Campus de São Carlos

**DETECÇÃO E CLASSIFICAÇÃO RÁPIDA DE
FALTAS EM LINHAS DE TRANSMISSÃO
UTILIZANDO REDES NEURAIS ARTIFICIAIS**

Autor: Renan Giovanini

Orientador: Prof. Dr. Denis V. Coury

UNIVERSIDADE DE SÃO PAULO

**ESCOLA DE ENGENHARIA
DE SÃO CARLOS**

Serviço de Pós-Graduação EESC/USP

EXEMPLAR REVISADO

Data de entrada no Serviço: 24 / 10 / 00

Ass.: Danilo

**DETECÇÃO E CLASSIFICAÇÃO RÁPIDA DE FALTAS EM
LINHAS DE TRANSMISSÃO UTILIZANDO REDES
NEURAIIS ARTIFICIAIS**

RENAN GIOVANINI

DEDALUS - Acervo - EESC

31100016736

Dissertação apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica

ORIENTADOR: Prof. Dr. Denis V. Coury

São Carlos
2000

Class.	TESE-EESC
Num.	G245f
Tombo	T0238/00

st 111 0041

Ficha catalográfica preparada pela Seção de Tratamento
da Informação do Serviço de Biblioteca – EESC/USP

G512d Giovanini, Renan
Detecção e classificação rápida de faltas em linhas de
transmissão utilizando redes neurais artificiais / Renan
Giovanini. -- São Carlos, 2000.

Dissertação (Mestrado) -- Escola de Engenharia de São
Carlos-Universidade de São Paulo, 2000.

Área: Engenharia Elétrica.

Orientador: Prof. Dr. Denis V. Coury.

1. Sistemas elétricos de potência. 2. Linhas de
transmissão. 3. Detecção e classificação de faltas.
4. Redes neurais artificiais. I. Título.

FOLHA DE APROVAÇÃO

Candidato: Engenheiro **RENAN GIOVANINI**

Dissertação defendida e aprovada em 28-08-2000
pela Comissão Julgadora:

Prof. Associado **DENIS VINICIUS COURY (Orientador)**
(Escola de Engenharia de São Carlos - Universidade de São Paulo)

Prof. Doutor **ALUÍZIO FAUSTO RIBEIRO ARAÚJO**
(Escola de Engenharia de São Carlos - Universidade de São Paulo)

Prof. Doutor **EDUARDO CÉSAR SENGER**
(Escola Politécnica - Universidade de São Paulo)

Profª. Associada **VILMA ALVES DE OLIVEIRA**
Coordenadora do Programa de Pós-Graduação
em Engenharia Elétrica

JOSÉ CARLOS A. CINTRA
Presidente da Comissão de Pós-Graduação da EESC

*Dedico esta dissertação aos meus pais, Ricardo e Maria Clara, pelo
apoio e confiança depositados em todos estes anos.*

AGRADECIMENTOS

Ao Prof. Dr. Denis Vinicius Coury pela orientação e conselhos ao longo desta jornada.

Aos amigos do laboratório LSEE e em especial a Donato da Silva Filho pelas valiosas discussões.

Aos meus irmãos, Ridinei e Neure, e a todos meus amigos que sempre acreditaram em mim.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela bolsa de mestrado concedida.

SUMÁRIO

LISTA DE FIGURAS	i
LISTA DE TABELAS	ii
LISTA DE ABREVIATURAS E SIGLAS	iv
LISTA DE SÍMBOLOS	v
RESUMO	vi
ABSTRACT	viii
1 A PROTEÇÃO DOS SISTEMAS ELÉTRICOS DE POTÊNCIA	1
1.1 COMPONENTES DOS ESQUEMAS DE PROTEÇÃO	1
1.1.1 ZONAS DE PROTEÇÃO	2
1.1.2 PROTEÇÃO PRIMÁRIA E DE RETAGUARDA	3
1.2 CARACTERÍSTICAS FUNCIONAIS DE UM RELÉ	4
1.3 O RELÉ DIGITAL	4
1.4 PROTEÇÃO DOS ELEMENTOS DE UM SISTEMA DE POTÊNCIA	5
1.4.1 TÉCNICAS PARA A PROTEÇÃO DE LINHAS DE TRANSMISSÃO	6
1.5 DETALHAMENTO DO PROJETO	7
2 REVISÃO BIBLIOGRÁFICA	9
2.1 UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS NA PROTEÇÃO DE LINHAS DE TRANSMISSÃO	9
3 REDES NEURAIS ARTIFICIAIS	16
3.1 HISTÓRICO	17
3.2 O <i>PERCEPTRON</i>	18
3.2.1 TREINAMENTO	19
3.3 A REDE <i>MULTILAYER PERCEPTRON</i>	20
3.3.1 TREINAMENTO	22
3.3.2 ACELERAÇÃO DO TREINAMENTO	26
3.3.3 O ALGORITMO <i>RESILIENT BACKPROPAGATION</i> (RPROP)	27
3.4 A REDE <i>RADIAL BASIS FUNCTION</i> (RBF)	28
3.4.1 TREINAMENTO	30
3.5 CONSIDERAÇÕES GERAIS SOBRE O TREINAMENTO DAS RNAS	33
3.5.1 TREINAMENTO DA REDE MLP PARCIALMENTE CONECTADA	36
3.5.2 TREINAMENTO DA REDE RBF PARCIALMENTE CONECTADA	36
4 MODELAGEM DO SISTEMA ELÉTRICO E DO RELÉ DIGITAL UTILIZADOS	43
4.1 O SISTEMA ELÉTRICO DE POTÊNCIA	43
4.1.1 TOPOLOGIA DO SEP	43

4.1.2	MODELAGEM DAS LINHAS DE TRANSMISSÃO	45
4.1.3	SIMULAÇÃO DO SEP	46
4.2	COMPONENTES BÁSICOS DO RELÉ DIGITAL	48
4.3	SUBSISTEMA DE ACONDICIONAMENTO DO SINAL	48
4.3.1	TRANSDUTORES	48
4.3.2	CIRCUITO PARA PROTEÇÃO DE SURTOS	50
4.3.3	FILTROS PASSA BAIXA	50
4.4	SUBSISTEMA DE CONVERSÃO DO SINAL	52
4.4.1	CIRCUITO <i>SAMPLE AND HOLD</i>	52
4.4.2	CIRCUITO MULTIPLEXADOR	53
4.4.3	CONVERSOR A/D	54
4.5	SUBSISTEMA DE PROCESSAMENTO DIGITAL DO SINAL	55
5	<u>O CONJUNTO DE TREINAMENTO PARA AS RNAs CONSIDERADAS E O ALGORITMO FINAL PARA DETECÇÃO E CLASSIFICAÇÃO DE FALTAS</u>	56
5.1	DESCRIÇÃO DO CONJUNTO DE SIMULAÇÕES PARA TREINAMENTO	56
5.2	DESCRIÇÃO DO BANCO DE DADOS PARA TREINAMENTO	58
5.3	TOPOLOGIA DAS RNAs PROJETADAS	59
5.4	O FUNCIONAMENTO DO ALGORITMO FINAL DE DETECÇÃO E CLASSIFICAÇÃO UTILIZANDO RNAs	60
6	<u>TESTES DE DESEMPENHO PARA AS REDES NEURAI MLP E RBF</u>	63
6.1	CRIAÇÃO DO BANCO DE DADOS PARA TESTES	63
6.2	ANÁLISE DOS RESULTADOS PARA A REDE TIPO MLP	64
6.2.1	MÓDULO DE DETECÇÃO	64
6.2.2	MÓDULO DE DETECÇÃO – TABELAS	65
6.2.3	MÓDULO DE CLASSIFICAÇÃO	67
6.2.4	MÓDULO DE CLASSIFICAÇÃO – TABELAS	68
6.2.5	ANÁLISE DO CONJUNTO DETECÇÃO E CLASSIFICAÇÃO	70
6.2.6	ANÁLISE DO CONJUNTO DETECÇÃO E CLASSIFICAÇÃO – TABELAS	72
6.3	ANÁLISE DOS RESULTADOS PARA A REDE TIPO RBF	76
6.3.1	MÓDULO DE DETECÇÃO	76
6.3.2	MÓDULO DE DETECÇÃO – TABELAS	77
6.3.3	MÓDULO DE CLASSIFICAÇÃO	78
6.3.4	MÓDULO DE CLASSIFICAÇÃO – TABELAS	79
6.3.5	ANÁLISE DO CONJUNTO DETECÇÃO E CLASSIFICAÇÃO	81
6.3.6	ANÁLISE DO CONJUNTO DETECÇÃO E CLASSIFICAÇÃO – TABELAS	82
6.4	COMPARAÇÃO DO DESEMPENHO DA REDE MLP COM A REDE RBF	84
7	<u>CONCLUSÕES</u>	87
	<u>REFERÊNCIAS BIBLIOGRÁFICAS</u>	89

LISTA DE FIGURAS

Figura 1.1 - Diagrama unifilar com duas LTs e os elementos do esquema de proteção para a linha compreendida entre os barramentos 1 e 2	2
Figura 1.2 - Um típico SEP com as suas respectivas zonas de proteção	3
Figura 1.3 - Esquema de decisão de um relé digital	7
Figura 3.1 - Representação do perceptron	18
Figura 3.2 - Representação esquemática de uma RNA	21
Figura 3.3 - Fluxo de processamento do algoritmo backpropagation	22
Figura 3.4 - Representação de uma rede tipo RBF	29
Figura 3.5 - Rede Neural tipo MLP parcialmente conectada	34
Figura 3.6 - Rede Neural tipo RBF parcialmente conectada	35
Figura 3.7 - Rede Neural tipo RBF parcialmente conectada na qual destacam-se os subconjuntos de neurónios da camada intermediária e os conjuntos de dados provenientes das correntes I_A , I_B , I_C e I_o	37
Figura 4.1 - Diagrama unifilar do SEP utilizado	43
Figura 4.2 - Formas de onda observadas pelo barramento 2 para uma falta tipo ABT	44
Figura 4.3 - Geometria da torre das linhas de transmissão	45
Figura 4.4 - Esquema geral de um relé digital	49
Figura 4.5 - Características de um filtro passa baixa - (a) caso ideal; (b) caso real	51
Figura 4.6 - Processo de amostragem para múltiplas entradas - Um conversor A/D para cada canal	52
Figura 4.7 - Processo de amostragem para múltiplas entradas - Utilização do circuito Sample and Hold	53
Figura 4.8 - Princípio do circuito multiplexador	53
Figura 4.9 - Ilustração do erro de quantização devido à conversão A/D	55
Figura 5.1 - Descrição das amostras utilizadas para o treinamento da rede neural	58
Figura 5.2 - Fluxograma do funcionamento do conjunto de algoritmos de detecção e de classificação	61
Figura 6.1 - Gráfico do desempenho das 3 RNAs do tipo MLP para a tarefa de detecção	64
Figura 6.2 - Gráfico do desempenho das 3 RNAs do tipo MLP para a tarefa de classificação	67
Figura 6.3 - Gráfico do desempenho das 3 RNAs do tipo MLP para a tarefa de detecção e classificação	71
Figura 6.4 - Gráfico do desempenho das 3 RNAs do tipo RBF para a tarefa de detecção	76
Figura 6.5 - Gráfico do desempenho das 3 RNAs do tipo RBF para a tarefa de classificação	79
Figura 6.6 - Gráfico do desempenho das 3 RNAs do tipo RBF para a tarefa de detecção e classificação	81
Figura 6.7 - Gráfico da comparação do desempenho da rede MLP com a rede RBF para a tarefa de detecção	85
Figura 6.8 - Gráfico da comparação do desempenho da rede MLP com a rede RBF para a tarefa de classificação	85
Figura 6.9 - Gráfico da comparação do desempenho da rede MLP com a rede RBF para a tarefa de detecção e classificação	86

LISTA DE TABELAS

Tabela 5.1 - Relação dos parâmetros utilizados para o conjunto de simulações I (Total=320)	57
Tabela 5.2 - Relação dos parâmetros utilizados para o conjunto de simulações II (Total=80)	57
Tabela 5.3 - Relação dos parâmetros utilizados para o conjunto de simulações III (Total=10)	57
Tabela 5.4 - Convenção utilizada no treinamento da rede neural	59
Tabela 6.1 - Relação dos parâmetros utilizados para o banco de dados para teste (Total=960)	63
Tabela 6.2 - Teste do módulo de detecção para faltas fase-terra (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	66
Tabela 6.3 - Teste do módulo de detecção para faltas fase-fase-terra (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	66
Tabela 6.4 - Teste do módulo de detecção para faltas fase-fase (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	66
Tabela 6.5 Teste do módulo de detecção para faltas trifásicas (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	67
Tabela 6.6 - Teste do módulo de classificação para uma falta tipo AT (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	69
Tabela 6.7 - Teste do módulo de classificação para uma falta tipo BCT (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	69
Tabela 6.8 - Teste do módulo de classificação para uma falta tipo AC (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	69
Tabela 6.9 - Teste do módulo de classificação para uma falta tipo ABC (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	70
Tabela 6.10 – Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω, Ângulo de Falta = 205°, Distância de Falta = 50 km, Tipo de Falta = BT	72
Tabela 6.11 – Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω, Ângulo de Falta = 205°, Distância de Falta = 10 km, Tipo de Falta = ACT	73
Tabela 6.12 – Exemplo do funcionamento detector + classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω, Ângulo de Falta = 205°, Distância de Falta = 130 km, Tipo de Falta = AC	74
Tabela 6.13 – Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 70 Ω, Ângulo de Falta = 100°, Distância de Falta = 10 km, Tipo de Falta = ACT	74
Tabela 6.14 – Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 150 Ω, Ângulo de Falta = 30°, Distância de Falta = 10 km, Tipo de Falta = ABT	75
Tabela 6.15 – Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω, Ângulo de Falta = 340°, Distância de Falta = 90 km, Tipo de Falta = BCT	75
Tabela 6.16 - Teste do módulo de detecção para faltas fase-terra (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	77
Tabela 6.17 - Teste do módulo de detecção para faltas fase-fase-terra (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	78
Tabela 6.18 - Teste do módulo de detecção para faltas fase-fase (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	78

Tabela 6.19 - Teste do módulo de detecção para faltas trifásicas (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	78
Tabela 6.20 - Teste do módulo de classificação para uma falta tipo AT (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	80
Tabela 6.21 - Teste do módulo de classificação para uma falta tipo BCT (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	80
Tabela 6.22 - Teste do módulo de classificação para uma falta tipo AC (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	80
Tabela 6.23 - Teste do módulo de classificação para uma falta tipo ABC (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)	81
Tabela 6.24 - Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω, Ângulo de Falta = 30°, Distância de Falta = 10 km, Tipo de Falta = BT	82
Tabela 6.25 - Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω, Ângulo de Falta = 30°, Distância de Falta = 130 km, Tipo de Falta = ABC	83
Tabela 6.26 - Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω, Ângulo de Falta = 205°, Distância de Falta = 130 km, Tipo de Falta = AT	83
Tabela 6.27 - Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω, Ângulo de Falta = 205°, Distância de Falta = 10 km, Tipo de Falta = CT	84

LISTA DE ABREVIATURAS E SIGLAS

MLP – *Multilayer Perceptron*

RBF – *Radial Basis Function*

LT – Linha de Transmissão

SEP – Sistema Elétrico de Potência

RNA – Rede Neural Artificial

RPROP – *Resilient Backpropagation*

CESP – Companhia Energética de São Paulo

TC – Transformador de Corrente

TP – Transformador de Potência

A/D – Analógico para Digital

I_A – Corrente da fase A

I_B – Corrente da fase B

I_C – Corrente da fase C

I_o – Corrente de sequência 0

LISTA DE SÍMBOLOS

V – volt

kV – quilovolt

A – ampère

GVA – giga volt-ampère

Ω – ohm

mm – milímetro

m – metro

km – quilômetro

Hz – Hertz

ms – milisegundo

RESUMO

Proteger as linhas de transmissão é uma das tarefas mais importantes dentro dos sistemas elétricos de potência. Faltas em linhas de transmissão devem ser localizadas precisamente e extintas o mais rápido possível. Para tal, o esquema de proteção de linhas utiliza valores amostrados de correntes e tensões para a execução das tarefas de detecção, classificação e localização da falta. Neste esquema, grandezas trifásicas de corrente (I_A , I_B , I_C) e tensão (V_A , V_B , V_C) compõem as entradas do sistema. Após a detecção e classificação da falta, o relé efetua o cálculo da impedância aparente para a verificação da zona de proteção na qual a falta se insere (localização). Dentro deste contexto, a rápida detecção e a correta classificação da falta são passos fundamentais para a lógica de controle de um relé. Para a utilização de sistemas de proteção com alta velocidade de operação, o conjunto detector + classificador deve realizar uma decisão precisa do tipo de falta envolvida em menos de 10 ms após a ocorrência desta. Alguns métodos convencionais têm lidado com este problema, porém os tempos para estimação do tipo de falta são algumas vezes excessivamente longos.

Este trabalho apresenta um novo sistema que provê uma rápida e confiável detecção e classificação de faltas através das medidas de valores de correntes trifásicas. O novo método utiliza-se da teoria de Redes Neurais Artificiais, baseada em dois diferentes tipos de redes (MLP e RBF), para a tarefa de detecção e classificação de faltas nos níveis de tempo requeridos para um moderno sistema de proteção. Um estudo comparativo em relação ao desempenho das redes mencionadas também foi realizado. Os testes efetuados para as redes dos tipos MLP e RBF mostraram que o sistema proposto foi capaz de detectar e classificar corretamente 100% dos casos estudados. Deve ainda ser ressaltado, que na maior parte dos casos (93% para a rede MLP e 84% para a rede RBF), o processo de detecção e classificação foi completado com no máximo 5 amostras de pós-falta (5ms). Isto demonstra a rapidez na tarefa de detecção e classificação embutida no método proposto, principalmente levando-se em consideração os tempos apresentados pelos métodos convencionais.

Palavras-chave: Sistemas Elétricos de Potência; Linhas de Transmissão; Detecção e Classificação de Faltas; Redes Neurais Artificiais.

ABSTRACT

Transmission line protection is one of the major tasks for a power system. Transmission line faults must be located accurately and isolated as fast as possible. In order to perform this task, the power system protection system uses the three-phase currents (I_A , I_B , I_C) and voltages (V_A , V_B , V_C) to detect, classify and locate the fault. After detecting and classifying the fault, the relay calculates the apparent impedance to verify in which protection zone the fault is located. Taking this into account, precise and fast detection and classification methods are fundamental steps for the relay control algorithm. The combination detection + classification must carry out the correct response in less than 10 ms after the fault for a high-speed protection system. Some conventional methods have treated this problem but the time for a correct classification is sometimes excessively long.

This work presents a fast and reliable new system for fault detection and classification using the three-phase current measurements. This new system is based on Artificial Neural Networks (RBF and MLP) for the detection and classification tasks. A comparative study involving both types of neural networks was done. Tests showed that the proposed system was able to correctly detect and classify 100% of the studied cases where the majority (93% of the cases for MLP net and 84% for RBF net) of them was done in up to 5 post-fault samples (5 ms). The aforementioned demonstrates the high speed of the new method for the detection and classification tasks when compared to the conventional ones.

Keywords: Power System; Transmission Lines; Fault Detection and Classification; Artificial Neural Networks.

A PROTEÇÃO DOS SISTEMAS ELÉTRICOS DE POTÊNCIA

Simultaneamente ao surgimento dos sistemas de transmissão e distribuição de energia elétrica, surgiram os primeiros esquemas de proteção que tinham como finalidade proteger o sistema de faltas que nestes pudessem ocorrer, resultantes de descargas atmosféricas, curtos-circuitos e problemas de chaveamento (STEVENSON JR., 1986). Apesar de tais faltas serem um evento um tanto raro, estas se não isoladas em um curto espaço de tempo, provocariam sérios danos ao sistema elétrico, tais como danos a equipamentos, redução da margem de estabilidade do sistema e explosões em equipamentos. Para que tais problemas não ocorressem, os esquemas de proteção deveriam possuir uma rápida ação, isolando a porção faltosa do sistema.

1.1 Componentes dos Esquemas de Proteção

A rápida ação dos esquemas de proteção exige a operação de vários subsistemas. Os esquemas de proteção podem ser subdivididos em três partes (STEVENSON JR., 1986):

- transdutores: são transformadores de corrente e tensão responsáveis pela alimentação do relé;
- relé: corresponde ao elemento lógico do esquema de proteção, tendo como função detectar faltas dentro de seu alcance, e a partir disto energizar as bobinas de disparo dos seus disjuntores associados;
- disjuntores: são acionados pelos relés e isolam a parte do sistema em que ocorreu a falta.

Na Figura 1.1 visualiza-se um esquema de proteção com todos os seus subsistemas.

Figura 1.1 - Diagrama unifilar com duas LTs e os elementos do esquema de proteção para a linha compreendida entre os barramentos 1 e 2

A ação coordenada do esquema de proteção pode ser vislumbrada da seguinte maneira: quando ocorre uma falha em P na linha de transmissão (LT) da Figura 1.1, uma corrente adicional flui de ambos os terminais da LT para a falha (supondo-se a existência de fontes de energia em ambos os lados) aumentando-se o nível de corrente na LT e conseqüente diminuição da tensão. Estes dados de corrente e tensão são então convertidos a níveis mais baixos pelos **transdutores** (T) servindo de entrada para o **relé** (R). O **relé** então processa os sinais de entrada e decide se uma falta realmente ocorreu na LT. Caso uma falta seja detectada, o relé energiza a bobina de disparo do **disjuntor** (D) correspondente fazendo que os contatos deste, que estão em série com a LT, abram e desconectem a LT do restante do sistema, isolando assim a parte defeituosa do sistema.

1.1.1 Zonas de Proteção

A filosofia de um esquema de proteção consiste basicamente na divisão do sistema elétrico de potência (SEP) em pequenas partes de modo que uma proteção adequada seja assegurada, bem como a garantia de que apenas uma pequena parte do sistema seja desligado no caso de uma falta. Um típico SEP e suas respectivas zonas de proteção podem ser visualizadas na Figura 1.2. Observa-se que as zonas de proteção se sobrepõem umas às outras de maneira a não existir zonas desprotegidas.

Figura 1.2 - Um típico SEP com as suas respectivas zonas de proteção

1.1.2 Proteção Primária e de Retaguarda

Conforme salientado, os esquemas de proteção dividem o SEP em zonas para assegurar uma proteção adequada. Estes esquemas são conhecidos como esquemas de proteção **primária**, pois eles são responsáveis pela remoção da falta o mais rápido possível, desligando a menor parcela do sistema. Entretanto, usualmente considera-se que alguns dos componentes desta proteção possam vir a falhar, sendo necessária portanto a criação de um esquema de proteção de **retaguarda** (ELMORE, 1994).

Uma maneira de se obter um esquema de retaguarda consiste na duplicação dos componentes de proteção primária de modo que a falha do esquema primário não impossibilite a remoção da falta. Este esquema geralmente é utilizado em circuitos importantes dentro de um SEP, visto o custo adicional que ele acarreta.

Uma outra maneira de se obter um esquema de proteção de retaguarda consiste na utilização das zonas de proteção vizinhas à zona de proteção primária. Dentro deste contexto, as zonas vizinhas (proteção de retaguarda) devem atuar quan-

do uma falta for detectada dentro da zona primária de outro relé e o mesmo não operar. Deve-se salientar que os esquemas de proteção de retaguarda devem dar ao esquema primário um tempo suficiente para que este possa atuar, visto que uma operação excessivamente rápida dos esquemas de retaguarda pode levar a um desligamento desnecessário de uma porção maior do sistema.

1.2 Características Funcionais de um Relé

Observando o quadro anterior, percebe-se que certas características são fundamentais para o desempenho de um relé: **velocidade**, **confiabilidade**, **seletividade** e **sensibilidade**. A primeira característica – velocidade – é básica dentro do funcionamento de um relé: o relé deve tomar uma decisão o mais rápido possível. A característica – confiabilidade – traduz-se como a probabilidade do relé satisfazer uma operação prevista sob dadas circunstâncias. Define-se seletividade como a capacidade de atuação do relé com conseqüente isolamento da menor parte do sistema evitando-se assim, desligamentos desnecessários de partes do sistema. Por último, a sensibilidade consiste na capacidade do relé em responder corretamente frente a anormalidades das condições de operação e de curtos-circuitos.

Sendo assim, observa-se que os relés são a parte fundamental (“cérebro”) dentro do esquema de proteção, sendo que especial atenção deve ser reservada a este elemento.

1.3 O Relé Digital

Os primeiros relés utilizados eram de constituição eletromecânica, que embora eficazes no acionamento dos disjuntores, apresentavam grandes dimensões e eram relativamente lentos. Estes relés possuíam como entradas as leituras de tensão e corrente provenientes dos transdutores, sendo que a sua decisão – *trip* – baseava-se diretamente na comparação ou combinação destes parâmetros com um valor predeterminado (valor ou curva de referência) (PHADKE e THORP, 1988).

No final dos anos 50 surgiram os primeiros relés eletrônicos (conhecidos também como relés de estado sólido). Eles eram constituídos basicamente por diodos, transistores e amplificadores operacionais, sendo mais flexíveis e mais velozes que os relés eletromecânicos, porém mais susceptíveis a ruídos eletromagnéticos (*EMI*).

Com o surgimento dos microprocessadores no início dos anos 70, começou-se a estudar o uso desta nova tecnologia dentro dos esquemas de proteção, criando-se um novo tipo de relé: o relé digital.

O relé digital possui como entrada os mesmos dados de tensão e corrente provenientes de transdutores, tais como no relé eletromecânico ou de estado sólido, sendo que estes sinais são então convertidos em sinais digitais. O processo de decisão é feito então pelo microprocessador através de um programa onde a análise destes sinais de entrada é feita.

Percebe-se logo a superioridade dos relés digitais em relação aos relés convencionais, visto que os convencionais baseiam-se em relações simples existentes entre os sinais de entrada enquanto os digitais possuem a capacidade de extração das características mais importantes dos sinais de entrada, bem como uma análise mais complexa da relação existente entre estes sinais. Esta característica só pôde ser obtida graças ao caráter programável dos microprocessadores.

Outras vantagens diretas do uso de relés digitais em relação aos relés convencionais são a crescente diminuição do **custo** dos microprocessadores e outros componentes digitais integrantes deste tipo de relé, a **flexibilidade** de operação proporcionada pela sua característica programável e por fim a capacidade de **autodiagnóstico** para a detecção de possíveis falhas existentes em algum dos componentes integrantes do relé para posterior reparo, evitando assim falhas no seu funcionamento (aumento da confiabilidade).

1.4 Proteção dos Elementos de um Sistema de Potência

Um sistema de potência pode ser dividido em 5 elementos básicos (ELMORE, 1994):

- Geradores
- Transformadores
- Barramentos
- Circuitos de distribuição e transmissão
- Motores

Dentre estes elementos, percebe-se que a LT (circuito de transmissão) é o elemento mais susceptível a faltas devido a sua grande dimensão física (STEVENSON JR., 1986). A proteção de LTs é objeto freqüente de estudos sendo que a proteção deste elemento será o objetivo principal deste trabalho.

1.4.1 Técnicas para a proteção de Linhas de Transmissão

A maioria das faltas em um SEP ocorre em LTs. Este elemento possui uma grande variação em suas características, configuração, comprimento e importância relativa dentro do SEP em que se encontra, ocasionando assim a existência de várias técnicas para a sua proteção. Dentre as diversas técnicas de proteção comumente utilizadas para a proteção de LTs, pode-se citar a proteção de **sobrecorrente**, a proteção **direcional**, a proteção de **distância** e a proteção através de **relé de fio piloto**.

A proteção de sobrecorrente consiste na comparação da magnitude da corrente com um valor típico de corrente para uma situação normal, indicando assim uma situação de falta ou não. A proteção direcional baseia-se na comparação do ângulo de fase da corrente de falta com uma quantidade referência (a tensão correspondente, por exemplo) indicando assim se uma falta adiante ou reversa existe.

O esquema de proteção de distância baseia-se no princípio que a relação das entradas tensão e corrente (impedância aparente) é função da distância entre o ponto de falta e a localização do relé. Basicamente este esquema de proteção compara as tensões e correntes vindas do sistema, determinando se uma falta está ocorrendo dentro da sua zona de proteção. Dentre os relés de distância mais comumente encontrados podem-se citar os relés de impedância, reatância e mho.

Por fim, a proteção através de relé de fio piloto utiliza como base um canal de comunicação entre os relés de terminais remotos de modo que eles funcionem cooperativamente na tomada de decisão e não de maneira independente (*standalone*). Um algoritmo básico utilizado dentro desta filosofia é a comparação diferencial.

1.5 Detalhamento do Projeto

A Figura 1.3 mostra as partes funcionais de um *software* para o releamento digital. Neste esquema, grandezas trifásicas de corrente (I_A , I_B , I_C) e tensão (V_A , V_B , V_C) compõem as entradas do sistema. Um módulo lógico controla todas as partes do relé. O primeiro módulo, **detecção da falta**, indica a existência de uma falta no sistema; o segundo, **classificação da falta**, indica qual o tipo de falta está ocorrendo, e o terceiro, **localização da falta**, indica se a falta está dentro da zona primária de proteção.

Figura 1.3 - Esquema de decisão de um relé digital

O objetivo deste trabalho consiste no desenvolvimento de dois módulos lógicos (módulos destacados), utilizando-se a teoria de Redes Neurais Artificiais baseadas em dois diferentes tipos de redes (MLP - *Multilayer Perceptron* e RBF - *Radial Basis Function*) para a constituição de um relé para proteção primária de uma LT. Pretende-se com isso fazer uma avaliação desta nova técnica que atualmente está merecendo grande destaque dentro da área de proteção em SEPs.

Observando-se este objetivo, organizou-se este trabalho de modo que tanto os aspectos teóricos quanto os aspectos práticos relativos ao desenvolvimento dos módulos considerados fossem abordados.

No capítulo 2, encontra-se uma breve revisão bibliográfica dos principais trabalhos publicados dentro da área de proteção de linhas de transmissão utilizando RNAs. Já no capítulo 3, apresenta-se a teoria relativa às RNAs onde são introduzidas as redes do tipo MLP e RBF e explicadas os seus respectivos funcionamento e treinamento. Para o capítulo 4, reserva-se a descrição do sistema elétrico utilizado, bem como os detalhes da modelagem de um relé digital. O capítulo 5 introduz os principais aspectos dos algoritmos de detecção e classificação de faltas utilizando RNAs. Nele são descritas as topologias de RNAs encontradas, assim como as regras de formação que foram utilizadas na criação do banco de dados para treinamento destas redes. Seguindo-se este capítulo, apresenta-se o capítulo 6, no qual encontram-se os testes relativos aos algoritmos desenvolvidos no capítulo anterior. Por fim, reserva-se ao capítulo 7 a análise e comentários finais sobre o desempenho dos algoritmos desenvolvidos, sendo este seguido pelas referências bibliográficas.

REVISÃO BIBLIOGRÁFICA

Ao longo da última década inúmeros trabalhos foram publicados dentro da área de proteção em SEPs. Dentro desta área, percebe-se que especial atenção foi dada a aplicação de RNAs como método de resolução, visto que a proteção digital de LTs pode ser considerada como um problema de reconhecimento de padrões (DALSTEIN e KULICKE, 1995). A seguir são destacados alguns dos trabalhos mais importantes encontrados na literatura para a resolução deste problema, sendo feita uma breve citação do tópico estudado e dos resultados obtidos pelos autores.

2.1 Utilização de Redes Neurais Artificiais na Proteção de Linhas de Transmissão

SULTAN et al. (1992) propõe-se o uso de uma rede neural para a detecção de faltas de alta impedância em arco em sistemas de potência. A detecção de faltas de alta impedância em arco representa um grande desafio dentro da área de proteção, sendo que vários métodos foram propostos para a sua solução. Entretanto, estas técnicas não são capazes de detectar todas as condições elétricas resultantes de um sistema em falta, fato que leva a utilização de redes neurais como uma solução atrativa, visto a sua grande capacidade de reconhecimento de padrões. A rede neural utilizada é do tipo *multilayer perceptron* (MLP) com algoritmo de treinamento *backpropagation*. Ela possui como entrada amostras de tensão e corrente e como saída a indicação de falta de alta impedância. No processo de treinamento variaram-se as faltas quanto à resistência de falta, à carga e à existência de arco. Testes foram realizados, obtendo-se resultados precisos quanto à distinção de faltas de alta impedância e situações de carga normal.

No artigo (DALSTEIN e KULICKE, 1995), um conjunto de redes neurais é utilizado para a tarefa de classificação e detecção de faltas. Dentro do trabalho ressalta-se a importância da detecção de faltas em arco, visto que normalmente os relés convencionais tentam um auto-religamento após um intervalo de tempo, fato que pode ocasionar o surgimento de instabilidade dentro do sistema elétrico para o caso de uma falta permanente. Neste trabalho, utilizaram-se apenas redes do tipo MLP com algoritmo de treinamento *backpropagation*, sendo que a rede responsável pela classificação possui como entrada amostras de tensão e corrente trifásicas e como saída os dez possíveis tipos de faltas. O conjunto de redes para detecção de faltas em arco possui como entrada apenas amostras de tensão e como saída a indicação de faltas em arco ou não. Os resultados obtidos para a classificação são precisos, sendo que os obtidos para a detecção de arco podem ser facilmente utilizados com um módulo de controle para que haja uma correta decisão.

No trabalho de (FERNANDO e MCLAREN, 1995) apresenta-se uma rede neural para a classificação de faltas em uma linha de transmissão com circuito duplo. No artigo mostram-se os problemas decorrentes do uso de uma técnica convencional para classificação de faltas em linhas de transmissão com circuito único aplicada às linhas de transmissão de circuito duplo, com conseguinte proposição de uma alteração ao método convencional utilizado. O uso de uma rede neural MLP é então proposto, obtendo-se resultados satisfatórios com apenas alguns erros para faltas entre circuitos.

Em (SIDHU et al., 1995), propõe-se o uso de uma rede neural para a discriminação direcional de faltas em um sistema de transmissão de energia. Atualmente encontram-se vários métodos para a execução desta tarefa dos quais todos possuem como desvantagem o uso de processamento de sinais e a incapacidade de adaptação às condições dinâmicas do sistema. Propõe-se então como solução uma rede neural do tipo MLP com treinamento *backpropagation* que possui como entrada amostras de tensão e corrente e como saída a determinação da direção da falta (reversa ou adiante). Testou-se a rede com dados simulados e reais, obtendo-se uma resposta altamente precisa em ambos os testes.

O uso de duas arquiteturas diferentes – MLP e *Kohonen* – para a classificação de faltas em dois sistemas de transmissão é apresentado no artigo (CHOWDHURY e WANG, 1996). A rede do tipo *Kohonen* foi escolhida pela sua excelente capacidade classificatória enquanto a rede MLP foi utilizada como padrão de comparação, visto que é a rede mais comumente encontrada. Utilizaram-se dados de tensão e corrente como entradas da rede, sendo que a transformada rápida de Fourier (FFT) foi utilizada para a extração das componentes fundamentais. Após as fases de treinamento e teste, observou-se que as duas redes obtiveram resultados idênticos quanto ao acerto (100%), sendo que uma atenção especial é dada a rede do tipo *Kohonen*, visto o seu baixo tempo de treinamento e a sua capacidade de retreinamento on-line.

Em (DALSTEIN et al., 1996), apresenta-se um estudo de redes neurais aplicadas à proteção de distância em linhas de transmissão. Utilizou-se um conjunto de redes neurais com arquitetura MLP e regra de aprendizagem *backpropagation*, sendo este composto por dez redes neurais independentes em paralelo. Na fase de treinamento considerou-se a localização, ângulo de incidência, tipo, faltas em arco e efeito de saturação dos transformadores. Testes foram realizados tomando-se como referência dois algoritmos tradicionais, obtendo-se resultados que mostram a superioridade das RNAs em relação aos métodos convencionais.

No trabalho (KEZUNOVIC e RIKALO, 1996), analisa-se o uso de uma rede neural do tipo *Kohonen* para a classificação de faltas em dois SEPs. No trabalho destacam-se a capacidade da rede tipo *Kohonen* na tarefa de extração das características das amostras de entrada e a sua característica de aprendizado não-supervisionado, onde o processo de definição de classes é feito pela própria rede e não pelo projetista, tal como na rede MLP. Vários testes foram realizados, obtendo-se 90% de acerto quanto ao tipo de falta ocorrido.

No artigo (KHAPARDE et al., 1996), discute-se o uso de redes neurais para a realização do releamento adaptativo para a proteção de distância de LTs. São propostas duas arquiteturas de redes neurais. Uma baseia-se na característica quadrilateral do relé de distância, enquanto a outra em um conjunto de treinamento onde são apresentadas amostras de tensão e corrente e definida a zona de proteção a

qual estas pertencem. A primeira arquitetura foi testada sem sucesso, enquanto que a segunda obteve resultados satisfatórios com erros na zona de transição (entre a zona primária e a secundária).

Em (NOVOSEL et al., 1996), propõe-se o uso de dois novos métodos para a proteção de distância de LTs com compensação série. Um dos métodos propostos consiste em um algoritmo determinístico que explora o uso de equações diferenciais para o cálculo da característica não-linear do resistor em paralelo presente no compensador série, enquanto que o outro método baseia-se no uso de uma rede neural MLP com algoritmo de aprendizado *backpropagation*. Vários testes foram realizados utilizando-se duas diferentes topologias de SEPs (circuito simples e circuito duplo) onde se variaram a localização, tipo, resistência e ângulo de incidência da falta. Os testes mostraram que ambas as técnicas foram satisfatórias possuindo erros totais médios equivalentes.

No trabalho (SONG et al., 1996), apresenta-se o estudo de um conjunto de redes neurais do tipo MLP para a proteção de linhas de transmissão AC com compensação série controlada. Uma das vantagens do uso de redes neurais neste tipo de problema é que os métodos tradicionais falham ao analisar sistemas de transmissão com compensação série visto que a impedância aparente da linha pode variar de indutiva à capacitiva rapidamente. O conjunto de redes é composto por duas redes neurais, sendo a primeira responsável pela tarefa de classificação e determinação da direção da falta e a segunda pela localização da falta. A coordenação do conjunto é feita por um sistema de regras. Os resultados obtidos mostram que a técnica utilizada é factível quando comparada às técnicas tradicionais.

Uma rede neural do tipo MLP é utilizada para a detecção de faltas do tipo fase-terra em uma linha de transmissão simples em (VÁSQUEZ et al., 1996). Nele faz-se a avaliação de vários filtros *anti-aliasing* para o uso em conjunto com a rede neural. Analisam-se também os vários tamanhos de janelas de dados mostrando-se, inclusive, as vantagens e desvantagens dos diferentes tamanhos de janelas utilizados. Os resultados obtidos são precisos, demonstrando a capacidade desta ferramenta.

Em (BO et al., 1997) apresenta-se o uso de uma rede neural do tipo MLP para a discriminação de descargas atmosféricas e faltas do tipo fase-terra em linhas de transmissão. No instante em que ocorre uma descarga atmosférica em um sistema de transmissão, ocorre a introdução de transientes de alta frequência dentro das ondas de tensão, característica esta semelhante a uma falta fase-terra. Por possuírem características semelhantes, surge uma impossibilidade de distinção entre os dois eventos através dos métodos convencionais, tornando assim o uso de redes neurais uma solução considerável. Para a solução deste problema, utilizou-se uma rede de 2 camadas treinada com o algoritmo *backpropagation*, tendo como entrada a corrente modal da fase analisada e como saída os três possíveis estados: estado normal, falta fase-terra e descarga atmosférica. A rede foi testada sob várias circunstâncias apresentando resultados altamente satisfatórios.

Já em (JIALI et al., 1997), um conjunto de redes neurais para a tarefa de proteção de linhas de transmissão é proposto. O conjunto é constituído de três redes independentes do tipo MLP que executam as seguintes tarefas: detecção de oscilação do sistema, detecção - discriminação de faltas e localização. O conjunto utiliza como entradas dados de tensão e corrente para as três redes. Os resultados provenientes destas redes são então analisados por uma rotina de julgamento, definindo-se então, os seguintes estados do sistema: operação normal, oscilação de potência, ativação do dispositivo de proteção para faltas dentro da zona de proteção primária e classificação. Nesta etapa do trabalho analisou-se a capacidade de detecção de faltas do sistema proposto, sendo que o projeto encontra-se ainda em desenvolvimento.

Um estudo para a proteção de distância em linhas de transmissão usando uma rede neural MLP é exposto em (QI et al., 1997). A rede possui como entradas dados de impedância (sequência positiva e zero) e como algoritmo de treinamento o método de *backpropagation*. Na fase de treinamento considerou-se como parâmetros variáveis a distância, resistência de falta, impedância das fontes e ângulo de carga para faltas do tipo fase-terra. Testes foram realizados obtendo-se respostas precisas.

Em (SONG et al., 1997), 5 diferentes tipos de redes neurais aplicadas à proteção de linhas de transmissão foram estudados. Esta abordagem é oferecida pois na literatura encontra-se um grande número de estudos utilizando-se a arquitetura MLP com o algoritmo de treinamento *backpropagation*. No artigo são avaliadas as arquiteturas dos tipos MLP, rede mapa de características, rede de função de base radial, rede *counterpropagation* e rede de aprendizado de quantização de vetor. Coloca-se uma grande ênfase na comparação de desempenho das cinco redes neurais em termos de tamanho, processo de treinamento, precisão da classificação e robustez. Resultados altamente encorajadores são obtidos com as redes de função de base radial e *counterpropagation*.

Em (SU et al., 1997), uma rede neural para a localização de faltas em sistemas de transmissão compostos (linhas aéreas + cabos subterrâneos) é relatada. Este tipo de problema possui como características básicas a alta impedância capacitiva e a alta impedância série introduzida pelos cabos subterrâneos, ocasionando assim uma menor distorção nas ondas viajantes produzidas pela falta, levando a uma maior dificuldade na sua localização. A rede neural proposta é do tipo MLP com algoritmo de treinamento *backpropagation*. Ela possui como entrada amostras de tensão e corrente e como saída a localização do ponto de falta. No processo de treinamento da rede variou-se o tipo, o ângulo e a localização da falta. Uma série de testes foi realizada, sendo que os testes realizados no ponto centrais da linha de transmissão (50% do comprimento) apresentaram os resultados mais satisfatórios (1% de erro), enquanto que os testes na zona de transição da linha (80% do comprimento) apresentaram um erro ligeiramente maior.

No artigo (COURY e JORGE, 1998), apresenta-se o uso de uma rede neural do tipo MLP para a localização de faltas em sistema de transmissão. Utilizou-se uma rede de 2 camadas treinada com o algoritmo *backpropagation*, tendo como entrada as componentes fundamentais de tensão e corrente previamente obtidas através da transformada discreta de Fourier (DFT) de $\frac{1}{2}$ ciclo. No estudo utilizou-se como zona primária um trecho equivalente a 80% da linha de transmissão considerando-se ainda a variação do ângulo de falta, ângulo de transmissão de potência, capacidade das fontes e a razão das impedâncias das fontes para a realização do trei-

namento. Os resultados obtidos foram satisfatórios, encontrando-se pequenos erros na transição das zonas de proteção ($80\% \pm 1\%$).

Uma nova técnica para a detecção e classificação de faltas baseada em conceitos de redes neurais e lógica *fuzzy* é apresentada em (WANG e KEERTHIPALA, 1998). No artigo propõe-se o uso de uma técnica híbrida que se aproveita da capacidade de representação de conhecimento difuso da lógica *fuzzy* e da eficiente habilidade que as redes neurais possuem para aprenderem a partir de exemplos. O sistema utiliza como parâmetros de entrada as magnitudes das correntes trifásicas mais as suas respectivas componentes simétricas. Uma série de testes foi feita obtendo-se resultados altamente precisos, sendo que o processo de detecção e classificação não tomou mais que 10 ms para todos os casos de teste.

Pretendeu-se apresentar com esta breve revisão bibliográfica os principais trabalhos desenvolvidos dentro da área de proteção de linhas de transmissão utilizando-se RNAs. Como pôde ser observada, a maioria dos trabalhos utilizou as redes do tipo MLP para as diferentes tarefas de detecção, classificação e localização de faltas em um SEP, fato que inspirou o estudo de um novo tipo de rede (rede RBF) para a realização das tarefas de detecção e classificação, como será apresentado nos próximos capítulos.

REDES NEURAIS ARTIFICIAIS

O ano de 1986 marcou o reinício de uma área tida como esquecida, as Redes Neurais Artificiais (RNAs). Em (RUMELHART e MCCLELLAND, 1986), Rumelhart e McClelland mostravam que as RNAs eram capazes de resolver problemas não-lineares e que constituíam uma alternativa a computação algorítmica tradicional. Mas o que são RNAs ?

As RNAs podem ser consideradas como sistemas de processamento paralelo e distribuído que calculam determinadas funções matemáticas. Elas são constituídas por elementos básicos (neurônios) que são organizados em grupos (camadas) interligados por um grande número de conexões. A essas conexões normalmente associam-se valores (pesos) que têm como função estabelecer uma ponderação entre os valores de entrada e de saída da RNA, de modo a armazenar o conhecimento contido no modelo. O procedimento usual para aplicação de uma RNA constitui-se inicialmente de uma fase de **projeto** onde se determina o tipo de rede e arquitetura (número de neurônios e de camadas). Em seguida passa-se para a fase de **treinamento**, que consiste na extração das características do modelo a ser resolvido através de um conjunto de exemplos. Posteriormente a rede é submetida à fase de **teste**, onde as características aprendidas anteriormente são utilizadas para a geração de respostas ao problema.

Neste trabalho as RNAs foram empregadas para duas tarefas distintas: a detecção e a classificação de faltas em um SEP. Nele foram empregados dois tipos de RNAs : a *Multilayer Perceptron* (MLP) e a *Radial Basis Function* (RBF).

A rede MLP é atualmente a RNA mais utilizada dentro da área de diagnósticos de faltas em SEPs, visto a sua facilidade de implementação e boa capacidade de generalização. Porém, a rede MLP possui um alto tempo de treinamento, o que leva a busca de novos tipos de redes a serem empregadas dentro desta área. Com

isso, a rede RBF apresenta-se como alternativa viável devido ao seu rápido processo de treinamento e boa capacidade de generalização.

3.1 Histórico

O primeiro modelo matemático de um neurônio surgiu em 1943 através do trabalho de McCulloch e Pitts (MCCULLOCH e PITTS, 1943). O trabalho descrevia basicamente um modelo artificial de neurônio mostrando as suas capacidades computacionais, sendo que nenhuma técnica de aprendizado era apresentada. Somente em 1949 apareceu o primeiro trabalho que descrevia a utilização de uma técnica de aprendizado. Hebb (1949) mostra que a aprendizagem de neurônios é obtida através do reforço dos pesos de entrada entre nodos excitados. Posteriormente, em 1960, Widrow e Hoff sugeriram em (WIDROW e HOFF, 1960) a utilização do gradiente descendente para a minimização do erro da saída de um neurônio com resposta linear. Esta regra é conhecida como regra delta, sendo ainda muito utilizada atualmente.

Em 1958, Rosenblatt descrevia em (ROSENBLATT, 1958) um novo modelo de neurônio, o *perceptron*. Em seu modelo mais simples, o *perceptron* era capaz de classificar problemas linearmente separáveis, sendo que inicialmente ele fornecia respostas aleatórias mas, com ajuste gradual dos pesos ele era capaz de fornecer saídas corretas ao conjunto de treinamento. Em 1969, as RNAs sofreram talvez o seu maior ataque. Minsky e Papert demonstravam em (MINSKY e PAPERT, 1969) que o *perceptron* não era capaz de resolver uma grande quantidade de problemas – os problemas linearmente não-separáveis. Durante os anos 70, as pesquisas em RNAs praticamente ficaram abandonadas devido principalmente ao trabalho de Minsky e Papert.

Somente em 1982 o interesse nas RNAs voltou a surgir. Em (HOPFIELD, 1982), mostra-se a relação entre redes recorrentes auto-associativas e sistemas físicos, abrindo espaço para a Física estudar estes modelos. Porém, apenas em 1986 surgiu o trabalho que alavancou novamente as pesquisas em RNAs. Em (RUMELHART e MCCLELLAND, 1986), Rumelhart e McClelland demonstraram que uma

rede constituída por *perceptrons* era capaz de resolver problemas linearmente não-separáveis através do algoritmo de treinamento *backpropagation*.

Este trabalho pode ser considerado como um marco nas pesquisas em RNAs, sendo o ponto determinante na retomada das pesquisas em RNAs. Deve-se ressaltar, porém, outro fator responsável pela retomada de interesse na área: o avanço da tecnologia microeletrônica. Foi somente através do avanço tecnológico que a realização física dos modelos de neurônios e suas interligações pôde ser implementada.

3.2 O Perceptron

O *perceptron* pode ser considerado como a forma mais simples de RNA para a classificação de padrões linearmente separáveis. Basicamente, ele é composto por entradas que são ponderadas através de pesos e de um limiar (*bias*) que estabelece um valor mínimo que a soma ponderada das entradas deve atingir para que o *perceptron* seja ativado. A representação do *perceptron* pode ser vista na Figura 3.1 e o cálculo do valor de saída (y) é dado pelas Equações 3.1 e 3.2.

Figura 3.1 – Representação do perceptron

$$y = g\left(\sum_{i=1}^p w_i x_i - \theta\right) \quad \text{eq. 3.1}$$

onde

$$g(a) = \begin{cases} -1 & \text{se } a < 0 \\ 1 & \text{se } a \geq 0 \end{cases} \quad \text{eq. 3.2}$$

Mostra-se que para um problema com duas classes linearmente separáveis o *perceptron* é capaz de diferenciá-las corretamente (HAYKIN, 1994).

3.2.1 Treinamento

Como apresentado e demonstrado em (HAYKIN, 1994), o algoritmo de treinamento do *perceptron* sempre chega a uma solução para problemas com duas classes linearmente separáveis em um tempo finito. Este algoritmo de treinamento, bem como uma lista com o sumário das variáveis e parâmetros utilizados no treinamento são apresentados a seguir.

Lista 3.1 - Sumário das variáveis e parâmetros utilizados no treinamento

p = número de entradas do neurônio

n = O símbolo n refere - se ao n - ésimo padrão de treinamento, estendo - se até o último padrão de treinamento N .

N = Número total de padrões.

s = Passo corrente do treinamento.

$$\begin{aligned} \mathbf{x}(n) &= (p+1) \times 1 \text{ vetor de entrada} \\ &= [-1, x_1(n), x_2(n), \dots, x_p(n)]^T \end{aligned}$$

$$\begin{aligned} \mathbf{w}(s) &= (p+1) \times 1 \text{ vetor de pesos} \\ &= [\theta_s, w_1(s), w_2(s), \dots, w_p(s)]^T \end{aligned}$$

$$\theta(s) = \text{bias}$$

$$y(n) = \text{valor da saída}$$

$$d(n) = \text{resposta desejada}$$

$$\eta = \text{taxa de aprendizagem, valor positivo menor que 1}$$

Algoritmo de treinamento para o *Perceptron*

Passo 1 : Inicialização

Inicializar η , vetor de pesos w , o padrão atual $n=1$ e o passo $s = 1$;

Passo2 : Ativação

Calcular o valor da saída y_n ;

Passo 3 : Correção do Vetor Peso

Calcular a correção do vetor peso w :

$$w(s+1) = w(s) + \eta[d(n) - y(n)]x(n) \quad \text{eq. 3.3}$$

onde

$$d(n) = \begin{cases} +1 & \text{se } x(n) \text{ pertence a classe 1} \\ -1 & \text{se } x(n) \text{ pertence a classe 2} \end{cases} \quad \text{eq. 3.4}$$

Passo 4 : Iteração

Incrementar o padrão n e o passo s ,

se n for maior que N , $n = 1$;

Volte ao passo 2.

3.3 A Rede *Multilayer Perceptron*

Tipicamente uma RNA consiste de um conjunto de neurônios organizados em uma **camada de entrada**, uma ou mais **camadas intermediárias** e uma **camada de saída**. O sinal de entrada é propagado através da RNA no sentido da camada de entrada para a camada de saída (sentido direto). Este tipo de rede neural é

conhecido como *multilayer perceptron* (MLP), representando a generalização do *perceptron* apresentado na seção anterior.

As redes do tipo MLP têm sido aplicadas com muito sucesso em muitos problemas de difícil solução através do treinamento supervisionado com o algoritmo de retropropagação do erro (*Backpropagation algorithm*). Basicamente o algoritmo *Backpropagation* consiste de duas fases: uma fase direta e uma fase reversa. Na fase direta, o sinal de entrada é propagado no sentido direto, camada por camada, obtendo-se assim uma resposta na camada de saída. A esta resposta compara-se a resposta desejada, obtendo-se assim o erro cometido pela rede. Este erro é então propagado no sentido inverso corrigindo-se então os pesos da rede de modo que o erro cometido seja minimizado. Uma representação esquemática de uma RNA do tipo MLP pode ser visualizada na Figura 3.2 enquanto que o fluxo de processamento do algoritmo *backpropagation* é descrito na Figura 3.3.

Figura 3.2 – Representação esquemática de uma RNA

Podemos afirmar então que uma RNA do tipo MLP possui três características distintas :

- 1 – O valor da ativação de cada neurônio é calculado através de uma função suave e não-linear ao contrário do modelo *perceptron* que utiliza a função degrau, sendo a função mais comumente empregada a *função sigmoide* (vide Lista 3.2):

$$y_j = \frac{1}{1 + e^{(-v_j)}} \quad \text{eq. 3.5}$$

2 – A RNA possui uma ou mais camadas de neurônios intermediários. Estes neurônios são responsáveis pela extração das características significativas do sinal de entrada.

3 – A RNA possui um alto grau de conectividade.

3.3.1 Treinamento

Como já citado anteriormente, o algoritmo *backpropagation* é um algoritmo que utiliza pares de valores (entrada, saída desejada) para, através de um mecanismo de retropropagação do erro, ajustar os pesos da rede. Ele pode ser descrito pelo algoritmo a seguir, sendo que sua demonstração pode ser encontrada em (HAYKIN, 1994). A descrição dos símbolos utilizados encontram-se Lista 3.2.

Figura 3.3 - Fluxo de processamento do algoritmo *backpropagation*

- O índice l refere-se aos índices das camadas. Ele se estende da camada de entrada ($l=0$) até a camada de saída ($l=L$).
- Os índices i, j , e k referem-se aos diferentes neurônios na rede; assumindo que o sinal de entrada propaga-se da esquerda para a direita, o neurônio j situa-se na camada à direita do neurônio i , e o neurônio k situa-se na camada à direita do neurônio j quando o neurônio j está dentro de uma camada intermediária.
- O símbolo n refere-se ao n -ésimo padrão de treinamento, estendendo-se até o último padrão de treinamento ($\{n = 1, 2, \dots, N\}$).
- O símbolo t refere-se à iteração em que se encontra o processo.
- O símbolo ξ_{AV} refere-se ao erro médio quadrático cometido pela rede para o conjunto de treinamento.
- O símbolo $e_j(n)$ refere-se ao erro cometido pelo neurônio j para o n -ésimo padrão de entrada.
- O símbolo $d_j(n)$ refere-se à resposta desejada para o neurônio j para o n -ésimo padrão de entrada.
- O símbolo $y_i^l(n)$ refere-se ao valor da ativação para o neurônio j presente na camada l para o n -ésimo padrão de entrada.
- O símbolo $w_{ji}^l(t)$ denota o peso compreendido entre a saída do neurônio i e a entrada do neurônio j pertencente à camada l na iteração t .
- A atividade interna de um neurônio j presente na camada l para o n -ésimo padrão de entrada é representada pelo símbolo $v_j^l(n)$.
- O bias aplicado ao neurônio j é simbolizado por $\theta_j(t)$; seu efeito é representado pelo peso $w_{j0}(t) = \theta_j(t)$ conectado a uma entrada fixa de valor -1 .
- O i -ésimo elemento do vetor de entrada é simbolizado por $x_i(n)$.

- O k-ésimo elemento do vetor de saída é simbolizado por $o_k(n)$.
- A taxa de aprendizado é simbolizada por η .

Algoritmo *Backpropagation*

Passo 1 : Inicialização

Inicialize η e o vetor de pesos $\mathbf{w}$, faça $t=1$.

Passo 2 : Apresentação do Conjunto de Treinamento

Apresentar à rede todos padrões de entrada (1 época). Para cada padrão de entrada fazer a seguinte seqüência de cálculos:

Fase Direta

Considere a matriz $[\mathbf{x}(n), \mathbf{d}(n)]$. Apresente o vetor $\mathbf{x}(n)$ à entrada da rede e o vetor $\mathbf{d}(n)$ à saída da rede. Calcule a ativação de todos os neurônios através do sentido direto, camada por camada. O valor da atividade interna $v_j^{(l)}(n)$ para o neurônio j na camada l é :

$$v_j^{(l)}(n) = \sum_{i=0}^p w_{ji}^{(l)}(t) y_i^{(l-1)}(n) \quad \text{eq. 3.6}$$

onde $y_i^{(l-1)}(n)$ é o valor da ativação do neurônio i na camada anterior $l-1$ na iteração n e $w_{ji}^{(l)}(n)$ é o peso compreendido entre o neurônio j na camada l e o neurônio i na camada $l-1$. Para $i = 0$, tem-se $y_0^{(l-1)}(n) = -1$ e $w_{j0}^{(l)}(t) = \theta_j^{(l)}(t)$, onde $\theta_j^{(l)}(t)$ corresponde ao bias aplicado ao neurônio j na camada l . Assumindo o uso da função sigmoidal, o valor da ativação do neurônio j na camada l é :

$$y_j^{(l)}(n) = \frac{1}{1 + e^{(-v_j^{(l)}(n))}} \quad \text{eq. 3.7}$$

Se o neurônio j estiver na primeira camada intermediária (i.e., $l=1$), faça:

$$y_j^{(0)}(n) = x_j(n) \quad \text{eq. 3.8}$$

onde $x_j(n)$ corresponde ao j -ésimo elemento do vetor de entrada $\mathbf{x}(n)$. Se o neurônio j encontrar-se na camada de saída (i.e., $l=L$), faça:

$$o_j(n) = y_j^{(L)}(n) \quad \text{eq. 3.9}$$

Uma vez calculada a saída, calcule o erro obtido para a entrada $\mathbf{x}(n)$

$$e_j(n) = d_j(n) - o_j(n) \quad \text{eq. 3.10}$$

onde $d_j(n)$ corresponde ao j -ésimo elemento do vetor de resposta desejada $\mathbf{d}(n)$.

Fase Reversa

Calcule os δ 's (i.e., os gradientes locais) para a rede no sentido reverso, camada por camada :

$$\delta_j^{(L)}(n) = e_j^{(L)}(n) o_j(n) [1 - o_j(n)] \quad \text{eq. 3.11}$$

para o neurônio j na camada de saída L

$$\delta_j^{(l)}(n) = y_j^{(l)}(n) [1 - y_j^{(l)}(n)] \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(t) \quad \text{eq. 3.12}$$

para o neurônio j na camada intermediária l

Por fim, ajuste os pesos da rede para a camada l de acordo com a regra delta generalizada:

$$w_{ji}^{(l)}(t+1) = w_{ji}^{(l)}(t) + \eta \delta_j^{(l)}(n) y_i^{(l)}(n) \quad eq. 3.13$$

onde η corresponde à taxa de aprendizado.

Passo 3 : Iteração

Faça $t=t+1$; volte ao passo 2 até que o erro médio quadrático ξ_{AV} (3.14) calculado para o conjunto de treinamento atinja um valor mínimo ou se atinja um número máximo de iterações ($tmax$).

$$\xi_{AV} = \frac{1}{2N} \sum_{n=1}^N \sum_{j \in C} e_j^2(n) \quad eq. 3.14$$

3.3.2 Aceleração do Treinamento

A seção anterior apresentou o algoritmo *Backpropagation* para o treinamento de RNAs. Esse algoritmo apesar de poderoso, é considerado lento para problemas reais (DEMUTH e BEALE, 1997). Ao longo dos anos vários algoritmos foram propostos para superar esta deficiência do algoritmo *Backpropagation*. Estes algoritmos possuem como vantagem a aceleração do processo de treinamento em dezenas ou até centenas de vezes comparado ao algoritmo apresentado anteriormente.

Estes algoritmos podem ser separados em duas categorias. A primeira categoria utiliza técnicas heurísticas que foram desenvolvidas a partir da análise do desempenho do algoritmo *Backpropagation*. Dentre os algoritmos encontrados nesta categoria, destacam-se o *Variable Learning Rate Backpropagation* (DEMUTH e BEALE, 1997) e o *Resilient Backpropagation* (DEMUTH e BEALE, 1997), (BRAGA et al, 1999).

A segunda categoria de algoritmos por sua vez foi desenvolvida a partir de técnicas de otimização numérica. Destacam-se entre estes algoritmos, o algoritmo do Gradiente Conjugado (DEMUTH e BEALE, 1997), (BISHOP, 1995), o

algoritmo quasi-Newton (DEMUTH e BEALE, 1997), (BISHOP, 1995) e o algoritmo Levenberg-Marquardt (DEMUTH e BEALE, 1997).

Neste trabalho foram analisados os algoritmos Levenberg-Marquardt e *Resilient Backpropagation*, sendo o último escolhido como algoritmo de treinamento para redes MLP, visto a sua rápida velocidade de convergência e sua baixa necessidade de memória computacional. Este algoritmo é brevemente apresentado na seção a seguir.

3.3.3 O Algoritmo *Resilient Backpropagation* (RPROP)

As redes MLP possuem tipicamente a função sigmoideal como função de ativação de seus neurônios. A função sigmoideal caracteriza-se pelo fato de sua inclinação aproximar-se de zero quando a sua entrada atinge um alto valor. Isto causa um sério problema para algoritmos que utilizam o gradiente descendente para a correção dos pesos, pois a baixa inclinação indica uma baixa magnitude para o valor do gradiente e, conseqüentemente, uma pequena correção nos valores dos pesos e bias, mesmo para valores de pesos e bias longe de seus pontos ótimos.

O propósito do algoritmo RPROP é eliminar o aspecto indesejado das baixas magnitudes dos gradientes locais. O algoritmo baseia-se apenas no sinal do gradiente e não no seu valor (BRAGA et al, 1999). O sinal indica a direção do ajuste dos pesos (aumentar ou diminuir o peso anterior) . O tamanho do ajuste dos pesos é dado por um fator de atualização Δ_{ji} indicado na Equação 3.15.

$$\Delta w_{ji} = \begin{cases} +\Delta_{ji}, & \text{se } \delta_j^l(n) > 0 \\ -\Delta_{ji}, & \text{se } \delta_j^l(n) < 0 \\ 0, & \text{caso contrário} \end{cases} \quad \text{eq. 3.15}$$

O valor da atualização Δ_{ji} é definido por um processo de adaptação que depende do sinal do gradiente anterior e do gradiente atual :

$$\Delta_{ji}(t) = \begin{cases} \eta^+ \Delta_{ji}(t-1), & \text{se } \delta_j^l(n) \delta_j^l(n-1) > 0 \\ \eta^- \Delta_{ji}(t-1), & \text{se } \delta_j^l(n) \delta_j^l(n-1) < 0 \\ \Delta_{ji}(t-1), & \text{caso contrário} \end{cases} \quad \text{eq. 3.16}$$

onde $0 < \eta^- < 1 < \eta^+$.

O valor do novo peso será dado então por:

$$w_{ji}^{(t)}(t+1) = w_{ji}^{(t)}(t) + \Delta w_{ji} y_i^{(t)}(n) \quad \text{eq. 3.17}$$

Segundo a regra de adaptação utilizada em RPROP, quando o gradiente mantém o seu sinal, o que indica que seu último ajuste reduziu o erro cometido, o valor de atualização Δ_{ji} é aumentado pelo fator η^+ , acelerando a convergência do treinamento. Quando o gradiente muda de sinal, o que indica que o seu último ajuste foi grande demais, o valor de atualização Δ_{ji} é reduzido pelo fator η^- , mudando a direção do ajuste.

3.4 A Rede Radial Basis Function (RBF)

A função de ativação aplicada a cada neurônio da maioria das redes multicamadas utiliza como argumento o produto escalar do vetor de entrada e do vetor de pesos deste neurônio (BISHOP, 1995). Existem contudo, outras categorias de redes multicamadas onde a ativação de um neurônio é função da distância entre seus vetores de entrada e de peso. Uma destas categorias é a rede RBF.

Este tipo de RNA possui normalmente duas camadas: uma intermediária e uma saída ¹. A primeira camada, cujos neurônios utilizam funções de base radial, agrupa os dados de entrada em *clusters*. A segunda camada então classifica os *clusters* fornecidos pela camada anterior. Esta camada possui normalmente como

¹ Redes RBF com mais de uma camada intermediária já foram propostas. Maiores informações em (BRAGA et al, 1999)

função de ativação funções lineares ($y_j = \sum_i w_{ji} x_i$). Uma representação de uma rede tipo RBF pode ser visualizada na Figura 3.4.

Figura 3.4 – Representação de uma rede tipo RBF

Funções de base radial representam um tipo de função cujo valor diminui ou aumenta em relação à distância a um ponto central. Diversas funções podem ser utilizadas em redes RBF, sendo as mais comuns a função Gaussiana (Equação 3.18), a função Multiquadrática (Equação 3.19) e a função *Thin-Plate-Spline* (Equação 3.20). Essas funções são descritas a seguir:

$$\phi(x) = e^{\left(-\frac{v^2}{2\sigma^2}\right)} \quad \text{eq. 3.18}$$

$$\phi(x) = \sqrt{v^2 + \sigma^2} \quad \text{eq. 3.19}$$

$$\phi(x) = v^2 \log(v) \quad \text{eq. 3.20}$$

onde $v = \|x - \mu\|$, que é dado geralmente pela distância Euclidiana, x é o vetor de entrada e μ e σ representam o centro e a largura da função radial respectivamente. A resposta gerada por um neurônio de saída, j , será:

$$y_j = \sum_{i=1}^K w_{ji} \phi(\|x - \mu_i\|) \quad \text{eq. 3.21}$$

onde K representa o número de neurônios contidos na camada intermediária.

3.4.1 Treinamento

Vários métodos são encontrados na literatura para o treinamento de redes RBF, sendo que na maioria das vezes o treinamento é classificado como híbrido, uma vez que ele é dividido em duas etapas.

Na primeira etapa, determinam-se os centros das funções radiais através de métodos não-supervisionados (métodos que se utilizam apenas dos dados de entrada). Na segunda etapa, a correção dos pesos é feita através de modelos lineares.

A seguir, apresenta-se o algoritmo de treinamento para redes RBF. Para a primeira fase, utiliza-se o algoritmo de *clustering* conhecido como *K-Means-Clustering*, ou K-Médias (BRAGA et al, 1999), sendo que na segunda fase os pesos são calculados através do cálculo da pseudo-inversa da matriz de ativação. A demonstração dos algoritmos apresentados a seguir, bem como maiores detalhes podem ser encontrados em (BISHOP, 1995).

Lista 3.3 - Sumário dos símbolos utilizados no algoritmo K-Means-Clustering

- K – número de agrupamentos.
- N – número de vetores.
- x^n – conjunto de vetores de entrada a serem agrupados ($n=1,...,N$).
- μ^j – conjunto de vetores correspondentes aos centros dos agrupamentos ($j=1,...,K$).
- S_j – conjunto dos vetores pertencentes ao agrupamento j ($j=1,...,K$).

1ª Fase - K-Means-Clustering

Passo 1

Escolha o número de agrupamentos K .

Passo 2

Associe aleatoriamente K vetores $\mathbf{x}^n$ aos K centros.

Passo 3

Para todo vetor $\mathbf{x}^n$ associe o centro mais próximo através da distância Euclidiana.

$$distância = \|\mathbf{x}^n - \boldsymbol{\mu}_j\| \quad eq. 3.22$$

Passo 4

Para cada subconjunto S_j calcule o novo centro.

$$\boldsymbol{\mu}_j = \frac{1}{N_j} \sum_{n \in S_j} \mathbf{x}^n \quad eq. 3.23$$

onde N_j representa o número de vetores pertencentes ao conjunto S_j .

Passo 5

Volte ao passo 3 até que não haja mais mudanças nos agrupamentos.

2ª Fase – Determinação dos Pesos

Considerando que as saídas da rede RBF são dadas por:

$$y_k(\mathbf{x}) = \sum_{j=1}^K w_{kj} \phi_j(\mathbf{x}) \quad eq. 3.24$$

Esta equação pode ser rescrita na notação matricial como:

$$\mathbf{y}(\mathbf{x}) = \mathbf{W}\boldsymbol{\phi} \quad eq. 3.25$$

onde $\mathbf{W} = (w_{kj})$ e $\boldsymbol{\phi} = (\phi_j)$. Como as funções de base radial são consideradas fixas, a rede RBF pode ser considerada equivalente a uma rede de uma única camada

(BISHOP, 1995) sendo que os seus pesos podem ser determinados através das seguintes equações lineares:

$$\mathbf{W}^T = \Phi^T \mathbf{D} \quad eq. 3.26$$

$$(\mathbf{D})_{nk} = d_k^n \quad eq. 3.27$$

$$(\Phi)_{nj} = \phi_j(x^n) \quad eq. 3.28$$

onde Φ^T simboliza a matriz pseudo-inversa de Φ .

A descrição dos símbolos utilizados na determinação da matriz peso $\mathbf{W}$ pode ser visualizada na Lista 3.4.

Lista 3.4 - Sumário dos símbolos utilizados na determinação da matriz $\mathbf{W}$

- k, j – Símbolos utilizados como índices dos vetores $\mathbf{y}$ e ϕ e da matriz $\mathbf{W}$.
- K – Número de neurônios da camada intermediária.
- $\mathbf{y}$ – Vetor de saída da rede RBF.
- $\mathbf{W}$ – Matriz de pesos da rede RBF.
- ϕ – Vetor de ativação da rede RBF.
- Φ – Matriz ativação para todo o conjunto de treinamento.
- $\mathbf{D}$ – Matriz dos valores desejados para todo o conjunto de treinamento.

3.5 Considerações Gerais Sobre o Treinamento das RNAs

Ao contrário do observado nos trabalhos descritos no capítulo 2, este trabalho utilizou-se de uma estratégia diferente de conexão entre as camadas das redes neurais do tipo MLP e RBF. As redes aqui apresentadas, para ambos os casos, possuem os seus neurônios da camada de entrada parcialmente conectados à camada intermediária; os neurônios da camada intermediária possuem a abordagem tradicional, isto é, eles estão totalmente conectados aos neurônios da camada de saída. Esta abordagem foi utilizada uma vez que, para uma correta detecção e classificação de falta para uma determinada fase, apenas os dados relativos a esta fase são necessários. A estratégia utilizada para a obtenção das topologias pode ser visualizada na Figura 3.5 e na Figura 3.6.

Figura 3.5 – Rede Neural tipo MLP parcialmente conectada

Figura 3.6 - Rede Neural tipo RBF parcialmente conectada

A partir destas topologias, uma nova técnica de treinamento teve de ser desenvolvida para a rede RBF. No próximo item, apresentam-se alguns comentários relativos ao desenvolvimento da rede MLP parcialmente conectada, sendo que a nova técnica de treinamento para a rede RBF é apresentada no item 3.5.2.

3.5.1 Treinamento da Rede MLP Parcialmente Conectada

Para o treinamento da rede MLP parcialmente conectada, utilizou-se o algoritmo *Resilient Backpropagation* presente no *Toolbox Neural Networks* do *software* Matlab. A construção da rede MLP parcialmente conectada foi realizada através das regras descritas para elaboração de redes personalizadas em (DEMUTH e BEALE, 1997), e após esta etapa, os processos de treinamento e teste foram realizados pelo mesmo método utilizado para o treinamento e teste de uma rede MLP totalmente conectada.

3.5.2 Treinamento da Rede RBF Parcialmente Conectada

Ao contrário da rede MLP parcialmente conectada, rede em que o processo de treinamento e teste puderam ser realizados através do *Toolbox Neural Networks* presente no *software* Matlab, a rede RBF parcialmente conectada não pôde ser desenvolvida através dos *softwares* encontrados (DEMUTH e BEALE, 1997) e (ORR, 1999). Somando-se a este impedimento, destaca-se ainda a impossibilidade de utilização do algoritmo proposto em 3.4.1, uma vez que este prevê a utilização de uma rede RBF totalmente conectada. Para superar estas dificuldades, desenvolveu-se então, um novo algoritmo de treinamento para redes RBF parcialmente conectadas utilizando-se o ambiente de programação do *software* Matlab. A lista com o sumário de todas as variáveis utilizadas pelo o algoritmo *K-Means Clustering* modificado e o próprio algoritmo são apresentados a seguir. Para uma maior clareza do processo de treinamento apresenta-se a Figura 3.7, na qual são destacados os vários subconjuntos de neurônios utilizados durante o treinamento, além dos conjuntos de dados relativos às correntes I_A , I_B , I_C e I_o .

Figura 3.7 - Rede Neural tipo RBF parcialmente conectada na qual destacam-se os subconjuntos de neurônios da camada intermediária e os conjuntos de dados provenientes das correntes I_A , I_B , I_C e I_o

- R – número de subconjuntos de neurônios presentes na camada intermediária. Para o treinamento em questão, R é igual a 4, uma vez que existe 1 subconjunto de dados provenientes da corrente A (I_A), 1 de I_B , 1 de I_C e 1 de I_O .
- K^r – número de centros para o subconjunto de neurônios r ($r = 1, \dots, R$).
- N – número de vetores presentes no conjunto de treinamento.
- x^n – conjunto de vetores de entrada ($n = 1, \dots, N$).
- x_1^n – conjunto de vetores de entrada com dados relativos à corrente I_A .
- x_2^n – conjunto de vetores de entrada com dados relativos à corrente I_B .
- x_3^n – conjunto de vetores de entrada com dados relativos à corrente I_C .
- x_4^n – conjunto de vetores de entrada com dados relativos à corrente I_O .
- xx^m – conjunto de vetores de entrada para situações normais, ou seja, conjunto de vetores cujo valor desejado de saída para detecção é igual a 0 ($m = 1, \dots, n/2$).
- xx_1^m – conjunto de vetores de entrada para situações normais com dados relativos à corrente I_A .
- xx_2^m – conjunto de vetores de entrada para situações normais com dados relativos à corrente I_B .
- xx_3^m – conjunto de vetores de entrada para situações normais com dados relativos à corrente I_C .
- xx_4^m – conjunto de vetores de entrada para situações normais com dados relativos à corrente I_O .
- μ_j^r – conjunto de vetores correspondentes aos centros pertencentes ao subconjunto de neurônios r ($j = 1, \dots, K^r$).
- S_j^r – conjunto dos vetores pertencentes ao agrupamento j relativo ao subconjunto de neurônios r ($j = 1, \dots, K^r$).

obs.: $x^n = [x_1^n \ x_2^n \ x_3^n \ x_4^n]$ e $xx^m = [xx_1^m \ xx_2^m \ xx_3^m \ xx_4^m]$

1ª Fase - K-Means-Clustering Modificado

Passo 1

Para todos subconjuntos de neurônios ($r = 1, \dots, 4$) faça:

Passo 2

Escolha o número de centros para o subconjunto K^r de neurônios presente na camada intermediária.

Passo 3

Associe aleatoriamente K^r vetores xx_r^m aos centros μ_j^r .

Passo 4

Para todo vetor xx_r^m associe o centro mais próximo através da distância Euclidiana.

$$distância = \|xx_r^m - \mu_j^r\| \quad eq. 3.29$$

Passo 5

Para cada subconjunto S_j^r calcule o novo centro.

$$\mu_j^r = \frac{1}{P_j^r} \sum_{n \in S_j^r} xx_r^n \quad eq. 3.30$$

onde P_j^r representa o número de vetores pertencentes ao conjunto S_j^r .

Passo 6

Volte ao passo 4 até que não haja mais mudanças nos agrupamentos.

Passo 7

Volte ao passo 1.

2ª Fase – Determinação dos Pesos

A determinação da matriz de pesos para a camada de saída é feita de maneira similar à descrita no item 3.4.1. Inicialmente calcula-se a matriz ativação para todos os padrões de treinamento, determina-se então a pseudo-inversa desta matriz, e por fim, multiplica-se esta matriz pela matriz de respostas desejadas obtendo-se a transposta da matriz de pesos. A única diferença entre estes cálculos e os cálculos feitos no item 3.4.1 refere-se a determinação da matriz de ativação. Enquanto no item 3.4.1 o cálculo da ativação era feito tomando-se todos os dados provenientes da camada de entrada, para este novo treinamento, a matriz ativação é calculada a partir das contribuições parciais do vetor de entrada. Este cálculo é sumariado pelas equações :

$$\mathbf{W}^T = \Phi^T \mathbf{D} \quad \text{eq. 3.31}$$

$$(\mathbf{D})_{nk} = d_k^n \quad \text{eq. 3.32}$$

$$(\Phi)_n = [\phi_j^1(x_1^n) \quad \phi_j^2(x_2^n) \quad \phi_j^3(x_3^n) \quad \phi_j^4(x_4^n)] \quad \text{eq. 3.33}$$

$$\text{onde } j = \begin{cases} 1, \dots, K^1 & \text{para } \phi_j^1(x_1^n) \\ 1, \dots, K^2 & \text{para } \phi_j^2(x_2^n) \\ 1, \dots, K^3 & \text{para } \phi_j^3(x_3^n) \\ 1, \dots, K^4 & \text{para } \phi_j^4(x_4^n) \end{cases}$$

$$\phi_j^r(x) = 1 - e^{\left(-\frac{(v_r^j(x))^2}{2\sigma_r} \right)} \quad \text{eq. 3.34}$$

$$v_r^j(x) = \|x - \mu_j^r\| \quad \text{eq. 3.35}$$

A resposta gerada por um neurônio da camada de saída, z ($z = 1, \dots, 5$), será :

$$y^z = \sum_{i=1}^{K^1} w_{zi} \phi(\|x_1 - \mu_i^1\|) + \sum_{i=1}^{K^2} w_{z(i+k^1)} \phi(\|x_2 - \mu_i^2\|) + \sum_{i=1}^{K^3} w_{z(i+k^1+k^2)} \phi(\|x_3 - \mu_i^3\|) + \sum_{i=1}^{K^4} w_{z(i+k^1+k^2+k^3)} \phi(\|x_4 - \mu_i^4\|) \quad \text{eq. 3.36}$$

A descrição dos símbolos adicionais utilizados na determinação da matriz de pesos W pode ser visualizada na Lista 3.6.

Lista 3.6 - Sumário dos símbolos adicionais utilizados na determinação da matriz W

- i, j, z – Símbolos utilizados como índices dos vetores y e ϕ e da matriz W .
- y^z – Elemento z do vetor de saída da rede RBF.
- σ_r – Valor da largura da função radial para o subconjunto de neurônios r .
- v_r^j – Valor da distância euclidiana em relação ao centro j pertencente ao subconjunto de neurônios r .
- ϕ_j^r – Valor da ativação do neurônio j pertencente ao subconjunto de neurônios r .
- Φ – Matriz ativação para todo o conjunto de treinamento.
- d_k^n – Elemento k do vetor dos valores desejados para o padrão n .
- D – Matriz dos valores desejados para todo o conjunto de treinamento.
- w_{ji} – Elemento (j,i) da matriz de pesos W .
- W – Matriz de pesos para a camada de saída.

Observação: Como pode ser observado nos passos 3,4 e 5 do algoritmo *K-Means Clustering*, apenas os dados relativos às situações normais foram utilizados para a determinação dos centros; os dados de situações de falta, em conjunto com os dados de situações normais, só foram utilizados na segunda etapa do treinamento da rede RBF (determinação da matriz de peso W). Essa técnica só pôde ser utilizada devido a topologia da rede RBF apresentada. Destaca-se como maior vantagem desta abordagem a necessidade de um menor número de neurônios na camada intermediária para obtenção de um treinamento satisfatório.

*MODELAGEM DO SISTEMA ELÉTRICO E DO RELÉ DIGITAL
UTILIZADOS*

4.1 O Sistema Elétrico de Potência

4.1.1 Topologia do SEP

Com o intuito de se obter dados para o desenvolvimento dos algoritmos de proteção de linhas de transmissão, utilizou-se um sistema de potência de 440 kV, com 4 barras e três linhas de transmissão. O diagrama unifilar deste sistema, juntamente com o comprimento das linhas de transmissão, potência de cada fonte e respectivos equivalentes elétricos podem ser observados na Figura 4.1.

Figura 4.1 – Diagrama unifilar do SEP utilizado

No desenvolvimento do trabalho será considerado como relé base para o desenvolvimento dos algoritmos de proteção o relé destacado na figura acima.

Com base neste sistema existem 10 diferentes tipos de faltas que podem ocorrer ao longo das linhas de transmissão:

- 3 faltas do tipo fase-terra (AT, BT, CT);
- 3 faltas do tipo fase-fase (AB, BC, AC);
- 3 faltas do tipo 2 fase-fase-terra (ABT, BCT, ACT);
- 1 falta do tipo trifásico (ABC) com ou sem conexão à terra.

Uma falta do tipo fase-fase-terra (ABT) no sistema mostrado na Figura 4.1 a 30 km do barramento 2 (falta localizada entre os barramentos 2 e 3) e com uma resistência de falta de 1Ω pode ser observada na Figura 4.2, no que diz respeito às formas de ondas visualizadas no barramento 2.

Figura 4.2 – Formas de onda observadas pelo barramento 2 para uma falta tipo ABT

4.1.2 Modelagem das Linhas de Transmissão

No processo de modelagem do sistema de potência utilizou-se um modelo de linha de transmissão presente no sistema de transmissão da Companhia Energética de São Paulo (CESP). A geometria da torre das LTs, assim como as especificações dos condutores presentes nas linhas de transmissão, podem ser observadas a seguir.

Figura 4.3 – Geometria da torre das linhas de transmissão

Deve-se ressaltar que no processo de simulação (vide 4.1.3), adotou-se a transposição ideal das linhas de transmissão. Abaixo são apresentadas as especificações referentes aos condutores empregados, onde podem ser observadas as suas características:

Condutores

- diâmetro interno do condutor : 4,635 mm;
- resistência em corrente contínua : 0,089898 Ω/km .

Cabo pára-raios

- diâmetro interno do condutor : 4,572 mm;
- resistência em corrente contínua : 0,35961 Ω/km .

4.1.3 Simulação do SEP

Dentro de um projeto de uma RNA faz-se necessária a disposição de uma grande quantidade de dados de situações de falta para que os processos de treinamento e teste sejam realizados. Observando este fato, e considerando que as companhias de transmissão de energia não possuem um banco de dados com situações de falta tão grande, a utilização de um *software* para simulação de sistemas elétricos de potência torna-se necessária.

Para a análise do sistema elétrico proposto utilizou-se o *software* PSCAD / EMTDC (MANITOBA, 1998). O *software* PSCAD/EMTDC é um *software* desenvolvido para a simulação de redes elétricas sendo que em seu ambiente é possível modelar elementos tais como:

- resistores, capacitores e indutores;
- bobinas mutuamente acopladas tais como transformadores;
- linhas de transmissão dependente da frequência;
- fontes de tensão e corrente;
- chaves e disjuntores;
- diodos e tiristores;
- funções de controle analógico e digital;
- máquinas AC;
- medidores de tensão e corrente;
- sistemas HVDC e dispositivos FACTS.

Além da modelagem destes diversos elementos, o *software* PSCAD/EMTDC possui uma avançada interface gráfica que permite a montagem do

circuito, execução da simulação, análise dos resultados e gerenciamento dos dados dentro do mesmo ambiente.

Como típicas aplicações deste *software* pode-se citar :

- Estudos para coordenação de relés;
- Coordenação de isolamento para transformadores e disjuntores;
- Estudos de ressonância subsíncrona para redes com máquinas e linhas de transmissão.
- Projetos de filtros e análise harmônica;
- Projetos de sistemas de controle e coordenação para FACTS e HVDC;
- Determinação ótima de parâmetros de controle;
- Investigação de novos circuitos e conceitos de controle.

A partir então deste *software* será possível a realização de várias simulações onde serão variados os seguintes parâmetros do sistema elétrico :

- fluxo de potência no sistema;
- distância do ponto de falta (em relação a um determinado barramento);
- resistência de falta ;
- ângulo de incidência da falta;
- tipo de falta.

No presente trabalho, o *software* será responsável pela geração de um banco de dados composto de valores trifásicos de tensão e corrente em um determinado ponto do sistema elétrico. Através deste banco de dados serão então criados e testados os algoritmos para detecção e classificação de faltas.

4.2 Componentes Básicos do Relé Digital

O relé digital constitui no principal elemento de processamento no diagnóstico de faltas em um sistema de potência, sendo então que sua precisa modelagem é de fundamental importância.

Qualquer relé digital pode ser visto como a composição de três subsistemas fundamentais (JOHNS e SALMAN, 1988) :

- subsistema de acondicionamento do sinal;
- subsistema de conversão do sinal ;
- subsistema de processamento digital do sinal.

Cada subsistema é constituído por um certo número de componentes que serão detalhados a seguir. O esquema geral de um relé digital pode ser observado na Figura 4.4.

4.3 Subsistema de acondicionamento do sinal

4.3.1 Transdutores

As tensões e correntes originárias de um sistema de potência possuem uma alta magnitude. Uma redução do nível destes sinais se faz necessária visto o nível utilizado pelos relés digitais – correntes de 1A a 5A e tensões de 110V a 220V. Normalmente esta redução é feita através de transformadores de corrente e tensão (TCs e TPs).

Neste trabalho foram utilizados TCs e TPs ideais (isto é, as características não lineares presentes nos dispositivos foram assumidas lineares) com as seguintes razões de transformação :

- TC: 250:1 ;
- TP: 4000:1 .

Figura 4.4 – Esquema geral de um relé digital

4.3.2 Circuito para proteção de surtos

As tensões e correntes provenientes dos secundários dos TCs e TPs são normalmente conectadas a circuitos para proteção de surtos. Estes circuitos são compostos tipicamente por capacitores e transformadores de isolamento. Estes elementos não foram modelados neste trabalho.

4.3.3 Filtros Passa-Baixa

Normalmente utiliza-se a filtragem analógica dos sinais provenientes dos TCs e TPs, visto o alto conteúdo harmônico que estes podem apresentar. Na prática, o quanto o sinal deve ser filtrado depende das necessidades de um determinado relé digital, sendo que normalmente utilizam-se filtros passa baixa para a remoção de sinais indesejados de alta frequência.

Outro aspecto que impõe o processo de filtragem é a dependência do processo de amostragem em relação ao conteúdo harmônico do sinal. Pelo teorema de *Nyquist*, a frequência amostral de um sinal deve ser no mínimo duas vezes maior que a maior frequência contida no sinal original, isto é:

$$f_a \geq 2f_m \quad \text{eq. 4.1}$$

onde f_a é a frequência amostral e f_m é a maior frequência contida no sinal (frequência de corte) a ser amostrado.

A Figura 4.5(a) mostra as características ideais de um filtro passa baixa. Nela observa-se que as componentes do sinal abaixo da frequência de corte são transferidas com atenuação zero, enquanto as componentes acima da frequência de corte são atenuadas a zero.

Na Figura 4.5(b) observa-se o comportamento de um filtro passa baixa real. Nota-se que na prática é impossível se obter uma transição brusca da banda de passagem para a banda de rejeição.

Figura 4.5 – Características de um filtro passa baixa – (a) caso ideal; (b) caso real

As características dinâmicas dos filtros passa-baixa assim como suas características em regime são de fundamental importância. Entre elas destacam-se:

- O tempo de subida, característica que indica quanto tempo a saída de um filtro passa baixa demora para atingir valor de regime permanente pela primeira vez;
- O *overshoot*, característica que indica o quanto a saída do filtro irá ultrapassar o seu valor em regime;
- O tempo de acomodação, indica quanto tempo o filtro demora até atingir e permanecer em uma vizinhança do seu valor em regime.

Todas as características acima atuam na resposta dinâmica dos sistemas de proteção digital. Deve-se ressaltar que em sistemas de decisão ultra-rápidos, o processo de filtragem deve ser projetado com uma frequência de corte que proporcione o melhor desempenho e que ao mesmo tempo não proporcione longos atrasos na filtragem (JOHNS e SALMAN, 1988).

Neste trabalho utilizou-se o filtro do tipo *Butterworth* de 3ª ordem com frequência de corte de 400 Hz. Pode-se citar como fatores para a escolha deste tipo de filtro o seu baixo *overshoot* e seu rápido tempo de acomodação. A frequência amostral utilizada foi de 1 kHz. Maiores informações sobre filtros podem ser encontradas em (MATHWORKS, 1988).

4.4 Subsistema de conversão do sinal

4.4.1 Circuito *Sample and Hold*

O relé digital é um dispositivo que trabalha com múltiplas entradas (sinais de tensão e corrente). Para que ele possa fazer uma correta análise do sinal é desejável que todos os sinais sejam amostrados simultaneamente. Uma possível solução para este problema seria o emprego de vários conversores A/D operando simultaneamente e disponibilizando, assim, os vários sinais digitais para a CPU do relé. Apesar desta ser uma solução fisicamente possível, ela é inviável economicamente devido ao alto custo de um conversor A/D. O esquema de funcionamento desta filosofia pode ser observada na Figura 4.6.

Figura 4.6 – Processo de amostragem para múltiplas entradas – Um conversor A/D para cada canal

Uma solução alternativa para este problema é o emprego de vários circuitos conhecidos como *Sample and Hold* em conjunto com um circuito multiplexador. Neste esquema o circuito *Sample and Hold* é responsável pela amostragem e armazenamento do sinal de entrada para que o conversor A/D (único neste esquema) possa realizar as várias conversões existentes para cada instante de amostragem. Estes vários circuitos em conjunto com um circuito multiplexador (explicado a seguir) possibilitam uma solução economicamente viável ao processo de amostragem do sinal. Este esquema pode ser observado na Figura 4.7.

Figura 4.7 - Processo de amostragem para múltiplas entradas – Utilização do circuito *Sample and Hold*

4.4.2 Circuito Multiplexador

Um circuito multiplexador é um dispositivo que seleciona um sinal a partir de um certo número de entradas e o transfere para uma saída, possibilitando assim a transmissão de vários sinais através de um mesmo canal serial. O princípio de multiplexação pode ser visualizado na Figura 4.8.

Figura 4.8 – Princípio do circuito multiplexador

Deve-se salientar que nem os circuitos *Sample and Hold* nem o circuito Multiplexador foram modelados neste trabalho.

4.4.3 Conversor A/D

A principal função do conversor A/D é a conversão de um sinal analógico para a sua representação digital. Ele possui como principal característica o comprimento da palavra em *bits* que ele consegue manipular (PHADKE e THORP, 1988).

Considere um conversor A/D de 12 bits. Um conversor deste tipo consegue então representar 2^{12} (= 4096) diferentes palavras de 12 bits. Considere agora que o sinal de entrada analógico possa variar entre ± 10 volts. Constata-se a partir destes dados que o conversor A/D é capaz de representar sinais analógicos em intervalos de $20/4096$ volts ou 4,883 milivolts. Percebe-se então que a representação fornecida pelo conversor A/D está sujeita a erros, visto o número finito de valores que ele consegue representar. Esta característica é conhecida como erro de quantização do conversor A/D.

Em geral, se o comprimento da palavra do conversor A/D é de N bits e a tensão máxima de entrada do conversor A/D é dada por V volts, o máximo erro de quantização q é dado por

$$q = \frac{2V}{2 \times 2^N} = 2^{-N} V \quad \text{eq. 4.2}$$

Este erro pode ser melhor observado na Figura 4.9.

Figura 4.9 – Ilustração do erro de quantização devido à conversão A/D

Na modelagem do conversor A/D deste trabalho utilizou-se um comprimento de palavra de 12 bits e tensões máxima e mínima de +110 e -110 V respectivamente.

4.5 Subsistema de processamento digital do sinal

O subsistema de processamento digital do sinal é constituído tanto pelo *software* quanto pelo *hardware*. O *hardware* consiste basicamente da unidade central de processamento (CPU), de dispositivos de memória e dos dispositivos para entrada e saída de dados. O *software* corresponde ao princípio básico de operação do relé (relé de distância, direcional, etc.) acrescido de algumas rotinas que possibilitam o correto funcionamento do relé tais como: rotinas para manipulação de dados de entrada e saída, rotinas para autochecagem do *hardware*, etc. O *software* é implementado através de alguma linguagem de programação e é compilado para o modelo de CPU presente em seu *hardware*.

Deve-se ressaltar então que os algoritmos desenvolvidos ao longo deste trabalho corresponderão ao módulo principal do *software*, isto é, ao princípio básico de operação.

O CONJUNTO DE TREINAMENTO PARA AS RNAs CONSIDERADAS E O ALGORITMO FINAL PARA DETECÇÃO E CLASSIFICAÇÃO DE FALTAS

5.1 Descrição do Conjunto de Simulações para Treinamento

O primeiro passo para o projeto de uma rede neural artificial para o reconhecimento de padrões consiste na preparação de um conjunto de simulações que contenha situações características do sistema a ser aprendido. Como o objetivo deste trabalho consiste na elaboração de uma rede neural do tipo MLP e uma rede neural do tipo RBF para as tarefas de detecção e classificação de faltas, o conjunto de simulações a ser constituído deve possuir então situações características das possíveis faltas que possam ocorrer dentro do sistema de potência escolhido.

Sabe-se de antemão que características como resistência, ângulo de incidência, distância e tipo de falta, bem como fluxo de potência influenciam fortemente na forma de onda lida pelos relés durante situações de falta (DALSTEIN e KULICKE, 1995). Outra característica que será também abordada na elaboração da rede neural será a influência da quantidade de padrões utilizados durante a fase de treinamento na qualidade e precisão da resposta obtida durante a fase de testes.

Observando-se estes fatores, projetaram-se 3 conjuntos de simulações relativas ao SEP mostrado no capítulo anterior - Figura 4.1.

Os dois primeiros conjuntos (conjuntos I e II) são compostos por 320 e 80 diferentes simulações respectivamente, sendo que em cada simulação um ou mais dos seguintes parâmetros - resistência de falta, ângulo de falta, distância de falta e tipo de falta - foram variados. Os parâmetros para estes conjuntos podem ser visualizados nas Tabela 5.1 e Tabela 5.2.

O terceiro conjunto de simulações (conjunto III) é composto apenas por 10 situações de faltas. Ele possui o mesmo valor de fluxo de carga dos conjuntos anteriores, apresentando resistência de falta igual a $1\ \Omega$ e distância de falta igual a 1 km. Os demais parâmetros para cada situação de falta podem ser visualizados na Tabela 5.3.

Tabela 5.1 - Relação dos parâmetros utilizados para o conjunto de simulações I (Total=320)

Fluxo de Carga	Fonte 1 = $1,0\angle 10$ Fonte 2 = $0,9\angle 0$
Resistência de Falta	1 e 200 Ω
Ângulo de Falta ²	0, 45, 90, 135, 180, 225, 270 e 315°
Distância de Falta ³	1 e 149 km
Tipo de Falta	AT, BT, CT, ABT, ACT, BCT, AB, AC, BC, ABC

Tabela 5.2 - Relação dos parâmetros utilizados para o conjunto de simulações II (Total=80)

Fluxo de Carga	Fonte 1 = $1,0\angle 10$ Fonte 2 = $0,9\angle 0$
Resistência de Falta	1 Ω
Ângulo de Falta ¹	0, 45, 90, 135, 180, 225, 270 e 315°
Distância de Falta ²	1 km
Tipo de Falta	AT, BT, CT, ABT, ACT, BCT, AB, AC, BC, ABC

Tabela 5.3 - Relação dos parâmetros utilizados para o conjunto de simulações III (Total=10)

Simulação	Tipo de Falta	Ângulo de Falta ¹
1 ^a	AT	0°
2 ^a	BT	45°
3 ^a	CT	90°
4 ^a	ABT	135°
5 ^a	ACT	180°
6 ^a	BCT	225°
7 ^a	AB	270°
8 ^a	AC	315°
9 ^a	BC	0°
10 ^a	ABC	45°

² Ângulos relativos à onda de tensão da fase A lida pelo relé base

³ Distâncias relativas à barra 2 para faltas compreendidas entre a barra 2 e a barra 3

5.2 Descrição do Banco de Dados para Treinamento

Para o treinamento das redes neurais para detecção e classificação de faltas em um sistema elétrico, determinou-se que o banco de dados para treinamento possuiria dados para situações normais e dados para situações de falta. Estes dados são compostos basicamente por três amostras consecutivas de cada corrente (I_A , I_B , I_C), mais três amostras consecutivas da corrente de sequência 0 (I_0) para estas situações. Na Figura 5.1 exemplificam-se as amostras utilizadas durante o treinamento para uma determinada fase.

Figura 5.1 – Descrição das amostras utilizadas para o treinamento da rede neural

A partir então desta regra de formação, obtiveram-se 3 bancos de dados. Os bancos I, II e III são compostos por 640, 160 e 20 padrões respectivamente, derivados dos conjuntos de simulações I, II e III.

Para a fase de treinamento, estipulou-se que para padrões em situação normal, a saída do neurônio de detecção deveria ser igual a 0, enquanto que para uma situação de falta, a saída deveria ser igual a 1. Uma convenção semelhante também foi utilizada para a determinação do tipo de falta. Determinou-se que para as fases envolvidas na falta, o valor de saída do neurônio de classificação deveria ser igual a

1, enquanto que o valor de saída para as fases não envolvidas deveria ser igual a 0. Esta convenção pode ser visualizada na Tabela 5.4.

Tabela 5.4 - Convenção utilizada no treinamento da rede neural

	Valor de saída para detecção	Valor de saída para a fase A	Valor de saída para a fase B	Valor de saída para a fase C	Valor de saída para a terra
Situação Normal	0	0	0	0	0
Falta AT	1	1	0	0	1
Falta BT	1	0	1	0	1
Falta CT	1	0	0	1	1
Falta AB	1	1	1	0	0
Falta AC	1	1	0	1	0
Falta BC	1	0	1	1	0
Falta ABT	1	1	1	0	1
Falta ACT	1	1	0	1	1
Falta BCT	1	0	1	1	1
Falta ABC	1	1	1	1	0

5.3 Topologia das RNAs projetadas

Como destacado no item 3.5, neste trabalho foram utilizadas, para ambas as redes, topologias parcialmente conectadas. Após exaustiva busca, estabeleceram-se as melhores configurações para a rede do tipo MLP e do tipo RBF focalizadas neste trabalho. Essas configurações são:

rede MLP:

- camada de entrada: 12 neurônios;
- camada intermediária: 14 neurônios (4 conectados em I_A , 4 em I_B , 4 em I_C e 2 em I_0);
- camada de saída: 5 neurônios.

rede RBF:

- camada de entrada: 12 neurônios;
- camada intermediária: 25 neurônios (8 conectados I_A , 8 em I_B , 8 em I_C e 1 em I_0) ;
- camada de saída: 5 neurônios.

5.4 O Funcionamento do Algoritmo Final de Detecção e Classificação Utilizando RNAs

Até agora foi explicado como as redes neurais utilizadas para detecção e classificação foram projetadas. Porém, considerando-se um algoritmo final que execute estas tarefas, deve ser enfatizado que, as mesmas não funcionam de maneira independente e sim de uma maneira coordenada. Esse funcionamento é descrito no fluxograma da Figura 5.2.

Nele pode-se observar que a tarefa de classificação só entra em funcionamento quando a tarefa de detecção indica a existência de uma falta por duas janelas consecutivas. Nota-se também que esta lógica é válida para a classificação, isto é, uma classificação só é tomada como válida caso esta seja indicada por duas janelas consecutivas.

Figura 5.2 – Fluxograma do funcionamento do conjunto de algoritmos de detecção e de classificação

O funcionamento do fluxograma é apresentado a seguir:

Detecção: Inicialmente assume-se o instante de tempo t igual a 1. Determinado o instante de tempo, faz-se a leitura da primeira janela de dados, janela composta pelos elementos: $I_A^1, I_A^2, I_A^3, I_B^1, I_B^2, I_B^3, I_C^1, I_C^2, I_C^3, I_0^1, I_0^2, I_0^3$. Uma vez composta a janela, calcula-se o valor da saída do neurônio de detecção. Caso o valor de saída seja igual a 1 e o valor de saída da janela anterior também for igual a 1, assume-se que o sistema está em situação de falta, e portanto, dispara-se a tarefa seguinte para o cálculo do tipo de falta, caso contrário, incrementa-se o valor de t ($t=t+1$) e refaz-se o procedimento.

Classificação: Uma vez detectada a falta, a classificação entra em ação. Para a composição da primeira janela de dados para a classificação, admite-se como primeira amostra pós-falta a amostra correspondente ao instante $t+2$. Esta amostra é admitida como a primeira amostra pós-falta pois ela é a última amostra da primeira janela de dados onde a detecção sinalizou a existência de falta. Uma vez composta a janela, calcula-se o tipo de falta que está ocorrendo e caso esta falta seja igual a falta calculada anteriormente, assume-se que o tipo de falta é igual ao tipo calculado, caso contrário incrementa-se o valor de t e refaz-se o procedimento.

Deve-se ressaltar que para a primeira iteração em ambos os casos não existe uma janela anterior que se possa realizar a comparação, fazendo-se necessário então a realização de uma nova iteração.

Os resultados relativos aos testes realizados com as redes MLP e RBF podem ser observados no próximo capítulo.

**TESTES DE DESEMPENHO PARA AS REDES NEURAIAS MLP E
RBF**

6.1 Criação do Banco de Dados para Testes

Para a realização dos testes relativos ao funcionamento do conjunto detecção e classificação para as redes consideradas, elaborou-se um banco de dados composto por 960 novas situações de falta, sendo que em cada situação um ou mais dos seguintes parâmetros foram variados :

Tabela 6.1 - Relação dos parâmetros utilizados para o banco de dados para teste (Total=960)

Fluxo de Carga	1) Fonte 1 = $1,0\angle 10$ Fonte 2 = $0,9\angle 0$ 2) Fonte 1 = $1,05\angle 5$ Fonte 2 = $0,95\angle 0$
Resistência de Falta	20, 70 e 150 Ω
Ângulo de Falta ⁴	30, 100, 205 e 340°
Distância de Falta ⁵	10, 50, 90 e 130 km
Tipo de Falta	AT, BT, CT, ABT, ACT, BCT, AB, AC, BC, ABC

⁴ Ângulos relativos à onda de tensão da fase A lida pelo relé base

⁵ Distâncias relativas à barra 2 para faltas compreendidas entre a barra 2 e a barra 3

6.2 Análise dos Resultados para a rede tipo MLP

6.2.1 Módulo de Detecção

Utilizando-se o banco de dados descrito anteriormente, as RNAs do tipo MLP descritas no capítulo anterior, sujeitas a diferentes conjuntos de treinamento, foram submetidas a 960 casos de falta, com o intuito de observar-se a sua precisão quanto à tarefa de detecção. Durante esta série de testes, admitiu-se que um valor de saída do módulo de detecção só seria tomado como definitivo quando houvesse a indicação da existência de falta por duas janelas consecutivas (para tanto, assumiu-se que para valores de saída iguais ou maiores a 0,5 o sistema encontrava-se em situação de falta), como descrito no capítulo anterior.

Através destes testes, foram formulados um gráfico e uma série de tabelas para a avaliação destas RNAs. Inicialmente, apresenta-se um gráfico com a comparação do desempenho destas RNAs, onde se destaca a percentagem de testes detectados corretamente em relação ao tempo para a ocorrência da detecção. Posteriormente são apresentadas algumas tabelas com os valores de saída para a tarefa de detecção.

Figura 6.1 – Gráfico do desempenho das 3 RNAs do tipo MLP para a tarefa de detecção

Na Figura 6.1. é apresentado o desempenho das 3 RNAs do tipo MLP para a tarefa de detecção em relação ao banco de dados de testes. A figura mostra, para as três redes utilizadas, a percentagem de padrões com relação ao total, que foram classificados com 2,3,4,5, e mais de 10 ms. É importante ressaltar que a percentagem total de acertos de uma determinada rede consiste na soma das percentagens para os diferentes tempos de detecção. Com o intuito de maior esclarecimento, a última coluna se refere ao índice global de acerto para cada rede considerada. Através deste gráfico é possível perceber a dependência da qualidade da resposta das redes do tipo MLP com o número de padrões existentes no banco de dados para treinamento. Nota-se que a rede I (rede treinada com 640 padrões) possui o melhor desempenho, apresentando 100% de acerto e detectando 43% dos testes com apenas 2 ms. A rede II (rede treinada com 160 padrões) apresenta uma degradação na qualidade da resposta, detectando apenas 24% dos testes com 2 ms, mas ainda apresentando 100% de acerto para o conjunto de teste. A rede III é a rede mais lenta para a detecção, sendo que dos 960 testes, em 90 testes (9,4%) não houve a detecção da existência de falta. Nota-se então que a rede MLP, para o estudo em questão, apresenta-se dependente da quantidade de dados disponível, visto a degradação da velocidade e qualidade da resposta com a diminuição do tamanho do banco de dados para treinamento.

6.2.2 Módulo de Detecção – Tabelas

A seguir, apresentam-se algumas tabelas pertencentes ao conjunto de testes para o módulo de detecção da rede I. Nelas pode-se observar o comportamento do módulo de detecção frente aos diversos testes.

Na primeira tabela (Tabela 6.2) verificam-se as respostas do módulo detector para faltas do tipo fase-terra com os seguintes parâmetros: ângulo de incidência de falta = 340° , resistência de falta = 70Ω , distância de falta = 10, 50, 90 e 130 km, fluxo de carga = 1. Em seguida, mostram-se as tabelas para as faltas fase-fase-terra, fase-fase e trifásica (Tabela 6.3, Tabela 6.4 e Tabela 6.5) para os mesmos parâmetros.

Tabela 6.2 - Teste do módulo de detecção para faltas fase-terra (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)

Distância (km)	Falta AT		Falta BT		Falta CT	
	Tempo para detecção (ms)	Resposta Obtida	Tempo para detecção (ms)	Resposta Obtida	Tempo para detecção (ms)	Resposta Obtida
10	3	1,000	2	1,000	2	1,000
50	3	1,000	3	1,000	2	1,000
90	3	1,000	3	1,000	3	1,000
130	4	1,000	3	1,000	3	1,000

Tabela 6.3 - Teste do módulo de detecção para faltas fase-fase-terra (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)

Distância (km)	Falta ABT		Falta ACT		Falta BCT	
	Tempo para detecção (ms)	Resposta Obtida	Tempo para detecção (ms)	Resposta Obtida	Tempo para detecção (ms)	Resposta Obtida
10	2	1,000	2	1,000	2	0,635
50	3	1,000	3	1,000	3	1,000
90	3	1,000	3	1,000	3	1,000
130	3	1,000	3	1,000	3	1,000

Tabela 6.4 - Teste do módulo de detecção para faltas fase-fase (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)

Distância (km)	Falta AB		Falta AC		Falta BC	
	Tempo para detecção (ms)	Resposta Obtida	Tempo para detecção (ms)	Resposta Obtida	Tempo para detecção (ms)	Resposta Obtida
10	3	1,000	3	1,000	3	1,000
50	3	1,000	3	1,000	3	1,000
90	3	1,000	3	1,000	3	1,000
130	3	1,000	3	1,000	3	1,000

Tabela 6.5 Teste do módulo de detecção para faltas trifásicas (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)

Distância (km)	Falta ABC	
	Tempo para detecção (ms)	Resposta Obtida
10	3	1,000
50	3	1,000
90	3	1,000
130	3	1,000

6.2.3 Módulo de Classificação

Utilizando-se o mesmo banco de dados descrito anteriormente, submeteu-se as 3 redes neurais projetadas à tarefa de classificação dos 960 casos considerados. Durante esta série de testes, admitiu-se que um conjunto de valores só seria tomado como classificação definitiva quando houvesse a existência de uma mesma saída por duas janelas consecutivas (utilizou-se a convenção que valores de saída maiores ou iguais a 0,5 seriam considerados como 1,0). Deve-se destacar também que a primeira janela de dados submetida às redes era constituída pelas primeiras 3 amostras pós-falta.

Seguindo este raciocínio construiu-se o gráfico a seguir:

Figura 6.2 – Gráfico do desempenho das 3 RNAs do tipo MLP para a tarefa de classificação

Analisando o gráfico acima, percebe-se claramente o alto desempenho da rede I. Nele fica evidenciado que a grande maioria dos testes (872 casos) é classificado corretamente com apenas 4ms. Além da alta velocidade de classificação mostrada por esta rede, deve-se ressaltar também a sua alta confiabilidade, visto que 945 casos (98,4%) foram classificados corretamente. Assim como na detecção, mais uma vez percebe-se a degradação da velocidade e precisão para as redes treinadas com um conjunto de treinamento menor. Enquanto a rede II possui uma resposta mais lenta que a rede I e uma taxa de acerto de 84%, a rede III praticamente não funciona, apresentando uma taxa de acerto de 17,3% nos testes realizados.

A análise anterior demonstra o alto desempenho da tarefa de classificação para a rede I. Porém, esta análise por si só não se faz conclusiva, uma vez que a tarefa de classificação deve trabalhar em conjunto com a tarefa de detecção. Faz-se então necessária uma análise do desempenho do conjunto de detecção e classificação. Esta análise será abordada no item 6.2.5.

6.2.4 Módulo de Classificação – Tabelas

A seguir apresentam-se algumas tabelas pertencentes ao conjunto de testes feito no módulo de classificação pertencente a rede I. Nelas podem-se observar o comportamento do módulo frente aos diversos testes.

Na primeira tabela (Tabela 6.6) apresentam-se as respostas do módulo de classificação para faltas do tipo AT com os seguintes parâmetros: ângulo de incidência de falta = 340° , resistência de falta = 70Ω , distância de falta = 10, 50, 90 e 130 km, fluxo de carga = 1. Em seguida mostram-se as tabelas para as faltas BCT, AC e ABC (Tabela 6.7, Tabela 6.8 e Tabela 6.9) para os mesmos parâmetros.

Tabela 6.6 - Teste do módulo de classificação para uma falta tipo AT (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)

Distância (km)	Tempo para classificação (ms)	Falta AT Resposta Obtida			
		Fase A	Fase B	Fase C	Terra
10	5	1,000	0,000	0,000	1,000
50	5	1,000	0,000	0,000	1,000
90	5	1,000	0,000	0,000	1,000
130	6	1,000	0,000	0,000	1,000

Tabela 6.7 - Teste do módulo de classificação para uma falta tipo BCT (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)

Distância (km)	Tempo para classificação (ms)	Falta BCT Resposta Obtida			
		Fase A	Fase B	Fase C	Terra
10	5	0,000	1,000	1,000	1,000
50	5	0,000	1,000	1,000	1,000
90	6	0,000	1,000	1,000	1,000
130	6	0,000	1,000	1,000	1,000

Tabela 6.8 - Teste do módulo de classificação para uma falta tipo AC (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)

Distância (km)	Tempo para classificação (ms)	Falta AC Resposta Obtida			
		Fase A	Fase B	Fase C	Terra
10	5	1,000	0,000	1,000	0,000
50	5	1,000	0,000	1,000	0,000
90	5	1,000	0,000	1,000	0,000
130	5	1,000	0,000	1,000	0,000

Tabela 6.9 - Teste do módulo de classificação para uma falta tipo ABC (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)

Distância (km)	Tempo para classificação (ms)	Falta ABC Resposta Obtida			
		Fase A	Fase B	Fase C	Terra
10	5	1,000	1,000	1,000	0,000
50	5	1,000	1,000	1,000	0,000
90	5	1,000	1,000	1,000	0,000
130	5	1,000	1,000	1,000	0,000

6.2.5 Análise do Conjunto Detecção e Classificação

Para a análise conjunta da detecção e classificação, utilizou-se o fluxograma descrito na Figura 5.2. Nele percebe-se que a classificação funciona em conjunto com a detecção, sendo que a classificação só entra em funcionamento após a detecção sinalizar a existência de uma falta por duas janelas consecutivas. Admitiu-se também que um conjunto de valores de saída da classificação só seria tomado como uma classificação definitiva quando houvesse a existência de uma mesma classificação por duas janelas consecutivas.

A partir desta lógica de funcionamento, formulou-se o gráfico a seguir onde podem ser observadas as distribuições dos tempos de detecção e classificação.

Figura 6.3 – Gráfico do desempenho das 3 RNAs do tipo MLP para a tarefa de detecção e classificação

Nota-se agora que o desempenho da classificação em termos de velocidade de atuação sofre uma degradação devido ao funcionamento da detecção. Isto acontece devido ao tempo que a detecção leva para chegar a uma decisão. Ao contrário do que acontecia no item 6.2.3 onde a rede era submetida a uma janela de dados composta pelas 3 primeiras amostras pós-falta, no presente exemplo esta janela é definida pela detecção. Por outro lado, este atraso permitiu que os casos classificados erroneamente pela rede I fossem classificados corretamente. Isto aconteceu pois todos os casos que foram classificados erroneamente para esta rede, foram assim classificados pois as duas primeiras janelas utilizadas para teste de classificação (item 6.2.3) não apresentavam informação suficiente para a caracterização da falta pela rede. Um exemplo para a tarefa de detecção e classificação onde a classificação é feita erroneamente nas primeiras duas janelas pós-falta e depois feita corretamente pode ser observado na Tabela 6.15.

Destaca-se uma vez mais que a rede I é a rede que apresenta melhor desempenho, sendo a única a apresentar 100% de acerto. A rede II, nesta série de testes, apresentou 85,1% de acerto (817 casos), enquanto que a rede III apresentou 41,1% de acertos (395 casos).

6.2.6 Análise do Conjunto Detecção e Classificação – Tabelas

Para exemplificar o funcionamento dos algoritmos de detecção e classificação, apresentam-se a seguir uma série de tabelas onde este funcionamento pode ser observado. Todos os testes a seguir apresentam resultados referentes a rede I.

Nas tabelas a seguir utiliza-se a seguinte convenção relativa a identificação das amostras presentes nas janelas de dados: valor identificado com o sinal (-) indica amostra pré-falta enquanto valor identificado com o sinal (+) indica amostra pós-falta. Ex.:

-3 : Significa que esta amostra corresponde a 3^a amostra pré-falta.

+2 : Significa que esta amostra corresponde a 2^a amostra pós-falta.

Tabela 6.10 – Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω , Ângulo de Falta = 205°, Distância de Falta = 50 km, Tipo de Falta = BT

Janela	Valor de Saída Módulo Detecção
-3 -2 -1	0,001
-2 -1 +1	1,000
-1 +1 +2	1,000

Janela	Valor de Saída Módulo Classificação			
	Fase A	Fase B	Fase C	Terra
+1 +2 +3	0,000	1,000	0,001	1,000
+2 +3 +4	0,000	1,000	0,000	1,000

Como primeiro exemplo, apresenta-se uma falta do tipo BT (parâmetros de simulação descritos na legenda da Tabela 6.10). Este exemplo caracteriza-se pela rápida atuação do módulo de detecção. Nele a falta é identificada com apenas 1 amostra pós-falta (janela = {-2 -1 +1}), sendo que a situação de falta é confirmada pela janela seguinte. Uma vez confirmada a situação de falta, o módulo de classificação possui a sua disposição suas primeiras duas amostras de entradas (para este caso amostras +1, +2), sendo que para a primeira janela de dados para classificação ser

completada, faz-se necessária a espera pela leitura da próxima amostra (amostra +3). Completada a primeira janela de dados para classificação, o módulo faz o cálculo do tipo de falta (BT) que está ocorrendo para esta janela. Uma vez feito o cálculo, faz-se necessária a confirmação deste resultado através do cálculo do tipo de falta para a segunda janela (janela composta pelas amostras {+2, +3, +4}). Mais uma vez o módulo de classificação faz o cálculo obtendo como resposta o tipo BT. Como o tipo obtido é o mesmo da janela anterior, assume-se que a falta em questão é do tipo BT e que esta demorou 4 amostras pós-falta para ser detectada e classificada.

Apresentam-se agora outros 2 conjuntos de tabelas (Tabela 6.11 e a Tabela 6.12), onde podem ser observadas situações de falta onde a detecção ocorre com 3 e 4 amostras pós-falta respectivamente. Os tipos de faltas ilustrados são ACT e AC respectivamente e foram necessárias somente duas janelas para sua classificação.

Tabela 6.11 – Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω , Ângulo de Falta = 205°, Distância de Falta = 10 km, Tipo de Falta = ACT

Janela	Valor de Saída Módulo Detecção
-3 -2 -1	0,001
-2 -1 +1	0,001
-1 +1 +2	1,000
+1 +2 +3	1,000

Janela	Valor de Saída Módulo Classificação			
	Fase A	Fase B	Fase C	Terra
+2 +3 +4	1,000	0,000	1,000	1,000
+3 +4 +5	1,000	0,000	1,000	1,000

Tabela 6.12 – Exemplo do funcionamento detector + classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω , Ângulo de Falta = 205°, Distância de Falta = 130 km, Tipo de Falta = AC

Janela	Valor de Saída Módulo Detecção
-3 -2 -1	0,001
-2 -1 +1	0,001
-1 +1 +2	0,465
+1 +2 +3	1,000
+2 +3 +4	1,000

Janela	Valor de Saída Módulo Classificação			
	Fase A	Fase B	Fase C	Terra
+3 +4 +5	0,917	0,000	1,000	0,000
+4 +5 +6	1,000	0,000	1,000	0,000

Até agora se apresentaram apenas testes onde o módulo de classificação funcionou corretamente para as primeiras duas janelas de classificação. Observado este fato, apresentam-se dois testes (Tabela 6.13 e Tabela 6.14) onde o módulo de classificação fez uso de 3 e 4 janelas para a apresentação do resultado correto.

Tabela 6.13 – Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 70 Ω , Ângulo de Falta = 100°, Distância de Falta = 10 km, Tipo de Falta = ACT

Janela	Valor de Saída Módulo Detecção
-3 -2 -1	0,001
-2 -1 +1	1,000
-1 +1 +2	1,000

Janela	Valor de Saída Módulo Classificação			
	Fase A	Fase B	Fase C	Terra
+1 +2 +3	1,000	0,000	1,000	0,379
+2 +3 +4	0,999	0,000	1,000	1,000
+3 +4 +5	1,000	0,000	1,000	1,000

Tabela 6.14 – Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 150 Ω , Ângulo de Falta = 30°, Distância de Falta = 10 km, Tipo de Falta = ABT

Janela	Valor de Saída Módulo Detecção
-3 -2 -1	0,001
-2 -1 +1	1,000
-1 +1 +2	1,000

Janela	Valor de Saída Módulo Classificação			
	Fase A	Fase B	Fase C	Terra
+1 +2 +3	1,000	1,000	0,000	1,000
+2 +3 +4	1,000	1,000	0,000	0,000
+3 +4 +5	1,000	1,000	0,000	1,000
+4 +5 +6	1,000	1,000	0,000	1,000

Por fim, apresenta-se a Tabela 6.15. Nela, destaca-se o caso comentado no item 6.2.5. Neste teste, nota-se que as janelas {+1 +2 +3} e {+2 +3 +4} foram classificadas como tipo BC, sendo que a classificação correta só começou a partir da janela {+3 +4 +5}, ocasionando assim uma classificação errônea para o teste abordado no item 6.2.3.

Tabela 6.15 – Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω , Ângulo de Falta = 340°, Distância de Falta = 90 km, Tipo de Falta = BCT

Janela	Valor de Saída Módulo Detecção
-3 -2 -1	0,001
-2 -1 +1	0,001
-1 +1 +2	1,000
+1 +2 +3	1,000

Janela	Valor de Saída Módulo Classificação			
	Fase A	Fase B	Fase C	Terra
+1 +2 +3	0,000	1,000	1,000	0,000
+2 +3 +4	0,000	1,000	1,000	0,000
+3 +4 +5	0,000	1,000	1,000	1,000
+4 +5 +6	0,000	1,000	1,000	1,000

6.3 Análise dos Resultados para a Rede tipo RBF

6.3.1 Módulo de Detecção

Utilizando-se ainda o mesmo banco de dados para testes, as 3 RNAs desenvolvidas a partir dos 3 conjuntos de treinamento descritos no capítulo anterior, foram submetidas aos 960 casos de falta abordados na Tabela 6.1. As mesmas considerações que foram feitas para a rede tipo MLP também foram adotadas aqui, isto é, a detecção só foi tomada como definitiva quando ocorresse a indicação da existência de falta por duas janelas consecutivas e assumiu-se que para valores de saída iguais ou superiores a 0,5 o sistema encontrava-se em situação de falta.

Apresenta-se inicialmente um gráfico com a comparação do desempenho destas RNAs.

Figura 6.4 – Gráfico do desempenho das 3 RNAs do tipo RBF para a tarefa de detecção

Analisando-se a Figura 6.4, percebe-se um comportamento atípico entre as redes RBF apresentadas. A rede III (rede treinada com o menor número de padrões) apresenta um maior número de detecções realizado com 2 ms do que as redes II e III. Porém, este melhor desempenho inicial é compensado pelas redes I e II para detecções realizadas com 3 ms, resultando assim em um desempenho médio

semelhante para as 3 redes para o conjunto de detecções realizado com 2 e 3 ms. Este fato provavelmente está relacionado a escolha do conjunto de treinamento III. Observa-se também que as redes I e II apresentam desempenhos semelhantes para todos os instantes.

Ao contrário do que aconteceu com as redes tipo MLP, onde a diminuição do número de padrões de treinamento ocasionou uma grande degradação da velocidade e qualidade da resposta da rede, a rede tipo RBF praticamente não apresentou perda de velocidade e nem de qualidade da resposta com esta diminuição, mostrando assim uma maior independência em relação ao conjunto de treinamento.

6.3.2 Módulo de Detecção – Tabelas

A seguir, apresentam-se algumas tabelas pertencentes ao conjunto de testes feito no módulo de detecção. Nelas pode-se observar o comportamento do módulo frente aos diversos testes.

Na primeira tabela (Tabela 6.16), apresentam-se as respostas do módulo detector para faltas do tipo fase-terra com os seguintes parâmetros: ângulo de incidência de falta = 340° , resistência de falta = 70Ω , distância de falta = 10, 50, 90 e 130 km, fluxo de carga = 1. Em seguida, apresentam-se as tabelas para as faltas fase-fase-terra, fase-fase e trifásica (Tabela 6.17, Tabela 6.18 e Tabela 6.19) para os mesmos parâmetros.

Tabela 6.16 - Teste do módulo de detecção para faltas fase-terra (parâmetros utilizados: Ângulo de incidência de falta= 340° , Resistência de Falta= 70Ω , Fluxo de Carga = 1)

Distância (km)	Falta AT		Falta BT		Falta CT	
	Tempo para detecção (ms)	Resposta Obtida	Tempo para detecção (ms)	Resposta Obtida	Tempo para detecção (ms)	Resposta Obtida
10	4	0,535	3	0,808	2	0,607
50	4	0,526	3	0,820	3	0,887
90	5	0,505	3	0,814	3	0,860
130	5	0,530	3	0,775	3	0,831

Tabela 6.17 - Teste do módulo de detecção para faltas fase-fase-terra (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)

Distância (km)	Falta ABT		Falta ACT		Falta BCT	
	Tempo para detecção (ms)	Resposta Obtida	Tempo para detecção (ms)	Resposta Obtida	Tempo para detecção (ms)	Resposta Obtida
10	3	0,813	2	0,547	3	1,269
50	3	0,821	3	0,644	3	1,252
90	3	0,771	3	0,652	3	1,238
130	3	0,707	3	0,657	3	1,222

Tabela 6.18 - Teste do módulo de detecção para faltas fase-fase (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)

Distância (km)	Falta AB		Falta AC		Falta BC	
	Tempo para detecção (ms)	Resposta Obtida	Tempo para detecção (ms)	Resposta Obtida	Tempo para detecção (ms)	Resposta Obtida
10	3	0,546	3	0,624	3	0,811
50	6	0,637	3	0,550	3	0,797
90	6	0,641	4	0,518	3	0,795
130	6	0,640	6	0,504	3	0,792

Tabela 6.19 - Teste do módulo de detecção para faltas trifásicas (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)

Distância (km)	Falta ABC	
	Tempo para detecção (ms)	Resposta Obtida
10	3	0,578
50	3	0,514
90	3	0,540
130	3	0,552

6.3.3 Módulo de Classificação

Utilizando-se o novamente o conjunto de testes, submeteu-se as 3 RNAs do tipo RBF desenvolvidas a partir dos 3 conjuntos de treinamento descritos no capítulo anterior aos 960 casos de falta descritos na Tabela 6.1. As mesmas considerações que foram feitas para a rede tipo MLP também foram adotadas aqui, isto é,

a classificação só foi tomada como definitiva quando ocorresse a indicação de um mesmo tipo de falta por duas janelas consecutivas, assumindo-se que valores de saída iguais ou superiores a 0,5 seriam considerados como 1,0.

Figura 6.5 – Gráfico do desempenho das 3 RNAs do tipo RBF para a tarefa de classificação

Observando-se o gráfico anterior, nota-se que a tarefa de classificação foi pouco influenciada pelos 3 diferentes conjuntos de treinamento. A rede I apresentou os melhores resultados classificando 80% dos casos com apenas 4 ms, sendo que a rede treinada com o menor conjunto de dados (rede III) classificou 76% dos casos também com 4ms. Deve-se salientar a presença de 13 testes (1,35%) classificados erroneamente pela rede III. Conforme será destacado no item 6.3.5, estes erros não serão observados no funcionamento do conjunto de detecção e classificação.

6.3.4 Módulo de Classificação – Tabelas

A seguir, apresentam-se algumas tabelas pertencentes ao conjunto de testes feito no módulo de classificação pertencente à rede III. Nelas pode-se observar o comportamento do módulo frente aos diversos testes.

Na primeira tabela (Tabela 6.20), apresentam-se as respostas do módulo de classificação para faltas do tipo AT com os seguintes parâmetros: ângulo de

incidência de falta = 340° , resistência de falta = 70Ω , distância de falta = 10, 50, 90 e 130 km, fluxo de carga = 1. Em seguida, apresentam-se as tabelas para as faltas BCT, AC e ABC (Tabela 6.21, Tabela 6.22 e Tabela 6.23) para os mesmos parâmetros.

Tabela 6.20 - Teste do módulo de classificação para uma falta tipo AT (parâmetros utilizados: Ângulo de incidência de falta= 340° , Resistência de Falta= 70Ω , Fluxo de Carga = 1)

Distância (km)	Tempo para classificação (ms)	Falta AT Resposta Obtida			
		Fase A	Fase B	Fase C	Terra
10	6	0,808	-0,128	-0,109	0,966
50	6	0,850	-0,037	-0,088	0,968
90	7	0,875	-0,137	-0,030	0,974
130	7	0,913	-0,072	-0,018	0,976

Tabela 6.21 - Teste do módulo de classificação para uma falta tipo BCT (parâmetros utilizados: Ângulo de incidência de falta= 340° , Resistência de Falta= 70Ω , Fluxo de Carga = 1)

Distância (km)	Tempo para classificação (ms)	Falta BCT Resposta Obtida			
		Fase A	Fase B	Fase C	Terra
10	5	-0,087	0,877	1,059	0,995
50	5	-0,063	0,893	1,058	0,996
90	5	-0,050	0,901	1,057	0,996
130	5	-0,029	0,914	1,055	0,997

Tabela 6.22 - Teste do módulo de classificação para uma falta tipo AC (parâmetros utilizados: Ângulo de incidência de falta= 340° , Resistência de Falta= 70Ω , Fluxo de Carga = 1)

Distância (km)	Tempo para classificação (ms)	Falta AC Resposta Obtida			
		Fase A	Fase B	Fase C	Terra
10	5	1,100	0,128	1,003	0,010
50	5	1,105	0,139	1,003	0,016
90	6	1,046	0,068	0,984	0,004
130	8	0,895	-0,171	1,039	-0,006

Tabela 6.23 - Teste do módulo de classificação para uma falta tipo ABC (parâmetros utilizados: Ângulo de incidência de falta=340°, Resistência de Falta=70Ω, Fluxo de Carga = 1)

Distância (km)	Tempo para classificação (ms)	Falta ABC Resposta Obtida			
		Fase A	Fase B	Fase C	Terra
10	5	1,000	1,000	1,000	0,007
50	5	1,000	1,000	1,000	0,000
90	5	1,000	1,000	1,000	0,003
130	5	1,000	1,000	1,000	0,000

6.3.5 Análise do Conjunto Detecção e Classificação

Utilizando o fluxograma descrito na Figura 5.2, submeteu-se o conjunto detecção e classificação aos 960 testes. Novamente, as mesmas considerações que foram feitas para o conjunto detecção e classificação para a rede tipo MLP (item 6.2.5) foram tomadas para este conjunto de testes.

Figura 6.6 – Gráfico do desempenho das 3 RNAs do tipo RBF para a tarefa de detecção e classificação

Novamente, o desempenho da classificação foi atrasado devido ao funcionamento da detecção, fato este que levou a eliminação de alguns erros cometidos pela rede III na tarefa de classificação (como já destacado no item 6.2.5.)

Percebe-se também que a diminuição do conjunto de treinamento não influenciou na qualidade da resposta, uma vez que todas as redes apresentaram uma taxa de 100% de acerto.

Apresenta-se agora uma série de tabelas, onde se visualiza o comportamento do conjunto detecção e classificação frente a alguns testes.

6.3.6 Análise do Conjunto Detecção e Classificação – Tabelas

São apresentadas a seguir 4 tabelas para a visualização do funcionamento do conjunto detecção e classificação, seguindo a mesma convenção utilizada no item 6.2.6. Nelas são apresentadas situações onde a detecção ocorreu com 2, 3 ou 4 janelas e a classificação ocorreu com 2 ou 3 janelas (Tabela 6.24, Tabela 6.25, Tabela 6.26 e Tabela 6.27).

Tabela 6.24 – Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω , Ângulo de Falta = 30°, Distância de Falta = 10 km, Tipo de Falta = BT

Janela	Valor de Saída Módulo Detecção
-3 -2 -1	0,060
-2 -1 +1	0,980
-1 +1 +2	0,900

Janela	Valor de Saída Módulo Classificação			
	Fase A	Fase B	Fase C	Terra
+1 +2 +3	-0,304	0,937	0,083	0,973
+2 +3 +4	-0,114	0,967	0,091	0,986

Tabela 6.25 – Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω , Ângulo de Falta = 30°, Distância de Falta = 130 km, Tipo de Falta = ABC

Janela	Valor de Saída Módulo Detecção
-3 -2 -1	0,058
-2 -1 +1	0,445
-1 +1 +2	0,823
+1 +2 +3	0,744

Janela	Valor de Saída Módulo Classificação			
	Fase A	Fase B	Fase C	Terra
+2 +3 +4	0,952	1,027	0,918	-0,001
+3 +4 +5	1,000	1,000	0,999	0,000

Tabela 6.26 – Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω , Ângulo de Falta = 205°, Distância de Falta = 130 km, Tipo de Falta = AT

Janela	Valor de Saída Módulo Detecção
-3 -2 -1	0,011
-2 -1 +1	0,120
-1 +1 +2	0,482
+1 +2 +3	0,839
+2 +3 +4	1,014

Janela	Valor de Saída Módulo Classificação			
	Fase A	Fase B	Fase C	Terra
+3 +4 +5	1,214	-0,900	0,359	0,991
+4 +5 +6	0,908	-0,524	0,313	1,013

Tabela 6.27 – Exemplo do funcionamento detector e classificador para o caso com os seguintes parâmetros: Fluxo de Carga = 1, Resistência de Falta = 20 Ω , Ângulo de Falta = 205°, Distância de Falta = 10 km, Tipo de Falta = CT

Janela	Valor de Saída Módulo Detecção
-3 -2 -1	0,014
-2 -1 +1	0,756
-1 +1 +2	0,943

Janela	Valor de Saída Módulo Classificação			
	Fase A	Fase B	Fase C	Terra
+1 +2 +3	-0,147	0,475	0,652	0,957
+2 +3 +4	-0,203	0,362	0,805	0,961
+3 +4 +5	-0,202	0,268	0,870	0,965

6.4 Comparação do Desempenho da Rede MLP com a Rede RBF

Com o intuito de se comparar o desempenho das Redes MLP com as Redes RBF, apresentam-se a seguir 3 gráficos onde se destacam o desempenho da melhor rede MLP (rede I) com a rede RBF que utilizou o menor conjunto de treinamento (rede III). Assim, a Figura 6.7, Figura 6.8 e Figura 6.9 apresentam esta comparação para a tarefa de detecção e classificação isoladas e em conjunto.

Figura 6.7 – Gráfico da comparação do desempenho da rede MLP com a rede RBF para a tarefa de detecção

Figura 6.8 – Gráfico da comparação do desempenho da rede MLP com a rede RBF para a tarefa de classificação

Figura 6.9 – Gráfico da comparação do desempenho da rede MLP com a rede RBF para a tarefa de detecção e classificação

Observando-se os 3 gráficos anteriores, percebe-se um desempenho um pouco melhor da rede MLP frente à rede RBF. Deve-se destacar, no entanto, que a rede MLP apresentada foi treinada com um conjunto de 640 padrões, enquanto que a rede RBF foi treinada apenas com 20 padrões.

Para o caso estudado, observou-se que a escolha do tipo de rede neural para as tarefas de detecção e classificação está ligada à quantidade de dados para treinamento disponível, isto é, para situações onde um grande banco de dados com situações de falta encontra-se disponível, a rede MLP apresenta-se como a melhor candidata, caso contrário, a rede mais indicada é a rede do tipo RBF.

CONCLUSÕES

Este trabalho descreveu o projeto, treinamento e teste de duas redes neurais artificiais dos tipos RBF e MLP para as tarefas de detecção e classificação de faltas em uma linha de transmissão.

Para o desenvolvimento destas redes foram utilizados dois *softwares*: PSCAD/EMTDC e MATLAB. O primeiro *software* foi responsável pela simulação das diversas situações de falta que a linha de transmissão pode sofrer, sendo que através destas simulações gerou-se um banco de dados para o treinamento e teste das redes. O segundo *software* foi responsável pelo treinamento e teste das redes. Ambos os *softwares* apresentaram-se bastante flexíveis dentro dos seus respectivos ambientes, fator que foi decisivo na escolha deles para o desenvolvimento deste trabalho.

Quanto às redes projetadas, observou-se que as redes MLP e RBF foram capazes de detectar uma falta em um sistema elétrico, bem como classificar as fases envolvidas na situação de falta em 100% dos casos, fato que demonstra a confiabilidade do método proposto.

Tanto o módulo de detecção quanto o módulo de classificação foram inicialmente testados isoladamente, obtendo-se assim as suas características de funcionamento. Posteriormente, estes módulos foram testados em conjunto e o seu desempenho foi avaliado.

Através destes testes foram possíveis avaliar as qualidades e limitações das arquiteturas do tipo MLP e RBF. A rede do tipo MLP treinada com o banco de dados I (rede I) apresentou os melhores resultados gerais enquanto as outras redes MLP treinadas com banco de dados menores apresentaram uma queda de desempenho (rede II) ou erro generalizado para as tarefas de detecção e classificação (rede III). Ao contrário das redes MLP que sofreram diminuição de desempenho e apresentação de falhas quando treinadas com bancos de dados menores, as redes RBF

apresentaram uma pequena queda em seu desempenho, mas nunca apresentaram erros, mostrando assim uma maior independência ao tamanho do banco de dados quando comparada às redes MLP.

Por fim, verificou-se para o caso estudado que a utilização de redes neurais do tipo MLP e RBF para as tarefas de detecção e classificação está ligada à quantidade de dados disponível para treinamento. Caso uma grande quantidade de dados esteja disponível, indica-se o uso de uma rede do tipo MLP devido à maior velocidade em que as respostas são obtidas e à maior precisão dos seus valores de saída; caso contrário, a rede RBF apresenta-se como melhor opção, visto a baixa necessidade de dados para treinamento, bem como uma taxa de acerto equivalente à taxa da melhor rede MLP projetada.

REFERÊNCIAS BIBLIOGRÁFICAS

- Bishop, C. (1995). *Neural Networks for Pattern Recognition*. Oxford, Oxford Press.
- Bo, Z. Q., Su, W. B., Hewet, R. H., Aggarwal, R. K., Johns, A. T., Moore, P. J., Redfern, M. A. (1997). Distinguishing Between Lightning Strokes and Earth Faults on Transmission Line Using Artificial Neural Network. *Proceedings of the International Conference on Power Systems Transients – IPST '97*, 407-411, Jun.
- Braga, A. P., Carvalho, A. P. L. F., Ludemir, T. B. (1999). *Redes Neurais Artificiais: Teoria e Aplicações – São Carlos, ICMSC/USP*.
- Chowdhury, B. H., Wang, K. (1996). Fault Classification in Power Systems Using Artificial Neural Networks. *Engineering Intelligent Systems*, 4(2):101-112, Jun.
- Coury, D. V., Jorge, D. C. (1998). Artificial Neural Network Approach to Distance Protection of Transmission Lines. *IEEE Transactions on Power Delivery*, 13(1):102-108, Jan.
- Dalstein, T., Kulicke, B. (1995). Neural Network Approach to Fault Classification for High Speed Protective Relaying. *IEEE Transactions on Power Delivery*, 10(2):1002-1009, Apr.
- Dalstein, T., Friedrich, T., Kulicke, B., Sobajic, D. (1996). Multi Neural Network Based Fault Area Estimation for High Speed Protective Relaying. *IEEE Transactions on Power Delivery*, 11(2):740-746, Apr.
- Demuth, H., Beale, M. (1997). *Neural Network Toolbox for Use with Matlab*. The MathWorks Inc.
- Elmore, W. A. (1994). *Protective Relaying Theory and Applications*. New York, Marcel Dekker Inc.
- Fernando, I. T., McLaren, P. G. (1995). Single Ended Protection Scheme for Three Phase Double Circuit Lines. *IEEE Wescanex 95 – Communications, Power and Computing – Conference Proceedings*, 117-122, May.
- Haykin, S. (1994). *Neural Networks – A Comprehensive Foundation*. Upper Saddle River – NJ, Prentice-Hall.
- Hebb, D. O. (1949). *The Organization of Behavior*. John Wiley.

- Hopfield, J. J. (1982). Neural Networks and Physical Systems with Emergent Collective Properties. *Proc. Nat. Acad. Sci.*, 79:2554-2558.
- Jiali, H., Yuqian, D., Yongli, L., Gang, W., Shanshan, L. (1997). Distance Relay Protection Based on Artificial Neural Network. *Proceedings of the 4th International Conference on Advances in Power System Control, Operation and Management*, APSCOM-97:515-520, Nov.
- Johns, A. T., Salman, S. K. (1988). *Digital Protection For Power Systems*. Stevenage, Peter Peregrinus Ltd.
- Kezunovic, M., Rikalo, I. (1996). Detect and Classify Faults Using Neural Nets. *IEEE Computer Applications in Power*, 9(4): 42-47, Oct.
- Khaparde, S. A., Warke, N., Agarwal, S. H. (1996). An Adaptive Approach in Distance Protection Using an Artificial Neural Network. *Electric Power System Research*, 37:39-44, Oct.
- Manitoba HVDC Research Centre (1998). *EMTDC User's Guide*.
- The MathWorks Inc. (1988). *Matlab – Signal Processing Toolbox*. The MathWorks Inc.
- McCulloch, W. S., Pitts, W. (1943). A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, 5:115-133.
- Minsky, M., Papert, S. (1969). *Perceptrons: An Introduction to Computational Geometry*. MIT Press.
- Novosel, D., Bachmann, B., Hart, D., Hu, Y., Saha, M. M. (1996). Algorithms for Locating Faults on Series Compensated Lines Using Neural Network and Deterministic Methods. *IEEE Transactions on Power Delivery*, 11(4):1728-1736, Oct.
- Orr, M. J. L. (1999). *Matlab Functions for Radial Basis Function Networks*. <http://www.anc.ed.ac.uk/~mjo/software/intro.ps>
- Phadke, A. G., Thorp, J. S. (1988). *Computer Relaying for Power Systems*. New York, John Wiley & Sons Inc.
- Qi, W., Swift, G., McLaren, P., Castro, A. (1997). Distance Protection Using an Artificial Neural Network. *Developments in Power System Protection*, 434:286-290, Mar.
- Rosenblatt, F. (1958). The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychol. Rev.*, 65:386-408.
- Rumelhart, D. E., McClelland, J. L. (1986). *Parallel Distributed Processing*, volume 1 : Foundations. The MIT Press.

- Sidhu, T. S., Singh, H., Sachdev, M. S. (1995). Design, Implementation and Testing of An Artificial Neural Network Based Fault Direction Discriminator for Protecting Transmission Lines. IEEE Transactions on Power Delivery, 10(2):697-706, Apr.
- Song, Y. H., Johns, A. T., Xuan, Q. Y. (1996). Artificial Neural-Network-Based Protection Scheme for Controllable Series-Compensated EHV Transmission Lines. IEE Proc.-Generation, Transmission and Distribution, 143(6):535-540, Nov.
- Song, Y. H., Xuan, Q. X., Johns, A. T. (1997). Comparison Studies of Five Neural Network Based Fault Classifiers for Complex Transmission Lines. Electric Power Systems Research, 43:125-132, Jan.
- Stevenson Jr., W. D. (1986). Elementos de Análise de Sistemas de Potência. São Paulo, Editora McGraw-Hill.
- Su, W. B., Mao, P. L., Bo, Z. Q., Aggarwal, R. K., Johns, A. T. (1997). A Fault Detection Technique for Composite Transmission Circuits Using Artificial Neural Networks. Proceedings of the 32nd Universities Power Engineering Conference - UPEC 1997, 2: 291-294, Jun.
- Sultan, A. F., Swift, G. W., Fedirchuk, D. J. (1992). Detection of High Impedance Arcing Faults Using a Multilayer Perceptron. IEEE Transactions on Power Delivery, 7(4):1871-1877, Oct.
- Vásquez, E., Altuve, H. J., Chacón, O. L. (1996). Neural Network Approach to Fault Detection in Electric Power Systems. IEEE International Conference on Neural Networks, 4: 2090-2095, Jun.
- Wang, H., Keerthipala, W. L. (1998). Fuzzy-Neuro Approach to Fault Classification for Transmission Line Protection. IEEE Transactions on Power Delivery, 13(4):1093-1102, Oct.
- Widrow, B., Hoff, M. E. (1960). Adaptive Switching Circuits. Institute of Radio Engineers, Western Electronics Show and Convention.