Campus de São Carlos

**ESQUEMA DE PROTEÇÃO DIRECIONAL PARA LINHAS DE TRANSMISSÃO
DE ALTA TENSÃO UTILIZANDO REDES NEURAIS ARTIFICIAIS**

Autor: Arturo Suman Bretas

Orientador: Prof. Dr. Denis Vinicius Coury

UNIVERSIDADE DE SÃO PAULO

**ESCOLA DE ENGENHARIA
DE SÃO CARLOS**

ESQUEMA DE PROTEÇÃO DIRECIONAL PARA LINHAS DE TRANSMISSÃO DE ALTA TENSÃO UTILIZANDO REDES NEURAIAS ARTIFICIAIS

ARTURO SUMAN BRETAS

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. Denis Vinicius Coury

DEDALUS - Acervo - EESC

31100017476

São Carlos

1998

Class.	TESE
Cutl.	0952
Tombo	0187/98.

19/06/98

t. 0984484

**Ficha catalográfica preparada pela Seção de Tratamento
da Informação do Serviço de Biblioteca - EESC-USP**

B844e Bretas, Arturo Suman
Esquema de proteção direcional para linhas de
transmissão de alta tensão utilizando redes
neurais artificiais / Arturo Suman Bretas. --
São Carlos, 1998.

Dissertação (Mestrado) -- Escola de
Engenharia de São Carlos-Universidade de São
Paulo, 1998.

Área: Engenharia Elétrica.

Orientador: Prof. Dr. Denis Vinicius Coury

1. Redes neurais artificiais. 2. Proteção
digital de linhas de transmissão. I. Título.

FOLHA DE APROVAÇÃO

Candidato: Engenheiro **ARTURO SUMAN BRETAS**

Dissertação defendida e aprovada em 19.06.1998
pela Comissão Julgadora:

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

Prof. Doutor **ANDRÉ CARLOS P. DE LEON FERREIRA DE CARVALHO**
(Instituto de Ciências Matemáticas e Computação - Universidade de São Paulo)

Prof. Adjunto **ANÉSIO DOS SANTOS JUNIOR**
(Universidade Estadual de Campinas - UNICAMP)

Prof. Doutor **DENIS VINICIUS COURY**
Coordenador da Área de Engenharia Elétrica

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

*Aos meus pais Newton e Rosario
e ao meu irmão Antonio pelo amor
e compreensão.*

AGRADECIMENTOS

Ao professor e orientador Denis Vinicius Coury pelo incentivo e pela amizade.

À Fundação de Apoio à Pesquisa do Estado de São Paulo – FAPESP e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq, que financiaram este trabalho.

Sumário

Lista de Figuras.....	v
Lista de Tabelas.....	vii
Lista de Abreviaturas e Siglas.....	x
Lista de Símbolos.....	xi
Resumo.....	xiii
<i>Abstract</i>	xiv
1. Introdução.....	1
1.1. Importância dos Sistemas de Proteção.....	1
1.2. Relés Eletromecânicos.....	3
1.3. Relés de Estado Sólido.....	3
1.4. Relés Digitais.....	4
1.5. Redes Neurais Artificiais aplicadas à Proteção de Sistemas Elétricos de Potência.....	6
2. Redes Neurais Artificiais.....	10
2.1. Neurônio Biológico.....	10
2.2. Modelagem Matemática do Neurônio Biológico.....	12
2.3. Redes Neurais Artificiais aplicadas ao problema de Reconhecimento de Padrões.....	13
2.4. Redes Neurais Artificiais de Múltiplas Camadas.....	16
2.5. Regra de Aprendizagem.....	18
2.5.1. Algoritmo <i>Backpropagation</i>	20
3. Revisão Bibliográfica.....	21
3.1. Proteção de Sistemas Elétricos de Potência utilizando Redes Neurais Artificiais.....	21
4. Configuração do Sistema Elétrico Estudado.....	30
4.1. Introdução.....	30
4.2. Gerador de dados - “Alternative Transients Program” (ATP).....	30
4.3. Configuração do Sistema Elétrico de Potência.....	31
4.3.1. Disposição geométrica da Linha de Transmissão.....	32

4.3.2. Parâmetros do Sistema Elétrico de Potência.....	33
4.3.3. <i>Line Constant</i> e a Interface Gráfica DESTRO.....	34
4.3.4. Arquivo Principal de Dados.....	36
4.4. Simulações Realizadas no Sistema Elétrico em Estudo.....	39
4.5. <i>Software</i> de Extração de Características.....	42
4.5.1. Filtro Digital passa-baixa Butterworth.....	44
4.5.2. Reamostragem de Dados para 960 Hz.....	47
4.5.3. Identificação do Ponto de Ocorrência da Falta.....	48
4.5.4. Formação dos Padrões de Entrada da Rede Neural Artificial.....	48
5. Aplicação de Redes Neurais Artificiais como Classificador de Padrões na Proteção Direcional.....	50
5.1. Introdução.....	50
5.2. <i>Software</i> de Simulação de Redes Neurais Artificiais SNNS.....	50
5.2.1. Padrões de Entrada.....	51
5.2.2. Topologia da Rede Neural Artificial.....	52
5.2.3. Treinamento da Rede Neural Artificial.....	53
5.3. Testes e Resultados.....	55
5.3.1. Influência da Resistência de Falta.....	85
5.3.2. Influência da Localização da Falta.....	86
5.3.3. Influência do Tipo de Falta.....	87
5.3.4. Influência da Distância de Falta.....	88
5.3.5. Influência do Ângulo de Incidência da Falta.....	90
5.3.6. Influência das Condições de Operação.....	90
6. Conclusões.....	92
Referências Bibliográficas.....	95

Lista de Figuras

FIGURA 01 - Sub-sistemas de um relé computacional.....	5
FIGURA 02 - Esquema de proteção direcional digital.....	7
FIGURA 03 - Esquema de proteção direcional utilizando RNA.....	8
FIGURA 04 - Desenho esquemático de um neurônio típico.....	11
FIGURA 05 - Esquema de um neurônio artificial.....	12
FIGURA 06 - O discriminador linear separa o espaço em duas regiões A e B.....	15
FIGURA 07 - Coleções linearmente separáveis (a) e não separáveis linearmente (b).....	16
FIGURA 08 - Função booleana XOR de duas variáveis.....	16
FIGURA 09 - Esquema de Rede Neural Artificial do tipo feed-forward.....	18
FIGURA 10 - Diagrama unifilar do sistema elétrico analisado.....	31
FIGURA 11 - Topologia da Linha de Transmissão.....	32
FIGURA 12 - Representação por parâmetros distribuídos de uma seção de uma L.T.....	34
FIGURA 13 - Arquivo de entrada da rotina <i>Line Constants</i>	35
FIGURA 14 - Arquivo de entrada do ATP.....	37
FIGURA 15 - Esquema da rede elétrica em estudo.....	38
FIGURA 16 (a) - Possíveis Tipos de Falta (Falta fase - terra).....	40
FIGURA 16 (b) - Possíveis Tipos de Falta (Falta fase - fase).....	40
FIGURA 16 (c) - Possíveis Tipos de Falta (Falta fase - fase - terra).....	40
FIGURA 16 (d) - Possíveis Tipos de Falta (Falta trifásica).....	40
FIGURA 16 (e) - Possíveis Tipos de Falta (Falta trifásica - terra).....	41
FIGURA 17 - Fluxograma do <i>software</i> Extração de Características.....	42

FIGURA 18 - Característica de um filtro passa-baixa ideal.....	43
FIGURA 19 - Característica de perda de um filtro passa-baixa ideal.....	44
FIGURA 20 - Característica de perda de um filtro passa-baixa real.....	44
FIGURA 21 - Valores amostrados referentes a corrente quando uma falta envolvendo a fase A à terra é aplicada a 6 Km do barramento T, com um ângulo de incidência de 90^0 e com resistência de falta de 0.1Ω	46
FIGURA 22 - Arquivo de entrada do SNNS contendo 1 padrão de treinamento, formado a partir de uma simulação de falta entre TQ, com resistência de falta de 5Ω , à 6 Km do barramento T, e com ângulo de incidência de 0^0	51
FIGURA 23 - Arquitetura da rede neural artificial utilizada.....	52
FIGURA 24 - Progresso do processo de aprendizagem durante o treinamento.....	54
FIGURA 25 – Sistema elétrico dividido em seções.....	88

Lista de Tabelas

TABELA 01 - Distribuição de faltas em um sistema de 500 KV, em um período de dez nos.....	2
TABELA 02 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase A - T entre os barramentos TQ.....	57
TABELA 03 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase A - T entre os barramentos PT.....	58
TABELA 04 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase B - T entre os barramentos TQ.....	59
TABELA 05 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase B - T entre os barramentos PT.....	60
TABELA 06 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase C - T entre os barramentos TQ.....	61
TABELA 07 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase C - T entre os barramentos PT.....	62
TABELA 08 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase AB entre os barramentos TQ.....	63
TABELA 09 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase AB entre os barramentos PT.....	64
TABELA 10 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase AC entre os barramentos TQ.....	65
TABELA 11 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase AC entre os barramentos PT.....	66
TABELA 12 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase BC entre os barramentos TQ.....	67

TABELA 13 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase BC entre os barramentos PT.....	68
TABELA 14 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase AB - T entre os barramentos TQ.....	69
TABELA 15 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase AB - T entre os barramentos PT.....	70
TABELA 16 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase AC - T entre os barramentos TQ.....	71
TABELA 17 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase AC - T entre os barramentos PT.....	72
TABELA 18 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase BC - T entre os barramentos TQ.....	73
FIGURA 19 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase BC - T entre os barramentos PT.....	74
TABELA 20 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase ABC - T entre os barramentos TQ.....	75
TABELA 21 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase ABC - T entre os barramentos PT.....	76
TABELA 22 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase ABC entre os barramentos TQ.....	77
TABELA 23 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase ABC entre os barramentos PT.....	78
TABELA 24 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase A-T entre os barramentos TQ, quando a capacidade da fonte do barramento P sofreu um decréscimo de 10%.....	79
TABELA 25 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase A-T entre os barramentos PT, quando a capacidade da fonte do barramento P sofreu um decréscimo de 10%.....	80
TABELA 26 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase AB entre os barramentos TQ, quando a capacidade da fonte do barramento P sofreu um decréscimo de 5% e a capacidade da fonte do	

barramento Q sofreu um decréscimo de 5,26%.....	81
TABELA 27 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase AB entre os barramentos PT quando a capacidade da fonte do barramento P sofreu um decréscimo de 5% e a capacidade da fonte do barramento Q sofre um decréscimo de 5,26%.....	82
TABELA 28 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase ABC entre os barramentos TQ quando a capacidade da fonte do barramento P sofreu um decréscimo de 5%, a capacidade da fonte e o ângulo de potência do barramento Q sofrem um decréscimo de 5,26% e 50% respectivamente.....	83
TABELA 29 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase ABC entre os barramentos PT quando a capacidade da fonte do barramento P sofreu um decréscimo de 5%, a capacidade da fonte e o ângulo de potência do barramento Q sofrem um decréscimo de 5,26% e 50% respectivamente.....	84
TABELA 30 - Porcentagem de padrões incorretamente classificados em relação à resistência de falta.....	85
TABELA 31 - Porcentagem de padrões incorretamente classificados em relação à localização da falta.....	86
TABELA 32 - Porcentagem de padrões incorretamente classificados em relação ao tipo de falta.....	87
TABELA 33 - Porcentagem de padrões incorretamente classificados em relação às seções da linha de transmissão.....	89
TABELA 34 - Porcentagem de padrões incorretamente classificados em relação aos ângulos de incidência de falta.....	90
TABELA 35 - Porcentagem de padrões incorretamente classificados em relação às condições de operação.....	91

Lista de Abreviaturas e Siglas

A/D	- Analógico/Digital
ADALINE	- Modelo neural linear
ATP	- <i>Alternative Transients Program</i>
EMTP	- <i>Eletromagnetic Transients Program</i>
L.T.	- Linhas de Transmissão
MADALINE	- Modelo neural linear mutidimensional
NFAE	- <i>Neural fault area estimator</i>
RNA	- Redes Neurais Artificiais
S.E.P.	- Sistemas Elétricos de Potência
SNNS	- <i>Stuttgart Neural Network Simulator</i>
SPAR	- <i>Single - pole autoreclosure</i>
SSE	- Soma dos erros por padrão

Lista de Símbolos

Φ	- Coleção de vetores
ξ_i	- I-ésima entrada de uma RNA
η	- Taxa de aprendizagem
$\overline{A}$	- Vetor de estados de ativação da camada intermediária de uma RNA do tipo <i>feed-forward</i>
$\overline{B}$	- Vetor de estados de ativação da camada de saída de uma RNA do tipo <i>feed-forward</i>
b	- Característica <i>offset</i> do neurônio
C	- Capacitância da linha por unidade de comprimento
E	- Função booleana E
f	- Função de ativação de um neurônio artificial
FPT	- Interruptor controlado pelo tempo
FTQ	- Interruptor controlado pelo tempo
G	- Condutância da linha por unidade de comprimento
I	- Entrada total de um neurônio artificial
L	- Indutância da linha por unidade de comprimento
Lfi	- Indutâncias relacionadas com a fonte i
$Ltij$	- Porções de linha segmentadas pelo nó contendo as resistências de falta
O_i''	- Saída desejada da i -ésima unidade na camada de saída correspondente ao padrão de entrada μ
OU	- Função booleana OU
P	- Barramento tomado como referência

R	- Resistência da linha por unidade de comprimento
R_f	- Resistência de falta
R_{fi}	- Resistências relacionadas com a fonte i
$\Re^n$	- Espaço euclidiano de dimensão n
$S(.)$	- Função sigmoide
$\text{sgn}(v)$	- Operador de sinal
T	- Barramento tomado como referência
u	- Vetor de dimensão n
w	- Vetor de pesos
V_i^m	- i -ésima saída da m -ésima camada de uma RNA
w_{ij}^m	- Peso da conexão entre as unidades V_j^{m-1} e V_i^m
w_i	- Peso entre a i -ésima entrada e o neurônio artificial
$\overline{X}$	- Padrão de entrada de uma RNA do tipo <i>feed-forward</i>
x	- Vetor de entrada de um neurônio artificial
x_i	- i -ésima entrada de um neurônio artificial
XOR	- Função booleana OU EXCLUSIVO
$\overline{Y}$	- Vetor de saída de uma RNA do tipo <i>feed-forward</i>
y	- Saída de um neurônio artificial
$y(v)$	- Função degrau unitário
z	- Vetor de dimensão n

Resumo

Este trabalho apresenta um esquema de proteção direcional para sistemas de transmissão, baseado na utilização de redes neurais artificiais, tentando solucionar as principais limitações dos esquemas então existentes. As redes neurais artificiais constituem uma nova ferramenta para a proteção, onde várias das limitações apresentadas pelos esquemas convencionais podem ser solucionadas. A escolha desta abordagem para a proteção das linhas de transmissão é uma decisão fundamentada principalmente na capacidade de generalização e abstração inerentes às redes neurais artificiais. Estas características, se bem exploradas, podem prover uma alta qualidade de resposta, aliada a uma elevada velocidade de decisão. Outro fator de interesse é que, dependendo de como se realizar o treinamento da rede, poderia gerar-se metodologias de proteção capaz de suportar com eficiência mudanças na configuração do sistema. Isto geraria possibilidade de diagnósticos de falta com adequada confiabilidade que por sua vez não dependeria da configuração do sistema em si. O esquema de proteção proposto, foi simulado utilizando os *softwares Alternative Transients Program (ATP)* e *Stuttgart Neural Network Simulator (SNNS)*. Também programas em Fortran foram desenvolvidos (filtro digital, reamostragem, identificação do ponto de ocorrência de falta, etc..) de forma a se representar adequadamente as condições reais de funcionamento do esquema de proteção. Testes simulando as mais diversas condições de falta foram realizados, de forma a se verificar a eficiência do esquema proposto. Os resultados demonstraram a capacidade da metodologia proposta de analisar corretamente os padrões provenientes de situações faltosas mesmo quando não vistas na fase de treinamento. Desta forma configurou-se um alto grau de generalização e abstração do esquema.

Abstract

This work presents a directional protection scheme for transmission systems, that uses artificial neural networks, and try to solve the main limitations of existing schemes. The artificial neural networks are a new tool for protection, were many of the limitations of conventional schemes can be solved. The choice of this approach for transmission lines protection is a decision based mainly on the capability of generalization and abstraction inherent to the artificial neural networks. These characteristics, if well explored, can provide a response of high quality, together with a high speed of decision. Another interesting factor is that, depending on how the learning on the artificial neural network is made, it can generate a protection methodology capable of supporting efficiently changes on the system configuration. This can generate reliable fault diagnostics, which is independent on network configuration. The proposed protection scheme was simulated using softwares like "Alternative Transients Program"(ATP) and "Stuttgart Neural Network Simulator"(SNNS). Other programs were written in Fortran (digital filter, resampling of data, fault point identification, etc..) in a way to correctly represent the real working conditions of the protection scheme. Tests simulating several fault conditions were made, in a way to verify the efficiency of the proposed scheme. The results demonstrate the capability of the proposed methodology of correctly analyzing the patterns generated from fault conditions even when not seen on the learning stage. In that way a high degree of generalization and abstraction of the scheme were configured.

1. Introdução

1.1. - Importância dos Sistemas de Proteção

Os Sistemas Elétricos de Potência (S.E.P.) são projetados para fornecer energia elétrica de forma contínua e com qualidade para os setores mais variados de nossa sociedade. Indústrias, cidades, e bancos são apenas alguns dos setores que necessitam de energia elétrica para o seu bom funcionamento. Ainda, para o desenvolvimento de uma região, o fornecimento de energia elétrica de boa qualidade é imprescindível. A instalação de indústrias e atividades comerciais em uma determinada localidade é hoje dependente ao acesso à energia elétrica. Desta forma, o fornecimento de energia elétrica de qualidade, bem como a capacidade dos S.E.P. realizar este fornecimento de maneira contínua é de grande importância para a população.

Para um usuário de energia elétrica, os S.E.P. aparentam estar sempre em condições estáveis: sem perturbações e com capacidade infinita. No entanto, sabe-se, que o sistema é sujeito à constantes distúrbios criados por mudanças randômicas de carga, por faltas ocasionadas pela interferência do meio ambiente e por faltas resultantes de falhas de equipamento ou da operação. Sabe-se ainda, que mesmo diante destes distúrbios constantes, os S.E.P. mantêm um estado quase estável devido à dois grandes fatores: a relativa grandeza do sistema em relação às cargas e geradores individuais e as ações corretivas de alta velocidade tomadas pelo equipamento de proteção.

Proteção é uma subárea da engenharia elétrica preocupada com os princípios de projeto e operação de equipamentos (chamados de ‘relés’ ou ‘relés de proteção’) que detectam condições anormais dos S.E.P., e inicializam ações corretivas da forma

mais rápida possível, de modo a levar o sistema ao estado normal de operação. A velocidade de resposta dos equipamentos de proteção é um requisito essencial a sua operação: tempos de resposta na ordem de alguns mili-segundos são usualmente requeridos. A resposta deve ser automática, rápida e deve minimizar ao máximo a área do sistema a ser desconectada. Assim, podemos afirmar que os principais objetivos a serem alcançados por um sistema de proteção são: correto diagnóstico da anormalidade, alta velocidade de resposta, e mínima perturbação aos S.E.P.

Um dos importantes componentes dos S.E.P. são as Linhas de Transmissão (L.T.), responsáveis pela transmissão da energia elétrica dos terminais geradores para os consumidores, e estes elementos são de extrema importância para o bom funcionamento do sistema. Dada sua clara importância no processo de transmissão de energia elétrica, e ao fato de serem as mais atingidas por situações faltosas, como colocado por VAN ZEE¹ *apud* COURY (1987) e explicitado na tabela 1., a proteção das L.T. é hoje uma das grandes áreas de pesquisa e estudo nos principais centros de desenvolvimento de engenharia elétrica, e tema de mestrado aqui apresentado.

TABELA 1- Distribuição de faltas em um sistema de 500KV, em um período de dez anos.

EQUIPAMENTOS FALTOSOS	NÚMERO DE FALTAS
Linha de Transmissão	82
Autotransformadores	6
Erro Humano	5
Circuitos Disjuntores	4
Barramentos	1
Geradores	1

¹ VAN ZEE, W.H.&FELTON,R.J. 500KV system relaying-design and operating experience. CIGRE-Paris, 1978, Paper nº 34-07 *apud* COURY, D.V.. Um estimador ótimo aplicado à proteção digital dos sistemas elétricos de potência. São Carlos, 1987. Dissertação (mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo.

Considerando as dimensões físicas de uma L.T., fica clara a sua susceptibilidade à ocorrência de faltas. Entre estes riscos temos (KINDERMANN (1991)):

- a) menor confiabilidade, devido ao grande número de componentes que a compõe;
- b) intempéries;
- c) descargas atmosféricas;

Com a expansão e aumento em complexidade dos S.E.P., que se acentuou a partir da década de 60, tornou-se necessário aumentar a eficiência dos equipamentos de proteção utilizados, principalmente os responsáveis pela proteção das L.T.. Nos próximos sub-ítemos apresentaremos, em ordem crescente de desenvolvimento tecnológico, alguns relés de proteção para L.T. hoje utilizados.

1.2. - Relés Eletromecânicos

Os primeiros relés de proteção projetados, e ainda hoje os mais utilizados na proteção de vários equipamentos dos S.E.P. são os relés eletromecânicos. Estes relés utilizam forças 'atuantes' que são produzidas pela interação eletromagnética entre correntes e fluxos, como em um motor. Estas forças atuantes são criadas pela combinação dos sinais de entrada e pela energia armazenada nas espiras. Em geral, os relés eletromecânicos respondem a uma ou mais entradas 'produtoras' de torque: (a) tensão, (b) corrente, (c) produto entre a tensão, corrente e o ângulo entre estes fasores, ou (d) uma força física como a de uma mola de controle.

O grande problema dos relés eletromecânicos se encontra na sua confiabilidade, que depende exclusivamente do resultado de uma interação de forças. Com o passar do tempo, as molas e outros componentes mecânicos do relé vão sofrendo um processo normal de desgaste, que acaba por reduzir a confiabilidade do equipamento, pois são componentes diretamente ligados ao processo de decisão.

1.3. - Relés de Estado Sólido

Os relés de estado sólido, possuem um nível de desempenho superior e características mais sofisticadas com relação aos relés eletromecânicos. Sua criação foi realizada graças ao desenvolvimento dos semicondutores e outros componentes associados, que são utilizados no equipamento. Todas as funções e características disponíveis nos relés eletromecânicos podem ser realizadas por dispositivos de estado sólido, como componentes discretos ou circuitos integrados.

Os relés de estado sólido, segundo PHADKE (1992), utilizam componentes de baixa potência com pouca tolerância a extremos de temperatura, a umidade, a sobretensões e sobrecorrentes. Estas características introduzem preocupações quanto a suportabilidade de relés de estado sólido no ambiente hostil de uma subestação. Estas preocupações foram confirmadas quando os primeiros projetos de relés de estado sólido apresentaram inúmeras falhas atribuídas ao ambiente hostil da subestação. Ainda, os relés de estado sólido necessitam de fontes de potência independentes, pois não possuem torques conseqüentes às quantidades de energia. No entanto, os relés de estado sólido possuem, em relação aos relés eletromecânicos, desempenho superior, maior flexibilidade, não são prejudicados por vibrações e poeira, além de possuírem um menor tamanho físico.

1.4. - Relés Digitais

Uma observação comumente realizada é a de que os relés são computadores analógicos. Ele aceita entradas, as processa eletromecanicamente, ou eletronicamente, para desenvolver um torque ou uma saída lógica, e por fim toma uma decisão resultando em um fechamento de contatos ou um sinal de saída. Com o advento dos microprocessadores, esta função descrita acima pode ser realizada por um computador digital. Como as entradas usuais consistem de tensões e correntes, é necessário obter-se a representação digital destes parâmetros.

FIGURA 1 - Sub-sistemas de um relé computacional.

A figura 1 ilustra as diferentes etapas de um relé digital. Os sinais de corrente e tensão provenientes do sistema de potência passam pelos transdutores (TP's e TC's) e filtros anti-aliasing, antes de serem amostrados e convertidos para a forma digital pelo conversor analógico/digital (A/D). O *clock* de amostragem fornece pulsos à frequência amostral. Frequências de amostragem típicas dos relés digitais de hoje variam entre 8-32 vezes a frequência fundamental do sistema de potência. Os sinais de entrada analógicos são geralmente 'congelados' por um circuito *sample-and-hold*, de forma a fornecer amostragens simultâneas de todos os sinais, independentemente da velocidade de conversão do conversor analógico/digital. O algoritmo para função de proteção, processa a informação amostrada para produzir uma saída digital. Em muitos casos, filtros digitais baseados na Transformada de Fourier são utilizados. Desta forma, o algoritmo é o centro do relé digital, tendo sido desenvolvido e publicado uma grande quantidade de algoritmos na literatura (PHADKE (1988)).

As maiores vantagens dos relés digitais em relação aos anteriormente mencionados são sua capacidade de autochecagem, que o permite advertir o sistema de operação quanto ao seu mau funcionamento possibilitando assim correções, sua alta confiabilidade, e seu relativo baixo custo. No entanto, mesmo esta filosofia

inovadora, possui algumas limitações. A principal se refere a sua adaptabilidade a mudanças na configuração do S.E.P.. Mudanças no fluxo de carga que passa pela L.T., conseqüente à variações de carga ou mesmo de geração, não são fatos incomuns no funcionamento do sistema. Estas mudanças nos parâmetros do sistema não são observadas pelos relés digitais, que possuem características de operação constantes. Algumas metodologias recentemente publicadas na literatura procuram solucionar esta limitação. Uma das mais conhecidas, proteção digital adaptativa, apresentada por XIA (1994), procura armazenar em um banco de dados algumas características de operação ótimas para determinadas configurações do sistema. Um dos grandes limitantes deste esquema é a quantidade de características de operação que podem ser armazenadas dentro deste banco, usualmente três ou quatro, que fazem com que o método cubra apenas algumas das possíveis configurações do sistema de transmissão, tornando-o limitado.

1.5. - Redes Neurais Artificiais aplicadas à Proteção de Sistemas Elétricos de Potência

Redes neurais artificiais (RNA), segundo HERTZ (1991), consistem em uma metodologia matemática, baseada em conceitos de processamento neurológicos que procuram reproduzir algumas características de inteligência, como a capacidade de generalização e abstração. Esta técnica tem sido aplicada em um amplo escopo de áreas, com diferentes formas de utilização. Analisando as recentes publicações na literatura, entre elas DALSTEIN (1995), evidenciamos uma atual tendência de utilização de RNA como classificador de padrões. Graças as características anteriormente mencionadas, a RNA consegue ótimos resultados, pois sua habilidade em reconhecer padrões incompletos ou mesmo não vistos, permite-a discernir e encontrar as melhores respostas. RNA também já foi tema de estudo e aplicações, como classificador de padrões, em proteção de S.E.P., assunto que será explicitado e caracterizado em capítulo posterior.

Dado o interesse em resolver as limitações das metodologias de proteção anteriormente citadas, bem como aumentar a velocidade de decisão, propõe-se a

utilização de RNA em um esquema de proteção direcional para L.T. de alta tensão. Um esquema de proteção direcional digital, pode ser visto, em diagrama de blocos na figura 2.

FIGURA 2 - Esquema de proteção direcional digital.

Segundo PHADKE (1992), um relé direcional digital se utiliza da posição relativa dos ângulos de fase dos fasores de tensão e corrente pós-falta para determinar a direcionalidade da falta. O esquema é inicializado com uma detecção de falta, em conjunto com a determinação do instante de ocorrência da falta. Em seguida, se inicia um procedimento determinado a verificar se ocorreu ou não uma inversão na polaridade da(s) fase(s) faltosa(s). Para tal, o esquema, através de um filtro de Fourier, obtém os fasores fundamentais dos sinais pós-falta de tensão e corrente. Obtidos os fasores, utiliza-se um classificador de faltas quanto ao tipo para identificar a(s) fase(s) faltosa(s). Com isto, tem-se uma informação qualitativa indicando quais os fasores a serem analisados, que notoriamente são apenas os provenientes da(s) fase(s) faltosa(s). Estes fasore(s) faltoso(s) juntamente com uma quantidade de polarização (sinal que não possui mudança na polaridade mesmo diante da incisão de falta), possuem informações suficientes para a verificação da

posição relativa da falta quanto ao relé. É interessante destacar que a quantidade de polarização anteriormente mencionada e utilizada na verificação da posição relativa da falta, é usualmente um fasor de tensão, que como afirmado anteriormente não possui mudança significativa de fase mesmo diante da incidência de uma falta. A verificação da direcionalidade da falta, é realizada através da análise comparativa entre os ângulos do fasor de corrente faltoso e da quantidade de referência (polarização). Para tal, verifica-se se houve uma inversão na polaridade do fasor de corrente em relação a situação pré-falta; em caso positivo (falta na direção reversa ao relé), o relé não deve mandar um sinal de abertura para o disjuntor, e em caso negativo (falta na direção frontal ao relé), este sinal deve ser enviado.

O esquema de proteção proposto, pode ser visto na figura 3.

FIGURA 3 - Esquema de proteção direcional utilizando RNA.

O esquema de proteção proposto procura utilizar as qualidades inerentes às RNAs, de forma a obter-se um relé com maior confiabilidade, e velocidade de atuação. Como pode ser notado, a detecção de uma falta inicia o esquema de proteção. Em seguida iniciar-se-á um processo de decisão lógica que irá determinar

se a falta está dentro ou não da zona de proteção do relé. As quantidades que servirão de entrada ao microcomputador e serão analisadas pela RNA serão amostras sequenciais de corrente e tensão. Estas amostras sequenciais irão ser inicialmente normalizadas por valores que as colocarão dentro do intervalo -1 e 1. Estes valores normalizados serão então analisados pela RNA que deverá emitir uma saída determinando a posição relativa da falta. A saída de valor unitário será interpretada como uma falta dentro da zona de proteção do relé (gerando assim a abertura do disjuntor), e uma saída nula como uma situação fora desta zona de proteção. Maiores detalhes a respeito da aplicação serão fornecidos no Capítulo 4. Os capítulos seguintes estão organizados da seguinte forma:

- Capítulo 2 - Apresentação da teoria sobre Redes Neurais Artificiais.
- Capítulo 3 - Revisão bibliográfica sobre aplicação de Redes Neurais Artificiais em Proteção de Sistemas Elétricos de Potência.
- Capítulo 4 - Detalhes de implementação do esquema de proteção proposto, bem como do sistema elétrico analisado.
- Capítulo 5 - Detalhes sobre a utilização do *software* de Redes Neurais Artificiais SNNS, testes e resultados obtidos da aplicação do esquema de proteção proposto.
- Capítulo 6 - Conclusões finais do trabalho.

2. Redes Neurais Artificiais

RNAs têm sido utilizadas com sucesso em diferentes áreas. A metodologia é inspirada no cérebro humano, pois esta tenta abstrair algumas características superiores do cérebro para o computador digital. Segundo Hertz (1991), as principais características do cérebro humano desejáveis em sistemas artificiais são:

- Ser robusto e tolerante a faltas. Células nervosas do cérebro morrem todos os dias sem afetar significativamente o desempenho.
- Ser flexível. Ele pode ser ajustado para um novo ambiente através de aprendizagem.
- Conseguir lidar com informação ruidosa, inconsistente e nebulosa.
- Possuir processamento paralelo.
- Ser pequeno, compacto, e consumir pouca energia.

Nos próximos itens, procura-se explicitar os fundamentos teóricos desta área, colocando-se sua origem, bem como alguns passos até a obtenção de uma RNA de várias camadas que faz parte da implementação em estudo.

2.1. - Neurônio Biológico

O cérebro possui aproximadamente 10^{11} neurônios (células nervosas) de vários tipos. A figura 4 representa um desenho esquemático de um único neurônio.

FIGURA 4 - Desenho esquemático de um neurônio típico.

No neurônio, redes de fibras nervosas chamadas dendritos são conectadas a um corpo celular, onde o núcleo está localizado. Estendendo-se pelo corpo celular, tem-se uma única fibra longa chamada de axônio, que eventualmente ramifica-se em filamentos e subfilamentos. No final destes filamentos, encontram-se as junções sinápticas ou sinapses, responsáveis pela transmissão de elementos químicos de uma célula nervosa para outra. Um axônio de um neurônio típico gera algumas centenas de sinapses conectadas com dendritos de outros neurônios.

Após anos de estudo, cientistas concluíram que o neurônio poderia ser considerado análogo à uma unidade de processamento lógica. Neste sentido, o neurônio seria uma unidade de processamento que aceitaria várias entradas e produziria apenas uma saída. Segundo BEALE (1996), se um número suficiente de entradas ativas fossem recebidas pelo neurônio, então este se tornaria ativo e geraria uma saída. Caso contrário, o neurônio permaneceria inativo, sem gerar uma saída. Dentro deste raciocínio de analogia, as entradas ao neurônio são provenientes das junções sinápticas entre um axônio e o dendrito da célula nervosa em questão. Os sinais que chegam pelos dendritos, provenientes da junção sináptica, são neurotransmissores que o neurônio processará para produzir uma saída também em forma de impulso nervoso, que por sua vez será mandada para o axônio. A transmissão de um sinal de uma célula nervosa para outra ocorre via sinapse, e é realizada através de um processo químico complexo em que substâncias transmissoras são liberadas no lado emissor da junção. No lado receptor, como consequência à liberação destas substâncias transmissoras, ocorre um aumento ou diminuição do potencial elétrico no interior do corpo da célula receptora. Se este

potencial alcançar um determinado limiar, um pulso com intensidade e duração fixa é enviado ao axônio. Dizemos então, que a célula está ativa ou estimulada e o pulso é enviado para as ramificações nas junções sinápticas de outras células.

Desta forma, os neurônios são considerados unidades básicas no processamento da informação. No item seguinte mostra-se um dos modelos mais utilizados para representá-los.

2.2. - Modelagem Matemática do Neurônio Biológico

Uma rede neural artificial é composta por unidades básicas de processamento, chamadas de neurônios artificiais, que compreendem uma modelagem matemática do neurônio biológico. O modelo utilizado para a representação matemática do neurônio biológico é mostrado na figura 5, apresentado por BERNIERE *et al.* (1994), foi inspirado no modelo proposto por Warren McCulloch e Walter Pitts em 1943.

FIGURA 5 - Esquema de um neurônio artificial.

Neste modelo, as entradas (x_i) são fornecidas ao neurônio através de conexões relacionadas a pesos (w_i), sendo b a característica *offset* do neurônio, ou ainda citada na literatura com o nome de *threshold*, como em HERTZ *et al.* (1991). O parâmetro (b) refere-se ao limiar ou potencial de ação de cada célula nervosa, como citado anteriormente. A saída (y) é obtida através da aplicação de uma função de ativação (f) que na maioria das aplicações deve ser contínua.

O funcionamento de um neurônio se dá através da obtenção de uma **entrada total**, que é resultante de uma somatória onde cada sinal de entrada (x_i) é associado a um peso relativo (w_i). O somatório que resulta na entrada total pode ser visto na equação 1.

$$I = \sum |w_i \cdot x_i| \quad (1)$$

Obtida a entrada total do neurônio artificial, ocorre em seguida uma comparação deste valor com o *threshold* característico. Se o somatório (I) for maior que o limiar (b), então o neurônio estará ativo e produzirá uma saída cujo valor será especificado pela função de ativação (f). Caso contrário, o neurônio estará inativo, e sua saída dependerá novamente da função de ativação utilizada. Este comportamento descrito anteriormente pode ser visualizado na equação 2 abaixo.

$$y = f [(\sum w_i \cdot x_i) - b] \quad (2)$$

A função de ativação mais utilizada quando se deseja saídas contínuas, é a função sigmoide, apresentada na equação 3.

$$f(y) = 1 / [1 + e^{-y}] \quad (3)$$

Uma RNA compreende um conjunto destas unidades de processamento, interconectadas e organizadas em camadas. A RNA utilizada neste trabalho, do tipo *feed-forward*, abordada em um capítulo posterior, é um exemplo típico deste tipo de arquitetura.

2.3. - Redes Neurais Artificiais aplicadas ao problema de Reconhecimento de Padrões

Reconhecimento de padrões compreende a ciência de identificação e classificação da informação em categorias. Para que haja um processo de classificação de padrões, é necessário que haja um mapeamento no espaço de características dos padrões de entrada. Este mapeamento compreende na definição de

regras de decisão de modo a separar as classes de padrões no espaço de características através de fronteiras. Uma forma de definir estas regras de decisão são as funções discriminantes. Funções discriminantes são as fronteiras que irão separar as classes em regiões no espaço de características. Os classificadores que utilizam uma linha reta como função discriminante para separar as classes no espaço de características são chamados de discriminantes lineares. Dentro deste caso particular, e com base em KOVÁCS (1996), encontramos um exemplo exposto por McCulloch e Pitts, cujas entradas são binárias. Neste exemplo, o autor apresenta um discriminador linear de n entradas $\{x_1, x_2, \dots, x_n\}$ e uma saída definida pela expressão:

$$\begin{aligned} y &= f\left[\sum_{i=1}^n w_i \cdot x_i - b\right] = f(w^t \cdot x - b) \rightarrow y \in [0;1] \\ y &= \text{sgn}\left(\sum_{i=1}^n w_i \cdot x_i - b\right) = \text{sgn}(w^t \cdot x - b) \rightarrow y \in [-1;1] \end{aligned} \quad (4)$$

onde os componentes do vetor w , $\{w_1, w_2, \dots, w_n\}$ são os pesos associados às entradas x_i , b é o valor do limiar, $f(v)$ é a função degrau unitário e $\text{sgn}(v)$ o operador do sinal. A expressão 4, representa um hiperplano que divide o espaço euclidiano $\mathbb{R}^n$, de dimensão n , em duas regiões A e B. Assim o vetor x de componentes $\{x_1, x_2, \dots, x_n\}$ estará em uma destas regiões na medida em que se verificar:

$$\begin{cases} w^t \cdot x - b > 0 \Rightarrow x \in A \\ w^t \cdot x - b < 0 \Rightarrow x \in B \end{cases} \quad (5)$$

enquanto que o valor da saída y será:

$$y = 1 \text{ se } x \in A \text{ e } y = 0 \text{ ou } -1 \text{ se } x \in B \quad (6)$$

Esta situação está representada no diagrama da figura 6 para o caso em que a dimensão do espaço é $n = 2$, ou seja no plano euclidiano. O discriminador linear

descrito anteriormente pode ser utilizado como um classificador de padrões. Para tal, suponhamos duas coleções $\Phi 1 = \{ \mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_k \}$ de k vetores n -dimensões e $\Phi 2 = \{ \mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_m \}$ de m vetores n -dimensões.

FIGURA 6 - O discriminador linear separa o espaço em duas regiões A e B.

Suponhamos ainda, que desejamos implementar um discriminador linear que separe estas duas coleções de vetores no sentido da expressão 6. Naturalmente isto só será possível se as coleções $\Phi 1$ e $\Phi 2$ formarem aglomerados no espaço $\mathbb{R}^n$, tal que seja possível passar um hiperplano:

$$\sum_{i=1}^n w_i x_i = \mathbf{w}^T \mathbf{x} = b \quad (7)$$

que separe os dois aglomerados. Se as coleções $\Phi 1$ e $\Phi 2$ forem tais que esta separação é possível, então são *ditas coleções linearmente separáveis*. Caso contrário, não são separáveis linearmente e não existirá nenhum discriminador linear capaz de executar esta função. Nas figuras 7(a) e 7(b) estão ilustradas as duas situações.

FIGURA 7 - Coleções linearmente separáveis (a) e não separáveis linearmente (b)

O neurônio de McCulloch e Pitts é um discriminador linear com a simplificação adicional de que os componentes do vetor de entrada x são também binários, isto é, $x_i \in [0,1]$. Deste modo, funções booleanas como **E**, e **OU**, que são linearmente separáveis, são implementáveis com o neurônio de McCulloch. No entanto, a função booleana **OU EXCLUSIVO**, que não é linearmente separável, não é implementável utilizando-se apenas um neurônio de McCulloch e Pitts. Neste caso, seriam necessários duas retas discriminatórias para separar os dois tipos de classes, como pode ser visualizado na Figura 8.

FIGURA 8 - Função booleana XOR de duas variáveis.

Contudo, ainda segundo KOVÁCS (1996), embora neurônios simples não tenham a capacidade de implementar todas as funções booleanas, sempre existirá

alguma rede de neurônios múltiplos interconectados que conseguirá realizar tal implementação.

2.4. - Redes Neurais Artificiais de Múltiplas Camadas

No final da década de 1950, ROSENBLATT² *apud* KOVÄCS (1996) na Universidade de Cornell, deu prosseguimento às idéias de McCulloch. Ele criou uma genuína rede de múltiplos neurônios de McCulloch do tipo *discriminadores lineares* e chamou esta rede de perceptron. Apesar de avanços em relação ao modelo de McCulloch e Pitts, como a introdução de uma regra de treinamento, o novo modelo não conseguia implementar a função booleana **OU EXCLUSIVO**, devido ao fato de ser um discriminador linear.

Na mesma época que Rosenblatt trabalhava no perceptron, WIDROW³ *apud* KOVÄCS (1996) desenvolveu um modelo neural linear, muito simples conceitualmente, que ele batizou de ADALINE. Mais tarde sua generalização multidimensional foi batizada MADALINE. A contribuição de Widrow diz respeito ao princípio de treinamento introduzido por este, conhecido como **REGRA DELTA**. No entanto, este novo conceito não passaria de um exercício acadêmico de otimização em espaços lineares, não tivesse preparado o terreno para a introdução mais tarde, por RUMELHART (1986), do mais poderoso procedimento que se conhece até hoje para treinamento de redes neurais, o método *backpropagation*, que será discutido posteriormente.

As limitações de um simples perceptron não se aplicam à redes neurais de multicamadas do tipo *feed-forward*, cujo esquema podemos observar na Figura 9.

² ROSENBLATT, F. (1962). *Principles of neurodynamics*. New York, Spartan.

³ WIDROW, B. (1962). *Generalization and information. Storage in networks of Adaline neurons, on Self-Organizing Systems*.

FIGURA 9 - Esquema de Rede Neural Artificial do tipo feed-forward.

Neste modelo a propagação da informação é da camada de entrada para a camada de saída, sem realimentação para as unidades de processamento anteriores. As conexões existem apenas entre elementos de camadas diferentes, sendo que as unidades conectadas diretamente na entrada da rede são pertencentes a uma camada conhecida como **camada de entrada**. Esta camada não possui *offset* (*threshold*). A saída da rede é fornecida por uma camada conhecida como **camada de saída**. As outras unidades são organizadas em uma ou mais camadas **intermediárias**, que não são diretamente alcançadas. A operação de uma RNA tipo *feed-forward* consiste inicialmente da apresentação de um padrão de entrada, representado na figura pelo vetor $\bar{X} = [x_1, x_2, \dots, x_n]$ à camada de entrada. Em seguida a camada de entrada redistribui este padrão, associado a um peso, à camada intermediária. A entrada total de cada unidade da camada intermediária ($I_j = \sum_{i=1}^n w_{ij}x_i$) provocará novos estados de ativação ($\bar{A} = [a_1, a_2, \dots, a_m]$), que serviram de entrada para a camada de saída ou uma outra camada intermediária. Na camada de saída, estas entradas provocaram novos estados de ativação ($\bar{B} = [b_1, b_2, \dots, b_p]$) que gerarão em respostas ($\bar{Y} = [y_1, y_2, \dots, y_p]$) na camada de saída. Compara-se então, às respostas obtidas com

as respostas desejadas, para, se necessário, modificar-se os pesos das conexões entre as unidades através de um algoritmo apropriado de treinamento, que será abordado no próximo item.

Terminado o treinamento, a RNA será capaz de fornecer as corretas respostas para as relativas entradas. Dada a capacidade deste modelo em generalizar, a RNA poderá responder corretamente à entradas não vistas, ou seja, que não foram apresentadas na fase de treinamento. Ainda, devido a capacidade de abstração do modelo, a rede será capaz de extrair apenas as características essenciais de entradas que possuem informações redundantes, irrelevantes, ou mesmo incompletas.

2.5. - Regra de Aprendizagem

Para que a RNA consiga efetuar a tarefa proposta eficientemente, ela deve passar por um processo de aprendizagem, no qual ocorrerá a mudança dos valores das conexões entre as unidades de processamento. Neste processo de mudanças dos valores entre as conexões, poderá existir o aparecimento de novas conexões, perda de conexões, ou ainda a modificação de conexões já existentes. Este processo de aprendizagem, que implica em modificação dos valores das conexões, visa a obtenção de **experiência**, característica relacionada à capacidade da RNA em efetuar corretamente a tarefa proposta. Para a obtenção desta experiência, faz-se uso de algoritmos de treinamento que podem ser:

- 1) **Treinamento supervisionado**, cuja principal característica é o conhecimento prévio da informação sobre a classe, a que pertence cada padrão de treinamento. Neste tipo de treinamento, a aprendizagem é realizada através da comparação direta entre a saída desejada e a saída obtida pela RNA. Para o ajuste dos pesos das conexões, utiliza-se o erro associado a diferença entre as duas saídas, que serve como orientador do processo de treinamento.

- 2) **Treinamento não supervisionado**, cuja principal característica é o não conhecimento da informação sobre a classe, a que pertence cada padrão de treinamento. Dada esta característica, a RNA não possui um orientador e assim, por si só, deve agrupar os padrões em diferentes classes no decorrer da fase de

treinamento. Para tal agrupamento, a RNA deve utilizar-se de algum critério de similaridade previamente definido. Espera-se que a RNA analise correlações entre os padrões de entrada fornecendo saídas correspondentes às classes das entradas.

3) **Treinamento supervisionado e não supervisionado**, cuja principal característica é a utilização dos dois métodos de treinamento mencionados anteriormente. Na fase de treinamento, utiliza-se conhecimento prévio sobre as classes que os padrões de treinamento pertencem, e na fase de utilização, novas classes são adicionadas através de treinamento não supervisionado.

Um dos algoritmos mais utilizados no treinamento de RNA de múltiplas camadas é conhecido como algoritmo de retropropagação ou também citado na literatura por *backpropagation*. Este algoritmo é do tipo supervisionado, e foi inventado independentemente por uma série de pesquisadores. No entanto, sua popularização, como citado anteriormente, foi realizada por Rumelhart (1986). O algoritmo é baseado no método do gradiente descendente e será discutido à seguir.

2.5.1. - Algoritmo *Backpropagation*

O algoritmo de treinamento *backpropagation*, é o algoritmo mais comumente utilizado nas pesquisas atuais em RNA. Este algoritmo pode ser aplicado a qualquer RNA de múltiplas camadas do tipo *feed-forward*. Segundo HERTZ (1991), o funcionamento do algoritmo ocorre em duas etapas distintas. Na primeira etapa, ocorre a propagação da informação no sentido camada de entrada, camada de saída. Em seguida, ocorre uma segunda etapa de processamento. Nesta, em sentido inverso (*backward*), propaga-se um erro que irá modificar os pesos das conexões entre as unidades de processamento. Este processo é repetido até a RNA satisfazer um critério de parada, usualmente uma diferença preestabelecida entre a saída desejada e a obtida. O algoritmo descrito procura, como citado, minimizar o erro entre a saída desejada e a obtida. Para tal, ele utiliza o método do gradiente descendente, que requer funções de ativação que variem suavemente, como é o caso da função sigmoide. Maiores detalhes sobre o funcionamento do algoritmo podem ser encontrados nas referências citadas anteriormente.

3. Revisão Bibliográfica

Como mencionado anteriormente, existe um grande número de publicações em artigos e teses apontando o progresso das aplicações utilizando Redes Neurais Artificiais. Neste capítulo serão comentados alguns destes trabalhos publicados, dando-se ênfase à linha de pesquisa aplicada em proteção de L.T.. Os trabalhos são apresentados por ordem cronológica.

3.1. Proteção de Sistemas Elétricos de Potência utilizando Redes Neurais Artificiais

KHAPARDE *et al.* (1991) investigaram a factibilidade do uso de RNAs em proteção de linhas de transmissão. No artigo é proposto a utilização do modelo sugerido por WIDROW ⁴ *apud* KHAPARDE *et al.* (1991) e conhecido como Adaptive Linear (Adaline), para funcionar como um classificador de padrões. Os padrões de entrada da rede neural, são compostos por amplitudes de tensão e corrente, que são quantificadas sobre a faixa de operação do relé. As atualizações dos pesos, durante a fase de treinamento, que é realizada *off-line*, segue a regra abaixo:

$$w(k+1) = w(k) + (y-d).x(k) \quad (1)$$

onde: $w(k+1)$ representa o peso atualizado, $w(k)$ o peso anterior, y a saída atual do neurônio, d é a saída desejada, e $x(k)$ é a entrada atual da unidade de processamento. Os resultados mostraram que o modelo proposto foi capaz de realizar

⁴ WIDROW, B.; WINTER, R.G.; BAXTER, R.A. (1988) Layered neural nets for pattern recognition. *IEEE Trans. On Acoustics, Speed and Signal Processing*, v. 36, n.7, jul.

uma correta classificação de padrões compostos por sinais de tensão e corrente. No entanto, o fato do modelo adotado se utilizar do ADALINE, que é um discriminador linear, limita a capacidade de atuação do esquema, principalmente quando o sistema a ser protegido é mais complexo.

KANOH *et al.* (1991) propuseram um método, baseado no processo de inferência, para a detecção da seção de falta ao longo de uma linha de transmissão. Este método aplica RNA, e utiliza como padrões de análise a distribuição da amplitude e fase da corrente nos cabos pára-raios. O método, que também é capaz de determinar a seção de falta para sistemas de transmissão secundários, propõe uma rede neural composta de três sub redes, com três camadas cada. Duas das sub redes, analisando a distribuição da amplitude e fase da corrente pelo cabo para-raio, fornecem como saída dois candidatos a seção faltosa. Estes dois valores por sua vez, servem de entrada para a terceira sub rede que gera uma saída determinando a seção faltosa. O algoritmo de treinamento utilizado é o *backpropagation*, sendo cada sub rede neural treinada de forma independente, e os padrões de treinamento foram gerados pelo *software* EMTP. Os resultados demonstram a alta precisão do método. No entanto, o mesmo tem sua viabilidade questionada dada a necessidade de sensores ao longo de toda a linha de transmissão.

SWARUP *et al.* (1991) apresentam um trabalho onde se utiliza RNA para a detecção e diagnóstico de faltas em um sistema de transmissão. O sistema a ser protegido compreende dois transformadores de potência, três barramentos e duas L.T.. A rede neural utilizada possui 35 nós na camada de entrada, uma camada escondida com 18 nós e a camada de saída com 10 nós. Os padrões de entrada utilizados correspondem aos estados *on/off* dos relés e disjuntores. No trabalho utilizou-se uma representação binária para o vetor de características, sendo os valores 0 e 1 correspondendo aos estados *off* e *on* dos equipamentos de proteção respectivamente. A camada de saída do esquema representa todos os equipamentos do sistema de transmissão a serem protegidos. Nesta, o estado ativo representa um equipamento com falha e o estado inativo representa um equipamento em estado normal de funcionamento. O algoritmo de treinamento utilizado foi o *backpropagation*, sendo utilizados um número de 53 diferentes tipos de falta. Os

resultados do trabalho demonstram a eficácia da rede neural em detectar e diagnosticar corretamente o(s) equipamento(s) faltoso(s). No entanto, apenas 4 tipos de faltas diferentes das de treinamento foram testadas, fato que deixa de comprovar a capacidade de generalização do esquema.

CHAKRAVARTHY *et al* (1992) apresentaram um trabalho onde se propõe a utilização de técnicas de reconhecimento de padrões em relés à distância. O trabalho é dividido em dois artigos referidos como **conceitos e possibilidades**. O objetivo da primeira parte do trabalho é encontrar uma característica de operação que resolva as limitações da característica quadrilateral. Para tal, o trabalho se utiliza de técnicas de reconhecimento de padrões de forma a se obter uma função discriminante que consiga mapear corretamente a impedância aparente medida com o estado da L.T.. Esta função discriminante é obtida de amostras classificadas e geradas por simulações e medidas *on-line*. Coloca-se, nesta parte do trabalho que a principal dificuldade em reconhecimento de padrões é associar uma impedância observada X , de origem desconhecida, a uma das classes de impedâncias, definidas como estado normal de operação ou condição de falta. O requerimento para uma correta classificação é que uma completa informação a respeito da distribuição de X no espaço de características seja conhecida. No entanto, normalmente esta distribuição de X não é completamente conhecida e sim, derivada de um pequeno número de amostras, fato que dificulta a obtenção da função discriminante. Na segunda parte do trabalho, testa-se a metodologia proposta, mostrando que as impedâncias observadas são corretamente classificadas, mesmo quando da modificação de algumas características de operação do sistema.

O grande problema em se detectar faltas envolvendo altas impedâncias decorre do fato destas faltas limitarem a corrente pós-falta, o que impede equipamentos do tipo sobrecorrente de agirem. De modo a resolver este problema, SULTAN *et al.* (1992) apresentou um trabalho que detecta faltas de alta impedância e que se utiliza de RNAs. A rede neural utilizada, possui três camadas, com 33 neurônios na camada de entrada, 6 neurônios na camada escondida e 1 neurônio na camada de saída. O padrão de análise utilizado é proveniente de sinais de corrente devidamente normalizados entre 0 e 1. A saída, terá um valor binário, sendo 1 em

caso de ocorrência de falta e 0 em situação normal de operação. No treinamento da rede neural foi utilizado o algoritmo *backpropagation*, sendo os padrões de treinamento provenientes de faltas de alta impedância, situações normais de carga e situações de carga que se assemelham com faltas. Os testes mostraram que a RNA foi capaz de detectar faltas de alta impedância e corretamente diferenciar esta situação de fluxos de potência normais. O grande problema da metodologia proposta é derivada do tempo necessário para a rede neural convergir a uma saída, entre 0.75 e 4 segundos, fato que inviabiliza a implementação do método.

Baseado na idéia de que a função de um sistema de proteção é realizar a remoção imediata de qualquer seção com falta em sua zona de proteção, minimizando a interrupção do serviço de fornecimento de energia, YANG *et al.* (1994) apresentaram um modelo de diagnóstico de faltas, utilizando RNAs, para estimar *on-line* a seção do sistema de energia com defeito. Os padrões de entrada são compostos por representações binárias dos estados *on/off* dos relés e disjuntores. A camada de saída é composta por um número de neurônios que representa as seções protegidas. Os testes mostraram a capacidade do esquema em localizar a seção que apresenta falhas simples ou múltiplas. A grande limitação do método, é sua dependência de esquemas de proteção convencionais, que limitam o tempo de atuação.

DALSTEIN *et al.* (1995) exploram uma metodologia para classificação de faltas. O trabalho é dividido em duas frentes: a primeira, propõe-se um esquema para classificação de tipo de faltas, e a segunda, um esquema para discernimento entre faltas permanentes e não permanentes. No classificador de tipo de falta, utiliza-se uma rede neural que é alimentada por 5 amostras consecutivas dos sinais pós-falta de corrente e tensão, gerando assim um vetor de caracterização de 30 amostras. Estas amostras, são devidamente normalizadas, e são fornecidas à rede neural por um detector de faltas. A rede neural utilizada para efetuar a classificação do tipo de falta, possui uma camada de entrada com 30 unidades de processamento, duas camadas escondidas com 20 e 15 unidades respectivamente, e uma camada de saída com 11 neurônios. Os nós da camada de saída representam os diferentes tipos de falta que podem ocorrer na L.T., sendo que uma unidade ativa na camada de saída representa

um tipo de falta. No treinamento foi utilizado o algoritmo *backpropagation*. Um número de 45360 padrões foram usados para obter-se a convergência da rede neural. Diante da necessidade de estabilidade na saída da rede neural, colocou-se uma unidade de processamento na saída da rede neural com um *threshold* de 0.5. Neste esquema, apenas se três saídas consecutivas de uma unidade de processamento forem superiores ao *threshold* é que se considera a saída válida. Os testes demonstram que a rede neural converge para uma saída constante e correta em menos de 7ms se utilizando de uma frequência amostral de 1 KHz. Uma segunda parte do artigo refere-se a classificação das faltas ocorrendo com ou sem arco. Normalmente faltas sem arco são faltas permanentes e métodos convencionais tentam o religamento automático do sistema. Nesta situação, diferentes tipos de danos podem ser acarretados à equipamentos do sistema de transmissão. Segundo os autores, 80 % de todos os tipos de faltas são produzidas por arco, cuja influência no sinal de tensão é uma tensão sobreposta ao sinal pré-falta. Como a tensão de arco tem pequena influência na corrente de curto, os autores utilizaram apenas padrões compostos por amostras normalizadas dos sinais de tensão. Para este tipo de classificação da falta, foram utilizadas três redes neurais, uma para cada fase. Estas redes neurais, são alimentadas pelo classificador anterior, e por um ciclo do sinal de tensão pós-falta, o que gera um padrão de 20 características. No treinamento, foram utilizados 3000 padrões, e apenas faltas do tipo fase-terra foram utilizadas. Cada rede neural tinha respectivamente uma camada de entrada com 20 neurônios, duas camadas intermediárias com 15 e 10 neurônios respectivamente, e uma unidade na camada de saída. Na saída da rede, o neurônio em estado ativo determina a fase em que está ocorrendo uma falta envolvendo arco. O algoritmo de treinamento utilizado foi novamente o *backpropagation*. Na saída de cada rede neural foi posto uma unidade de processamento para dar confiabilidade ao esquema. Os testes demonstraram um grande grau de acerto do esquema, tendo a saída da rede alcançado estabilidade em tempos inferiores a 50ms.

SIDHU *et al.* (1995) apresentam em seu artigo um discriminador direcional de falta, que utiliza RNA. O discriminador, alimentado por amostras de corrente e tensão, deve localizar a posição da falta. Estando em sua zona de proteção, o

discriminador deve enviar um sinal de abertura para os respectivos disjuntores. A rede neural escolhida para efetuar esta localização, possui 12 neurônios na camada de entrada, uma camada escondida com 4 neurônios e 1 neurônio na camada de saída. O padrão de entrada, é composto por 5 amostras consecutivas pós-falta de corrente e tensão, gerando assim um padrão com 30 características. Os padrões de treinamento foram gerados no *software* EMTP e posteriormente processados. Na saída do EMTP, os sinais digitalizados de tensão e corrente saem a uma frequência amostral de 24 KHz. Estes sinais são filtrados por um filtro passa-baixa, com frequência de corte de 100Hz, e em seguida são reamostrados a uma frequência de 1.2 KHz. Em seguida, os sinais são normalizados de forma a terem um máximo valor unitário e um mínimo valor de -1. No treinamento de rede neural, foram utilizados 3240 padrões, e utilizou-se o algoritmo *backpropagation*. O discriminador foi testado aplicando-se 378 padrões de teste diferentes dos de treinamento. Os resultados demonstraram que a rede neural consegue localizar a falta em um tempo de no máximo 2.4 ms, mesmo diante da variação de parâmetros do sistema de transmissão. O esquema proposto, foi treinado e testado apenas em situações de falta envolvendo terra. Esta característica coloca uma dúvida sobre a capacidade de generalização da rede neural quando da apresentação de faltas não envolvendo terra.

DALSTEIN *et al.* (1996) propõe uma nova abordagem para a detecção da seção faltosa de um sistema de transmissão utilizando RNAs. O método proposto chamado de *Neural fault area estimator* (NFAE) consiste de 10 redes neurais, uma para cada tipo de falta possível. Quando a falta é classificada, um módulo da NFAE decide qual rede neural deve determinar a área faltosa. Esta rede neural, irá utilizar cinco amostras consecutivas dos sinais de tensão e corrente das fases faltosas, e gerará na sua saída um valor indicando a seção faltosa (1 ou 2) ou a não capacidade de classificação. As redes neurais que iram efetuar a localização da seção faltosa são do tipo *feedforward* contendo três camadas. O algoritmo de treinamento utilizado foi o *backpropagation*, com um número total de padrões de treinamento igual à 16000. O método foi testado utilizando-se 8000 padrões de teste, diferentes das de treinamento, e verificou-se que a boa qualidade de resposta, com tempos de atuação inferiores à 12ms. O fato do esquema ser treinado apenas para discernir entre duas

seções faltosas, e não todas as área possíveis, bem como a não inclusão nos testes de faltas com diferentes ângulos de incisão tornam o método de aplicação restrita.

BO *et al.* (1997) apresentaram um método baseado em RNA para identificar fase(s) faltosa(s) com o objetivo de viabilizar o *single-pole autoreclosure* (religamento automático de uma única fase, SPAR). O religamento de uma única fase tem sido bastante utilizado em aplicações de linhas longas, provando melhorar a segurança e a confiabilidade do sistema. Este sistema de religamento é apenas usado quando da ocorrência de faltas tipo fase-terra, e no caso de outro tipo de falta ser detectada, este detector inicia o religamento trifásico. O esquema proposto no artigo, se utiliza dos ruídos de alta frequência dos sinais de tensão, gerados pelas faltas, para identificar a(s) fase(s) faltosa(s). Para tal, um método para captar os ruídos da L.T. é necessário. Este método de captação das ondas de alta frequência, resume-se em um circuito projetado para ter uma impedância igual a da L.T. para a banda de passagem desejada, e bastante alta para a componente fundamental. Depois da captação dos componentes desejados, os padrões que irão ser apresentados à rede neural são formados. Nesta formação dos padrões, os autores propõe um procedimento para extração de características. Este procedimento, segundo os autores, irá diminuir o tamanho da rede neural utilizada, pois os padrões de entrada possuirão apenas características pertinentes. O procedimento divide o sinal no domínio da frequência em seis faixas, para cada fase:

(1) 0 - 16.6 KHz; (2) 16.7 - 31.3 KHz; (3) 31.4 - 46.9 KHz; (4) 50 - 65.6 KHz; (5) 66.7 - 81.3 KHz; (6) 81.4 - 100 KHz. Para cada faixa, é associado um valor de característica que compreende a soma das magnitude dos componentes de frequência da respectiva faixa. Deste modo, o padrão de entrada é formado por 18 características, 6 de cada fase. Os padrões foram gerados por simulação no *software* EMTP, e a rede neural escolhida possui 3 camadas, com 18 nós na entrada, 12 nós na camada escondida, e 3 nós na camada de saída. A frequência amostral utilizada é de 200 KHz. De modo a obter saídas mais precisas, os autores adicionaram à rede um *threshold* na camada de saída. Neste, se a saída for superior a 0.8 ela será classificada como 1, e classificada como zero no caso de ser inferior a 0.1. Os resultados demonstram que a rede neural é capaz de identificar faltas fase-terra, ocorrendo em

diferentes condições das apresentadas durante o treinamento. Outros tipos de falta, como trifásico-terra não são testados, fato que impede a confirmação da capacidade de generalização da rede neural.

COURY *et al.* (1997) colocaram as limitações dos relés à distância convencionais, e propuseram a utilização de RNAs como um classificador de padrões para a proteção de L.T. com circuito simples. Dentre as principais limitações dos relés à distância, os autores destacam que estes dispositivos são projetados com características de atuação constante, fato que limita o seu desempenho quando o sistema elétrico é sujeito a mudanças nos parâmetros de operação. Dada a conhecida capacidade de generalização e abstração de uma RNA, os autores propõe que a técnica seja utilizada para efetuar e aperfeiçoar a operação de um relé à distância. O esquema proposto é composto por uma RNA, que é alimentada pelas magnitudes dos fasores fundamentais de corrente e de tensão. Desta forma o padrão de entrada é um vetor composto por 6 amostras. Testes realizados demonstram bom desempenho da RNA mesmo quando diante de diferentes condições de falta, bem como diante de diferentes condições de operação do sistema. No entanto, devido a não efetuação de um maior número de testes com diferentes tipos de falta, não fica evidenciado a capacidade de generalização e abstração do esquema proposto.

JONGEPIER *et al.* (1997) propuseram a utilização de proteção à distância adaptativa para a proteção de L.Ts com circuito duplo. Neste trabalho, os autores utilizam RNAs para a estimação das condições de operação do sistema de potência. Com esta estimação, pode-se escolher a melhor característica de operação do relé. Os padrões utilizados pela rede neural são compostos por amostras dos sinais de corrente e tensão em situações não-faltosas e o “status” das chaves de alguns transformadores. O algoritmo de treinamento utilizado é o *backpropagation*. Para testar o esquema proposto, foram utilizados dados reais provenientes de algumas linhas de transmissão do sistema de transmissão holandês. Os testes demonstram que a rede neural é capaz de efetuar a estimação corretamente, e proporcionar assim uma característica ótima de operação para o relé. O grande benefício do método segundo os autores é de utilizar apenas medidas locais para efetuar a estimação, no entanto, mesmo em algumas situações apresentadas medidas de subestações adjacentes foram utilizadas.

Através das publicações apresentadas, procurou-se demonstrar alguns dos aspectos considerados por pesquisadores que propõe a utilização de RNAs para a resolução de problemas relacionados à proteção dos sistemas de potência. Destaca-se que a grande maioria dos autores utilizou redes neurais *feedforward* e empregou o algoritmo de treinamento *backpropagation*. Também é característica comum dos trabalhos apresentados a utilização do *software* EMTP na geração dos padrões de treinamento e teste da situação analisada.

4. Configuração do Sistema Elétrico Estudado

Nos próximos itens será apresentada a configuração do sistema elétrico de potência estudado, características do *software* ATP utilizado para simular o sistema em questão, e um programa computacional que servirá para gerar padrões de treinamento para a rede neural artificial.

4.1. Introdução

De forma a comprovarmos a eficiência do método de proteção proposto, um modelo de linha de transmissão de dois terminais foi simulado sob diversas condições de operação de forma a possibilitar informações precisas sobre os sinais de tensão e corrente referentes ao barramento de medição.

Para simular o sistema elétrico sob as várias condições de operação desejadas, utilizou-se o *software* ATP, cujos detalhes de funcionamento são descritos a seguir.

4.2. Gerador de Dados - “Alternative Transients Program” (ATP)

O *software* ATP é um programa digital que permite a simulação de transitórios eletromagnéticos em redes polifásicas de configurações arbitárias. A simulação se baseia em um método que utiliza a matriz de admitância de barras, sendo a formulação matemática baseada no método de características (método de Bergeron), para elementos representados por parâmetros distribuídos, ou na integração trapezoidal, para elementos representados por parâmetros concentrados.

Durante a solução, são utilizadas técnicas de esparsidade e de fatorização triangular otimizada de matrizes. Os valores finais obtidos são calculados em intervalos discretos de tempo os quais são previamente definidos. O programa permite ainda a representação de chaves, transformadores, geradores, reatores, etc... O ATP é um *software* desenvolvido a partir de versões anteriores do programa *Eletromagnetic Transients Program* (EMTP), sendo encontradas informações sobre o programa no manual ATP RULE - BOOK (1987).

4.3. Configuração do Sistema Elétrico de Potência

A configuração básica do S.E.P. analisado, com especificação das fontes, barramentos e comprimentos das linhas é mostrado em diagrama unifilar na figura 10. O sistema analisado corresponde a uma linha de transmissão com dois terminais de 400 KV, 100 Km interligando os terminais PT, e 100 Km interligando os terminais TQ.

FIGURA 10 - Diagrama unifilar do sistema elétrico analisado.

Conforme colocado anteriormente, o sistema elétrico da figura 10 foi simulado no *software* ATP, que será explicitado posteriormente. Neste trabalho, a L.T. entre os barramentos T e Q, representada pela região pontilhada da figura 10, foi definida como a zona do sistema de transmissão a ser protegida. De forma a definir a zona de proteção para posterior análise e treinamento da rede neural artificial,

simula-se no ATP situações faltosas entre os barramentos PT e TQ. Dentro desta filosofia, faltas entre os barramentos PT não pertencentes a zona de proteção do relé foram relacionadas a um valor nulo (0). Por sua vez, situações de faltas que pertencem a zona de proteção do relé, ou seja entre os barramentos TQ, foram relacionadas a um valor unitário (1), indicando que devem ser tomadas decisões para excluir a falta.

4.3.1. Disposição geométrica da Linha de Transmissão

A configuração geométrica da L.T. é mostrada na figura 11. Nesta mostra-se o perfil da torre utilizada, disposição espacial dos condutores e dos cabos pára-raios.

FIGURA 11 - Topologia da Linha de Transmissão.

A seguir, apresenta-se as especificações dos condutores empregados, denotando-se suas principais características.

Condutores

- 1) tipo do condutor: Bluejay 45 x 7 - ACSR;
- 2) relação entre a espessura e o diâmetro externo do condutor (T/D) : 0.231;
- 3) diâmetro interno do condutor: 7.98 mm;
- 4) diâmetro externo do condutor: 31.98 mm;
- 5) resistência em corrente contínua: 0.051370 Ω/Km .

Pára-raios

- 1) tipo do condutor: Guínea 12 x 7 - ACSR;
- 2) relação entre a espessura e o diâmetro externo do condutor (T/D): 0.5;
- 3) diâmetro externo do condutor: 14.6 mm;
- 4) resistência em corrente contínua: 0.35961 Ω/Km ;

Resistividade do solo

R_{solo} : 250 Ω/Km .

4.3.2. Parâmetros do Sistema Elétrico de Potência

De modo a efetuar as simulações do sistema elétrico proposto, utilizando o *software* ATP, adotou-se as considerações necessárias para se calcular os parâmetros da L.T.. Entre as considerações, optou-se por linhas transpostas. A transposição das linhas compensa os desequilíbrios dos campos magnéticos entre as fases, cabo pára-raios, ferragens e o solo sob a L.T.. Outra consideração, foi a de representar a L.T. por parâmetros distribuídos e não dependentes da frequência. Os parâmetros dependentes da frequência são importantes quando os efeitos de alta frequência são objetivo de estudo, o que não se refere ao caso estudado.

Segundo STEVENSON (1978), para se obter uma representação exata de uma L.T., deve-se considerar que os parâmetros da linha estão uniformemente distribuídos ao longo de seu comprimento, e não concentrados em um único ponto. Na figura 12, mostra-se uma pequena seção de uma L.T. de uma única fase.

FIGURA 12 - Representação por parâmetros distribuídos de uma seção de uma L.T.

Os parâmetros distribuídos e constantes R , L , C , e G são respectivamente a resistência da linha por unidade de comprimento, a indutância da linha por unidade de comprimento, a capacitância da linha por unidade de comprimento e a condutância da linha por unidade de comprimento.

Estes parâmetros citados anteriormente, serão determinados por uma rotina do *software* ATP chamada *Line Constants*, que será discutido adiante. A resistência de fuga, representada pela condutância na figura 12, representa os vários caminhos da linha para a terra. O percurso principal, é aquele formado pelos isoladores da L.T., cuja resistência depende do estado de limpeza da superfície do artefato, que por sua vez, é bastante variável dependendo da localização da linha. Diante deste fato, e ainda de seu valor desprezível, resolveu-se desprezar a resistência de fuga.

4.3.3. *Line Constant* e a Interface Gráfica DESTRO

A rotina *Line Constant*, presente no *software* ATP, permite o cálculo dos parâmetros da L.T.. Os valores gerados, são valores de sequência positiva e zero referentes às resistências, reatâncias e susceptâncias, considerando a L.T. com transposição. O arquivo de entrada que permitirá a rotina calcular os parâmetros, possuirá informações da topologia da L.T., resistividade do solo, condições da linha (com ou sem transposição), frequência em que os parâmetros serão calculados, número de condutores por fase, etc. Na figura 13 é listado o arquivo de entrada da rotina *Line Constants*.

```
BEGIN NEW DATA CASE
C  LINE CONSTANT      com transposicao
C  Test of for 200-km, single-circuit, 400-kV overhead
C  line that connects "Rio Maior" with "Cedillo" (Portuguese substations).
C  There are 2 ground wires (both eliminated), and each phase consists of a
C  bundle of 2 conductors.
C
C  parametros calculados para 600 Hz
C
LINE CONSTANTS
METRIC
BRANCH PA  BUSTA PB  BUSTB PC  BUSTC
C  1      2      3      4      5
C 34567890123456789012345678901234567890123456789012345678901234567890
1 .231 .05137 4      3.198 -12.2 21.63 9.83
1 .231 .05137 4      3.198 -11.8 21.63 9.83
2 .231 .05137 4      3.198 -0.2 21.63 9.83
2 .231 .05137 4      3.198 0.2 21.63 9.83
3 .231 .05137 4      3.198 11.8 21.63 9.83
3 .231 .05137 4      3.198 12.2 21.63 9.83
0.5 .35961 4      1.46 -8.05 30.5 23.2
0.5 .35961 4      1.46 -7.65 30.5 23.2
0.5 .35961 4      1.46 7.65 30.5 23.2
0.5 .35961 4      1.46 8.05 30.5 23.2
BLANK card ending conductor cards within "LINE CONSTANTS" data
C  1      2      3      4      5      6      7
C 34567890123456789012345678901234567890123456789012345678901234567890
250.    600.0      11 11  1 150.    0
C 250.    6.0      150.    5 30
BLANK card ending frequency cards of "LINE CONSTANTS" data
BLANK card ending "LINE CONSTANTS" data cases
BEGIN NEW DATA CASE
BLANK
```

FIGURA 13- Arquivo de entrada da rotina *Line Constants*.

Obtidos os parâmetros da L.T., utilizou-se a interface gráfica DESTRO (1996) para gerar o arquivo de entrada do ATP. Esta interface, permite facilidades na geração do arquivo de entrada do ATP, que por sua vez descreve a situação em que se encontra o sistema elétrico de potência.

4.3.4. Arquivo Principal de Dados

O arquivo de entrada do *software* ATP, possui informações sobre os parâmetros do sistema elétrico, sua configuração e condição de operação. A idéia básica do estudo em questão consiste em simular o sistema sob diversas condições faltosas, de forma a gerarmos informações suficientes para a rede neural artificial ser capaz de aprender a discernir as situações em que deve atuar (faltas dentro da sua zona de proteção), das situações em que não deve atuar (faltas fora da zona de proteção). Na figura 14 temos uma listagem do arquivo de entrada.


```

BEGIN NEW DATA CASE
2.0000-5.1000000
  1 1 1 1 1 1
$DISABLE
$ENABLE
$VINTAGE, 1
RPTA 5.000000000E+00 0.000000000E+00 0.000000000E+00 0
RPTB 5.000000000E+00 0.000000000E+00 0.000000000E+00 0
RPTC 5.000000000E+00 0.000000000E+00 0.000000000E+00 0
RTQA 5.000000000E+00 0.000000000E+00 0.000000000E+00 0
RTQB 5.000000000E+00 0.000000000E+00 0.000000000E+00 0
RTQC 5.000000000E+00 0.000000000E+00 0.000000000E+00 0
-1PA FPTA 5.08621E-01 2.02910E+00 8.33030E-03 5.00000E+01 0 00
-2PB FPTB 4.69600E-02 1.05245E+00 1.10310E-02 5.00000E+01 0 00
-3PC FPTC
-1FPTA TA 5.08621E-01 2.02913E+00 8.33030E-03 5.00000E+01 0 00
-2FPTB TB 4.69600E-02 1.05245E+00 1.10310E-02 5.00000E+01 0 00
-3FPTC TC
-1T1A FTQA 5.08621E-01 2.02913E+00 8.33030E-03 5.00000E+01 0 00
-2T1B FTQB 4.69600E-02 1.05245E+00 1.10310E-02 5.00000E+01 0 00
-3T1C FTQC
-1FTQA QA 5.08621E-01 2.02913E+00 8.33030E-03 5.00000E+01 0 00
-2FTQB QB 4.69600E-02 1.05245E+00 1.10310E-02 5.00000E+01 0 00
-3FTQC QC
$VINTAGE, 0
51GERPA PA .31820 9.62069E+00
52GERPB PB 1.4035 4.24403E+01
53GERPC PC
$VINTAGE, 0
51QA GERQA .33490 1.01273E+01
52QB GERQB 1.4774 4.46737E+01
53QC GERQC
$VINTAGE, 1
$VINTAGE, 0
BLANK card terminating network
TA T1A MEASURING 1
TB T1B MEASURING 1
TC T1C MEASURING 1
FPTA RPTA 1.000E+00 1.000E+02 0.000E+00 0
FPTB RPTB 1.000E+00 1.000E+02 0.000E+00 0
FPTC RPTC 1.000E+00 1.000E+02 0.000E+00 0
FTQA RTQA 1.000E+00 1.000E+02 0.000E+00 0
FTQB RTQB 1.000E+00 1.000E+02 0.000E+00 0
FTQC RTQC 1.000E+00 1.000E+02 0.000E+00 0
BLANK card terminating switches
14GERPA 0 3.266E+05 6.000E+01 0.000E+00 0 -1.000E+00 1.000E+02
14GERPB 0 3.266E+05 6.000E+01 -1.200E+02 0 -1.000E+00 1.000E+02
14GERPC 0 3.266E+05 6.000E+01 1.200E+02 0 -1.000E+00 1.000E+02
14GERQA 0 3.266E+05 6.000E+01 1.000E+01 0 -1.000E+00 1.000E+02
14GERQB 0 3.266E+05 6.000E+01 -1.100E+02 0 -1.000E+00 1.000E+02
14GERQC 0 3.266E+05 6.000E+01 1.300E+02 0 -1.000E+00 1.000E+02
BLANK card terminating sources
TA TB TC
BLANK card terminating outputs
BLANK card terminating plots
BEGIN NEW DATA CASE

```

FIGURA 14 - Arquivo de entrada do ATP.

De forma a simular as condições faltosas no sistema elétrico, criou-se seis chaves que ligam cada fase entre os barramentos PT e TQ à terra. Estas chaves, que

inicialmente estão abertas, serão fechadas de forma conveniente a se representar as possíveis faltas. Na figura 15, está exposto um esquema do sistema elétrico em estudo caracterizando os principais nós que ajudam na montagem do sistema no arquivo de entrada do ATP.

FIGURA 15 - Esquema da rede elétrica em estudo.

O esquema apresentado na figura 15 inclui os geradores (fonte ideal somada a um circuito RL), com valores especificados em p.u., as resistências e indutâncias dos segmentos da linha de transmissão, as possíveis resistências de falta, os barramentos e os respectivos nós que ajudam na montagem do sistema no arquivo de entrada do ATP. Ainda, de acordo com a figura 15, segue a legenda abaixo:

- R_{fi} e L_{fi} indicam as resistências e indutâncias relacionadas com a fonte i , para $i = 1, 2$.
- L_{tij} indicam as porções da linha segmentadas pelo nó contendo as resistências de falta.
- P , T , e Q são os barramentos tomados como referência do sistema estudado.

- **FPT** e **FTQ** indicam os interruptores controlados por tempo (especificados em campos definidos no arquivo de dados), que são fechados quando se quer determinar a ocorrência de uma falta na linha de transmissão.

- **Rf** representam as resistências de falta.

O esquema da figura 15, como colocado anteriormente, serve para facilitar a representação do sistema elétrico em estudo no arquivo de entrada do ATP. De forma a simularmos diferentes condições de operação com o objetivo de gerar informações a respeito do comportamento dos sinais de corrente e tensão no barramento T, variações no arquivo de entrada devem ser feitas. A seguir, expõe-se as simulações realizadas caracterizando as condições de operação do sistema elétrico.

4.4. Simulações Realizadas no Sistema Elétrico em Estudo

De modo a gerar padrões que explicitem informações suficientes de forma que a rede neural artificial consiga aprender a discernir corretamente entre as possíveis situações faltosas, é necessário simular um conjunto de situações de operação do sistema elétrico. Este conjunto de padrões, que no caso resumirá informações a respeito de faltas em que o sistema de proteção deve ou não atuar, será utilizado, como mencionado anteriormente, para o treinamento da rede neural artificial através do algoritmo *backpropagation*. O conjunto de situações de operação do sistema elétrico escolhido foi composto através de informações provenientes de 1710 situações faltosas simuladas no *software* ATP. Para obtermos este conjunto, variou-se a distância de falta (em relação ao barramento T), o ângulo de incidência da falta, a resistência de falta e o tipo de falta. De modo a obtermos um conjunto representativo para as duas situações de faltas possíveis, entre PT ou entre TQ (figura 10), utilizou-se um número igual de padrões para as duas situações possíveis (855 para cada segmento da L.T.). As variações utilizadas consideraram os seguintes parâmetros:

a) Distâncias de falta utilizadas na formação do conjunto de padrões:

- Distâncias entre os barramentos P e T, tomando T como referência (Km):

6, 10, 15, 20, 25, 30, 35, 40, 45, 50, 55, 60, 65, 70, 75, 80, 85, 90, e 94.

- Distâncias entre os barramentos T e Q, tomando T como referência (Km):

6, 10, 15, 20, 25, 30, 35, 40, 45, 50, 55, 60, 65, 70, 75, 80, 85, 90, e 94.

- b) Ângulos de incidência de falta ($^{\circ}$):

0, 45, e 90.

- c) Resistências de falta utilizadas (Ω):

5, 25 e 75.

- d) Tipos de falta:

B-T : fase B à terra.

AC-T: fase BC à terra.

AB: fase AB à terra.

ABC: fase ABC à terra.

C-T: fase C à terra.

Nas figuras seguintes, são mostradas os possíveis tipos de faltas.

16.a - Falta fase-terra
(falta a-terra)

16.b - Falta fase-fase
(falta a-b)

16.c - Falta fase-fase-terra
(falta a-b-terra)

16.d - Falta trifásica
(falta a-b-c)

16.e - Falta trifásica-terra
(falta a-b-c-terra)

FIGURA 16 - Possíveis Tipos de Falta.

A resposta de cada simulação no *software* ATP gerou sinais de corrente e tensão em relação ao barramento T (figura 10), onde estará localizado o relé. Estes respectivos sinais trifásicos são gerados a uma frequência amostral de 50 KHz, ou seja 834 amostras em um ciclo de 60 Hz. Devido a alta taxa amostral presente na saída do *software* ATP, resolveu-se implementar um *software* chamado de **Extração de Características**, que atuará de forma a extrair as informações úteis dos sinais trifásicos. Maiores detalhes sobre o programa são apresentados a seguir.

4.5. *Software* de Extração de Características

O *software* implementado é composto, inicialmente, por um conjunto de operações (filtragem digital e reamostragem) que procuram simular o *hardware* de um esquema de proteção convencional, e desta forma adequar a realidade a massa de dados provenientes da saída do ATP. Um segundo conjunto de operações presentes no programa visa a formação dos padrões de entrada da rede neural artificial, e desta forma simular a parte de *software* do esquema de proteção proposto. Na figura 13, apresenta-se um fluxograma que contém as principais operações realizadas pelo programa.

FIGURA 17 - Fluxograma do *software* Extração de Características.

Como citado anteriormente, a saída do ATP, resultante das simulações de situações faltosas no sistema elétrico analisado, gera os sinais trifásicos de tensão e corrente do barramento T a uma frequência amostral de 50 KHz. O primeiro passo do programa de extração de características é a filtragem dos sinais de corrente e tensão

provenientes do ATP. O filtro digital passa-baixa implementado no programa, é do tipo Butterworth, sendo alguns comentários sobre o mesmo dados a seguir.

4.5.1. Filtro Digital passa-baixa Butterworth

Com o objetivo de se adequar os sinais de corrente e tensão a realidade encontrada em um barramento de medição, fez-se necessário a implementação dentro do programa **extração de características** um filtro digital passa-baixa do tipo Butterworth (SERRA(1983)).

Na figura 18, vemos a característica de um filtro passa-baixa ideal, onde a amplitude da função de transferência é constante de $w = 0$ até $w = w_c$ (frequência de corte) e zero para $w > w_c$. Deste modo, o filtro deixará passar apenas as componentes de baixa frequência.

FIGURA 18 - Característica de um filtro passa-baixa ideal.

A característica de perdas de um filtro passa-baixa ideal pode ser vista na figura 19. Nesta observa-se que o filtro possui perda zero na banda de passagem e perda infinita na faixa de frequência superior a frequência de corte (ANTONIOU (1979)).

FIGURA 19 - Característica de perda de um filtro passa-baixa ideal.

Um filtro passa-baixa real não possui estas características de funcionamento. Na banda de passagem existe perda e na banda de corte a atenuação não é infinita. Também no filtro real existe uma faixa de transição que se caracteriza pelo fato de que existe uma transição gradual da faixa de passagem para a faixa de corte. Na figura 20, ilustram-se estas características de atuação descritas anteriormente. Nesta figura, ω_p indica a frequência final da banda de passagem, ω_c a frequência de corte e ω_a a frequência de atenuação.

FIGURA 20 - Característica de perda de um filtro passa-baixa real.

Escolheu-se o filtro Butterworth pois este pode prover máxima planura na faixa de passagem, com um valor máximo de atenuação igual a 1dB e um decréscimo monotônico de ganho até a frequência desejada com atenuação 60 dB (caso projetado). A frequência de corte escolhida do filtro digital implementado foi de 400 Hz. A escolha deste valor de frequência de corte é uma consequência da idéia de se simular criteriosamente o *hardware* de um esquema de proteção convencional. Como é sabido, de forma a se evitar o efeito *aliasing* no conversor A/D, filtra-se os sinais com uma frequência de corte igual a metade da frequência amostral do conversor. Partindo do princípio de que teremos um conversor com frequência amostral de 960 Hz, teríamos um filtro analógico passa-baixa com uma frequência de corte menor ou igual à 480 Hz, igual ao simulado no programa. Como ilustração da aplicação do filtro digital de Butterworth implementado, apresenta-se na figura 21 o sinal da corrente da fase A para uma falta ocorrida a 6 Km do barramento T, entre TQ envolvendo a fase A, com resistência de falta de 5 Ω e com ângulo de incidência de falta de 90°. Ainda, na mesma figura é apresentada a saída do filtro passa-baixa para a mesma situação.

FIGURA 21 - Valores amostrados referentes a corrente quando uma falta envolvendo a fase a à terra é aplicada a 6 Km do barramento T (figura 10), com um ângulo de incidência de 90^0 e com resistência de falta de 0.1Ω .

Como pode-se notar na figura 21, o filtro digital filtra as componentes de alta frequência dos sinais, simulando assim um filtro analógico real passa-baixa.

4.5.2. Reamostragem dos Dados para 960 Hz

De modo a simularmos um conversor A/D com frequência amostral de 960 Hz, reamostrou-se os sinais filtrados, obtendo-se 16 amostras em um ciclo de 60 Hz. Com esta reamostragem, adequa-se os sinais provenientes do *software* ATP às condições encontrada na realidade, e finaliza-se a simulação do *hardware* de um esquema de proteção convencional. A seguir, apresentam-se as simulações da parte de *software* do esquema de proteção proposto. A primeira parte do *software* de proteção corresponde a uma operação que irá detectar e identificar a ocorrência de uma falta.

4.5.3. Identificação do Ponto de Ocorrência da Falta

Para detectar uma falta no sistema analisado, o programa implementado avalia mudanças bruscas nos sinais de corrente filtrados e reamostrados anteriormente. Para detectar mudanças bruscas nos sinais de corrente, compara-se as amostras de cada fase da linha com as amostras do ciclo anterior. A diferença de magnitude entre estes valores é, por sua vez, comparada com um valor de *threshold* previamente estipulado. Se três amostras consecutivas de uma mesma fase obtiverem diferenças em relação as amostras correspondentes do ciclo anterior, superiores ao valor estipulado, então considera-se que o sistema de transmissão está em condição faltosa.

Detectada a falta, o ponto de ocorrência da falta ou a primeira amostra pós-falta é considerada como sendo a primeira das três amostras consecutivas que obtiveram diferenças, em relação as amostras correspondentes do ciclo anterior, superiores ao *threshold* estipulado. O procedimento irá salvar a informação correspondente ao número da primeira amostra pós-falta e o tempo em que ela aconteceu, valores que serão posteriormente utilizados.

4.5.4. Formação dos Padrões de Entrada da Rede Neural Artificial

Testes demonstraram que padrões formados por 5 amostras consecutivas pós-falta dos sinais de tensão e corrente, gerando um padrão de entrada composto por 30 características continham informações suficientes para a rede neural artificial conseguir aprender a discernir corretamente. De modo a facilitar ainda mais o processo de treinamento da rede neural artificial, normalizou-se estas amostras de modo que ficassem entre o intervalo $[-1,1]$. Desta forma, o programa implementado neste estágio irá, com a informação do ponto de ocorrência da falta, utilizar-se de 5 amostras consecutivas pós-falta dos sinais de corrente e tensão referentes ao barramento T, normalizá-las e formar um padrão contendo 30 características (5 amostras para cada fase). Foram gerados 1710 padrões, correspondendo a 1710

simulações no *software* ATP, cujas características foram colocadas anteriormente (4.4.).

5. Aplicação de Redes Neurais Artificiais como Classificador de Padrões na Proteção Direcional

Neste capítulo será apresentado o simulador de redes neurais artificiais utilizado, características do treinamento da rede neural artificial escolhida, e resultados de testes feitos no esquema de proteção proposto.

5.1. Introdução

De forma a implementarmos uma rede neural artificial, utilizou-se o *software* “STUTTGART NEURAL NETWORK SIMULATOR” (SNNS). Este programa permite através de uma interface gráfica, a criação de um ambiente eficiente e flexível para a pesquisa e aplicação de redes neurais artificiais. Todo o processo de treinamento, bem como de testes da rede neural escolhida, foi realizado através do mesmo.

De modo a se comprovar a capacidade de generalização e abstração da rede neural artificial, gerou-se padrões de testes e avaliou-se a resposta da rede. As simulações de ocorrências de faltas no sistema elétrico analisado que geraram os padrões de teste, foram distintas das simulações que geraram os padrões de treinamento. Detalhes de funcionamento do SNNS são explicitados a seguir.

5.2. Software de Simulação de Redes Neurais Artificiais SNNS

O SNNS versão 4.1 é um simulador de redes neurais artificiais desenvolvido no *Institute for Parallel and Distributed High Performance Systems* na Universidade de Stuttgart, que também criou um manual, *User Manual, Version 4.1* (1995) contendo informações a respeito do funcionamento do *software*. Como colocado anteriormente, o objetivo do *software* é a criação de um ambiente de simulação flexível e eficiente que servirá para a efetuação de pesquisa e aplicações de redes neurais artificiais. A utilização do SNNS começa com a apresentação dos padrões de entrada (nesta fase padrões de treinamento), em seguida cria-se uma rede neural artificial de topologia determinada pelo usuário. Escolhida a arquitetura da rede neural, inicia-se a fase de treinamento. Em caso de obtenção de sucesso na fase de treinamento, convergência das saídas obtidas para as desejadas, realizam-se testes com padrões distintos dos de treinamento para verificar a capacidade de generalização da rede neural artificial. Para o problema em questão, foi utilizado o algoritmo de *Backpropagation* na fase de treinamento.

5.2.1. Padrões de Entrada

Os padrões de entrada devem estar em um arquivo com uma formatação específica do SNNS. Na figura 22, apresenta-se um arquivo contendo um padrão de treinamento resultante de uma falta localizada à 6 Km do barramento T, com ângulo de incidência de 0^0 , resistência de falta de 5Ω , entre TQ (figura 10).

```

Snns pattern definition file V3.2
generated at Mon July 11:30 1997

No. of patterns: 1
No. of input units: 30
No. of output units: 1

-.1179738E+00 -.1185279E+00 .3091650E+00 .3486300E+00 .4864463E+00
-.2695645E+00 .3503090E-01 -.7768545E-01 .1653693E+00 .2302704E+00
.3869593E+00 .8335955E-01 -.2310513E+00 -.5153220E+00 -.7168638E+00
.1570981E+00 .5736973E+00 .9534365E+00 .1216591E+00 .1421759E+00
-.1102102E+00 -.5743963E+00 -.1001907E+00 -.1306075E+00 -.1538872E+00
-.4727055E-01 .6931727E-03 .4848645E-01 .8888017E-01 .1158130E+00 1.00

```

FIGURA 22 - Arquivo de entrada do SNNS contendo 1 padrão de treinamento, formado a partir de uma simulação de falta entre TQ (figura 10), com resistência de falta de 5Ω , à 6 km do barramento T, e ângulo de incidência de 0° .

Como explicitado anteriormente, sendo a falta entre TQ dentro da zona de proteção do relé, a saída da rede neural artificial deve ser igual a um, informação que é fornecida no arquivo de entrada da figura 22. Outra informação que deve estar presente no arquivo de padrões, é o número de *inputs* e *outputs* da rede neural artificial. No caso estudado, teremos 30 entradas com 5 amostras de cada fase, e uma saída, que criará ou não um sinal de abertura para os disjuntores.

O arquivo apresentado na figura 22 possui apenas um padrão de treinamento, no entanto, como colocado anteriormente, o arquivo de padrões de treinamento utilizado para a etapa de aprendizagem da rede neural artificial possui 1710 padrões. Este arquivo não é apresentado por questões de espaço.

5.2.2. Topologia da Rede Neural Artificial

Uma das grandes dificuldades encontradas na utilização de redes neurais artificiais em reconhecimento de padrões se encontra na escolha da topologia (arquitetura) da rede. A escolha da topologia da rede neural é um fator determinante na capacidade ou não da técnica em classificar os padrões corretamente. No entanto,

não existe nenhuma metodologia indicando qual a melhor arquitetura de uma rede neural para a solução de um determinado problema, ou seja, a escolha do número de unidades de processamento nas camadas de entrada, intermediária e de saída é um procedimento empírico.

Diante deste fato, testou-se algumas arquiteturas no SNNS, utilizando como parâmetro de qualificação o erro total (somatório dos erros gerados por padrão) gerado ao final da fase de treinamento da rede neural. Os testes indicaram que a arquitetura que melhor classificava os padrões de treinamento possuía 3 camadas, com 2 camadas intermediárias de 12 e 4 unidades de processamento respectivamente e uma unidade de processamento na camada de saída. Na figura 23 expõe-se a arquitetura utilizada.

FIGURA 23 - Arquitetura da rede neural artificial utilizada.

Como colocado anteriormente, a topologia da rede neural artificial simulada no SNNS e apresentada na figura 23 obteve os melhores resultados ao final da etapa de treinamento. As características da rede neural artificial foram colocadas anteriormente (item 2.5.1.). A criação da topologia ilustrada na figura 23 no *software*

SNNS é de fácil execução, sendo realizada na rotina **BIGNET** do painel principal. A seguir apresenta-se detalhes da etapa de aprendizagem da rede neural escolhida.

5.2.3. Treinamento da Rede Neural Artificial

O algoritmo de treinamento utilizado foi o *backpropagation*, cujos detalhes de funcionamento foram fornecidos no capítulo 2. Nesta etapa de utilização do *software* SNNS, o arquivo contendo os padrões de treinamento já foi carregado pelo programa, e a rede neural artificial, com a topologia escolhida já foi criada. Toda a etapa de treinamento, como a de teste é realizada na rotina **CONTROL** do painel principal.

O primeiro passo no processo de treinamento da rotina **CONTROL** é a escolha dos valores iniciais dos pesos das conexões entre as unidades de processamento. Em nosso caso, foi escolhido a função que determina valores randômicos aos pesos iniciais das conexões. O segundo passo, concerne na escolha do algoritmo de treinamento, que como colocado anteriormente, foi escolhido o *backpropagation*. Ao se escolher a função de aprendizagem, deve-se definir alguns parâmetros. Entre eles destacamos a taxa de aprendizagem e o máximo erro total permitido (SSE, soma quadrática dos erros por padrão). A taxa de aprendizagem utilizada, foi decrescendo de 0.5 - 0.1 no decorrer do treinamento. O máximo erro total permitido, foi estabelecido em 0.001. Dentro da rotina **CONTROL**, pode-se escolher a forma de apresentação dos padrões de treinamento, sendo a primeira a própria seqüência do arquivo de entrada e a segunda misturando os padrões randômicamente na apresentação ao algoritmo de treinamento. Percebeu-se através de testes, que a segunda forma de apresentação dos padrões de treinamento proporcionava tempos de convergência menores, bem como menores SSEs ao final da etapa de treinamento. Na figura 24 é apresentado um gráfico demonstrando o progresso do processo de aprendizagem durante o treinamento.

FIGURA 24 - Progresso do processo de aprendizagem durante o treinamento.

Analisando o gráfico da figura 24, pode-se notar que em 15.000 ciclos de treinamento, o SSE da rede neural artificial é igual à 0.00051, abaixo do valor estipulado como critério de parada. É importante destacar que considera-se como um ciclo de treinamento quando todos os padrões são apresentados a rede neural e assim calcula-se o SSE. Com a convergência da rede neural escolhida ao final da etapa de treinamento, ou seja, com a descoberta dos pesos ideais para as conexões entre as unidades de processamento, salva-se no *software* SNNS a matriz de pesos. É importante destacar que a matriz de pesos contém a informação resultante do processo de aprendizagem, ou seja, possui em seu conteúdo a informação que possibilitará a rede neural a corretamente classificar os padrões de treinamento.

De forma a tornar o esquema de proteção proposto mais eficiente, colocou-se um *threshold* ao final da rede neural, como exposto na figura 3. Este *threshold* possui valor igual a 0.5, de modo que se a saída da rede neural for superior ao valor estipulado, a saída da unidade será igual a 1, em caso contrário, saída da rede neural inferior a 0.5, a saída da unidade será igual a 0. A seguir, apresentam-se testes que procuram provar a capacidade de generalização e abstração da rede neural artificial.

5.3. Testes e Resultados

De forma a testarmos o esquema de proteção proposto, simulou-se no ATP diversas condições faltosas, distintas das simulações utilizadas na geração dos padrões de treinamento. As variações utilizadas nestas simulações consideraram os seguintes parâmetros:

- a) Distâncias de falta utilizadas na formação do conjunto de padrões:
 - Distâncias entre os barramentos P e T, tomando T como referência (Km):
7, 9, 18, 19, 26, 29, 33, 38, 47, 48, 53, 58, 64, 68, 76, 78, 84, 89, e 94.
 - Distâncias entre os barramentos T e Q, tomando T como referência (Km):
6, 11, 16, 22, 24, 32, 36, 42, 47, 52, 53, 62, 67, 71, 74, 81, 82, 91, e 93.
- b) Ângulos de incidência de falta ($^{\circ}$):
22.5 e 67.5.
- c) Resistências de falta utilizadas (Ω):
7, 20 e 55.
- d) Tipos de falta:
 - A-T: Fase A à terra.
 - B-T: Fase B à terra.
 - C-T: Fase C à terra.
 - AC-T: Fase AC à terra.
 - AB-T: Fase AB à terra.
 - BC-T: Fase BC à terra.
 - ABC: Fase ABC.
 - ABC-T: Fase ABC à terra.
 - AB: Fase AB à terra.
 - AC: Fase AC.
 - BC: Fase BC.
- e) Mudança nas condições de operação do sistema de transmissão:

Diminuição de 10% na capacidade da fonte do barramento P (10GVA para 9GVA), com os outros parâmetros de operação constantes, para faltas A-T nas condições faltosas apresentadas anteriormente.

Diminuição de 5% na capacidade da fonte do barramento P (10 GVA para 9.5GVA), e de 5.26% na capacidade da fonte do barramento Q (9.5GVA para 9GVA), com os outros parâmetros de operação constantes, para faltas AB nas condições faltosas apresentadas anteriormente.

Diminuição de 5% na capacidade da fonte do barramento P (10 GVA para 9.5GVA), e de 5.26% na capacidade da fonte do barramento Q (9.5GVA para 9GVA), e de 50% no ângulo de transferência de potência do barramento Q (10^0 para 5^0), com os outros parâmetros de operação constantes, para faltas ABC nas condições faltosas anteriormente.

Foram simuladas 3192 situações de falta no sistema elétrico analisado da figura 10, sendo que em metade destas simulações a falta ocorreu entre os barramentos PT, e na outra metade entre os barramentos TQ (dentro da zona de proteção do relé). Os resultados das simulações no ATP, sinais de tensão e corrente referentes ao barramento T, foram processados pelo programa **extração de características** descrito no capítulo 4, gerando assim 3192 padrões de teste. Apresenta-se nas tabelas seguintes, as saídas da rede neural artificial quando da aplicação dos referidos padrões de teste. As tabelas são compostas por saídas da rede neural artificial quando apresentada à padrões provenientes de diferentes tipos de falta, localizadas dentro ou fora da zona de proteção do esquema, diferentes distâncias de falta em relação ao barramento T, diferentes ângulos de incidência de falta, diferentes resistências de falta e diferentes condições de operação. Será destacado em negrito os erros de classificação da rede neural artificial implementada.

Faltas tipo A-T entre os barramentos TQ							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5 ⁰	67.5 ⁰	22.5 ⁰	67.5 ⁰	22.5 ⁰	67.5 ⁰	
6 Km	1	1	1	1	1	1	1
11 Km	1	1	1	1	1	1	1
16 Km	1	1	1	1	1	1	1
22 Km	1	1	1	1	1	1	1
24 Km	1	1	1	1	1	1	1
32 Km	1	1	1	1	1	1	1
36 Km	1	1	1	1	1	1	1
42 Km	1	1	1	1	1	1	1
47 Km	1	1	1	1	1	1	1
52 Km	1	1	1	1	1	1	1
53 Km	1	1	1	1	1	1	1
62 Km	1	1	1	1	1	1	1
67 Km	1	1	1	1	1	1	1
71 Km	1	1	1	1	1	1	1
74 Km	1	1	1	1	1	1	1
81 Km	1	1	1	1	1	1	1
82 Km	1	1	1	1	1	1	1
91 Km	1	1	1	1	1	1	1
93 Km	1	1	1	1	1	1	1

TABELA 2 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase A-T entre os barramentos TQ.

Faltas tipo A-T entre os barramentos PT							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5^0	67.5^0	22.5^0	67.5^0	22.5^0	67.5^0	
7 Km	0	0	0	0	0.000010	0.000018	0
9 Km	0	0	0	0	0	0	0
18 Km	0	0	0	0	0	0	0
19 Km	0	0	0	0	0	0	0
26 Km	0	0	0	0	0	0	0
29 Km	0	0	0	0	0	0	0
33 Km	0	0	0	0	0	0	0
38 Km	0	0	0	0	0	0	0
47 Km	0	0	0	0	0	0	0
48 Km	0	0	0	0	0	0	0
53 Km	0	0	0	0	0	0	0
58 Km	0	0	0	0	0	0	0
64 Km	0	0	0	0	0	0	0
68 Km	0	0	0	0	0	0	0
76 Km	0	0	0	0	0	0	0
78 Km	0	0	0	0	0	0	0
84 Km	0	0	0	0	0	0	0
89 Km	0	0	0	0	0	0	0
94 Km	0	0	0.002021	0.001491	0	0	0

TABELA 3 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase A-T entre os barramentos PT.

Faltas tipo B-T entre os barramentos TQ							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5 ⁰	67.5 ⁰	22.5 ⁰	67.5 ⁰	22.5 ⁰	67.5 ⁰	
6 Km	1	1	1	1	1	1	1
11 Km	1	1	1	1	1	1	1
16 Km	1	1	1	1	1	1	1
22 Km	1	1	1	1	1	1	1
24 Km	1	1	1	1	1	1	1
32 Km	1	1	1	1	1	1	1
36 Km	1	1	1	1	1	1	1
42 Km	1	1	1	1	1	1	1
47 Km	1	1	1	1	1	1	1
52 Km	1	1	1	1	1	1	1
53 Km	1	1	1	1	1	1	1
62 Km	1	1	1	1	1	1	1
67 Km	1	1	1	1	1	1	1
71 Km	1	1	1	1	1	1	1
74 Km	1	1	1	1	1	1	1
81 Km	1	1	1	1	1	1	1
82 Km	1	1	1	1	1	1	1
91 Km	1	1	1	1	1	1	1
93 Km	1	1	1	1	1	1	1

TABELA 4 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **B-T** entre os barramentos TQ.

Faltas tipo B-T entre os barramentos PT							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5 °	67.5 °	22.5 °	67.5 °	22.5 °	67.5 °	
7 Km	0	0	0	0.000113	0	0.000003	0
9 Km	0	0	0	0	0	0	0
18 Km	0	0	0	0	0	0	0
19 Km	0	0	0	0	0	0	0
26 Km	0	0	0	0	0	0	0
29 Km	0	0	0	0	0	0	0
33 Km	0	0	0	0	0	0	0
38 Km	0	0	0	0	0	0	0
47 Km	0	0	0	0	0	0	0
48 Km	0	0	0	0	0	0	0
53 Km	0	0	0	0	0	0	0
58 Km	0	0	0	0	0	0	0
64 Km	0	0	0	0	0	0	0
68 Km	0	0	0	0	0	0	0
76 Km	0	0	0	0	0	0	0
78 Km	0	0	0	0	0	0	0
84 Km	0	0	0	0	0	0	0
89 Km	0	0	0	0	0	0	0
94 Km	0	0	0.000001	0	0	0	0

TABELA 5 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase B-T entre os barramentos PT.

Faltas tipo C-T entre os barramentos TQ							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5 ⁰	67.5 ⁰	22.5 ⁰	67.5 ⁰	22.5 ⁰	67.5 ⁰	
6 Km	1	1	1	1	1	1	1
11 Km	1	1	1	1	1	1	1
16 Km	1	1	1	1	1	1	1
22 Km	1	1	1	1	1	1	1
24 Km	1	1	1	1	1	1	1
32 Km	1	1	1	1	1	1	1
36 Km	1	1	1	1	1	1	1
42 Km	1	1	1	1	1	1	1
47 Km	1	1	1	1	1	1	1
52 Km	1	1	1	1	1	1	1
53 Km	1	1	1	1	1	1	1
62 Km	1	1	1	1	1	1	1
67 Km	1	1	1	1	1	1	1
71 Km	1	1	1	1	1	1	1
74 Km	1	1	1	1	1	1	1
81 Km	1	1	1	1	1	1	1
82 Km	1	1	1	1	1	1	1
91 Km	1	1	1	1	1	1	1
93 Km	1	1	1	1	1	1	1

TABELA 6 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase C-T entre os barramentos TQ.

Faltas tipo C-T entre os barramentos PT							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5 ⁰	67.5 ⁰	22.5 ⁰	67.5 ⁰	22.5 ⁰	67.5 ⁰	
7 Km	0	0	0	0	0	0	0
9 Km	0	0	0	0	0	0	0
18 Km	0	0	0	0	0	0	0
19 Km	0	0	0	0	0	0	0
26 Km	0	0	0	0	0	0	0
29 Km	0	0	0	0	0	0	0
33 Km	0	0	0	0	0	0	0
38 Km	0	0	0	0	0	0	0
47 Km	0	0	0	0	0	0	0
48 Km	0	0	0	0	0	0	0
53 Km	0	0	0	0	0	0	0
58 Km	0	0	0	0	0	0	0
64 Km	0	0	0	0	0	0	0
68 Km	0	0	0	0	0	0	0
76 Km	0	0	0	0	0	0	0
78 Km	0	0	0	0	0	0	0
84 Km	0	0	0	0	0	0	0
89 Km	0	0	0	0	0	0	0
94 Km	0	0	0	0	0	0	0

TABELA 7 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase C-T entre os barramentos PT.

Faltas tipo AB entre os barramentos TQ							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5 ⁰	67.5 ⁰	22.5 ⁰	67.5 ⁰	22.5 ⁰	67.5 ⁰	
6 Km	1	1	1	1	1	1	1
11 Km	1	1	1	1	1	1	1
16 Km	1	1	1	1	1	1	1
22 Km	1	1	1	1	1	1	1
24 Km	1	1	1	1	1	1	1
32 Km	1	1	1	1	1	1	1
36 Km	1	1	1	1	1	1	1
42 Km	1	1	1	1	1	1	1
47 Km	1	1	1	1	1	1	1
52 Km	1	1	1	1	1	1	1
53 Km	1	1	1	1	1	1	1
62 Km	1	1	1	1	1	1	1
67 Km	1	1	1	1	1	1	1
71 Km	1	1	1	1	0.999999	1	1
74 Km	1	1	1	1	0.999999	1	1
81 Km	1	1	1	1	0.999999	1	1
82 Km	1	1	1	1	0.999999	1	1
91 Km	1	1	1	1	1	1	1
93 Km	1	1	1	1	1	1	1

TABELA 8 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **AB** entre os barramentos TQ.

Faltas tipo AB entre os barramentos PT							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5 ⁰	67.5 ⁰	22.5 ⁰	67.5 ⁰	22.5 ⁰	67.5 ⁰	
7 Km	0	0	0	0	0	0.000001	0
9 Km	0	0	0	0	0	0	0
18 Km	0	0	0	0	0	0	0
19 Km	0	0	0	0	0	0	0
26 Km	0	0	0	0	0	0	0
29 Km	0	0	0	0	0	0	0
33 Km	0	0	0	0	0	0	0
38 Km	0	0	0	0	0	0	0
47 Km	0	0	0	0	0	0	0
48 Km	0	0	0	0	0	0	0
53 Km	0	0	0	0	0	0	0
58 Km	0	0	0	0	0	0	0
64 Km	0	0	0	0	0	0	0
68 Km	0	0	0	0	0	0	0
76 Km	0	0	0	0	0	0	0
78 Km	0	0	0	0	0	0	0
84 Km	0	0	0	0	0	0	0
89 Km	0	0	0	0	0	0	0
94 Km	0	0	0	0.000003	0	0	0

TABELA 9 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **AB** entre os barramentos PT.

Faltas tipo AC entre os barramentos TQ							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5^0	67.5^0	22.5^0	67.5^0	22.5^0	67.5^0	
6 Km	1	1	1	1	1	1	1
11 Km	1	1	1	1	1	1	1
16 Km	1	1	1	1	1	1	1
22 Km	1	1	1	1	1	1	1
24 Km	1	1	1	1	1	1	1
32 Km	1	1	1	1	1	1	1
36 Km	1	1	1	1	1	1	1
42 Km	1	1	1	1	1	1	1
47 Km	1	1	1	1	1	1	1
52 Km	1	1	1	1	1	1	1
53 Km	1	1	1	1	1	1	1
62 Km	1	1	1	1	1	1	1
67 Km	1	1	1	1	1	1	1
71 Km	1	1	1	1	1	1	1
74 Km	1	1	1	1	1	1	1
81 Km	1	1	1	1	1	1	1
82 Km	1	1	1	1	1	1	1
91 Km	1	1	1	1	1	1	1
93 Km	1	1	1	1	1	0.834177	1

TABELA 10 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase AC entre os barramentos TQ.

Faltas tipo AC entre os barramentos PT							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7 Ω		Resistência de Falta igual à 20 Ω		Resistência de Falta igual à 55 Ω		Saída desejada
	22.5 ⁰	67.5 ⁰	22.5 ⁰	67.5 ⁰	22.5 ⁰	67.5 ⁰	
7 Km	0.140746	0.000001	0.747572	0.000115	0.980352	0.193686	0
9 Km	0.059023	0.000001	0.596606	0.000079	0.972038	0.150570	0
18 Km	0.035355	0	0.494215	0.000034	0.965281	0.090816	0
19 Km	0.027674	0	0.447841	0.000033	0.961469	0.091902	0
26 Km	0.008484	0	0.247660	0.000009	0.939342	0.025148	0
29 Km	0.008891	0	0.258517	0.000003	0.939645	0.007505	0
33 Km	0.002999	0	0.125327	0.000002	0.914318	0.005739	0
38 Km	0.001568	0	0.077782	0.000001	0.886609	0.003097	0
47 Km	0.000483	0	0.031651	0.000001	0.842498	0.003226	0
48 Km	0.000470	0	0.028760	0.000001	0.839804	0.002907	0
53 Km	0.000170	0	0.011722	0	0.776891	0.000365	0
58 Km	0.000080	0	0.005775	0	0.733394	0.000167	0
64 Km	0.000038	0	0.002492	0	0.653285	0.000209	0
68 Km	0.000021	0	0.001384	0	0.596358	0.000127	0
76 Km	0.000010	0	0.000626	0	0.517432	0.000028	0
78 Km	0.000009	0	0.000552	0	0.500285	0.000028	0
84 Km	0.000002	0	0.000145	0	0.357654	0.000007	0
89 Km	0.000002	0	0.000136	0	0.354281	0.000003	0
94 Km	0.782842	0.000731	0.982503	0.454048	0.000003	0	0

TABELA 11 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase AC entre os barramentos PT.

Faltas tipo BC entre os barramentos TQ							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5^o	67.5^o	22.5^o	67.5^o	22.5^o	67.5^o	
6 Km	0.977650	0.506990	0.945492	0.449831	0.942867	0.936278	1
11 Km	0.968620	0.405346	0.933567	0.392639	0.960306	0.962142	1
16 Km	0.965439	0.426323	0.932789	0.469595	0.981380	0.989472	1
22 Km	0.972569	0.516502	0.946142	0.576134	0.989805	0.995613	1
24 Km	0.943087	0.372203	0.910076	0.477418	0.993587	0.996363	1
32 Km	0.951016	0.410215	0.921958	0.540522	0.995671	0.997741	1
36 Km	0.960466	0.595535	0.960275	0.854189	0.999724	0.999918	1
42 Km	0.970242	0.646772	0.970907	0.899604	0.999877	0.999944	1
47 Km	0.961898	0.478181	0.974310	0.854385	0.999957	0.999941	1
52 Km	0.957030	0.469296	0.971825	0.858002	0.999960	0.999945	1
53 Km	0.957101	0.654539	0.984281	0.973693	0.999993	0.999988	1
62 Km	0.977724	0.854849	0.994742	0.995360	0.999998	0.999996	1
67 Km	0.981369	0.906723	0.997498	0.998458	0.999999	0.999997	1
71 Km	0.986893	0.935853	0.998879	0.999217	1	0.999997	1
74 Km	0.981271	0.858798	0.998615	0.997620	1	0.999995	1
81 Km	0.979252	0.867996	0.998571	0.997926	1	0.999994	1
82 Km	0.991921	0.984359	0.999857	0.999917	1	0.999997	1
91 Km	0.994888	0.992756	0.999930	0.999963	1	0.999998	1
93 Km	0.903353	0.253897	0.845951	0.712054	0.315159	0.999909	1

TABELA 12 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **BC** entre os barramentos TQ.

Faltas tipo BC entre os barramentos PT							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5 °	67.5 °	22.5 °	67.5 °	22.5 °	67.5 °	
7 Km	0.000049	0.000063	0.000246	0.000110	0.000596	0.000249	0
9 Km	0.000147	0.000325	0.000923	0.000486	0.001678	0.000550	0
18 Km	0.000064	0.000439	0.000474	0.000537	0.001100	0.000506	0
19 Km	0.000044	0.000206	0.000265	0.000254	0.000805	0.000438	0
26 Km	0.000091	0.000307	0.000834	0.000392	0.002079	0.000453	0
29 Km	0.000126	0.001740	0.001187	0.001757	0.002936	0.001148	0
33 Km	0.000057	0.000328	0.000652	0.000354	0.002220	0.000309	0
38 Km	0.000141	0.001158	0.002251	0.001139	0.008482	0.000701	0
47 Km	0.000307	0.040075	0.008724	0.034982	0.050820	0.007258	0
48 Km	0.000205	0.033338	0.006451	0.029905	0.049237	0.006150	0
53 Km	0.000156	0.142237	0.006737	0.168141	0.098541	0.038339	0
58 Km	0.000143	0.339795	0.007339	0.388834	0.147230	0.086766	0
64 Km	0.000047	0.073942	0.002836	0.131601	0.123491	0.038274	0
68 Km	0.000104	0.369581	0.007393	0.483284	0.250041	0.130904	0
76 Km	0.000056	0.511950	0.005685	0.658266	0.345427	0.287864	0
78 Km	0.000054	0.504215	0.005249	0.646575	0.353168	0.293624	0
84 Km	0.000013	0.526131	0.001126	0.731834	0.289981	0.377236	0
89 Km	0.000011	0.350432	0.001022	0.626913	0.297566	0.312171	0
94 Km	0.000519	0.000443	0.001096	0.000657	0.000268	0.038920	0

TABELA 13 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **BC** entre os barramentos PT.

Faltas tipo AB-T entre os barramentos TQ							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5^0	67.5^0	22.5^0	67.5^0	22.5^0	67.5^0	
6 Km	1	1	1	1	1	1	1
11 Km	1	1	1	1	1	1	1
16 Km	1	1	1	1	1	1	1
22 Km	1	1	1	1	1	1	1
24 Km	1	1	1	1	1	1	1
32 Km	1	1	1	1	1	1	1
36 Km	1	1	1	1	1	1	1
42 Km	1	1	1	1	1	1	1
47 Km	1	1	1	1	1	1	1
52 Km	1	1	1	1	1	1	1
53 Km	1	1	1	1	1	1	1
62 Km	1	1	1	1	1	1	1
67 Km	1	1	1	1	1	1	1
71 Km	1	1	1	1	1	1	1
74 Km	1	1	1	1	1	1	1
81 Km	1	1	1	1	1	1	1
82 Km	1	1	1	1	1	1	1
91 Km	1	1	1	1	1	1	1
93 Km	1	1	1	1	1	1	1

TABELA 14 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **AB-T** entre os barramentos TQ.

Faltas tipo AB-T entre os barramentos PT							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5°	67.5°	22.5°	67.5°	22.5°	67.5°	
7 Km	0	0	0	0	0	0	0
9 Km	0	0	0	0	0	0	0
18 Km	0	0	0	0	0	0	0
19 Km	0	0	0	0	0	0	0
26 Km	0	0	0	0	0	0	0
29 Km	0	0	0	0	0	0	0
33 Km	0	0	0	0	0	0	0
38 Km	0	0	0	0	0	0	0
47 Km	0	0	0	0	0	0	0
48 Km	0	0	0	0	0	0	0
53 Km	0	0	0	0	0	0	0
58 Km	0	0	0	0	0	0	0
64 Km	0	0	0	0	0	0	0
68 Km	0	0	0	0	0	0	0
76 Km	0	0	0	0	0	0	0
78 Km	0	0	0	0	0	0	0
84 Km	0	0	0	0	0	0	0
89 Km	0	0	0	0	0	0	0
94 Km	0	0	0	0	0	0	0

TABELA 15 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **AB-T** entre os barramentos PT.

Faltas tipo AC-T entre os barramentos TQ							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5^0	67.5^0	22.5^0	67.5^0	22.5^0	67.5^0	
6 Km	1	1	1	1	1	1	1
11 Km	1	1	1	1	1	1	1
16 Km	1	1	1	1	1	1	1
22 Km	1	1	1	1	1	1	1
24 Km	1	1	1	1	1	1	1
32 Km	1	1	1	1	1	1	1
36 Km	1	1	1	1	1	1	1
42 Km	1	1	1	1	1	1	1
47 Km	1	1	1	1	1	1	1
52 Km	1	1	1	1	1	1	1
53 Km	1	1	1	1	1	1	1
62 Km	1	1	1	1	1	1	1
67 Km	1	1	1	1	1	1	1
71 Km	1	1	1	1	1	1	1
74 Km	1	1	1	1	1	1	1
81 Km	1	1	1	1	1	1	1
82 Km	1	1	1	1	1	1	1
91 Km	1	1	1	1	1	1	1
93 Km	1	1	1	1	1	1	1

TABELA 16 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase AC-T entre os barramentos TQ.

Faltas tipo AC-T entre os barramentos PT							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5^0	67.5^0	22.5^0	67.5^0	22.5^0	67.5^0	
7 Km	0	0	0	0	0.000059	0.000003	0
9 Km	0	0	0	0	0.000002	0	0
18 Km	0	0	0	0	0	0	0
19 Km	0	0	0	0	0	0	0
26 Km	0	0	0	0	0	0	0
29 Km	0	0	0	0	0	0	0
33 Km	0	0	0	0	0	0	0
38 Km	0	0	0	0	0	0	0
47 Km	0	0	0	0	0	0	0
48 Km	0	0	0	0	0	0	0
53 Km	0	0	0	0	0	0	0
58 Km	0	0	0	0	0	0	0
64 Km	0	0	0	0	0	0	0
68 Km	0	0	0	0	0	0	0
76 Km	0	0	0	0	0	0	0
78 Km	0	0	0	0	0	0	0
84 Km	0	0	0	0	0	0	0
89 Km	0	0	0	0	0	0	0
94 Km	0	0	0.001620	0.000113	0	0	0

TABELA 17 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase AC-T entre os barramentos PT.

Faltas tipo BC-T entre os barramentos TQ							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5°	67.5°	22.5°	67.5°	22.5°	67.5°	
6 Km	0.025334	0.999974	0.599578	0.999946	0.971729	0.999520	1
11 Km	0.029886	0.999971	0.606364	0.999930	0.966951	0.999205	1
16 Km	0.035573	0.999978	0.618985	0.999943	0.964003	0.999192	1
22 Km	0.040048	0.999979	0.630451	0.999944	0.963561	0.999243	1
24 Km	0.050198	0.999986	0.634732	0.999958	0.954189	0.999204	1
32 Km	0.067007	0.999994	0.706145	0.999978	0.966602	0.999526	1
36 Km	0.081253	0.999986	0.723339	0.999945	0.965356	0.998463	1
42 Km	0.071799	0.999991	0.652130	0.999959	0.934073	0.998490	1
47 Km	0.139971	0.999990	0.775526	0.999947	0.956578	0.997804	1
52 Km	0.154354	0.999990	0.790454	0.999944	0.956966	0.997295	1
53 Km	0.140127	0.999989	0.753363	0.999920	0.934988	0.994400	1
62 Km	0.240984	0.999988	0.845673	0.999891	0.952346	0.992271	1
67 Km	0.208021	0.999976	0.800622	0.999734	0.927280	0.979077	1
71 Km	0.297121	0.999966	0.834701	0.999592	0.927099	0.969920	1
74 Km	0.307788	0.999947	0.802926	0.999014	0.900807	0.938470	1
81 Km	0.329379	0.999942	0.813811	0.998933	0.899037	0.936738	1
82 Km	0.626511	0.998707	0.883917	0.969566	0.916064	0.643358	1
91 Km	0.663109	0.996602	0.888325	0.937390	0.911225	0.579335	1
93 Km	0.571979	0.999913	0.972679	0.999395	0.999955	0.996569	1

TABELA 18 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase BC-T entre os barramentos TQ.

Faltas tipo BC-T entre os barramentos PT							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5^0	67.5^0	22.5^0	67.5^0	22.5^0	67.5^0	
7 Km	0.012299	0.000411	0.000603	0.067966	0.000640	0.770543	0
9 Km	0.010260	0.000025	0.000245	0.003964	0.000170	0.408451	0
18 Km	0.042902	0.000006	0.000544	0.000463	0.000219	0.203577	0
19 Km	0.058914	0.000004	0.000553	0.000245	0.000166	0.136884	0
26 Km	0.046520	0.000001	0.000313	0.000020	0.000075	0.014213	0
29 Km	0.104137	0.000001	0.000641	0.000020	0.000103	0.015616	0
33 Km	0.060357	0	0.000320	0.000004	0.000044	0.001539	0
38 Km	0.059066	0	0.000274	0.000004	0.000031	0.002091	0
47 Km	0.037781	0	0.000158	0.000001	0.000016	0.000371	0
48 Km	0.050726	0	0.000190	0.000001	0.000018	0.000190	0
53 Km	0.049779	0	0.000161	0	0.000013	0.000073	0
58 Km	0.042956	0	0.000137	0	0.000010	0.000047	0
64 Km	0.024400	0	0.000088	0	0.000007	0.000019	0
68 Km	0.030861	0	0.000093	0	0.000007	0.000016	0
76 Km	0.012845	0	0.000052	0	0.000004	0.000008	0
78 Km	0.012984	0	0.000051	0	0.000004	0.000008	0
84 Km	0.004984	0	0.000021	0	0.000002	0.000002	0
89 Km	0.003829	0	0.000017	0	0.000002	0.000003	0
94 Km	0.000571	0.075521	0.001155	0.585190	0.000777	0.981669	0

TABELA 19 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **BC-T** entre os barramentos PT.

Faltas tipo ABC-T entre os barramentos TQ							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5^0	67.5^0	22.5^0	67.5^0	22.5^0	67.5^0	
6 Km	1	1	1	1	1	1	1
11 Km	1	1	1	1	1	1	1
16 Km	1	1	1	1	1	1	1
22 Km	1	1	1	1	1	1	1
24 Km	1	1	1	1	1	1	1
32 Km	1	1	1	1	1	1	1
36 Km	1	1	1	1	1	1	1
42 Km	1	1	1	1	1	1	1
47 Km	1	1	1	1	1	1	1
52 Km	1	1	1	1	1	1	1
53 Km	1	1	1	1	1	1	1
62 Km	1	1	1	1	1	1	1
67 Km	1	1	1	1	1	1	1
71 Km	1	1	1	1	1	1	1
74 Km	1	1	1	1	1	1	1
81 Km	1	1	1	1	1	1	1
82 Km	1	1	1	1	1	1	1
91 Km	1	1	1	1	1	1	1
93 Km	1	1	1	1	1	1	1

TABELA 20 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **ABC-T** entre os barramentos TQ.

Faltas tipo ABC-T entre os barramentos PT							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5°	67.5°	22.5°	67.5°	22.5°	67.5°	
7 Km	0	0	0	0	0	0	0
9 Km	0	0	0	0	0	0	0
18 Km	0	0	0	0	0	0	0
19 Km	0	0	0	0	0	0	0
26 Km	0	0	0	0	0	0	0
29 Km	0	0	0	0	0	0	0
33 Km	0	0	0	0	0	0	0
38 Km	0	0	0	0	0	0	0
47 Km	0	0	0	0	0	0	0
48 Km	0	0	0	0	0	0	0
53 Km	0	0	0	0	0	0	0
58 Km	0	0	0	0	0	0	0
64 Km	0	0	0	0	0	0	0
68 Km	0	0	0	0	0	0	0
76 Km	0	0	0	0	0	0	0
78 Km	0	0	0	0	0	0	0
84 Km	0	0	0	0	0	0	0
89 Km	0	0	0	0	0	0	0
94 Km	0	0	0	0	0	0	0

TABELA 21 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **ABC-T** entre os barramentos PT.

Faltas tipo ABC entre os barramentos TQ							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5°	67.5°	22.5°	67.5°	22.5°	67.5°	
6 Km	1	1	1	1	1	1	1
11 Km	1	1	1	1	1	1	1
16 Km	1	1	1	1	1	1	1
22 Km	1	1	1	1	1	1	1
24 Km	1	1	1	1	1	1	1
32 Km	1	1	1	1	1	1	1
36 Km	1	1	1	1	1	1	1
42 Km	1	1	1	1	1	1	1
47 Km	1	1	1	1	1	1	1
52 Km	1	1	1	1	1	1	1
53 Km	1	1	1	1	1	1	1
62 Km	1	1	1	1	1	1	1
67 Km	1	1	1	1	1	1	1
71 Km	1	1	1	1	1	1	1
74 Km	1	1	1	1	1	1	1
81 Km	1	1	1	1	1	1	1
82 Km	1	1	1	1	1	1	1
91 Km	1	1	1	1	1	1	1
93 Km	1	1	1	1	1	1	1

TABELA 22 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **ABC** entre os barramentos TQ.

Faltas tipo ABC entre os barramentos PT							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5°	67.5°	22.5°	67.5°	22.5°	67.5°	
7 Km	0	0	0	0	0	0	0
9 Km	0	0	0	0	0	0	0
18 Km	0	0	0	0	0	0	0
19 Km	0	0	0	0	0	0	0
26 Km	0	0	0	0	0	0	0
29 Km	0	0	0	0	0	0	0
33 Km	0	0	0	0	0	0	0
38 Km	0	0	0	0	0	0	0
47 Km	0	0	0	0	0	0	0
48 Km	0	0	0	0	0	0	0
53 Km	0	0	0	0	0	0	0
58 Km	0	0	0	0	0	0	0
64 Km	0	0	0	0	0	0	0
68 Km	0	0	0	0	0	0	0
76 Km	0	0	0	0	0	0	0
78 Km	0	0	0	0	0	0	0
84 Km	0	0	0	0	0	0	0
89 Km	0	0	0	0	0	0	0
94 Km	0	0	0	0	0	0	0

TABELA 23 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **ABC** entre os barramentos PT.

Faltas tipo A-T entre os barramentos TQ							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5^0	67.5^0	22.5^0	67.5^0	22.5^0	67.5^0	
6 Km	1	1	1	1	1	0.999996	1
11 Km	1	1	1	1	1	0.999982	1
16 Km	1	1	1	1	1	0.999940	1
22 Km	1	1	1	1	1	0.999933	1
24 Km	1	1	1	1	1	0.999686	1
32 Km	1	1	1	1	1	0.998485	1
36 Km	1	1	1	1	1	0.963481	1
42 Km	1	1	1	1	1	0.675869	1
47 Km	1	1	1	1	1	0.337716	1
52 Km	1	1	1	1	1	0.284647	1
53 Km	1	1	1	1	1	0.368061	1
62 Km	1	1	1	1	1	0.647818	1
67 Km	1	1	1	1	1	0.569633	1
71 Km	1	1	1	1	1	0.698262	1
74 Km	1	1	1	1	1	0.814320	1
81 Km	1	1	1	1	1	0.784260	1
82 Km	1	1	1	0.999933	1	0.602105	1
91 Km	1	1	1	0.999698	1	0.566360	1
93 Km	1	1	1	0.999998	1	1	1

TABELA 24 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase A-T entre os barramentos TQ, quando a capacidade da fonte do barramento P sofreu um decréscimo de 10%.

Faltas tipo A-T entre os barramentos PT							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5 °	67.5 °	22.5 °	67.5 °	22.5 °	67.5 °	
7 Km	0	0	0	0.002202	0.000048	0.467680	0
9 Km	0	0	0	0.000038	0.000001	0.352575	0
18 Km	0	0	0	0	0	0.147663	0
19 Km	0	0	0	0	0	0.058837	0
26 Km	0	0	0	0	0	0.000933	0
29 Km	0	0	0	0	0	0.000046	0
33 Km	0	0	0	0	0	0.000002	0
38 Km	0	0	0	0	0	0.000001	0
47 Km	0	0	0	0	0	0.000001	0
48 Km	0	0	0	0	0	0	0
53 Km	0	0	0	0	0	0	0
58 Km	0	0	0	0	0	0	0
64 Km	0	0	0	0	0	0	0
68 Km	0	0	0	0	0	0	0
76 Km	0	0	0	0	0	0	0
78 Km	0	0	0	0	0	0	0
84 Km	0	0	0	0	0	0	0
89 Km	0	0	0	0	0	0	0
94 Km	0	0.079661	0.003147	0.539068	0	0.000001	0

TABELA 25 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase A-T entre os barramentos PT, quando a capacidade da fonte do barramento P sofreu um decréscimo de 10%.

Faltas tipo AB entre os barramentos TQ							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5 ^o	67.5 ^o	22.5 ^o	67.5 ^o	22.5 ^o	67.5 ^o	
6 Km	1	1	1	1	1	1	1
11 Km	1	1	1	1	1	1	1
16 Km	1	1	1	1	1	1	1
22 Km	1	1	1	1	1	1	1
24 Km	1	1	1	1	1	1	1
32 Km	1	1	1	1	1	1	1
36 Km	1	1	1	1	1	1	1
42 Km	1	1	1	1	1	0.999999	1
47 Km	1	1	1	1	1	0.999999	1
52 Km	1	1	1	1	1	0.999999	1
53 Km	1	1	1	1	1	0.999979	1
62 Km	1	1	1	1	1	0.999994	1
67 Km	1	1	1	1	1	0.999988	1
71 Km	1	1	1	0.999999	1	0.999993	1
74 Km	1	1	1	1	1	0.999998	1
81 Km	1	1	1	1	1	0.999998	1
82 Km	1	1	1	1	1	0.999999	1
91 Km	1	1	1	1	1	1	1
93 Km	1	1	1	1	1	1	1

TABELA 26 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **AB** entre os barramentos TQ quando a capacidade da fonte do barramento P sofreu um decréscimo de 5% e a capacidade da fonte do barramento Q sofreu um decréscimo de 5,26%.

Faltas tipo AB entre os barramentos PT							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5 °	67.5 °	22.5 °	67.5 °	22.5 °	67.5 °	
7 Km	0	0.000296	0	0.000004	0.000756	0.000110	0
9 Km	0	0.000056	0	0.000002	0.000076	0.000047	0
18 Km	0	0.000015	0	0.000001	0.000007	0.000009	0
19 Km	0	0.000008	0	0	0.000005	0.000004	0
26 Km	0	0.000001	0	0	0	0	0
29 Km	0	0	0	0	0	0	0
33 Km	0	0	0	0	0	0	0
38 Km	0	0	0	0	0	0	0
47 Km	0	0	0	0	0	0	0
48 Km	0	0	0	0	0	0	0
53 Km	0	0	0	0	0	0	0
58 Km	0	0	0	0	0	0	0
64 Km	0	0	0	0	0	0	0
68 Km	0	0	0	0	0	0	0
76 Km	0	0	0	0	0	0	0
78 Km	0	0	0	0	0	0	0
84 Km	0	0	0	0	0	0	0
89 Km	0	0	0	0	0	0	0
94 Km	0	0.000008	0.008112	0.000302	0	0.001653	0

TABELA 27 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **AB** entre os barramentos PT quando a capacidade da fonte do barramento P sofreu um decréscimo de 5% e a capacidade da fonte do barramento Q sofre um decréscimo de 5,26%.

Faltas tipo ABC entre os barramentos TQ							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5°	67.5°	22.5°	67.5°	22.5°	67.5°	
6 Km	1	1	1	0.999992	1	0.328678	1
11 Km	1	1	1	0.999994	1	0.361201	1
16 Km	1	1	1	0.999966	1	0.186049	1
22 Km	1	1	1	0.999993	1	0.295894	1
24 Km	1	1	1	0.999977	1	0.325736	1
32 Km	1	1	1	0.999989	1	0.398894	1
36 Km	1	1	1	0.999937	1	0.230801	1
42 Km	1	1	1	0.999204	1	0.164221	1
47 Km	1	1	1	0.998152	1	0.301212	1
52 Km	1	1	1	0.997755	1	0.280177	1
53 Km	1	0.999994	1	0.968900	1	0.619557	1
62 Km	1	0.999995	1	0.994185	1	0.953659	1
67 Km	1	0.999991	1	0.992802	1	0.977193	1
71 Km	1	0.999976	1	0.984708	1	0.979140	1
74 Km	1	0.999995	1	0.997697	1	0.997688	1
81 Km	1	0.999995	1	0.997564	1	0.997383	1
82 Km	1	0.999998	1	0.999578	1	0.999905	1
91 Km	1	0.999998	1	0.999745	1	1	1
93 Km	1	0.999998	1	0.306934	1	0.999956	1

TABELA 28 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **ABC** entre os barramentos TQ quando a capacidade da fonte do barramento P sofreu um decréscimo de 5%, a capacidade da fonte e o ângulo de transferência potência do barramento Q sofrem um decréscimo de 5,26% e 50% respectivamente.

Faltas tipo ABC entre os barramentos PT							
Distância da Falta em relação ao Barramento T	Resistência de Falta igual à 7Ω		Resistência de Falta igual à 20Ω		Resistência de Falta igual à 55Ω		Saída desejada
	22.5^0	67.5^0	22.5^0	67.5^0	22.5^0	67.5^0	
7 Km	0	0	0	0	0	0.000003	0
9 Km	0	0	0	0	0	0.000003	0
18 Km	0	0	0	0	0	0.000001	0
19 Km	0	0	0	0	0	0.000001	0
26 Km	0	0	0	0	0	0	0
29 Km	0	0	0	0	0	0	0
33 Km	0	0	0	0	0	0	0
38 Km	0	0	0	0	0	0	0
47 Km	0	0	0	0	0	0	0
48 Km	0	0	0	0	0	0	0
53 Km	0	0	0	0	0	0	0
58 Km	0	0	0	0	0	0	0
64 Km	0	0	0	0	0	0	0
68 Km	0	0	0	0	0	0	0
76 Km	0	0	0	0	0	0	0
78 Km	0	0	0	0	0	0	0
84 Km	0	0	0	0	0	0	0
89 Km	0	0	0	0	0	0	0
94 Km	0	0	0.000026	0.000008	0	0	0

TABELA 29 - Saída da rede neural artificial quando o sistema elétrico é sujeito à faltas do tipo fase **ABC** entre os barramentos PT quando a capacidade da fonte do barramento P sofreu um decréscimo de 5%, a capacidade da fonte e o ângulo de transferência potência do barramento Q sofrem um decréscimo de 5,26% e 50% respectivamente.

Analisando as tabelas 2-29, nota-se que apenas 74 dos 3192 padrões de teste foram incorretamente classificados pela rede neural artificial, saídas obtidas que

diferem das desejadas em um valor superior à 0.5 . Em termos de porcentagem, verifica-se que apenas 2.318 % dos padrões de teste foram incorretamente classificados. De forma a se efetuar uma análise dos resultados com maior rigor, as influências das variáveis envolvidas serão explicitadas separadamente.

5.3.1. Influência da Resistência de Falta

O desempenho da rede neural artificial foi avaliada por padrões de teste possuindo, entre outros parâmetros de falta, três diferentes tipos de resistência de falta, 7 Ω , 20 Ω e 55 Ω . A seguir, apresenta-se uma tabela relacionando os erros de classificação da RNA com as respectivas resistências de falta.

Resistência de Falta (Ω)	Número de Padrões Incorretamente Classificados pela RNA	Porcentagem de Padrões Incorretamente Classificados (%)
7	27	36.49
20	14	18.92
55	33	44.59
Total	74	100

TABELA 30 – Porcentagem de padrões incorretamente classificados em relação à resistência de falta.

Analisando a tabela 30, verifica-se que a resistência de falta de 55 Ω foi a que gerou mais erros de classificação por parte da RNA. Existe uma tendência nos relés digitais à distância de ter um decréscimo da qualidade de acerto quando existe o aumento da resistência de falta. No entanto, baseado nos testes realizados, na RNA

implementada esta característica não pode ser afirmada, já que o método possui uma qualidade de acerto superior para 20Ω em relação à resistência de falta de 7Ω .

5.3.2. Influência da Localização da Falta

Observando a figura 10, podemos notar que a falta pode ocorrer em dois segmentos da L.T.. A primeira, entre os barramentos PT (fora da zona de proteção) e a segunda entre os barramentos TQ (dentro da zona de proteção). A seguir apresenta-se uma tabela que irá relacionar os erros de classificação da RNA com a localização da falta.

Localização da Falta	Número de Padrões Incorretamente Classificados pela RNA	Porcentagem de Padrões Incorretamente Classificados (%)
PT	31	41.9
TQ	43	58.1
Total	74	100

TABELA 31 – Porcentagem de padrões incorretamente classificados em relação à localização da falta.

Analisando a tabela 31, podemos verificar que existe uma homogeneidade entre o número de erros de classificação em relação à localização da falta. Esta característica pode ser explicada pelo número igualitário de padrões de treinamento em relação a localização da falta (855 entre PT e 855 entre TQ). Este número igualitário de padrões evita que a RNA tenha um aprendizado direcionado, isto é, aprenda a classificar melhor faltas localizadas em um determinado segmento da L.T..

5.3.3. Influência do Tipo de Falta

Os testes realizados na RNA envolveram todos os onze tipos de falta. A seguir expõe-se uma tabela relacionando os erros de classificação da RNA com os diferentes tipos de falta.

Tipo de Falta	Número de Padrões Incorretamente Classificados pela RNA	Porcentagem de Padrões Incorretamente Classificados (%)
A-T	4	5.41
B-T	0	0
C-T	0	0
AB	0	0
AC	20	27.03
BC	19	25.68
AB-T	0	0
AC-T	0	0
BC-T	19	25.68
ABC	0	0
ABC-T	12	16.22
Total	74	100

TABELA 32 – Porcentagem de padrões incorretamente classificados em relação ao tipo de falta.

Analisando a tabela 32, podemos observar que faltas envolvendo uma única fase e faltas trifásicas (não incluindo o envolvimento da terra) não apresentaram grandes problemas de classificação. No entanto, alguns tipos de faltas envolvendo duas fases (AC, BC e BC-T) e faltas trifásicas envolvendo a terra (ABC-T)

apresentaram erros consideráveis de classificação. Esta concentração de erros de classificação pode ser explicada pelo fato de os tipos de faltas citados anteriormente não terem feito parte dos tipos de falta utilizadas no treinamento da RNA.

5.3.4. Influência da Distância de Falta

Os testes realizados na RNA envolveram 36 diferentes distâncias de falta. De maneira a se evidenciar a concentração dos erros de classificação da RNA em relação à distância das faltas, dividiu-se os dois segmentos da L.T. em seções de 25 Km.

FIGURA 25 – Sistema elétrico dividido em seções.

A tabela a seguir relaciona os erros de classificação da RNA com as diferentes seções apresentadas na figura 25.

Seções da Linha de Transmissão	Número de Padrões Incorretamente Classificados pela RNA
Seção Número 1	14
Seção Número 2	4
Seção Número 3	6
Seção Número 4	7
Seção Número 5	17
Seção Número 6	11
Seção Número 7	11
Seção Número 8	4
Total	74

TABELA 33 – Porcentagem de padrões incorretamente classificados em relação às seções da Linha de Transmissão.

Analisando estes segmentos e a tabela 33 notamos que a maioria dos erros de classificação da RNA se concentram na seção 5 (17 erros de classificação), entre os barramentos TQ. Em seguida, encontramos a seção 1 com 14 erros de classificação, e as seções 6, 7, 4, 3, 2 e 8 com respectivamente 11, 11, 7, 6, 4 e 4 erros de classificação. Não se observou nenhuma tendência de comportamento da RNA em relação à variação da distância de falta, existindo uma certa homogeneidade no número de erros por seção.

5.3.5. Influência do Ângulo de Incidência da Falta

As faltas geradas para testar a RNA envolveram dois valores de ângulos de incidência de falta 22.5° e 67.5° . A seguir apresenta-se uma tabela relacionando os erros de classificação da RNA com os ângulos de incidência de falta.

Ângulo de Incidência de Falta ($^{\circ}$)	Número de Padrões Incorretamente Classificados pela RNA	Entre os barramentos PT	Entre os barramentos TQ
22.5	37	20	17
67.5	37	11	26
Total	74	-	-

TABELA 34 – Porcentagem de padrões incorretamente classificados em relação aos ângulos de incidência de falta.

Analisando a tabela 34 podemos observar que os erros de classificação da RNA são divididos de maneira igualitária para os dois ângulos.

5.3.6. Influência das Condições de Operação

Os testes envolveram além de condições de falta distintas das de treinamento, como o tipo de falta, condições de operação (fluxo de carga e capacidade da fontes) também distintas das de treinamento. A tabela a seguir mostra a relação entre os erros de classificação da RNA e as diferentes condições de operação do sistema.

Condições de Operação	Número de Padrões Testados	Número de Padrões Incorretamente Classificados pela RNA	Porcentagem de Padrões Incorretamente Classificados (%)
Condições modificadas de Operação	684	16	2.339
Condições Normais de Operação	2508	58	2.313
Total	3192	74	2.318

TABELA 35 – Porcentagem de padrões incorretamente classificados em relação às condições de operação.

Analisando a tabela 35, podemos observar que a RNA tem um desempenho semelhante quando classifica padrões provenientes de condições de operação vistas e não vistas durante a fase de treinamento. Deve-se lembrar que nenhum dos padrões de teste foram vistos na fase de treinamento, e que a capacidade da RNA em classificar com bom desempenho os padrões anteriormente colocados evidencia sua capacidade de generalização.

6. Conclusões

Este trabalho apresentou uma nova metodologia para proteção direcional de sistemas elétricos de potência utilizando redes neurais artificiais. A metodologia proposta é baseada na utilização de cinco amostras pós-falta dos sinais de corrente e tensão na taxa amostral de 960 Hz, tomados no barramento de medição T (figura 10) e, faz uso de um processo de normalização dos referidos dados de modo a limitá-los entre a faixa $+1$ e -1 .

A metodologia foi testada utilizando-se um microcomputador Pentium 100 MHz, com dados obtidos a partir de simulações de uma configuração típica encontrada na prática, ilustrada na figura 10, através do *software* ATP. A configuração utilizada é simétrica com comprimentos de linha até o barramento T iguais e fontes com diferentes capacidades conectadas em ambos os terminais. As linhas são consideradas transpostas e a sua representação no ATP é realizada por parâmetros distribuídos.

Através de testes realizados, a metodologia demonstrou um alto grau de acerto mesmo diante de condições de falta e de operação não vistas anteriormente na fase de treinamento da RNA. As variedades de condições de teste tais como: diferentes condições de operação, localizações, resistências, ângulos de incidência, e tipos de falta, não influenciaram de forma significativa no alto desempenho da metodologia.

Analisando as variações nos parâmetros de teste e suas influências no desempenho do esquema proposto de forma separada, nos deparamos inicialmente com a influência da resistência de falta. Pelos resultados apresentados na seção 5.3.1. pode-se observar que o aumento da resistência de falta não gerou mais erros de classificação do esquema proposto.

O efeito da localização da falta, dentro ou fora da zona de proteção, também em pouco influenciou a precisão do esquema proposto. Isto pode ser comprovado analisando a tabela 31, já que esta mostra uma homogeneidade entre o número de erros de classificação em relação à localização da falta.

Pelos resultados da seção 3.3.4., pode-se notar que a distância de falta em relação ao barramento T (barramento onde está localizado o relé baseado em redes neurais), pouco influenciou no desempenho da metodologia. Na figura 25 dividiu-se o sistema elétrico em seções e, não se observou nenhuma tendência de concentração de erros de classificação da RNA, existindo uma certa homogeneidade no número de erros por seção.

O ângulo de incidência de falta, também não influenciou na precisão obtida pelo esquema proposto. Analisando a tabela 34 pode-se notar que os erros de classificação da RNA são divididos de maneira igualitária para os dois ângulos de incidência de teste.

Na seção 3.3.6. analisou-se a influência das condições de operação do sistema na precisão do esquema proposto. Pela tabela 35, pode-se observar que o desempenho do esquema é semelhante quando classifica padrões provenientes de condições de operação vistas e não vistas durante a fase de treinamento. Desta forma, pode-se afirmar que o esquema proposto possui uma alta precisão de acerto mesmo quando apresentado a faltas provenientes de condições de operação modificadas.

Nos testes realizados, a única tendência de comportamento do esquema de proteção verificada, foi em relação à influência do tipo de falta no desempenho do esquema proposto. Analisando a tabela 32 da seção 5.3.3., pode-se verificar que os tipos de falta não vistos anteriormente na fase de treinamento da RNA foram os que mais geraram erros de classificação por parte do esquema. Desta forma, mesmo o esquema tendo a capacidade de generalizar e corretamente classificar todos os tipos de falta, ele possui maior dificuldade de reconhecer padrões provenientes de tipos de faltas não vistas na fase de treinamento.

Os Sistemas Elétricos de Potência são projetados para fornecer energia elétrica de forma contínua e com qualidade. Um dos importantes fatores que possibilitam este objetivo é a implementação de esquemas de proteção de alto

desempenho para as linhas de transmissão. Um esquema de proteção de linhas de transmissão de alta qualidade deve prover, principalmente, um correto diagnóstico da anormalidade e possuir uma alta velocidade de resposta. Dentro destas características, o esquema de proteção proposto obtém bons resultados. A velocidade de resposta do esquema, referente a cinco amostras consecutivas dos sinais de tensão e corrente, e sem contar o tempo de processamento dos sinais, é da ordem de 5 ms. A confiabilidade do esquema pode ser analisada por sua porcentagem de erro, da ordem de 2.318%. Outra característica importante do esquema proposto é sua capacidade de adaptabilidade às diferentes condições de operação do sistema de transmissão, tendo um desempenho quase constante mesmo diante de condições não vistas na fase de treinamento.

Um possível próximo passo, seria testar o esquema com dados provenientes de um sistema real. Diante do sucesso desta fase, um protótipo poderia ser construído e testado em regime *on-line*. Diante dos bons resultados apresentados, acredita-se ter demonstrado a viabilidade do estudo da aplicação de redes neurais artificiais em proteção de linhas de transmissão, indicando assim que maiores estudos neste aplicativo devem ser realizados.

Referências Bibliográficas

ANTONIOU, A. (1979). *Digital filters: analysis and design*. New York, McGraw-Hill.

ATP RULE - BOOK (1987). Leuven EMTP Center (LEC).

BEALE, M.; HAGAN, M.T. (1996). *Neural network design*. Boston, PWS.

BERNIERE, A.; D'APUZZO, M.; SANSONE, L.; SAVASTANO, M. (1994). A neural network approach for identification and fault diagnosis on dynamic systems. *IEEE Transactions on Instrumentation and Measurement*, v. 43, n. 6, dezembro.

BO, Z.Q.; AGGARWAL, R.K.; JOHNS, A.T.; LI, H.Y. ; SONG, Y. H. (1997). A new approach to phase selection using fault generated high frequency noise and neural networks. *IEEE Transactions on Power Delivery*, v. 12, n. 1, p.106-115, janeiro.

CHAKRAVARTHY, S.K.; NAYAR, C.V.; ACHUTHAN, N.R. (1992). Applying pattern recognition in distance relaying part 1: concept. *IEE Proceedings-C*, v. 139, n. 4, p.301-305, Julho.

CHAKRAVARTHY, S.K.; NAYAR, C.V.; ACHUTHAN, N.R. (1992). Applying pattern recognition in distance relaying part 2: feasibility. *IEE Proceedings-C*, v. 139, n. 4, p.306-314, Julho.

COURY, D.V. ; JORGE, D.C. (1997). Artificial neural network approach to distance protection of transmission lines. *IEEE Summer Meeting*, Berlin, Julho.

DALSTEIN, T.; KULICKE, B. (1995). Neural network approach to fault classification for high speed protective relaying. *IEEE Transactions on Power Delivery*, v. 10, n. 2, p.1002-1011, Abril.

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*, v. 11, n. 2, p.740-747, Abril.

DESTRO- MANUAL DO USUÁRIO. (1996). MYRA Engenharia Elétrica e Consultoria Ltda.

HERTZ, J.; KROGH, A.; PALMER, R.G. (1991). *Introduction to the theory of neural computation*. Santa Fe Institute Studies in the Sciences of Complexity, v. 1, Addison-Wesley.

INSTITUTE FOR PARALLEL AND DISTRIBUTED HIGH PERFORMANCE SYSTEMS, UNIVERSITY OF STUTTGART (1995). *User manual, version 4.1*. Stuttgart.

JONGEPIER, A.G.; VAN DER SLUIS, L. (1997). Adaptive distance protection of double-circuit lines using artificial neural networks. *IEEE Transactions on Power Delivery*, v.12, n. 1, p.97-105, Janeiro.

KANO, H.; KANETA, M.; KANEMARU, K. (1991). Fault location for transmission lines using inference model neural network. *Electrical Engineering in Japan*, v. 111, n. 7.

KHAPARDE, S.A.; KALE, P.B.; AGARWAL, S.H. (1991). Application of artificial neural network in protective relaying of transmission lines. *IEEE*, /1991/.

KINDERMAN, G. (1992). *Curto circuito*. Porto Alegre, Sagra-DC Luzzato.

KOVÁCS, Z. L. (1996). *Redes neurais artificiais. Fundamentos e aplicações*. São Paulo, Edição Acadêmica.

PHADKE, A.G. (1988) *Computer relaying for power systems*. Inglaterra, Research Studies Press Ltd.

PHADKE, A.G.; HOROWITZ, S.H. (1992). *Power system relaying*. England, Research Studies Press Ltd.

RUMELHART, D.E.; McCLELLAND, J.L. (1986). *Parallel distributed processing. Explorations in the micro structure of cognition*. Cambridge, MIT Press.

SERRA, C.P. (1983). *Teoria e projeto de filtros*. Série ouro CPQD, v.1,ed. Limitada.

SIDHU, T.S.; 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*, v. 10, n. 2, p.697-706, Abril.

STEVENSON JR, W.D. (1978) *Elementos de análise de sistemas de potência*. Rio de Janeiro, McGraw-Hill do Brasil.

SULTAN, A.F.; SWIFT, G.W.; FEDIRCHUK, D.J. (1992). Detection of high impedance arcing faults using a multi-layer perceptron. *IEEE Transactions on Power Delivery*, v. 7, n. 4, p.1871-1877, Outubro.

SWARUP, K.S.; CHANDRASEKHARAIAH, H.S. (1991). Fault detection and diagnosis of power systems using artificial neural networks. *IEEE*, /1991/.

Xia, Y.Q.; Li, K.K.; David, A.K. (1994). Adaptive Relay Setting For Stand-Alone Digital Distance Protection. *IEEE Transactions on Power Delivery*, v. 9, n. 9, p.480-492, janeiro.

YANG, H.; CHANG, W.; HUANG, C. (1994). A new neural network approach to on-line fault section estimation using information of protective relays and circuit breakers. *IEEE Transactions on Power Delivery*, v. 9, n. 1, p.220-229, janeiro.