

PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**“Detecção e Classificação de Curtos-Circuitos em
Sistemas de Distribuição Usando Rede Neural
Artificial ARTMAP Nebulosa”**

JOÃO ROBERTO DEROCO MARTINS

Orientador: Prof. Dr. Jozué Vieira Filho

Dissertação apresentada à Faculdade de
Engenharia – UNESP – Campus de Ilha
Solteira, para a obtenção do título de
Mestre em Engenharia Elétrica.

Área de conhecimento: Automação.

Ilha Solteira – SP
fevereiro de 2010

Livros Grátis

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

Milhares de livros grátis para download.

FICHA CATALOGRÁFICA


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

M366d Martins, João Roberto Deroco.
Detecção e classificação de curto-circuitos em sistemas de distribuição usando rede neural artificial ARTMAP nebulosa / João Roberto Deroco Martins. -- Ilha Solteira : [s.n.], 2010.
84 f. : il.

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

Orientador: Josué Vieira Filho
Bibliografia: p. 80-84

1. Energia elétrica – Curto-circuito. 2. Diagnóstico de faltas – Energia elétrica. 3. Redes neurais (Computação). 4. Rede neural artificial. 5. Redes neurais ARTMAP nebulosa.



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

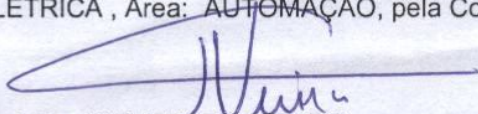


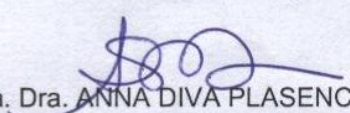
CERTIFICADO DE APROVAÇÃO

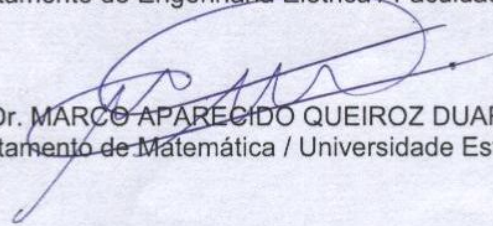
TÍTULO: Detecção e Classificação de Curtos-Circuitos em Sistemas de Distribuição Usando Rede Neural Artificial ART MAP Nebulosa

AUTOR: JOÃO ROBERTO DEROCO MARTINS
ORIENTADOR: Prof. Dr. JOZUE VIEIRA FILHO

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


Prof. Dr. JOZUE VIEIRA FILHO
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


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


Prof. Dr. MARCO APARECIDO QUEIROZ DUARTE
Departamento de Matemática / Universidade Estadual de Mato Grosso do Sul - - Cassilândia/MS

Data da realização: 19 de fevereiro de 2010.

Dedicatória

A Deus, por sempre ser meu maior companheiro em todos os momentos, e aos meus pais, Cleide e Roberto, por nunca deixarem de me apoiar e acreditar em mim.

Agradecimentos

Agradeço, primeiramente, a Deus, por sempre me confortar nos momentos difíceis e, principalmente, por esse tão valioso dom da vida.

Agradeço aos meus pais, Cleide e Roberto, e ao meu irmão, George, por nunca deixarem de estar ao meu lado, sempre me proporcionando forças que, sem elas, não me seria possível chegar até aqui.

Agradecimentos especiais ao meu orientador, Jozué Viera Filho, pelos momentos de conhecimento e compreensão e pela dedicação em me ajudar a concluir esse importante processo.

Agradeço ao meu companheiro de laboratório, Élito, que, além de um grande amigo, foi, praticamente, um co-orientador deste meu trabalho.

Agradeço aos meus amigos que tanto me apoiaram durante estes dois anos de pós-graduação: Ana Cláudia, Bertequini, Cibele, Eduardo, Elisabete, Germano, Ivan, Jadiel, João Luiz, Luiz, Mantovani, Marlon, Meire, Renan, Stefani, Tiago, Wesley, Marcel Dudu, Rafael Barreto e Rafael Costa...

Agradecimentos, também, aos meus atuais superiores Major Fernando Marques Júnior e Tenente Renata Rodrigues Frias por terem me disponibilizado três dias de folga, essenciais para que eu pudesse retornar a Ilha Solteira e apresentar minha defesa de dissertação.

Agradeço, finalmente, à CAPES pela ajuda financeira proporcionada em quase todo o período de pós-graduação.

*“Eu acredito em milagres
Eu acredito em um mundo melhor para mim e para você”*

Dee Dee Ramone / Daniel Rey

Resumo

Este trabalho apresenta uma metodologia para detecção e classificação de faltas do tipo curto-circuito. Esta operação de diagnóstico tem como principal operador um banco de redes neurais artificiais (RNAs) do tipo ARTMAP Nebulosa. Tal ferramenta segue a principal filosofia das RNAs: o reconhecimento de padrões, através de um treinamento supervisionado inicial, responsável por atualizar os parâmetros das redes concomitantemente com os resultados desejados. Finalizada a fase de adaptação, as redes serão capazes de, após receber novos padrões, classificá-los, de forma a propiciar, ao operador, informações importantes quanto ao estado de transmissão de barras presentes em um determinado complexo elétrico. Aqui, tomou-se como modelo a simulação de um grande alimentador real, composto por mais de 800 barras. Aliados às RNAs, também foram aplicadas, no que se refere à análise de dados amostrados de corrente elétrica, duas importantes e flexíveis ferramentas matemáticas: a Transformada de *Fourier* e a Transformada *Wavelet*. Observa-se, ao final do trabalho, que os resultados apresentados são bastante encorajadores, o que possibilitaria a utilização do programa em um ambiente real.

Palavras-chave: Diagnósticos de Faltas do tipo Curto-Circuito, Rede Neural Artificial, Rede ARTMAP Nebulosa.

Abstract

This work presents a detection and classification of short-circuit faults methodology. The main operator of this diagnostic operation is a Fuzzy ARTMAP Artificial Neural Networks (ANN) bank. This tool follows the ANN's main core: pattern recognition, through an initial supervised training stage, responsible for updating the parameters of the networks concomitant with the desired results. Completed the adaptation phase, the network will be able to, after receiving new standards, classifying them in order to provide to the operator important information about the state of transmission of bars present in a given complex electric. Here, there is, like a model, a simulation of a real big feeder, comprising more than 800 bars. Besides the ANNs, two important and flexible mathematical tools were also applied with regard to the analysis of sampled data of electric current: Fourier Transform and Wavelet Transform. At the end of the work the results presented are very encouraging, which would allow the use of the program in a no simulations real environment.

Keywords: Short-circuit Faults Diagnostic, Artificial Neural Network, Fuzzy ARTMAP Network.

Lista de Figuras

<i>Figura 2.1</i> - Subestação e seus principais componentes.....	16
<i>Figura 2.2</i> - Principais barramentos utilizados nas subestações brasileiras: (a) Barramento Simples; (b) Barramento Principal e de Transferência; (c) Barramento Simples Seccionado; (d) Duplo Barramento Simples; (e) Barramento Duplo com um Disjuntor; (f) Barramento Duplo com Disjuntor Duplo; (g) Barramento de Disjuntor e Meio; (h) Barramento em Anel.....	17
<i>Figura 4.1</i> - Espectro das janelas referentes aos subespaços V_j e V_{j-1}	34
<i>Figura 4.2</i> - Diagrama ilustrativo de decomposição através de um banco de filtros.	35
<i>Figura 4.3</i> - Diagrama ilustrativo da reconstrução.....	36
<i>Figura 5.1</i> - Esquema básico de dois neurônios, suas principais partes e sinapse.	38
<i>Figura 5.2</i> - Representação de um neurônio artificial.....	39
<i>Figura 5.3</i> - Gráfico da função Relé.....	40
<i>Figura 5.4</i> - Gráfico da função Linear.....	41
<i>Figura 5.5</i> - Gráfico da função Sigmoidal para diferentes valores de a	42
<i>Figura 5.6</i> - Gráfico da função Tangente Hiperbólica para diferentes valores de a	42
<i>Figura 5.7</i> - Esquema de uma RNA acíclica, contendo quatro entradas, uma camada intermediária com três neurônios e dois neurônios de saída.....	43
<i>Figura 5.8</i> - Esquema de uma RNA Cíclica, com duas entradas e duas saídas.....	44
<i>Figura 6.1</i> - Arquitetura básica da rede ART	47
<i>Figura 6.2</i> - Formação do vetor peso w_j , que conecta os campos F_1 e F_2	49
<i>Figura 6.3</i> - Ilustração esquemática do treinamento da rede ARTMAP Nebulosas.....	55
<i>Figura 7.1</i> - Fluxograma esquematizando os três blocos principais do diagnóstico de faltas de curto-circuito: Pré-Processador, Banco de Redes Neurais e Pós-Processador.....	58
<i>Figura 7.2</i> - Parte do fluxograma do sistema de detecção e classificação de faltas, dando ênfase ao bloco de Pré-Processamento, aos seus dois subsetores/operadores matemáticos e aos principais vetores gerados durante o processo: E , F e C	61

Figura 7.3 - Exemplo de uma janela de amostragens para um sistema trifásico de corrente: observa-se a janela de dois ciclos, em linha pontilhada, englobando um trecho caracterizado pela presença de falta monofásica na fase B..... **62**

Figura 7.4 - Fluxograma do Banco de Redes Neurais, esboçando o posicionamento, no algoritmo, das quatro RNAs responsáveis pelo diagnóstico de faltas de curtos-circuitos..... **67**

Lista de Tabelas

<i>Tabela 6.1</i> - Comparação entre ART1 e ART Nebulosa.....	54
<i>Tabela 7.1</i> - Saídas possíveis da RNA_1, correspondentes à ocorrência ou não de falta.....	67
<i>Tabela 7.2</i> - Saídas das redes RNA_2, RNA_3 e RNA_4, associadas às respectivas faltas.....	68
<i>Tabela 8.1</i> - Sistemas que, em Matos (2009), apresentaram 100% de acerto.....	72
<i>Tabela 8.2</i> - Resultados percentuais de acertos obtidos com os mesmos parâmetros utilizados em Matos, 2009.....	72
<i>Tabela 8.3</i> - Resultados percentuais de acertos quanto ao resultado global do Programa Detector e Classificador de Faltas.....	76
<i>Tabela 8.4</i> - Sistemas Detectores e Classificadores de Faltas com resultados globais de 100% de acerto.....	76

Sumário

Capítulo 1: Introdução	13
Capítulo 2: Subestações de Energia Elétrica	15
2.1. Características Gerais.....	15
2.2. Configurações de Subestações de Energia Elétrica.....	16
2.3. Proteção de Subestações de Energia Elétrica.....	20
2.4. Conclusão.....	23
Capítulo 3: Transformada Discreta de <i>Fourier</i> aplicada à Representação de Sinais Elétricos	24
3.1. Representação Fasorial de Sinais Contínuos.....	25
3.2. Representação Fasorial de Sinais Discretos.....	27
3.3. Conclusão.....	30
Capítulo 4: Análise <i>Wavelet</i>	32
4.1. Transformada <i>Wavelet</i>	33
4.2. Análise de Multirresolução e Bancos de Filtros.....	34
4.3. Conclusão.....	36
Capítulo 5: Redes Neurais Artificiais	37
5.1. Características Gerais e o Modelo Biológico.....	37
5.2. O Neurônio Artificial.....	39
5.3. Arquiteturas de RNAs.....	43
5.4. Treinamento de Redes Neurais Artificiais.....	44
5.5. Conclusão.....	45
Capítulo 6: Teoria da Ressonância Adaptativa	46
6.1. Introdução e Motivação.....	46

6.2. Características Básicas das Redes ART.....	47
6.3. Algoritmo da Rede ART Nebulosa.....	50
6.4. Algoritmo da Rede ARTMAP Nebulosa.....	53
6.5. Conclusão.....	56
Capítulo 7: Detecção e Classificação de Faltas usando RNAs do tipo ARTMAP Nebulosa	57
7.1. Alimentador de Distribuição e Procedimentos de Simulação.....	59
7.2. Blocos Funcionais do Sistema de Detecção de Faltas.....	60
7.2.1. <i>Pré-Processamento</i>	60
7.2.2. <i>Banco de Redes Neurais</i>	66
7.2.3. <i>Pós-Processamento</i>	69
7.3. Conclusão.....	70
Capítulo 8: Apresentação e Discussão dos Resultados	71
8.1. Conclusão.....	77
Capítulo 9: Conclusão e Trabalhos Futuros	78
Referências Bibliográficas	80

Capítulo 1: Introdução

Atualmente, cresce, cada vez mais, a exigência pelo aumento da confiabilidade e segurança dos sistemas de energia elétrica, em especial, nas subestações agregadas aos sistemas de distribuição. Em face desta situação, aparece a necessidade de automatizar as operações relacionadas a este tão importante setor.

As subestações de distribuição de energia elétrica e o sistema de distribuição são os responsáveis pelo fornecimento de energia ao consumidor final. Esta energia deve ser entregue ao consumidor, respeitando-se parâmetros de qualidade, dentre eles, frequência e tensão “constantes”, DIC (Duração de Interrupção Individual), FIC (Frequência de Interrupção Individual), DMIC (Duração Máxima de Interrupção Contínua). Porém, os sistemas de energia elétrica estão sujeitos a várias perturbações causadas por fatores diversos, como falhas de equipamentos, descargas atmosféricas, etc. Desta maneira, é fundamental que esteja presente, nas subestações, um sistema de proteção eficiente (MORETO, 2005).

O princípio básico da proteção consiste em selecionar, coordenar, ajustar e alo-car os vários equipamentos e dispositivos protetores em um sistema elétrico, de forma a guardarem, entre si, uma determinada relação, tal que uma anormalidade no sistema possa ser isolada ou removida, sem que outras partes do mesmo sejam afetadas.

Outra preocupação atrelada aos sistemas de proteção é a eficiência da distribuição nos momentos críticos: um grande número de consumidores pode permanecer sem fornecimento de energia elétrica após a atuação do sistema de proteção. Desta forma, o tempo gasto pelas equipes de manutenção, na localização do ponto de ocorrência da falta, assim como na elaboração de um diagnóstico do problema e da medida corretiva, ou mesmo preventiva, deverá ser o menor possível.

A partir destes desafios enfrentados diuturnamente pelas concessionárias de distribuição de energia elétrica, é apresentado, neste trabalho, o algoritmo de um programa capaz de detectar e classificar faltas do tipo curto-circuito, provenientes da simulação de um alimentador de distribuição real.

Primeiramente, é feito um reconhecimento das principais configurações presentes nas subestações brasileiras, assim como uma observação superficial de alguns com-

ponentes de proteção. O estudo de tal material não é de grande influência na idealização do algoritmo de detecção e classificação, mas, caso, em um trabalho futuro, almeje-se a aplicação prática do projeto, será necessário um conhecimento teórico ainda mais detalhado.

Após esta fase inicial, adentra-se na teoria que, realmente, está atrelada ao algoritmo elaborado. Começa-se, assim, a uma apresentação de tópicos relacionados às Transformadas de *Fourier* e *Wavelet*. Ressalta-se que este embasamento encontra-se de um modo mais centrado naquilo que foi aplicado no sistema detector de faltas.

Ainda na introdução teórica, ilustra-se o funcionamento geral de Redes Neurais Artificiais para, desta forma, chegar ao modo de operação das redes **ARTMAP Nebulosas**. Tal ferramenta é a principal responsável, aqui, pela detecção e classificação de falhas, justificando-se, assim, a ênfase especial dada a este assunto nesta obra.

Em seguida, apresenta-se o algoritmo, dividido em três etapas principais: **Pré-Processamento, Banco de Redes Neurais** – estando este provido das referidas ARTMAP Nebulosas – e **Pós-Processamento**. Cada um destes setores será detalhado separadamente.

Por fim, apresentam-se os resultados obtidos com a implementação do algoritmo, assim como as respectivas discussões de seus valores e uma conclusão geral de todo o processo.

Capítulo 2: Subestações de Energia Elétrica

Subestações de energia elétrica tratam-se de complexos munidos de equipamentos responsáveis por modificar, controlar, comandar, distribuir e direcionar o fluxo de energia elétrica em um sistema elétrico.

As transformações a que o setor elétrico está sendo submetido exigem que os sistemas elétricos estejam aptos a atuar em ambientes cada vez mais dinâmicos e em permanente evolução, para que possam oferecer energia com maior confiabilidade e qualidade. Sendo assim, as subestações agregadas aos sistemas elétricos vêm automatizando suas operações (BARROS, 2009).

2.1. Características Gerais

Subestações de energia elétrica podem atuar de diferentes maneiras, podendo estar atrelada a uma usina de geração de energia ou, ainda, controlar, de alguma forma, o fluxo de potência na rede. Podem, também, estar associadas a transformadores de potência, que convertem a tensão de fornecimento para um nível superior e, até mesmo, serem utilizadas para chavear diferentes rotas de fornecimento de energia, de mesmo nível de tensão (SILVA; CARVALHO, 2002).

Existem, praticamente, quatro tipos de subestações de energia elétrica (SILVA; CARVALHO, 2002):

- Subestação de Geração;
- Subestação de Transmissão;
- Subestação de Distribuição;
- Subestação de Utilização.

Uma subestação é composta por uma quantidade variada de chaves, linhas e barramentos, além de vários outros importantes equipamentos (SILVA; CARVALHO, 2002):

- **Transformadores** – responsáveis pela alteração do nível de tensão;
- **Transformadores de correntes** – responsáveis pela medição da corrente elétrica, dentro de uma subestação;
- **Transformadores de potência** – medem a tensão;
- **Disjuntores e Religadores** – têm, como principal função, a proteção contra correntes de curto-circuito (abrem, automaticamente, nesses casos).

Na figura 2.1, apresenta-se o diagrama unifilar de uma subestação com os seus componentes básicos (PINHEIRO, 1995). O caminho para alimentar as cargas é denominado de barramento, que pode ser definido como sendo condutores reforçados, sólidos e de impedância desprezível, que servem como centros comuns de coleta e redistribuição de corrente (LEÃO, 2007).

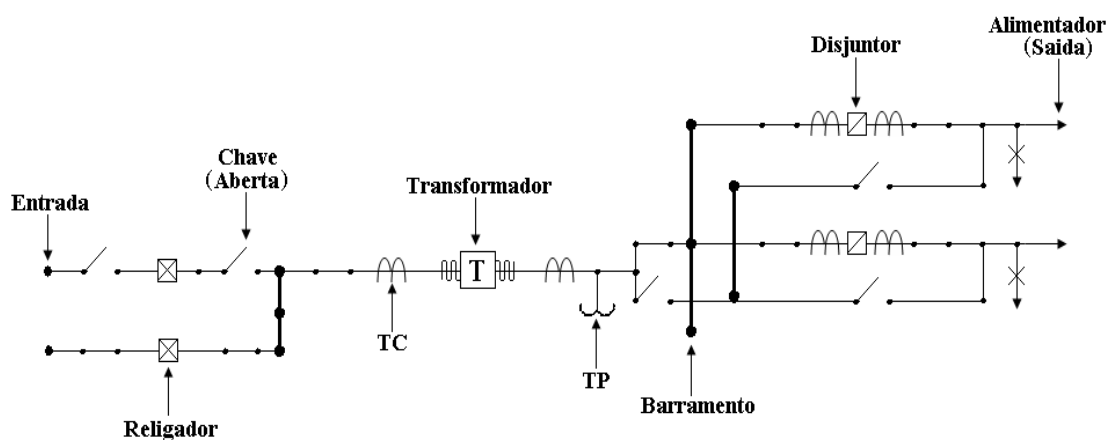


Figura 2.1 - Subestação e seus principais componentes.

2.2. Configurações de Subestações de Energia Elétrica

As diferentes configurações de subestações são baseadas no tipo de barramento utilizado. No Brasil, os principais barramentos (vide suas ilustrações esquemáticas na figura 2.2) são (DECANINI, 2008; LEÃO, 2007):

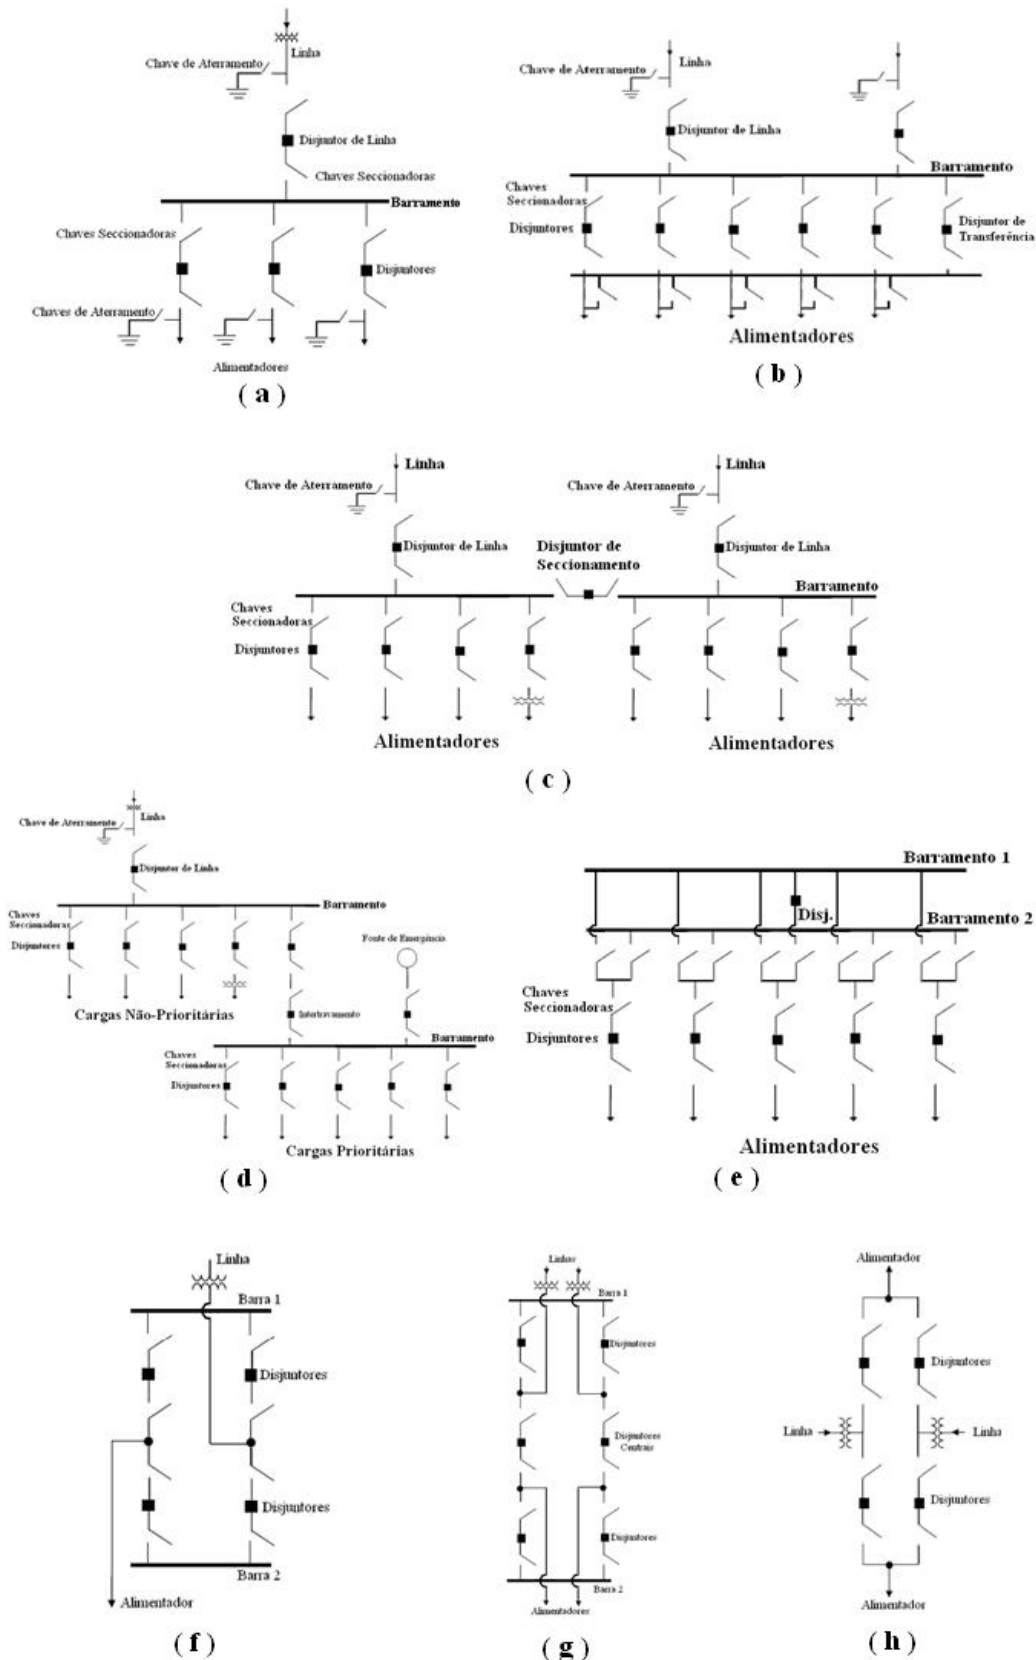


Figura 2.2 – Principais barramentos utilizados nas subestações brasileiras: (a) Barramento Simples; (b) Barramento Principal e de Transferência; (c) Barramento Simples Seccionado; (d) Duplo Barramento Simples; (e) Barramento Duplo com um Disjuntor; (f) Barramento Duplo com Disjuntor Duplo; (g) Barramento de Disjuntor e Meio; (h) Barramento em Anel.

- **Barramento Simples:** possui um único barramento, com todos os circuitos, diretamente, conectados a ele. A confiabilidade desta configuração é baixa. Uma simples falha no barramento ocasionará a saída de todo sistema, assim como este deverá ser desconectado para realização de manutenções ou ampliações no barramento. Assim, essa configuração é recomendada para, apenas, instalações que requeiram baixas potências. A vantagem desta configuração está no baixo custo e na facilidade de instalação.

- **Barramento Principal e de Transferência:** seu barramento principal é ligado ao barramento de transferência através de um disjuntor de transferência, o qual substituirá um disjuntor de linha, quando este estiver desligado para fins de manutenção. Nesta configuração, qualquer disjuntor pode ser retirado de serviço para manutenção. A desvantagem está na necessidade de um disjuntor extra para conexão com o outro barramento. Caso ocorra uma falha no barramento principal, resultará no desligamento da subestação. Este arranjo é mais caro que o barramento único, porém, possibilita maior flexibilidade durante a manutenção.

- **Barramento Simples Seccionado:** caracteriza-se pela presença de um disjuntor de barra, o qual evita que uma falha provoque a completa paralisação do sistema, isolando, portanto, apenas o elemento com falha da subestação. Este tipo de instalação é indicado para funcionar com duas fontes de energia. As principais vantagens deste arranjo são: maior continuidade no fornecimento de energia, flexibilidade na manutenção e, em caso de falha da barra, como já foi citado, somente são desconectados os consumidores ligados à seção afetada. Como desvantagens, têm-se a complexidade do sistema de proteção e a manutenção de um disjuntor deixam fora de serviço a linha correspondente.

- **Duplo Barramento Simples:** formato utilizado quando existem instalações consumidoras com grupos de cargas prioritários e grupos de cargas não prioritários. Esta configuração é indicada para instalações consumidoras que requerem alta confiabilidade para cargas essenciais e aceitam desligamentos rotineiros das cargas não essenciais. É, comumente, encontrada em subestações consumidoras, como hospitais e hotéis. A utilização deste arranjo permite maior flexibilidade

de conexão de circuitos para outra barra, retirada de disjuntores para manutenção e fácil recomposição. Sua desvantagem está no custo mais elevado.

- **Barramento Duplo com um Disjuntor:** utilizado em instalações de grande porte e de grande importância. Permite flexibilidade com os barramentos em operação, já que qualquer um dos barramentos poderá ser isolado para manutenção e há uma facilidade de transferência dos circuitos de um barramento para o outro. Nesta estrutura, a falha, em um barramento, não afeta o outro. Porém, uma falta, no disjuntor de transferência, poderá causar a saída da subestação. A necessidade de quatro chaves por circuito e de um disjuntor extra é seu inconveniente.
- **Barramento Duplo com Disjuntor Duplo:** trata-se de um tipo de instalação de alta confiabilidade, pois possui dois barramentos e dois disjuntores em cada circuito, permitindo, assim, que várias operações sejam realizadas, isentas da necessidade de desconexão do sistema. É empregada em instalações de grande potência, como em subestações de UHV (ultra-alta tensão), por razão de possuir maior flexibilidade e confiabilidade. As manutenções nos barramentos e nos circuitos de proteção podem ser realizadas com o sistema em seu estado normal de operação. A desvantagem desta configuração está no seu custo e na área requerida para a sua construção.
- **Barramento de Disjuntor e Meio:** nesta configuração, existem três disjuntores em série ligando uma barra dupla, sendo que cada dois circuitos são ligados, de um lado e outro, ao disjuntor central de um grupo. Três disjuntores protegem dois circuitos, em uma configuração com dois barramentos, ou seja, existe um disjuntor e meio para proteção de cada circuito. Este esquema é equivalente ao barramento duplo anterior, todavia, com uma importante simplificação: utiliza-se um disjuntor e meio para cada entrada e saída, ao invés de dois disjuntores por circuito, como no caso anterior. Desta forma, há uma economia maior, com, praticamente, a mesma confiabilidade.
- **Barramento em Anel:** todos os seus dispositivos de proteção são dispostos em anel. Cada alimentador é energizado através de dois disjuntores. Ocorrendo falha, somente o trecho em que a falta ocorreu ficará isolado. Denota-se sua flexi-

bilidade para manutenção dos disjuntores e a alta confiabilidade da configuração. A desvantagem é que, se um disjuntor estiver desligado para manutenção, o anel estará aberto e o restante do barramento, assim como os disjuntores alternativos, deverá ser projetado para transportar toda a carga.

A escolha de um determinado tipo de barramento é baseada, principalmente, nos seguintes parâmetros:

- Continuidade e confiabilidade de operações;
- Manutenções;
- Flexibilidade requerida em termos de facilidade de manobras;
- Custos de implantação.

2.3. Proteção de Subestações de Energia Elétrica

Para que se tenha um fornecimento de energia elétrica com qualidade e confiabilidade, os sistemas de proteção devem satisfazer Aos seguintes requisitos (GIGUER, 1988):

- Seletividade: a proteção deve, somente, isolar a parte do sistema atingida pelo defeito, mantendo a continuidade do serviço das demais partes do sistema;
- Sensibilidade: a proteção deve ser, suficientemente, sensível a defeitos que possam ocorrer durante a operação do sistema. Por sensibilidade, entende-se como o menor valor de grandeza capaz de ativar os dispositivos de proteção;
- Segurança: o sistema de proteção não pode realizar uma falsa operação sob condições normais de operação, ou falhar no caso de faltas no sistema;
- Rapidez: as sobrecorrentes geradas pelos curtos-circuitos ou sobrecargas devem ser extintas no menor tempo possível, reduzindo a probabilidade de propagação dos defeitos;
- Economia: o sistema de proteção deve ter sua implantação viável economicamente, evitando-se um número excessivo de dispositivos de proteção.

Nos alimentadores dos sistemas de distribuição, encontram-se vários dispositivos de proteção e, para que apenas o dispositivo mais próximo da falta atue, é necessário realizar a coordenação dos diversos dispositivos. Desta maneira, a proteção acarretará nos seguintes benefícios (GIGUER, 1988):

- Menores danos aos materiais e equipamentos;
- Menores custos de manutenção;
- Redução no número de desligamentos;
- Aumento do faturamento;
- Menor queima de elos em cascata;
- Facilidades de manobras;
- Maior segurança.

Para chegar a uma proteção satisfatória e eficiente, deve-se ter conhecimento, também, dos dispositivos utilizados nas operações. A seguir, de forma básica, serão descritos os principais equipamentos empregados, com este fim, em subestações (GIGUER, 1988):

- **Elos Fusíveis:** são dispositivos de proteção, largamente, utilizados em sistemas de distribuição. Aparecem juntos das chaves fusíveis, as quais, em caso de rompimento do fusível, abrem os contatos e permitem manobras em certas situações. A atuação do elo fusível acontece quando uma corrente superior a sua capacidade de condução percorre o elemento fusível. Assim sendo, ele fundirá, interrompendo a circulação de corrente pelo circuito. Sua troca deve ser realizada manualmente.
- **Religadores Automáticos:** atualmente, o uso de tais equipamentos tem aumentado em consequência do maior faturamento, quando comparado à utilização de elos fusíveis, já que estes não são capazes de distinguir faltas permanentes e transitórias. O religador deverá tentar “limpar” uma falta, caso esta seja transitória (característica instantânea). Em caso de a falta ser permanente, ele deverá permitir a atuação do dispositivo de proteção mais próximo da falta (característica temporizada). As distribuidoras de energia elétrica os utilizam, geralmente,

próximos das fontes adicionais que contenham pontos críticos, em ramais importantes, trechos sujeitos às descargas atmosféricas e trechos arborizados

- **Seccionalizadores Automáticos:** aumentam a confiabilidade do sistema. Ocorrida uma falta permanente na zona principal do seccionizador, este, assim como o religador, será excitado. O religador deverá fazer uma série de desligamentos, obedecendo à sequência pré-ajustada, enquanto que o seccionizador efetuará as contagens do número de desligamentos. Quando for atingido o número de contagens ajustadas, o seccionizador abrirá seus contatos, sempre com o circuito desenergizado.
- **Disjuntores:** são dispositivos eletromecânicos de abertura e fechamento comandados pelos relés. Pode-se ver, na figura 2.2, a importância da presença dos disjuntores em subestações. As especificações técnicas de disjuntores de alta tensão alternada, utilizados em subestações, são regularizadas pela norma **NBR IEC 62271-100:**

“ABNT NBR IEC 62271-100: Equipamentos de alta-tensão - Parte 100: Disjuntores de alta-tensão de corrente alternada.

Aplica-se a disjuntores de corrente alternada, projetados para uso interior e exterior e para operação a frequências de 50 Hz e 60 Hz em sistemas de tensões acima de 1000 V. Origem: 03:017.01-003. Palavras-chave: Alta-tensão. Disjuntor. Corrente alternada – 275 páginas” (ABNT, 2008).

- **Relés:** estes aparelhos, ao detectarem uma perturbação que venha a comprometer os equipamentos ou o funcionamento normal do sistema, enviam um sinal elétrico com a finalidade de comandar a abertura de um ou mais disjuntores. Esta ação isolará o equipamento ou parte do sistema afetado pela falha, impedindo que a perturbação danifique equipamentos, comprometa a operação ou se propague para outros componentes defeituosos. Os relés mais empregados nos sistemas elétricos são: relé de sobrecorrente, relé de sobrecorrente direcional, relé de sobretensão, relé de subtensão, relé de distância, relé diferencial, relé de religamento e relé direcional de potência. No âmbito da distribuição de energia elétri-

ca, são mais importantes os relés de sobrecorrente e os relés de religamento (GIGUER, 1988).

2.4. Conclusão

É inegável a necessidade de conhecimentos sobre subestações para este trabalho. Através de estudos na área, pôde-se analisar as principais formas de barramentos, assim como as funções desempenhadas pelos equipamentos existentes. Deve-se denotar, também, a importância de se automatizar as subestações, uma vez que, devido à situação atual, os critérios de fiscalização, sobre o correto funcionamento de complexos elétricos, são, cada vez mais, exigentes.

Capítulo 3: Transformada Discreta de *Fourier* aplicada à Representação de Sinais Elétricos

A partir da Geração, passando pela Transmissão e finalizando com a Distribuição, os valores de corrente e tensões elétricas passam por várias mudanças, sendo estas aplicáveis concomitantemente com o ambiente em que se encontram os referidos parâmetros. Entretanto, tais modificações não interferem na grandeza que sempre deverá se apresentar imutável: a frequência. Tal, geralmente, encontra-se fixada em 50 ou 60 hertz.

Assim sendo, com os formatos de onda de tensão e corrente periódicos, afirma-se que estes poderão ser representados, completamente, através de dois valores: amplitude e ângulo de fase. Toma-se, então, uma corrente $i(t)$ puramente senoidal. Tem-se, assim:

$$i(t) = I_m \cdot \cos(\omega t + \alpha) \quad (3.1)$$

sendo:

- ω : frequência do sinal de corrente;
- I_m : amplitude do sinal;
- α : ângulo de fase.

Este sinal $i(t)$ poderá ser representado, fasorialmente, através da seguinte relação:

$$i(t) = \operatorname{Re}\{I_m \cdot e^{j(\omega t + \alpha)}\} = \operatorname{Re}\left\{\sqrt{2} \cdot \frac{I_m}{\sqrt{2}} \cdot e^{j\alpha} \cdot e^{j\omega t}\right\} = \sqrt{2} \cdot \operatorname{Re}\{\mathbf{I} \cdot e^{j\omega t}\} \quad (3.2)$$

sendo:

- \mathbf{I} : fasor representativo da corrente $i(t)$.

Contudo, deve-se lembrar que os sinais de corrente e tensão não apresentam um formato puramente senoidal. Para estes casos, a representação, utilizando-se somente a relação (3.2), torna-se inviável. Assim, será apresentada, a seguir uma forma generalizada de se representar sinais periódicos não-senoidais (MATOS, 2009).

3.1. Representação Fasorial de Sinais Contínuos

Toma-se uma função $s(t)$ contínua e periódica de período T . Pode-se afirmar, então, que, para todo r inteiro, tem-se $s(t) = s(t + r.T)$. A partir disto, esta função poderá ser representada através de uma Série de *Fourier* (HSU, 1972):

$$s(t) = \frac{a_0}{2} + \sum_{n=1}^{\infty} [a_n \cdot \cos(n\Omega t) + b_n \cdot \sin(n\Omega t)] \quad (3.3)$$

sendo:

- a_0, a_n, b_n : coeficientes da Série de *Fourier*, dados por:

$$a_0 = \frac{2}{T} \cdot \int_T s(t) dt \quad (3.4)$$

$$a_n = \frac{2}{T} \cdot \int_T s(t) \cdot \cos(n\Omega t) dt \quad (3.5)$$

$$b_n = \frac{2}{T} \cdot \int_T s(t) \cdot \sin(n\Omega t) dt \quad (3.6)$$

onde:

$$\Omega = \frac{2\pi}{T} \quad (3.7)$$

A equação (3.3) é chamada de forma trigonométrica retangular da representação de *Fourier*. Outro formato, este mais compacto, seria a representação complexa da série. Sua relação é concebida partindo-se da identidade de Euler:

$$\cos(n\Omega t) = \frac{e^{jn\Omega t} + e^{-jn\Omega t}}{2} \quad (3.8)$$

$$\sin(n\Omega t) = \frac{e^{jn\Omega t} - e^{-jn\Omega t}}{j2} \quad (3.9)$$

Substituindo, deste modo, as equações (3.8) e (3.9) na (3.3), chega-se à forma complexa da Série de *Fourier* de $s(t)$, dada por:

$$s(t) = \sum_{n=-\infty}^{\infty} c_n \cdot e^{jn\Omega t} \quad (3.10)$$

sendo:

$$c_n = \frac{a_n - jb_n}{2} = \frac{1}{T} \cdot \int_T s(t) \cdot e^{-jn\Omega t} dt \quad (3.11)$$

Deve-se observar que, apesar de $s(t)$ ser uma função contínua no tempo, sua Série de *Fourier* é discreta em relação à variável $n\Omega$.

Uma terceira forma de representação da Série de *Fourier*, estando esta mais adequada à utilização na engenharia elétrica, denomina-se de forma trigonométrica polar, dada pela relação (ORSINI, 1994):

$$s(t) = C_0 + \sum_{n=1}^{\infty} C_n \cdot \cos(n\Omega t + \alpha_n) \quad (3.12)$$

sendo:

$$C_0 = \frac{a_0}{2} = c_0 \quad (3.13)$$

$$C_n = \sqrt{a_n^2 + b_n^2} = 2 \cdot |c_n| \quad (3.14)$$

$$\alpha_n = \tan^{-1} \left(\frac{-b_n}{a_n} \right) = \arg(c_n) \quad (3.15)$$

Desta forma, pode-se representar sinais de correntes elétricas através das relações apresentadas, principalmente, a partir da equação (3.12). Retornando-se ao sinal $i(t)$, este poderá ser dado por:

$$i(t) = I_0 + \sum_{n=1}^M I_n \cdot \cos(n\Omega t + \alpha_n) = I_0 + I_1 \cdot \cos(\Omega t + \alpha_1) + \dots + I_M \cdot \cos(M\Omega t + \alpha_M) \quad (3.16)$$

Neste caso, nota-se que o extremo superior do somatório não é infinito, ao contrário do que ocorre com a relação (3.12). Esta modificação foi realizada já visando sua aplicação na representação de sinais elétricos.

Mais adiante, demonstra-se que será interessante a concepção de um vetor que contenha os coeficientes da Série de *Fourier* da corrente elétrica. Este vetor é tal que:

$$\vec{I} = \left[I_0 \quad \frac{I_1}{\sqrt{2}} \cdot e^{-j\alpha_1} \quad \dots \quad \frac{I_M}{\sqrt{2}} \cdot e^{-j\alpha_M} \right] \quad (3.17)$$

3.2. Representação Fasorial de Sinais Discretos

No tópico anterior, foram expostas definições e equações referentes a aplicações em sinais contínuos. A partir de agora, serão detalhados procedimentos de utilização da Transformada de *Fourier* na decomposição de sinais discretos. Para isso, as equações anteriores deverão ser adaptadas para que se possibilite o almejado processamento digital de sinais (MATOS, 2009).

A partir daí, então, considera-se um sinal discreto $s[n]$. Tal será uma sequência finita de N amostras da função analógica, já referida acima, $s(t)$, podendo esta ser de corrente ou tensão. Sua representação, no domínio da frequência, poderá ser concebida através da aplicação da Transformada de *Fourier* (de tempo discreto) (OPPENHEIM; SCHAFER; BUCK, 1999):

$$S(e^{j\omega}) = \sum_{n=-\infty}^{\infty} s[n] \cdot e^{-j\omega n} \quad (3.18)$$

$S(e^{j\omega})$ trata-se de uma função contínua, complexa e periódica em ω . Por $e^{j\omega n}$ (para todo n inteiro) possuir um período de 2π , sendo assim, $S(e^{j\omega})$ terá um período de 2π radianos. Caso se queira obter $s[n]$ a partir de sua representação no domínio da frequência, aplica-se a Transformada Inversa de *Fourier* sobre $S(e^{j\omega})$:

$$s[n] = \frac{1}{2\pi} \cdot \int_{-\pi}^{\pi} S(e^{j\omega}) \cdot e^{j\omega n} d\omega \quad (3.19)$$

Já que $S(e^{j\omega})$ é uma função contínua, tal fato traz algumas complicações quanto ao seu processamento digital de sinais. O ideal seria que a representação de *Fourier* fosse uma onda discreta, ou seja, uma sequência de pontos. Daí, torna-se mais benéfica a utilização da Transformada Discreta de *Fourier* (DFT). Assim como disposto, na equação (3.11), tal expansão também apresentará coeficientes, dados pela relação:

$$c_k = \frac{1}{T} \cdot \int_T s(t) \cdot e^{-jk\Omega t} dt \quad (3.20)$$

Através do método de *Euler*, pode-se aproximar esta equação do seguinte modo:

$$c_k = \frac{1}{T} \cdot \int_0^T s(t) \cdot e^{-jk\Omega t} dt \cong \frac{1}{T} \cdot \sum_{n=0}^{N-1} s(nT_s) \cdot e^{-jk\Omega \cdot nT_s} \cdot T_s \quad (3.21)$$

sendo:

- T_s : período de amostragem, dado por:

$$T_s = \frac{T}{N} \quad (3.22)$$

Deve-se observar que, quanto maior for N , melhor será a aproximação da equação (3.21). Isto se conclui através do raciocínio de que, quanto maior for o número de pontos amostrados do sinal $s(t)$, maior será a fidelidade dos resultados derivados do processamento desta função.

Pode-se, também, concluir que $s[n]$ possui com $s(t)$ a seguinte relação:

$$s[n] = s(nT_s) \quad (3.23)$$

Logo, substituindo-se as relações (3.7), (3.22) e (3.23) em (3.21), chega-se em (ORSINI, 1994):

$$c_k \cong \frac{1}{T} \cdot \sum_{n=0}^{N-1} s[n] \cdot e^{-jk \frac{2\pi}{T} n} \cdot \frac{T}{N} = \frac{1}{N} \cdot \sum_{n=0}^{N-1} s[n] \cdot e^{-jk \frac{2\pi}{N} n} \quad (3.24)$$

A DFT do sinal discreto $s[n]$ é definida formalmente como:

$$S[k] = \sum_{n=0}^{N-1} s[n] \cdot e^{-jk \frac{2\pi}{N} n} \quad (3.25)$$

Das relações (3.24) e (3.25), é possível demonstrar que (ORSINI, 1994):

$$\begin{cases} S[k] = N \cdot c_k \\ S[N - k] = N \cdot c_{-k} \end{cases} \quad \text{para } k = 0, 1, 2, \dots, M \quad (3.26)$$

Uma interpretação interessante da DFT é a de que se trata de uma amostragem em frequência, feita em intervalos constantes de $2\pi/N$ radianos, na Transformada da sequência original, ou seja (OPPENHEIM; SCHAFER; BUCK, 1999):

$$S[k] = S(e^{j\omega}) \Big|_{\omega = \frac{2\pi}{N} k} \quad (3.27)$$

Aqui, também há a possibilidade de se obter a inversa da DFT (IDFT):

$$s[n] = \sum_{k=0}^N s[k] \cdot e^{jk \frac{2\pi}{N} n} \quad (3.28)$$

A partir da resolução anterior, principalmente em relação às equações (3.25) e (3.26), obtêm-se os fasores representativos do sinal $s(t)$. Relembrando que $C_0 = c_0$, $C_k = 2 \cdot |c_k|$, $\alpha_k = \arg(c_k)$ e sendo:

$$s(t) = C_0 + \sum_{k=1}^M C_k \cdot \cos(k\omega t + \alpha_k) \quad (3.29)$$

possibilita-se a estruturação do vetor que constitui uma representação fasorial de $s(t)$:

$$\vec{s} = \left[C_0 \quad \frac{C_1}{\sqrt{2}} \cdot e^{j\alpha_1} \quad \dots \quad \frac{C_M}{\sqrt{2}} \cdot e^{j\alpha_M} \right] \quad (3.30)$$

Finalmente, chega-se, assim, a partir da relação (3.26), a:

$$\vec{s} = \frac{1}{N} \cdot [s[0] \quad \sqrt{2} \cdot |s[1]| \cdot e^{j \cdot \arg(s[1])} \quad \dots \quad \sqrt{2} \cdot |s[M]| \cdot e^{j \cdot \arg(s[M])}] \quad (3.31)$$

Na prática, esses procedimentos estão, cada vez mais, sendo simplificados através da aplicação da Transformada Rápida de *Fourier* (FFT) (ELLIOT; RAO, 1982). Isso possibilitou a utilização dos conceitos da DFT em diversas áreas, como análise espectral de sinais, aplicações médicas, processamentos de sinais de radar, processamento digital de imagens, análise de vibrações mecânicas e análise e reconhecimento de padrões, dentre muitas outras.

3.3. Conclusão

O capítulo tem a finalidade de apresentar fundamentos relacionados à aplicação de uma importante ferramenta matemática: a Transformada de *Fourier*. Este recurso

possibilita a representação de sinais periódicos, sem perdas de informações, através de vetores de coeficientes. Apontam-se, assim, uma importante vantagem proveniente deste tipo de representação, já que o manuseio de vetores é de grande utilização na concepção de algoritmos computacionais. Aqui, neste trabalho, a Transformada de *Fourier* é de grande valia, uma vez que será responsável pela representação de sinais discretos. Deste modo, também foram apresentadas as formulações quanto à Transformada de *Fourier* Discreta (DFT), sendo ela um dos principais destaques da primeira etapa do algoritmo formulado.

Capítulo 4: Análise *Wavelet*

Como visto, no capítulo anterior, a Transformada de *Fourier* trata-se como uma importante ferramenta, já que decompõe o sinal em coeficientes, sendo este processamento realizado na escala da frequência. A partir de agora, será apresentado um outro recurso que, assim como a DFT, também desmembra sinais em coeficientes: a Transformada *Wavelet*.

A principal diferença entre *Wavelet* e *Fourier* é que a primeira opera no domínio do tempo, descartando a condição exigida pela segunda: a de operar na escala da frequência. Além disso, do ponto de vista de processamento de sinais, a Transformada *Wavelet* comporta-se como uma operação de filtragem de um sinal $f(t)$, executada por um filtro cujos coeficientes são gerados pela função *Wavelet* que está sendo usada na análise.

Iniciando, então, a análise matemática e vetorial das Transformadas *Wavelets*, toma-se um conjunto $L^2(\mathbb{R})$. Estabelece-se que tal trata-se de um espaço de funções de quadrado integrável, ou seja, de funções de energia finita. Deste modo, se $\psi(t) \in L^2(\mathbb{R})$, então (HÖNIG, 1977):

$$\int_{-\infty}^{+\infty} |\psi(T)|^2 dt < \infty \quad (4.31)$$

Além disso, $\psi(t)$ é denominada como uma *Wavelet* se, e somente se, sua Transformada de *Fourier*, $\hat{\Psi}(\omega)$, satisfizer a seguinte relação (condição da admissibilidade) (DAUBECHIES, 1992):

$$C_{\psi} = \int_{-\infty}^{+\infty} \frac{|\hat{\Psi}(\omega)|^2}{|\omega|} d\omega < \infty \quad (4.2)$$

4.1. Transformada *Wavelet*

Assim como outras transformadas, a Transformada *Wavelet* é aplicada através do janelamento inicial da função em questão. Contudo, no caso das outras, as janelas possuem escalas (ou “larguras”) fixas, apresentando alguns problemas de distorção, falta de detalhes ou, até mesmo, já em aplicações práticas, alto custo computacional. A partir disso, chega-se a um dos principais diferenciais proporcionados pela Transformada *Wavelet*: sua escala de janelas é variável. Retorna-se, então, a $\psi(t)$ como função de modulação. Haverá que (DAUBECHIES, 1992):

$$\psi_{a,b}(t) = |\alpha|^{-p} \cdot \psi\left(\frac{t-b}{\alpha}\right), \quad p/\alpha \in \mathbb{R}_+^* \quad (4.3)$$

sendo:

- a : parâmetro de escala: quanto maior for a , maior será a escala utilizada no janelamento;
- p : parâmetro de translação, coeficiente a ser aplicado sobre o termo a .

Desta maneira, definida a função moduladora $\psi_a(t)$, considera-se uma função $f(t)$. Sua Transformada *Wavelet* contínua será dada a seguir (DAUBECHIES, 1992):

$$W_f(a,b) = \langle f, \psi(a,b) \rangle = \int_{-\infty}^{+\infty} f(t) \cdot |\alpha|^{-p} \cdot \psi^*\left(\frac{t-b}{\alpha}\right) dt \quad (4.4)$$

sendo:

- ψ^* : complexo conjugado de ψ .

Assumindo-se $p = 1/2$, resulta em:

$$W_f(a,b) = \langle f, \psi(a,b) \rangle = \frac{1}{\sqrt{|\alpha|}} \int_{-\infty}^{+\infty} f(t) \cdot \psi^*\left(\frac{t-b}{\alpha}\right) dt \quad (4.5)$$

4.2. Análise de Multirresolução e Bancos de Filtros

Primeiramente, retorna-se ao sinal a ser analisado $f(t)$. Quando este sinal é amostrado a uma frequência 2^j , serão representados os detalhes cujas complexidades não ultrapassem a mencionada frequência de amostragem. Porém, caso se deseje, também, a análise destes detalhes mais ínfimos, conclui-se que a frequência de amostragem deverá ser maior. Ou seja, o janelamento deverá ser provido de uma resolução maior (2^k , com $k > j$).

Deste modo, define-se uma família de funções moduladoras $\phi(t) \in L^2(\mathbb{R})$ (DUARTE, 2005):

$$\phi_{j,k}(t) = 2^{-j/2} \cdot \phi\left(2^{-j} \cdot (t - k)\right), \quad p/ \quad j, k \in \mathbb{Z} \quad (4.6)$$

A partir deste raciocínio, exemplificam-se os conjuntos de subespaços fechados V_j e V_{j-1} , representados pela figura 4.1. Pode-se notar que tais subespaços representarão as janelas para as frequências de amostragem de 2^j e 2^{j-1} , respectivamente.




Figura 4.1 – Espectro das janelas referentes aos subespaços V_j e V_{j-1} .

A partir da figura 4.1, observa-se que $V_{j-1} \supseteq V_j$. Isto faz com que haja, entre os dois conjuntos, um determinado espaço. Na figura, este complemento é chamado de W_j .

Este tipo de análise recebe, então, o nome de Análise Multiresolução (AMR) (DAUBECHIES, 1992). A função de escala de uma AMR é um filtro passa-baixa e a *Wavelet* associada é um filtro passa-alta. Será mostrado, agora, que uma AMR define um banco de filtros.

Inicialmente, faz-se as seguintes definições:

$$L_j(f) = Proj_{V_j}(f) \quad (4.7)$$

$$H_j(f) = Proj_{W_j}(f) \quad (4.8)$$

sendo:

- **$Proj_{V_j}$, $Proj_{W_j}$** : projeções ortogonais dos espaços V_j e W_j , respectivamente (DUARTE, 2005).

Desta maneira, pode-se afirmar que (DUARTE, 2005):

$$L_{j-1}(f) = L_j(f) + H_j(f) \quad (4.9)$$

Decompondo-se, assim, $L_j(f)$ de forma sucessiva, conclui-se que:

$$L_{j-1}(f) = L_k(f) + H_k(f) + H_{k-1}(f) + \dots + H_j(f) \quad (4.10)$$

Ou seja, o sinal $f(t)$ é decomposto num componente de baixa frequência, $L_k(f)$, porém, sem muitos detalhes, juntamente com componentes de altas frequências, $H_n(f)$ ($n = k, k-1, \dots, j$), que contêm os detalhes perdidos na representação em baixa frequência. A figura 4.2 ilustra a relação (4.10), com a análise - ou decomposição - de $f(t)$ através de um banco de filtros.




Figura 4.2 – Diagrama ilustrativo de decomposição através de um banco de filtros.

Assim, conclui-se que a aplicação da Transformada *Wavelet* consiste em aplicar, sobre um sinal genérico $f(t)$ – que poderia ser, por exemplo, de corrente ou tensão –, uma sucessão de filtros passa-baixa. Suas frequências de corte apresentarão, entre si, uma proporção logarítmica de 2^j . Desta maneira, a cada aplicação de um novo filtro, mais detalhes do sinal serão amostrados, podendo, até mesmo, após a aplicação da Transformada, haver uma reconstrução – ou síntese – do sinal. Isso se daria a partir do processo inverso, como pode ser visto na figura 4.3.




Figura 4.3 – Diagrama ilustrativo da reconstrução

O diagrama apresentado, na figura 4.2, ilustra a Transformada *Wavelet* Discreta (DWT). Já, na figura 4.3, tem-se a Transformada *Wavelet* Discreta Inversa (IDWT). Desta forma, pode-se concluir que a DWT decompõe um determinado sinal $f(t)$ em altas e baixas frequências.

4.3. Conclusão

Apresentou-se, assim, tópicos bem gerais referentes às Transformadas *Wavelet*. Ao se comparar tal recurso matemático com a, anteriormente, exposta Transformada de *Fourier*, notam-se algumas semelhanças – principalmente quanto à decomposição do sinal amostrado em coeficientes – e diferenças – a Transformada *Wavelet* dispensa a passagem do sinal do domínio do tempo para o da frequência – marcantes. Deve-se ressaltar que o tópico foi destrinchado de uma maneira bem centrada naquilo que foi aplicado no algoritmo, dando maiores ênfases na, propriamente dita, Transformada *Wavelet* e na passagem do sinal pelos filtros e sua conseqüente decomposição em faixas de frequência.

Capítulo 5: Redes Neurais Artificiais

Com o desenvolvimento da inteligência artificial, surgiram idéias de como representar, através de determinados programas, o funcionamento do processo de aprendizagem do cérebro humano. A tentativa de emular a rede neural do cérebro deu origem à chamada Rede Neural Artificial (LOPES, 2005).

5.1. Características Gerais e o Modelo Biológico

Na obra “*Neural Networks: A Comprehensive Foundation*” (HAYKIN, 1999), pode ser verificada a seguinte definição para as Redes Neurais Artificiais (RNAs):

“Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso.”

A idéia da concepção de redes neurais é chegar a padrões de classificação de eventos através de um aprendizado realizado antes da utilização, propriamente dita, da RNA em um sistema prático ou simulado. Tal característica é comparada ao funcionamento do cérebro humano, quando se observa a atuação de um neurônio junto de outros seus vizinhos, através das sinapses. Desta forma, torna-se interessante um pré-conhecimento, em termos biológicos, das células nervosas cerebrais.

No cérebro humano são encontrados mais de 100 bilhões de neurônios, responsáveis pelo comando das mais diversas atividades humanas, tanto em nível físico quanto pensante. A figura 5.1 esboça, de modo simples, as principais partes formadoras das células nervosas (MENDES FILHO; CARVALHO, 1997).

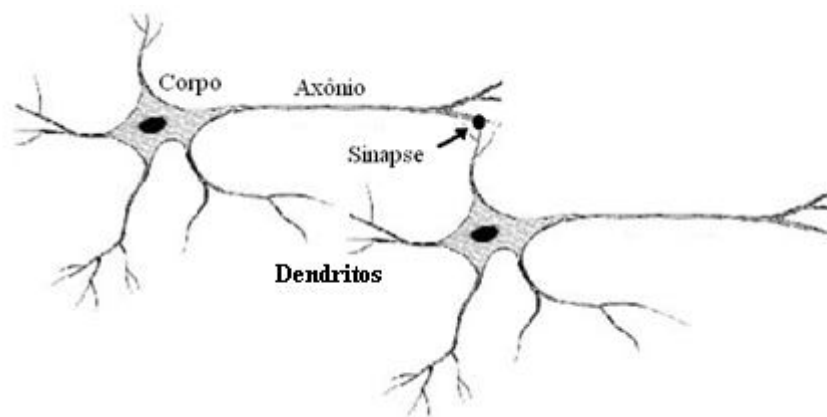


Figura 5.1 – Esquema básico de dois neurônios, suas principais partes e sinapse.

Os neurônios interligam-se através de seus axônios – ramificação mais alongada – e dendritos. Entre estes, aparecem as sinapses, responsáveis por gerar impulsos nervosos de célula para célula. Tais impulsos, para que sejam reconhecidos pelo neurônio vizinho, deverão alcançar um grau mínimo de excitação (*threshold*). Pode-se afirmar que este processo é o grande responsável pela atribuição da inteligência (LOPES, 2005).

Essas definições e o conhecimento biológico são usados para criar as estruturas das Redes Neurais Artificiais. Assim como no modelo biológico, uma RNA é constituída pela interconexão de elementos simples de processamento, os neurônios artificiais, que são conectados pelas, aqui, também nomeadas de sinapses.

As RNAs possuem a capacidade de aprender a definir padrões, classificando-os de acordo com a função desejada pelo operador. Tal aprendizado é chamado de treinamento, podendo este ser supervisionado ou não-supervisionado (MATOS, 2009).

As Redes Neurais podem ser utilizadas com eficiência em sistemas de potência em uma variedade de aplicações, tais como: previsão de cargas elétricas (ALTRAN, 2005), análise de estabilidade transitória (LOTUFO, 2004; LOPES, 2005), proteção de transformadores de potência (SEGATTO; COURY, 2008) e diagnósticos de faltas (BO et al, 1997; MORA FLÓREZ; MORALES ESPAÑA; PÉREZ LONDOÑO, 2008; OLESKOVICZ; AGGARWAL; COURY, 2003; MORETO, 2005; CARDOSO JR; ROLLIM; ZÜRN, 2004; SILVA et al, 2007).

5.2. O Neurônio Artificial

Assim como o cérebro humano, uma RNA possui, como unidade básica de processamento de informação, o neurônio artificial (figura 5.2), estando este designado a atuar com características semelhantes às apresentadas pelos neurônios biológicos, dentre elas (HAYKIN, 1999):

- **Processamento paralelo maciço:** estruturação do conhecimento através do treinamento;
- **Conexões sinápticas:** são as interligações entre os neurônios, responsáveis pela troca e armazenamento de informações;
- **Capacidade de generalização:** permite que a rede neural forneça, em tempo real e com considerável precisão, saídas correspondentes a entradas que não participaram do treinamento.




Figura 5.2 – Representação de um neurônio artificial

O processo de treinamento do neurônio artificial é muito simples e se desenvolve nos seguintes passos (HAYKIN, 1999):

1. Um conjunto X de entradas x_1, x_2, \dots, x_n é aplicado ao neurônio artificial. As entradas correspondem aos sinais dentro das sinapses de um neurônio biológico.
2. Cada sinal é multiplicado por um peso W associado W_1, W_2, \dots, W_n , que está relacionado com a “resistência” de uma única ligação sináptica biológica.
3. Em seguida, estes são aplicados a um bloco somatório, Σ , denominado soma, que corresponde ao corpo celular biológico.

4. Se a soma ponderada das entradas for maior que o valor de W_0 (peso *bias*), o neurônio é ativado, provocando um pulso na saída y . Caso contrário, o neurônio não é ativado. O peso *bias* pondera uma entrada (arbitrária) $X_0 = +1$, que atua como controle do nível de saída do neurônio.

Tais etapas poderão, então, ser resumidos pela fórmula:

$$y = f(s) = f\left(\sum_{i=0}^n W_i \cdot X_i\right) \quad (5.1)$$

O pulso, na saída y , poderá ser de diferentes magnitudes, restringidas entre 0 e 1, dependendo da relação apresentada pela função de ativação $f(\cdot)$ (MATOS, 2009). Existem diferentes formatos de funções, sendo as mais comuns:

- **Função Relé (ou Limiar de Heaviside):**

Tal função é utilizada para casos em que apenas se interessam respostas binárias, ou seja, 0 ou 1. Sua fórmula é dada por:

$$f(s) = \begin{cases} 1 & \text{se } s \geq 0 \\ 0 & \text{se } s < 0 \end{cases} \quad (5.2)$$

Gráfico da Função Relé:




Figura 5.3 – Gráfico da função Relé.

- **Função Linear:**

Dada pela equação:

$$f(s) = \begin{cases} 1 & \text{se } s \geq \frac{1}{2} \\ s & \text{se } -\frac{1}{2} < s < \frac{1}{2} \\ 0 & \text{se } s \leq -\frac{1}{2} \end{cases} \quad (5.3)$$

Gráfico da Função Linear:




Figura 5.4 – Gráfico da função Linear.

- **Função Sigmoidal (ou Sigmóide):**

Trata-se da função mais utilizada em operações que envolvem redes neurais artificiais por ser facilmente derivável, estritamente crescente e possuir um balanceamento adequado entre componentes linear e não-linear (MATOS, 2009). Sua equação é dada por:

$$f(s) = \frac{1}{1 + e^{-a \cdot s}} \quad (5.4)$$

sendo a o nível de inclinação da função. Seu gráfico será:




Figura 5.5 – Gráfico da função Sigmoidal para diferentes valores de a .

▪ Função Tangente Hiperbólica:

A Tangente Hiperbólica é uma espécie de função Sigmoidal, com o recurso adicional de possibilitar saídas que variam, não somente, entre 0 e 1, mas entre -1 e 1 (MATOS, 2009). Sua equação é dada por:

$$f(s) = \frac{e^{a \cdot s} - e^{-a \cdot s}}{e^{a \cdot s} + e^{-a \cdot s}} \quad (5.5)$$

Assim como para a função sigmoidal, o termo a também denotará o grau de inclinação da função Tangente Hiperbólica. Seu gráfico será:




Figura 5.6 – Gráfico da função Tangente Hiperbólica para diferentes valores de a .

5.3. Arquiteturas de RNAs

Uma RNA pode ser estruturada de várias formas, de acordo com as funções nas quais será aplicada a rede. Alguns importantes parâmetros deverão ser considerados, no momento do projeto, para a concepção inicial da rede: número de camadas, número de neurônios por camadas, tipo de conexões entre os neurônios e a topologia da rede. Basicamente, ela é composta por três camadas, classificadas em três grupos (HAYKIN, 1999):

- **Camada de Entrada:** onde os padrões são apresentados à rede;
- **Camadas Intermediárias ou Ocultas:** onde é feita a maior parte do processamento, através das conexões ponderadas;
- **Camada de Saída:** onde o resultado final é concluído e apresentado.

No que se refere ao tipo de conexão entre os neurônios, ou seja, ao modo de propagação de dados, há duas classificações:

- **Redes Acíclicas (ou *Feedforward*):** os dados são propagados na direção entrada-saídas, estritamente. Dessa forma, não haverá realimentações no decorrer da rede. Tal simplificação, no fluxo de dados, possibilita extrações estatísticas de ordem elevada dos dados entrada. Na figura 5.7, encontra-se o esquema de uma rede Acíclica (HAYKIN, 1999).




Figura 5.7 – Esquema de uma RNA acíclica, contendo quatro entradas, uma camada intermediária com três neurônios e dois neurônios de saída.

Redes Cíclicas (ou Recorrentes ou *Backpropagation*): apresenta conexões *feedback*, ou seja, existência de realimentação, possibilitando que informações concebidas mais próximas às últimas camadas influenciem em camadas posteriores. Em muitos casos, os valores de ativação das unidades submetem-se a um processo de adaptação, tal que a rede convergirá para um estado estável, no qual essas ativações não variarão mais (KROSE; SMAGT, 1996). A figura 5.8 ilustra um exemplo de uma rede cíclica.

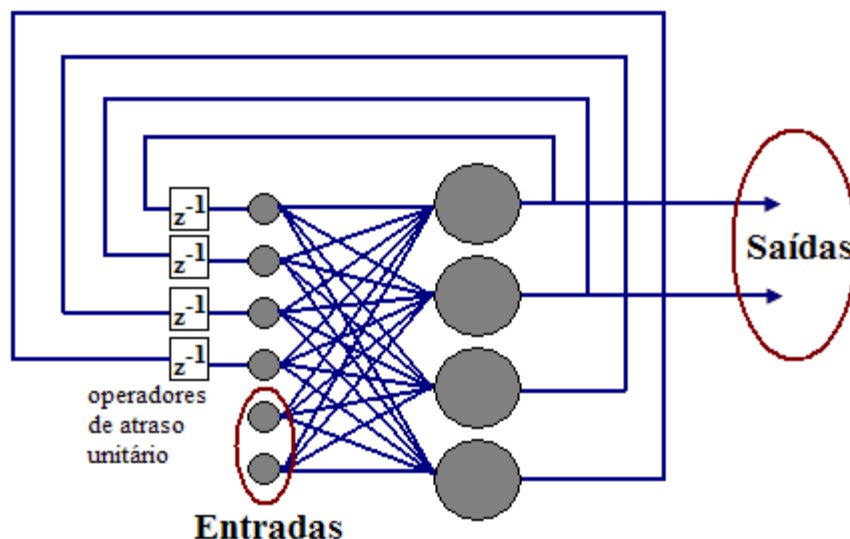


Figura 5.8 – Esquema de uma RNA Cíclica, com duas entradas e duas saídas.

5.4. Treinamento de Redes Neurais Artificiais

A característica primordial de uma rede neural é sua habilidade de aprender a partir de seu ambiente e de melhorar o seu desempenho através da aprendizagem (HAYKIN, 1999). Isso é feito através de um processo iterativo de ajustes aplicados a seus pesos: o treinamento. Quando a rede neural atinge uma solução generalizada para uma classe de problemas, ocorre o Aprendizado ou Treinamento. Pode-se classificar o aprendizado em grupos distintos:

- **Aprendizagem Supervisionada** – A rede é treinada através de padrões de entradas e de saídas. Este treinamento utiliza um agente externo (professor) que informa à rede a resposta desejada para o padrão de entrada. O professor adqui-

re conhecimento da rede, na forma de mapeamentos (padrões) de entrada-saída. Dentre algumas redes que possuem este tipo de treinamento, pode-se citar: a rede Adaline, que utiliza o algoritmo de aprendizagem *Backpropagation*, a rede Grossberg, a rede ARTMAP, a rede ARTMAP Nebulosa, entre outras (LOPES, 2005; KROSE; SMAGT, 1996).

- **Aprendizagem Não-Supervisionada** – O treinamento consiste, exclusivamente, de vetores de entradas. Este treinamento não possui um agente externo (professor) informando à rede a resposta desejada para o padrão de entrada. A partir desta conjuntura, a rede projetada deverá ser capaz de efetuar seu aprendizado através de um processamento estatístico dos padrões de entrada juntos de seus respectivos resultados na saída. Como exemplos de redes que utilizam este tipo de treinamento, pode-se citar *Hopfield*, *Kohonen* e ART (LOPES, 2005; KROSE; SMAGT, 1996).

Dentre os diversos algoritmos destinados a treinar RNAs, destacam-se:

- Regra de *Heeb*;
- Regra Delta de *Widrow e Hoff*;
- Regra Delta Generalizada;
- Algoritmo de Aprendizagem *Backpropagation*.

5.5. Conclusão

Neste capítulo, foram mostrados conceitos pertinentes ao conhecimento de uma importante ferramenta: as Redes Neurais Artificiais. Tal artifício foi criado com o intuito de se emular algumas características do cérebro humano, principalmente, no que diz respeito à capacidade de aprendizado, apresentando, assim, como unidade fundamental, o neurônio artificial. Sua propriedade de treinamento, através de atualizações de pesos, é um grande chamativo para pesquisadores que atuam nas mais diversas áreas. Após passar por muitas reformulações e ramificações, as RNAs, indubitavelmente, conquistaram um importante papel entre os principais algoritmos classificadores.

Capítulo 6: Teoria da Ressonância Adaptativa

6.1. Introdução e Motivação

Como citado, no capítulo anterior, uma das principais características das Redes Neurais Artificiais é a sua capacidade de generalização. Através de padrões, previamente apresentados à rede (fase de treinamento), esta será capaz de classificar dados posteriores. A rede neural, então, irá comparar dados atuais com aqueles presentes na fase de treinamento. Essa capacidade de generalização é um dos principais atrativos, quando se trabalha com RNAs.

Porém, deve-se salientar que, ao se projetar um algoritmo ou programa, espera-se que este opere em um tempo indefinido, para infinitos tipos de padrões ou, até mesmo, para mudanças e evoluções que estes venham a sofrer. Neste paradigma, alguns algoritmos propostos para RNAs podem apresentar certos problemas: um grande número de padrões é apresentado à rede por um longo período. Logo, é de se esperar que, com o tempo, apareça uma infinidade de padrões diferentes e evoluídos, podendo acontecer que alguns destes não estejam em conformidade com os apresentados na fase treinamento.

Haverá, assim, a possibilidade de que a rede, não-familiarizada com estes novos tipos de vetores de entrada, venha a classificar alguns casos de maneira errônea. Desta forma, torna-se interessante que uma rede neural adapte-se a novos tipos de padrões, ou seja, que ela seja plástica (MARCHIORI, 2006).

Poder-se-ia pensar numa maneira de se chegar a essa condição de plasticidade: retrainar a rede com os novos padrões de entrada. Contudo, tal ação faria com que os pesos atualizados, no primeiro treinamento, se perdessem, prejudicando a classificação de padrões antigos. Outra saída seria o treinamento periódico da rede, utilizando-se tanto os padrões antigos como os atuais. Todavia, à medida que o número de padrões fosse aumentando, chegaria o momento que o treinamento se tornaria inviável, tornando a rede instável. Este conflito é conhecido como “Dilema Estabilidade-Plasticidade” (CARPENTER; GROSSBERG, 1991).

Para estes casos em que se deseja que a rede trabalhe durante um longo período, havendo uma contínua possibilidade do aparecimento de novos padrões, e que atualize seus pesos de forma contínua e incremental, foi desenvolvida uma nova família de redes neurais artificiais, denominada ART (*Adaptive Resonance Theory*: Teoria da Ressonância Adaptativa) (CARPENTER; GROSSBERG, 1991).

6.2. Características Básicas das Redes ART

A Teoria da ressonância adaptativa é de grande utilidade, quando se deseja reconhecer e classificar padrões. Suas características lhe dão a capacidade de auto-organizar padrões de entrada em categorias de reconhecimento, mantendo, como citado no tópico anterior, um satisfatório equilíbrio entre plasticidade e estabilidade (MARCHIORI, 2006).

O treinamento das redes ART é do tipo competitivo não-supervisionado. Trata-se de um modelo que possibilita o treinamento rápido e estável de categorias de reconhecimento em resposta a uma sequência arbitrária de padrões de entrada. Como ilustrado, na figura 6.1, dois principais subsistemas compõem a rede ART: o Subsistema de Atenção e o Subsistema de Orientação (CARPENTER; GROSSBERG, 1991).

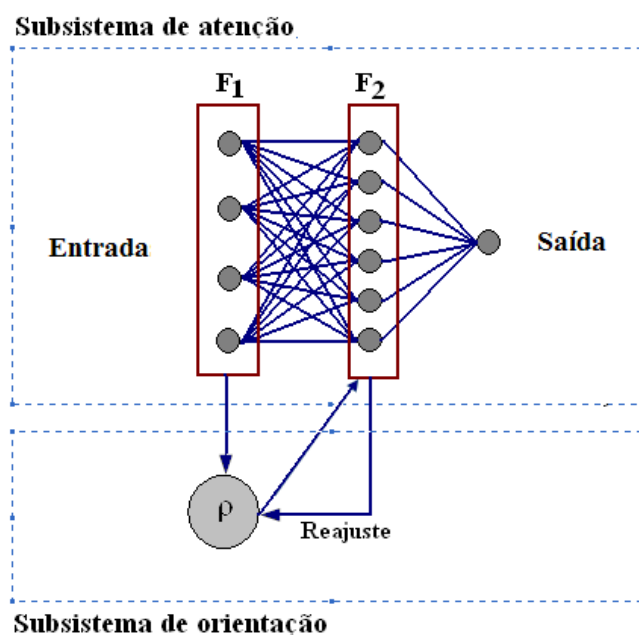


Figura 6.1 – Arquitetura básica da rede ART.

O Subsistema de Atenção é estruturado por dois campos de neurônios: o campo F_1 , cuja função é processar os dados de entrada, e o campo F_2 , que classifica os padrões de treinamento em categorias de reconhecimento. Os neurônios de F_2 são de dois tipos: os comprometidos – armazenam as informações dos padrões já apresentados à rede, representando categorias reais – e os descomprometidos (ou livres) – representam os nós ainda não utilizados, no processamento, ou seja, a memória “em branco” da rede. Tais campos, que podem consistir de várias camadas de neurônios, são conectados por pesos de conexão, responsáveis pelo armazenamento das informações através de um processo que envolve a escolha da categoria, critério de equalização e treinamento (todos esses passos serão detalhados mais adiante) (MARCHIORI, 2006; CARPENTER; GROSSBERG, 1991).

O Subsistema de Orientação é caracterizado por apresentar um parâmetro de vigilância, chamado ρ , designado a determinar se um determinado padrão de entrada poderá ser incluído em uma das categorias existentes (CARPENTER; GROSSBERG, 1991).

A figura 6.2 apresenta, com maiores detalhes, a formação dos pesos de conexão alocados entre os campos F_1 e F_2 . Trata-se de uma conexão entre N componentes de atividade correspondentes aos componentes do vetor de entrada \mathbf{a} (em F_1) e M neurônios da atividade F_2 . O número M pode ser escolhido de forma arbitrária, porém, denota-se que este deverá ter um valor suficiente para abrigar todas as categorias classificadas em F_2 . Para que não haja a possibilidade de M ser insuficiente, costuma-se adotá-lo igual ao número de vetores padrões a serem armazenados, ou seja, haveria, no máximo, N categorias formadas (uma para cada padrão). Tal ação, mesmo sendo eficiente, do ponto de vista teórico, pode-se tornar um problema no que se refere ao armazenamento de informações: mesmo que algumas categorias fiquem vazias, estas ocuparão espaços na memória do sistema (MARCHIORI, 2006).




Figura 6.2 – Formação do vetor peso w_j , que conecta os campos F_1 e F_2 .

Assim, outra alternativa, de algoritmo mais extenso, porém, em casos de grande número de padrões de entrada, de maior eficiência, é a criação contínua de novos neurônios à medida que novas categorias são formadas. Nota-se que esta segunda forma de operação poderá ser bem mais rápida do que a primeira, pois ocupará menos espaço de memória. As duas formas poderão ser aplicadas em algoritmos ART, dependendo do tipo de função a que a rede será submetida (MARCHIORI, 2006).

O processo de classificação de padrões, pela rede ART, pode ser subdividido em quatro etapas (MARCHIORI, 2006; CARPENTER; GROSSBERG, 1991):

1. **Reconhecimento:** os neurônios do campo F_1 , um por vez, recebem sinais provindos do vetor de entrada a , de baixo para cima, e do campo F_2 (camada de saída, que representa a categoria ativa), de cima para baixo. A atividade é calculada e o vetor resultante é comparado com todos os vetores de pesos w_j já armazenadas na rede (memória), visando encontrar aquele de maior correspondência com o padrão de entrada atual. O neurônio de F_2 com maior valor de ativação, ou seja, aquele que for correspondente ao vetor peso de maior semelhança, é selecionado como provável categoria para armazenar o novo padrão em questão. Este neurônio selecionado enviará, ao campo F_1 , seu protótipo a ser analisado.

- 2. Comparação:** nesta fase, onde se adentra no Subsistema de Orientação, ocorre um processo de reajuste: teste da similaridade entre o vetor de entrada a e o vetor de comparação z – resultante da atividade calculada, no campo F_1 , mediante o vetor protótipo advindo da fase de Reconhecimento. Tal teste ocorre após uma manipulação matemática dos vetores envolvidos. O resultado desta operação será comparado com o parâmetro de vigilância ρ . Se o resultado for maior que o parâmetro, o atual padrão de entrada será incluído da categoria ativa, caso contrário, a rede entra na fase de Busca. A partir dessa situação, conclui-se que há a possibilidade de se “regular” a exigência da rede quanto à classificação de padrões: para sistemas com maiores valores de ρ , a comparação entre vetores será mais detalhista, o que acarretará num maior número de categorias, enquanto que, para parâmetros de vigilância menores, muitos vetores de entrada poderão ser agrupados na mesma classe.
- 3. Busca:** essa fase será necessária caso o neurônio envolvido, na fase de Comparação, seja rejeitado, ou seja, não tenha passado no teste de similaridade. A rede procurará, no campo F_2 , um novo neurônio que apresente a maior correspondência com o vetor de entrada. Deve-se observar que o(s) neurônio(s) desabilitado(s), na fase de Comparação, não mais participará(ão) desta fase. Assim como na fase de Reconhecimento, o neurônio vencedor enviará seu protótipo ao campo F_1 , fazendo com que a rede entre, novamente, em fase de Comparação. Esse processo cíclico *Fase de Comparação* \Leftrightarrow *Fase de Busca* se repetirá até que o resultado do cálculo matemático, entre os vetores a e z , seja maior do que o parâmetro de vigilância ρ . Caso nenhum dos neurônios ativados satisfaça essa condição, a rede entra em fase de Treinamento.
- 4. Treinamento:** esta etapa é um dos grandes diferenciais das redes da família ART, pois poderá ser acionada a qualquer momento, sempre que houver a necessidade da criação de uma nova classe de padrões. Trata-se de um treinamento não-supervisionado e poderá ser de duas espécies: o aprendizado rápido e o aprendizado lento. No aprendizado rápido, os pesos de conexão serão ajustados, em seus valores ótimos, em poucos ciclos, geralmente, em

apenas um. Já, no lento, os pesos são atualizados de uma forma bem mais detalhada, levando vários ciclos de treinamento, contudo, apresentando melhores resultados nos ajustes.

Tais etapas podem ser enxergadas de modo generalizado, já que este é, praticamente, o procedimento completo da maior parte das redes pertencentes à família ART, como a rede ART1 – a mais conhecida e utilizada da família (CARPENTER; GOSSBERG, 1987). Porém, há algumas variações, onde os resultados poderão ser melhorados ou, também, utilizados em casos em que se necessita de uma aplicação mais específica para um determinado sistema. Dentre essas redes evoluídas, será apresentado o algoritmo ART Nebuloso.

6.3. Algoritmo da Rede ART Nebulosa

A rede ART Nebulosa é uma generalização da ART1. Esta propriedade é alcançada através da utilização da teoria de conjuntos nebulosos (BARROS, 2009), ao invés da aplicação da teoria de conjuntos binários. A arquitetura é semelhante à utilizada para a ART1, com a adição de um campo inicial de pré-processamento de neurônios, F_0 , responsável por modificar a entrada em questão a . Há, assim como na ART1, o campo F_1 que, com uma quantidade de $M (= 2N)$ nós (neurônios), receberá suas entradas advindas do campo F_0 e do, aqui, também presente, campo F_2 (MARCHIORI, 2006).

O algoritmo da rede neural ART Nebulosa, contendo as operações com conjuntos nebulosos, pode ser resumido nos seguintes passos (MARCHIORI, 2006; CARPENTER; GROSSBERG; ROSEN, 1992):

- **Passo 1: Inicialização dos pesos e parâmetros da rede**

Inicialmente, todos os pesos são iguais a 1, ou seja, $w_{ij} = 1$. Quanto aos parâmetros da rede, estes poderão ser arbitrários, dependendo da aplicação da rede, contudo, respeitando seus respectivos intervalos de valores:

- Parâmetro de vigilância: $\rho \in [0, 1]$;

- Parâmetro de escolha: $\alpha > 0$;
- Parâmetro da taxa de treinamento: $\beta \in [0, 1]$.

- **Passo 2: Codificação do vetor de entrada**

O segundo passo é, por inteiro, executado no campo F_θ . Para cada vetor de entrada \mathbf{a} , são necessárias certas modificações. Tal operação consiste de uma codificação complementar preliminar, gerando vetores \mathbf{I} , de dimensão $2N$, tal que:

$$\mathbf{I} \triangleq [\mathbf{a} \ \mathbf{a}^c] = [a_1 \ a_2 \ \dots \ a_N \ a_1^c \ a_2^c \ \dots \ a_N^c] \quad (6.1)$$

sendo:

$$a_i^c = 1 - a_i \quad (6.2)$$

Deve-se observar que, para que tais operações façam sentido ou, mais precisamente, para que a equação (6.2) possa ser definida como um incremento, todo a_i deverá pertencer ao intervalo $[0, 1]$. Além disso, também nota-se que:

$$|\mathbf{I}| = |[\mathbf{a} \ \mathbf{a}^c]| = \sum_{i=1}^N a_i + \left(N - \sum_{i=1}^N a_i \right) = N \quad (6.3)$$

- **Passo 3: Escolha da categoria**

Trata-se da etapa de Reconhecimento, do Subsistema de Atenção. Dado o vetor de entrada \mathbf{I} , em F_1 , para cada nó (neurônio) j , em F_2 , a função T_j (vide figura 6.2) é determinada por:

$$T_j = \frac{|I \wedge w_j|}{\alpha + |w_j|} \quad (6.4)$$

sendo o operador \wedge definido como o operador nebuloso *and*, cuja operação é calculada por:

$$(I \wedge w_j)_i \triangleq \min(I_i, w_{ji}) \quad (6.5)$$

A categoria J será apontada como ativa de acordo com o maior elemento T_j , ou seja:

$$T_j = \max\{T_j; j = 1, 2, \dots, M\} \quad (6.6)$$

Caso haja mais de uma categoria ativa, ou seja, empate entre dois ou mais valores de T_j , a escolhida será aquela que apresentar o menor índice j.

- **Passo 4: Teste de vigilância**

Após a escolha da categoria, a rede começa a operar na etapa de Comparação, do Subsistema de Orientação. Deve-se verificar se houve ressonância para a categoria eleita, na fase anterior. Tal fato poderá ser atestado através do teste de vigilância:

$$\frac{|I \wedge w_j|}{|I|} \geq \rho \quad (6.7)$$

Satisfeito o critério, passa-se para o próximo passo. Caso contrário, ocorre o evento denominado *reset*: a rede faz $T_j = 0$, adentra a etapa de Busca, executa uma nova escolha da categoria e atesta, novamente, a existência ou não de ressonância. Este processo se repetirá até que a relação (6.7) seja confirmada.

Passo 5: Atualização dos pesos

Inicia-se, assim, a última etapa, a de Treinamento, com a atualização do vetor w_j , através da seguinte equação:

$$w_j^{(novo)} = \beta \cdot (I \wedge w_j^{(velho)}) + (1 - \beta) \cdot w_j^{(velho)} \quad (6.8)$$

Caso se opte pelo treinamento rápido, basta fazer $\beta = 1$.

Na tabela 6.1, apresentam-se algumas comparações entre as redes ART1 e ART Nebulosa. Nota-se que a segunda é uma versão da primeira, havendo a substituição do operador *crisp* (\cap - não-nebuloso) pelo operador *and* (\wedge - nebuloso). Essa operação faz com que a ART Nebulosa torne-se uma versão mais poderosa, pois melhora o desempenho da rede, no que se refere, principalmente, ao tempo de execução do treinamento e, também, no processamento de dados analógicos (MARCHIORI, 2006).

Tabela 6.1 – Comparação entre ART1 e ART Nebulosa		
Módulo (Passo)	ART1	ART Nebulosa
Escolha da Categoria	$T_j = \frac{ I \cap w_j }{\alpha + w_j }$	$T_j = \frac{ I \wedge w_j }{\alpha + w_j }$
Teste de Vigilância	$\frac{ I \cap w_j }{ I } \geq \rho$	$\frac{ I \wedge w_j }{ I } \geq \rho$
Atualização dos Pesos	$w_j^{(nova)} = \beta \cdot (I \cap w_j^{(velha)}) + (1 - \beta) \cdot w_j^{(velha)}$	$w_j^{(nova)} = \beta \cdot (I \wedge w_j^{(velha)}) + (1 - \beta) \cdot w_j^{(velha)}$

6.4. Algoritmo da Rede ARTMAP Nebulosa

A ARTMAP Nebulosa é uma rede mais sofisticada, quando comparada com as demais redes, aqui, expostas, anteriormente. Sua função é treinar e realizar o mapeamento entre dois espaços de vetores, utilizando treinamento supervisionado (MARCHIORI, 2006; CARPENTER et al, 1992).

O sistema ARTMAP Nebuloso, na sua forma geral, inclui dois módulos (ou camadas) ART Nebulosos, ARTa e ARTb (vide figura 6.3). Tais camadas são interligadas por outro módulo, o qual pode ser chamado de inter-ART. Este módulo de interligação é dotado de campo de mapeamento, responsável por controlar: *I*. o treinamento de um

mapa associativo de categorias de reconhecimento de ARTa para categorias de reconhecimento de ARTb; 2. a regra *match tracking*, que aumenta o parâmetro de vigilância da rede ARTa por um valor necessário para corrigir um erro preditivo. (MARCHIORI, 2006; CARPENTER et al, 1992).

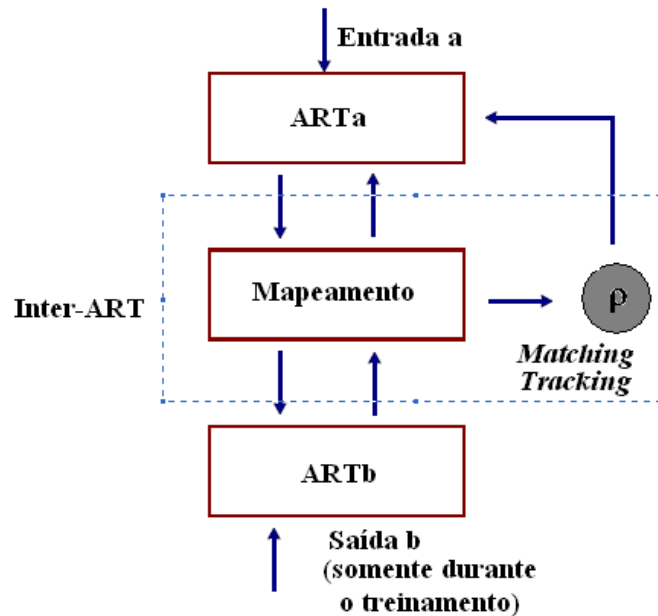


Figura 6.3 – Ilustração esquemática do treinamento da rede ARTMAP Nebulosa.

O início do treinamento da rede ocorre de forma semelhante ao exibido para o algoritmo da ART Nebulosa. Durante o treinamento, o módulo ARTa recebe, como padrão, o vetor de entrada \mathbf{a} , enquanto que o ARTb receberá o vetor de saída \mathbf{b} – daí se justifica o fato de o treinamento da ARTMAP Nebulosa ser classificado como supervisionado.

Nos dois módulos, ocorrerá todo o processo descrito, na seção anterior, gerando os vetores de pesos, \mathbf{w}_j^a – para ARTa – e \mathbf{w}_j^b – para ARTb –, e determinando as escolhas das categorias (aqui, chamadas de predições), J - para ARTa - e K - para ARTb -, que satisfizeram os seus respectivos testes de vigilância (observa-se que cada módulo possui o seu próprio parâmetro de vigilância).

Quando uma predição, em ARTa, não é confirmada por ARTb, a inibição da memória associativa inter-ART ativa o processo *match tracking*. Este processo aumenta a vigilância, em ARTa, por uma quantia mínima necessária para o sistema ativar uma outra categoria, em ARTa, que iguala a categoria, em ARTb, ou para treinar uma nova categoria, em ARTa. Os mecanismos de controle interno das ARTMAPs criam catego-

rias de reconhecimento estáveis, de forma ótima, via maximização da generalização preditiva em operações em tempo real (Carpenter; Grossberg, 1991b; Carpenter et al., 1992).

6.5. Conclusão

Este trabalho teve como objetivo a classificação de faltas de curto-circuito, sendo que sua principal ferramenta, que atuará como classificador, trata-se de um banco de redes neurais ARTMAP Nebulosas. E, para se chegar aos conceitos sobre a referida rede, foi necessário explanar a teoria desde conceitos primários, a cerca de Redes Neurais Artificiais (vide capítulo 5), até chegar à Teoria da Ressonância Adaptativa, a família ART de redes neurais. Deste modo, este capítulo demonstrou as vantagens em se operar com redes desta família, como a constante possibilidade de se criar novas categorias e o recurso de tornar mais ou menos exigente essa concepção de novas classes (através do parâmetro de vigilância). A partir do desenvolvimento do algoritmo ART Nebuloso, a teoria dos conjuntos nebulosos trouxe mais avanços, com a generalização das redes já existentes. E, finalmente, seu aprimoramento gerou as redes ARTMAP Nebulosas que, com o mapeamento de seus dois blocos ARTa e ARTb, tornam possível um treinamento supervisionado mais rápido e dinâmico que o não-supervisionado anterior.

Capítulo 7: Detecção e Classificação de Falhas usando RNAs do tipo ARTMAP Nebulosa

O objetivo deste trabalho é chegar a um programa que monitore, ao longo de um alimentador de distribuição, a ocorrência de faltas do tipo curtos-circuitos. A aplicação de RNAs do tipo ARTMAP Nebulosa representa um diferencial, quando comparado com outros sistemas desenvolvidos com o mesmo fim. A principal vantagem é a decisão mais robusta na classificação das faltas, já que a ARTMAP incorpora uma lógica *fuzzy* na sua operação.

O sistema proposto, neste trabalho, deve ser capaz de detectar e classificar os seguintes tipos de faltas em sistemas de distribuição:

- Falta Monofásica na fase A;
- Falta Monofásica na fase B;
- Falta Monofásica na fase C;
- Falta Bifásica nas fases A e B;
- Falta Bifásica nas fases B e C;
- Falta Bifásica nas fases C e A;
- Falta Trifásica.

O alimentador de distribuição é baseado em um sistema elétrico real, caracterizado por um grande número de ramais e sub-ramais. As informações sobre ele captadas são obtidas através do monitoramento das correntes de suas ramificações, todas elas mensuradas na saída da subestação de distribuição (MATOS, 2009). Por se tratar do alvo prático das análises do trabalho, o alimentador terá suas principais características apresentadas, neste capítulo, assim como os procedimentos de simulação.

O sistema de detecção de faltas desenvolvido pode ser dividido em três blocos principais:

1. **Pré-Processamento**, parcialmente baseado em Matos (2009): setor onde os valores de correntes serão manipulados matematicamente, extraindo suas caracte-

rísticas, de forma a decompô-las em componentes harmônicos e, paralelamente, componentes *Wavelet*. Tais resultados, após serem normalizados, estarão, então, adequados a serem analisados pelo banco de redes neurais.

2. **Banco de Redes Neurais:** composto por quatro redes ARTMAP Nebulosas, sendo a primeira responsável pela detecção das faltas, a segunda pela classificação da falta, e a terceira e a quarta por uma segunda classificação, operando como redundantes à segunda rede.
3. **Pós-Processamento:** essa fase será responsável por fazer a interface programa-operador, ou seja, modelará os resultados binários, provindos das redes neurais, a fim de deixá-los, facilmente, compreensíveis pelo operador.

Tais blocos podem ser visualizados, em fluxograma e, ainda, de forma generalizada, na figura 7.1. Assim como o alimentador de distribuição, os três, também, serão mais detalhados adiante.

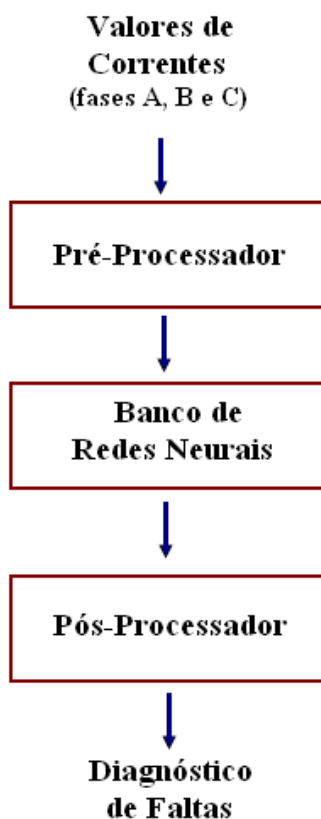


Figura 7.1 – Fluxograma esquematizando os três blocos principais do diagnóstico de faltas de curto-circuito: Pré-Processador, Banco de Redes Neurais e Pós-Processador.

7.1. Alimentador de Distribuição e Procedimentos de Simulação

O alimentador de distribuição trata-se de um sistema elétrico complexo e de grande porte, contendo 836 barras, estando a de número três mais próxima do alimentador e a 836 mais distante. Sua tensão nominal é de 11,4 kV. Tal valor de diferença de potencial também foi utilizado nas simulações como valor base de tensão, $V_{\text{base}} = 11,4\text{kV}$.

As simulações do alimentador foram realizadas através do *software Alternative Transients Program* e, além do já citado valor de V_{base} , foi utilizada uma potência base de $S_{\text{base}} = 5 \text{ MVA}$.

Como explanado, nos capítulos cinco e seis, redes neurais necessitam de uma pré-fase de treinamento, a fim de que possam operar, depois, classificando padrões. Desta forma, foram criados dois bancos de simulações, cada um contendo certa quantidade de barras, sendo:

- **Primeiro banco:** composto por 44 barras (as de números 5, 10, 15 e todas as múltiplas inteiras de 20, entre 20 e 820) – sendo simulados todos os sete tipos de falta em cada uma, ou seja, um total de 308 simulações – e destinado ao treinamento das redes neurais;
- **Segundo banco:** composto por 42 barras (as de números 03, 28, 53, 71, 85, 111, 126, 155, 162, 191, 205, 233, 254, 264, 290, 312, 327, 348, 374, 385, 410, 430, 452, 467, 487, 515, 533, 542, 566, 593, 611, 627, 655, 673, 684, 710, 725, 748, 773, 792, 813 e 836) – aqui, também, simulados os sete tipos de faltas em cada uma das barras – e destinado à etapa de validação do sistema de detecção, ou seja, à contestação do desempenho satisfatório do programa.

Para as faltas monofásicas, a resistência de falta adotada foi de 40Ω , enquanto que, para as bifásicas e trifásicas, a resistência de fase a fase foi de 1Ω . Cada simulação foi formada por dez ciclos de corrente: como foi usada uma frequência de 60 hertz, isso leva a um tempo total de 166,7 ms. O ponto de incidência da falta foi padronizado para o quinto ciclo de corrente da fase A, correspondendo a um ângulo de 90° em relação à tensão da mesma fase.

7.2. Blocos Funcionais do Sistema de Detecção de Falhas

Como já citado, o sistema de detecção de falhas apresentou, em sua estrutura, três blocos, cada um com funções bem definidas. Antes de explicar o funcionamento de tais, deve-se observar que o sistema foi elaborado de modo a apresentar um ambiente de desenvolvimento e simulação de detecção de falhas, utilizando, como ferramenta de programação, o *software* MATLAB[®].

Quanto ao programa, este foi desenvolvido de forma bastante clara, buscando, ao máximo, seguir a ordem esboçada no fluxograma da figura 7.1. Também houve a preocupação de apresentar informações do tipo *comments* – no MATLAB[®], tais resenhas são antecipadas pelo caractere % – que ajudariam a algum outro operador a entender a linguagem, além de se trabalhar, apenas, com funções bem conhecidas dos programadores deste ambiente de programação.

7.2.1. Pré-Processamento

Inicia-se, assim, a concepção do algoritmo detector e classificador de falta. O primeiro bloco trata-se do Pré-Processador. Sua principal função é a preparação dos dados de entrada de corrente, diminuindo o número de informações a serem utilizadas, no treinamento e validação das redes, porém, aumentando a eficiência e a rapidez de tal.

O fluxograma desta etapa está ilustrado na figura 7.2. Levando-se, assim, tal figura como um padrão para que se comece a entender o programa concebido para o diagnóstico de falhas, toma-se os **Valores de Correntes (fases A, B e C)**. Tal entrada do sistema é caracterizada por um único vetor, por janelamento, contendo valores de correntes amostrados das três fases. Esta amostragem, num sistema real, seria feita por aparelhos de medição ou proteção localizados, estrategicamente, nos mais variados locais do sistema elétrico.

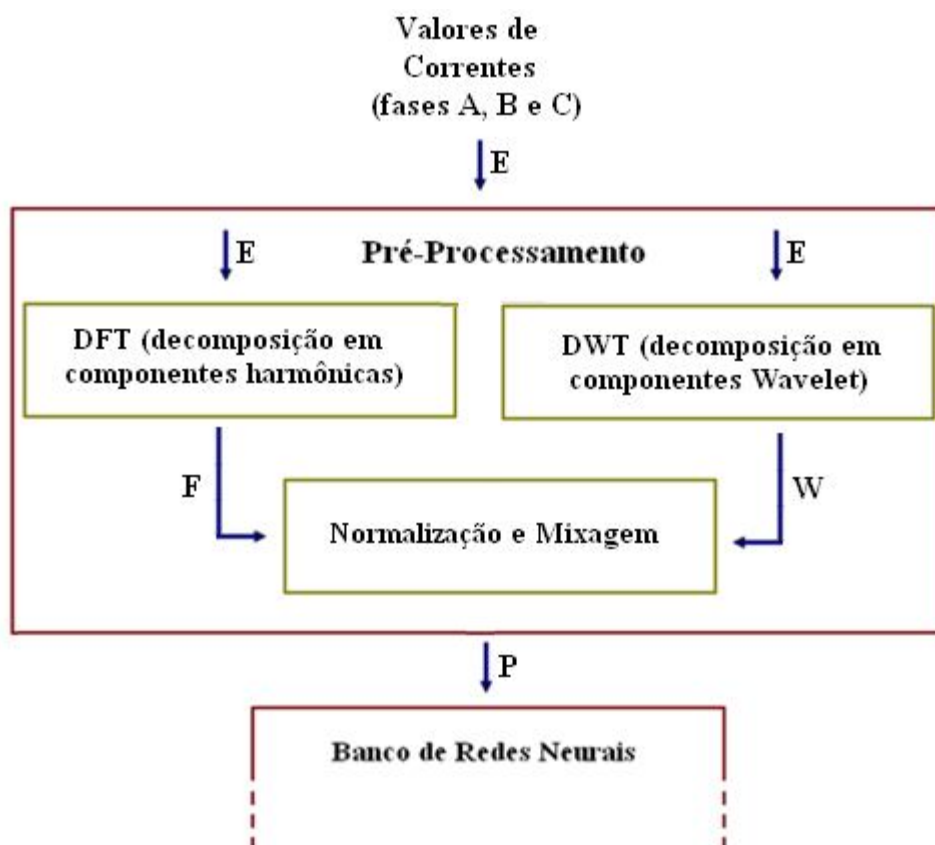


Figura 7.2 – Parte do fluxograma do sistema de detecção e classificação de faltas, dando ênfase ao bloco de Pré-Processamento, aos seus dois subconjuntos/operadores matemáticos e aos principais vetores gerados durante o processo: *E*, *F*, *W* e *R*.

Para este projeto, pode ser estabelecida, por exemplo, uma taxa de amostragem de 64 pontos por período de corrente. Ao se considerar que as correntes, nas três fases, apresentem uma frequência de 60 Hertz, conclui-se que a taxa de amostragem chegará a 3840 Hertz, sendo este um valor concebível em situações reais.

As amostragens serão processadas a partir de “pedaços” do formato de onda das correntes, chamados de janelas. Pode-se dizer que tais varrerão, digitalmente, as ondas advindas das correntes das fases, atualizando, constantemente, o sistema com novos valores a serem analisados. Na figura 7.3, encontra-se um exemplo desse janelamento, aplicado em um trecho de amostragem englobando dois períodos.

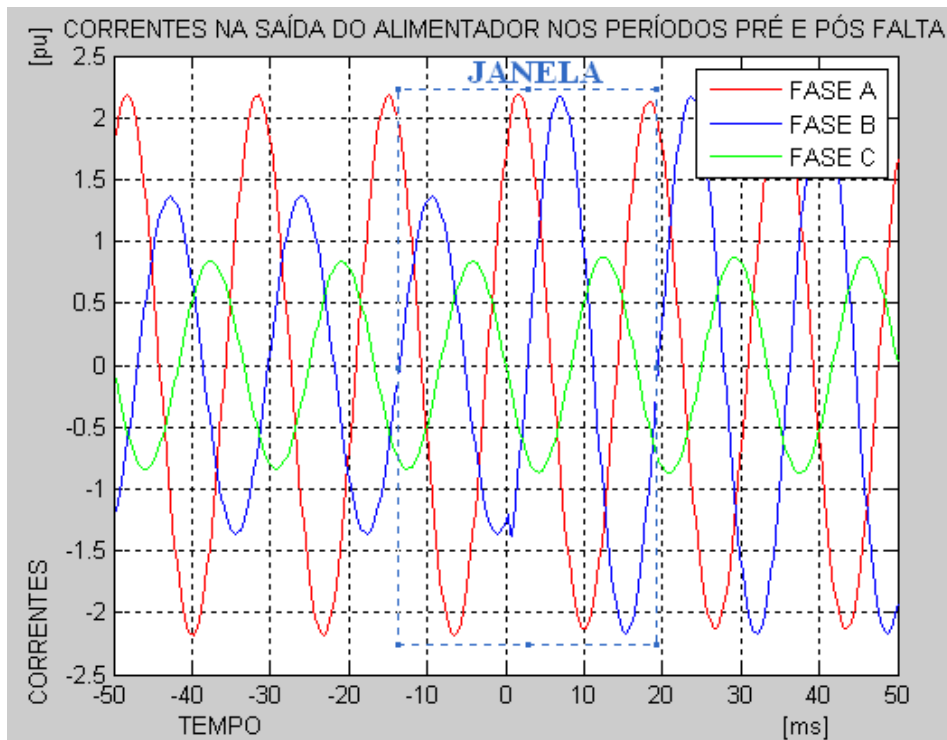


Figura 7.3 – Exemplo de uma janela de amostragens para um sistema trifásico de corrente: observa-se a janela de dois ciclos, em linha pontilhada, englobando um trecho caracterizado pela presença de falta monofásica na fase B.

Considerando-se a relação:

$$N = p \times 64 \quad (7.1)$$

sendo:

- N : número total de amostras por fase da janela;
- p : número de ciclos completos, do componente fundamental, englobados pela janela;

haverá que, para a figura 7.3, com $p = 2$, o número total de amostras, para as três fases, será $3 \times N$. Ou seja, neste caso, de uma taxa amostral de 64 amostras por ciclos e, conseqüentemente, $N = 128$, serão 384 amostras. Este, então, será o número de componentes presentes no vetor de entrada do bloco de Pré-Processamento. Tal conjunto de valores pode ser dado, de forma genérica, pela seguinte representação:

$$E = [i_A[1] \dots i_A[N] \quad i_B[1] \dots i_B[N] \quad i_C[1] \dots i_C[N]]^T \quad (7.2)$$

sendo:

- E : vetor de entrada do bloco de Pré-Processamento;
- $i_A(n)$, $i_B(n)$, $i_C(n)$: valores de corrente das n -ésimas amostras de cada uma das fases A, B e C, respectivamente.

Composto, assim, o vetor de entrada, adentra-se o bloco de Pré-Processamento, propriamente, dito. Nota-se que o vetor E conterà muitos valores – lembrando que, para o caso exemplificado, ele teria 384 –, o que resultaria, em uma aplicação com redes neurais, numa operação de alto custo computacional e considerável gasto de tempo. Torna-se, deste modo, muito interessante a manipulação matemática deste vetor, a fim de torná-lo bem menor, porém, sem perder a eficiência necessária em suas informações.

Então, executa-se, primeiramente, a decomposição das amostras em componentes harmônicos (aplicação da DFT), com seus fasores representativos determinados pelas equações (ORSINI, 1994):

$$I_{k \in \text{harm}}^F = \frac{\sqrt{2}}{N} \cdot I_f \cdot [1 + k \cdot p], \quad \begin{cases} (k = 0, 1, \dots, (N/2) - 1) & \text{se } N \text{ par} \\ (k = 0, 1, \dots, (N - 1)/2) & \text{se } N \text{ ímpar} \end{cases} \quad (7.3)$$

$$I_F[k] = \sum_{n=1}^N i_F[n] \cdot e^{-j(k-1) \cdot \frac{2\pi}{N} \cdot (n-1)}, \quad k = 1, 2, \dots, N \quad (7.4)$$

sendo:

- $I_{k \in \text{harm}}^F$: o k -ésimo harmônico da fase F (= A, B ou C);
- $I_F[k]$: DFT de $i_F[n]$.

O número de componentes harmônicos a serem utilizados dependerá da experiência do operador/programador, quando este analisar o grau de dificuldade presente em cada situação de falta. Para os testes simulados neste projeto, com uma impedância de

40Ω, para faltas monofásicas, e de 1Ω de fase a fase, para bifásicas e trifásica, três componentes de baixa ordem já são suficientes para resultados satisfatórios.

Após a aplicação da DFT sobre as amostragens de correntes, chega-se à relação genérica (MATOS, 2009):

$$F = \begin{bmatrix} i_{1\Omega}^A & i_{2\Omega}^A & \dots & i_{K\Omega}^A \\ i_{1\Omega}^B & i_{2\Omega}^B & \dots & i_{K\Omega}^B \\ i_{1\Omega}^C & i_{2\Omega}^C & \dots & i_{K\Omega}^C \end{bmatrix} \quad (7.5)$$

sendo, assim como na equação (57):

$$\begin{cases} k = 0, 1, \dots, (N/2) - 1 & \text{se } N \text{ par} \\ k = 0, 1, \dots, (N - 1)/2 & \text{se } N \text{ ímpar} \end{cases}$$

Como citado anteriormente, o valores de correntes amostrados passam, paralelamente, por duas manipulações matemáticas. Desta maneira, o vetor E , além passar pela decomposição em componentes harmônicos, também sofrerá, de forma independente da DFT, uma decomposição em componentes *Wavelet*. Isso se dará através da aplicação da DWT, pela equação (SARKAR et al, 1998):

$$d_{j\Omega}^F \text{ filtro} = \sum_n h_j \cdot c_{(j-1)\Omega}^F \text{ filtro} \quad (7.6)$$

sendo:

- $d_{j\Omega}^F \text{ filtro}$: coeficiente *Wavelet* da fase F (=A, B ou C) derivado da ação do j^o filtro;
- $c_{(j-1)\Omega}^F \text{ filtro}$: aproximação resultante do $(j-1)^o$ filtro e que será filtrada pelo j^o filtro. Observa-se que o primeiro c_j^F , ou seja, aquele que ainda não passou por filtragem alguma (c_0), corresponde ao sinal de corrente amostrado $i_F[n]$;
- h_j : função dada pelas propriedades de frequência de corte do j^o filtro.

À medida que se ultrapassam os filtros, suas frequências de corte apresentarão uma relação logarítmica decrescente de 2^{j+1} . Deste modo, para a já citada frequência

fundamental – correspondente à de amostragem – de 3840Hz, o primeiro filtro terá sua frequência de corte em 1970Hz (= metade de 3840), enquanto que a do segundo será de 985Hz e assim sucessivamente.

Pode-se concluir, assim, que, com o decorrer das filtrações, os coeficientes *Wavelet* resultantes serão cada vez menores. Portanto, atesta-se que, até certo grau de filtração, os componentes posteriores poderão ser descartados. Para este projeto, utilizou-se até a quarta filtração, resultando na matriz W :

$$W = \begin{bmatrix} d_{12}^A & d_{22}^A & d_{32}^A & d_{42}^A \\ d_{12}^B & d_{22}^B & d_{32}^B & d_{42}^B \\ d_{12}^C & d_{22}^C & d_{32}^C & d_{42}^C \end{bmatrix} \quad (7.7)$$

Têm-se, então, as matrizes F , advinda da DFT, e W , derivada da DWT. Tais são compostas de componentes numéricos complexos que, por si são, não poderiam ser analisadas, diretamente, pelo Banco de Redes Neurais. A partir disso, F e W passarão por um último processo: **Normalização e Mixagem**.

No processo de Normalização, serão extraídos os módulos de todos os componentes e tais, após isso, serão normalizados. Desta forma, todos estarão no intervalo $[0,1]$.

A Mixagem será o derradeiro processo: os coeficientes resultantes da Normalização serão dispostos num único vetor coluna.

Concluem-se, assim, as operações matemáticas as quais serão aplicadas sobre o vetor de entrada E , composto pelos valores medidos de correntes amostrados das fases A, B e C. Retornando-se ao caso da figura 7.3, no qual uma falta monofásica B foi amostrada com uma janela de dois períodos, ou seja, $p = 2$, recorda-se que o vetor E era estruturado por 384 elementos. Ao transpô-lo pelo bloco de Pré-Processamento, escolhe-se, por exemplo, componentes harmônicos de 2ª, 5ª e 11ª ordens. Além disso, recorda-se que, da DWT, serão aproveitados os coeficientes *Wavelet* de até quarta ordem de filtração. Chega-se, deste modo, ao vetor coluna que será concebido, finalmente, pelo Pré-Processamento e responsável por treinar o banco de redes neurais:

$$\begin{aligned}
R = & \left[\left(|I_{22}^A| \right)_N \left(|I_{55}^A| \right)_N \left(|I_{11}^A| \right)_N \left(|I_{22}^B| \right)_N \left(|I_{55}^B| \right)_N \left(|I_{11}^B| \right)_N \left(|I_{22}^C| \right)_N \dots \right. \\
& \dots \left(|I_{55}^C| \right)_N \left(|I_{11}^C| \right)_N \left(|d_{22}^A| \right)_N \left(|d_{55}^A| \right)_N \left(|d_{11}^A| \right)_N \left(|d_{22}^B| \right)_N \left(|d_{55}^B| \right)_N \left(|d_{11}^B| \right)_N \dots \\
& \left. \dots \left(|d_{22}^C| \right)_N \left(|d_{55}^C| \right)_N \left(|d_{11}^C| \right)_N \right]^T \quad (7.8)
\end{aligned}$$

sendo:

- $\left(|I_{22}^A| \right)_N \dots \left(|I_{11}^C| \right)_N$: módulos normalizados dos componentes harmônicos de 2ª, 5ª e 11ª ordens das fases A, B e C;
- $\left(|d_{22}^A| \right)_N \dots \left(|d_{11}^C| \right)_N$: módulos normalizados dos componentes *Wavelet* de 2ª, 5ª e 11ª ordens das fases A, B e C.

Observa-se que se gerou um vetor de apenas 21 elementos numéricos reais, ou seja, menos de 1/18 avos do número de componentes do vetor original E . E, mais uma vez, afirma-se que essa diminuição não será prejudicial ao desempenho do programa, que apresentou resultados satisfatórios, mesmo para vetores R ainda menores.

7.2.2. Banco de Redes Neurais

Na figura 7.3, pode-se ver a janela responsável pela amostragem dos valores de correntes das fases A, B e C. Ela executa uma varredura digital, percorrendo, de forma espaçada, a região de interesse do formato de onda de corrente. Deste modo, para cada trecho coberto, um vetor do tipo R será enviado ao segundo bloco do sistema de detecção de faltas: o Banco de Redes Neurais. O fluxograma representativo do banco está ilustrado na figura 7.4.

O Banco de Redes Neurais é o maior responsável pelo completo diagnóstico de faltas de curtos-circuitos. Ele é composto por quatro redes neurais ARTMAP Nebulosas, cada uma localizada, estrategicamente, de modo operar somente quando necessário.

Os vetores R adentram o banco e entram, diretamente, no treinamento ou, dependendo da etapa de implementação do sistema, da validação da rede RNA_1. Esta rede será responsável direta pelo correto funcionamento do sistema, pois ela detectará a existência ou não de falta. Sua saída dependerá da inter-relação presente na tabela 7.1. Nota-se a saída binária da rede, indicando a ocorrência ou não de faltas.

Tabela 7.1 – Saídas possíveis da RNA_1, correspondentes à ocorrência ou não de falta	
Ocorrência	Saída binária da rede
Falta não-detectada	0
Falta detectada	1

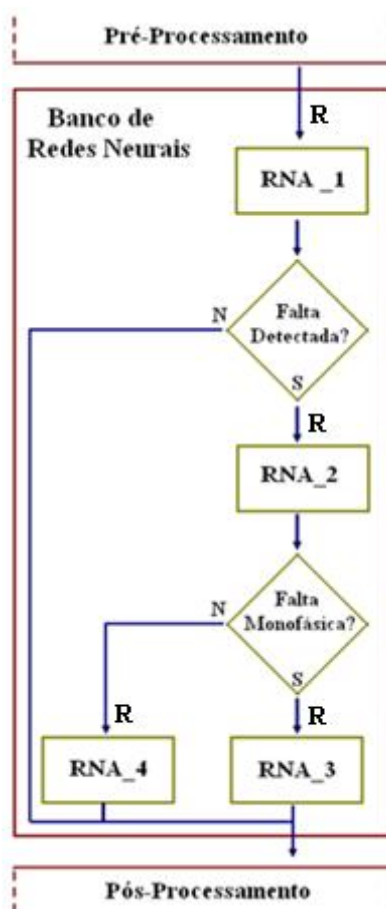


Figura 7.4 – Fluxograma do Banco de Redes Neurais, esboçando o posicionamento, no algoritmo, das quatro RNAs responsáveis pelo diagnóstico de faltas de curtos-circuitos.

A seguir, inicia-se a operação da RNA_2. Observa-se que, para a RNA_1, todos os vetores R gerados, inclusive os referentes aos períodos de pré e pós-falta, participam de seu treinamento. Já para a RNA_2, em seu treinamento, somente os períodos contendo falta participam. Isso se deve ao fato de esta rede ter a função de classificação das faltas, não havendo, assim, a necessidade de trechos, que não apresentem anormalidades, participarem do treinamento. Seu treinamento supervisionado fará com que a

rede proporcione saídas relacionadas de acordo com o apresentado na tabela 7.2. Quanto à validação, caso a RNA_1 indique a não-ocorrência de anormalidades, tanto a RNA_2 quanto as outras duas redes não participarão de desta etapa.

Tabela 7.2 – Saídas das redes RNA_2, RNA_3 e RNA_4, associadas às respectivas faltas		
Falta	Saída	Redes envolvidas
Monofásica - Fase A	001	RNA_2 e RNA_3
Monofásica - Fase B	010	RNA_2 e RNA_3
Monofásica - Fase C	100	RNA_2 e RNA_3
Bifásica Fases - A e B	011	RNA_2 e RNA_4
Bifásica Fases - B e C	110	RNA_2 e RNA_4
Bifásica Fases - C e A	101	RNA_2 e RNA_4
Trifásica	111	RNA_2 e RNA_3

A função da RNA_2, então, será a de classificar o vetor R dentre os sete tipos de faltas existentes. Porém, mesmo com toda a confiança no correto funcionamento das redes ARTMAP Nebulosas, optou-se por utilizar outras duas RNAs com função de redundância: as RNA_3 e RNA_4. Tais redes também classificarão as faltas detectadas, contudo, como pode ser interpretado, através da tabela 7.2, cada uma sendo responsável por um conjunto de falhas: a RNA_3 classificará somente faltas monofásicas, à medida que a RNA_4 operará com as demais.

Deve-se apontar a importância destas últimas duas redes, pois elas terão poder de veto sobre a RNA_2: esta somente terá seu resultado validado sob a confirmação das RNA_3 e RNA_4.

Poderia, então, aparecer a dúvida: por que não utilizar, somente, as RNA_3 e RNA_4 e descartar a RNA_2? Com certeza, as RNA_3 e RNA_4 terão seus resultados sobrepostos aos provenientes da RNA_2. Todavia, é interessante fazer a comparação de redes que operem com números diferentes de classes, analisando se a precisão apresentada, por cada uma, será influenciada por um número maior ou menor de classificações. Além disso, a RNA_2 possui um papel importante, na etapa de validação do algoritmo: a partir do seu resultado, será apontado se a falta, em questão, é de cunho monofásico,

bifásico ou trifásico, acionando-se ou a RNA_3 – para o primeiro caso de faltas – ou a RNA_4 – para os segundo e terceiro casos.

7.2.3. Pós-Processamento

Conclui-se, assim, a fase, propriamente, funcional do sistema. Até aqui, foram apresentadas as etapas de amostragem das correntes das fases A, B e C, a preparação de tais dados, para que estes sejam analisados pelas redes neurais artificiais, e o sistema de detecção e classificação dos vetores de entrada, composto pelas RNAs. Mas os resultados obtidos das redes serão de formato binário, dificultando sua interpretação. Aparece, com isso, a necessidade de preparar tais dados para que sejam mais bem recebidos por operadores. Para tal, torna-se necessária a etapa de **Pós-Processamento**.

Pode-se dizer que tal bloco não está, corretamente, posicionado como ilustrado na figura 7.1. Tal setor encontra-se presente desde o Banco de Redes Neurais, entrando com as condicionais (vide figura 7.4) que indicam quais RNAs deverão operar. Ou seja, será responsável, já após os resultados da RNA_1, por indicar se haverá a necessidade da RNA_2 classificar os padrões. Como citado, no subcapítulo anterior, a RNA_2 somente receberá os vetores **R** os quais sejam caracterizados pela ocorrência de falta. O bloco atual também aparece quando, com o resultado da RNA_2, deve-se indicar qual das outras duas redes entrará em ação: a RNA_3 – para faltas monofásicas – ou a RNA_4 – para faltas bifásicas e trifásicas.

Quanto à interface programa-operador, foi utilizado o próprio ambiente de interação disponibilizado pelo MATLAB[®]. Tal execução foi feita em um formato gráfico simples, todavia, de fácil entendimento e manipulação.

Essa parte do algoritmo foi baseada em Matos (2009), com algumas modificações, visando adaptação às redes ARTMAP Nebulosas. A partir dela, pode-se escolher os seguintes parâmetros:

- Pré-Processamento:
 - Número de períodos abrangidos pela janela de amostragem;
 - Número de amostras por passo da janela;
 - Barras, do primeiro banco de simulações, a serem utilizadas no treinamento das redes;

- Barras, do segundo banco de simulações, a serem utilizadas na validação pós-treinamento;
 - Componentes harmônicos que representarão as correntes das fases A, B e C;
- Banco de Redes Neurais, para cada uma das quatro redes:
- Número de categorias;
 - Parâmetro de vigilância.

Todos os parâmetros a serem utilizados poderão ser escolhidos de acordo com as necessidades do sistema, possibilitando uma grande flexibilidade quanto ao funcionamento do programa de diagnóstico de faltas.

Além disso, também procurou-se apresentar os resultados de validação em um formato o mais claro possível. Após o término da implementação do programa, é apresentada a percentagem de acerto de cada uma das redes. Nos casos de resultados errôneos, são apontadas as barras onde ocorreram erros, assim como qual foi a falta detectada ou classificada insatisfatoriamente

7.3. Conclusão

Após toda a teoria acerca de redes neurais artificiais e, mais especificamente, redes ARTMAP Nebulosas, este capítulo explanou sobre o algoritmo responsável por executar o diagnóstico de faltas. Pôde-se ver que tal metodologia foi dividida em três partes distintas, porém, atreladas entre si. Na primeira etapa, o Pré-Processamento, baseou-se nos conceitos de Transformadas de *Fourier* e *Wavelet*. A segunda, o Banco de Redes Neurais, caracterizou-se pela aplicação das redes ARTMAP Nebulosas, aproveitando-se de seus recursos e vantagens. Finalmente, o Pós-Processamento – terceira etapa do algoritmo – trata-se do responsável pela interface programa-operador, assim como dos caminhos que os vetores de dados deverão tomar internamente ao programa de detecção e classificação de faltas.

Capítulo 8: Apresentação e Discussão dos Resultados

O sistema de detecção e classificação de faltas do tipo de curto-circuito é provido de entradas, que possibilitam, ao operador, apontar os dados necessários ao funcionamento do programa. Tais dados, como o número de períodos abrangidos pela janela de amostragem ou o fator de vigilância, são escolhidos de acordo com as necessidades da operação. Desta forma, conclui-se que serão inúmeras as possibilidades de se caracterizar o sistema. Em vista disto, foram feitas simulações com diferentes combinações de parâmetros de entrada, sempre buscando aquelas que apresentassem o melhor desempenho.

Deve-se lembrar que as correntes das barras foram amostradas a partir da simulação de um alimentador real, provido das seguintes características:

- Tensão de 11,4kV;
- Potência de 5MVA;
- Frequência de 60 hertz;
- Impedância de 40Ω para as faltas monofásicas;
- Impedância de 1Ω de fase a fase para as faltas bifásicas e trifásicas.

Como já citado, o Pré-Processador teve parte de sua estrutura baseada em Matos (2009), no que se refere à utilização da Transformada de Fourier. Porém, naquela obra, utilizou-se, ao invés da Transformada *Wavelet*, a decomposição em componentes simétricas e de modo serial. Recordar-se que, aqui, as DFT e DWT são dispostas paralelamente.

Assim, primeiramente, foram feitas simulações com os mesmos parâmetros de entrada apresentados, em Matos (2009), a fim de se comparar os resultados dos dois projetos. Na tabela **8.1**, estão as combinações que proporcionaram 100% de acerto – Sistemas de Diagnóstico de Faltas *SDF_1*, *SDF_2*, *SDF_3*, *SDF_4* e *SDF_5* –, tanto na detecção quanto na classificação, para Matos (2009).

Deve-se ressaltar que a apresentação dos resultados do atual trabalho se dá por meio de uma análise direta do desempenho do programa: é mostrada a percentagem de acertos, tanto de detecção quanto de classificação. Além disso, havendo a ocorrência de erros, também são apontadas para quais barras estes apareceram. Na tabela 8.2, estão os resultados percentuais para as mesmas combinações de parâmetros presentes na tabela 8.1. Esta tabela 8.2 deve ser entendida da seguinte forma: seus resultados percentuais remetem a um total de 294 testes por sistema de detecção e classificação. Tal número se justifica por terem sido simuladas todos os sete tipos de faltas em cada uma das 42 barras do banco 2. Porém, essa quantia só deverá ser toda ela considerada apenas para as redes *RNA_1* e *RNA_2*, já que somente elas operam com todos os tipos de faltas. Para as outras duas, ocorre o seguinte: a *RNA_3* somente trabalha com as três faltas monofásicas, ou seja, esta será testada 126 vezes (= 3 x 42). Já para a *RNA_4*, esta classifica as três faltas bifásicas e a trifásica, resultando em 168 testes (= 4 x 42).

Sistema	Largura da Janela (p)	Amostras por passo	Componentes Harmônicos
SDF_1	2	16	1 ^a a 7 ^a
SDF_2	1	12	1 ^a a 5 ^a
SDF_3	2	32	1 ^a , 3 ^a e 5 ^a
SDF_4	1	8	1 ^a e 3 ^a
SDF_5	2	10	1 ^a , 3 ^a e 5 ^a

Sistema	Detecção (RNA_1)	Classificação 1 (RNA_2)	Classificação 2 (RNA_3)	Classificação 3 (RNA_4)
SDF_1	100%	92,9%	100%	98,2%
SDF_2	99,3%	90,1%	97,6%	96,4%
SDF_3	98,3%	88,1%	95,2%	94,0%
SDF_4	100%	93,6%	99,2%	98,2%
SDF_5	99,7%	91,1%	97,6%	97%

Pode-se, assim, notar que o sistema de diagnóstico mostrou bons resultados – quase todos com uma taxa de acerto acima de 90% – para as combinações advindas de Matos (2009), porém, com alguns erros:

- Para o *SDF_1*:
 - Erros da rede *RNA_2* em classificar:
 - Falta monofásica da fase B nas barras 3, 264 e 673;
 - Falta monofásica da fase C nas barras 3, 126, 264, 410 e 611;
 - Falta bifásica das fases A-B nas barras 28, 111, 126, 233, 655, 684, 710 e 725;
 - Falta bifásica das fases C-A nas barras 3, 28, 191, 430 e 725;
 - Erros da rede *RNA_4* em classificar:
 - Falta bifásica das fases A-B na barra 126 e 684;
 - Falta bifásica das fases C-A na barra 430;

- Para o *SDF_2*:
 - Erros da rede *RNA_1* em detectar:
 - Falta bifásica das bases A-B nas barras 162 e 515;
 - Erros da rede *RNA_2* em classificar:
 - Falta monofásica da fase A nas barras 254, 264, 533, 542 e 684;
 - Falta monofásica da fase B na barra 3;
 - Falta monofásica da fase C na barra 3, 410, 813;
 - Falta bifásica das fases A-B nas barras 28, 111, 162, 233, 348, 452, 515, 627;
 - Falta bifásica das fases B-C nas barras 684, 836;
 - Falta bifásica das fases C-A nas barras 111, 290, 374, 410, 593 e 813
 - Falta trifásica nas fases: 162, 290 e 684;
 - Erro da rede *RNA_3* em classificar:
 - Falta monofásica na fase A nas barras 264 e 542;
 - Falta monofásica na fase C nas barras 410;
 - Erro da rede *RNA_4* em classificar:
 - Falta bifásica nas fases A-B nas barras 28, 348, 515 e 537;

- Falta bifásica das fases C-A nas barras 290 e 813;
- Para o *SDF_3*:
 - Erros da rede *RNA_1* em detectar:
 - Falta monofásica da fase A na barra 3;
 - Falta monofásica da fase C na barra 410;
 - Falta bifásica nas fases A-B nas barras 312 e 515;
 - Falta bifásica nas fases B-C na barra 312;
 - Erros da rede *RNA_2* em classificar:
 - Falta monofásica da fase A nas barras 3, 111, 233, 673 e 792;
 - Falta monofásica da fase B na barra 374;
 - Falta monofásica da fase C nas barras 71, 126, 264, 374, 410, 792 e 813;
 - Falta bifásica das fases A-B nas barras 205, 264, 290, 312, 348, 515, 542 e 611;
 - Falta bifásica das fases B-C nas barras 290, 312, 374 e 684;
 - Falta bifásica das fases C-A nas barras 162, 430 e 817;
 - Falta trifásica nas barras 3, 126, 374, 710, 725, 813 e 836;
 - Erros da rede *RNA_3* em classificar:
 - Falta monofásica da fase A nas barras 3, 111;
 - Falta monofásica da fase B na barra 374;
 - Falta bifásica das fases A-B nas barras 264, 374, 410, 813;
 - Erros da rede *RNA_4* em classificar:
 - Falta bifásica das fases A-B nas barras 264, 312, 348, 515 e 542;
 - Falta bifásica das fases B-C nas barras 290, 312, 684;
 - Falta trifásica na barra 3, 710;
- Para o *SDF_4*:
 - Erros da rede *RNA_2* em classificar:
 - Falta monofásica da fase A nas barras 3, 233 e 264;
 - Falta monofásica da fase B na barra 3;
 - Falta monofásica da fase C nas barras 410 e 593;
 - Falta bifásica das fases B-C nas barras 542 e 813;
 - Falta bifásica das fases C-A nas barras 3, 410 e 710;
 - Falta trifásica nas barras 3, 264, 312, 348, 410, 487, 542 e 792;

- Erro da rede **RNA_3** em classificar:
 - Falta monofásica da fase A na barra 3;
- Erro da rede **RNA_4** em classificar:
 - Falta bifásica das fases B-C na barra 813;
 - Falta bifásica das fases C-A nas barras 3 e 710;
- Para o **SDF_5**:
 - Erro da rede **RNA_1** em detectar:
 - Falta bifásica das fases A-B na barra 3;
 - Erro da rede **RNA_2** em classificar:
 - Falta monofásica da fase A na barra 430;
 - Falta monofásica da fase B nas barras 3, 71, 233, 467, 673 e 813;
 - Falta monofásica da fase C nas barras 191, 410 e 627;
 - Falta bifásica das fases A-C nas barras 3, 264, 327, 385, 542, 593, 710 e 836;
 - Falta bifásica das fases B-C nas barras 3, 82, 155, 566, 710 e 773;
 - Falta trifásica na barra 3;
 - Erro da rede **RNA_3** em classificar:
 - Falta monofásica da fase B nas barras 3 e 673;
 - Falta monofásica da fase C nas barras 410;
 - Erro da rede **RNA_4** em classificar:
 - Falta bifásica das fases A-B nas barras 3 e 542;
 - Falta bifásica das fases B-C na barras 566 e 155;
 - Falta trifásica na barra 3.

A partir dos resultados esboçados, observa-se uma maior incidência de erros quanto ao desempenho da **RNA_2**. Tal fato não é surpreendente, pois esta rede foi responsabilizada por executar a tarefa mais complexa dentre as quatro redes presentes: classificar sete padrões de faltas diferentes, ou seja, todos eles.

Deste modo, pode-se atestar a importância da existência das redes de redundância, no que se refere à classificação de faltas: as **RNA_3** e **RNA_4**. Por terem de, também, classificar faltas, porém, com menos padrões, tais RNAs mostraram melhores resultados, corrigindo, na maioria das vezes, as falhas apresentadas pela **RNA_2**. Levando-se, então, em consideração esse acobertamento dos erros, da **RNA_2**, pelos melhores

resultados das *RNA_3* e *RNA_4*, pode-se montar a tabela 8.3, indicadora do verdadeiro resultado que seria mostrado ao operador.

Tabela 8.3 – Resultados percentuais de acertos quanto ao resultado global do Programa Detector e Classificador de Faltas	
Sistema	Acerto global do programa
SDF_1	99,0%
SDF_2	96,9%
SDF_3	94,2%
SDF_4	98,6%
SDF_5	97,3%

Deixando um pouco a classificação e entrando no assunto da detecção, chega-se à análise da *RNA_I*: sua ação foi a mais eficiente dentre as quatro redes. Isso se justifica pelo fato de esta apenas classificar dois tipos de padrões: ocorrência ou não-ocorrência de falta. Todavia, mesmo com essa facilidade, deve-se ressaltar que o ótimo desempenho da *RNA_I* torna o programa consideravelmente confiável quanto à detecção de faltas.

A tabela 8.4 esboça outros dois sistemas detectores e classificadores de faltas, porém, com um importante diferencial: seus resultados globais atingiram 100% de acerto.

Tabela 8.4 – Sistemas Detectores e Classificadores de Faltas com resultados globais de 100% de acerto		
Largura da janela (períodos)	Amostras por passo	Componentes Harmônicos
1	16	1 ^a a 7 ^a
1	8	1 ^a a 9 ^a

Pelos dados apresentados, na tabela 8.4, nota-se o grande número de harmônicos utilizados. Porém, isso não tira o mérito do programa em apresentar combinações de resultados que atinjam os 100% de acerto. Isto demonstra a possibilidade de se chegar a

configurações ótimas que, em possíveis situações de aplicações em um ambiente real, seriam as primeiras a serem testadas.

Analisando-se, agora, os resultados de uma forma mais geral, observa-se que a utilização das redes ARTMAP Nebulosas mostrou-se bastante satisfatória. Seus acertos estiveram globais, quase sempre, acima dos 95%, exibindo, ainda, grande grau de confiança em relação à detecção de faltas (*RNA_I*).

Portanto, em vista de tudo o que foi apresentado e discutido, não há dúvidas de que a aplicação paralela das DFT e DWT mostrou-se uma ferramenta de grande valor.

8.1. Conclusão

Como já referenciado em certos trechos desta obra, a manipulação matemática dos dados amostrados de corrente, executada na etapa de Pré-Processamento, foi, parcialmente, baseada na metodologia de Matos (2009), através da aplicação da Transformada de *Fourier*. Portanto, nada mais justificado seria do que fazer uma comparação entre os resultados apresentados em Matos (2009) e os obtidos no atual projeto. Foram feitas simulações utilizando-se dos mesmos parâmetros de entrada usados em Matos (2009). Tais padrões, na referida obra, propiciaram taxas de acertos de 100% em classificação e detecção de falhas. Aqui, estes dados também apontaram resultados satisfatórios. Além destas combinações de parâmetros, também foram mostrados os importantes sistemas que consequenciaram em resultados de 100%, comprovando a funcionalidade do novo método.

Capítulo 9: Conclusão e Trabalhos Futuros

As Subestações de Energia Elétrica compõem um dos mais importantes complexos do sistema de Geração/Transmissão/Distribuição. O seu correto funcionamento, como pôde ser visto, é baseado em muitos fatores, sendo a sua malha de proteção um dos mais essenciais. Desta maneira, é indiscutível que esta área de proteção não é composta, apenas, de aparelhos eletromecânicos manuseados, somente, à mercê da experiência dos operadores.

A concepção de um processo eletrônico, capaz de automatizar o diagnóstico, correção e prevenção de faltas, mostra-se de suma importância no contexto atual. Partindo desta conjuntura, apareceu a idéia de se elaborar um algoritmo capaz de detectar e classificar falhas de curto-circuito em sistemas de distribuição.

Durante toda a presente obra, destrinchou-se o algoritmo implementado, assim como, esboçou-se a teoria em que foram baseadas as principais etapas do funcionamento: o Pré-Processamento, o Banco de Redes Neurais e o Pós-Processamento.

A elaboração do Pré-Processador foi um dos maiores desafios. Foram necessárias duas aplicações independentes das Transformadas Discretas de *Fourier* e *Wavelet*. Isso se justifica pelo fato de ambas trabalharem em domínios distintos: a DFT opera no domínio da frequência, enquanto que a DWT trabalha somente no tempo. Mesmo com tais dificuldades, o trabalho se mostrou recompensador, já que a utilização paralela das duas ferramentas propiciou resultados animadores.

Quanto ao Banco de Redes Neurais, foi necessário um pré-estudo teórico do funcionamento das redes ARTMAP Nebulosas. Tal artifício segue a principal filosofia das redes neurais artificiais: a operação de classificações de dados através de um pré-treinamento de reconhecimento de padrões. E a ARTMAP Nebulosa mostrou-se eficiente tanto na detecção quanto na classificação de faltas do tipo curto-circuito, apresentando taxas de acertos superiores a 95%.

Após essa análise geral, ressalta-se outro grande benefício da implementação deste projeto: a considerável mescla de assuntos aplicados. A fim de se chegar ao Sistema Detector e Classificador de Faltas, foram necessários estudos quanto às características, tanto construtivas quanto de funcionamento, de subestações, houve a necessidade

de se elucidar as formas de aplicação de duas importantes ferramentas matemáticas – a DFT e a DWT, sendo elas tão utilizadas no processamento de sinais –, além do já citado profundo estudo a cerca das RNAs ARTMAP Nebulosas.

A principal sugestão, visando projetos futuros, seria a aplicação do programa num ambiente real. Tal empreitada, com certeza, seria provida de difíceis desafios, sendo que o principal é obter as correntes em tempo real e a uma taxa que permitisse uma operação adequada do algoritmo. Outro desafio é, de fato, enfrentar a imprevisibilidade presente nos sistemas elétricos reais. Contudo, os resultados alcançados são encorajadores, pois ultrapassa a etapa de concepção e implementação de um algoritmo funcional, com testes baseados em dados reais.

Referências Bibliográficas

ALTRAN, A. B.. **Aplicação de funções de base radial em problemas de cargas elétricas via redes neurais artificiais**. 2005. 95 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Departamento de Engenharia Elétrica, Universidade Estadual Paulista Julio de Mesquita Filho, Faculdade de Engenharia de Ilha Solteira, Ilha Solteira, 2005.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (Brasil). **ABNT NBR IEC 62271-100: Equipamentos de alta tensão - Parte 100: Disjuntores de alta-tensão de corrente alternada**. 100 p. Disponível em: <www.abnt.org.br>. Acesso em: 17 jun. 2008.

BARROS, A. C.. **Deteção e classificação de faltas de alta impedância em sistemas elétricos de potência usando lógica fuzzy**. 2009. 93 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Departamento de Engenharia Elétrica, Universidade Estadual Paulista Julio de Mesquita Filho, Faculdade de Engenharia de Ilha Solteira, Ilha Solteira, 2009.

BO, Z. Q. et al. A new approach to phase selection using fault generated high frequency noise and neural networks. **IEEE Transactions On Power Delivery**, New York, v. 12, n. 1, p.106-115, Jan. 1997. Quadrimestral.

CARDOSO JÚNIOR, G.; ROLIM, J. G.; ZÜRN, H. H.. Diagnóstico de faltas em sistemas de potência: definição do problema e abordagens via inteligência artificial. **Revista SBA: Controle e Automação**, Porto Alegre, v. 15, n. 2, p.215-229, abr. 2004. Trimestral.

CARPENTER, G. A.; GROSSBERG, S.. ART 2: self-organization of stable category recognition codes for analog input patterns. **Applied Optics**, Rochester, v. 26, n. 23, p.4919-4930, Dec. 1987. Quinzenal.

CARPENTER, G. A.; GROSSBERG, S.. **Pattern recognition by self-organizing neural networks**. Cambridge: The Mit Press, 1991. 710 p.

CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B.. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. **Neural Networks**, Oxford, v. 4, n. 6, p.759-771, June 1991. Mensal.

CARPENTER, G. A. et al. Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions On Neural Networks**, New York, v. 3, n. 5, p.698-713, Sep. 1992. Quadrimestral.

DAUBECHIES, I.. **Ten Lectures on Wavelets**. 2nd Philadelphia: SIAM Books, 1992. 355 p.

DECANINI, J. G. M. S.. **Detecção e classificação de faltas de curto-circuito em sistemas de distribuição de energia elétrica usando lógica nebulosa**. 110 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Departamento de Engenharia Elétrica, Universidade Estadual Paulista, Ilha Solteira, 2008.

DUARTE, M. A. Q.. **Redução de Ruídos em Sinais de Voz no Domínio Wavelet**. 2005. 121 f. Tese (Doutorado) - Curso de Engenharia Elétrica, Departamento de Engenharia Elétrica, Universidade Estadual Paulista Júlio de Mesquita Filho, Ilha Solteira, 2005.

ELLIOTT, D. F.; RAO, K. R.. **Fast Transforms - Algorithms, Analyses and Applications**. 3rd New York: Academic Press, 1982. 488 p.

GIGUER, S.. **Proteção de sistemas de distribuição**. Porto Alegre: Editora Sagra, 1988. 344 p.

HAYKIN, S.. **Neural networks: A comprehensive foundation**. 2. ed. New Jersey, EUA: Macmillan College Publishing, Inc., 1999. 700 p.

HÖNIG, S. C.. A Integral de Lebesgue e suas Aplicações. In: COLÓQUIO BRASILEIRO DE MATEMÁTICA, 11., 1977, Caldas Novas. **Anais...** . Caldas Novas: IMPA, 1977. p. 237 - 253.

HSU, H. P.. **Análise de Fourier**. Rio de Janeiro: Livros Técnicos e Científicos, 1973. 273 p.

KROSE, B.; SMAGT, P.. **An introduction to neural networks**. 8. ed. Amsterdam: University Of Amsterdam, 1996. 135 p.

LEÃO, R. P. S.. **Elementos de sistemas de potência**. Fortaleza: Universidade Federal do Ceará, 2007. Disponível em: <www.dee.ufc.br>. Acesso em: 03 jul. 2008.

LOPES, M. L. M.. **Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica**. 169 f. Tese (Doutorado) - Curso de Engenharia Elétrica, Departamento de Engenharia Elétrica, Universidade Estadual Paulista, Ilha Solteira, 2005.

LOTUFO, A. D. P.. **Análise de sensibilidade por redes neurais para estudos de estabilidade transitória de sistemas elétricos de potência**. 2004. 149 f. Tese (Doutorado) - Curso de Engenharia Elétrica, Departamento de Engenharia Elétrica, Universidade Estadual Paulista Julio de Mesquita Filho, Faculdade de Engenharia de Ilha Solteira, Ilha Solteira, 2004.

MARCHIORI, S. C.. **Desenvolvimento de um sistema para análise da estabilidade transitória de sistemas de energia elétrica via redes neurais**. 2006. 130 f. Tese (Doutorado) - Curso de Engenharia Elétrica, Departamento de Engenharia Elétrica, Universidade Estadual Paulista Julio de Mesquita Filho, Faculdade de Engenharia de Ilha Solteira, Ilha Solteira, 2006.

MATOS, E. R.. **Um método para detecção e classificação de curtos-circuitos em redes de distribuição de energia elétrica baseado na Transformada de Fourier e redes neurais artificiais**. 2009. 97 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Departamento de Engenharia Elétrica, Universidade Estadual Paulista Julio de Mesquita Filho, Faculdade de Engenharia de Ilha Solteira, Ilha Solteira, 2009.

MENDES FILHO, E. F.; CARVALHO, A. C. P. L.. Evolutionary design of MLP neural

network architectures. In: SIMPÓSIO BRASILEIRO DE REDES NEURAIAS, 4., 1997, Campos do Jordão. **Anais...** . Campo do Jordão: SBRN, 1997. p. 58 - 65.

MORA FLÓREZ, J. J.; MORALES ESPAÑA, G.; PÉREZ LONDOÑO, S.. Classification methodology and feature selection to assist fault location in power distribution systems. **Revista Facultad de Ingeniería Universidad Antioquia**, Medellín, n. 44, p.83-96, jun. 2008. Trimestral.

MORETO, M.. **Localização de faltas de alta impedância em sistemas de distribuição de energia: uma metodologia baseada em redes neurais artificiais**. 126 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2005.

OLESKOVICZ, M.; AGGARWAL, R. K.; COURY, D. V. O emprego de redes neurais artificiais na detecção, classificação e localização de faltas em linhas de transmissão. **Revista SBA: Controle e Automação**, Porto Alegre, v. 14, n. 2, p.163-172, abr. 2003. Trimestral.

OPPENHEIM, A. V.; SCHAFER, R. W.; BUCK, J. R.. **Discrete-time signal processing**. 2nd Upper Saddle River: Prentice-Hall, 1999. 870 p.

ORSINI, L. Q.. **Curso de circuitos elétricos**. São Paulo: Editora Edgard Blücher Ltda, 1994. 466 p.

PINHEIRO, H. B. **Sistema especialista para operação de subestações de energia elétrica**. 1995. 97 f. Dissertação (Mestrado) - Faculdade de Engenharia Elétrica, Universidade Estadual de Campinas, Campinas, 1995.

SEGATTO, E. C.; COURY, D. V.. Redes neurais aplicadas a relés diferenciais para transformadores de potência. **Revista SBA: Controle e Automação**, Porto Alegre, v. 19, n. 1, p.93-106, jan. 2008. Trimestral.

SILVA, M. R.; CARVALHO, J. C.. **Barramentos de SE's**. Curitiba: Centro Federal de Educação Tecnológica do Paraná, Departamento Acadêmico de Eletrotécnica, 2002. 87p.

Livros Grátis

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

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

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

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

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