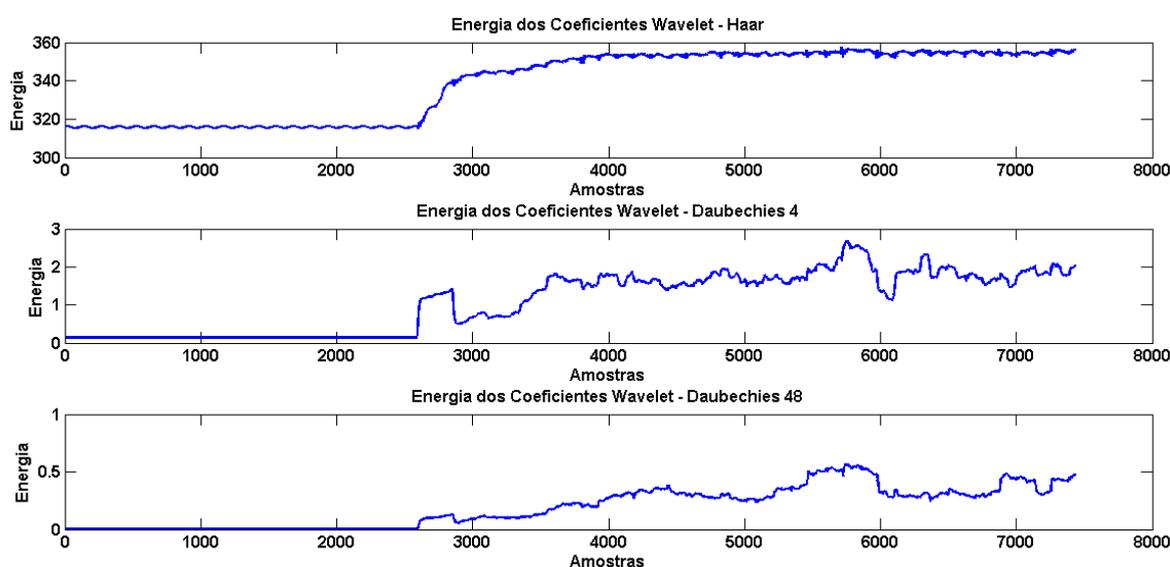


Figura 5.3. Energia dos coeficientes *wavelet* das correntes (Fonte: Próprio Autor).

Na Figura 5.4 está a justificativa da utilização das energias dos CW aliada às amostras das correntes trifásicas no domínio do tempo. Há duas simulações de FAI: uma com 25% de carregamento e outra com 100%. Imaginar-se-ia que com um carregamento maior e corrente maior na subestação, conseqüentemente a energia seria maior e vice-versa. Nota-se que para o caso de menor corrente na subestação, a energia é maior que no caso de 100%. Qualitativamente pode-se apontar que a falta (do caso de 25%) ocorreu próxima a subestação, pois não houve amortecimento dos transitórios ao longo do alimentador. O inverso ocorreu para o caso do carregamento de 100%. Com a energia menor, infere-se que houve significativo amortecimento dos transitórios, característica de uma falta distante.

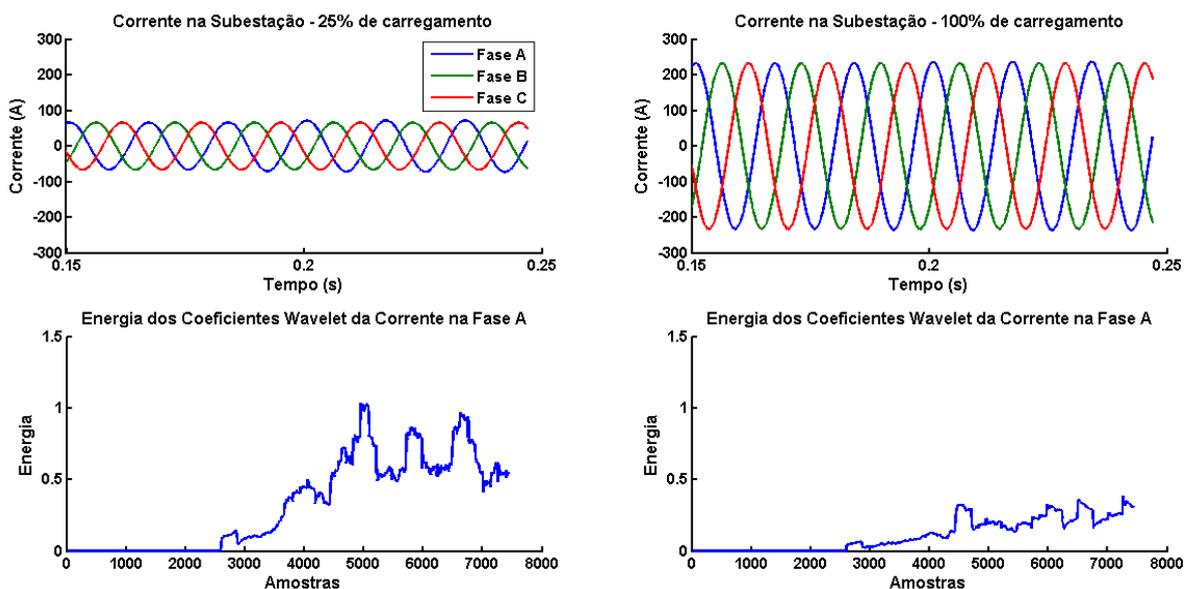


Figura 5.4. Análise da energia dos CW para FAI de carregamentos diferentes (Fonte: Próprio Autor).

5.2 Redes Treinadas

É apresentada na Tabela 5.1 uma síntese do treinamento das RNA utilizadas para determinar a localização das FAI. Os dados estão em função da configuração da rede e a *wavelet* utilizada para o cálculo da energia dos CW das correntes. São fornecidos o número de épocas além do erro médio quadrático.

Tabela 5.1. Síntese do treinamento das RNA

	12-1		12-50-1		12-50-20-1	
	Épocas	Erro	Épocas	Erro	Épocas	Erro
Daubechies 4	12063	0,0548	30000	0,0413	30000	0,0384
Daubechies 48	123	0,0551	30000	0,023	28768	0,021
Haar	30000	0,0574	30000	0,0465	30000	0,043

Fonte: Próprio Autor.

Em alguns casos, o número máximo de épocas não foi atingido devido ao critério de parada por validação. O treinamento foi interrompido no momento a partir do qual identificou-se que a rede começou a perder a capacidade de generalização dos padrões, passando a memorizar características específicas dos padrões pertencentes ao conjunto de treinamento. A arquitetura 12-50-20-1

apresentou menor erro em todos os cenários. Nas Figuras 5.5 a 5.7 estão as evoluções dos erros médio para as 100 primeiras épocas do treinamento.

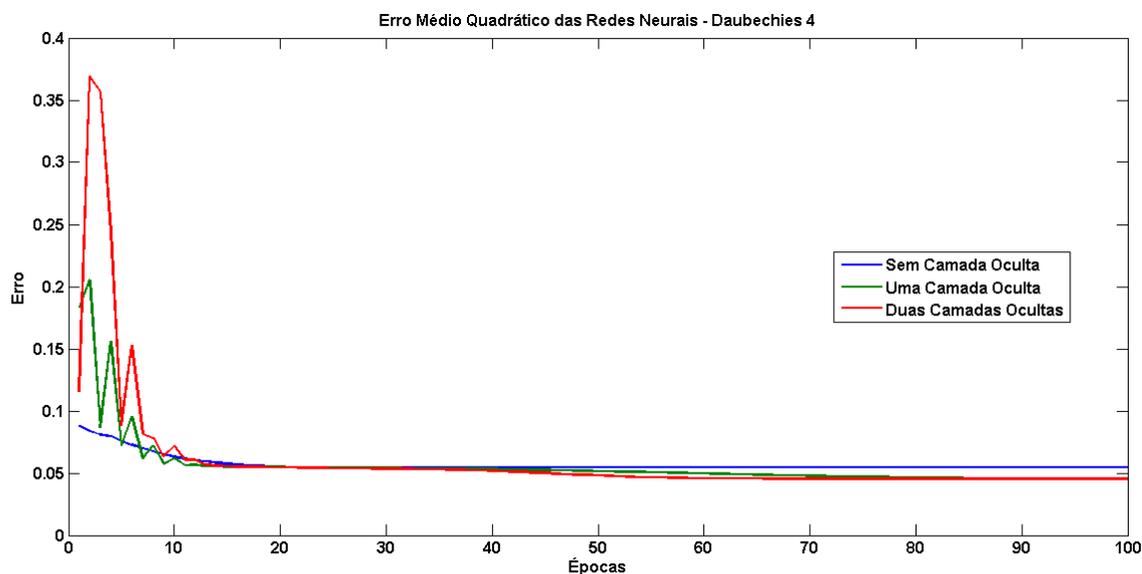


Figura 5.5. Evolução do treinamento das RNA - Daubechies 4 (Fonte: Próprio Autor).

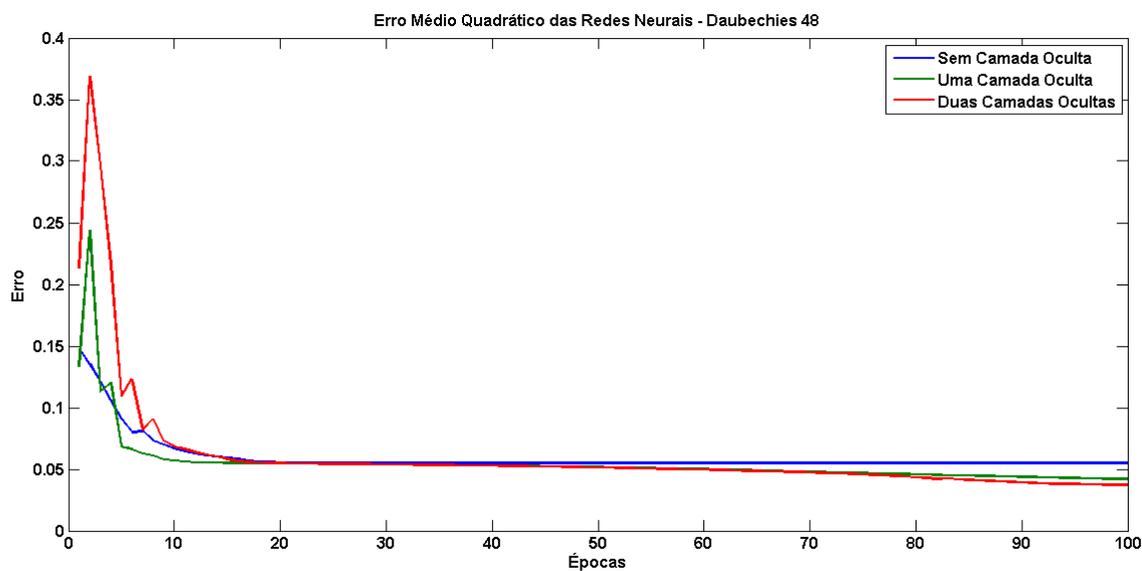


Figura 5.6. Evolução do treinamento das RNA - Daubechies 48 (Fonte: Próprio Autor).

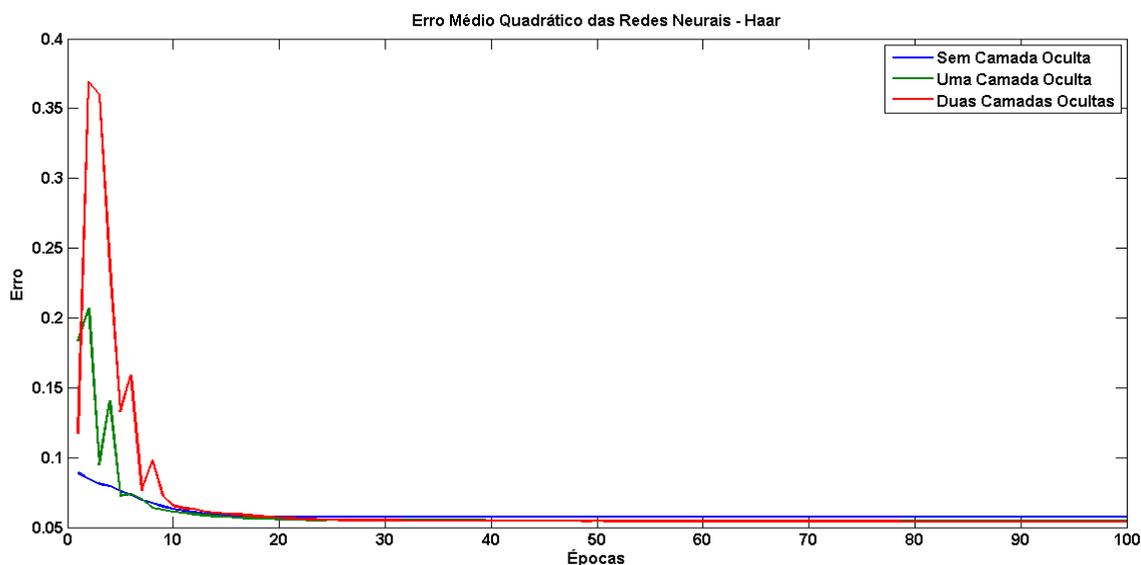


Figura 5.7. Evolução do treinamento das RNA - Haar (Fonte: Próprio Autor).

Na Tabela 5.2 a seguir são apresentados os tempos gastos no treinamento das RNA localizadoras, em função de cada configuração das camadas e da *wavelet* mãe adotada. Vale ressaltar que as simulações foram realizadas em um computador Dell Inspiron, com processador Pentium i5 (*clock* 1,80 MHz) e 6 GB de memória RAM. Como esperado, as estruturas com mais camadas demandaram um tempo maior de treinamento.

Tabela 5.2. Tempo de treinamento das RNA

	12-1	12-50-1	12-50-20-1
	Tempo (hh:mm:ss)	Tempo (hh:mm:ss)	Tempo (hh:mm:ss)
Daubechies 4	00:08:45	04:43:32	07:20:41
Daubechies 48	00:00:11	04:46:25	07:07:39
Haar	00:05:16	04:31:36	06:54:09

Fonte: Próprio Autor.

5.3 Resultados da MLP localizadora

Com a aplicação do padrão de testes à RNA localizadora, foram obtidos diversos resultados expostos nas Tabelas 5.3 a 5.14 a seguir em detalhes. Nas respectivas Tabelas, os piores resultados de cada conjunto de simulações estão sombreados. Para algumas localizações é notório a disparidade com as médias obtidas, assim como os resultados para outras localizações. Como descrito no

Capítulo 4, para cada superfície testada foram treinadas três RNA diferentes, com três *wavelets* diferentes e quatro situações de carregamento. É importante lembrar que para cada caso de teste, a falta teve duração de 20 ciclos. Dessa forma, há diversas estimações para cada arquivo. Optou-se por duas medidas para determinação da localização: a média das indicações e a mediana. A média trata-se da medida estatística que na maioria das vezes exprime forma resumida o comportamento de determinada variável. O uso da mediana deveu-se a tentativa de se obter uma medida que não fosse tão influenciada por valores individuais erráticos e não significativos. Dessa forma seria mais simples minimizar o efeito de dados espúrios que viessem a ocorrer em cada registro. Nas Tabelas, a *wavelet* Daubechies 48 está abreviada como db48 e a Daubechies 4 como db4. O conjunto de testes foi dividido em arquivos com registros no padrão COMTRADE, de cujos dados foram calculadas as energias dos CW.

Pretende-se investigar qual a melhor *wavelet* para o caso em questão, além da configuração de RNA. Pelo apresentado na Tabela 5.1 e Figuras 5.5 a 5.7, as indicações são para a configuração 12-50-20-1 e Daubechies 48. Os resultados das Tabelas fornecerão mais subsídios para confirmar se a sentença é verdadeira ou não. A margem de acerto é referente à precisão da localização. Calcula-se o módulo do erro da indicação em relação à localização verdadeira, subtraindo o resultado de 100%.

Tabela 5.3. Areia - Rede 12-1.

Barra	d (m)	Carga (%)	Acerto (%) - Média			Acerto (%) - Mediana		
			db4	db48	Haar	db4	db48	Haar
2	860	100	90,96	90,85	92,00	97,31	97,31	97,45
2	860	25	90,98	90,88	89,63	97,31	97,31	97,31
2	860	50	90,97	90,86	90,12	97,31	97,31	97,32
2	860	75	90,97	90,86	91,10	97,31	97,31	97,33
4	3660	100	91,07	89,85	83,89	99,88	97,61	88,45
4	3660	25	91,38	90,25	75,12	99,48	99,08	79,59
4	3660	50	92,27	91,39	78,35	98,10	99,06	83,38
4	3660	75	91,68	90,56	81,13	98,64	99,26	86,33
23	14860	100	94,92	95,06	98,64	94,91	95,06	98,63
23	14860	25	94,91	95,06	90,61	94,92	95,06	90,61
23	14860	50	94,92	95,06	93,27	94,91	95,06	93,23
23	14860	75	94,92	95,06	97,16	94,92	95,06	97,16
30	15960	100	98,38	98,50	95,17	98,37	98,50	95,16
30	15960	25	98,38	98,51	94,08	98,38	98,51	94,09
30	15960	50	98,38	98,50	96,74	98,36	98,50	96,70
30	15960	75	98,38	98,51	99,37	98,38	98,50	99,39
35	18560	100	93,50	93,37	87,06	93,51	93,37	87,06
35	18560	25	93,50	93,36	97,81	93,49	93,36	97,81
35	18560	50	93,51	93,37	95,15	93,52	93,37	95,19
35	18560	75	93,51	93,37	91,27	93,51	93,37	91,26
49	11660	100	84,90	85,04	91,35	84,88	85,04	91,36
49	11660	25	84,89	85,04	80,59	84,91	85,04	80,60
49	11660	50	84,90	85,04	83,25	84,89	85,04	83,22
49	11660	75	84,90	85,04	87,14	84,90	85,04	87,15
50	4560	100	85,36	83,84	87,99	63,28	63,09	70,07
50	4560	25	95,27	93,06	91,79	86,60	93,89	90,38
50	4560	50	83,53	82,88	81,77	62,95	62,98	61,88
50	4560	75	80,62	80,29	81,51	62,93	63,00	65,17
63	17060	100	98,22	98,06	91,88	98,21	98,06	91,84
63	17060	25	98,22	98,06	97,47	98,22	98,06	97,50
63	17060	50	98,22	98,06	99,89	98,23	98,06	99,90
63	17060	75	98,22	98,06	96,05	98,23	98,06	96,03
68	22460	100	81,32	81,17	75,00	81,30	81,17	74,96
68	22460	25	81,32	81,17	85,63	81,32	81,17	85,62
68	22460	50	81,33	81,17	83,00	81,33	81,17	83,01
68	22460	75	81,32	81,17	79,16	81,32	81,17	79,13
86	27360	100	65,98	65,84	59,67	65,97	65,84	59,63
86	27360	25	65,98	65,84	70,29	65,98	65,84	70,28
86	27360	50	65,99	65,84	67,67	65,99	65,84	67,68
86	27360	75	65,99	65,84	63,83	65,98	65,84	63,81
Média (%)			88,60	88,34	86,82	88,25	88,38	86,57

Fonte: Próprio Autor.

Tabela 5.4. Areia - Rede 12-50-1.

Barra	d (m)	Carga (%)	Acerto (%) - Média			Acerto (%) - Mediana		
			db4	db48	Haar	db4	db48	Haar
2	860	100	90,11	94,00	88,06	98,68	99,90	95,03
2	860	25	89,39	93,64	87,48	99,49	99,90	99,38
2	860	50	88,89	94,09	87,34	99,25	99,90	98,47
2	860	75	89,34	94,22	88,09	99,13	99,90	97,63
4	3660	100	93,65	95,34	93,42	99,61	99,36	99,95
4	3660	25	91,21	95,20	93,19	98,97	99,64	99,98
4	3660	50	92,54	95,26	93,65	99,57	99,33	99,46
4	3660	75	93,59	95,71	93,80	99,81	99,33	99,36
23	14860	100	96,85	92,94	99,84	94,71	92,01	99,51
23	14860	25	97,55	95,11	95,72	98,92	93,41	95,94
23	14860	50	97,50	93,76	98,11	94,95	92,71	98,01
23	14860	75	97,93	93,11	99,47	95,25	92,19	98,59
30	15960	100	89,42	88,88	95,87	86,72	85,89	96,60
30	15960	25	92,24	92,45	99,85	90,09	88,49	99,72
30	15960	50	89,44	92,82	97,61	85,87	86,60	97,84
30	15960	75	89,34	90,17	96,32	86,13	86,01	97,32
35	18560	100	84,63	81,28	88,21	82,30	80,35	88,86
35	18560	25	89,41	82,07	92,58	85,17	80,46	92,42
35	18560	50	87,31	82,11	90,32	84,35	81,50	90,37
35	18560	75	85,22	81,17	88,87	82,35	80,72	89,82
49	11660	100	89,31	96,60	89,95	90,47	98,05	89,29
49	11660	25	82,36	96,03	85,36	81,09	97,16	85,60
49	11660	50	88,05	96,51	87,70	90,22	96,96	87,71
49	11660	75	90,79	95,90	89,15	93,93	97,35	88,21
50	4560	100	85,35	86,27	82,54	99,50	99,73	71,68
50	4560	25	90,21	89,70	89,76	97,80	99,33	98,19
50	4560	50	83,58	84,64	81,76	79,32	79,23	70,63
50	4560	75	80,74	81,93	78,91	77,50	78,02	69,30
63	17060	100	91,39	92,71	97,19	91,38	85,42	98,24
63	17060	25	96,13	91,69	99,81	95,93	86,76	99,29
63	17060	50	94,55	92,53	98,39	94,54	86,37	99,91
63	17060	75	92,09	92,17	97,32	92,01	85,60	98,52
68	22460	100	92,80	90,42	87,10	92,73	89,42	86,39
68	22460	25	87,64	93,54	83,58	87,84	93,26	82,58
68	22460	50	89,33	93,50	85,53	89,14	93,76	83,78
68	22460	75	92,03	92,00	86,88	91,90	91,42	85,88
86	27360	100	75,78	95,68	72,45	75,90	96,07	71,58
86	27360	25	70,46	95,85	68,29	70,93	96,58	67,26
86	27360	50	72,83	96,22	70,68	73,36	96,49	69,16
86	27360	75	75,65	95,76	72,16	75,86	96,35	71,21
Média (%)			88,67	91,82	89,31	90,07	92,02	90,22

Fonte: Próprio Autor.

Tabela 5.5. Areia - Rede 12-50-20-1.

Barra	d (m)	Carga (%)	Acerto (%) - Média			Acerto (%) - Mediana		
			db4	db48	Haar	db4	db48	Haar
2	860	100	91,62	93,85	88,62	97,86	99,74	94,08
2	860	25	90,20	93,75	87,91	99,94	99,81	99,38
2	860	50	89,49	94,55	87,85	99,79	99,76	97,65
2	860	75	90,33	94,95	88,57	99,59	99,75	96,18
4	3660	100	94,23	95,28	93,95	99,61	99,38	99,82
4	3660	25	91,78	95,07	92,31	99,32	99,49	99,30
4	3660	50	92,85	95,33	92,93	99,65	99,39	99,66
4	3660	75	93,85	96,16	93,68	99,76	99,37	99,83
23	14860	100	95,01	92,41	95,66	93,23	91,97	94,64
23	14860	25	97,71	94,00	96,19	98,56	93,12	96,03
23	14860	50	97,25	93,28	99,93	94,57	92,82	99,78
23	14860	75	96,07	92,88	96,44	93,77	92,23	95,93
30	15960	100	89,19	88,72	91,07	86,68	86,63	89,79
30	15960	25	93,83	92,01	99,41	91,00	89,11	99,71
30	15960	50	89,20	92,45	95,36	85,88	87,35	95,56
30	15960	75	88,95	90,75	91,56	85,43	86,76	90,76
35	18560	100	83,44	80,94	84,00	81,56	80,35	82,82
35	18560	25	88,99	81,21	92,18	85,03	80,89	92,32
35	18560	50	86,94	81,59	88,53	83,70	81,41	88,21
35	18560	75	84,43	80,93	84,76	82,32	80,13	83,99
49	11660	100	94,23	96,61	93,87	95,31	97,51	95,21
49	11660	25	82,29	97,03	85,65	81,84	97,57	85,63
49	11660	50	88,64	96,88	89,16	91,67	97,04	89,47
49	11660	75	92,32	96,22	92,86	94,92	97,76	93,51
50	4560	100	86,12	86,80	82,98	99,31	99,94	78,48
50	4560	25	90,04	90,24	90,49	98,34	99,04	96,48
50	4560	50	83,93	85,67	82,27	80,04	80,23	74,76
50	4560	75	81,95	82,36	80,29	79,76	78,10	74,65
63	17060	100	91,04	92,35	92,26	91,64	85,99	93,30
63	17060	25	95,84	90,37	99,56	95,64	86,80	99,58
63	17060	50	94,17	90,90	96,76	93,67	86,31	98,28
63	17060	75	92,16	91,57	93,51	92,12	85,89	94,92
68	22460	100	95,56	90,73	93,10	94,49	90,31	92,67
68	22460	25	88,17	92,43	84,10	88,38	91,45	83,09
68	22460	50	91,14	93,37	87,65	90,73	93,13	86,19
68	22460	75	94,09	91,52	91,63	93,14	90,83	90,58
86	27360	100	81,86	97,00	78,94	81,15	96,98	78,89
86	27360	25	69,97	98,23	69,04	70,01	99,21	67,94
86	27360	50	74,95	99,69	73,20	74,77	99,57	71,96
86	27360	75	79,72	97,94	77,51	78,99	98,34	76,78
Média (%)			89,34	91,95	89,39	92,24	92,29	90,45

Fonte: Próprio Autor.

Tabela 5.6. Calçamento - Rede 12-1.

Barra	d (m)	Carga (%)	Acerto (%) - Média			Acerto (%) - Mediana		
			db4	db48	Haar	db4	db48	Haar
2	860	100	86,70	94,10	52,17	97,31	97,31	52,14
2	860	25	85,98	95,31	51,59	97,31	97,31	52,03
2	860	50	86,27	95,27	51,85	97,31	97,31	52,32
2	860	75	86,70	94,59	52,04	97,31	97,31	52,25
4	3660	100	90,29	98,16	61,56	93,76	88,55	61,85
4	3660	25	88,73	97,71	61,42	99,48	88,55	61,52
4	3660	50	88,01	98,07	61,49	95,56	88,73	61,65
4	3660	75	90,08	98,66	61,52	96,18	88,55	61,75
23	14860	100	98,13	99,85	96,61	96,24	94,97	96,90
23	14860	25	98,94	95,71	96,49	95,34	89,82	96,63
23	14860	50	98,60	96,58	96,55	95,62	91,97	96,74
23	14860	75	99,45	97,83	96,59	97,96	95,72	96,79
30	15960	100	94,88	95,56	99,95	91,58	90,68	99,69
30	15960	25	94,44	93,52	99,93	90,20	87,85	99,95
30	15960	50	95,25	93,76	99,99	92,07	88,78	99,77
30	15960	75	94,91	93,39	99,97	92,82	91,79	99,77
35	18560	100	88,06	86,15	91,81	85,84	82,68	91,57
35	18560	25	87,42	81,21	91,93	85,82	78,66	91,84
35	18560	50	86,92	82,61	91,87	84,24	79,19	91,70
35	18560	75	87,50	82,96	91,83	84,30	78,84	91,56
49	11660	100	88,21	94,45	86,60	88,32	98,22	86,84
49	11660	25	87,94	96,29	86,48	89,92	99,83	86,56
49	11660	50	87,04	94,10	86,54	88,80	98,86	86,74
49	11660	75	88,44	94,00	86,58	91,31	99,23	86,83
50	4560	100	72,28	73,58	64,38	75,71	74,54	64,69
50	4560	25	74,88	77,54	64,26	74,73	78,68	64,37
50	4560	50	76,14	79,18	64,32	80,70	76,27	64,54
50	4560	75	76,39	80,89	64,36	76,93	82,03	64,53
63	17060	100	96,13	96,88	96,50	96,95	97,98	96,28
63	17060	25	96,78	98,59	96,62	98,33	96,50	96,51
63	17060	50	96,16	98,60	96,56	97,29	99,82	96,36
63	17060	75	95,89	96,62	96,52	96,68	97,53	96,27
68	22460	100	85,78	94,35	79,60	85,32	94,29	79,39
68	22460	25	84,87	93,61	79,72	84,11	93,26	79,60
68	22460	50	85,85	93,85	79,66	85,58	93,68	79,45
68	22460	75	86,00	94,22	79,62	85,42	94,13	79,42
86	27360	100	68,73	79,79	64,26	68,83	79,80	64,08
86	27360	25	66,84	79,34	64,39	65,78	79,24	64,26
86	27360	50	68,11	79,63	64,33	67,58	79,65	64,14
86	27360	75	68,52	79,64	64,29	67,70	79,69	64,08
Média (%)			86,96	91,15	79,32	88,31	89,70	79,33

Fonte: Próprio Autor.

Tabela 5.7. Calçamento – Rede 12-50-1.

Barra	d (m)	Carga (%)	Acerto (%) - Média			Acerto (%) - Mediana		
			db4	db48	Haar	db4	db48	Haar
2	860	100	85,86	92,57	85,15	99,27	99,43	99,89
2	860	25	83,34	92,65	84,05	99,28	99,52	99,90
2	860	50	83,28	93,20	83,92	99,28	99,52	99,91
2	860	75	84,70	92,90	84,86	99,28	99,51	99,90
4	3660	100	86,64	94,46	80,17	98,18	99,05	82,51
4	3660	25	85,64	91,81	82,62	99,56	97,67	76,60
4	3660	50	84,96	93,30	77,36	97,87	99,81	80,50
4	3660	75	86,43	94,98	80,69	98,58	99,07	82,68
23	14860	100	96,19	95,82	95,95	92,62	92,48	94,77
23	14860	25	98,20	95,08	99,60	96,40	92,65	99,60
23	14860	50	97,14	96,00	97,87	95,06	93,18	94,76
23	14860	75	96,62	93,43	96,98	93,02	91,23	95,93
30	15960	100	92,68	93,20	92,12	89,08	89,59	91,00
30	15960	25	93,10	94,88	95,92	91,09	89,38	95,75
30	15960	50	93,27	94,84	93,93	90,76	90,27	90,89
30	15960	75	91,28	91,09	92,84	88,35	88,13	91,91
35	18560	100	85,25	82,64	84,55	81,58	80,40	83,46
35	18560	25	87,13	80,77	89,16	86,81	79,86	89,07
35	18560	50	85,62	82,18	86,32	83,21	80,34	83,31
35	18560	75	84,52	81,20	85,44	80,88	79,13	84,58
49	11660	100	92,19	95,81	93,37	94,84	98,61	94,28
49	11660	25	88,94	96,31	88,69	89,05	98,26	88,77
49	11660	50	88,83	95,14	90,95	89,07	97,03	93,76
49	11660	75	92,83	95,77	92,25	95,78	98,47	93,10
50	4560	100	72,80	76,78	70,30	74,66	77,06	72,04
50	4560	25	77,04	77,78	69,57	74,54	77,06	69,11
50	4560	50	78,73	80,22	70,33	81,21	77,95	73,64
50	4560	75	79,35	83,60	69,85	79,41	82,04	71,86
63	17060	100	95,82	90,33	97,55	96,21	86,41	99,01
63	17060	25	99,07	92,54	98,13	98,71	86,34	98,88
63	17060	50	98,64	92,41	99,10	98,68	88,53	98,21
63	17060	75	97,88	93,10	97,78	98,10	88,21	99,87
68	22460	100	90,24	97,46	87,17	89,90	97,33	86,06
68	22460	25	86,12	98,57	81,70	86,76	98,87	82,29
68	22460	50	87,37	96,27	85,08	87,61	96,13	82,81
68	22460	75	88,75	96,82	86,94	88,80	96,69	85,27
86	27360	100	75,56	94,27	72,79	75,26	94,85	71,85
86	27360	25	70,16	92,77	66,36	70,16	95,01	66,78
86	27360	50	73,79	96,28	70,06	74,38	97,48	68,01
86	27360	75	74,57	94,46	72,32	74,50	95,76	70,86
Média (%)			87,26	91,59	85,74	89,44	91,71	87,08

Fonte: Próprio Autor.

Tabela 5.8. Calçamento - Rede 12-50-20-1.

Barra	d (m)	Carga (%)	Acerto (%) - Média			Acerto (%) - Mediana		
			db4	db48	Haar	db4	db48	Haar
2	860	100	88,49	93,17	90,41	99,85	99,78	97,31
2	860	25	83,83	93,59	84,01	99,85	99,78	97,31
2	860	50	84,50	93,97	86,24	99,86	99,78	97,31
2	860	75	86,62	93,17	88,15	99,86	99,78	97,31
4	3660	100	89,05	94,18	87,66	99,61	99,72	90,75
4	3660	25	84,74	93,79	78,39	98,85	98,86	75,94
4	3660	50	85,42	94,32	77,04	98,18	99,19	77,66
4	3660	75	87,93	94,48	82,74	99,41	99,52	82,95
23	14860	100	94,32	94,05	91,74	91,93	91,87	88,78
23	14860	25	97,68	93,27	99,79	95,13	91,78	99,27
23	14860	50	96,14	94,59	97,66	92,50	92,02	96,53
23	14860	75	96,02	92,48	94,76	92,13	91,38	93,26
30	15960	100	90,97	91,04	87,64	88,51	88,99	84,64
30	15960	25	92,78	93,93	96,17	90,04	88,67	95,26
30	15960	50	91,99	93,67	93,67	88,52	89,52	92,65
30	15960	75	90,37	89,88	90,45	87,67	88,11	88,76
35	18560	100	83,90	81,53	80,38	81,43	80,11	77,50
35	18560	25	86,82	79,40	88,74	84,98	78,73	87,92
35	18560	50	84,45	80,32	86,18	81,05	79,15	85,15
35	18560	75	84,15	80,60	83,14	80,63	79,77	81,69
49	11660	100	95,03	97,06	97,27	96,87	98,68	99,87
49	11660	25	89,14	97,83	88,82	90,02	99,10	89,67
49	11660	50	91,64	96,98	91,07	92,92	98,26	91,89
49	11660	75	94,69	96,03	94,30	97,62	97,74	95,68
50	4560	100	74,60	78,93	73,71	75,10	77,69	76,18
50	4560	25	77,40	77,93	69,20	75,91	77,33	70,05
50	4560	50	79,90	80,92	70,73	80,22	78,97	72,30
50	4560	75	80,98	84,47	71,81	81,21	82,26	73,57
63	17060	100	94,64	92,65	92,35	95,19	89,19	91,94
63	17060	25	99,46	91,73	97,55	99,39	86,78	96,42
63	17060	50	98,46	90,32	99,56	98,13	86,61	98,88
63	17060	75	96,40	92,89	95,78	96,49	88,50	96,99
68	22460	100	93,59	94,78	93,71	92,54	92,61	94,01
68	22460	25	86,98	94,84	80,89	88,16	92,71	79,75
68	22460	50	89,35	93,62	84,98	89,28	90,94	83,33
68	22460	75	93,05	95,24	89,89	91,97	92,91	89,25
86	27360	100	80,15	96,70	79,99	79,91	97,51	80,27
86	27360	25	71,84	93,81	65,27	72,49	94,92	64,05
86	27360	50	77,04	97,28	70,12	77,35	98,25	68,74
86	27360	75	79,26	95,17	75,66	78,32	96,23	75,42
Média (%)			88,09	91,36	86,19	89,98	91,34	86,91

Fonte: Próprio Autor.

Tabela 5.9. Grama - Rede 12-1.

Barra	d (m)	Carga (%)	Acerto (%) - Média			Acerto (%) - Mediana		
			db4	db48	Haar	db4	db48	Haar
2	860	100	99,83	99,44	98,13	97,31	97,31	97,31
2	860	25	99,82	99,44	95,75	97,31	97,31	97,31
2	860	50	99,87	99,54	97,04	97,31	97,31	97,31
2	860	75	99,85	99,56	98,07	97,31	97,31	97,31
4	3660	100	97,78	93,92	78,10	88,69	88,55	80,28
4	3660	25	96,97	93,91	64,71	88,58	88,55	66,77
4	3660	50	96,74	94,19	67,66	88,63	88,55	69,19
4	3660	75	97,18	94,13	73,17	88,70	88,55	74,59
23	14860	100	94,22	95,25	97,56	95,78	95,93	97,33
23	14860	25	98,21	97,74	85,93	98,89	98,10	86,02
23	14860	50	95,10	96,66	89,84	94,11	98,15	89,91
23	14860	75	94,97	95,24	95,96	95,57	95,12	96,17
30	15960	100	97,08	91,85	93,47	98,85	94,69	93,50
30	15960	25	91,03	87,69	90,11	90,07	87,67	90,22
30	15960	50	90,93	86,77	94,35	88,72	83,92	94,58
30	15960	75	97,54	93,37	99,91	97,15	91,63	99,89
35	18560	100	93,70	85,02	85,92	93,62	83,96	85,79
35	18560	25	88,30	83,30	97,53	87,43	81,56	97,55
35	18560	50	91,74	83,64	98,46	90,21	81,92	98,23
35	18560	75	92,61	84,58	92,45	91,62	81,03	92,17
49	11660	100	79,53	84,25	91,97	80,27	85,29	92,12
49	11660	25	83,26	86,57	75,32	83,33	88,41	75,32
49	11660	50	82,89	86,31	79,57	83,63	87,04	79,68
49	11660	75	79,73	85,24	85,37	79,95	87,24	85,52
50	4560	100	94,03	94,26	99,57	85,73	85,73	94,66
50	4560	25	93,00	92,02	93,73	85,73	85,73	96,04
50	4560	50	93,84	94,21	96,83	85,73	85,73	92,87
50	4560	75	92,84	91,78	94,94	85,73	85,73	96,71
63	17060	100	90,44	93,80	92,28	90,71	93,92	92,25
63	17060	25	93,90	98,18	91,66	94,13	99,30	91,68
63	17060	50	93,45	97,40	95,74	93,59	97,62	95,78
63	17060	75	91,88	98,02	98,55	91,57	96,11	98,48
68	22460	100	93,41	98,35	75,50	93,58	98,33	75,50
68	22460	25	89,22	97,42	91,33	90,65	97,31	91,32
68	22460	50	91,27	97,82	87,57	91,47	97,83	87,48
68	22460	75	91,24	97,89	81,60	91,65	97,92	81,53
86	27360	100	76,96	83,47	60,11	77,14	83,49	60,08
86	27360	25	73,33	83,16	75,94	73,50	83,18	75,96
86	27360	50	74,88	83,28	72,13	74,75	83,29	72,04
86	27360	75	75,05	83,33	66,21	75,15	83,34	66,12
Média (%)			91,19	92,05	87,50	89,35	90,49	87,56

Fonte: Próprio Autor.

Tabela 5.10. Grama - Rede 12-50-1.

Barra	d (m)	Carga (%)	Acerto (%) - Média			Acerto (%) - Mediana		
			db4	db48	Haar	db4	db48	Haar
2	860	100	96,73	96,93	96,10	99,90	99,94	99,31
2	860	25	96,07	96,59	95,66	99,92	99,99	99,17
2	860	50	95,87	96,59	95,33	99,96	99,83	98,56
2	860	75	96,43	97,04	95,93	99,99	99,87	99,10
4	3660	100	92,59	93,03	92,06	97,78	97,36	97,04
4	3660	25	92,95	93,12	93,40	99,08	97,09	99,95
4	3660	50	93,52	93,63	93,76	98,23	97,77	99,04
4	3660	75	93,63	93,24	92,72	97,96	97,75	97,57
23	14860	100	98,53	96,56	98,97	98,18	95,68	98,22
23	14860	25	98,00	98,34	96,64	99,77	95,07	96,93
23	14860	50	99,18	97,40	98,72	97,37	95,01	99,24
23	14860	75	99,19	95,94	99,91	97,89	94,62	99,22
30	15960	100	94,54	94,56	92,19	94,24	93,76	92,04
30	15960	25	95,18	95,54	95,43	94,82	95,99	95,06
30	15960	50	95,65	95,71	92,45	94,56	95,67	90,78
30	15960	75	95,19	95,84	93,80	94,51	95,51	93,13
35	18560	100	85,77	87,71	87,27	85,41	87,97	86,91
35	18560	25	90,11	88,36	91,73	88,30	86,85	91,49
35	18560	50	87,61	89,04	89,16	86,33	88,07	88,30
35	18560	75	86,99	89,22	88,89	86,51	89,46	88,40
49	11660	100	94,83	93,20	87,65	96,09	94,35	87,71
49	11660	25	87,06	92,19	82,77	89,07	94,78	82,52
49	11660	50	90,01	93,22	85,89	91,91	95,27	86,37
49	11660	75	90,88	93,14	86,16	92,11	94,91	85,54
50	4560	100	94,94	95,96	95,19	99,47	99,47	99,48
50	4560	25	94,60	95,87	94,26	98,94	99,63	98,42
50	4560	50	94,20	95,56	95,14	99,20	99,77	99,84
50	4560	75	95,73	96,86	95,51	99,45	99,64	99,59
63	17060	100	86,99	93,89	89,67	86,72	89,54	90,43
63	17060	25	89,82	90,53	93,52	89,16	87,42	93,67
63	17060	50	91,59	91,59	92,29	91,49	88,17	92,62
63	17060	75	88,81	91,72	90,40	87,33	89,13	90,73
68	22460	100	98,16	92,50	96,16	97,87	92,61	95,60
68	22460	25	93,01	90,57	90,02	94,18	90,03	89,90
68	22460	50	96,88	92,94	94,03	98,23	92,51	93,08
68	22460	75	96,68	91,58	95,11	98,10	91,51	94,50
86	27360	100	84,79	93,54	82,09	85,70	94,01	81,69
86	27360	25	77,63	91,58	75,77	78,66	92,18	75,45
86	27360	50	81,07	91,32	80,27	82,53	92,08	79,43
86	27360	75	81,21	92,86	81,73	83,19	93,23	81,69
Média (%)			92,32	93,63	91,59	93,75	94,34	92,69

Fonte: Próprio Autor.

Tabela 5.11. Grama - Rede 12-50-20-1.

Barra	d (m)	Carga (%)	Acerto (%) - Média			Acerto (%) - Mediana		
			db4	db48	Haar	db4	db48	Haar
2	860	100	97,18	97,09	96,91	100,00	99,96	99,52
2	860	25	96,27	96,93	96,86	99,99	99,96	99,52
2	860	50	96,24	96,88	96,30	100,00	99,97	99,80
2	860	75	96,89	97,35	96,68	100,00	99,96	99,73
4	3660	100	92,72	93,17	92,86	97,91	97,37	96,79
4	3660	25	92,84	93,78	93,83	98,35	97,71	98,92
4	3660	50	93,90	93,71	94,22	98,19	97,75	98,71
4	3660	75	93,93	93,64	93,66	98,06	97,67	97,57
23	14860	100	98,58	96,11	96,54	99,42	95,16	95,40
23	14860	25	98,79	98,21	96,66	99,36	94,85	97,32
23	14860	50	98,08	96,89	99,79	97,05	94,82	98,79
23	14860	75	98,46	95,59	97,64	98,70	94,84	96,84
30	15960	100	93,85	93,76	90,97	94,43	93,26	90,94
30	15960	25	96,10	95,68	96,47	95,80	96,35	96,01
30	15960	50	96,62	95,35	94,01	95,92	95,59	93,37
30	15960	75	95,59	95,16	94,11	95,92	95,24	93,83
35	18560	100	86,69	87,52	84,71	86,82	88,22	84,00
35	18560	25	90,02	88,63	91,85	88,27	87,40	90,96
35	18560	50	87,40	88,56	87,94	86,62	88,30	87,16
35	18560	75	87,26	88,59	85,61	87,29	88,83	84,95
49	11660	100	95,07	93,70	91,49	95,71	95,01	93,02
49	11660	25	88,00	92,92	83,25	90,23	95,32	83,58
49	11660	50	91,53	93,64	88,30	93,13	95,32	89,17
49	11660	75	93,42	93,45	91,49	94,15	94,70	92,77
50	4560	100	95,66	96,17	95,23	99,97	99,43	99,68
50	4560	25	94,99	96,55	95,46	99,50	99,77	99,64
50	4560	50	94,70	95,75	95,20	99,35	99,76	99,70
50	4560	75	96,20	96,88	95,89	99,97	99,62	99,67
63	17060	100	87,42	94,79	88,20	86,89	90,51	88,50
63	17060	25	90,21	90,41	94,21	89,73	87,62	94,61
63	17060	50	91,58	91,29	92,75	90,64	88,24	94,04
63	17060	75	89,52	91,54	90,25	88,48	89,49	89,49
68	22460	100	97,13	93,11	98,81	96,88	92,89	98,70
68	22460	25	93,55	94,22	90,31	94,65	93,75	89,48
68	22460	50	98,34	93,05	96,11	98,77	92,31	94,64
68	22460	75	97,63	91,14	96,76	98,77	90,38	97,22
86	27360	100	87,42	94,77	87,92	88,02	95,09	88,30
86	27360	25	79,76	92,58	76,77	80,57	93,53	75,22
86	27360	50	84,47	92,97	83,17	84,96	93,95	82,20
86	27360	75	83,32	93,67	85,02	85,64	94,23	86,68
Média (%)			92,93	93,88	92,36	94,35	94,60	93,41

Fonte: Próprio Autor.

Tabela 5.12. Terra - Rede 12-1.

Barra	d (m)	Carga (%)	Acerto (%) - Média			Acerto (%) - Mediana		
			db4	db48	Haar	db4	db48	Haar
2	860	100	81,82	89,64	78,30	83,37	99,48	73,99
2	860	25	82,60	90,10	76,35	85,81	99,23	69,18
2	860	50	82,38	90,17	76,45	84,06	99,89	69,84
2	860	75	82,55	90,80	77,75	84,56	99,80	72,24
4	3660	100	73,82	83,58	72,28	70,17	82,24	70,00
4	3660	25	73,39	83,51	66,15	70,79	82,67	64,77
4	3660	50	72,33	82,87	66,93	72,11	86,08	66,30
4	3660	75	72,23	83,71	68,86	71,98	86,05	68,44
23	14860	100	97,06	95,97	99,01	95,12	93,56	99,91
23	14860	25	95,90	95,70	94,36	95,30	94,21	93,71
23	14860	50	96,45	95,63	96,16	95,21	94,21	95,18
23	14860	75	96,14	95,52	98,02	94,91	93,40	97,26
30	15960	100	90,58	91,80	89,02	99,93	96,77	97,22
30	15960	25	92,21	93,75	95,04	97,32	96,56	97,03
30	15960	50	91,98	92,06	93,99	98,18	96,47	98,46
30	15960	75	91,04	92,07	91,32	97,54	96,41	99,90
35	18560	100	89,75	90,33	86,40	94,26	95,36	89,58
35	18560	25	88,40	89,28	91,17	94,54	95,39	95,10
35	18560	50	91,71	91,61	92,31	94,56	95,70	94,29
35	18560	75	88,74	89,38	87,80	93,31	95,29	91,68
49	11660	100	83,55	82,42	88,30	83,53	82,47	88,39
49	11660	25	83,53	82,44	82,23	83,53	82,35	82,29
49	11660	50	83,58	82,44	83,76	83,57	82,44	83,80
49	11660	75	83,55	82,42	85,92	83,52	82,46	85,93
50	4560	100	76,59	78,88	77,12	66,80	65,34	70,79
50	4560	25	77,31	79,41	72,76	69,69	67,36	66,08
50	4560	50	76,55	79,14	73,55	67,24	67,34	66,63
50	4560	75	75,04	77,93	74,14	67,07	65,35	68,79
63	17060	100	97,82	97,22	93,53	98,99	99,67	94,12
63	17060	25	97,36	96,65	98,84	98,89	99,68	99,66
63	17060	50	97,59	96,97	97,70	99,20	99,81	98,89
63	17060	75	97,43	96,35	95,57	99,14	99,95	96,84
68	22460	100	81,63	83,62	76,85	82,37	83,65	77,41
68	22460	25	80,80	83,23	81,65	82,45	83,57	82,89
68	22460	50	81,21	83,33	80,65	82,41	83,52	82,23
68	22460	75	80,99	83,45	78,52	82,22	83,58	79,92
86	27360	100	63,68	68,15	59,07	66,85	68,26	61,92
86	27360	25	63,66	68,05	64,30	67,16	68,39	67,80
86	27360	50	62,99	68,24	62,58	67,08	68,29	66,85
86	27360	75	63,28	68,04	60,84	66,94	68,23	64,65
Média (%)			85,12	86,15	82,14	85,41	87,01	82,25

Fonte: Próprio Autor.

Tabela 5.13. Terra - Rede 12-50-1.

Barra	d (m)	Carga (%)	Acerto (%) - Média			Acerto (%) - Mediana		
			db4	db48	Haar	db4	db48	Haar
2	860	100	83,86	88,91	80,11	83,24	89,97	77,69
2	860	25	82,89	87,57	78,28	81,54	87,63	71,86
2	860	50	83,68	88,29	78,98	81,97	88,78	73,77
2	860	75	84,22	89,42	80,11	83,14	89,71	76,40
4	3660	100	79,56	87,28	75,86	77,87	89,48	74,08
4	3660	25	76,73	87,54	71,59	76,54	91,80	70,42
4	3660	50	77,73	86,11	71,91	78,19	91,80	72,33
4	3660	75	78,41	87,25	73,17	79,26	91,25	74,21
23	14860	100	99,74	98,47	99,21	98,00	96,59	96,70
23	14860	25	94,10	99,84	97,25	93,84	96,06	96,20
23	14860	50	96,70	99,35	97,34	94,01	97,32	96,48
23	14860	75	97,54	97,32	97,07	97,61	94,74	95,63
30	15960	100	88,50	89,14	90,68	91,57	88,91	95,96
30	15960	25	93,40	92,05	94,26	94,98	90,80	99,95
30	15960	50	91,10	90,66	93,74	93,30	89,92	99,44
30	15960	75	86,58	87,49	92,16	88,89	88,39	98,62
35	18560	100	83,99	82,56	88,46	83,92	79,66	92,47
35	18560	25	83,98	80,97	88,89	85,54	80,80	92,04
35	18560	50	84,36	81,33	89,95	83,99	80,45	91,87
35	18560	75	83,86	81,66	88,20	83,73	80,04	91,76
49	11660	100	94,19	96,85	85,57	94,22	98,39	84,44
49	11660	25	88,76	95,42	85,07	91,20	96,76	84,60
49	11660	50	94,38	94,99	86,04	93,95	96,89	85,92
49	11660	75	92,70	94,82	85,20	94,18	97,85	84,27
50	4560	100	75,32	76,37	75,75	72,08	75,66	72,79
50	4560	25	75,34	76,00	73,68	71,77	74,95	69,87
50	4560	50	73,34	75,95	73,83	70,03	75,73	69,12
50	4560	75	74,62	79,34	73,65	71,38	76,36	69,98
63	17060	100	95,32	94,24	99,07	91,67	92,40	99,96
63	17060	25	95,58	95,05	96,54	92,61	93,11	97,95
63	17060	50	96,29	94,63	98,11	94,30	91,13	97,95
63	17060	75	95,39	91,45	98,60	91,58	89,11	99,98
68	22460	100	92,34	94,92	82,21	94,86	93,71	83,40
68	22460	25	86,02	99,32	79,58	86,09	98,01	81,17
68	22460	50	89,55	99,77	81,36	91,12	98,44	81,29
68	22460	75	86,60	99,09	82,25	86,59	98,09	83,41
86	27360	100	68,02	86,53	63,64	69,51	92,13	67,70
86	27360	25	68,16	87,16	63,06	69,17	93,39	65,95
86	27360	50	69,17	88,45	62,81	71,63	92,40	65,45
86	27360	75	68,32	87,00	63,77	71,06	92,77	67,88
Média (%)			86,03	89,76	83,42	85,57	90,03	83,77

Fonte: Próprio Autor.

Tabela 5.14. Terra - Rede 12-50-20-1.

Barra	d (m)	Carga (%)	Acerto (%) - Média			Acerto (%) - Mediana		
			db4	db48	Haar	db4	db48	Haar
2	860	100	85,28	89,53	83,56	84,08	91,63	82,98
2	860	25	85,34	88,89	81,39	85,42	90,51	78,46
2	860	50	86,34	89,66	82,33	85,79	91,02	80,27
2	860	75	86,09	90,42	83,85	84,95	91,61	82,55
4	3660	100	81,03	87,19	77,79	79,66	88,19	77,16
4	3660	25	78,49	88,11	74,23	79,30	91,43	72,76
4	3660	50	80,76	87,55	75,54	80,45	92,02	75,78
4	3660	75	81,12	88,29	76,73	81,28	90,98	77,18
23	14860	100	98,66	97,20	99,53	98,29	94,91	99,13
23	14860	25	94,35	99,24	97,72	94,12	96,22	96,74
23	14860	50	98,37	97,67	98,06	97,68	95,97	97,15
23	14860	75	99,31	96,27	99,08	99,84	93,46	98,57
30	15960	100	86,97	88,60	89,50	89,80	89,07	92,08
30	15960	25	94,60	93,38	94,73	96,19	91,48	99,78
30	15960	50	90,42	90,73	93,57	92,18	89,56	97,30
30	15960	75	85,99	87,97	89,43	87,82	88,88	91,27
35	18560	100	84,44	82,62	86,74	85,81	80,89	88,78
35	18560	25	85,73	81,38	89,29	86,56	81,30	91,52
35	18560	50	82,84	81,12	88,35	82,86	80,62	89,37
35	18560	75	83,66	82,13	86,03	83,81	80,76	88,13
49	11660	100	95,52	97,03	89,12	94,77	97,41	87,88
49	11660	25	88,81	95,12	85,22	90,49	96,28	84,40
49	11660	50	95,33	95,86	88,85	95,42	97,29	87,36
49	11660	75	94,52	95,51	89,72	95,30	97,24	88,02
50	4560	100	75,64	77,44	75,51	73,55	77,02	72,11
50	4560	25	75,54	75,58	73,63	71,67	73,66	69,32
50	4560	50	73,56	76,48	73,73	71,39	76,72	70,09
50	4560	75	75,22	79,27	73,86	72,73	77,16	70,73
63	17060	100	93,90	95,30	98,82	91,47	94,46	98,95
63	17060	25	98,32	95,19	96,34	96,27	93,68	98,21
63	17060	50	96,40	94,92	99,55	93,82	91,48	99,56
63	17060	75	94,72	92,36	99,90	91,82	90,35	99,49
68	22460	100	94,74	95,41	86,07	96,22	93,65	86,06
68	22460	25	87,28	99,79	81,63	87,17	96,58	82,37
68	22460	50	91,84	98,53	83,82	94,14	97,10	82,95
68	22460	75	88,39	97,83	85,11	88,89	95,75	85,36
86	27360	100	71,22	87,59	67,83	73,62	93,63	69,65
86	27360	25	70,24	88,33	65,68	71,66	92,29	67,22
86	27360	50	71,77	90,73	66,30	74,92	93,51	66,94
86	27360	75	71,52	89,51	67,61	74,38	94,96	69,18
Média (%)			86,82	90,14	84,90	86,64	90,27	84,82

Fonte: Próprio Autor.

Os resultados das Tabelas 5.3 a 5.14 confirmam que a melhor configuração de RNA é a 12-50-20-1, com os CW determinados pela *wavelet* Daubechies 48. Para esse melhor caso, na Tabela 5.15 tem-se uma síntese dos resultados.

Tabela 5.15. Síntese dos resultados – Melhor caso.

	Média (%)	Mediana (%)
Areia	91,95	92,29
Calçamento	91,36	91,34
Gramma	93,88	94,60
Terra	90,14	90,27

Fonte: Próprio Autor.

Em função da grande base de dados e variedade de situações, pode-se considerar os resultados satisfatórios. Porém algumas observações devem ser feitas:

- Analisando-se as Tabelas, nota-se que grande parte dos acertos “ruins” estão principalmente na Barra 86, distante mais de 27,36 km da subestação (consistiram na maior parte dos resultados sombreados). COSTA (2011) não conseguiu detectar faltas a essa distância da subestação, com maior destaque para as de maior impedância como a terra local e calçamento.
- Margens de acertos baixas em alguns casos foram verificadas na Barra 50, localizada a 4,56 km da subestação. Apesar de estar relativamente próxima a subestação, trata-se de uma barra cuja distância é muito aproximada de outras localizadas em seções diferentes (Barras 6, 10, 38 e 45).
- Casos de FAI que acarretaram maiores erros dificilmente seriam detectados. Os resultados percentuais indicam: se a falta for possível de ser detectada, terá as margens de acerto que constam nas Tabelas. Os

maiores erros contribuíram para diminuir a média. Aliado a um detector confiável, a RNA pode fornecer melhores resultados; com uma média mais alta.

- A mediana para indicação da localização é melhor que a média para cada registro.
- Não foi observada nenhuma regularidade do acerto com o carregamento. Porém, na maioria dos casos, quanto maior a carga, maior será o acerto percentual.
- A *wavelet* Daubechies 48 apresentou melhores resultados porque sua resposta em frequência captou melhor as componentes dos transitórios. Vale salientar que a banda passante estava limitada a 3 kHz.

Na Figura 5.8 a seguir, tem-se o comportamento do acerto (média e mediana) para as superfícies utilizadas nas simulações, com 100% de carregamento. É notado que os acertos são maiores, quanto mais próximo da subestação ocorrer a FAI. Além da distância, um fator preponderante é a existência de muitas ramificações próximas ao ponto da falta.

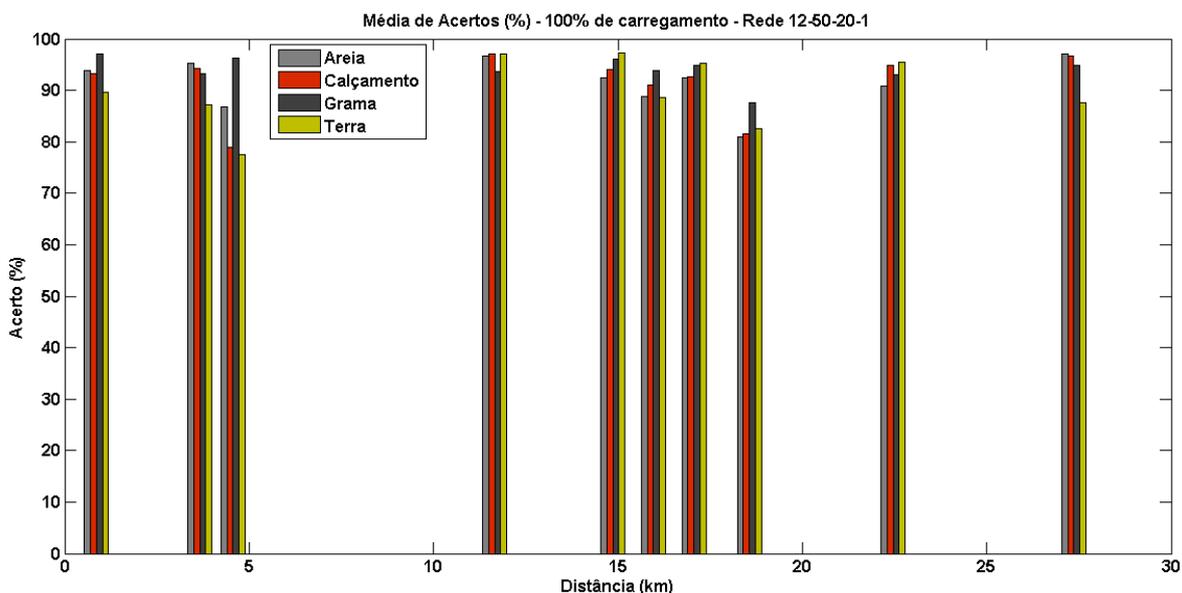


Figura 5.8. Média de acertos – 100% de carregamento (Fonte: Próprio Autor).

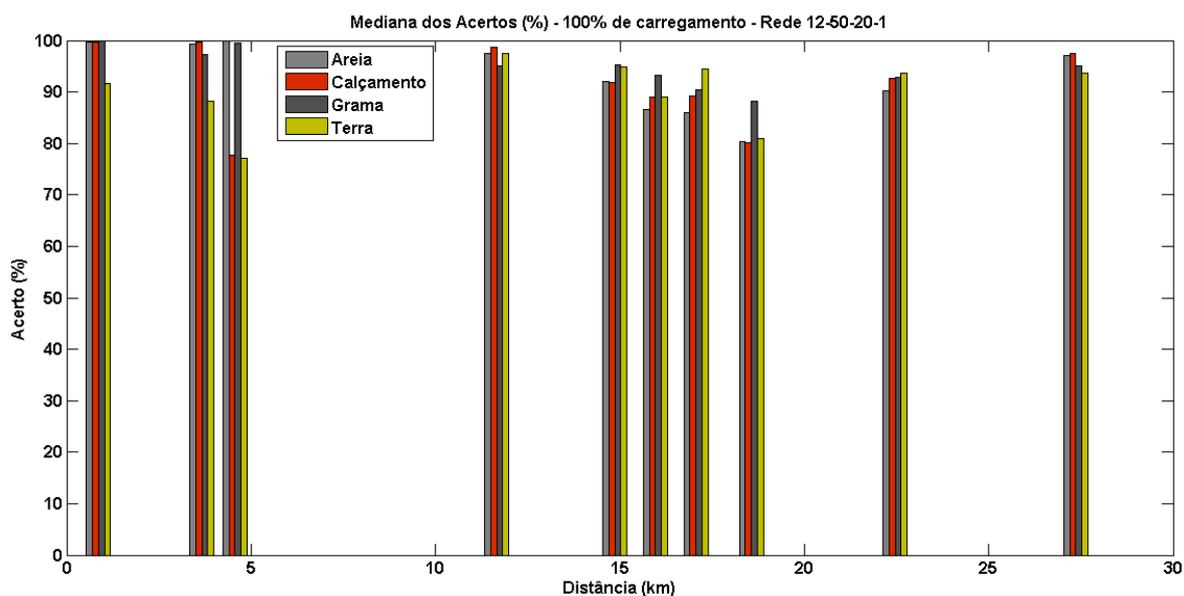


Figura 5.9. Mediana dos acertos – 100% de carregamento (Fonte: Próprio Autor).

5.3.1 Dados Reais

A RNA que apresentou melhores resultados foi submetida a dados reais colhidos na superfície de areia, molhada e seca. O RDP estava conectado a 11 km das FAI ocorridas. Na Figura 5.10 a seguir é ilustrada uma FAI real ocorrida na superfície, com uma síntese dos dados nas Tabelas 5.16 e 5.17.

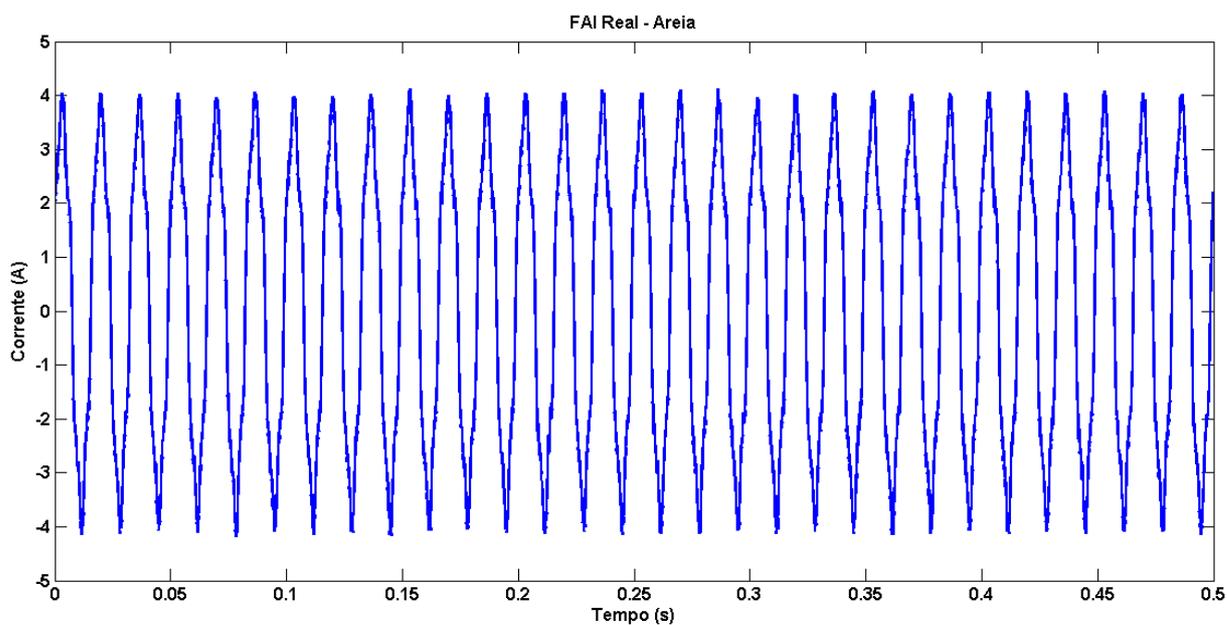


Figura 5.10. Exemplo de uma FAI real na areia (Fonte: Próprio Autor).

Tabela 5.16. Resultados FAI Reais – Areia Seca.

Areia Seca		
Arquivo	Acerto - Média (%)	Acerto - Mediana (%)
areias1.dat	95,61	95,67
areias2.dat	95,47	95,60
areias3.dat	95,64	95,74
areias4.dat	95,76	95,79
areias5.dat	95,51	95,66
Média	95,60	95,69

Fonte: Próprio Autor.

Tabela 5.17. Resultados FAI Reais – Areia Molhada.

Areia Molhada		
Arquivo	Acerto - Média (%)	Acerto - Mediana (%)
areiam1.dat	95,67	95,68
areiam2.dat	95,65	95,70
areiam3.dat	95,63	95,63
areiam4.dat	99,97	100,00
areiam5.dat	99,74	99,59
Média	97,34	97,32

Fonte: Próprio Autor.

Analisando-se as Tabelas 5.16 e 5.17, verifica-se que a RNA treinada (melhor caso) foi capaz de localizar FAI reais. Escolheu-se os casos que ocorreram na areia porque foram os possíveis de se detectar quando da execução do P&D objeto da Tese.

5.3.2 Inicializações da Rede

Para a RNA que apresentou melhor resultado na localização (Daubechies 48 - 12-50-20-1), foi efetuada uma inicialização adicional na mesma de modo a verificar se os resultados obtidos apresentam a mesma consistência. Na Tabela 5.18 estão apresentados testes das inicializações para a localização de FAI para a superfície de areia. Uma síntese dos resultados em relação aos erros médios é apresentada na Tabela 5.19.

Tabela 5.18. Resultados com as inicializações.

Barra	d (m)	Carga (%)	Acerto Média (%)		Acerto Mediana (%)	
			1	2	1	2
2	860	100	93,85	94,58	99,74	99,98
2	860	25	93,75	94,63	99,81	99,94
2	860	50	94,55	95,37	99,76	99,95
2	860	75	94,95	95,48	99,75	99,95
4	3660	100	95,28	95,87	99,38	99,49
4	3660	25	95,07	95,55	99,49	99,38
4	3660	50	95,33	95,89	99,39	99,29
4	3660	75	96,16	96,49	99,37	99,41
23	14860	100	92,41	92,62	91,97	91,92
23	14860	25	94,00	94,59	93,12	93,41
23	14860	50	93,28	93,60	92,82	92,98
23	14860	75	92,88	93,28	92,23	92,42
30	15960	100	88,72	89,13	86,63	86,51
30	15960	25	92,01	92,67	89,11	89,40
30	15960	50	92,45	92,68	87,35	87,74
30	15960	75	90,75	91,08	86,76	87,79
35	18560	100	80,94	81,07	80,35	80,33
35	18560	25	81,21	81,37	80,89	80,74
35	18560	50	81,59	81,98	81,41	81,74
35	18560	75	80,93	81,11	80,13	80,53
49	11660	100	96,61	96,51	97,51	97,47
49	11660	25	97,03	96,31	97,57	97,09
49	11660	50	96,88	96,54	97,04	96,86
49	11660	75	96,22	95,91	97,76	97,17
50	4560	100	86,80	86,85	99,94	98,82
50	4560	25	90,24	90,04	99,04	99,39
50	4560	50	85,67	85,30	80,23	81,30
50	4560	75	82,36	82,24	78,10	78,12
63	17060	100	92,35	92,84	85,99	87,30
63	17060	25	90,37	90,66	86,80	86,40
63	17060	50	90,90	91,08	86,31	85,92
63	17060	75	91,57	91,63	85,89	85,91
68	22460	100	90,73	90,52	90,31	90,37
68	22460	25	92,43	92,58	91,45	91,91
68	22460	50	93,37	93,23	93,13	93,31
68	22460	75	91,52	91,33	90,83	90,60
86	27360	100	97,00	96,41	96,98	97,04
86	27360	25	98,23	98,20	99,21	99,02
86	27360	50	99,69	98,93	99,57	99,24
86	27360	75	97,94	97,72	98,34	98,46
Média (%)			91,95	92,10	92,29	92,36

Fonte: Próprio Autor.

Tabela 5.19. Inicializações da RNA com melhor resultado.

Inicialização 1		Inicialização 2	
Épocas	Erro	Épocas	Erro
28768	0,021	30000	0,022

Fonte: Próprio Autor.

Conforme observado na Tabela 5.18, com uma nova inicialização os resultados foram muito aproximados. A mudança consistiu apenas nos valores iniciais aos quais os pesos dos neurônios foram submetidos. Observa-se também que não houve a parada por erro de validação, como na primeira inicialização. É notado que o resultado da segunda simulação foi ligeiramente superior.

5.4 Resultados da SOM

Após a apresentação das bases de dados e rótulos adotados no Capítulo 4, são apresentados nessa seção alguns resultados para diversas arquiteturas adotadas para a SOM classificadora de setor. Para cada superfície envolvida, foram avaliadas 15 arquiteturas, dependentes de um fator k , cuja correspondência com as dimensões da grade está expressa na Tabela 5.20.

Tabela 5.20. Relação do fator k com as dimensões da SOM.

k	Dimensões
1	10x10
2	15x15
3	20x20
4	25x25
5	30x30
6	35x35
7	40x40
8	45x45
9	50x50
10	55x55
11	60x60
12	65x65
13	70x70
14	75x75
15	80x80

Fonte: Próprio Autor.

A avaliação quantitativa foi realizada com base em dois parâmetros: o erro de quantização (E_q) e a margem de acerto de classificação. O erro de quantização é definido como a média do erro correspondente à diferença entre o vetor de características x_i (dimensão n) e o vetor de pesos sinápticos w_{BMU} , correspondente ao neurônio vencedor no processo competitivo (KOHONEN, 2000):

$$E_q = \frac{\sum_{i=1}^n \|x_i - w_{BMU}\|}{n}. \quad (5.1)$$

A margem de acerto de classificação é dada pela razão entre os padrões classificados corretamente e o total de padrões.

Nas Figuras 5.11 a 5.18 a seguir são apresentadas as margens de acerto e erros de quantização da SOM para as superfícies da base de dados, para cada *wavelet* adotada.

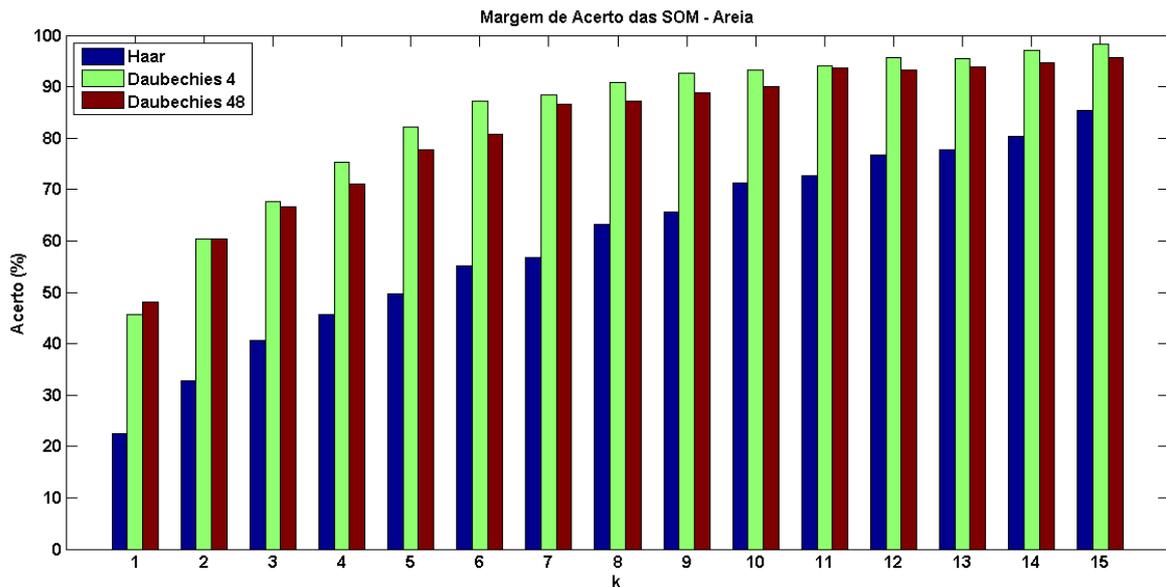


Figura 5.11. Acerto das SOM – Areia (Fonte: Próprio Autor).

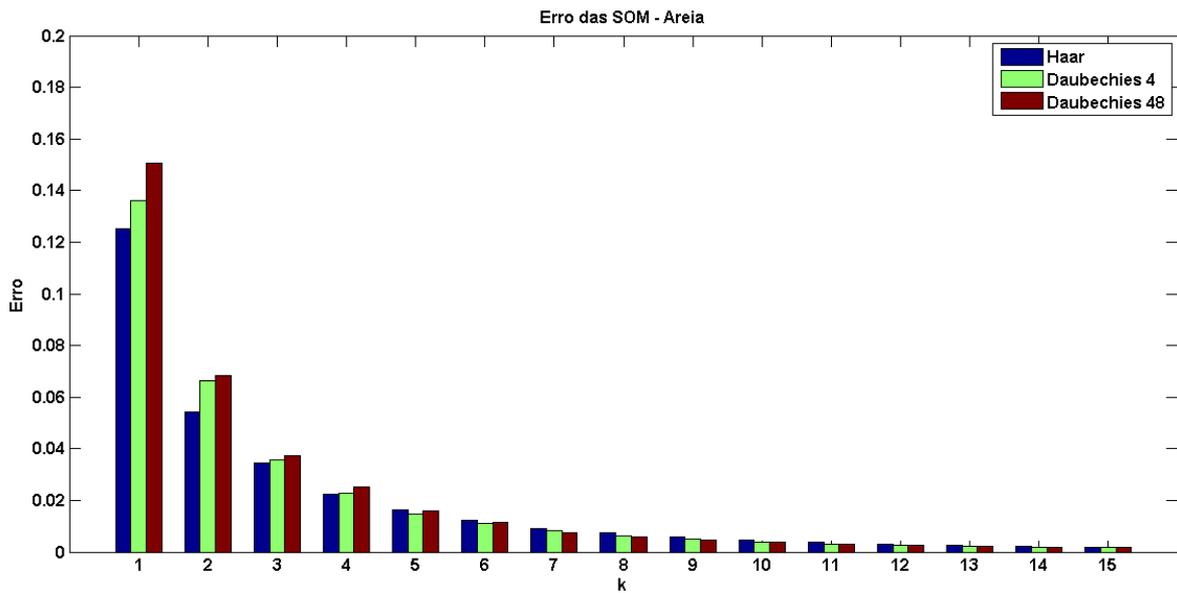


Figura 5.12. Erro quadrático das SOM - Areia (Fonte: Próprio Autor).

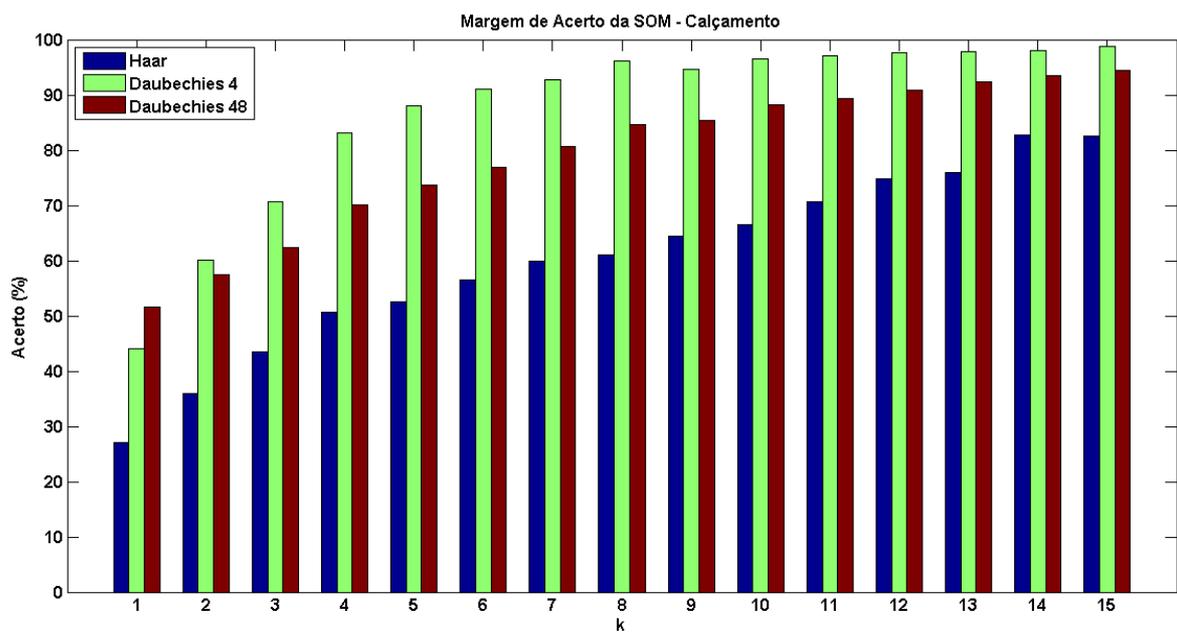


Figura 5.13. Acerto das SOM - Calçamento (Fonte: Próprio Autor).

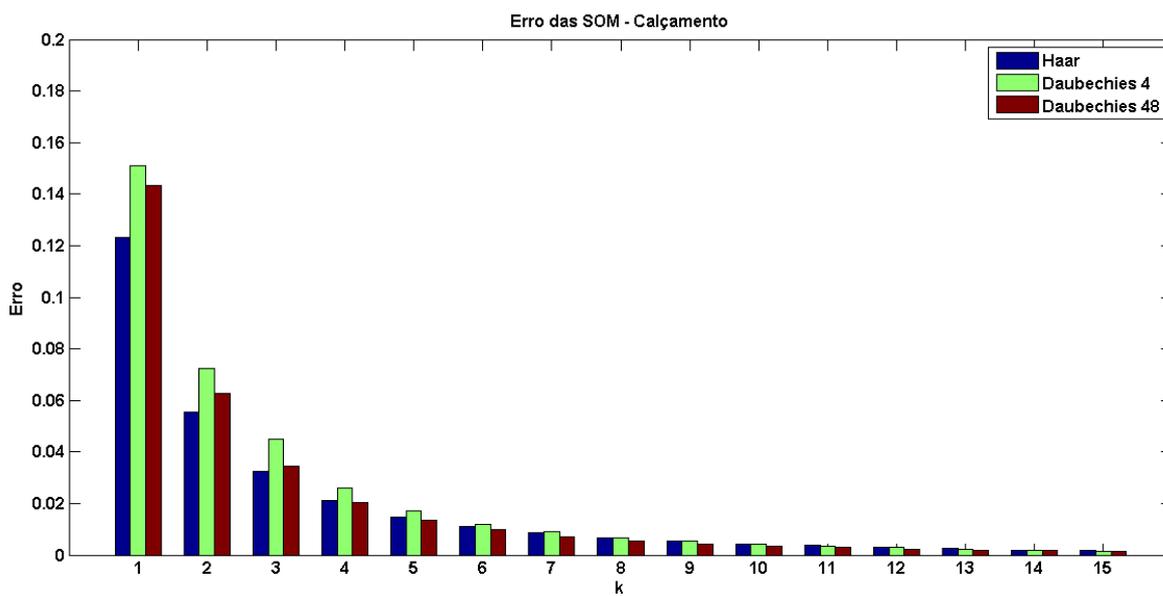


Figura 5.14. Erro quadrático das SOM - Calçamento (Fonte: Próprio Autor).

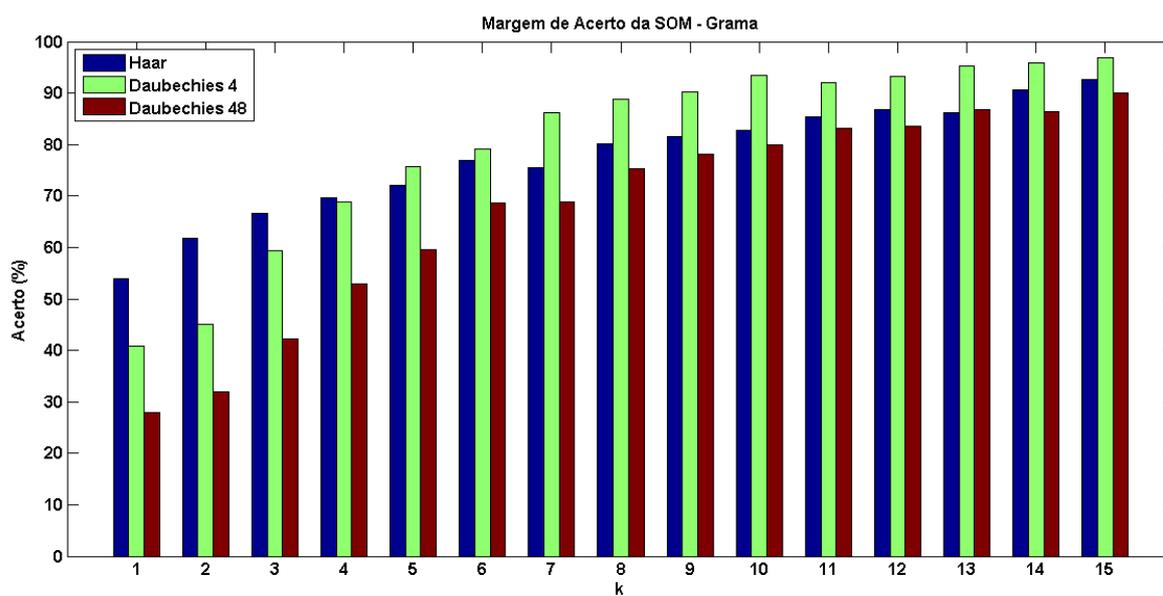


Figura 5.15. Acerto das SOM - Grama (Fonte: Próprio Autor).

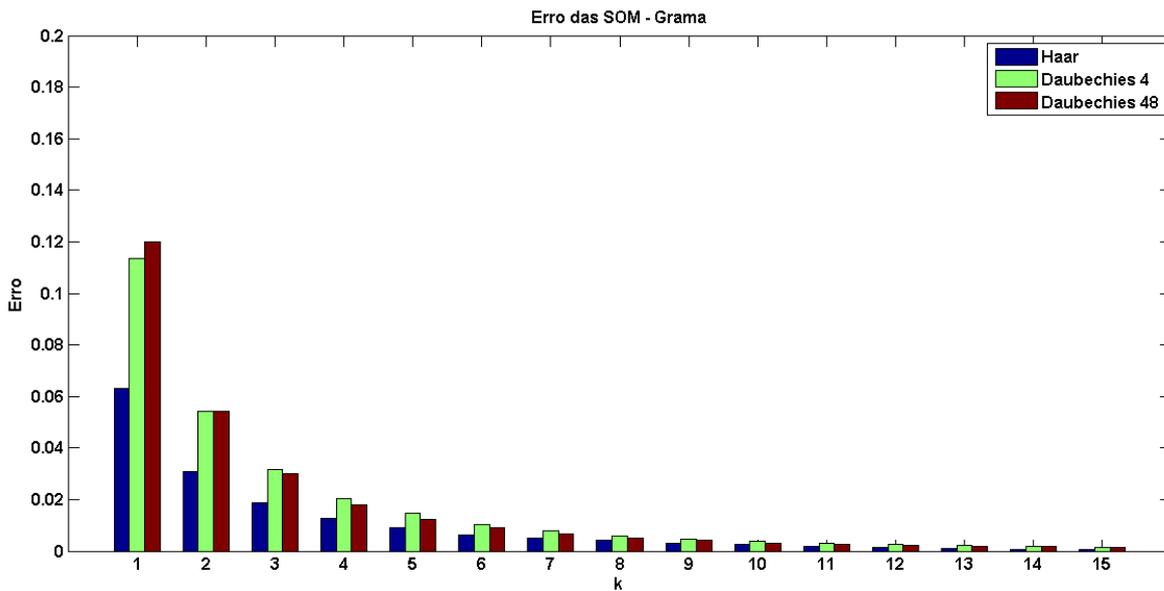


Figura 5.16. Erro quadrático das SOM - Grama (Fonte: Próprio Autor).

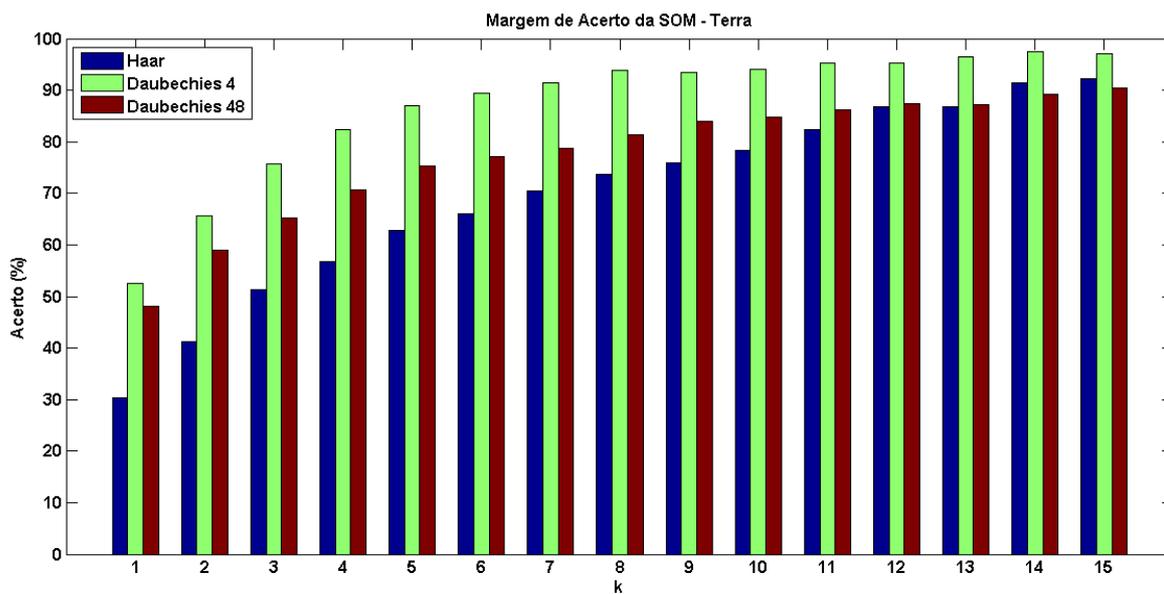


Figura 5.17. Acerto das SOM - Terra (Fonte: Próprio Autor).

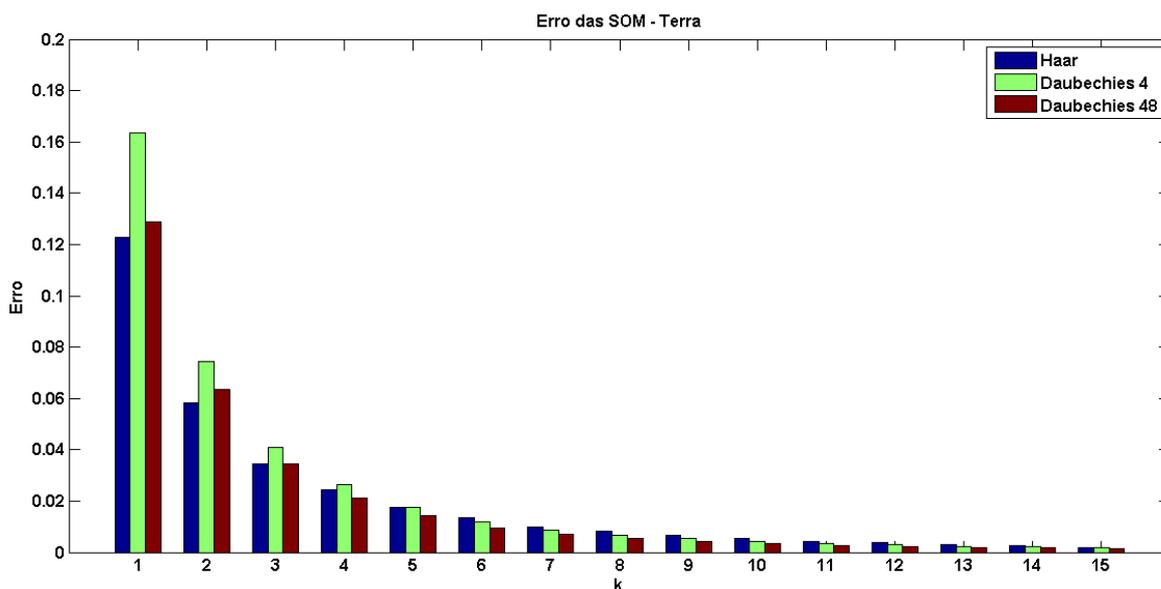


Figura 5.18. Erro quadrático das SOM - Terra (Fonte: Próprio Autor).

Analisando-se os erros médios quadráticos, é observado que os mesmos são inversamente proporcionais ao número de neurônios da grade. As superfícies terra e calçamento apresentaram erros maiores, em função de sua maior impedância e menor corrente de falta, dificultando assim as etapas de detecção e localização. A partir de $k = 8$ (grade 45x45), para todas as superfícies o erro é visivelmente inferior a 0,02, havendo uma ligeira estabilização do mesmo com o aumento das dimensões. Foi verificado também que será praticamente o mesmo para as *wavelets* adotadas. Quanto mais próximo for o erro do zero, maior será a adaptação da SOM à base de dados do treinamento.

Relativo aos acertos, foi observado que são diretamente proporcionais ao número de neurônios da SOM e a partir da configuração 45x45, são da ordem de 90%. Para a configuração 80x80 são superiores a 95% em todas as superfícies quando se opta pela *wavelet* Daubechies 4. Ao contrário da localização da distância para a subestação, em que os melhores resultados vieram com a Daubechies 48, para determinação do setor as frequências mais destacadas no filtro *wavelet* da Daubechies 48 não são os mais relevantes. Conforme análise das respostas em frequências, conclui-se que as componentes de baixas frequências entre 0 e $f_s/4$ foram mais relevantes para determinação do setor.

A análise qualitativa também é facilitada com o auxílio do mapa neural apresentado na Figura 5.19 para $k = 1$ (grade 10x10). Escolheu-se a grade de 100 neurônios para efeito demonstrativo da identificação dos *clusters*, com a identificação espacial destacada de cada rótulo que corresponde a um setor do alimentador.

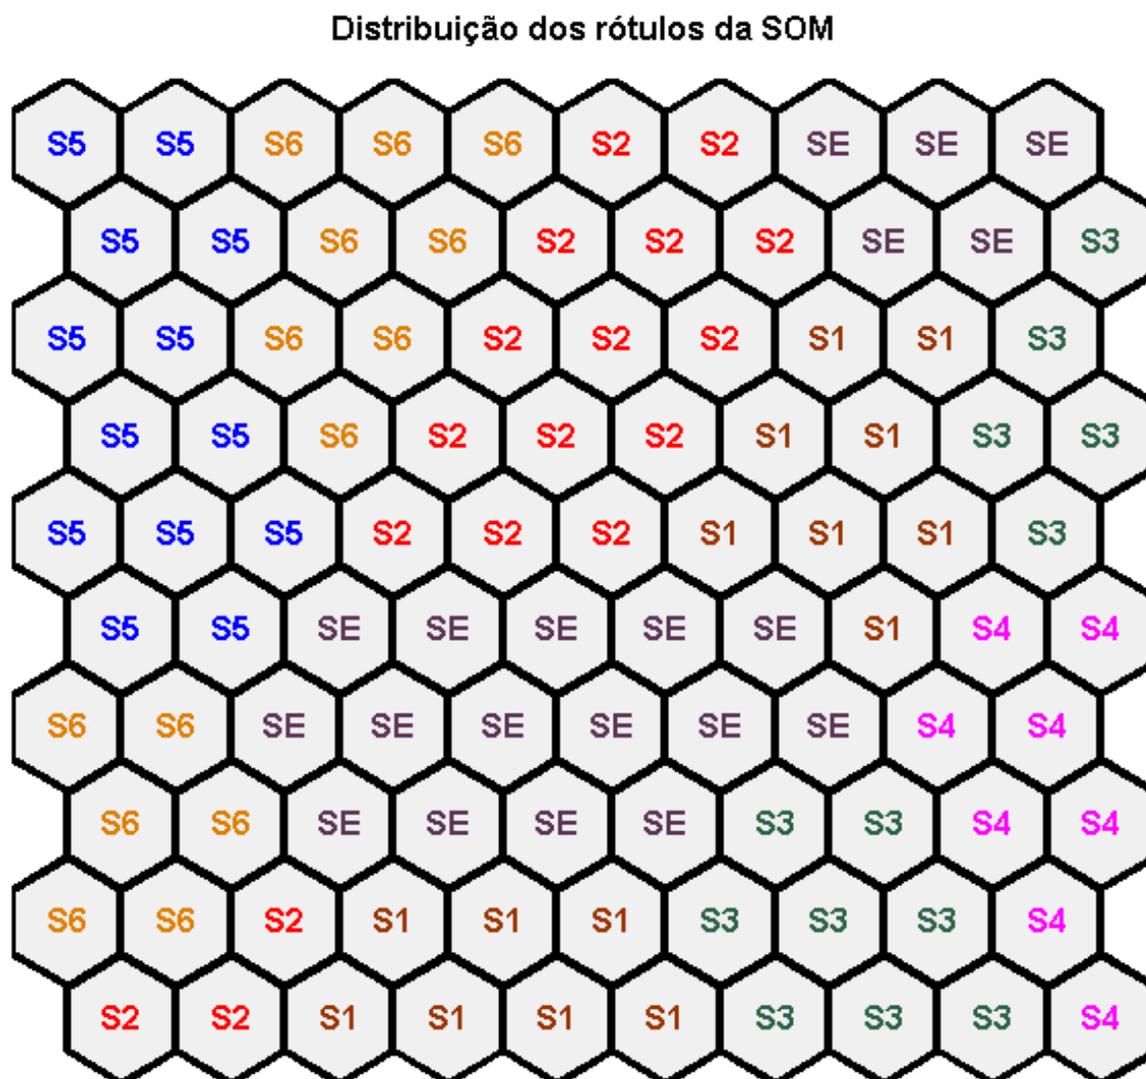


Figura 5.19. Mapa Neural da SOM para a base de dados testada
(Fonte: Próprio Autor).

Capítulo 6

Conclusões e Perspectivas de Trabalhos Futuros

6.1 Conclusões

Foi proposto no presente trabalho um localizador de FAI para sistemas de distribuição baseado em dois aspectos: determinação da localização da distância para a subestação, além do setor do alimentador. Tornaram-se necessárias duas indicações devido à característica de ramificações dos alimentadores. Para prover as indicações foram utilizadas RNA, adotando-se como dados de entrada as correntes trifásicas e a energia dos CW da fase com falta.

Para determinação dos modelos de FAI e aquisição de dados para futuros testes no localizador, foram realizados experimentos de campo com a provocação de FAI em algumas superfícies em um alimentador real na cidade de Boa Vista-PB. O sistema foi modelado no ATP e as redes neurais no MATLAB.

Para teste e validação da técnica proposta, foi construída uma base de dados contemplando a variação de algumas características, como: local da falta, superfície, ângulo de incidência, carregamento do sistema, *wavelet* utilizada para o

cálculo da energia dos CW. Vale salientar que se optou pela TWDR por não proporcionar o efeito de decimação, com redução no número de amostras.

Para a rede localizadora MLP, testaram-se algumas configurações, obtendo-se maiores margens de acerto com duas camadas intermediárias e a configuração 12-50-20-1. Com mais camadas e conseqüentemente mais neurônios e mais conexões, houve um maior detalhamento das variáveis da base de dados proporcionando maior generalização. Os acertos foram superiores a 90% tanto para os dados reais quanto simulados, utilizando-se a média e mediana para determinação. Concluiu-se que para essa etapa, a *wavelet* que apresentou melhores resultados foi a Daubechies 48. Isso ocorreu em função de seu filtro *wavelet* ser de maior ordem, e cortar com mais eficiência as baixas frequências. Para identificação do local a energia pura dos transitórios é mais relevante. Para algumas amostras em superfícies de maior impedância, como terra e calçamento foram observados erros maiores. É importante ressaltar que há grande dificuldade na detecção dessas faltas. Notou-se também que com outro tipo de inicialização, os resultados foram similares.

Para a SOM, com grades neurais acima de 45x45, os acertos foram sempre superiores a 90% com a utilização da *wavelet* Daubechies 4, observando-se uma relação diretamente proporcional entre o acerto e o número de neurônios. Optou-se para localizar o setor pela SOM por ser uma estrutura classificadora (a rede um dentre vários rótulos) além do processo de treinamento ser não-supervisionado. Notou-se que as componentes de baixa frequência são mais relevantes que para determinação do local propriamente dito.

Em suma, as estruturas de redes neurais são aptas para localizar e determinar o setor/seção do alimentador para FAI. Conclui-se que a energia dos CW da fase de falta é uma ferramenta adequada para a análise em questão e desempenha papel relevante na localização, tendo em vista que carregam consigo informações sobre os transitórios de alta frequência. A mescla com as correntes trifásicas no tempo mostrou-se acertada, pois as mesmas fornecem informações relacionadas ao carregamento, por exemplo.

Devem ser destacados os nuances práticos dos ensaios referentes ao trabalho, em que foi utilizado um RDP com banda passante até 3 kHz. Tal fato influenciou diretamente no levantamento da característica da FAI e sua modelagem, em que dados de frequências mais altas não foram registrados, como ocorrem na realidade. Combinando-se com a frequência de amostragem do equipamento, resultou em Daubechies 48 para o local e Daubechies 4 para o setor.

6.2 Perspectivas de Trabalhos Futuros

Como continuação dos estudos realizados para a elaboração desta Tese, são sugeridas as seguintes propostas de trabalhos futuros:

- Determinação detalhada da resposta em frequência do RDP para se obter uma correção nos modelos de FAI e dos dados reais. De posse da resposta em frequência do RDP utilizado (pelo menos até a frequência de amostragem), seria possível a obtenção dos dados reais das FAI sem as distorções introduzidas pelo equipamento. A correção consistiria na aplicação da Resposta Inversa aos dados obtidos.
- Teste com outros tipos de RNA, como a Artmap (baseada na Teoria da Ressonância Adaptativa) em que há um treinamento não-supervisionado e adaptabilidade no tamanho da grade neural. Isso significa que caso haja a necessidade com a entrada de novos dados, são “criados” novos neurônios na rede.
- Extensão da metodologia para *Smart Grids* (redes inteligentes). Nos últimos anos, os conceitos de *Smart Grids* tiveram maior aceitação dos pesquisadores na área de Sistemas Elétricos de Potência (SEP), motivando inúmeras pesquisas. Com o avanço da tecnologia nos campos da computação, do controle e das comunicações, as *Smart Grids* têm sido consideradas como a grande tendência dos SEP, em virtude da possibilidade de interconectar os equipamentos elétricos instalados nos sistemas supervisionados. Em locais comprometidos com a qualidade do serviço prestado, a implementação prática das *Smart Grids*

acelera e verificam-se avanços na América do Norte e Europa (MASA, 2012). Em curto prazo, não há horizontes para a plena implementação nos sistemas de distribuição brasileiros; devido à inércia em se realizar investimentos, falta de universalização de redes de dados robustas e confiáveis e até mesmo escassez de equipamentos de qualidade. A transição tende a ser lenta e gradual.

- Teste da metodologia para sistemas de distribuição com geração distribuída.
- Implementar um simulador que escolha aleatoriamente as barras, tipos de falta e carregamento para construção da base de dados. Pretende-se também variar a escolha dos setores para avaliação do impacto na localização realizada pela SOM.

Referências Bibliográficas

- ALI, M. S.; BAKAR, A. H. A.; MOKHLIS, H.; AROFF, H.; ILLIAS, H. A., AMAN, M. M., *High Impedance Fault Localization in a Distribution Network using the Discrete Wavelet Transform*, IEEE International Power Engineering and Optimization Conference (PEOCO 2012), Melaka, Malásia, 2012.
- AUCOIN, B. M., *Status of High Impedance Fault Detection*, IEEE Transactions on Power Apparatus and Systems, vol. PAS-104, n.º 3, pp. 638-644, March 1985.
- AUCOIN, B. M.; JONES, R. H., *High Impedance Fault Detection Implementation* IEEE Transactions on Power Delivery, v. 11, n. 1, pp. 139-148, January 1996.
- BURRUS, C. S.; RAMESH, A. G.; GUO, H., *Introduction to Wavelets and Wavelet Transforms*, New Jersey, USA: Prentice Hall, 1998.
- BUTLER, K. L.; MOMOH, J. A., *A Neural Net Based Approach for Fault Diagnosis in Distribution Networks*, Power Engineering Society Winter Meeting, Texas, USA, v.2, p.1275-1278, 2000.
- CABRAL, S. L. S.; SENGER, E. C.; SANTOS, J. C., *Falta de Alta Impedância – Proposta de Solução através de Sistemas Supervisórios*. Seminário Nacional de Distribuição de Energia Elétrica (SENDI), Blumenau, 1992.
- CHRISTIE, R. D.; ZADEHGOL, H.; HABIB, M. M., *High Impedance Fault Detection in Low Voltage Networks*, IEEE Transactions on Power Delivery, Vol. 8, n.º 4, pp. 1829-1836, October 1993.

- COSER, J.; ROLIM, J. G., *Método para Diagnóstico de Falhas em Sistemas de Distribuição de Energia Elétrica*, CBA2004 - Congresso Brasileiro de Automática, Gramado, 2004.
- COSTA, F. B., *Uma técnica de diagnóstico em tempo real de distúrbios transitórios baseada na Transformada Wavelet para uso em registradores digitais de perturbação*, Tese de Doutorado, Universidade Federal de Campina Grande, Campina Grande, Brasil, 2010.
- COSTA, F. B.; LIMA, G.R.S.; SANTOS, W. C.; SILVA, J. A. C. B.; SOUZA, B. A.; BRITO, N. S. D.; PAES JR., M. R. C., *High Impedance Fault Detection*, International Symposium on High Voltage Engineering - ISH 2011, Hannover, 2011.
- COSTA, F. B.; SOUZA, B. A.; BRITO, N. S. D.; SILVA, J. A. C. B.; SANTOS, W. C., *Real-Time Detection of Transients Induced by High Impedance Faults Based on the Boundary Wavelet Transform*, IEEE Transactions on Industry Applications, Vol. 51, n^o. 6, pp. 5312 - 5323, November 2015.
- DAS, R.; BAYOUMI, D., *System for Detection of High Impedance Fault*, 19th International Conference on Electricity Distribution, Viena, Áustria, 2007.
- DAUBECHIES, I., *Ten Lectures on Wavelets*, Philadelphia, USA: CBMS-NSF Regional Conference Series, SIAM, 1992.
- ELKALASHY, N.I.; LEHTONEN, M.; DARWISH, H.A.; TAALAB, A.-M.I.; IZZULARAB, M.A., *DWT-Based Detection of High Impedance Fault due to Leaning Trees in Compensated MV Networks*, 19th International Conference on Electricity Distribution, Viena, Áustria, 2007.
- ELKALASHY, N.I.; LEHTONEN, M.; DARWISH, H.A.; TAALAB, A.-M.I.; IZZULARAB, M.A., *DWT-Based Detection and Transient Power Direction-Based Location of High-Impedance Faults Due to Leaning Trees in Unearthed MV Networks*, IEEE Transactions on Power Delivery, vol. 23, n^o 1, pp. 94-101, January 2008.

- EMANUEL, A. E.; GULACHENSKI, E. M.; CYGANSKI, D.; ORR, A. J.; SHILLER, S., *High impedance fault arcing on sandy soil in 15 kV distribution feeders: contributions to the evaluation of the low frequency spectrum*, IEEE Transactions on Power Delivery, vol.5, n. 2, pp. 676-686, Abril 1990.
- ENDRENYI, J., *Evaluation of resistivity tests for design of station grounds in nonuniform soil*, AIEE Transactions, December, pp.966-970, 1963.
- FANUCCHI, R. Z.; OLESKOVICZ, M.; BARBOSA, D., *Análise da Detecção de Falhas de Alta Impedância Utilizando Redes Neurais Artificiais com Topologias Baseadas em Perceptron Multicamadas e Redes RBF*, Simpósio Brasileiro de Automação Inteligente (SBAI), Fortaleza, 2013.
- FLAUZINO, R. A., *Identificação e Localização de Falhas de Alta Impedância em Sistemas de Distribuição Baseadas em Decomposição por Componentes Ortogonais e Inferência Fuzzy*, Tese de Doutorado, Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, Brasil, 2007.
- FRANK, A.; ASUNCION, A., *UCI Machine Learning Repository*, Disponível em: <http://archive.ics.uci.edu/ml>. Acesso em: 05/04/2016.
- GROSSMAN, A.; MORLET, J., *Decomposition of hardy functions into square integrable wavelets of constant shape*, Society for Industrial and Applied Mathematics Journal on Mathematical Analysis, p. 155-166, 1984.
- HAGAN, M. T.; MENHAJ, M. B., *Training feedforward networks with the Marquardt algorithm*, IEEE Transactions on Neural Networks, v.5, n.6, p.989-993, November 1994.
- HAYKIN, S., *Neural Networks: A comprehensive foundation*, New Jersey: Prentice Hall, 1999.

- HIZAM H., CROSSLEY, P., *Estimation of Fault Location on a Radial Distribution Network Using Fault Generated Travelling Waves Signals*, North American Power Symposium (NAPS), Pullman, Estados Unidos, 2014.
- HOSSAIN, S.; ZHU, H., OVERBYE, T., *Distribution High Impedance Fault Location Using Localized Voltage Magnitude Measurements*, Journal of Applied Sciences, Vol. 7, No. 23, pp. 3736-3742, 2007.
- IURINIC, L. U., HERRERA-OROZCO, A. R., FERRAZ, R. G.; BRETAS, A. S., *Distribution Systems High Impedance Fault Location: a Parameter Estimation Approach*, IEEE Transactions on Power Delivery, Dec. 2015.
- JEERINGS, D. I.; LINDERS, J. R., *Unique Aspects of Distribution System Harmonics due to High Impedance Ground Faults*, IEEE Transactions on Power Delivery, USA, v.5, n.2, p.1086-1094. apr. 1990.
- JENSEN, K. J.; MUNK, S. M.; SORENSEN, J. A., *Feature Extraction Method for High Impedance Ground Fault Localization in Radial Power Distribution Networks*, IEEE International Conference on Acoustics, Speech and Signal Processing, pp.1177-1180, 1998.
- KOHONEN, T., *Self-organized formation of topological correct feature maps*, Biological Cybernetics 43, 1982.
- KOHONEN, T., *Self-Organizing Maps*, Berlin, Alemanha: Springer, 2000.
- LAZKANO, A.; RUIZ, J.; ARAMENDI, E.; LETURIONDO, L. A., *Evaluation of a new proposal for arcing fault detection method based on wavelet packet analysis*, Power Engineering Society Summer Meeting, Vol. 3, 2001.
- LEUVEN EMTF CENTER. *ATP – Alternative Transient Program – Rule Book*. Herverlee, Bélgica, 1987.

- LIRA, G. R. S., *Monitoramento de Para-raios de Óxido de Zinco com Base na Medição da Corrente de Fuga Total*, Tese de Doutorado, Universidade Federal de Campina Grande, Campina Grande, Brasil, 2012.
- LOPES, F. V.; SANTOS, W. C.; FERNANDES JR., D.; NEVES, W. L. A.; SOUZA, B. A., *An Adaptive Fault Location Method for Smart Distribution and Transmission Grids*, 2011 IEEE PES Conference on Innovative Smart Grid Technologies (ISGT Latin America), oct. 2011.
- MALLAT, S. G., *A theory for multiresolution signal decomposition: The wavelet representation*, IEEE Transaction on Pattern Analysis and Machine Intelligence, v. 11, n. 7, Jul 1989.
- MARQUES, M. C., *Comparação entre os métodos de agrupamentos Kmeans e Mapa de Kohonen (SOM) em análise de pesquisa de mercado*, Revista Inteligência Computacional Aplicada da Puc-Rio: Junho de 2008.
- MASA, A. V., *High Impedance Fault Detection Method in Multi-Grounded Distribution Networks*, PhD Thesis, Ecole Polytechnique de Bruxelles, Bruxelas, Bélgica, 2012.
- MAZÓN, A. J.; ZAMORA, I.; MIÑAMBRES, J. F.; ZORROZUA, M. A.; BARANDIARAN, J. J.; SAGASTABEITIA, K., *A new approach to fault location in two-terminal transmission lines using artificial neural networks*, Electric Power Systems Research, n.56, p.261-266, 2000.
- MEYER, Y., *Ondelettes et Opérateurs*, Hermann, 1990.
- MICHALIK, M.; REBIZANT, W.; LUKOWICZ, M.; LEE, S.-H.; KANG, S.-H., *High-Impedance Fault Detection in Distribution Networks with use of Wavelet-Based Algorithm*, IEEE Transactions on Power Delivery, v. 21, n. 4, pp. 1793-1802, October 2006.

- MICHALIK, M.; LUKOWICZ, M.; REBIZANT, W.; LEE, S.-H.; KANG, S.-H., *New ANN-Based Algorithms for Detecting HIFs in Multigrounded MV Networks*, IEEE Transactions on Power Delivery, v. 23, n. 1, pp. 139-148, January 2008.
- MOKHTARI, H.; AGHATEHRANI, R., *A New Wavelet-Based Method for Detection of High Impedance Faults*, Future Power System International Conference, 2005.
- MOMOH, J.; RIZY, D. T., *Application of Wavelet Theory to Power Distribution Systems for Fault Detection*, International Conference on Intelligent Systems Applications to Power Systems, pp. 345-350, 1996.
- MORETO, M., *Localização de faltas de alta impedância em sistemas de distribuição de energia: uma metodologia baseada em redes neurais artificiais*, Dissertação de Mestrado, Universidade Federal do Rio Grande do Sul, 2005.
- NAKAGOMI, R. M., *Proposição de um Sistema de Faltas de Alta Impedância em Redes de Distribuição*, Dissertação de Mestrado, Universidade de São Paulo, 2006.
- NAM, S. R.; PARK, J. K.; KANG, Y. C.; KIM, T. H., *A modeling method of a high impedance fault a distribution system using two series time-varying resistances in EMTP*, IEEE PES Summer Meeting 2001, vol. 2, pp. 1175-1180.
- OLESKOVICZ, M.; COURY, D. V.; DELMONT FILHO, O.; USIDA, W. F.; CARNEIRO, A. A. F M., *Power quality applying a hybrid methodology with wavelet transform and neural networks*, International Journal of Electrical Power & Energy Systems, v. 31, p. 206-212, 2009.
- OLIVEIRA, H. M., *Análise de Sinais para Engenheiros: Uma abordagem via Wavelets*, Editora Brasport, Rio de Janeiro, 2007.
- OLIVEIRA JÚNIOR, D. A., *Faltas de alta impedância: detecção e localização de rompimento de condutores em circuito primário de redes aéreas de distribuição baseado em desequilíbrio de tensão*, Dissertação de Mestrado, Universidade Federal de Minas Gerais, 2006.

- OPPENHEIM, A. V.; SCHAFER, R. W., *Discrete-time signal processing*, New Jersey: Prentice-Hall, 1989.
- PERCIVAL, D. B.; WALDEN, A. T., *Wavelet Methods for Time Series Analysis*, New York, USA: Cambridge University Press, 2000.
- RIEDMILLER, M.; BRAUN, H., *A direct adaptive method for faster backpropagation learning: the RPROP algorithm*, Proceedings of the IEEE Int. Conf. on Neural Networks, San Francisco, 1993, pp. 586-591.
- SALIM, R. H.; OLIVEIRA, K. R. C.; FILOMENA, A. D.; RESENER, M.; BRETAS, A. S., *Hybrid Fault Diagnosis Scheme Implementation for Power Distribution Systems Automation*, IEEE Transactions on Power Delivery, v. 23, n. 4, pp. 1846-1856, October 2008.
- SALIM, R. H., *Novos Desenvolvimentos na Localização de faltas em Sistemas de Distribuição de Energia Elétrica Fundamentada na Impedância*, Dissertação de Mestrado, Universidade Federal do Rio Grande do Sul, 2008.
- SANTOS, W. C., *Uma Revisão de Modelos Clássicos de Faltas de Alta Impedância para Efeito de Melhoramento*, Dissertação de Mestrado, Universidade Federal de Campina Grande, Campina Grande, Brasil, 2011.
- SANTOS, W. C.; LOPES, F. V.; COSTA, F. B.; BRITO, N. S. D.; SOUZA B. A.; FERNANDES JR, D.; NEVES, W. L. A., *Detecção de Faltas de Alta Impedância: Revisão da Literatura e Tendências Futuras*, Conferência Brasileira sobre Qualidade da Energia Elétrica, Araxá, 2013.
- SANTOS, W. C.; LIMA, G.R.S.; COSTA, F. B.; SILVA, J. A. C. B.; SOUZA, B. A.; BRITO, N. S. D.; PAES JR., M. R. C., *Staged-fault Testing for High Impedance Fault Data Collection and Simulation Support*, International Symposium on High Voltage Engineering - ISH 2011, 2011, Hannover.

- SEDIGHI, A. R.; HAGHIFAM, M. R.; MALIK, O. P.; GHASSEMIAN, M. H., *High Impedance Fault Detection based on Wavelet Transform and Statistical Pattern Recognition*, IEEE Transaction on Power Delivery, Vol. 20, 2005.
- SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A., *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas – Curso Prático*, Editora Artliber, São Paulo, 2010.
- SILVA, J. A. C. B., *Um Localizador de Faltas em Linhas de Transmissão Baseado em Redes Neurais Artificiais*, Dissertação de Mestrado, Universidade Federal de Campina Grande, Campina Grande, 2004.
- SILVA, J. A. C. B., *Diagnóstico Automatizado de Faltas em Sistemas de Distribuição*, Relatório - Projeto de Pesquisa, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Campina Grande, 2011.
- SILVA, K. M., *Estimação de Fasores Baseada na Transformada Wavelet para Uso na Proteção de Distância de Linhas de Transmissão*, Tese de Doutorado, Universidade Federal de Campina Grande, Campina Grande, Brasil, 2009.
- SILVA, J. A. C. B.; COSTA, F. B.; SANTOS, W. C.; NEVES, W. L. A.; SOUZA, B. A., *High Impedance Fault Location - Case Study using Wavelet Transform and Artificial Neural Networks*, 22nd International Conference on Electricity Distribution, Estocolmo, 2013.
- SILVA, K. M.; SOUZA, B. A.; BRITO, N. S. D.; DANTAS, K. M. C.; COSTA, F. B.; SILVA, S. S. B., *Detecção e Classificação de Faltas a partir da análise de registros oscilográficos via redes neurais artificiais e transformada wavelet*, Controle & Automação, v. 18, p. 163-172, 2007.
- SOLÍS, N.; GUTIÉRREZ, J. A.; NAREDO, J. L.; ORTIZ, V. H., *Analysis of complex faults in distribution systems*, 7th International Conference on Power Systems Transients, Lyon, França, 2007.

- SOUZA, B. A.; BRITO, N. S. D.; NEVES, W. L. A.; SILVA, K. M.; LIMA, R. B. V.; SILVA, S. S. B., *Comparison between Backpropagation and RPROP Algorithms Applied to Fault Classification in Transmission Lines*, I Internacional Joint Conference on Neural Networks, Budapeste, Hungria, 25-29 Jul. 2004.
- SPATTI, D. H., *Automatização de Processos de Localização de Falhas em Linhas de Distribuição Utilizando Sistemas Especialistas Híbridos*, Tese de Doutorado, EESC-USP, São Carlos, 2011.
- PINHO, A. G., *Mineração de Dados com Mapas de Kohonen: Uma Abordagem no Setor Financeiro*, Revista Pensamento Contemporâneo em Administração, v.2, n.2, p. 39-49, Maio/Agosto 2008.
- TANG, Y.; WANG, H. F.; AGGARWAL, R. K.; JOHNS, A. T., *Fault Indicator in Transmission and Distribution Systems*, Proceedings of International Conference on Electric Utility Deregulation and Restructuring and Power Technologies, pp. 238-243, 2000.
- TAKAGI, T.; YAMAKOSHI, Y.; BABA, J.; UEMURA, K.; SAKAGUCHI, T., *A New Algorithm of an Accurate Fault Location for EHV/UHV Transmission Lines: Part I - Fourier Transformation Method*, IEEE Transactions on Power Apparatus and Systems, v.PAS-100, n.3, p.1316-1322, March 1981.
- TAKAGI, T.; YAMAKOSHI, Y.; YAMAURA, M.; KONDOW, R.; MATSUSHIMA, T., *Development of a New Type Fault Locator using the One-terminal Voltage and Current Data*, IEEE Transactions on Power Apparatus and Systems, v.PAS-101, n.8, p.2892-2898, August 1982.
- THUKARAM, D.; KHINCHA, H. P.; JENKINS, L.; VISAKHA, K., *A Three Phase Fault Detection Algorithm for Radial Distribution Networks*, 2002 IEEE Region 10 Conference on Computers, Communications, Control and Power Engineering, Vol. 2, pp. 1242-1248, 2002.

UFCG, *Sistema de Detecção e Localização de Falhas de Alta Impedância em Redes de Distribuição*, Relatório Final – Projeto de P&D, Campina Grande, 2010.

VIANNA, J. T. A.; ARAÚJO, L. R.; PENIDO, D. R. R., *High Impedance Fault Area Location in Distribution Systems Based on Current Zero Sequence Component*, IEEE Latin America Transactions, vol. 14, nº 2, p. 759-766, Feb. 2016.

YANG, M. T.; GU, J. C.; JENG, C. Y.; KAO, W. S., *Detection High Impedance Fault in Distribution Feeder using Wavelet Transform and Artificial Neural Networks*, International Conference on Power System Technology, 2004.

YANG, M. T.; GUAN, J. L.; GU, J. C., *Detection of Downed Conductor in Distribution System*, Power Engineering Society General Meeting, 2005.

Apêndice A

Publicações Realizadas

EVENTO	ARTIGO	AUTORES
22 nd International Conference on Electricity Distribution (Cired 2013), 2013, Estocolmo.	High Impedance Fault Location Case Study Using <i>Wavelet</i> Transform and Artificial Neural Networks	SILVA, J. A. C. B.; COSTA, F. B.; SANTOS, W. C.; NEVES; SOUZA, B. A.
Fourth World Congress on Nature and Biologically Inspired Computing (NaBIC 2012), 2012, Cidade do México.	Sampling Frequency Influence at Fault Locations Using Algorithms Based on Artificial Neural Networks.	SILVA, J. A. C. B.; SILVA, K. M. E.; NEVES, W. L. A.; SOUZA, B. A.; COSTA, F. B.
21 st International Conference and Exhibition on Electricity Distribution Cired, 2011, Frankfurt.	High Impedance Fault Location Case Study with Developed Models From Field Experiments	SILVA, J. A. C. B.; COSTA, F. B.; SANTOS, W. C.; LIMA, G.R.S.; NEVES, W. L. A.; SOUZA, B. A.; BRITO, N. S. D.; PAES Jr., M. R. C.
Simpósio de Automação de Sistemas Elétricos - SIMPASE 2011, 2011, Curitiba.	Proposta de um sistema de gatilhamento de registradores digitais de perturbação	SOUZA JUNIOR, F. C.; ANDRADE, J. P.; BRITO, N. S. D.; SOUZA, B. A.; COSTA, F. B.; SANTOS, W. C.; LIMA, G.R.S.; SILVA, J. A. C. B.; PAES Jr., M. R. C.
Conferência Brasileira sobre Qualidade da Energia Elétrica - CBQEE 2011, 2011, Cuiabá.	Post-analysis of faults and high impedance faults	COSTA, F. B.; Souza, B. A.; BRITO, N. S. D.; SANTOS, W. C.; SILVA, J. A. C. B.; LIMA, G.R.S.; PAES Jr., M. R. C.

Congresso de Inovação Tecnológica em Energia Elétrica - CITENEL 2011, 2011, Fortaleza.	Um sistema de detecção e localização de faltas de Alta Impedância	Souza, B. A.; BRITO, N. S. D.; LIMA, G.R.S.; SANTOS, W. C.; SILVA, J. A. C. B.; ANDRADE, J. P.; COSTA, F. B.; PAES Jr., M. R. C.
International Symposium on High Voltage Engineering - ISH 2011, 2011, Hannover.	High impedance fault detection	COSTA, F. B.; LIMA, G.R.S.; SANTOS, W. C.; SILVA, J. A. C. B.; SOUZA, B. A.; BRITO, N. S. D.; PAES Jr., M. R. C.
International Symposium on High Voltage Engineering - ISH 2011, 2011, Hannover.	Staged-fault testing for high impedance fault data collection and simulation support.	SANTOS, W. C.; LIMA, G.R.S.; COSTA, F. B.; SILVA, J. A. C. B.; SOUZA, B. A.; BRITO, N. S. D.; PAES Jr., M. R. C.
7 th International Conference on Electrical and Electronics Engineering Research, 2010, Aguascalientes.	A Comparative Analysis of the Multi-layer Perceptron and Self-Organizing Map Networks Applied for Fault Classification.	COSTA, F. B.; SILVA, J. A. C. B.; ALMEIDA, C. W. D.; SOUZA, B. A.
IEEE/PES T&D2010 Latin América, 2010, São Paulo.	Automatic Building of a Simulated High Impedance Fault Database.	SANTOS, W. C.; COSTA, F. B.; SILVA, J. A. C. B.; LIMA, G.R.S.; SOUZA, B. A.; BRITO, N. S. D.; PAES Jr., M. R. C.

Periódicos

PERIÓDICO	ARTIGO	AUTORES
IEEE PES Transactions on Power Delivery - Special Issue: Modern Substation Technologies (A1) - Submetido	A High Impedance Fault Locator Installed in a Distribution Substation using <i>Wavelet</i> Current Energy	SILVA, J. A. C. B.; NEVES, W. L. A.; SOUZA, B. A.; COSTA, F. B.
IEEE Transactions on Industry Applications (A1)	High Impedance Fault Location: Case Study Using <i>Wavelet</i> Transform and Artificial Neural Networks	COSTA, F.B.; SOUZA, B.A.; BRITO, N.S.D.; SILVA, J.A.C.B.; SANTOS, W.C.