

UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE CIÊNCIAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Dissertação de Mestrado

**Um Localizador de Falhas em Linhas de
Transmissão Baseado em Redes Neurais Artificiais**

José Antônio Cândido Borges da Silva

Campina Grande - Paraíba - Brasil
Julho de 2004

©José Antônio Cândido Borges da Silva



Ficha catalográfica preparada pela Biblioteca Central da UFCEG.

S5811 Silva, José Antônio Cândido Borges da
2004 Um Localizador de Faltas em Linhas de Transmissão
Baseado em Redes Neurais Artificiais/ José Antônio
Cândido Borges da Silva. - Campina Grande: UFCEG,
2004.

85 p. il.

Dissertação (mestrado) UFCEG / CCT.

Inclui Bibliografia.

1. Localização de Faltas. 2. Linhas de Transmissão.
3. Redes Neurais Artificiais. 4. Transmissão Elétrica.

CDU: 621.315

José Antônio Cândido Borges da Silva

**Um Localizador de Falhas em Linhas de
Transmissão Baseado em Redes Neurais Artificiais**

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

Área de Concentração: Processamento da Energia

Washington Luiz Araújo Neves, Ph.D.

Orientador

Benemar Alencar de Souza, D.Sc.

Orientador

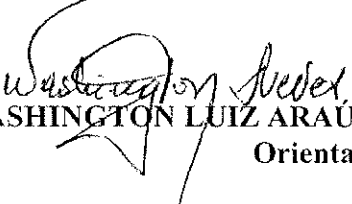
Campina Grande - Paraíba - Brasil

Julho de 2004

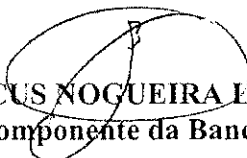
UM LOCALIZADOR DE FALTAS EM LINHAS DE TRANSMISSÃO BASEADOS
EM REDES NEURAIS ARTIFICIAIS

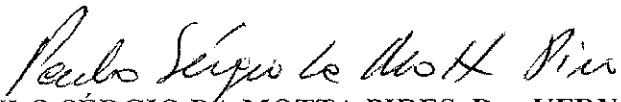
JOSÉ ANTONIO CÂNDIDO BORGES DA SILVA

Dissertação Aprovada em 28.07.2004


WASHINGTON LUIZ ARAÚJO NEVES, Ph.D., UFCG
Orientador


BENEMAR ALENCAR DE SOUZA, D.SC., UFCG
Orientador


ANTONIO MARCUS NOGUEIRA LIMA, Dr., UFCG
Componente da Banca


PAULO SÉRGIO DA MOTTA PIRES, Dr., UFRN
Componente da Banca


ERON DE OLIVEIRA BARRETO, M.Sc., CHESF
Componente da Banca

CAMPINA GRANDE - PB
Julho - 2004

Agradecimentos

A Deus acima de tudo por ter me permitido chegar aqui.

Aos meus pais Severino e Maria José, meus irmãos Francisco de Assis e Inez, minha avó Lia, todos os meus tios, tias, primos e primas por representarem muito em minha vida.

À CHESF e à CAPES pelo apoio financeiro.

À COPELE por ter me proporcionado a oportunidade de fazer parte do programa de Pós-Graduação.

Ao Professor Washington Neves pela amizade, conhecimentos técnicos transmitidos desde a graduação como aluno de disciplina, de Iniciação Científica e orientação no Mestrado.

Ao Professor Benemar Alencar de Souza pela orientação e amizade.

Ao Professor Edson Guedes da Costa por ter me proporcionado a chance de fazer parte do Grupo de Sistemas Elétricos através de minha primeira Bolsa de Iniciação Científica.

À Professora Núbia Brito pela disponibilidade de ajudar e tirar dúvidas, e sua amizade.

Ao Professor Damásio Fernandes Júnior pela orientação no Estágio Docente, e amizade ao longo dos anos.

Ao Professor Wellington Santos Mota pelas sugestões na apresentação da Proposta dessa dissertação.

Aos amigos do Laboratório de Alta Tensão: Franklin, Luciano, Estácio, Ângelo, Hellon, Josivan, Andréa, Danielly, Eduardo, Darlan, Rodrigo, Fabiano e Diana, pela amizade e convivência no dia-a-dia.

Ao Professor Alécio Barreto Fernandes pela sua ajuda e contribuição quando das minhas dúvidas com ATP.

A Eron de Oliveira Barreto, e aos professores Paulo Sérgio da Motta Pires e Antônio Marcus Nogueira Lima pela participação na banca, e contribuições ao trabalho.

Aos alunos do Projeto de Pesquisa e Desenvolvimento que deu origem ao programa Neuranálise: Antônio Carlos, Ricardo, Flávio, Karcus Marcelus e Alessandro, pela disponibilidade em ajudar, e pelas dúvidas tiradas quando precisei.

Ao amigo Kleber Melo pelas discussões sobre Redes Neurais, pela parceria na produção de artigos, e por valiosas sugestões e contribuições que vieram enriquecer o conteúdo dessa dissertação.

Aos amigos da Graduação Ronimack, Max Neri, Max Wendel, José Carlos, Carlos Alberto, Tercius Cassius e Renata pela amizade fraternal cultivada ao longo desses anos.

Aos amigos de todas as horas Pedro, Joverlaine, Marcos, Daysan, Valclemir e Lhíncio, pelo estímulo e convivência.

Aos funcionários da COPELE: Ângela, Pedro, Marcos e Eleonôra.

Aos funcionários do Laboratório de Alta Tensão: Francisco, Eduardo, Dona Lourdes, Adalberto, Adriano e Selma.

Resumo

Um algoritmo de localização de faltas para linhas de transmissão utilizando Redes Neurais Artificiais (RNAs) é apresentado neste trabalho. A arquitetura de rede adotada foi a perceptron multi-camada. Os softwares Neuranálise e ATP foram utilizados para construção da base de dados utilizada no treinamento, teste e validação das RNAs. As entradas para as RNAs são as amostras de tensões e correntes de fase e de seqüência zero. As condições de falta foram simuladas para uma linha de transmissão de 230 kV. Cada arquivo necessário para a construção da base de dados é gerado automaticamente em um formato padronizado e executado em modo *batch*. Para a localização de faltas, a linha de transmissão é dividida em 8 zonas. Anterior à localização, é feita a classificação do tipo de falta treinando-se uma RNA com a base de dados completa. Após a classificação, é feita a seleção da zona em que se encontra a falta. Para a localização, 8 RNAs são treinadas para cada tipo de falta, cada uma com os dados da zona específica. O localizador possui ao todo 37 RNAs, e apresentou resultados satisfatórios para o problema analisado.

Abstract

A fault location algorithm for transmission lines using artificial neural networks (ANNs) is presented in this work. The network architecture adopted was the multilayer perceptron. The softwares Neuranálise and ATP were used to build the data base used for training, test and validation of the ANNs. The inputs to the ANNs are phase quantities and zero sequence voltage and current waveform data from the electric system. The fault conditions were simulated for a 230 kV transmission line. Each file needed to build the data base is generated automatically from a standard format file and run in batch mode. For the fault location, the transmission line is divided into 8 zones. Previous to localization, the classification of fault type is carried out by training the ANNs with the full line data. After the classification of fault type the zone in which the fault is located is selected. For the final localization, eight ANNs are trained for each fault type, each one with the data of the specific zone. The full localizer has 37 ANNs, and the results presented for the problem analyzed were satisfactory.

SUMÁRIO

Agradecimentos	ii
Resumo	iv
Abstract	v
Sumário	vi
Lista de Figuras	viii
Lista de Tabelas	x
Glossário	xii
CAPÍTULO 1 – INTRODUÇÃO	1
1.1 Motivação	2
1.2 Objetivos	6
1.3 Estrutura da Dissertação	7
CAPÍTULO 2 – FUNDAMENTAÇÃO TEÓRICA	9
2.1 Conceitos de Redes Neurais Artificiais	9
2.1.1 Modelo do Neurônio	10
2.2.2 Arquiteturas de Redes Neurais e Treinamento	12
2.2 Falhas em Sistemas Elétricos de Potência	21
CAPÍTULO 3 – REVISÃO BIBLIOGRÁFICA	27
3.1 Algoritmos baseados em dados de um terminal	28
3.1.1 Método de Eriksson	28

3.1.2 Método de Takagi	30
3.1.3 Método de Wiszniewski	34
3.1.4 Outros Algoritmos de Um Terminal	35
3.2 Algoritmos baseados em dados de 2 terminais	36
3.2.1 Método de Zamora	36
3.2.2 Método de Girgis	40
3.2.3 Outros Algoritmos de Dois Terminais	41
3.3 Outros Métodos de Localização	42
3.4 RNAs em Engenharia Elétrica	44
CAPÍTULO 4 - MÉTODO IMPLEMENTADO	49
4.1 Sistema Proposto	50
4.2 Implementação do Método	52
4.2.1 Sistema Elétrico Utilizado	52
4.2.2 Base de Conhecimento	54
4.2.3 Implementação das RNAs	59
CAPÍTULO 5 - ANÁLISE DOS RESULTADOS	63
5.1 Resultados para o Sistema Proposto	64
5.2 Resultados para a RNA simples	74
CAPÍTULO 6 - CONCLUSÕES	77
REFERÊNCIAS BIBLIOGRÁFICAS	80
ANEXOS	86

Lista de Figuras

Figura 2.1 - Modelo não-linear de um neurônio.	11
Figura 2.2 - Sistema Trifásico a ser representado em componentes simétricas.	22
Figura 2.3 - Componentes de seqüência zero, positiva e negativa do sistema da Figura2.2.	23
Figura 3.1 - Sistema equivalente para análise de faltas pro método de Eriksson. (a) Circuito pré-falta. (b) Circuito de falta. (c) Circuito pós-falta (Superposição de (a) e (b)).	29
Figura 3.2 - Modelo da linha de transmissão para o método de Zamora. (a) Em condição de falta. (b) Circuito de falta de seqüência positiva. (c) Equivalente de Thévenin.	39
Figura 3.3 - Representação unifilar do sistema elétrico de três terminais com falta no trecho PT.	43
Figura 4.1 -Topologia do sistema localizador de faltas.	51
Figura 4.2 - Sistema elétrico utilizado.	53
Figura 4.3 - Configuração da torre da linha 04V4.	53
Figura 4.4 - Interface do software Neuranálise.	55
Figura 4.5 - Processo de janelamento dos sinais de tensão e corrente.	59

Figura 5.1 – Comparação entre os Erros Médios Absolutos para Faltas Fase-Terra na Base 1.	69
Figura 5.2 – Comparação entre os Erros Médios Absolutos para Faltas Fase-Fase na Base 1.	69
Figura 5.3 – Comparação dos Erros Médios Absolutos para Faltas Fase-Fase-Terra na Base 1.	70
Figura 5.4 – Comparação dos Erros Médios Absolutos para Faltas Trifásicas na Base 1.	70
Figura 5.5 – Comparação dos Erros Médios Absolutos para para Faltas Fase-Terra na Base 2.	73
Figura 5.6– Comparação dos Erros Médios Absolutos para Faltas Fase-Fase na Base 2.	73
Figura 5.7 – Comparação dos Erros Médios Absolutos para Faltas Fase-Fase-Terra na Base 2.	74
Figura 5.8 – Comparação dos Erros Médios Absolutos para Faltas Trifásicas na Base 2.	74

Lista de Tabelas

Tabela 2.1 - Faltas ocorridas no sistema CHESF nos anos de 2003 e 2004.	21
Tabela 2.2a - Resumo das tensões de fase para as condições de falta.	24
Tabela 2.2b - Resumo das correntes de fase para as condições de falta.	24
Tabela 2.3a - Resumo das tensões de seqüência para as condições de falta.	25
Tabela 2.3b - Resumo das tensões de seqüência para as condições de falta.	25
Tabela 3.1 - Expressões da distância de falta para os casos fase-terra, fase-fase e fase-fase-terra.	33
Tabela 3.2 - Características das redes propostas por [Oleskovicz et al, 2003].	47
Tabela 4.1 - Dados das bases de conhecimento utilizada.	57
Tabela 4.2 - Codificação dos Tipos de Falta.	58
Tabela 4.3 - Codificação das Zonas de Localização.	58
Tabela 5.1 - Síntese das Simulações do Sistema Proposto.	65
Tabela 5.2 - Resultados para Faltas Fase-Terra da Base 1 com Janela de 4 amostras.	66
Tabela 5.3 - Resultados para Faltas Fase-Fase da Base 1 com Janela de 4 amostras.	66
Tabela 5.4 - Resultados para Faltas Fase-Fase-Terra da Base 1 com Janela de 4 amostras.	67

Tabela 5.5 – Resultados para Falhas Trifásicas da Base 1 com Janela de 4 amostras.	67
Tabela 5.6 – Resultados para Falhas Fase-Terra da Base 2 com Janela de 4 amostras.	71
Tabela 5.7 – Resultados para Falhas Fase-Fase da Base 2 com Janela de 4 amostras.	71
Tabela 5.8 – Resultados para Falhas Fase-Fase-Terra da Base 2 com Janela de 4 amostras.	72
Tabela 5.9 – Resultados para Falhas Fase-Terra da Base 1 com Janela de 4 amostras.	72
Tabela 5.10a – Resultados para uma única RNA localizadora – Teste por padrões.	75
Tabela 5.10b – Resultados para uma única RNA localizadora – Teste por arquivos.	76

Glossário

ATP	Alternative Transient Program.
CHESF	Companhia Hidro Elétrica do São Francisco.
GPS	Global Positioning System.
MLP	Multilayer Perceptron.
RDP	Registrador Digital de Perturbação.
RNA	Rede Neural Artificial.
RPROP	Resilient Propagation.
TC	Transformador de Corrente.
TDF	Transformada Discreta de Fourier.
TP	Transformador de Potencial.

1

Introdução

O Setor Elétrico Brasileiro vem sofrendo nos últimos anos um profundo processo de reestruturação. Essa reestruturação sacramentou a importância de se investir na obtenção de altos índices de disponibilidade do sistema de transmissão de energia elétrica. O que antes consistia numa política de bom senso das empresas passou a ser uma questão de sobrevivência, diante das rigorosas regras e pesadas multas impostas pelos órgãos fiscalizadores.

É eminente a necessidade do sistema de transmissão de energia elétrica ser dotado de equipamentos que possam monitorar suas condições e fornecer todas as informações necessárias ao seu restabelecimento imediato, quando da ocorrência de uma falha. Falhas nos sistemas elétricos de potência são comuns devido às condições adversas a que podem ser submetidos. Essas condições incluem desligamentos não programados de um ou mais componentes do sistema, dentre eles as linhas de transmissão.

O desenvolvimento nos últimos anos de novas técnicas de localização de faltas em linhas de transmissão é assunto de grande interesse para pesquisadores e engenheiros da área de sistemas elétricos de potência. A localização precisa e imediata de falta na linha de transmissão permite uma rápida determinação de sua natureza, facilitando os reparos e a restauração do sistema elétrico em questão.

1.1 Motivação

A complexidade atual do sistema elétrico tem tornado o mercado de energia cada vez mais competitivo, exigindo *eficiência* do sistema e *qualidade* no serviço prestado. O sistema elétrico, entretanto, está sujeito a eventos inesperados que podem causar interrupção no suprimento de energia, acarretando redução da eficiência e da qualidade [Silva, 2004]. Dessa forma, é cada vez mais importante a monitoração de qualquer perturbação que venha a ocorrer no sistema, e a correta identificação de todos os detalhes, como tipo e localização.

A ocorrência aleatória e imprevisível que pode causar a interrupção no fornecimento de energia elétrica é denominada falta [Caminha, 1977]. O sistema de proteção é responsável pela remoção imediata das seções com falta, pela atuação apropriada dos seus disjuntores; garantindo a integridade do sistema elétrico e dos equipamentos envolvidos.

Dentre os componentes de um sistema elétrico de potência, a linha de transmissão é o elemento mais susceptível a faltas, considerando-se suas dimensões físicas. Para as linhas utilizam-se, em geral, os valores das tensões e correntes de fase registrados para detectar, classificar e localizar determinada falta e então enviar um sinal para os circuitos de interrupção que irão desconectá-la [Oleskovicz et al, 2003]. Os defeitos mais frequentes nas linhas de transmissão são causados pela perda de isolamento entre o condutor e a terra, ou entre condutores, geralmente em função de [Barreto, 2003]:

- Deterioração da cadeia de isoladores seja por poluição ou por quebra, oriunda de atos de vandalismo;
- Quebra de condutores de fase, provocada por ruptura dos pinos dos isoladores, quebra das ferragens de sustentação das cadeias de isoladores ou mesmo por ruptura do próprio condutor;
- Queda do cabo pára-raio montado sobre os condutores de fase, gerando curtos-circuitos mono, bi ou trifásicos;
- Incidência de descargas atmosféricas.

O conhecimento imediato da localização da falta e de sua natureza facilita os reparos e a restauração da linha, sendo de importância vital para uma

operação econômica. Além de facilitar a manutenção e os reparos necessários no sistema elétrico, a localização precisa das faltas fornece informações úteis em estudos de proteção e análise de desempenho frente a surtos atmosféricos.

Até a década de 70, os sistemas de controle das subestações eram predominantemente dominados pelos relés eletromecânicos e desprovidos de qualquer sistema de localização de faltas em linhas de transmissão. Os registradores de perturbação existentes eram caros e limitados, pois seus registros tinham que ser coletados localmente e enviados por transportes convencionais para os centros de análise. Apenas permitiam uma análise simplificada do tipo de defeito ocorrido (mono, bi ou trifásico), além de uma estimativa grosseira da proximidade do defeito de um terminal ou do outro.

Com a entrada dos relés semi-estáticos no final da década de 70, os primeiros localizadores de faltas passaram a ser incorporados aos sistemas de controle e proteção das linhas de transmissão. Com o processo de digitalização dos sistemas de controle e dos relés de proteção, os localizadores de falta foram incorporados definitivamente ao sistema de controle e supervisão de um terminal de linha, uma vez que todo o processo de aquisição de dados (corrente e tensão dos terminais de linha) passou a ser unificado.

Os localizadores de falta desempenham papel relevante, mesmo quando há helicópteros disponíveis para a inspeção das linhas de transmissão. Isso ocorre porque existem linhas situadas em regiões de difícil acesso, ou em locais bastante insalubres, em que o simples percurso por um vão pode levar muito tempo. A importância dos localizadores de faltas é ainda mais óbvia quando

não se dispõe de helicópteros, e as patrulhas são realizadas por terra, particularmente em linhas longas e em terrenos acidentados. Também são úteis onde a manutenção da jurisdição é dividida entre diferentes companhias ou entre divisões dentro da mesma companhia.

Outro aspecto que possibilitou o uso de localizadores de faltas em linhas de transmissão foi a ampliação e, principalmente, a modernização das redes de oscilografia. Os registradores digitais de perturbação passaram a dominar o mercado, e uma vez que as informações de corrente e tensão estavam disponíveis em sua forma digital, a aplicação de softwares direcionados para a localização de faltas passou também a ser largamente utilizada.

As técnicas de Inteligência Artificial têm se tornado soluções alternativas para problemas em Engenharia Elétrica, destacando-se o uso das redes neurais artificiais (RNAs). As RNAs vêm sendo aplicadas em problemas de classificação, previsão de séries temporais e identificação de sistemas. Essa diversidade de aplicações se deve ao fato de possuírem alta capacidade de aprendizado e generalização, além de velocidade e robustez no diagnóstico.

O uso das RNAs em Engenharia Elétrica já é bastante expressivo atualmente. Utilizando suas capacidades de generalização e abstração, é possível detectar, classificar e localizar uma situação de falta. No caso de localização de faltas em linhas de transmissão, as RNAs vêm apresentando bons resultados [Jorge et al, 1999], [Oleskovicz et al, 2000; 2003] e [Kezunovic & Rikalo, 1996; 1999], o que encoraja o aprofundamento dos estudos da aplicação dessa metodologia nessa linha de pesquisa.

1.2 Objetivos

O estudo de alguns algoritmos de localização de faltas em linhas de transmissão, com a posterior implementação de um sistema de localização com a utilização de uma estrutura encadeada de RNAs são os objetivos desta dissertação. Os valores amostrados das tensões e correntes no sistema são utilizados como parâmetros de entrada para o localizador. A linha de transmissão utilizada para teste da metodologia proposta foi a 04V4 de 230kV, pertencente ao subsistema Leste da CHESF, entre as cidades de Campina Grande - PB e Natal - RN.

No esquema adotado, inicialmente uma RNA realiza a classificação do tipo de falta (Fase-Terra, Fase-Fase, Fase-Fase-Terra ou Trifásica). Em seguida, com a linha dividida uniformemente em 8 trechos, denominados zonas de localização, identifica-se o trecho onde a falta ocorreu. Nesse momento, uma RNA treinada com os padrões referentes àquele trecho e ao tipo de falta identificado, realiza a estimação da localização. A escolha de 8 zonas ocorreu devido ao fato de ser uma potência de 2 (possibilitando assim a codificação em 3 bits). A divisão em 4 zonas não implicaria numa exatidão satisfatória na localização por zona, e dividindo-se em 16 resultaria num número excessivo de redes localizadoras. A arquitetura de RNA escolhida foi a perceptron multicamada, mais conhecida como rede MLP, e o recurso computacional utilizado para construção do sistema foi o Neural Network Toolbox do MATLAB®. A base de dados para treinamento das RNAs foi construída de forma automatizada, utilizando o software Neuranálise desenvolvido em um projeto

de P&D da UFCG/CHESF [GSE/DEE/UFCG, 2004]. Com o software é possível construir todos arquivos de dados para as localizações desejadas, executar na plataforma de simulação ATP para obtenção das tensões e correntes. Posteriormente, os dados são agrupados em janelas deslizantes e colocados em forma aleatória para apresentação às RNAs.

1.3 Estrutura da Dissertação

O trabalho aqui apresentado está organizado da seguinte forma:

- Capítulo 2: Fundamentação Teórica. Neste capítulo será abordada a teoria de redes neurais, assim como princípios fundamentais de faltas em sistemas elétricos de potência.
- Capítulo 3: Revisão Bibliográfica. Neste capítulo serão mostrados alguns métodos tradicionais de localização de faltas, assim como a utilização das RNAs em Engenharia Elétrica.
- Capítulo 4: Método Implementado. Será abordada a estrutura encadeada de redes neurais que forma o localizador proposto, com as particularidades e ajustes realizados para cada simulação.
- Capítulo 5: Análise dos Resultados. Serão mostrados os resultados obtidos para o método implementado, com discussão dos mesmos.
- Capítulo 6: Conclusões. Serão apresentadas as conclusões obtidas a partir dos resultados apresentados no capítulo anterior. Neste capítulo serão também feitas sugestões de melhorias que poderão ser implementadas futuramente.

- Anexo: Artigo “Implementação de um Localizador de Faltas Utilizando Redes Neurais Artificiais” resultante dessa dissertação, submetido ao IEEE Latin América Congress on Transmission and Distribution - T&D 2004.

2

Fundamentação Teórica

Neste capítulo serão apresentados uma revisão dos conceitos básicos de redes neurais, assim como os princípios fundamentais de faltas em sistemas elétricos de potência.

2.1 Conceitos de Redes Neurais Artificiais

O trabalho em RNAs iniciou-se pelo reconhecimento de que o cérebro humano processa informações de uma forma inteiramente diferente do computador

digital convencional. O cérebro é um computador altamente complexo, não-linear e paralelo [Haykin, 1999]. Na sua forma geral, uma rede neural é uma estrutura que é projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse. Para o trabalho em questão, foi utilizada uma classe importante de redes neurais que desempenham suas funções obedecendo a um processo ou algoritmo de aprendizagem. Em termos gerais, uma RNA contém uma camada de entrada, uma camada de saída e uma ou mais camadas escondidas. Cada camada pode possuir uma ou várias unidades de processamento, denominadas neurônios.

Os neurônios podem estar dispostos em estruturas interligadas por um grande número de conexões (sinapses). Geralmente essas conexões são associadas a pesos, que servem como fator de ponderação das entradas recebidas por cada unidade de rede [Silva, 2004].

2.1.1 Modelo do Neurônio

Um neurônio é a unidade de processamento de informação fundamental para a operação de uma rede neural. Seu modelo em diagrama de blocos, que forma a base para a modelagem artificial de RNAs, está ilustrado na Figura 2.1.

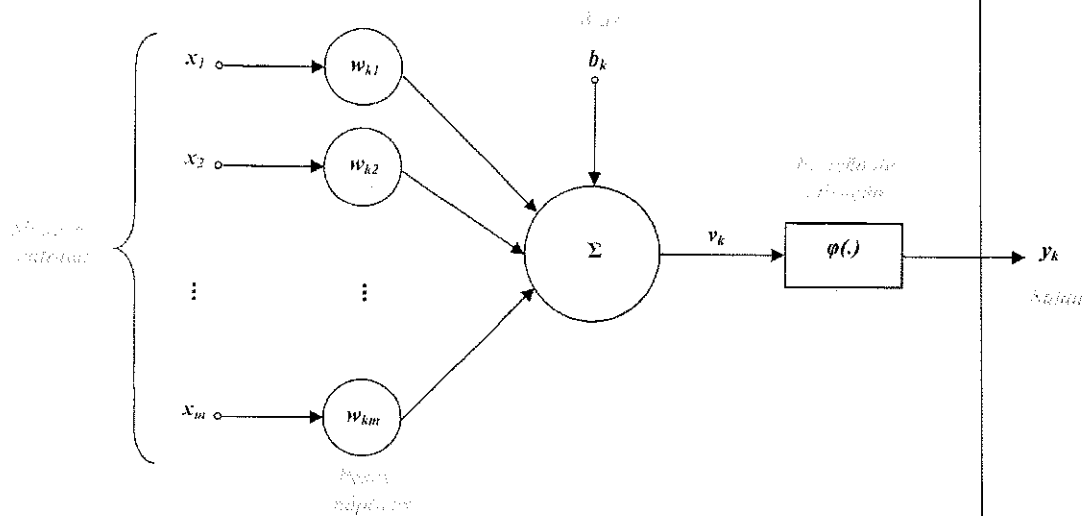


Figura 2.1 - Modelo não-linear de um neurônio.

O neurônio recebe a informação de entrada através de um conjunto de ligações ponderadas pelos pesos sinápticos. Um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} (o primeiro índice indica o neurônio em questão, enquanto o segundo refere-se à sinapse). Os sinais de entrada ponderados pelos respectivos pesos sinápticos são somados; com a saída do neurônio sendo definida pela função de ativação, que limita o intervalo permissível de amplitude do sinal de saída a um valor finito. No modelo também está incluso o *bias*, que aumenta ou diminui a entrada líquida da função de ativação. Matematicamente, o neurônio é assim definido:

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

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

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

Existem três tipos básicos de função de ativação:

1. Função limiar ou degrau unitário, definida por:

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

2. Função linear por partes, definida por:

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

3. Função sigmóide, cujo gráfico tem a forma de s. É a forma mais freqüentemente utilizada. É definida por:

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

As funções sigmóides constituem a forma mais comum de funções de ativação usadas na construção de RNAs. A constante a é conhecida como parâmetro de suavidade da função sigmóide, sendo sempre maior que zero. Com o valor de a tendendo ao infinito, a função torna-se a função limiar.

2.1.2 Arquiteturas de Redes Neurais e Treinamento

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

- **Redes de camada única** - É a forma mais simples de redes em camadas, em que há uma camada de entrada de nós de fonte que se projeta sobre uma

camada de saída de neurônios, mas não vice-versa. A camada única se refere à camada de saída.

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

Neste trabalho foram utilizadas redes com múltiplas camadas, normalmente conhecidas como perceptrons de múltiplas camadas (MLP - *multilayer perceptron*). A razão da escolha é o fato de ser uma arquitetura de fácil implementação e por ser bastante difundida na linha de pesquisa na qual o trabalho se enquadra. O treinamento utilizado geralmente para esse tipo de rede é conhecido como algoritmo de retropropagação do erro, utilizado em aproximadamente 80-90% das aplicações práticas [Mazón et al, 2000], e que consiste de dois passos através das diferentes camadas da rede:

- **Propagação** - Um vetor de entrada é aplicado a rede, e seu efeito se propaga camada por camada; produzindo uma resposta nas camadas de saída. Durante esse passo os pesos sinápticos são todos fixos.

- **Retropropagação** - Os pesos sinápticos são ajustados de acordo com uma regra de correção de erro. A resposta real da rede é subtraída da resposta desejada, gerando um sinal de erro, que é propagado através da rede em direção contrária às conexões sinápticas.

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

$$e_j(n) = d_j(n) - y_j(n) \quad (2.4)$$

Em que:

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

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

$y_j(n)$ - Saída real no neurônio.

O valor instantâneo da energia para o neurônio j é definido como $\frac{1}{2}e_j^2(n)$. Da mesma forma, o valor instantâneo da energia total do erro $E(n)$ é obtido somando-se as energias de todos os neurônios da camada de saída. Tem-se então:

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (2.5)$$

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

$$E_{med} = \frac{1}{N} \sum_{n=1}^N E(n) \quad (2.6)$$

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

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (2.7)$$

Diferenciando-se ambos os membros da equação (2.5) em relação a $e_j(n)$, da equação (2.4) em relação a $y_j(n)$, da equação (2.3) em relação a $v_j(n)$, e da equação (2.1) em relação a $w_{ji}(n)$ obtêm-se:

$$\frac{\partial E(n)}{\partial e_j(n)} = e_j(n) \quad (2.8)$$

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (2.9)$$

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi_j'(v_j(n)) \quad (2.10)$$

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = x_i(n) \quad (2.11)$$

Aplicando-se as equações (2.8), (2.9), (2.10) e (2.11) em (2.7) obtém-se:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = -e_j(n) \varphi_j'(v_j(n)) x_i(n) \quad (2.12)$$

A correção $\Delta w_{ji}(n)$ aplicada a $w_{ji}(n)$ é definida por [Haykin, 1999]:

$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)} \quad (2.13)$$

em que η é o parâmetro da taxa de aprendizagem do algoritmo de retropropagação, que tem por função regular a velocidade de convergência.

Vale salientar que os pesos sinápticos são corrigidos no passo da retropropagação. Aplicando-se a equação (2.12) em (2.13):

$$\Delta w_{ji}(n) = \eta \delta_j(n) x_j(n) \quad (2.14)$$

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

$$\delta_j(n) = -\frac{\partial E(n)}{\partial v_j(n)} \quad (2.15)$$

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

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

Para o modo de treinamento por lote, o valor de reajuste dos pesos a cada padrão apresentado à rede é calculado da mesma forma que no modo seqüencial. Contudo, os pesos sinápticos só são atualizados ao final da época de treinamento, utilizando-se a média aritmética de todos os reajustes calculados para todos os padrões da época. Dessa forma, a equação (2.13) pode ser escrita como:

$$\Delta w_{ji}^k(n) = -\frac{\alpha}{N} \sum_{n=1}^N \frac{\partial E(n)}{\partial w_{ji}^k} \quad (2.16)$$

em que α é chamado de *momentum da rede*. Esse termo tem a função de acelerar a convergência. Sua incorporação representa uma modificação pequena na atualização dos pesos, contudo pode ter alguns efeitos benéficos sobre a aprendizagem no algoritmo. O termo de momento pode também ter o benefício de evitar que o processo de aprendizagem termine em um mínimo local. O termo $\frac{\partial E(n)}{\partial w_{ji}^k}$ é calculado da mesma forma que no modo seqüencial.

No reajuste seqüencial uma época de treinamento é composta por apenas um padrão, já que o reajuste é feito a cada padrão, enquanto que no reajuste por lote uma época é formada pelo conjunto de padrões de um lote. O modo seqüencial de treinamento é preferível por requerer menor armazenamento local para cada conexão sináptica, também por ser mais fácil de implementar. Além disso, visto que os parâmetros são apresentados à rede de forma aleatória, o treinamento tem natureza estocástica. Desta forma é menos provável que o algoritmo fique preso em um mínimo local. Devido à natureza estocástica, é mais difícil estabelecer as condições teóricas para convergência. O uso do

treinamento por lote fornece uma estimativa precisa do vetor de gradiente, garantindo uma convergência mais simples para um mínimo local.

A escolha dos padrões a serem apresentados à rede durante a etapa de treinamento é de extrema importância. Eles devem ser representativos, de forma que seu conteúdo seja o maior possível para a tarefa considerada. Nas tarefas de classificações de padrões, é comum tornar aleatória a ordem em que os padrões são apresentados à rede de uma época para a seguinte. Idealmente, a aleatoriedade garante que os padrões sucessivos apresentados, raramente pertençam à mesma classe e sim que eles sejam radicalmente diferentes.

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

O treinamento de uma RNA pode ser encarado como um problema de otimização, em que se deseja minimizar o erro referente aos pesos sinápticos. Os métodos mais utilizados são os de gradiente conjugado e quasi-Newton. Também pode ser aplicada a teoria dos mínimos quadrados. Hagan & Menhaj [1994] sugeriram a adoção do método de Levenberg-Marquardt, que é mais sofisticado em relação aos que utilizam gradiente descendente ou conjugado;

porém requer maior esforço computacional. Seja w o vetor de pesos correspondente a cada camada da rede. De acordo com o método de Newton, a correção para cada camada é dada por [Hagan & Menhaj, 1994]:

$$\Delta w = -\left[\nabla^2 E_{med}(w)\right]^{-1} \nabla E_{med}(w) \quad (2.17)$$

em que $\nabla^2 E_{med}(w)$ é a matriz Hessiana, e $\nabla E_{med}(w)$ o gradiente. Como $E_{med}(w)$, de acordo com (2.6), é escrita como uma função quadrática tem-se:

$$\nabla E_{med}(w) = J^T(w)e(w) \quad (2.18)$$

$$\nabla^2 E_{med}(w) = J^T(w)J(w) + S(w) \quad (2.19)$$

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

$$J(w) = \begin{bmatrix} \frac{\partial e_1(w)}{\partial w_1} & \frac{\partial e_1(w)}{\partial w_2} & \dots & \frac{\partial e_1(w)}{\partial w_n} \\ \frac{\partial e_2(w)}{\partial w_1} & \frac{\partial e_2(w)}{\partial w_2} & \dots & \frac{\partial e_2(w)}{\partial w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(w)}{\partial w_1} & \frac{\partial e_N(w)}{\partial w_2} & \dots & \frac{\partial e_N(w)}{\partial w_n} \end{bmatrix} \quad (2.20)$$

$$S(w) = \sum_{i=1}^N e_i(w) \nabla^2 e_i(w) \quad (2.21)$$

Para o método de Gauss-Newton é feita a aproximação $S(w) \approx 0$, escrevendo-se:

$$\Delta w = -\left[J^T(w)J(w)\right]^{-1} J^T(w)e(w) \quad (2.22)$$

A modificação do método de Levenberg-Marquardt em relação ao de Gauss-Newton é a seguinte:

$$\Delta w = -\left[J^T(w)J(w) + \mu I\right]^{-1} J^T(w)e(w) \quad (2.23)$$

em que o parâmetro μ é multiplicado por um fator β quando o incremento é positivo. Caso contrário é dividido pelo mesmo fator. Na literatura, os valores utilizados foram: $\mu = 0,01$ (inicialmente), e $\beta = 10$. Nota-se que quando μ é muito alto, o algoritmo comporta-se como gradiente descendente, e quando μ é pequeno como Gauss-Newton. O treinamento com o algoritmo de Levenberg-Marquardt apresenta maior eficiência em relação aos demais, principalmente para redes com pesos da ordem de centenas.

Outros algoritmos de treinamento têm sido propostos, na tentativa de se obter uma atualização apropriada dos pesos da rede. O que torna muitas estratégias de treinamento, algumas vezes não eficazes, é que a atualização Δw_{ji} dos pesos não depende apenas do valor adaptado do coeficiente de aprendizagem, mas também do valor da derivada parcial. Assim, o efeito de uma adaptação do coeficiente de aprendizagem pode ser drasticamente distorcido pela variação do comportamento da derivada.

Na tentativa de solucionar esse problema, Riedmiller & Braun [1993] propuseram um algoritmo de treinamento chamado de Rprop, *resilient Propagation*, que é derivado do algoritmo tradicional de retropropagação. A diferença entre eles é que, no Rprop, a atualização dos pesos é feita fazendo-se uso apenas do sinal da derivada parcial da função de erro, e não de seu valor. O valor da atualização dos pesos é calculado pela avaliação do sinal da derivada parcial de uma iteração para outra, o que melhora o processo de aprendizagem e faz com que a convergência torne-se mais rápida [Souza et al, 2004].

2.2 Faltas em Sistemas Elétricos de Potência

As faltas em sistemas de potência podem ser basicamente de dois tipos: simétricas, quando todas as fases estão envolvidas; e assimétricas que ocorrem entre fases, entre fase e terra ou podem ser entre duas fases e a terra. Em uma situação de falta, o caminho da corrente de fase a fase ou de fase a terra pode ou não ter impedância significativa. De acordo com os dados da CHESF para os anos de 2003 e 2004, cerca de 70% das faltas nas linhas de transmissão ocorrem entre apenas uma fase e a terra. Um número menor, em torno de 5%, refere-se às faltas que envolvem todas as três fases. Na Tabela 2.1 os dados estão em maiores detalhes.

Tabela 2.1 - Faltas ocorridas no sistema CHESF nos anos de 2003 e 2004.

Tipo da Falta	Ocorrências	Ocorrências (%)
Fase-Terra	2260	67,71
Fase-Fase	660	19,77
Fase-Fase-Terra	177	5,30
Trifásica	241	7,22
TOTAL	3338	100,00

Com exceção das faltas trifásicas, todas as outras apresentam uma condição de desequilíbrio no sistema trifásico. No caso dos defeitos trifásicos simétricos, todas as fases são solicitadas de modo idêntico e conduzem ao mesmo valor eficaz de corrente de curto-circuito. Conseqüentemente, como em qualquer caso de carga simétrica, o cálculo precisa ser feito apenas para um condutor. Ao contrário, em todos os demais casos de curto-circuito, originam-se

cargas assimétricas, havendo a necessidade de se efetuar cálculos que levem em conta as assimetrias. Um modo clássico de se fazer isso é empregar o método das componentes simétricas [Silva, 2002]. Esta técnica decompõe o sistema desbalanceado em três outros sistemas balanceados, chamados de circuitos de seqüências positiva, negativa e zero, para tanto sendo necessário a aplicação do Teorema de Thévenin ao sistema de potência, a fim de substituí-lo por um único gerador e uma impedância série.

Para a seqüência positiva os fasores possuem mesma amplitude, estão defasados de 120° ; e na seqüência ABC. Para a seqüência negativa os fasores também possuem mesma amplitude, e estão defasados de 120° , mas possuem a seqüência CBA. Para a seqüência zero os fasores possuem mesma amplitude e estão em fase. Vale salientar que a componente positiva é referente a componente da fonte do sistema. Nas Figuras 2.2 e 2.3 são apresentados o sistema trifásico a ser representado em componentes simétricas, e as respectivas componentes.




Figura 2.2 - Sistema Trifásico a ser representado em componentes simétricas.




Figura 2.3 - Componentes de seqüência zero, positiva e negativa do sistema da Figura 2.2.

Da Figura 2.3 se têm as seguintes relações entre as tensões e correntes de seqüência:

$$V_0 = -Z_0 I_0 \quad (2.24)$$

$$V_1 = V - Z_1 I_1 \quad (2.25)$$

$$V_2 = -Z_2 I_2 \quad (2.26)$$

Sendo \dot{S}_a , \dot{S}_b e \dot{S}_c as grandezas de fase (tensões ou correntes), e \dot{S}_0 , \dot{S}_1 e \dot{S}_2 as de seqüência zero, positiva e negativa respectivamente; a equação matricial que relaciona cada conjunto de grandezas é dada a seguir:

$$\begin{bmatrix} \dot{S}_a \\ \dot{S}_b \\ \dot{S}_c \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 \\ 1 & \alpha^2 & \alpha \\ 1 & \alpha & \alpha^2 \end{bmatrix} \begin{bmatrix} \dot{S}_0 \\ \dot{S}_1 \\ \dot{S}_2 \end{bmatrix} \quad (2.27)$$

em que: $\alpha = 1 \angle 120^\circ$. A transformação inversa é calculada da seguinte forma:

$$\begin{bmatrix} \dot{S}_0 \\ \dot{S}_1 \\ \dot{S}_2 \end{bmatrix} = \frac{1}{3} \begin{bmatrix} 1 & 1 & 1 \\ 1 & \alpha & \alpha^2 \\ 1 & \alpha^2 & \alpha \end{bmatrix} \begin{bmatrix} \dot{S}_a \\ \dot{S}_b \\ \dot{S}_c \end{bmatrix} \quad (2.28)$$

Na Tabela 2.2 é apresentado um resumo dos valores das tensões e correntes de fase em regime permanente, e na Tabela 2.3 as grandezas de

seqüência para cada tipo de falta existente, considerando-se a impedância de falta nula.

Tabela 2.2a - Resumo das tensões de fase para as condições de falta.

Falta	V_a	V_b	V_c
AT	0	$\frac{[(a^2 - 1)Z_0 + (a^2 - a)Z_2]V}{Z_0 + Z_1 + Z_2}$	$\frac{[(a - 1)Z_0 + (a - a^2)Z_2]V}{Z_0 + Z_1 + Z_2}$
AB	$\frac{2Z_2V}{Z_1 + Z_2}$	$\frac{2Z_2V}{Z_1 + Z_2}$	$\frac{2Z_2V}{Z_1 + Z_2}$
ABT	0	0	$\frac{3Z_0Z_2V}{Z_1Z_2 + Z_0Z_2 + Z_0Z_1}$
ABC	0	0	0

Tabela 2.2b - Resumo das correntes de fase para as condições de falta.

Falta	I_a	I_b	I_c
AT	$\frac{3V}{Z_0 + Z_1 + Z_2}$	0	0
AB	$\frac{-j\sqrt{3}V}{Z_1 + Z_2}$	$\frac{j\sqrt{3}V}{Z_1 + Z_2}$	0
ABT	$\frac{-j\sqrt{3}V(Z_0 - aZ_2)}{Z_1Z_2 + Z_0Z_2 + Z_0Z_1}$	$\frac{j\sqrt{3}V(Z_0 - a^2Z_2)}{Z_1Z_2 + Z_0Z_2 + Z_0Z_1}$	0
ABC	$\frac{V}{Z_1}$	$\frac{a^2V}{Z_1}$	$\frac{aV}{Z_1}$

Tabela 2.3a - Resumo das tensões de seqüência para as condições de falta.

Falta	V_0	V_1	V_2
Fase-Terra	$\frac{-Z_0V}{Z_0+Z_1+Z_2}$	$\frac{(Z_0+Z_2)V}{Z_0+Z_1+Z_2}$	$\frac{-Z_2V}{Z_0+Z_1+Z_2}$
Fase-Fase	0	$\frac{Z_2V}{Z_1+Z_2}$	$\frac{Z_2V}{Z_1+Z_2}$
Fase-Fase-Terra	$\frac{Z_0Z_2V}{Z_1Z_2+Z_0Z_2+Z_0Z_1}$	$\frac{Z_0Z_2V}{Z_1Z_2+Z_0Z_2+Z_0Z_1}$	$\frac{Z_0Z_2V}{Z_1Z_2+Z_0Z_2+Z_0Z_1}$
Trifásica	0	0	0

Tabela 2.3b - Resumo das tensões de seqüência para as condições de falta.

Falta	I_0	I_1	I_2
Fase-Terra	$\frac{V}{Z_0+Z_1+Z_2}$	$\frac{V}{Z_0+Z_1+Z_2}$	$\frac{V}{Z_0+Z_1+Z_2}$
Fase-Fase	0	$\frac{V}{Z_1+Z_2}$	$\frac{-V}{Z_1+Z_2}$
Fase-Fase-Terra	$\frac{-Z_2V}{Z_1Z_2+Z_0Z_2+Z_0Z_1}$	$\frac{(Z_0+Z_2)V}{Z_1Z_2+Z_0Z_2+Z_0Z_1}$	$\frac{-Z_0V}{Z_1Z_2+Z_0Z_2+Z_0Z_1}$
Trifásica	0	$\frac{V}{Z_1}$	0

Em que:

AT - Falta da fase A para a terra.

AB - Falta entre as fases A e B.

ABT - Falta entre as fases A e B e a terra.

ABC - Falta entre as fases A, B e C.

V_a, V_b e V_c - Tensões nas fases A, B e C.

I_a, I_b e I_c - Correntes nas fases A, B e C.

V_0, V_1 e V_2 - Tensões de seqüência zero, positiva e negativa.

I_0, I_1 e I_2 - Correntes de seqüência zero, positiva e negativa.

Vale salientar que para a Tabela 2.2 as grandezas são as mesmas para cada tipo de falta (por exemplo, para falta BT os valores de V_a , V_b e V_c serão os mostrados na Tabela 2.2a trocando-se V_a por V_b , V_b por V_c e V_c por V_a). As faltas trifásicas para terra proporcionam as mesmas grandezas que as faltas trifásicas sem conexão para a terra.

Para análise de faltas em sistemas elétricos, destaca-se também a capacidade de operadores experientes de identificar o tipo de defeito analisando o registro oscilográfico, proveniente de registradores digitais de perturbação (RDPs). Alternativamente, a aplicação de técnicas de inteligência artificial, em particular RNAs, ao problema se traduz em emular o raciocínio do especialista, através de algoritmos computacionais mais velozes, robustos e precisos em comparação aos métodos convencionais [Souza et al, 2004].

3

Revisão Bibliográfica

Muitos algoritmos de localização de faltas foram propostos visando localizar as faltas de modo preciso e eficiente. Alguns utilizam dados pré e pós-falta, outros apenas pós-falta. Esses dados podem ser adquiridos de um ou de ambos terminais da linha de transmissão avaliada. Há a opção de se utilizar tensões e correntes, ou apenas um ou outro desses sinais. Além dos algoritmos tradicionais, existem outros que utilizam RNAs. Neste capítulo é apresentada uma revisão dos métodos.

3.1 Algoritmos baseados em dados de um terminal

3.1.1 Método de Eriksson

Eriksson et al [1985] sugeriram um algoritmo que utiliza dados relativos a apenas um terminal da linha de transmissão. Hipóteses simplificadoras para equacionar o problema da determinação da distância da falta foram efetuadas para dispensar os dados do terminal remoto. O cálculo da distância da falta é feito recorrendo a um sistema equivalente em regime permanente, mostrado a seguir na Figura 3.1.

Em que:

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

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

I_{idA}, I_{idB} - Corrente pré-falta nos terminais A e B.

I_{fA}, I_{fB} - Corrente de falta nos terminais A e B. $I_f = I_i - I_{id}$.


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

R_f - Resistência de falta.


p - Fração do comprimento total da linha (distância normalizada).

Z_L - Impedância de surto da linha de transmissão.


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



(a)



(b)



(c)

Figura 3.1 - Sistema equivalente para análise de faltas pro método de Eriksson. (a) Circuito pré-falta. (b) Circuito de falta. (c) Circuito pós-falta (Superposição de (a) e (b)).

As grandezas pós-falta são a superposição das grandezas pré-falta com as grandezas apenas de falta. A expressão para a tensão no terminal local, com a linha de transmissão submetida a uma falta trifásica é a soma da queda de

tensão na linha entre o terminal A e o ponto de falta com a tensão no ponto de falta:

$$V_A = I_A \cdot p \cdot Z_L + I_f \cdot R_f \quad (3.1)$$

O valor de p é encontrado através da relação [Eriksson et al, 1985]:

$$p^2 - p \cdot K_1 + K_2 - K_3 \cdot R_f = 0 \quad (3.2)$$

Em que:

$$K_1 = 1 + \frac{Z_{SB}}{Z_L} + \frac{V_A}{I_A \cdot Z_L} \quad K_2 = \frac{V_A}{I_A \cdot Z_L} \cdot \left(1 + \frac{Z_{SB}}{Z_L}\right) \quad K_3 = \frac{I_{fA}}{I_A \cdot Z_L} \cdot \left(1 + \frac{(Z_{SB} + Z_{SA})}{Z_L}\right)$$

e $I_{fA} = I_A \cdot D_A$; sendo D_A o fator de distribuição para o sistema analisado.

$$D_A = \frac{(1-p)Z_L + Z_{SH}}{Z_{SA} + Z_L + Z_{SB}} \quad (3.3)$$

Os cálculos da distância e da resistência de falta são realizados resolvendo-se as equações (3.1) e (3.2). As tensões e correntes são obtidas dos registradores, as impedâncias Z_{SA} e Z_{SB} são determinadas por técnicas de determinação de equivalentes, e a impedância da linha é um parâmetro conhecido. Como fontes de erro para o algoritmo de Eriksson podem ser citadas a omissão do efeito das admitâncias *shunt* nas linhas de transmissão, possíveis imprecisões na determinação dos equivalentes, assim como ruídos superpostos na medição das tensões e correntes.

3.1.2 Método de Takagi

Takagi et al [1981, 1982] desenvolveram outro algoritmo para localização de faltas utilizando apenas dados de um terminal da linha. Para os cálculos necessários, representou-se a linha de transmissão como uma linha longa.

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

$$V_f = V_A \cosh(\gamma d) - Z_C I_A \sinh(\gamma d) \quad (3.4)$$

$$I_{fA} = \frac{V_{fA}}{Z_C} \sinh(\gamma d) - I_A \cosh(\gamma d) \quad (3.5)$$

Em que:

γ - Constante de propagação da linha.

Z_C - Impedância característica da linha de transmissão.

Uma alternativa simples para resolução é fazer as seguintes considerações: $\tanh(\gamma d) = \gamma d$ e $\angle I_{fA} = \angle I_A$. As aproximações são válidas para linhas curtas, cuja extensão não exceda 100 km. Sendo: $Z_L = \gamma Z_C$, a distância de ocorrência da falta d pode ser encontrada pela seguinte expressão:

$$d = \frac{\text{Im}(V_A I_{fA}^*)}{\text{Im}(Z_L I_A I_{fA}^*)} \quad (3.6)$$

A expressão (3.6) é uma aproximação eficiente para linhas curtas. Quando o comprimento da linha de transmissão ultrapassa os 100 km, é necessária uma correção na distância de falta, dada por:

$$d_2 = d_1 - \frac{\beta^2 d_1^3}{3} \quad (3.7)$$

Em que:

d_1 - Distância calculada por (3.6).

d_2 - Distância corrigida.

β - $\text{Im}(\gamma)$.

Uma forma mais precisa de se utilizar o algoritmo de Takagi para localizar a falta é baseada nas equações a seguir, que tomam como referência a Figura 3.1, e foi avaliada por Pereira & Zanetta [2000]:

$$V_f = R_f I_f \quad (3.8)$$

$$I_f = -(I_{1fA} + I_{1fB}) \quad (3.9)$$

$$K(d) = \frac{I_{1fB}}{I_{1fA}} \quad (3.10)$$

Aplicando-se (3.10) em (3.9) chega-se a:

$$I_f = -I_{1fA} - K(d)I_{1fA} \quad (3.11)$$

$$V_f = -R_f I_{1fA} (1 + K(d)) \quad (3.12)$$

Usando-se (3.4) e (3.5) em (3.12) tem-se que:

$$V_A \cosh(\gamma d) - Z_C I_A \sinh(\gamma d) = -R_f \left(\frac{V_{fA}}{Z_C} \sinh(\gamma d) - I_{fA} \cosh(\gamma d) \right) (1 + K(d)) \Rightarrow$$

$$\frac{V_A \cosh(\gamma d) - Z_C I_A \sinh(\gamma d)}{\frac{V_{fA}}{Z_C} \sinh(\gamma d) - I_{fA} \cosh(\gamma d)} = -R_f (1 + K(d)) \quad (3.13)$$

Considerando que para a expressão (3.13) as hipóteses de que a impedância de falta é puramente resistiva e linear, e a relação $K(d)$ é um número real; sua parte imaginária será nula. Desta forma tem-se que:

$$\text{Im} \left(\frac{V_A \cosh(\gamma d) - Z_C I_A \sinh(\gamma d)}{\frac{V_{fA}}{Z_C} \sinh(\gamma d) - I_{fA} \cosh(\gamma d)} \right) = 0 \quad (3.14)$$

A expressão (3.14) é aplicada apenas em casos de falta trifásica, e pode ser resolvida através de um método iterativo, como o de Newton-Raphson, para

obtenção da distância de falta d . Para os outros tipos de falta, são utilizados os diagramas de seqüência para dedução das equações que expressam a distância de falta. Na Tabela 3.1 são mostradas essas expressões. Há de se ressaltar que as variáveis com índice 0, 1 e 2 referem-se às componentes de seqüência zero, positiva e negativa respectivamente.

Tabela 3.1 - Expressões da distância de falta para os casos fase-terra, fase-fase e fase-fase-terra.

Tipo de Falta	Expressão
Fase-Terra	$\operatorname{Im} \left(\frac{V_f^0 + V_f^1 + V_f^2}{\frac{V_{fA}^1}{Z_C} \sinh(\gamma d) - I_{fA}^1 \cosh(\gamma d)} \right) = 0$ $V_f^0 + V_f^1 + V_f^2 = 3R_f I_f^1$
Fase-Fase	$\operatorname{Im} \left(\frac{V_f^1 - V_f^2}{\frac{V_{fA}^1}{Z_C} \sinh(\gamma d) - I_{fA}^1 \cosh(\gamma d)} \right) = 0$ $V_f^1 - V_f^2 = R_f I_f^1$
Fase-Fase-Terra	$\operatorname{Im} \left(\frac{V_f^1 - V_f^0}{\frac{V_{fA}^0}{Z_C} \sinh(\gamma d) - I_{fA}^0 \cosh(\gamma d)} \right) = 0$ $V_f^1 - V_f^0 = -3R_f I_f^0$

De acordo com a equação (3.14) e a Tabela 3.1, nota-se a necessidade do armazenamento adequado das tensões e correntes pré-falta, assim como a classificação da mesma; visto que para o cálculo apurado cada tipo de falta é modelado de maneira diferente. Segundo Barreto [2003], Pereira & Zanetta [2000] e Takagi et al [1981] o algoritmo é eficiente para faltas a “curtas distâncias”, apresentando deficiências para faltas distantes do terminal local.

3.1.3 Método de Wiszniewski

De acordo com Wiszniewski [1983], as resistências de falta são responsáveis por erros de localização nas linhas curtas. Para faltas fase-fase seus valores são relativamente pequenos, não influenciando na localização. Entretanto, para faltas envolvendo a terra, tornam-se significativos a ponto de afetar a precisão. Para obtenção de melhores resultados, foi sugerida uma correção na reatância aparente medida no terminal remoto, baseada na diferença de fase entre a corrente total de falta e a através da resistência. A reatância corrigida é proporcional à distância de ocorrência da falta.

O método de Wiszniewski adota também como base os circuitos da Figura 3.1, com a modificação de que há uma impedância conectada diretamente entre as barras A e B, e também utiliza dados apenas do terminal local. O equivalente monofásico é adaptável para circuitos trifásicos. Assim como nos métodos propostos por Takagi et al [1981, 1982] e Eriksson et al [1985], é necessária a decomposição em circuito pré-falta e circuito pós-falta. É definido também um fator de distribuição, dependente das impedâncias do equivalente monofásico, sendo, portanto um número complexo. Sua estimação não é trivial, constituindo um empecilho para adoção do algoritmo. O método de Wiszniewski apresenta melhores resultados que o de Takagi para faltas distantes do terminal local.

3.1.4 Outros Algoritmos de Um Terminal

Girgis et al [1992] desenvolveram um método de localização de faltas utilizando dados obtidos por registradores digitais de faltas em apenas um terminal da linha. Sua teoria é baseada no cálculo da impedância aparente, com inclusão das cargas dos *taps* intermediários e das impedâncias em seções diferentes da linha, para aumentar a precisão.

Pereira & Zanetta [2004] desenvolveram um algoritmo que necessita da medição das correntes e tensões pré-falta e apenas tensões pós-falta de um terminal da linha. Em ambos os terminais são utilizados os equivalentes, considerando também a impedância entre eles. Os dados do terminal remoto são calculados utilizando os equivalentes obtidos. É utilizado um tipo de matriz admitância para cada tipo de falta, o que torna o método pouco flexível. Os testes foram efetuados apenas para faltas fase-terra e trifásica numa linha de 320 km e 500 kV, apresentando erros relativos inferiores a 1% da extensão da linha adotada. A vantagem do método é que não é necessária a medição das correntes pós-falta, que poderiam ser fontes de erro devido a saturação dos TCs.

Das et al [2000] desenvolveram um algoritmo utilizando tensões e correntes pré e pós-falta para sistemas radiais de distribuição. A técnica obteve bons resultados para faltas fase-terra. Jamali & Ghezleji [2003] propuseram um algoritmo para localização baseado nas ondas viajantes de alta frequência que são geradas quando as faltas ocorrem. A faixa de frequência das ondas vai de alguns Hz a alguns kHz. Quando uma falta ocorre, as ondas viajantes são transmitidas do ponto de falta aos terminais da linha aproximadamente na

velocidade da luz no espaço livre. Para localização, é medida a diferença de tempo entre dois picos da mesma onda; calculando-se posteriormente a distância. São utilizadas informações de tensão e corrente em um terminal, extraídas dos secundários dos TPs e TCs. Os algoritmos de localização baseados em ondas viajantes tornaram-se viáveis após a consolidação do uso do GPS (Global Positioning Systems - Sistemas de Posicionamento Global), que possibilitou estimar com precisão a diferença de tempo entre a chegada das amostras (ondas viajantes) nos dois terminais.

3.2 Algoritmos baseados em dados de 2 terminais

3.2.1 Método de Zamora

Com a finalidade de melhorar a precisão da localização das faltas, muitos pesquisadores propuseram algoritmos que utilizam informações de dados coletados em ambos os terminais da linha. Essas técnicas geralmente são independentes da impedância de falta e de mudanças na configuração das fontes do sistema de potência. Um algoritmo de localização utilizando dados de ambos os terminais da linha foi proposto por Zamora et al [1996].

O método é independente da impedância de falta, das correntes de falta e pré-falta, do tipo de falta e do sincronismo entre os registradores localizados em cada terminal da linha. A independência se deve à introdução de uma constante K_v , denominada fator de distância, dada por:

$$K_v = \left| \frac{V_A^1}{V_B^1} \right| \quad (3.15)$$

Em que:

V_A^1, V_B^1 - Tensão de falta de seqüência positiva nos lados A e B.

A componente de seqüência positiva é a única que está presente na expressão para determinação da distância para todos os tipos de falta. Isso é previsível, visto que essa componente refere-se á fonte de tensão ou corrente aplicada ao sistema. Tal fato pode ser comprovado com as expressões vistas na Tabela 3.1. Dessa forma, o modelo de linha para o procedimento de localização de falta é desenvolvido considerando-se apenas essa componente para o circuito de falta. Nota-se que a equação (3.15) do fator de distância depende apenas dessa componente também em ambos os terminais da linha, e indiretamente da distância do ponto de falta. Por isso que o método é independente do tipo de falta. Para o cálculo do K_v deve-se considerar o modelo de linha adotado, mostrado na Figura 3.2. Uma diferença entre os modelos do sistema das Figuras 3.1 e 3.2 é a existência de uma impedância adicional no último entre os terminais, decorrente da maneira como foram obtidos os equivalentes.

Aplicando-se o equivalente de Thévenin à linha para a componente de seqüência positiva, como visto na Figura 3.2c, serão obtidas as seguintes equações:

$$Z_{th}^1 = f(Z_{SA}^1, Z_{SB}^1, Z_L^1, Y_L^1, Z_{EQ}^1, p) \quad (3.16)$$


$$V_f^1 = -Z_{th}^1 \cdot I_f^1 \quad (3.17)$$

$$V_A^1 = V_f^1 + p \cdot Z_L^1 \cdot I_A^1 = -Z_{th}^1 \cdot I_f^1 + p \cdot Z_L^1 \cdot I_A^1 \quad (3.18)$$


$$V_B^1 = V_f^1 + (1-p) \cdot Z_L^1 \cdot I_B^1 = -Z_{th}^1 \cdot I_f^1 + p \cdot Z_L^1 \cdot I_B^1 \quad (3.19)$$

Analisando-se as equações (3.16) a (3.19) nota-se que o fator de distância é dependente das impedâncias e admitâncias presentes no modelo da linha (geralmente conhecidas) e da distância em que ocorreu a falta (que é o fator a ser encontrado). Como o fator de distância é o módulo do quociente entre as tensões de falta de seqüência positiva em cada extremidade da linha, se torna independente da diferença de fase entre as tensões nos dois terminais da linha; dispensando a sincronização entre os dois registradores.


Para se localizar a falta é necessária a medição das tensões em ambos os terminais da linha antes e durante a ocorrência da situação; pelo fato das equações (3.15), (3.18) e (3.19) se referirem aos dados dos dois terminais e não ser possível se medir diretamente as grandezas V_A^1 e V_B^1 (as tensões de falta são determinadas pela diferença entre as tensões pós-falta e pré-falta). Dessa forma, aplicando-se componentes simétricos obtém-se o valor numérico do fator de distância. Comparando-se esse valor obtido à função matemática que o define (dependente dos parâmetros da linha), é possível encontrar-se o valor de p . Dentre as vantagens do método podem ser citadas: não é necessária a medição das correntes, a técnica é não-iterativa, dispensa sincronização entre os registradores, e independência do tipo de falta.



(a)



(b)



(c)

Figura 3.2 – Modelo da linha de transmissão para o método de Zamora. (a) Em condição de falta. (b) Circuito de falta de seqüência positiva. (c) Equivalente de Thévenin.

Em que:

Y_L - Admitância *shunt* da linha de transmissão.

Z_{EQ} - Impedância equivalente entre os dois terminais da linha.

3.2.2 Método de Girgis

Girgis et al [1992] desenvolveram também um método de localização de faltas utilizando dados obtidos por registradores digitais de faltas em dois terminais. São utilizados vetores trifásicos de tensão e corrente, gerando um sistema de equações. Foi considerado que a corrente de falta para casos de falta fase-terra, é proporcional a corrente de seqüência zero. As equações básicas que descrevem o método são mostradas a seguir:

$$[V_f] = [V_A] - d[Z_{abc}][I_A] \quad (3.20)$$

$$[V_f] = [V_B] - (l-d)[Z_{abc}][I_B] \quad (3.21)$$

Em que:

l - Extensão da linha de transmissão.

d - Distância de ocorrência da falta.

$[Z_{abc}]$ - Matriz impedância do sistema.

Igualando-se (3.20) e (3.21), e após reorganizar, obtém-se:

$$[V_A] - [V_B] + l[Z_{abc}][I_B] = d[Z_{abc}][I_A + I_B] \quad (3.22)$$

A estimação da distância d é possível utilizando-se o método dos mínimos quadrados em (3.22) da seguinte forma:

$$d = (\overline{F^T F})^{-1} \overline{F^T L} \quad (3.23)$$

$\overline{F^T}$ significa o conjugado da transposta de F .

Em que:

$$L = [V_A] - [V_B] + l[Z_{abc}][I_B] \quad (3.24)$$

$$F = [Z_{abc}][I_A] + [I_B] \quad (3.25)$$

3.2.3 Outros Algoritmos de Dois Terminais

Sachdev & Aggarwal [1985] propuseram uma técnica de localização de faltas não iterativa adequada para estimar localizações de faltas para terra. O método faz uso da impedância aparente local da linha, da corrente de sequência positiva que sensibiliza os relés, e também de dados correspondentes ao terminal remoto. Impedâncias das fontes, fatores de distribuição e correntes pré-falta não foram usados no processo de estimação. A técnica foi testada para dados simulados de faltas fase-terra e fase-fase-terra. Os resultados indicaram que os erros de estimação são menores que 5% do comprimento da linha, exceto para uma porção da linha próxima do seu ponto médio, onde as contribuições das correntes de faltas dos dois terminais da linha são iguais. As medidas realizadas nos dois terminais não necessitam ser sincronizadas.

Outras técnicas sugeriram o uso de dados sincronizados em ambos os terminais da linha empregando o conceito da impedância aparente [Schweitzer, 1982] ou o conceito das ondas viajantes [Ibe & Cory, 1986]. Vale ressaltar que todos os métodos baseados no conceito da impedância aparente assumem a linha idealmente transposta, com impedâncias por unidade de comprimento de sequência zero e positiva constantes na frequência. Para a localização de faltas baseada no conceito das ondas viajantes, foi desenvolvido um modelo matemático avançado da linha de transmissão, recorrendo-se aos transitórios de

alta frequência. O modelo foi usado para a localização de faltas de uma única fase, e aproveitado por Ibe & Cory [1987] para cobrir a localização de faltas no sistema trifásico com o auxílio da análise modal. Gopalakrishnan et al [2000] propuseram um algoritmo de localização considerando o modelo de linha de transmissão com perdas, e resolvendo as equações de linha no domínio do tempo para localizar a falta. É utilizada uma frequência de amostragem dos dados de 20 kHz, e modelo a parâmetros distribuídos apenas para linhas com comprimento superior a 150 milhas. Os passos básicos do algoritmo são: decomposição dos dados no domínio modal, discretização da linha num número finito de pontos, localização aproximada da falta, e localização refinada.

3.3 Outros Métodos de Localização

Kezunovic et al [1999] propuseram o emprego de sistemas inteligentes e técnicas avançadas de processamento de sinais para análise automatizada de distúrbios e operações de proteção. São utilizados os registradores digitais de perturbação, e GPS para sincronizar os dados amostrados nos dois terminais da linha. O funcionamento do sistema apresentou forte dependência com a frequência de amostragem dos dados.

Pereira & Zanetta [2000] fizeram um estudo comparativo de alguns algoritmos de localização. Os modelos considerados mais precisos foram os de dois terminais, considerando o uso de quadripólos, e o modelo da linha a parâmetros distribuídos. No mesmo trabalho foi avaliada a viabilidade de

utilização de um algoritmo para sistemas com três terminais. Esses sistemas possuem problemas adicionais e exigem atenção especial. As maiores dificuldades são causadas por uma alimentação intermediária proveniente de um terceiro terminal alimentador. Para o caso do sistema em questão, mostrado na Figura 3.3, a distância de falta é dada pela seguinte expressão [Pereira & Zanetta, 2000]:

$$d = a \tanh \left(\frac{V_A - V_T \cosh(\gamma_A) + Z_c I_{TP} \sinh(\gamma_A)}{Z_c I_P - V_T \sinh(\gamma_A) + Z_c I_{TP} \sinh(\gamma_A)} \right) \frac{1}{\gamma} \quad (3.26)$$

Em que:

$$I_{TP} = -\frac{V_B \sinh(\gamma_B)}{Z_c} + I_B \cosh(\gamma_B) - \frac{V_C \sinh(\gamma_C)}{Z_c} + I_C \cosh(\gamma_C) \quad (3.27)$$

$$V_T = V_C \cosh(\gamma_C) - Z_c I_C \sinh(\gamma_C) \quad (3.28)$$




Figura 3.3 - Representação unifilar do sistema elétrico de três terminais com falta no trecho PT.

A equação (3.26) fornece a distância da falta no trecho PT. Para o caso da falta ocorrer nos outros trechos a modelagem é análoga, trocando-se apenas as variáveis. Uma forma de se identificar o trecho em que ocorreu a falta é calcular a tensão V_T em função da tensão e corrente em cada um dos três terminais da

linha de transmissão, sendo os trechos sem falta aqueles em que a tensão calculada é a mesma:

$$\begin{aligned}V_T &= V_A \cosh(\gamma_A) - Z_C I_A \sinh(\gamma_A) \\V_T &= V_B \cosh(\gamma_B) - Z_C I_B \sinh(\gamma_B) \\V_T &= V_C \cosh(\gamma_C) - Z_C I_C \sinh(\gamma_C)\end{aligned}\tag{3.29}$$

As formas de onda de tensão e corrente são filtradas usando a técnica TDF (Transformada Discreta de Fourier) para se obter os fasores em regime permanente. A técnica é também virtualmente independente da resistência de falta e amplamente insensível a variações na impedância da fonte e configurações da linha. O método em questão apresentou boa precisão.

Kezunovic & Liao [2001] e Pereira & Zanetta [2003] propuseram algoritmos utilizando programação orientada ao objeto para a localização. O motivo de sua utilização é a flexibilidade. Kezunovic & Liao [2001] utilizaram dados dos RDPs. Para a localização propriamente dita da falta foi utilizado um algoritmo genético. Pereira & Zanetta [2003] combinaram subrotinas escritas em C com a rotina MODELS do ATP para localização de faltas com dados de um e dois terminais.

3.4 RNAs no Diagnóstico de Faltas

O uso das RNAs em Engenharia Elétrica vem se expandindo nos últimos anos. É muito comum encontrar-se trabalhos com aplicações para detecção, classificação e localização de faltas utilizando esta técnica. Oleskovicz et al [2000], Souza et al [2003], Giovanini & Coury [1999] desenvolveram sistemas de classificação. Oleskovicz et al [2000] utilizaram valores amostrados de tensões e

correntes de fase pós-falta para treinamento das redes. Os testes foram efetuados numa linha de 440kV, obtendo um acerto de 99,16%. Souza et al [2003] construíram a base de dados para treinamento das RNAs de forma automatizada, utilizando o ATP. Foi implementado um software construído em C++, que possibilitou drástica redução no tempo de treinamento (o treinamento com o MATLAB® utilizando o método de Levenberg-Marquardt durou 30h, enquanto que para o software construído 2 segundos apenas). Giovanini & Coury [1999] utilizaram apenas as correntes de fase e de seqüência zero, que foram divididas em conjuntos de três amostras, para efetuar a classificação.

Para aplicação de RNAs ao diagnóstico de faltas em linhas de transmissão, é indispensável à elaboração de um banco de dados que apresente as situações de falta do sistema elétrico analisado; para utilização no algoritmo de treinamento. Usualmente é necessária a aquisição das grandezas antes e depois da ocorrência da falta em janelas de dados. Os dados reais são obtidos dos registradores, geralmente com ruídos superpostos, e necessitando de filtragem para obtenção das grandezas verdadeiras. Para geração de uma base de dados sem os inconvenientes citados anteriormente opta-se por plataformas de simulação como o ATP, MICROTRAN, ou EMTDC [Jorge et al, 1999], [Oleskovicz et al, 2003], [Sidhu et al, 1995]. Lembrando-se que para o treinamento é imprescindível utilizar um número coerente de dados, pois o número excessivo de informações torna desnecessário o uso das RNAs, já que numa base de dados muito extensa a localização da falta pode ser feita por um processo de busca ou consulta.

Para implementação das topologias das redes, diversos recursos computacionais podem ser utilizados, como: o software NeuralWorks [Oleskovicz et al, 2003], o toolbox Neural Network do MATLAB® [Lira & Jr., 1999], [Jorge et al, 1999], o software FALNEUR [Mazón et al, 2000].

Oleskovicz et al [2003] implementaram e treinaram 3 redes para localização dos diversos tipos de falta: uma para faltas fase-terra, outra para faltas fase-fase e fase-fase-terra, e a última para faltas trifásicas. Cada rede apresenta 3 saídas, referentes às zonas de proteção primária, secundária e terciária. A zona de proteção primária se estende desde o terminal local até 67,4% da linha utilizada, a zona secundária do terminal local até 83,3% da linha, e por fim, a zona terciária inicia-se no terminal local até 97% da linha utilizada. Nota-se que a zona terciária abrange toda zona secundária, e a zona secundária abrange toda a primária. Os parâmetros utilizados para o treinamento das arquiteturas foram: a distância da falta, a resistência de falta e o ângulo de incidência (que é o ângulo da tensão senoidal correspondente ao instante do início da falta). Na Tabela 3.2 a seguir, pode ser visto um resumo com as principais características das arquiteturas das redes utilizadas; salientando que do conjunto de dados utilizado, 80% foi destinado ao treinamento, e 20% para validação.

Tabela 3.2 – Características das redes propostas por [Oleskovicz et al, 2003].

TIPO DA FALTA	FASE-TERRA	FASE-FASE	FASE-FASE-TERRA	TRIFÁSICA
Conjunto de dados	14700	9225	22575	6100
Localizações corretas (%)	94,65	88,78	95,97	92,84
Arquitetura (camadas)	24-48-44-3	24-42-40-3		24-24-20-3

Os erros médios quadráticos das redes convergiram rapidamente para uma resposta esperada, e se comportaram de forma satisfatória. Parte dos erros apresentados pelas redes devem-se às incertezas das áreas de transição entre as zonas de proteção. As arquiteturas encontradas por Jorge et al [1999] apresentaram erro médio menor que 9%, com a utilização de um banco de dados muito menor para treinamento e validação em relação ao utilizado por Oleskovicz et al [2003]. Para correção de erros típicos nos processos de treinamento e validação, Lira & Jr. [1999] propuseram um sistema híbrido de redes neurais com lógica Fuzzy, tornando o sistema mais confiável. Joorabian [2000] também propôs o uso da lógica Fuzzy, como também treinou redes específicas para localização, de acordo com o tipo de falta. Foi realizada previamente a classificação dos distúrbios. Coury & Jorge [1998] e Souza et al [2001] também utilizaram RNAs para localização de faltas, com os últimos utilizando as redes também para o processamento dos alarmes.

Purushothama et al [2000] desenvolveram dois sistemas baseados em RNAs para localização das faltas e determinação da resistência de falta, um utilizando dados de apenas um terminal, e o outro com dados de dois

terminais. Utilizou-se tensões e correntes pré e pós-falta para treinamento das redes. O sistema com dados de apenas um terminal é composto por 7 redes: uma classificadora e 6 localizadoras (AT, BT, CT, AB/ABT, BC/BCT, CA/CAT). O sistema com dados de dois terminais é composto por 3 redes: a localizadora, e 2 para determinação da resistência de falta (uma para faltas envolvendo a terra, e outra não). O desempenho dos sistemas foi superior aos algoritmos tradicionais.

Mazón et al [2000] utilizaram o método de Levenberg-Marquardt para treinamento das RNAs. Os resultados apresentados foram também satisfatórios, apresentando erros menores que 3% nos casos mais extremos, utilizando dados de dois terminais da linha de transmissão, com um tempo de treinamento de no máximo 2,5 minutos.

4

Método Implementado

No presente capítulo é apresentada a metodologia proposta, bem como todas as variações utilizadas nas simulações, que foram realizadas com dados de um terminal pelo fato de se pretender integrar o método proposto ao software Neuranálise [GSE/DEE/UFCC, 2004], que tem por função detectar e classificar faltas utilizando Redes Neurais Artificiais, e assim aproveitar a mesma base de dados utilizada para as outras funções do software também para localização. Outros fatores, como ângulo de incidência da falta e resistência de falta também

foram avaliados. Dentre as variações da simulação é realizada a localização com uma estrutura encadeada de RNAs em que é feita uma classificação prévia, e uma localização por trecho; a outra variação é a localização por uma única RNA. Para todas as redes utilizadas, os dados de entrada foram as tensões e correntes de fase e de seqüência zero de apenas um terminal da linha de transmissão utilizada. Também será comentada a forma com que foram gerados os dados necessários para o treinamento das RNAs, que constituem a base de dados automatizada.

4.1 Sistema Proposto

Na Figura 4.1 é apresentado o sistema localizador de faltas composto por uma estrutura encadeada de RNAs. O módulo de classificação (composto por uma RNA) é responsável pela etapa de classificação da falta, de acordo com o comportamento das tensões e correntes, em quatro grupos diferentes: fase-terra, fase-fase, fase-fase-terra e fase-fase-fase (trifásica). O módulo seletor de grupo escolhe o grupo de faltas de acordo com a indicação dada pelo módulo de classificação. Cada grupo possui uma estrutura composta por um módulo de identificação de zona, um seletor de zona e de oito módulos de zona. Após a etapa de classificação do grupo de falta, o módulo de identificação de zona determina o trecho da linha onde ocorre a falta. Em seguida, o seletor de zona seleciona o módulo de zona referente àquela que foi identificada. Por fim, a localização da falta é realizada por uma rede treinada especificamente por padrões relativos ao trecho da linha e grupo de falta identificados.

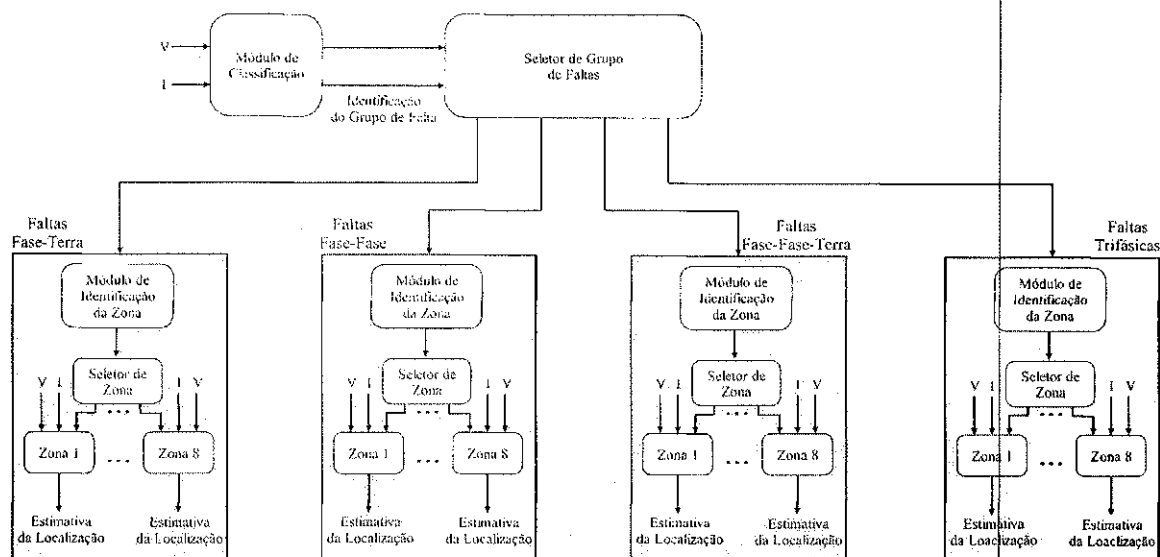


Figura 4.1 –Topologia do sistema localizador de faltas.

O método proposto permite que se tenha duas estimativas para a localização da falta: a primeira realizada de forma mais grosseira, quando se identifica a zona de incidência da falta; e uma mais precisa, que utiliza a estimativa dada pelas RNAs treinadas especificamente, para aquele trecho identificado na estimativa anterior.

A base de dados que compõe o conjunto de padrões para treinamento, validação e teste de todas as RNAs envolvidas foi construída de forma automatizada e será abordada em detalhes nas seções posteriores. A base do *módulo classificador* é composta de dados referentes a todos os tipos de faltas e em várias localizações da linha a ser simulada.

O sistema possui 37 RNAs, sendo uma classificadora, quatro localizadoras de zona e 32 localizadoras finais, já que em cada um dos quatro grupos de faltas existe uma rede para cada uma das oito zonas de localização. Cada uma das redes localizadoras é treinada com tensões e correntes referentes apenas à zona e ao grupo de falta correspondente. Vale salientar que as bases de

dados das redes localizadoras são subconjuntos da base utilizada para a rede classificadora, ou seja, para cada RNA localizadora foram extraídos dados da base de dados completa, que se enquadram no grupo de falta e na zona de localização.

Para verificação da eficiência do método proposto, serão comparados os resultados obtidos de localização com os obtidos a partir da utilização de apenas uma RNA localizadora. Os dados de entrada dessa RNA localizadora também serão as tensões e correntes de fase e de seqüência zero. A verificação dos resultados para essa RNA será feita de duas formas:

- Verificação de todos os padrões constituintes do conjunto de testes da base de dados utilizada ou;
- Analisando-se os padrões relativos a cada arquivo constituinte da base de dados e extraíndo-se a média de localização por arquivo analisado.

4.2 Implementação do Método

4.2.1 Sistema Elétrico Utilizado

Para implementação do método e avaliação de sua eficácia escolheu-se uma linha de transmissão trifásica de 230 kV e 188 km de extensão, que pertence ao subsistema leste da CHESF, entre as cidades de Natal e Campina Grande. O sistema foi modelado e simulado utilizando-se o software ATP (*Alternative Transient Program*), mais precisamente as rotinas LINE CONSTANTS e MODELS, considerando-se os seus parâmetros distribuídos e

constantes na frequência. Na Figura 4.2 é mostrado de forma simplificada o sistema modelado, evidenciando-se a linha 04V4 escolhida para análise; cuja configuração da torre é mostrada na Figura 4.3. A impedância de surto da linha é de 400Ω .

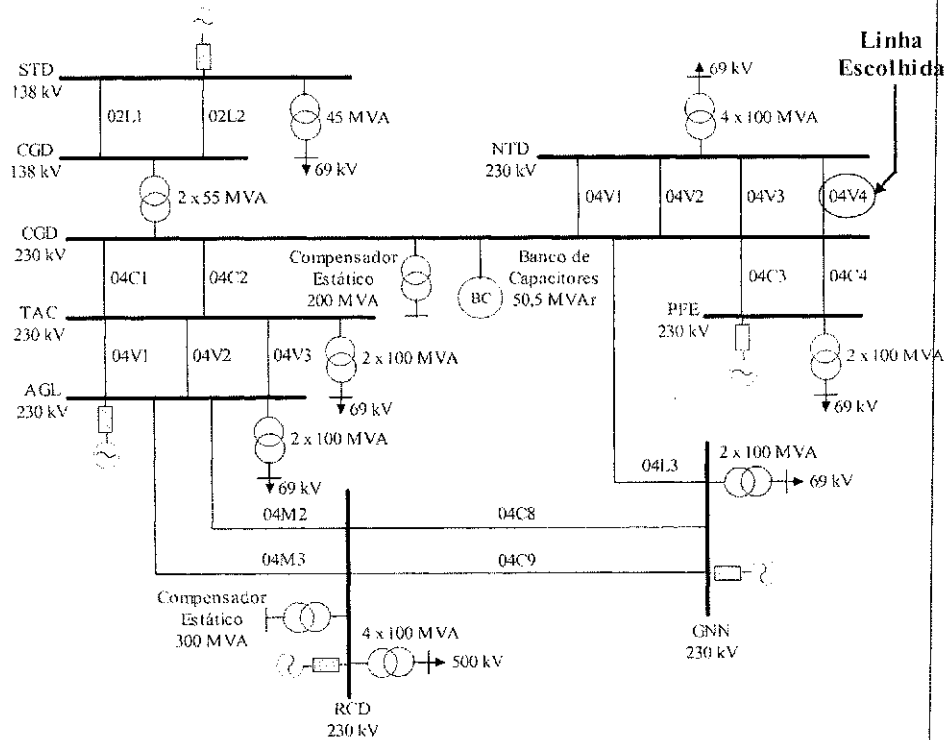


Figura 4.2 - Sistema elétrico utilizado.




Figura 4.3 - Configuração da torre da linha 04V4.

4.2.2 Base de Dados

Para a aplicação das RNAs ao problema de localização de faltas em linhas de transmissão, é indispensável a elaboração de um conjunto de padrões que represente as situações de falta no sistema elétrico analisado, o qual designamos de *base de dados*.

Os padrões da base são subdivididos em três subconjuntos disjuntos denominados de conjuntos de treinamento, validação e teste. Essa divisão previne o sobre-treinamento da rede, situação em que é perdida sua capacidade de generalização, fazendo com que apenas “decore” o conjunto de treinamento apresentado. O conjunto de treinamento é utilizado para escolher o modelo da rede que melhor se adapta. O processo de treinamento é interrompido a cada determinado número de épocas, calculando-se o erro médio quadrático para o conjunto de validação. Se o erro atual for menor que o erro para as iterações anteriores, as alterações na configuração da RNA são armazenadas, seguindo-se este procedimento até se atingir um valor mínimo do erro para a fase de treinamento. O conjunto de teste é utilizado para testar o desempenho da rede na tarefa considerada. Após o aprendizado, a RNA deve ser capaz de localizar corretamente as faltas que foram apresentadas durante as fases de treinamento e validação da rede, e ainda ser capaz de generalizar para os casos pertencentes ao conjunto de teste formado por casos diferentes dos apresentados até então. Nas simulações, após vários testes com inúmeras distribuições dos subconjuntos, utilizou-se 50% da base de dados para o treinamento, 30% para a validação e 20% para o teste, por ter sido a distribuição que proporcionou

melhores resultados.

A base de dados utilizada para treinamento, validação e teste das RNA foi gerada por um processo automatizado [Souza et al, 2003]. O software que possibilitou a construção da base foi o NeuraRede, pertencente ao pacote Neuranálise; desenvolvido em um projeto de P&D da CHESF com a UFCG. O primeiro passo da metodologia aplicada na construção foi a simulação das faltas a partir da condição de pré-falta, até meio ciclo após seu início. Utilizou-se um esquema de faltas deslizantes, considerando 18 localizações de ocorrência, de modo a contemplar várias situações ao longo da linha. Além dos pontos de ocorrência das faltas, foram considerados na simulação diferentes ângulos de incidência e resistências de falta. Na Figura 4.4 é mostrada a interface do software Neuranálise, sendo evidenciadas algumas variáveis que podem ser modificadas, como resistência e tipo de falta.

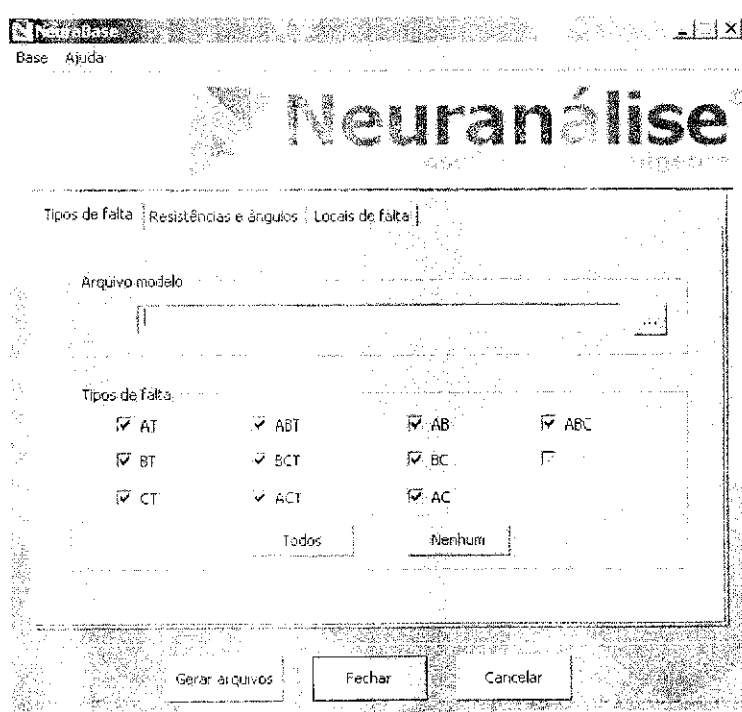


Figura 4.4 - Interface do software Neuranálise.

Para geração da base é necessária apenas a construção de um arquivo modelo no ATP do sistema a ser simulado. As variáveis de saída são as tensões e correntes de fase e de seqüência zero na linha, que numa simulação real serão obtidas a partir de um registrador digital de perturbação (RDP) considerado no terminal de Campina Grande. Fazendo-se uso da rotina \$PARAMETER do ATP foi possível automatizar o processo de geração dos casos a serem simulados, bastando apenas modificar os parâmetros dessa rotina de um caso para outro.

No processo automatizado cada arquivo é nomeado de forma sistemática, de modo a conter em seu nome informações do tipo, da localização e da resistência da falta, além do ângulo de incidência. Um exemplo de arquivo da base automatizada é o seguinte: Fc_01_ab_0.1_90.dat. Todos os dados estão presentes no nome do arquivo:

- Fc - Modelagem com parâmetros constantes na frequência;
- 01 - Primeiro trecho de 10 km em que a linha foi dividida para simulação das ocorrências (o arquivo refere-se então a distância de 10 km);
- ab - Falta entre as fases ab;
- 0.1 - Valor da resistência de falta;
- 90 - Ângulo de incidência da falta.

Para as simulações foram construídas duas bases de dados: uma considerando-se as resistências de falta um curto-circuito, e a outra se aumentando seus valores. Na Tabela 4.1 é apresentado o cenário de faltas simuladas para apresentação ao sistema.

O uso de uma resistência de falta de $0,1\Omega$ caracteriza um curto-circuito. Cada cenário considerado na geração da base de dados possui um arquivo de dados no padrão COMTRADE [Souza et al, 2003]. No entanto, foi necessário adicionar mais duas colunas em cada arquivo, que representam a codificação binária do grupo de falta ao qual cada amostra pertence (Tabela 4.2), e três que representam a codificação binária da zona em que se encontra a falta (Tabela 4.3). A taxa de amostragem adotada do registrador foi de 1200 Hz, resultando em 10 amostras das tensões e correntes nas fases da linha em cada arquivo, considerando-se em cada simulação apenas meio ciclo de falta em 60 Hz.

Tabela 4.1 - Dados das bases de dados utilizada

Variáveis de Simulação		Base de Dados
Locais da falta (km)		10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120,
		130, 140, 150, 160, 170, 180
Tipos de falta		AT - BT - CT
		AB - AC - BC
		ABT - ACT - BCT - ABC
Resistência de falta (Ω)	Base 1	FT: 0,1
		FF: 0,1
	Base 2	FT: 50 - 100
		FF: 5 - 10
Ângulo de incidência ($^\circ$)	Base 1	30, 60, 90
	Base 2	30, 60

FT: Falta envolvendo as fases e a terra;

FF: Falta envolvendo apenas fases.

Tabela 4.2 - Codificação dos Tipos de Falta

Tipo de Falta	Codificação	
	T1	T2
Fase-Terra (AT - BT - CT)	0	0
Fase-Fase (AB - AC - BC)	0	1
Fase-Fase-Terra (ABT - ACT - BCT)	1	0
Trifásica (ABC)	1	1

Tabela 4.3 - Codificação das Zonas de Localização

Zona	L1	L2	L3
1	0	0	0
2	0	0	1
3	0	1	0
4	0	1	1
5	1	0	0
6	1	0	1
7	1	1	0
8	1	1	1

Um método de janelamento dos arquivos de dados simulados foi empregado, para que os dados obtidos das simulações fossem agrupados nos padrões a serem apresentados às RNAs (Figura 4.5). O janelamento consistiu em agrupar n amostras consecutivas das tensões e correntes nas três fases e n amostras das tensões e correntes de seqüência zero em um único vetor de entrada para a rede. As simulações foram efetuadas para um janelamento de 3, 4 e 5 amostras, com o esquema de 4 amostras apresentando melhores resultados. A janela de dados é tida como móvel, já que percorre todo o arquivo, deslocando-se ao passo de uma amostra. Nesse processo, uma janela corresponde a uma situação de falta apenas se todas suas amostras também corresponderem.

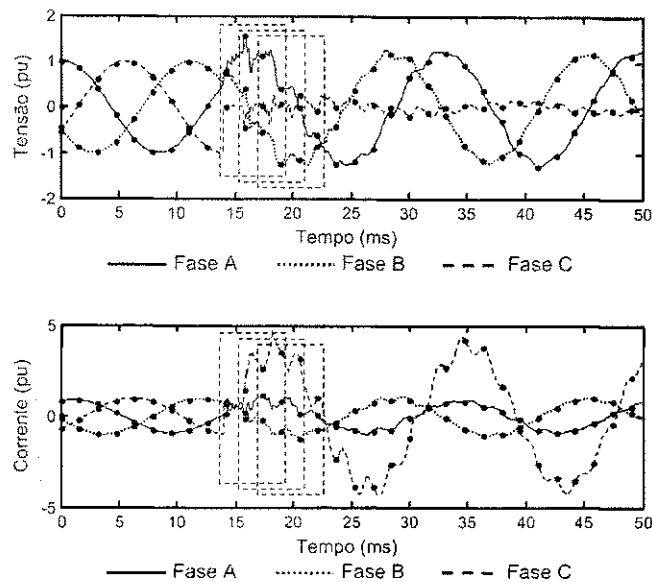


Figura 4.5 - Processo de janelamento dos sinais de tensão e corrente.

O janelamento é aplicado a todos os arquivos gerados na construção das bases de dados. Cada padrão é constituído de um vetor de entrada com 32 elementos e um vetor de saída constituído da indicação do grupo de falta e da localização da falta correspondente ao vetor de entrada. De acordo com o janelamento aplicado, cada arquivo considerado origina sete padrões de entrada. A Base 1 possui 540 arquivos e 3780 padrões, sendo 210 para cada uma das 18 localizações de falta consideradas. A Base 2 possui 720 arquivos e 5040 padrões, sendo 280 para cada localização de falta considerada.

4.2.3 Implementação das RNAs

Para apresentação dos padrões de entrada às RNAs, os valores de tensão e corrente amostrados das bases de dados foram normalizados pelos máximos valores dessas grandezas, acrescidos de 10%, com o intuito de que os mesmos permaneçam no intervalo $[-1, 1]$. O acréscimo de 10% é uma margem de segurança para manter os padrões de entrada da rede no intervalo unitário,

mesmo quando houver alguma sobretensão/sobrecorrente de valor maior que o encontrado nos subconjuntos das bases.

Durante o treinamento, devido à similaridade dos padrões de entrada, pode ocorrer uma tendência no reajuste dos pesos que provoque a perda da capacidade de generalização da rede. Para contornar essa situação, é feita uma mistura aleatória dos padrões na base de dados, proporcionando um treinamento mais eficaz [Silva, 2004].

Para implementação das RNAs, a ferramenta computacional escolhida foi o *Neural Network Toolbox* do MATLAB®. O algoritmo de treinamento escolhido foi o RPROP, *Resilient Propagation*. Para a RNA classificadora são utilizados todos os padrões constituintes da base de dados, para a localizadora de zonas apenas os padrões de cada grupo de falta selecionado pela rede anterior, e para as redes localizadoras finais são utilizados apenas os padrões referentes à zona e ao grupo de falta correspondente. Para definição das arquiteturas realizou-se inúmeras simulações modificando-se o número de neurônios nas camadas de entrada (definido pelo número de amostras em cada janela), e nas camadas ocultas das RNAs. Também foram variados os tamanhos dos subconjuntos de treinamento, teste e validação.

Para a RNA classificadora, os dados de saída são os bits T1 e T2, conforme indicado na Tabela 4.2. A arquitetura 32-52-26-2 (32 neurônios na camada de entrada, 52 na primeira camada oculta, 26 na segunda e 2 na camada de saída) foi a que apresentou melhor desempenho, dentre as topologias avaliadas. Como os dados da RNA em questão são binários, considerou-se

como 0 (zero) qualquer valor abaixo de 0,5; caso contrário considerou-se 1 (um). O mesmo procedimento foi adotado para a RNA seletora de zonas.

Com a falta classificada, a etapa seguinte é selecionar em que zona está localizada dentre as 4 RNAs seletoras. Para essas redes, os dados de saída são os bits L1, L2 e L3, conforme indicado na Tabela 4.3. A seleção da zona é feita analisando-se cada arquivo da base de dados. Treina-se a respectiva rede com os conjuntos de treinamento e validação, e depois se simula para os dados janelados de cada arquivo. Cada arquivo possui sete janelas, e para cada janela de dados será indicada uma zona pela rede. A zona correspondente de cada arquivo será a que a maioria das janelas referentes ao arquivo indicar. A arquitetura que proporcionou melhores resultados foi a 32-50-3. O último passo é a seleção da rede localizadora final, dentre as 32 existentes, que fornecerá o local da ocorrência. Para a localização, é considerada a média das faltas de cada tipo referentes a determinada distância. Por exemplo, para uma falta fase-terra a uma distância de 100 km, são avaliados todos os padrões correspondentes no conjunto de testes e se extrai a média aritmética de todas as localizações. A seleção é feita pelo grupo de falta classificado e pela zona em que se encontra o distúrbio. As distâncias apresentadas às redes são normalizadas em função da extensão de cada zona, de modo que permaneçam no intervalo [0,1]. Para todas as redes implementadas, nas camadas intermediárias a função de ativação escolhida foi a tangente hiperbólica (*tansig*), para limitar a saída dos neurônios ao intervalo [-1,1]; enquanto que para as camadas de saída utilizou-se a função sigmóide (*logsig*), para limitar a saída dos neurônios ao intervalo [0,1].

Para o treinamento do sistema completo optou-se pela adoção de 30.000 épocas para cada RNA. Contudo, não foram necessárias as 30.000 para todas, visto que em alguns casos foi atingido o critério de parada por validação, que é o momento a partir do qual identifica-se que a rede começa a perder a capacidade de generalização dos padrões, passando a memorizar características específicas dos padrões pertencentes ao conjunto de treinamento. Optou-se pela utilização de uma mesma configuração para todas as redes localizadoras, 32 neurônios de entrada, 40 neurônios na camada oculta e apenas 1 neurônio na camada de saída.

O processo de aprendizagem de todas as RNA foi realizado entre 2 e 3 horas para a Base 1, e entre 7,5 e 9 horas para a Base 2. Obteve-se erros médios quadráticos no treinamento praticamente nulos, enquanto que para a validação inferiores a 0,01. Todos as simulações foram realizados em um Athlon PC (1.8 GHz).

Para comparação com o método proposto realizou-se a simulação para a localização com uma única rede. A base de dados utilizada foi a Base 1 para os processos de treinamento e validação. Para o conjunto de testes optou-se por duas alternativas: utilizar parte da base de dados para verificação dos resultados, ou abrir arquivo por arquivo da base e verificar a localização para no fim do processo se extrair a média. A topologia que apresentou melhores resultados dentre as testadas foi a 40-50-1, para um tempo de simulação de aproximadamente 2 horas.

5

Análise dos Resultados

No presente capítulo serão apresentados os resultados obtidos para o sistema proposto com janela de 4 amostras para as duas bases geradas com dados do terminal de Campina Grande, apresentando os erros médios obtidos para cada localização, assim como erros percentuais e outros detalhes. Será feita uma breve síntese sobre a simulação com janela de 3 e 5 amostras, que apresentaram resultados inferiores. Também serão mostrados os resultados obtidos com uma única RNA para a simulação efetuada com o conjunto de teste da base de dados

utilizada, e também com a análise dos padrões constituintes de cada arquivo. Diferentemente do sistema proposto, em que os melhores resultados foram obtidos para uma janela de 4 amostras, a simulação para esse caso específico que proporcionou melhores resultados foi utilizando uma janela de 5 amostras.

5.1 Resultados para o Sistema Proposto

Para a topologia proposta na Figura 4.1, a simulação que proporcionou melhores resultados, foi a que utilizou as janelas com 4 amostras. Para essa situação, os módulos classificador e seletor de zonas obtiveram 100% de acerto.

Na fase de localização, a média aritmética do módulo do erro para cada padrão de falta obtido foi de 1,66 km para a Base 1, equivalente a 0,88% do comprimento da linha utilizada. O erro médio máximo para determinada localização é inferior a 5 km, o que comprova a eficácia do método proposto. Na Tabela 5.1 a seguir, apresenta-se uma síntese dos resultados obtidos para cada janela adotada, evidenciando-se o tempo de simulação e o erro médio em km. Nas Tabelas 5.2 a 5.5 são apresentadas as médias dos resultados obtidos (média de cada tipo de falta no mesmo local) para cada caso testado, com os respectivos erros absolutos médios em km e percentuais em relação ao comprimento da linha. Os erros mínimos obtidos foram praticamente nulos para todas as localizações.

Tabela 5.1 – Síntese das Simulações do Sistema Proposto.

Base	Janela	Erro Médio (km)	Tempo (h)
Base 1	Janela 3	2,04	2,72
	Janela 4	1,66	3,11
	Janela 5	2,10	2,08
Base 2	Janela 3	3,38	4,91
	Janela 4	2,92	9,09
	Janela 5	3,04	1,91

Nota-se pelos resultados expostos que quando se consideram as resistências de falta como um curto-circuito obteve-se melhores localizações. A simulação com uma janela de 4 amostras foi a mais demorada em relação às demais. Isso ocorre porque para a janela com 3 amostras tem-se uma configuração mais simples da rede, com menos neurônios de entrada, facilitando o treinamento. Para a janela de 5 amostras, o banco de dados é menor. É visível também que as simulações para a Base 2 são mais demoradas, pelo fato de conter um cenário maior de faltas, e também maior complexidade, pelo fato das RNAs não serem treinadas com dados referentes a apenas uma resistência de falta. A expectativa de erro nesse caso é maior, pois não há um padrão de resistência de falta, visto que o treinamento foi realizado considerando-se 2 valores para cada tipo de falta. Para a janela com 5 amostras, houve uma parada precoce no treinamento, por erro de validação.

Tabela 5.2 – Resultados para Faltas Fase-Terra da Base 1 com Janela de 4 amostras.

Localização		Erro			
Real (km)	Obtida (km)	Médio Absoluto (km)	Médio Percentual (%)	Máximo Absoluto (km)	Máximo Percentual (%)
10	10,21	0,21	0,11	5,70	3,03
20	19,66	0,34	0,18	2,95	1,57
30	31,09	1,09	0,58	10,40	5,53
40	39,10	0,90	0,48	6,47	3,44
50	50,49	0,49	0,26	5,56	2,96
60	59,07	0,93	0,50	11,21	5,96
70	71,93	1,93	1,03	21,23	11,29
80	78,80	1,20	0,64	7,67	4,08
90	89,08	0,92	0,49	9,74	5,18
100	102,32	2,32	1,23	10,82	5,76
110	108,24	1,76	0,94	12,93	6,88
120	123,08	3,08	1,64	13,74	7,31
130	127,37	2,63	1,40	12,60	6,70
140	141,12	1,12	0,60	5,95	3,16
150	150,25	0,25	0,13	10,72	5,70
160	158,95	1,05	0,56	10,39	5,53
170	171,39	1,39	0,74	7,33	3,90
180	178,64	1,36	0,72	9,36	4,98

Tabela 5.3– Resultados para Faltas Fase-Fase da Base 1 com Janela de 4 amostras.

Localização		Erro			
Real (km)	Obtida (km)	Médio Absoluto (km)	Médio Percentual (%)	Máximo Absoluto (km)	Máximo Percentual (%)
10	11,09	1,09	0,58	10,18	5,41
20	19,34	0,66	0,35	11,70	6,22
30	32,42	2,42	1,29	9,85	5,24
40	38,74	1,26	0,67	7,63	4,06
50	52,09	2,09	1,11	14,44	7,68
60	59,12	0,88	0,47	6,14	3,27
70	71,24	1,24	0,66	15,67	8,34
80	80,13	0,13	0,07	6,85	3,64
90	85,93	4,07	2,16	16,84	8,96
100	101,27	1,23	0,67	10,28	5,47
110	108,25	1,75	0,93	12,12	6,45
120	121,60	1,60	0,85	14,74	7,84
130	125,74	4,26	2,26	13,93	7,41
140	143,40	3,40	1,81	20,74	11,03
150	149,47	0,53	0,28	11,82	6,29
160	156,39	3,61	1,92	21,95	11,68
170	173,40	3,40	1,81	13,16	7,00
180	176,53	3,47	1,85	15,43	8,21

Tabela 5.4 - Resultados para Falhas Fase-Fase-Terra da Base 1 com Janela de 4 amostras.

Localização		Erro			
Real (km)	Obtida (km)	Médio Absoluto (km)	Médio Percentual (%)	Máximo Absoluto (km)	Máximo Percentual (%)
10	10,79	0,79	0,42	6,45	3,43
20	19,62	0,38	0,20	4,81	2,56
30	30,15	0,15	0,08	4,39	2,34
40	39,88	0,12	0,07	1,35	0,72
50	50,54	0,54	0,29	2,68	1,43
60	58,87	1,13	0,60	8,90	4,73
70	72,60	2,60	1,38	20,11	10,70
80	80,43	0,43	0,23	9,70	5,16
90	89,33	0,67	0,36	6,53	3,47
100	101,16	1,16	0,61	13,28	7,06
110	107,92	2,08	1,11	7,19	3,82
120	122,33	2,33	1,24	7,45	3,96
130	129,29	0,71	0,38	10,46	5,56
140	142,37	2,37	1,26	14,36	7,64
150	149,78	0,22	0,12	5,71	3,04
160	158,57	1,43	0,76	20,64	10,98
170	171,85	1,85	0,98	10,16	5,40
180	178,71	1,29	0,69	8,36	4,45

Tabela 5.5- Resultados para Falhas Trifásicas da Base 1 com Janela de 4 amostras.

Localização		Erro			
Real (km)	Obtida (km)	Médio Absoluto (km)	Médio Percentual (%)	Máximo Absoluto (km)	Máximo Percentual (%)
10	10,89	0,89	0,48	6,86	3,65
20	20,06	0,06	0,03	0,51	0,27
30	32,63	2,63	1,40	9,03	4,80
40	38,42	1,58	0,84	5,66	3,01
50	51,59	1,59	0,85	4,95	2,63
60	58,96	1,04	0,55	5,64	3,00
70	71,36	1,36	0,73	8,55	4,55
80	79,16	0,84	0,45	9,74	5,18
90	87,53	2,47	1,31	18,42	9,80
100	100,62	0,62	0,33	3,98	2,12
110	107,40	2,60	1,38	9,93	5,28
120	121,22	1,22	0,65	8,54	4,54
130	129,47	0,53	0,28	5,32	2,83
140	144,24	4,24	2,26	17,48	9,30
150	151,70	1,70	0,90	6,23	3,31
160	158,95	1,05	0,00	6,25	3,32
170	171,39	1,39	2,12	13,24	7,04
180	178,64	1,36	0,32	6,00	3,19

Analisando-se as respostas apresentadas pelo sistema, para os diferentes padrões de entrada do conjunto de teste, constatou-se que o maior índice de erro encontra-se justamente nos padrões referentes às primeiras janelas pós-falta. Isso acontece devido à grande influência do ângulo de incidência considerado, que pode distorcer muito a característica do tipo de falta nas primeiras amostras. Os erros médios absolutos obtidos foram satisfatórios. Vale salientar que para cada localização houve uma localização destoante das demais, geralmente nas primeiras janelas. Isso quer dizer que se a primeira janela for descartada, os resultados terão significativa melhora. Na prática isso é aceitável, pois com uma taxa de amostragem de 1200Hz, se uma falta durar 100ms, teremos 120 amostras, proporcionando 117 janelas. O descarte da primeira não irá alterar o diagnóstico, e sim contribuir para melhor exatidão. À medida que a janela desloca-se pelas amostras pós-falta, o erro de localização diminui gradativamente, já que a influência do ângulo de incidência diminui e as características singulares de cada tipo de falta tornam-se mais evidentes.

Nas Figuras 5.1 a 5.4 a seguir é feita uma comparação entre a utilização das janelas com 3, 4 ou 5 amostras, com os gráficos dos erros médios absolutos para cada tipo de falta em função da distância de falta. Nota-se que para maioria dos casos, os melhores resultados (menores erros) se referiram a opção de 4 amostras.




Figura 5.1 - Comparação entre os Erros Médios Absolutos para Falhas Fase-Terra na Base 1.

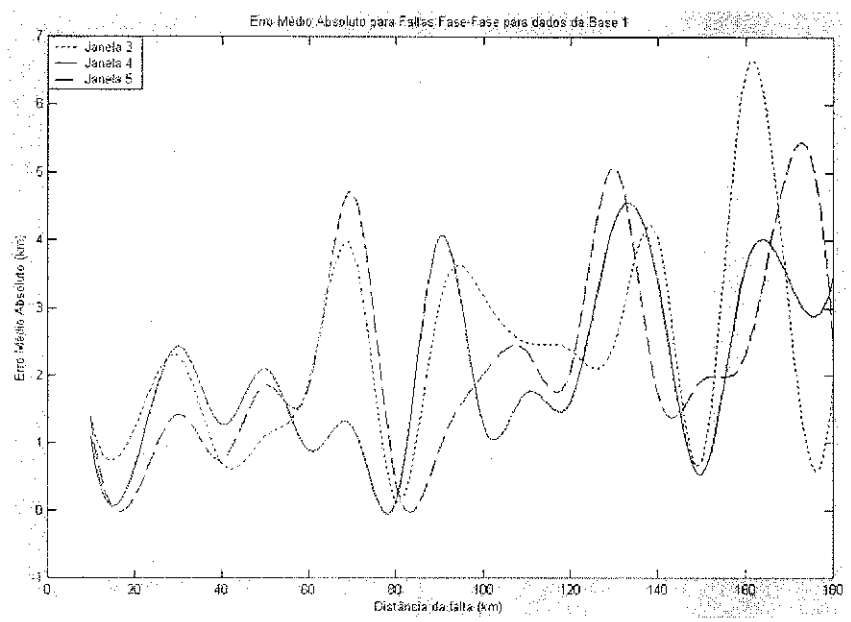


Figura 5.2 - Comparação entre os Erros Médios Absolutos para Falhas Fase-Fase na Base 1.




Figura 5.3 - Comparação dos Erros Médios Absolutos para Falhas Fase-Fase-Terra na Base 1.




Figura 5.4 - Comparação dos Erros Médios Absolutos para Falhas Trifásicas na Base 1.

Nas Tabelas 5.6 a 5.9 a seguir são apresentadas as médias dos resultados obtidos (média de cada tipo de falta no mesmo local) para cada caso testado da Base 2 com janelamento de 4 amostras, com os respectivos erros absolutos médios em km e percentuais em relação ao comprimento da linha. É notável que os resultados são piores que os da Base 1, devido ao fato de se utilizarem 2

valores de resistência para cada tipo de falta na base de dados.

Tabela 5.6 – Resultados para Falhas Fase-Terra da Base 2 com Janela de 4 amostras.

Localização		Erro			
Real (km)	Obtida (km)	Médio Absoluto (km)	Médio Percentual (%)	Máximo Absoluto (km)	Máximo Percentual (%)
10	12,69	2,69	1,43	10,72	5,70
20	16,60	3,40	1,81	19,09	10,16
30	35,49	5,49	2,92	7,59	4,04
40	34,73	5,27	2,80	7,70	4,10
50	54,98	4,98	2,65	16,43	8,74
60	58,11	1,89	1,00	13,10	6,97
70	74,32	4,32	2,30	21,98	11,69
80	79,34	0,66	0,35	11,96	6,36
90	87,87	2,13	1,13	14,12	7,51
100	101,34	1,34	0,71	13,67	7,27
110	106,56	3,44	1,83	12,09	6,43
120	125,24	5,24	2,78	8,24	4,38
130	124,18	5,82	3,10	9,43	5,02
140	144,93	4,93	2,62	20,01	10,64
150	151,36	1,36	0,72	9,47	5,04
160	154,74	5,26	2,80	17,91	9,53
170	171,12	1,12	0,60	7,82	4,16
180	179,55	0,45	0,24	3,47	1,84

Tabela 5.7 – Resultados para Falhas Fase-Fase da Base 2 com Janela de 4 amostras.

Localização		Erro			
Real (km)	Obtida (km)	Médio Absoluto (km)	Médio Percentual (%)	Máximo Absoluto (km)	Máximo Percentual (%)
10	13,51	3,51	1,87	9,52	5,06
20	16,92	3,08	1,64	9,27	4,93
30	32,56	2,56	1,36	9,11	4,85
40	38,37	1,63	0,87	7,41	3,94
50	53,50	3,50	1,86	13,67	7,27
60	57,92	2,08	1,11	11,86	6,31
70	73,69	3,69	1,96	21,27	11,31
80	79,85	0,15	0,08	11,67	6,21
90	87,39	2,61	1,39	19,26	10,25
100	104,31	4,31	2,29	7,32	3,89
110	105,93	4,07	2,16	9,67	5,14
120	125,73	5,73	3,05	11,17	5,94
130	124,65	5,35	2,84	8,78	4,67
140	145,42	5,42	2,88	15,72	8,36
150	150,08	0,08	0,04	9,99	5,31
160	154,12	5,88	3,13	13,72	7,30
170	172,56	2,56	1,36	10,37	5,52
180	177,64	2,36	1,26	13,48	7,17

Tabela 5.8 – Resultados para Faltas Fase-Fase-Terra da Base 2 com Janela de 4 amostras.

Localização		Erro			
Real (km)	Obtida (km)	Médio Absoluto (km)	Médio Percentual (%)	Máximo Absoluto (km)	Máximo Percentual (%)
10	10,57	0,57	0,30	7,08	3,77
20	20,02	0,02	0,01	0,96	0,51
30	30,04	0,04	0,02	4,32	2,30
40	38,02	1,98	1,05	9,61	5,11
50	51,71	1,71	0,91	11,51	6,12
60	58,59	1,41	0,75	10,50	5,59
70	72,36	2,36	1,26	17,01	9,05
80	79,74	0,26	0,14	10,73	5,71
90	89,01	0,99	0,52	12,19	6,48
100	104,22	4,22	2,24	13,98	7,44
110	108,92	1,08	0,58	5,19	2,76
120	123,55	3,55	1,89	12,94	6,88
130	127,92	2,08	1,11	9,55	5,08
140	142,42	2,42	1,29	18,92	10,07
150	148,79	1,21	0,65	9,94	5,29
160	158,36	1,64	0,87	12,86	6,84
170	170,89	0,89	0,47	5,07	2,70
180	177,66	2,34	1,24	7,09	3,77

Tabela 5.9 – Resultados para Faltas Fase-Terra da Base 2 com Janela de 4 amostras.

Localização		Erro			
Real (km)	Obtida (km)	Médio Absoluto (km)	Médio Percentual (%)	Máximo Absoluto (km)	Máximo Percentual (%)
10	9,99	0,01	0,01	5,60	2,98
20	19,53	0,47	0,25	2,69	1,43
30	30,06	0,06	0,03	3,16	1,68
40	39,58	0,42	0,22	4,64	2,47
50	50,37	0,37	0,20	3,25	1,73
60	59,37	0,63	0,34	4,55	2,42
70	74,09	4,09	2,17	20,18	10,73
80	79,94	0,06	0,03	11,72	6,24
90	89,64	0,36	0,19	2,77	1,47
100	101,85	1,85	0,99	9,17	4,88
110	109,67	0,33	0,18	4,57	2,43
120	121,53	1,53	0,81	13,18	7,01
130	130,20	0,20	0,11	4,69	2,50
140	142,96	2,96	1,58	16,05	8,54
150	147,99	2,01	1,07	7,74	4,12
160	159,21	0,79	0,42	6,53	3,48
170	171,70	1,70	0,91	7,07	3,76
180	177,69	2,31	1,23	5,19	2,76

Da mesma forma como foi mostrado para os dados da Base 1, nas Figuras 5.5 a 5.8 são apresentadas comparações dos erros médios absolutos para cada opção de amostras no janelamento. Mais uma vez, a opção com 4 amostras foi mais viável, proporcionando erros menores.




Figura 5.5 - Comparação dos Erros Médios Absolutos para Faltas Fase-Terra na Base 2.

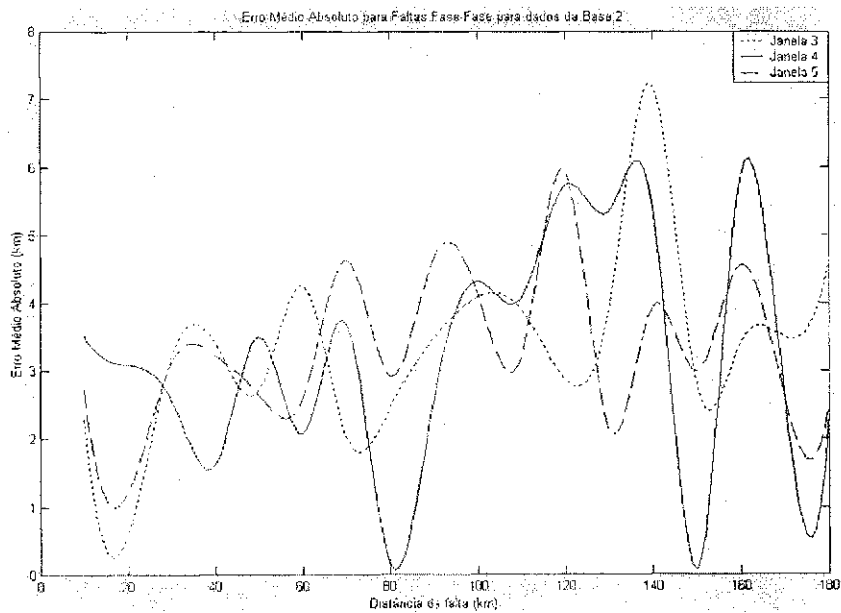


Figura 5.6- Comparação dos Erros Médios Absolutos para Faltas Fase-Fase na Base 2.




Figura 5.7 – Comparação dos Erros Médios Absolutos para Falhas Fase-Fase-Terra na Base 2.




Figura 5.8 – Comparação dos Erros Médios Absolutos para Falhas Trifásicas na Base 2.

5.2 Resultados para a RNA simples

Como citado anteriormente, para a RNA simples utilizada para localização de faltas, foram adotadas duas metodologias: a análise de cada arquivo com a obtenção da localização para cada janela com o posterior cálculo da média; e a

obtenção diretamente do conjunto de testes da base de dados. A base de dados utilizada foi a Base 1, janelada com 5 amostras. Assim como no caso anterior, notou-se principalmente para dados das primeiras amostras localizações destoantes das demais, apresentando erro de até 20 km. O descarte dessas amostras não influi na eficiência da rede, mas vale salientar que todos os dados apresentados não estão incluindo o descarte proposto. O tempo de simulação foi de 2 horas aproximadamente. Na Tabela 5.10 está exposta uma síntese dos resultados obtidos. O erro médio absoluto para a análise dos padrões do conjunto de teste foi de 3,37 km, enquanto que para a análise dos padrões de cada arquivo da base obteve-se um erro médio de 1,78 km.

Tabela 5.10a - Resultados para uma única RNA localizadora - Teste por padrões.

Localização		Erro			
Real (km)	Obtida (km)	Médio Absoluto (km)	Médio Percentual (%)	Máximo Absoluto (km)	Máximo Percentual (%)
10	10,61	0,61	0,32	15,59	8,29
20	20,06	0,06	0,03	9,04	4,81
30	28,67	1,33	0,71	14,87	7,91
40	39,17	0,83	0,44	15,63	8,31
50	48,56	1,44	0,77	15,98	8,50
60	59,32	0,68	0,36	16,06	8,54
70	70,22	0,22	0,12	7,87	4,19
80	79,53	0,47	0,25	8,55	4,55
90	89,55	0,45	0,24	9,66	5,14
100	100,47	0,47	0,25	9,56	5,08
110	112,71	2,71	1,44	14,34	7,63
120	121,96	1,96	1,04	13,03	6,93
130	129,00	1,00	0,53	19,86	10,56
140	141,56	1,56	0,83	9,21	4,90
150	151,06	1,06	0,56	13,32	7,08
160	159,94	0,06	0,03	12,03	6,40
170	166,45	3,55	1,89	14,83	7,89
180	173,56	6,44	3,43	17,23	9,17

Tabela 5.10b - Resultados para uma única RNA localizadora - Teste por arquivos.

Localização		Erro			
Real (km)	Obtida (km)	Médio Absoluto (km)	Médio Percentual (%)	Máximo Absoluto (km)	Máximo Percentual (%)
10	11,44	1,44	0,77	4,35	2,32
20	19,67	0,33	0,18	2,27	1,21
30	29,20	0,80	0,43	1,97	1,05
40	39,27	0,73	0,39	2,45	1,31
50	49,09	0,91	0,48	4,02	2,14
60	59,79	0,21	0,11	2,27	1,21
70	69,76	0,24	0,13	1,72	0,92
80	79,51	0,49	0,26	2,36	1,26
90	89,91	0,09	0,05	2,68	1,43
100	100,20	0,20	0,11	3,13	1,67
110	112,40	2,40	1,28	9,16	4,87
120	121,83	1,83	0,97	8,14	4,33
130	129,34	0,66	0,35	10,27	5,46
140	141,39	1,34	0,71	8,37	4,45
150	151,15	1,15	0,61	4,88	2,60
160	160,05	0,05	0,03	4,82	2,56
170	167,20	2,80	1,49	7,33	3,90
180	173,42	6,58	3,50	10,37	5,51

Comparando-se os resultados, e tempo de simulação nota-se que a arquitetura proposta na Figura 4.1 apresenta melhor desempenho, pois apesar de uma localização com níveis semelhantes de precisão, oferece a classificação do tipo e a localização da zona com 100% de acerto. Os resultados são mais consistentes por apresentarem níveis de erros médios um pouco menores, e também ser mais flexível ao se utilizar uma base de dados maior e mais complexa.

6

Conclusões

No presente trabalho fez-se uma revisão bibliográfica sobre os conceitos de Redes Neurais Artificiais, bem como suas aplicações em Engenharia Elétrica, mais precisamente para os casos de classificação e localização de faltas em Sistemas Elétricos. Foi efetuada a revisão bibliográfica sobre algoritmos tradicionais de localização, buscando identificar as vantagens e desvantagens de sua utilização.

Um sistema localizador de faltas para linhas de transmissão utilizando RNAs foi proposto. Tal sistema é composto por um módulo localizador, um módulo seletor de zonas e o localizador propriamente dito. Sua avaliação se deu na linha 04V4, de 230 kV e 188 km de extensão, pertencente ao subsistema Leste do Sistema CHESF. Para localização, a linha foi dividida em 8 zonas. Os dados de entrada foram as amostras de tensões e correntes de fase e de seqüência zero na barra de Campina Grande. Toda base de dados para treinamento das RNAs foi gerada de maneira automatizada com auxílio do programa Neuranálise. Para implementação da metodologia, alguns parâmetros foram modificados para se avaliar o desempenho das RNAs, como: resistência de falta e ângulo de incidência. O sistema proposto foi comparado com uma RNA localizadora simples.

Para um janelamento com 4 amostras, conseguiu-se obter 100% de acerto na classificação da falta e na localização da zona em que ocorreu. O erro médio absoluto registrado foi de 1,66 km para a Base 1, equivalente a 0,88% da extensão da linha; e de 2,92 km para a Base 2 (1,55% da extensão da linha). Com uma RNA apenas para localização também se conseguiu bons resultados, com níveis de erros (de localização e quadrático no processo de treinamento da rede) e tempos de simulação semelhantes. Entretanto, o sistema proposto se mostrou mais eficiente, por fornecer uma informação mais completa da ocorrência (com a classificação da falta e localização por zona com 100% de acerto).

Para trabalhos futuros são propostos:

1. Aplicar o localizador objeto desta dissertação a bases de dados construídas a partir de sinais reais adquiridos por meio de registradores digitais, e contribuir para aperfeiçoar o localizador para superar eventuais dificuldades nesses casos.
2. Incluir Lógica Fuzzy para auxiliar as RNAs nos casos em que elas tenham dificuldades em dar resultados compatíveis com o esperado.
3. Incorporação da metodologia proposta ao software Neuranálise.
4. Treinar as RNAs constituintes a partir de bases de dados construídas a partir de um tempo maior de falta (1, 2 ou 3 ciclos), como também utilizar uma base expandida, composta por várias resistências de falta e ângulos de incidência; e que mescle dados simulados com reais.
5. Construir cada módulo localizador a partir das grandezas mais significativas para cada tipo de falta.

Referências Bibliográficas

BARRETO, E. O.. *Avaliação de algoritmos para localização de faltas em redes elétricas*.
Dissertação de Mestrado, UFPE, 2003.

CAMINHA, A. C.. *Introdução à proteção dos sistemas elétricos*. Edgard Blücher,
1977.

COURY, D. V.; JORGE, D. C.. *Artificial neural network approach to distance
protection of transmission lines*. IEEE Transaction on Power Delivery, v.13, n.1,
p.102-108, January 1998.

DAS, R.; SACHDEV, M. S.; SIDHU, T. S.. *A fault locator for radial subtransmission
and distribution lines*. IEEE Power Engineering Society Summer Meeting, Seattle,
Washington, USA, July 2000.

ERIKSON, L.; SAHA, M. M.; ROCKEFELLER, G. D.. *An accurate fault locator
with compensation for apparent reactance in the fault resistance resulting from remote-
end infeed*. IEEE Transactions on Power Apparatus and Systems, v.PAS-104, n.2,
p.424-436, February, 1985.

GIOVANINI, R.; COURY, D. V.. *Classificação rápida de faltas em sistemas elétricos
utilizando redes neurais artificiais*. IV Congresso Brasileiro de Redes Neurais,
p.281-286, Julho 1999.

GIRGIS, A. A.; HART, D. V.; PETERSON, W. L.. *A new fault location technique for
two-and three-terminal lines*. IEEE Transactions on Power Delivery, v.7, n.1, p.98-
107, January 1992.

- GOPALAKRISHNAN, A.; KEZUNOVIC, M.; MCKENNA, S. M.; HAMAI, D. M.. *Fault location using the distributed parameter transmission line model*. IEEE Transactions on Power Delivery, v.15, n.4, p.1169-1174, October 2000.
- GSE/DEE/UFMG (GRUPO DE SISTEMAS ELÉTRICOS DA UNIVERSIDADE FEDERAL DE CAMPINA GRANDE), *Neuranálise: Manual do usuário - Versão 1.1*, Campina Grande, Julho de 2004.
- HAGAN, M. T.; MENHAJ, M. B.. *Training feedforward networks with the Marquardt algorithm*. IEEE Transactions on Neural Networks, v.5, n.6, p.989-993, November 1994.
- HAYKIN, S.. *Redes Neurais - Princípios e prática*, 2ª Edição, Bookman, 1999.
- IBE, A. O.; CORY, B. J.. *A travelling wave-based fault locator for two-and three-terminal networks*. IEEE Transactions on Power Systems, v.PWRD-1, n.2, p.283-288, April 1986.
- IBE, A. O.; CORY, B. J.. *Fault location algorithm for multiphase power lines*. IEE Proceedings, v.134, Pt. C, n.1, p.43-50, January 1987.
- JAMALI, S.; GHEZELJEH, A.. *Fault location on transmission line using high frequency travelling waves*. International Conference on Power Systems Transients - IPST 2003.
- JOORABIAN, M.. *Artificial neural network based fault locator for ehv transmission system*. X Mediterranean Electrotechnical Conference, p.1003-1006, 2000.
- JORGE, D. C.; CORY, D. V.; CARVALHO, A. C. P. L. F.. *Localização de faltas em linhas de transmissão de energia elétrica utilizando reconhecimento de padrões*. IV Congresso Brasileiro de Redes Neurais, p.61-66, Julho 1999.

- KEZUNOVIC, M.; RIKALO, I.. *Detect and classify faults using neural nets*. IEEE Computer Applications in Power, p.42-47, October 1996.
- KEZUNOVIC, M.; RIKALO, I.. *Automating the analysis of faults and power quality*. IEEE Computer Applications in Power, p.46-50, January 1999.
- KEZUNOVIC, M.; LIAO, Y.. *Development of a fault locating system using object-oriented programming*. IEEE PES Winter Meeting, p.763-768, January/February 2001.
- LIRA, M. M. da S.; CARVALHO Jr., M. A.. *Sistemas híbridos aplicados à filtragem de sinais de alarme de proteção de uma subestação telecomandada*. IV Congresso Brasileiro de Redes Neurais, p.20-22, Julho 1999.
- MAZÓN, A. J.; ZAMORA, I.; MIÑAMBRES, J. F.; ZORROZUA, M. A.; BARANDIARAN, J. J.; SAGASTABEITIA, K.. *A new approach to fault location in two-terminal transmission lines using artificial neural networks*. Electric Power Systems Research, n.56, p.261-266, 2000.
- OLESKOVICZ, M.; COURRY, D. V.; AGGARWAL, R. K.. *Redes neurais aplicadas à classificação rápida de faltas em sistemas elétricos de potência*. SBA Controle & Automação, v.11, n.3, p.160-168, 2000.
- OLESKOVICZ, M.; COURRY, D. V.; AGGARWAL, R. K.. *O emprego de redes neurais artificiais na detecção, classificação e localização de faltas em linhas de transmissão*. SBA Controle & Automação, v.14, n.2, p.138-150, 2003.
- PEREIRA, C. E. de M.; ZANETTA Jr., L. C.. *Análise comparativa de alguns algoritmos de localização digital de faltas em linhas de transmissão*. SBA Controle & Automação, v.11, n.3, p.135-140, 2000.

PEREIRA, C. E. de M; ZANETTA Jr., L. C.. *Simulation of fault location algorithms in ATP Program using "C" link*. International Conference on Power Systems Transients - IPST 2003.

PEREIRA, C. E. de M; ZANETTA Jr., L. C.. *Fault location in transmission lines using one-terminal postfault voltage data*. IEEE Transactions on Power Delivery, v.19, n.2, p.570-575, April 2004.

PURUSHOTHAMA, G. K.; NARENDRANATH, A. U.; THUKARAM, D.; PARTHASARATHY, K.. *ANN applications in fault locators*. Electrical Power & Energy Systems, n.23, p.491-506, 2001.

RIEDMILLER, M.; BRAUN, H.. *A direct adaptive method for faster backpropagation learning: the rprop algorithm*, Proceedings of the IEEE Int. Conf. on Neural Networks, San Francisco, 1993, pp. 586-591.

SACHDEV, M. S.; AGGARWAL, R.. *Accurate fault location estimates from digital impedance relay measurements*. IEE Conference Publication, n.249, p.193-198, 1985.

SCHWEITZER, E.. *Evaluation and development of transmission line fault locating techniques which use sinusoidal steady-state information*. Ninth Annual Western Relay Conference, Spokane, Washington, Usa, 1982.

SIDHU, T. S.; SINGH, H.; SACHDEV, M. S.. *Design, implementation and testing of an artificial neural network based fault direction discriminator for protecting transmission lines*. IEEE Transactions on Power Delivery, v.10, n.2, p.697-706, April 1995.

SILVA, K. M.. *Aplicação de redes neurais artificiais na análise de ocorrências em sistemas elétricos de potencia*. Trabalho de Conclusão de Curso, UFCG, 2004.

- SILVA, S. S. B.. *Uso de Inteligência Artificial para Análise de Ocorrências em Sistemas de Potência*. Dissertação de Mestrado, UFPE, 2002.
- SOUZA, B. A.; NEVES, W. L. A.; BRITO, N. S. D.; FERNANDES, A. B.; SILVA, S. S. B.; SILVA, K. M.; DANTAS, K. M. C.; FONTES, A. V.; COSTA, F. B.. *Classificação de faltas via redes neurais artificiais*. V Seminário Brasileiro sobre Qualidade da Energia Elétrica, Aracaju, Brasil, 2003.
- SOUZA, B. A.; BRITO, N. S. D.; NEVES, W. L. A.; SILVA, K. M.; LIMA, R. B. V.; SILVA, S. S. B.. "Comparison between Backpropagation and RPROP Algorithms Applied to Fault Classification in Transmission Lines", aceito para o I International Joint Conference on Neural Networks, Budapeste, Hungria, 25-29 Jul. 2004.
- SOUZA, J. C. S.; RODRIGUES, M. A. P.; SCHILLING, M. T.; COUTO FILHO, M. B.. *Fault location in electrical power systems using intelligent systems techniques*. IEEE Transactions on Power Delivery, v.16, n.1, p.59-67, January 2001.
- TAKAGI, T.; YAMAKOSHI, Y.; BABA, J.; UEMURA, K.; SAKAGUCHI, T.. *A new algorithm of an accurate fault location for EHV/UHV transmission lines: Part I - Fourier Transformation method*. IEEE Transactions on Power Apparatus and Systems, v.PAS-100, n.3, p.1316-1322, March 1981.
- TAKAGI, T.; YAMAKOSHI, Y.; YAMAURA, M.; KONDOW, R.; MATSUSHIMA, T.. *Development of a new type fault locator using the one-terminal voltage and current data*. IEEE Transactions on Power Apparatus and Systems, v.PAS-101, n.8, p.2892-2898, August 1982.
- WISZNIEWSKI, A.. *Accurate fault impedance locating algorithm*. IEE Proceedings, v.130, Pt. C, n.6, p.311-315, November 1983.

ZAMORA, I.; MIÑAMBRES, J. F.; MAZÓN, A. J.; ALVAREZ-ISASI, R.;
LAZARO, J.. *Fault location on two-terminal transmission lines based on voltages*. IEE
Proceedings, v.143, n.1, p.1-6, January 1996.

ANEXOS

Implementação de um Localizador de Falhas Utilizando Redes Neurais Artificiais

J. A. C. B. Silva, K. M. Silva, N. S. D. Brito, W. L. A. Neves, *Membro, IEEE*, B. A. Souza, *Membro, IEEE*, S. S. B. Silva, *Membro, IEEE*

Abstract—A fault location algorithm using artificial neural networks (ANN) was implemented. The software ATP was used to build the knowledge base for training, test and validation of the ANN. The inputs to the ANN are phase quantities and zero sequence voltage and current waveform data from the electric system. The fault conditions were simulated for a 230 kV transmission line. Each file needed to build the knowledge base is generated automatically from a standard format file and run in batch mode. For the fault location, the transmission line is divided into 8 zones. Previous to localization, the classification of fault type is carried out by training the ANN with the full line data. For the localization, eight ANN are trained for each fault type, each one with the data of each zone.

Index Terms— Fault Localization, Artificial Neural Networks, Electric Power Systems.

I. INTRODUÇÃO

A OCORRÊNCIA de situações inesperadas num sistema de transmissão podem causar a interrupção no fornecimento de energia elétrica, realizada pelo sistema de proteção visando resguardar os equipamentos envolvidos. A linha de transmissão, devido a suas dimensões físicas, é o componente do sistema de potência mais susceptível a falhas, que geralmente são diagnosticadas tomando-se como base os valores de tensão e corrente no sistema analisado [1].

O desenvolvimento nos últimos anos de novas técnicas de diagnóstico de falhas em linhas de transmissão tem aumentado a expectativa dos engenheiros de sistemas de potência pela localização precisa e imediata. Isso permite uma determinação rápida de sua natureza, o que facilita os reparos e a restauração do sistema elétrico em questão, de tal modo que o restabelecimento da transmissão da energia ocorra o mais rapidamente possível [2].

As técnicas de inteligência artificial têm se tornado uma

solução alternativa para problemas em diversas áreas. Em particular, as redes neurais artificiais (RNA) vêm sendo aplicadas em problemas de classificação, previsão de séries temporais e identificação de sistemas. Essa diversidade de aplicações se deve ao fato de que as RNA possuem alta capacidade de aprendizado e generalização, além de velocidade e robustez no diagnóstico. No caso de localização de falhas em linhas de transmissão, as RNA vêm apresentando bons resultados, o que encoraja os estudos da aplicação dessa metodologia nessa linha de pesquisa [3-4].

Este artigo apresenta a implementação de um localizador de falhas em linhas de transmissão a partir da utilização de uma estrutura encadeada de RNA. Os valores amostrados das tensões e correntes trifásicas e de sequência zero do sistema analisado são utilizados como parâmetros de entrada para o localizador.

No esquema adotado, inicialmente uma RNA realiza a classificação do grupo de falta (Fase-Terra, Fase-Fase, Fase-Fase-Terra ou Trifásica). Em seguida, com a linha dividida uniformemente em 8 trechos, denominados de *zonas de localização*, identifica-se o trecho onde a falta ocorreu. Nesse momento, uma RNA treinada com os padrões referentes àquele trecho e ao grupo de falta identificado, realiza a estimação da localização. Esse esquema vem apresentando bons resultados. A arquitetura de RNA escolhida foi a perceptron multi-camada, mais conhecida como rede MLP, e o recurso computacional utilizado para construção do sistema foi o *Neural Network Toolbox* do MATLAB[®], o que proporcionou versatilidade na implementação do método proposto.

II. RNA APLICADAS NO DIAGNÓSTICO DE FALTAS

O processo de diagnóstico de falhas compreende três etapas: detecção, classificação e localização. Na fase de detecção a falta é detectada se o sistema apresentar características diferentes do regime permanente, principalmente quanto aos níveis de tensão e corrente nas fases. A etapa de classificação é realizada avaliando o comportamento das tensões e correntes no que diz respeito a seus níveis, defasagens e tendências de crescimento e decrescimento, que são distintas para cada tipo de falta. Por fim, o diagnóstico está completo com a localização da falta. Neste caso, leva-se em consideração os níveis das tensões e correntes no sistema, já que esses níveis são dependentes da localização do defeito na linha.

Os autores agradecem a CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior), ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) e a CHESF (Companhia Hidro Elétrica do São Francisco) pelo suporte financeiro para elaboração e execução dos trabalhos.

J. A. C. B. Silva e K. M. Silva estão atualmente no Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande - UFCG; N. S. D. Brito, W. L. A. Neves e B. A. Souza são professores do Departamento de Engenharia Elétrica da UFCG, Av. Aprígio Veloso, 882, Bodocongó, Campina Grande - PB, 58109-970, Brasil. (candido, kms, nubia, waneves, benemar}@dec.ufcg.edu.br).

Sandra S. B. Silva é Engenheira pertencente ao Departamento de Proteção e Automação (DPA) da CHESF, R. Quinze de Março 50, Bongi, Recife - PE, 58761-901, Brasil. (sandra@chesf.gov.br).

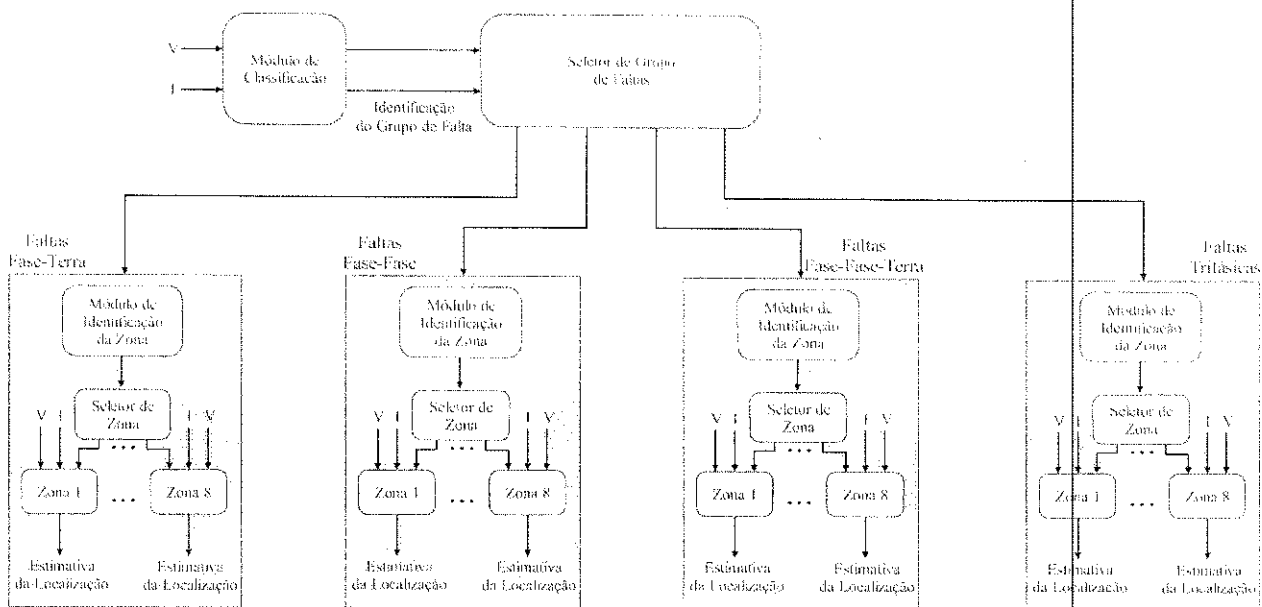


Fig. 1 Topologia do sistema localizador de falhas.

Tradicionalmente, métodos analíticos vêm sendo utilizados para realizar o diagnóstico de falhas, como por exemplo, aqueles que se baseiam nas componentes fasoriais das tensões e correntes para diagnosticar uma dada ocorrência no sistema. No entanto, o desempenho desses métodos é comprometido por alguns fatores como: influência de ruído e não-linearidades nas medições, presença de harmônicos na rede e mudanças nas condições de operação do sistema. Nesse contexto, as técnicas de inteligência artificial, em especial as RNA, vêm sendo largamente utilizadas e estão se mostrando como uma boa alternativa para esta aplicação [3-5].

Como em qualquer aplicação de RNA, é essencial a construção de uma *base de conhecimento* composta de um conjunto de exemplos representativos, do qual é adquirido o conhecimento. Os exemplos são subdivididos em três subconjuntos disjuntos denominados de conjuntos de treinamento, validação e teste [6]. No caso particular da etapa de localização de falhas, é necessário simular as situações de falha no sistema a ser analisado, tendo em vista que não há abundância nem variabilidade nos casos de falhas reais registrados. Em verdade, não há uniformidade na distribuição da quantidade de falhas reais no sistema, já que 70% a 80% das falhas ocorridas são monofásicas, enquanto que as falhas trifásicas ficam em torno de 5% dos casos registrados [7].

Após o aprendizado, a RNA deve ser capaz de localizar corretamente as falhas que foram apresentadas durante as fases de treinamento e validação da rede, e ainda ser capaz de generalizar para os casos pertencentes ao conjunto de teste formado por casos diferentes dos apresentados até então. Dessa forma, terá adquirido a capacidade de generalização e será capaz de localizar falhas que possuam características similares às apresentadas, mas não necessariamente as mesmas.

III. MÉTODO PROPOSTO

Na Fig. 1 apresenta-se o sistema localizador de falhas, composto por uma estrutura encadeada de RNA. A primeira RNA (*módulo de classificação*) é responsável pela etapa de classificação da falha, de acordo com o comportamento das tensões e correntes, em quatro grupos diferentes: fase-terra, fase-fase, fase-fase-terra e fase-fase-fase (trifásica). O *módulo seletor de grupo* escolhe o grupo de falhas de acordo com a indicação dada pelo *módulo de classificação*. Cada grupo possui uma estrutura composta por um *módulo de identificação de zona*, um *seletor de zona* e de oito *módulos de zona*. Após a etapa de classificação do grupo de falha, o *módulo de identificação de zona* identifica a zona de localização da linha onde ocorre a falha. Em seguida, o *seletor de zona* seleciona o *módulo de zona* referente àquela que foi identificada. Por fim, a localização da falha é realizada por uma rede treinada especificamente por padrões relativos a aquele trecho da linha e grupo de falha que foram identificados.

O método proposto permite que se tenha duas estimativas para a localização da falha: a primeira realizada de forma mais grosseira, quando se identifica a zona de incidência da falha; e uma mais precisa, que utiliza a estimativa dada pelas RNA treinadas especificamente, para aquele trecho identificado na estimativa anterior.

A base de conhecimento que compõe o conjunto de exemplos para treinamento, validação e teste de todas as RNA envolvidas foi construída de forma automatizada e será abordada em detalhes nas seções posteriores. A base do *módulo classificador* é composta de dados referentes a todos os tipos de falhas e em várias localizações da linha a ser simulada. Os dados de entrada de todas as RNA são as tensões e correntes trifásicas e de sequência zero.

O esquema como um todo possui 33 RNA, sendo uma classificadora e 32 localizadoras, já que em cada um dos quatro grupos de faltas existe uma rede para cada uma das oito zonas de localização. Cada uma das redes localizadoras é treinada com tensões e correntes referentes apenas à zona e ao grupo de falta correspondente. Vale salientar que as bases de conhecimento das redes localizadoras são subconjuntos da base utilizada para a rede classificadora, ou seja, para cada RNA localizadora foram extraídos dados da base de conhecimento completa, que se enquadram no grupo de falta e na zona de localização.

IV. IMPLEMENTAÇÃO DO MÉTODO

A. Sistema Elétrico Utilizado

Para implementação do método e avaliação de sua eficácia escolheu-se uma linha de transmissão trifásica de 230 kV e 188 km de extensão, que é pertencente ao subsistema leste da CHESF, entre as cidades de Natal e Campina Grande. O sistema foi modelado e simulado utilizando-se o software ATP (*Alternative Transient Program*), considerando-se os seus parâmetros distribuídos e constantes na frequência. Na Fig. 2 é mostrado de forma simplificada o sistema modelado, evidenciando-se a linha 04V4 escolhida para análise.

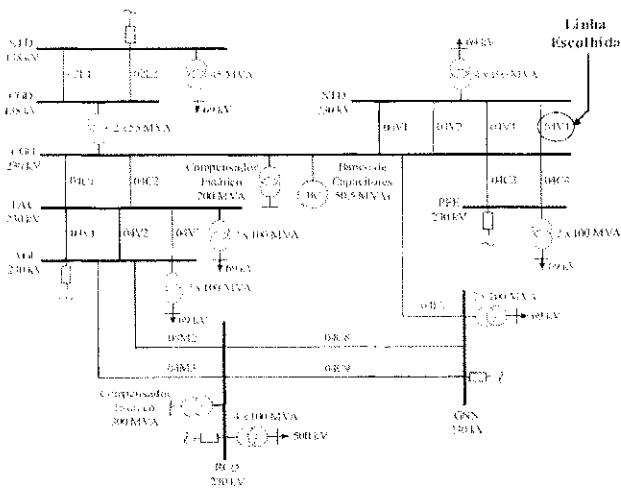


Fig. 2 Sistema elétrico utilizado.

B. Base de Conhecimento

A base de conhecimento utilizada para treinamento, validação e teste das RNA foi gerada por um processo automatizado [8]. O primeiro passo para sua construção foi a simulação das faltas a partir da condição de pré-falta, até meio ciclo após seu início. Utilizou-se um esquema de faltas deslizantes, considerando 18 localizações de ocorrência, de modo a contemplar várias situações ao longo da linha. Além dos pontos de ocorrência das faltas, foram considerados na simulação diferentes ângulos de incidência e resistências de falta.

Para geração da base é necessária apenas a construção de um arquivo modelo no ATP do sistema a ser simulado. As

variáveis de saída são as tensões e correntes trifásicas e de seqüência zero na linha, obtidas a partir de um registrador digital de perturbação (RDP) considerado no terminal de Campina Grande. Fazendo-se uso da rotina \$PARAMETER do ATP foi possível automatizar o processo de geração dos casos a serem simulados, bastando apenas modificar os parâmetros dessa rotina de um caso para outro.

No processo automatizado cada arquivo é nomeado de forma sistemática, de modo a conter em seu nome informações do tipo, da localização e da resistência da falta, além do ângulo de incidência. Os arquivos de saída do ATP são convertidos para o formato COMTRADE [9]. Na Tabela I apresenta-se o cenário de faltas simuladas para apresentação à RNA classificadora.

TABELA I
DADOS DA BASE DE CONHECIMENTO UTILIZADA

Variáveis de Simulação	Base de Conhecimento
Locais da falta (km)	10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 160, 170, 180
Tipos de falta	AT - BT - CT AB - AC - BC ABT - ACT - BCT - ABC
Resistência de falta (Ω)	FT 0,1 FF 0,1
Ângulo de incidência ($^\circ$)	30, 60, 90

FT: Faltas envolvendo as fases e a terra;
FF: Faltas envolvendo apenas fases.

A utilização de uma resistência de falta de 0,1 Ω caracteriza um curto-circuito. Cada cenário considerado na geração da base de conhecimento possui um arquivo de dados no padrão COMTRADE. No entanto, foi necessário adicionar mais duas colunas em cada arquivo, que representam a codificação binária do grupo de falta ao qual cada amostra pertence (Tabela II). A taxa de amostragem adotada do registrador foi de 1200 Hz, resultando em 10 amostras das tensões e correntes nas fases da linha em cada arquivo, considerando-se em cada simulação apenas meio ciclo de falta em 60 Hz.

TABELA II
CODIFICAÇÃO DOS TIPOS DE FALTA

Tipo de Falta	Codificação	
	T1	T2
Fase-Terra (AT - BT - CT)	0	0
Fase-Fase (AB - AC - BC)	0	1
Fase-Fase-Terra (ABT - ACT - BCT)	1	0
Trifásica (ABC)	1	1

Um método de janelamento dos arquivos de dados simulados foi empregado (Fig. 3). Esse janelamento consistiu em agrupar 4 amostras consecutivas das tensões e correntes

nas três fases e 4 amostras das tensões e correntes de seqüência zero em um único vetor de entrada para a rede neural. A janela de dados é feita como móvel, já que percorre todo o arquivo, deslocando-se ao passo de uma amostra. Nesse processo, uma janela corresponde a uma situação de falta apenas se todas suas amostras também corresponderem.

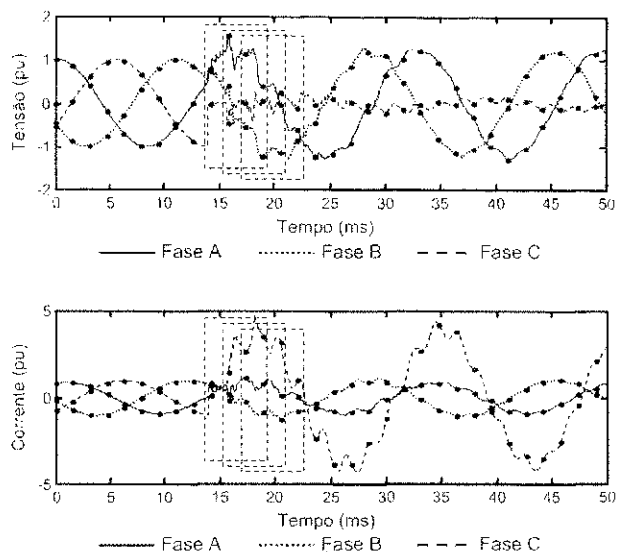


Fig. 3 - Processo de janelamento dos sinais de tensão e corrente.

O janelamento se aplica a todos os arquivos gerados na construção da base de conhecimento. Cada padrão da base é constituído de um vetor de entrada com 32 elementos e um vetor de saída constituído da indicação do grupo de falta e da localização da falta correspondente ao vetor de entrada.

De acordo com o janelamento aplicado aos arquivos, cada cenário considerado origina 6 padrões de entrada. Como a base possui 540 cenários, ela contém 3240 padrões, sendo 180 para cada uma das 18 localizações de falta consideradas.

C. Implementação das RNA

Para implementação das RNA, a ferramenta computacional escolhida foi o *Neural Network Toolbox* do MATLAB[®]. O algoritmo de treinamento escolhido foi o RPROP, *Resilient Propagation*, que é derivado do algoritmo de retropropagação do erro. A diferença existente é que no RPROP a atualização dos pesos sinápticos é realizada de acordo com o sinal da derivada parcial do erro em relação ao peso e não com seu valor. Com o RPROP, o valor da atualização dos pesos é calculado pela avaliação do sinal da derivada parcial de uma iteração para outra, o que melhora o processo de aprendizagem e torna o treinamento mais rápido [10].

Os dados de entrada de todas as RNA são as tensões e correntes trifásicas e de seqüência zero normalizados, de modo que os valores permaneçam no intervalo $[-1, 1]$. Entretanto, para a RNA classificadora são utilizados todos os padrões constituintes da base de conhecimento, enquanto redes localizadoras utilizam apenas os padrões referentes à zona e ao grupo de falta correspondente.

Para a RNA classificadora, os dados de saída são os bits T1 e T2, conforme indicado na Tabela II. A arquitetura 32-52-26-2 (32 neurônios na camada de entrada, 52 na primeira camada oculta, 26 na segunda e 2 na camada de saída) foi a que apresentou melhor desempenho. Como os dados da RNA em questão são binários, considerou-se como 0 (zero) qualquer valor abaixo de 0,5; caso contrário considerou-se 1 (um).

Com a falta classificada, a etapa seguinte é selecionar dentre as 32 RNA, a que será utilizada na localização da falta. A seleção é feita pelo grupo de falta classificado e pela zona em que se encontra o distúrbio. As distâncias apresentadas às redes são normalizadas em função da extensão de cada zona, de modo que permaneçam no intervalo $[0, 1]$.

Para todas as redes implementadas, nas camadas intermediárias a função de ativação escolhida foi a tangente hiperbólica (*tansig*), enquanto que para as camadas de saída utilizou-se a função sigmóide (*logsig*).

Para o treinamento do sistema completo optou-se pela adoção de 30.000 épocas para cada RNA do sistema de localização completo. Contudo, não foram necessárias as 30.000 para todas as RNA, visto que em alguns casos foi atingido o critério de parada por validação, que é o momento a partir do qual identifica-se que a rede começa a perder a capacidade de generalização dos padrões, passando a memorizar características específicas dos padrões pertencentes ao conjunto de treinamento. Optou-se pela utilização de uma mesma configuração para todas as redes localizadoras, 32 neurônios de entrada, 40 neurônios na camada oculta e apenas 1 neurônio na camada de saída.

O processo de aprendizagem de todas as RNA que compõem o esquema proposto foi realizado em cerca de 3 horas, obtendo-se os erros médios quadráticos no treinamento praticamente nulos, enquanto que para a validação foram inferiores a 0,01.

V. RESULTADOS OBTIDOS

O sistema de localização proposto ainda não está completo, pois o *módulo de identificação da zona* está em desenvolvimento. Dessa forma, os resultados apresentados a seguir levam em consideração que a fase de identificação da zona será bem sucedida, restando apenas refinar a localização da falta dentro da zona identificada.

O módulo classificador obteve 100% de acerto na classificação do grupo de faltas.

Na fase de localização, a média aritmética do módulo do erro para cada padrão de falta obtido foi de 1,66 km, equivalente a 0,88% do comprimento da linha. O erro médio máximo para determinada localização é inferior a 5 km, o que comprova a eficácia do método proposto. Nas Tabelas III a VI a seguir, apresenta-se uma síntese dos resultados obtidos para cada tipo de falta. A média dos resultados obtidos (média de cada tipo de falta no mesmo local) para cada caso testado, com os respectivos erros absolutos médios e máximos em km são mostrados. Os erros mínimos obtidos foram praticamente nulos para todas as localizações.

TABELA III
RESULTADOS PARA FALTAS FASE-TERRA

Localização		Erro	
Real (km)	Obtida (km)	Médio Absoluto (km)	Máximo Absoluto (km)
10	10,21	0,21	5,70
20	19,66	0,34	2,95
30	31,09	1,09	10,40
40	39,10	0,89	6,47
50	50,49	0,49	5,56
60	59,07	0,93	11,21
70	71,93	1,93	21,23
80	78,80	1,20	7,67
90	89,08	0,92	9,74
100	102,32	2,32	10,82
110	108,24	1,76	12,93
120	123,08	3,08	13,74
130	127,37	2,63	12,60
140	141,12	1,12	5,95
150	150,25	0,25	10,72
160	158,95	1,05	10,39
170	171,39	1,39	7,33
180	178,64	1,36	9,36

TABELA IV
RESULTADOS PARA FALTAS FASE-FASE

Localização		Erro	
Real (km)	Obtida (km)	Médio Absoluto (km)	Máximo Absoluto (km)
10	11,09	1,09	10,18
20	19,34	0,65	11,70
30	32,42	2,42	9,85
40	38,74	1,26	7,63
50	52,09	2,09	14,44
60	59,12	0,88	6,14
70	71,24	1,24	15,67
80	80,13	0,13	6,85
90	85,93	4,06	16,84
100	101,27	1,24	10,28
110	108,25	1,75	12,12
120	121,60	1,60	14,74
130	125,74	4,26	13,93
140	143,40	3,40	20,74
150	149,47	0,53	11,82
160	156,39	3,60	21,95
170	173,40	3,40	13,16
180	176,53	3,47	15,43

TABELA V
RESULTADOS PARA FALTAS FASE-TERRA

Localização		Erro	
Real (km)	Obtida (km)	Médio Absoluto (km)	Máximo Absoluto (km)
10	10,79	0,79	6,45
20	19,62	0,38	4,81
30	30,15	0,15	4,39
40	39,88	0,12	1,35
50	50,54	0,54	2,68
60	58,87	1,13	8,90
70	72,60	2,60	20,11
80	80,43	0,44	9,70
90	89,33	0,67	6,53
100	101,16	1,16	13,38
110	107,92	2,08	7,19
120	122,33	2,33	7,45
130	129,29	0,71	10,46
140	142,37	2,37	14,36
150	149,78	0,22	5,71
160	158,57	1,43	20,64
170	171,85	1,85	10,16
180	178,71	1,29	8,36

TABELA VI
RESULTADOS PARA FALTAS TRIFÁSICAS

Localização		Erro	
Real (km)	Obtida (km)	Médio Absoluto (km)	Máximo Absoluto (km)
10	10,89	0,89	6,86
20	20,06	0,06	0,51
30	32,63	2,63	9,03
40	38,42	1,58	5,66
50	51,59	1,59	4,93
60	58,96	1,04	5,64
70	71,36	1,36	8,55
80	79,16	0,84	9,74
90	87,53	2,47	18,42
100	100,62	0,62	3,98
110	107,40	2,60	9,93
120	121,22	4,22	8,54
130	129,47	0,53	5,32
140	144,24	4,24	17,48
150	151,70	1,70	6,23
160	158,95	1,05	6,25
170	171,39	1,39	13,24
180	178,64	1,36	6,00

VI. CONCLUSÕES

O método proposto proporciona uma localização robusta e confiável, tendo em vista que são realizadas duas estimativas: uma inicial, identificando a zona na qual ocorreu a falta e uma segunda, que fornece uma localização mais precisa.

Acredita-se que o ponto principal é a etapa de identificação da zona, já que um erro em sua estimativa invalida completamente a localização mais refinada. A pesquisa ainda está em andamento, e a implementação desse módulo sendo realizada. No entanto, os resultados obtidos com o esquema proposto foram considerados satisfatórios, quando aplicados a uma linha de 230 kV do sistema CHESF. Obteve-se 100% de acerto na fase de classificação. Na fase de localização, o erro médio obtido foi de 1,66 km e o erro médio máximo de 4,26 km, equivalente a 2,26% da extensão da linha utilizada.

VII. AGRADECIMENTOS

Este artigo é resultado de uma pesquisa ampla que conta com a colaboração do Dr. José J. de A. L. Leitão, do Departamento de Proteção e Automação da Operação da CHESF e da Eng. Milde M. S. Lira, doutoranda em Engenharia Elétrica da Universidade Federal de Pernambuco. Os autores agradecem a esses dois grandes colaboradores.

VIII. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] M. Oleskovicz, D. V. Coury, R. K. Aggarwal, "O Emprego de Redes Neurais Artificiais na Detecção, Classificação e Localização de Falhas em Linhas de Transmissão," *Revista Controle & Automação*, vol. 14, n.2, pp. 138-150, 2003.
- [2] J. A. C. B. Silva, "Um Localizador de Falhas em Linhas de Transmissão," Proposta de Dissertação de Mestrado, UFCG, 2003.
- [3] D. C. Jorge, D. V. Coury, A. C. P. L. F. Carvalho, "Localização de Falhas em Linhas de Transmissão de Energia Elétrica Utilizando Reconhecimento de Padrões," em *II Congresso Brasileiro de Redes Neurais*, pp.61-66, Jul. 1999.
- [4] M. Kezunovic, I. Rikalo, "Detect and Classify Faults Using Neural Nets," *IEEE Computer Applications in Power*, pp.42-47, Outubro 1996.
- [5] M. Kezunovic, I. Rikalo, "Automating the Analysis of Faults and Power Quality," *IEEE Computer Applications in Power*, pp.46-50, Jan. 1999.
- [6] S. Haykin, *Redes Neurais - Princípios e prática*, 2ª Ed., Bookman, 1999.
- [7] W. D. Stevenson Jr., *Elementos de Análise de Sistemas de Potência*, 2ª edição, McGraw-Hill do Brasil, 1986.
- [8] B. A. Souza, W. L. A. Neves, N. S. D. Brito, A. B. Fernandes, S. S. B. Silva, K. M. Silva, K. M. C. Dantas, A. V. Fontes, F. B. Costa, "Classificação de Falhas via Redes Neurais Artificiais," em *V Seminário Brasileiro sobre Qualidade da Energia Elétrica*, pp. 163-168, 2003.
- [9] B. A. Souza, N. S. D. Brito, W. L. A. Neves, K. M. Silva, R. B. V. Lima, S. S. B. Silva, "Comparison between Backpropagation and RPROP Algorithms Applied to Fault Classification in Transmission Lines," aceito para o I International Joint Conference on Neural Networks, Budapeste, Hungria, 25-29 Jul. 2004.
- [10] M. Riedmiller, H. Braun, "A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm", *Proceedings of the IEEE Int. Conf. on Neural Networks*, San Francisco, pp. 586-591, 1993.

IX. BIOGRAFIAS

José Antônio Cândido Borges da Silva nasceu em Resende, Brasil, 1978. Concluiu o curso de Engenharia Elétrica pela Universidade Federal de Campina Grande (UFCG), Brasil, em 2003. Atualmente é aluno do Programa de Pós-Graduação em Engenharia Elétrica da mesma universidade, com a previsão de obtenção do título de M.Sc. em Engenharia Elétrica para 2004. Suas áreas de interesse são transitórios eletromagnéticos, e operação e planejamento de sistemas elétricos.

Kleber Melo e Silva nasceu em João Pessoa, Brasil, 1980. Concluiu o curso de Engenharia-Elétrica pela Universidade Federal de Campina Grande (UFCG), Brasil, em 2004. Atualmente é aluno do Programa de Pós-Graduação em Engenharia Elétrica da mesma universidade, com a previsão de obtenção do título de M.Sc. em Engenharia Elétrica para 2005. Tem especial interesse nas áreas de planejamento, operação e controle de sistemas de elétricos, bem como por técnicas de inteligência artificial aplicadas a sistemas de potência.

Núbia Silva Dantas Brito nasceu em Antenor Navarro, Brasil, 1965. Recebeu os títulos de engenheira e D.Sc. em Engenharia Elétrica da Universidade Federal da Paraíba (UFPB), Brasil, em 1988 e 2001, respectivamente. Em 1996 recebeu o título de M.Sc. em Engenharia Elétrica da Universidade Estadual de Campinas (UNICAMP), Brasil. Atualmente é professora do Departamento de Engenharia Elétrica da Universidade Federal de Campina Grande (UFCG), Brasil. Suas atividades de pesquisa estão concentradas principalmente na área de Qualidade de Energia, em especial nas aplicações envolvendo detecção e classificação de falhas no sistema elétrico.

Washington Luiz Araújo Neves (M'95) nasceu em Iporanga, Brasil em 1957. Concluiu o curso de Engenharia Elétrica em 1979 e Mestrado em 1982 pela Universidade Federal da Paraíba em Campina Grande, Brasil. Concluiu o Doutorado em 1994 pela Universidade de British Columbia, Vancouver, Canadá. De 1982 a 1985 foi professor do Departamento de Engenharia Elétrica da Faculdade de Engenharia de Joazeiro. De 1985 a 2002 trabalhou no Departamento de Engenharia Elétrica da Universidade Federal da Paraíba em Campina Grande, Brasil, onde ministrou disciplinas, orientou teses de doutorado e dissertações de mestrado na área de transitórios eletromagnéticos. Desde abril de 2002 é professor do Departamento de Engenharia Elétrica da Universidade Federal de Campina Grande (UFCG).

Benemar Alencar de Souza (M'02) nasceu em Crato, Brasil, 1954. Recebeu os títulos de engenheiro, M.Sc. e D.Sc. em Engenharia Elétrica da Universidade Federal da Paraíba (UFPB), Brasil, em 1977, 1981 e 1995, respectivamente. Atualmente, é professor do Departamento de Engenharia Elétrica da Universidade Federal de Campina Grande (UFCG), Brasil. Suas atividades de pesquisa estão concentradas principalmente em métodos de otimização aplicados a sistemas de potência, transitórios eletromagnéticos, e operação e planejamento de sistemas elétricos.

Sandra Sayonara Bispo da Silva (M'02) nasceu em Recife, Brasil, 1960. Recebeu os títulos de engenheira e M.Sc. em Engenharia Elétrica da Universidade de Pernambuco (UPE) em 1984 e da Universidade Federal de Pernambuco (UFPE), Brasil, em 2002, respectivamente. Atualmente é engenheira especialista em análise de ocorrência da Companhia Hidro Elétrica do São Francisco (CHESF), Recife, Brasil. Além de redes de oscilografia e proteção de sistemas elétricos, tem interesse por técnicas de inteligência artificial aplicadas a sistema de potência, tema do projeto de doutorado que está iniciando na Universidade Federal de Campina Grande, Brasil.