

**REDES NEURAIIS ARTIFICIAIS:
UMA ALTERNATIVA PARA PROTEÇÃO
DE LINHAS DE TRANSMISSÃO**

MÁRIO OLESKOVICZ

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

ORIENTADOR: Prof. Dr. Denis V. Coury

São Carlos

1997



31100115792

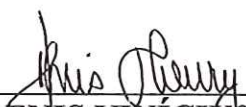


DEDALUS - Acervo - EESC

FOLHA DE APROVAÇÃO

Candidato: Engenheiro **MARIO OLESKOVICZ**

Dissertação defendida e aprovada em 10-12-1997
pela Comissão Julgadora:




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




Prof. Doutor **ADRIANO ALBER DE FRANÇA MENDES CARNEIRO**
(Escola de Engenharia de São Carlos - Universidade de São Paulo)



Prof. Titular **GERMANO LAMBERT TORRES**
(Escola Federal de Engenharia de Itajubá - MG)



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



JOSÉ CARLOS A CINTRA
Presidente da Comissão de Pós-Graduação

Dedico este trabalho aos meus pais, Fabiano e Lenira, aos meus irmãos e amigos, estímulos constantes na minha caminhada.

AGRADECIMENTOS

Ao Prof. Dr. Denis Vinicius Coury pela sua orientação e amizade, demonstrados tanto pela preocupação no desenvolvimento do trabalho quanto pelos conhecimentos ensinados.

À Maria Cristina Dias Tavares (pesquisadora RHAE/CNPq) pela prontidão e auxílio na solução de problemas encontrados quando da aplicação e uso do *software* “Eletromagnetic Transients Program - ATP”.

Aos amigos, Fabiano Oleskovicz e Fabiano Fagundes, que juntos tiveram a iniciativa e paciência de ler e discutir o trabalho quando da sua apresentação para o exame de qualificação.

Aos amigos que souberam entender a dificuldade de se realizar um trabalho sério e, ao mesmo tempo, dosar os momentos de descontração.

Ao Departamento de Engenharia Elétrica pela utilização e fácil acesso aos seus laboratórios, bem como aos professores e funcionários que estiveram sempre dispostos a colaborar.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq, pelo auxílio financeiro fornecido no período da realização deste trabalho, sem o qual o mesmo não seria possível.

A todos, muito obrigado.

SUMÁRIO

LISTA DE FIGURAS	i
LISTA DE TABELAS	iv
LISTA DE ABREVIATURAS E SIGLAS	ix
LISTA DE SÍMBOLOS	x
RESUMO	xiiiiv
<i>ABSTRACT</i>	xiv
<hr/>	
1 INTRODUÇÃO	1
1.1 A proteção das linhas de transmissão	1
1.2 Proteção por relés de distância eletromecânicos e de estado sólido	3
1.3 Proteção por relés de distância digitais	5
1.4 Proteção por relés de distância aplicando-se redes neurais artificiais	6
2 LEVANTAMENTO BIBLIOGRÁFICO	9
2.1 Redes neurais artificiais aplicadas à proteção de sistemas elétricos de potência	9
3 REDES NEURAIAS ARTIFICIAS	14
3.1 O neurônio biológico	14
3.2 Modelagem matemática do neurônio biológico	16
3.3 Redes neurais aplicadas ao problema de reconhecimento de padrões	18
3.4 Redes neurais artificiais de múltiplas camadas	20
3.5 Regra de aprendizagem	23
3.5.1 Algoritmo <i>backpropagation</i>	25

4 SISTEMA ELÉTRICO ANALISADO	28
4.1 Configuração do sistema de potência	29
4.2 Modelagem da linha de transmissão	30
4.2.1 Parâmetros do sistema elétrico	31
4.2.2 Rotina <i>Line Constant</i> e a interface gráfica DESTRO	33
4.3 Variações nas simulações das condições de faltas	35
4.4 Filtro digital passa-baixo Butterworth	36
4.5 Análise dos valores amostrados	39
<hr/>	
5 APLICAÇÃO DO <i>SOFTWARE</i> SNNS	41
5.1 Primeira arquitetura analisada	44
5.1.1 Resultados	46
5.2 Segunda arquitetura analisada	51
5.2.1 Resultados	53
5.3 Terceira arquitetura analisada	58
5.3.1 Resultados	60
5.4 Quarta arquitetura analisada	64
5.4.1 Resultados	66
5.5 Generalização para todos os tipos de faltas	70
5.6 <i>Hardware</i> de um relé de distância usando RNAs	72
6 CONCLUSÕES	74
7 REFERÊNCIAS BIBLIOGRÁFICAS	78

APÊNDICE

LISTA DE FIGURAS

FIGURA 1- Forma de onda da tensão, para uma falta fase-terra, com um ângulo de incidência de 90°	3
FIGURA 2- Impedância medida pelo relé, observando as devidas impedâncias encontradas	4
<hr/>	
FIGURA 3 - Neurônios do sistema nervoso central dos vertebrados	15
FIGURA 4 - Diagrama esquemático de um neurônio artificial	16
FIGURA 5 - Função sigmoideal	17
FIGURA 6 - Discriminador linear que separa o espaço em duas regiões A e B ..	19
FIGURA 7 - Uma arquitetura <i>feedforward</i>	21
FIGURA 8 - Representação do sistema elétrico analisado	29
FIGURA 9 - Topologia da linha de transmissão definindo seus principais parâmetros	31
FIGURA 10 - Transposição de uma linha de transmissão	32
FIGURA 11 - Representação de uma seção de uma linha de transmissão por parâmetros distribuídos	33
FIGURA 12 - Arquivo de entrada para a rotina <i>Line Constant</i> descrevendo a topologia da linha de transmissão analisada	34

FIGURA 13 - Característica do filtro ideal passa-baixa, onde b_p representa a banda ou faixa de passagem	36
FIGURA 14 - Característica das perdas de um filtro passa-baixa ideal	37
FIGURA 15 - Característica das perdas em um filtro passa-baixa real	37
FIGURA 16 - Valores amostrados (não filtrados) referentes a tensão quando uma falta envolvendo a fase a à terra é aplicada a 10 Km do barramento P (item 4.1, figura 8), com um ângulo de incidência de 90° e com uma resistência de falta de 0.1Ω	38
FIGURA 17 - Valores amostrados (filtrados - filtro Butterworth) referentes a tensão quando uma falta envolvendo a fase a à terra é aplicada a 10 km do barramento P (item 4.1, figura 8), com um ângulo de incidência de 90° e com uma resistência de falta de 0.1Ω	39
FIGURA 18 - Primeira arquitetura analisada	45
FIGURA 19 - Convergência da rede neural analisada, para os seus 15100 ciclos de treinamento	46
FIGURA 20 - Segunda arquitetura analisada	52
FIGURA 21 - Convergência da rede neural analisada, para os seus 26500 ciclos de treinamento	53
FIGURA 22 - Terceira arquitetura analisada	59
FIGURA 23 - Convergência da rede neural analisada, para os seus 395000 ciclos de treinamento	59

FIGURA 24 - Quarta arquitetura analisada	65
FIGURA 25 - Convergência da rede neural analisada para os seus 380000 ciclos de treinamento	65
FIGURA 26 - Diagrama de blocos de um relé de distância digital baseado em RNA.....	73

LISTA DE TABELAS

TABELA 1 - Distribuição de faltas em um sistema de 500 KV, num período de dez anos, com a ocorrência de noventa e nove faltas	2
TABELA 2 - Conjuntos de treinamento e testes aplicados às arquiteturas	43
TABELA 3 - Resultados obtidos pela arquitetura 20-20-20-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 20°	47
TABELA 4 - Resultados obtidos pela arquitetura 20-20-20-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 30°	48
TABELA 5 - Resultados obtidos pela arquitetura 20-20-20-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 40°	48
TABELA 6 - Resultados obtidos pela arquitetura 20-20-20-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 50°	49
TABELA 7 - Resultados obtidos pela arquitetura 20-20-20-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 60°	49
TABELA 8 - Resultados obtidos pela arquitetura 20-20-20-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 70°	50

TABELA 9 - Resultados obtidos pela arquitetura 20-20-20-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 80°	50
TABELA 10 - Resultados obtidos pela arquitetura 20-20-20-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 100°	51
TABELA 11 - Resultados obtidos pela arquitetura 20-15-10-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 20°	54
TABELA 12- Resultados obtidos pela arquitetura 20-15-10-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 30°	54
TABELA 13 - Resultados obtidos pela arquitetura 20-15-10-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 40°	55
TABELA 14 - Resultados obtidos pela arquitetura 20-15-10-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 50°	55
TABELA 15 - Resultados obtidos pela arquitetura 20-15-10-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 60°	56
TABELA 16 - Resultados obtidos pela arquitetura 20-15-10-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 70°	56

TABELA 17 - Resultados obtidos pela arquitetura 20-15-10-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 80°	57
TABELA 18 - Resultados obtidos pela arquitetura 20-15-10-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 100°	57
TABELA 19 - Resultados obtidos pela arquitetura 6-6-2-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 20°	60
TABELA 20 - Resultados obtidos pela arquitetura 6-6-2-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 30°	61
TABELA 21 - Resultados obtidos pela arquitetura 6-6-2-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 40°	61
TABELA 22 - Resultados obtidos pela arquitetura 6-6-2-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 50°	62
TABELA 23 - Resultados obtidos pela arquitetura 6-6-2-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 60°	62
TABELA 24 - Resultados obtidos pela arquitetura 6-6-2-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 70°	63

TABELA 25 - Resultados obtidos pela arquitetura 6-6-2-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 80°	63
TABELA 26 - Resultados obtidos pela arquitetura 6-6-2-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 100°	64
TABELA 27 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 20°	66
TABELA 28 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 30°	67
TABELA 29 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 40°	67
TABELA 30 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 50°	68
TABELA 31 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 60°	68
TABELA 32 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 70°	69

TABELA 33 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 80°	69
TABELA 34 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 100°	70
<hr/>	
TABELA 35 - Desempenho geral das quatro arquiteturas de redes neurais analisadas	76

LISTA DE ABREVIATURAS E SIGLAS

ATP	- Alternative Transients Program
ACSR	- Aluminium Cable Steel Reinforced
CC	- Corrente Contínua
EMTP	- Eletromagnetic Transients Program
RNAs	- Redes Neurais Artificiais
s.l.	- sem local de publicação
SNNS	- Stuttgart Neural Network Simulator
SSE	- Soma Quadrática dos Erros
TC's	- Transformadores de Corrente
TP's	- Transformadores de Potencial

LISTA DE SÍMBOLOS

- A_p - atenuação máxima na banda de passagem
 A_a - atenuação mínima na banda de atenuação
 b - característica *off-set*, *bias* ou *threshold* do neurônio
 $b_j(k+1)$

- *bias* referente a unidade j atualizado após um ciclo de treinamento
 b_p - banda ou faixa de passagem
 C - capacitância da linha de transmissão por unidade de comprimento
 d_j - diferença máxima que é tolerada entre o valor de aprendizado (t_j) e a saída desejada (y_j)
 f - função de ativação
 H_o - constante representando o ganho desejado
 I - entrada total considerada pelo neurônio
 I_A - corrente na fase A
 I_B - corrente na fase B
 I_C - corrente na fase C
 I_{\rightarrow} - valor da corrente observada no ponto considerado
 I_o - módulo da corrente à terra
 L - indutância da linha de transmissão por unidade de comprimento
 $P, T,$
 Q e R - barramentos referentes a topologia do sistema elétrico analisado
 R - resistência da linha de transmissão por unidade de comprimento
 R_f - resistência de falta considerada
 R_{solo} - resistividade do solo
 $S_j(k)$ - função de ativação sigmoideal considerada para a unidade j em um determinado instante k
 $S'_j(k)$ - derivada de primeira ordem da função de ativação sigmoideal considerada para a unidade j em um determinado instante k

- T/D - relação entre a espessura e o diâmetro externo do condutor
- $V \updownarrow$ - valor da tensão observada entre os pontos considerados
- x_i - entradas fornecidas à rede neural artificial
- Z_c - impedância da carga conectada ao sistema considerado
- Z_{l1} - impedância da linha de transmissão do sistema considerado
- Z_{l2} - impedância da linha de transmissão situada entre o ponto de ocorrência da falta e a carga conectada ao sistema considerado
-
- w_{ij} - pesos atribuídos as conexões da rede neural
- $w_{ij}(k+1)$
- pesos atribuídos as conexões da rede neural após um ciclo de treinamento
- $y_j(k)$ - saída apresentada pelo neurônio em um determinado instante k
- $y_j^*(k)$ - saída desejada para o neurônio em um determinado instante k
- α - taxa de aprendizagem especificando o passo de aproximação considerado pelo método do gradiente descendente
- μ - termo *momentum* especificando o quanto altera-se o valor da conexão considerada
- $\delta_j(k)$ - erro apresentado pelo neurônio em um determinado instante k
- Δx - pequena seção de uma linha de transmissão
- 20-20-20-1
- arquitetura de uma rede neural artificial apresentando 20 unidades na camada de entrada, duas camadas intermediárias com 20 unidades cada e uma camada de saída com 1 unidade
- 20-15-10-1
- arquitetura de uma rede neural artificial apresentando 20 unidades na camada de entrada, duas camadas intermediárias, com 15 e 10 unidades cada, e uma camada de saída com 1 unidade
- 6-6-2-1
- arquitetura de uma rede neural artificial apresentando 6 unidades na camada de entrada, duas camadas intermediárias, com 6 e 2 unidades cada, e uma camada de saída com 1 unidade

7-7-7-1

- arquitetura de uma rede neural artificial apresentando 7 unidades na camada de entrada, duas camadas intermediárias com 7 unidades cada e uma camada de saída com 1 unidade
-

RESUMO

OLESKOVICZ, M. *Redes neurais artificiais: uma alternativa para proteção de linhas de transmissão*. São Carlos, 1997. 81p. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo.

Este trabalho apresenta a aplicação de Redes Neurais Artificiais (RNAs) como um classificador de padrões para as operações do relé de distância. As grandezas analisadas referem-se aos valores trifásicos de tensões e correntes do sistema elétrico, incluindo a sequência zero. Para a obtenção dos valores amostrais da linha de transmissão em condição faltosa, valores estes utilizados como entradas para as arquiteturas de RNAs em seus processos de treinamento e teste, utilizou-se do *software Alternative Transients Program - ATP*. Para se observar o desempenho do relé de distância implementado, duas formas de análise dos valores trifásicos foram adotadas. Uma utilizando-se como entrada os cinco valores amostrados em meio ciclo pós-falta do sinal analisado e a segunda, pelo emprego da magnitude dos fasores de tensões e correntes, incluindo a sequência zero. A função da rede neural implementada é de capturar o conhecimento da correta atuação do relé de distância, para posteriormente atuar com melhores resultados frente às situações de operações que por ventura venham a ocorrer. Para criar, treinar (obtenção dos pesos associados como saída) e testar as arquiteturas de RNAs, utilizou-se do *software Stuttgart Neural Network Simulator (SNNS)*. Dos resultados encontrados comenta-se o desempenho do relé de distância implementado frente às duas abordagens anteriormente descritas. Do uso de RNAs como um classificador de padrões, observa-se uma melhora no desempenho do sistema de proteção, alcançando-se uma definição de 96% do comprimento da linha de transmissão como sendo a zona de proteção primária do relé de distância digital.

Palavras chave: Proteção de distância, sistemas de potência, redes neurais artificiais.

ABSTRACT

OLESKOVICZ, M. *Artificial Neural Networks: an alternative for the protection of transmission lines.* São Carlos, 1997. 81p. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo.

This work demonstrates the use of Artificial Neural Networks (ANNs) theory as a pattern classifier for a distance relay operation. The approach utilizes the magnitudes of the three phase voltage and current phasors (including the zero sequence) as inputs. The Alternative Transients Program (ATP) software is used to generate data for the transmission line in a faulted condition both for the training process and the tests. Two different types of ANN architecture, concerning the input data, are taken into account. The main objective was to analyse the relay performance considering each of them. One approach utilises the five post-fault samples as inputs. The other one employs the magnitudes of the three phase voltage and current phasors (including the zero sequence) as inputs. The implemented neural network should capture the knowledge for the correct relay operation facing the different network conditions. A comparison of how well the schemes performed is carried out. The Stuttgart Neural Network Simulator (SNNS) was used to create the ANN diagram, train it and obtain the weights as an output. An improvement concerning the use of ANNs for distance protection purposes is found. Through the use of ANN as a pattern classifier, a reach of 96% of the transmission line length as the relay primary protection zone was implemented in this work.

Key words: Distance Protection, Power Systems, Artificial Neural Networks.

INTRODUÇÃO

1.1 A proteção das linhas de transmissão

O sistema de proteção tem por função salvaguardar um sistema elétrico de potência dos efeitos danosos de uma falta sustentada. Logo, a proteção deve remover o elemento defeituoso o mais rápido possível do resto do sistema, isolando deste, a menor seção possível. Com isto, o sistema de proteção deve apresentar a capacidade de responder às anormalidades, nas condições de operação e aos curtos-circuitos para os quais fora projetado. Além disto, deve reconhecer e selecionar entre as condições de operação instantânea e temporizada, apresentando confiabilidade e rapidez de ação na ocorrência de uma situação de falta.

Dentre os componentes de um sistema elétrico de potência, a linha de transmissão é o elemento mais susceptível a faltas, especialmente se considerarmos as suas dimensões físicas e complexidade funcional. Esta fica exposta a uma grande margem de riscos como intempéries, descargas atmosféricas e outros.

Das principais causas de faltas em linhas de transmissão, destacam-se as descargas atmosféricas, conforme HEDMAN (1979). O seu efeito é de iniciar um arco tanto entre fases, quanto entre fases à terra, ou ainda através de uma porção aterrada da estrutura da linha.

Quanto aos tipos da ocorrência sobre uma linha de transmissão, faltas podem ocorrer entre:

- a) algum condutor à terra (faltas fase-terra);
- b) entre dois condutores à terra (faltas fase-fase-terra);
- c) entre dois condutores (faltas fase-fase) ou
- d) faltas trifásicas.

Podemos ilustrar a predominância de faltas em linhas de transmissão, observando a Tabela 1, de acordo com VAN ZEE* *apud* COURY (1987), que mostra o registro da distribuição de faltas, em um sistema de 500 kV, num período de dez anos.

TABELA 1 - Distribuição de faltas em um sistema de 500 kV, num período de dez anos, com a ocorrência de noventa e nove faltas.

EQUIPAMENTOS FALTOSOS	NÚMERO DE FALTAS
linha de transmissão	82
circuitos disjuntores	4
autotransformadores	6
barramentos	1
geradores	1
erro humano	5

A prática demonstra, de acordo com STEVENSON (1978), que entre 70% a 80% das faltas nas linhas de transmissão ocorrem entre um só condutor e a terra. Um menor número de faltas refere-se às que envolvem todas as três fases, em torno de 5%.

*VAN ZEE, W. H. & FELTON, R. J. 500 kV 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.

Outro importante apontamento refere-se ao ângulo de incidência da falta, onde, segundo WARRINGTON (1968), esta ocorre entre os 40° que antecedem o valor máximo de tensão. Para maior esclarecimento apresenta-se na Fig. 1 o comportamento da forma de onda de tensão e corrente sobre um sistema elétrico, para uma falta aplicada com um ângulo de incidência de 90° .

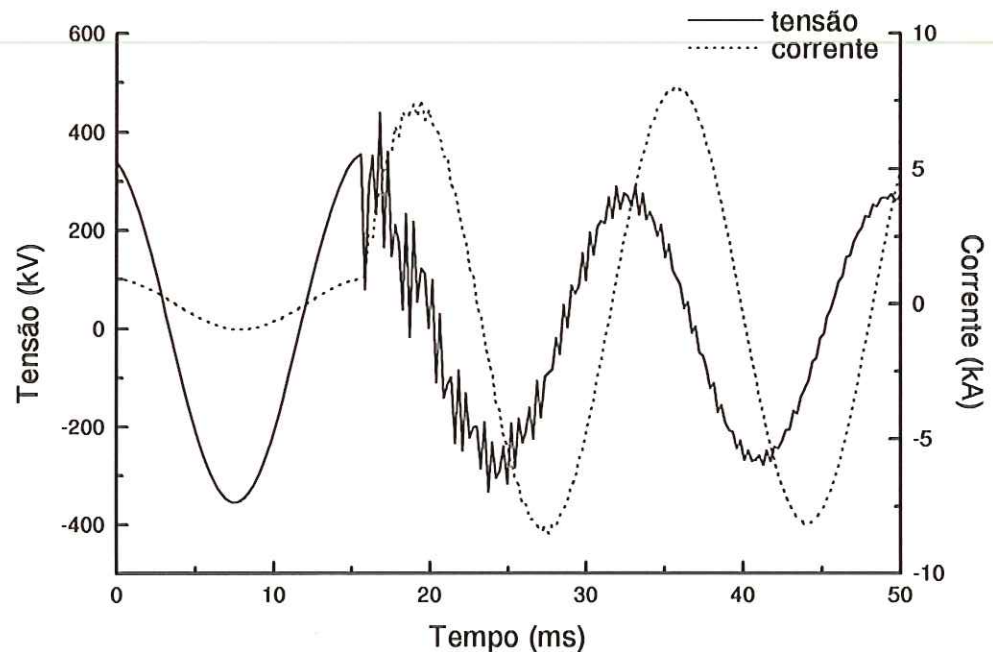


FIGURA 1- Forma de onda da tensão e corrente, para uma falta fase-terra, com um ângulo de incidência de 90° .

1.2 Proteção por relés de distância eletromecânicos e de estado sólido

Para a proteção das linhas de transmissão, frente às possíveis situações de faltas, diferentes tipos de relés convencionais são utilizados. Os mais frequentemente empregados são os relés de distância eletromecânicos e de estado sólido. Estes respondem através da impedância observada entre a localização do relé e a localização da falta, obtida em função dos valores de tensão e corrente registrados.

Como a impedância por quilômetro de uma linha de transmissão, como afirma STANLEY & PHADKE (1992), é favoravelmente constante, estes respondem à distância da falta sobre a linha de transmissão; de onde explica-se o seu nome - **relé de distância**. Como o seu próprio nome nos diz, este mede a distância, ou seja, reconhece faltas ocorrendo dentro de uma seção ou zona protegida da linha, considerando que a distância do relé à falta é menor do que o seu valor de ajuste pré-especificado. Contudo, esta seção ou zona de proteção do relé de distância não pode ser precisamente determinada, e uma certa incerteza sobre o seu exato alcance na proteção deve ser aceito. Normalmente, conforme WARRINGTON (1968), o relé mede um valor de impedância superior a da linha, devido à impedância da carga conectada à mesma (Fig. 2).

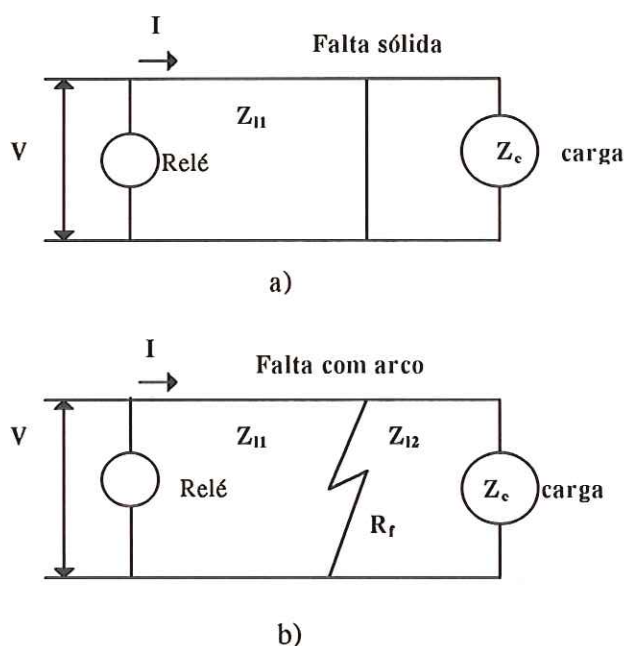


FIGURA 2- Impedância medida pelo relé, observando as devidas impedâncias encontradas.

Se uma falta sólida ocorrer (Fig. 2a), há um curto-circuito na carga e a impedância medida pelo relé é somente a impedância da linha (Z_{l1}). No entanto, se encontrarmos uma situação (Fig. 2b) com determinado valor de resistência de falta (R_f), esta impedância, em paralelo com a da carga (Z_c) e da linha para a carga (Z_{l2}), é

adicionada à da seção da linha com falta (Z_{11}), e isto indica uma falta mais distante do que realmente é, diminuindo o alcance de proteção do relé.

A incerteza sobre o alcance da zona de proteção é tipicamente da ordem de 5% da zona marcada, que é usualmente fixa entre 80 a 90% do comprimento da linha, segundo STANLEY & PHADKE (1992). Assim, define-se a zona de proteção primária do relé, e deve-se estar certo de que o relé não atuará instantaneamente para situações de faltas fora da sua zona de proteção primária. Deve estar claro que somente a zona de proteção primária não protege o total da linha de transmissão. Conseqüentemente, o relé de distância é projetado com outras zonas de proteção (zonas de proteção secundária e terciária), as quais deliberadamente alcançam além do terminal remoto da linha de transmissão, que não serão abordadas neste trabalho.

1.3 Proteção por relés de distância digitais

Com a crescente disponibilidade dos circuitos integrados e uso de microprocessadores, pesquisas nos anos de 1960 e seguintes, conforme PHADKE (1988), marcaram o início da aplicação do computador digital, substituindo tradicionais ferramentas e possibilitando a aplicação de equipamentos de controle e análise mais sofisticados para funções específicas.

Atentando ao princípio de funcionamento do relé de distância, observou-se a possibilidade da aplicação do computador digital para desempenhar as funções atribuídas ao modelo convencional (eletromecânicos e de estado sólido). Os sinais de entrada para o relé digital de impedância são os sinais de tensões e correntes, obtidos através de transdutores (TP's e TC's) que atenuam os mesmos, para um nível computacionalmente aceitável. Os sinais atenuados são então convertidos à forma digital (discreta) através de um conversor analógico/digital. Contudo, os sinais de entrada, após a ocorrência da falta, apresentam componentes de frequência fundamental, que são de interesse, e componentes indesejáveis, caracterizados como ruídos (componente CC e harmônicas), que podem ser removidos através de um filtro digital, dependendo do algoritmo lógico empregado para determinar a operação funcional do relé. O algoritmo lógico usa as amostras de sinais, filtrados ou não, para

apresentar a decisão de abertura ou não da linha de transmissão, decisão esta que é comunicada ao sistema.

No decurso dos anos a partir de 1970, com avanços significativos no *hardware* computacional, observou-se dentre as principais vantagens no uso do relé digital ao eletromecânico, a diminuição em custo do dispositivo digital comparado ao aumento em custo do relé convencional em um mesmo período, tornando o relé digital atrativo. Além disto, em um sistema de transmissão com características operacionais variáveis, tem-se a necessidade de adaptações ou modificações nas características do relé, e a **flexibilidade** desejada para tais situações é facilmente alcançada através de um sistema digital, que apresenta características programáveis podendo desempenhar várias funções. Outro argumento que coloca o relé digital à frente é a possibilidade de **auto-checagem**, ou seja, este pode ser programado para um autodiagnóstico a fim de detectar possíveis falhas nos componentes do relé tão logo aconteçam e, com isto, permitir eventuais reparos antes que aconteça uma ação errônea do mesmo (PHADKE & THORP, 1988).

Uma questão a ser considerada, com respeito ao *hardware* empregado para suportar tal aplicação, é o rápido avanço da tecnologia digital nos últimos anos. O preocupante da questão é a manutenção e adaptação destes dispositivos quando comparados a tecnologia atual já que, como é de conhecimento, um equipamento digital torna-se obsoleto em poucos anos de utilização. Uma possível solução para tal problema, apresentada por PHADKE & THORP (1988), talvez seja a modularização do *hardware*, com processadores e periféricos pertencendo a uma mesma família. Tal idéia provê um maior período de operação aos dispositivos, proporcionando a possibilidade de reposição dos módulos com o passar dos anos, acompanhando as inovações.

1.4 Proteção por relés de distância aplicando-se redes neurais artificiais

Diante das evidências apresentadas em *journals* e *papers*, indicando a confiança depositada pela comunidade científica na teoria referente a redes neurais artificiais, esta linha de pesquisa mostra-se hoje como uma das ferramentas

empregadas com sucesso, não só em assuntos específicos como também em várias áreas do conhecimento. Empregam-se redes neurais artificiais não só em sistemas de controle, identificação e processamento de sinais, mas também em outros campos, tanto em aspectos teóricos quanto do ponto de vista prático, através das implementações desenvolvidas. As referências DILLON & NIEBUR (1996) e WARWICK *et al.* (1997) ilustram aplicações de RNAs em problemas relacionados a Sistemas Elétricos de Potência.

O trabalho que a seguir será apresentado, traz como objetivo a implementação de um sistema de proteção aplicando-se a teoria de Redes Neurais Artificiais (RNAs) como um classificador de padrões. Através das características inerentes as RNAs mostra-se por uma implementação prática, o emprego desta ferramenta que, considerando as possíveis variações operacionais do sistema, proporcionará uma devida proteção para linhas de transmissão. As grandezas analisadas na implementação, referem-se a valores trifásicos de tensões e correntes do sistema elétrico, cujos valores amostrais são obtidos pela aplicação do *software* “Alternative Transients Program (ATP)”, sendo este uma versão do *software* “Eletromagnetic Transients Program (EMTP)”. Estes *softwares* serão abordados em capítulo posterior. O banco de dados gerado através de simulações no *software* ATP descreve, através dos valores trifásicos de tensões e correntes amostrados, situações em que o relé de distância digital deveria ou não atuar, delimitando a sua zona de proteção primária. A função da rede neural implementada é de capturar o conhecimento da atuação do relé de distância digital, para posteriormente atuar com melhores resultados frente às diferentes situações de operação que porventura venham a ocorrer.

Para efeito de treinamento da rede neural, situações que caracterizavam a ação do relé de proteção digital de distância foram relacionadas a resposta um (1). Tais situações mostram que uma falta ocorreu dentro da zona de proteção primária do relé e que a linha deve ser isolada pelo sistema de proteção. Caso contrário, as situações que caracterizavam a não atuação do relé (faltas ocorridas fora da zona de proteção primária) foram relacionadas a resposta zero (0), devendo o sistema de proteção atuar como proteção de retaguarda, se outro dispositivo de proteção não o fizer.

As simulações, aplicando-se o “software” ATP, incidem sobre um sistema de transmissão de 400 kV, sendo aplicadas situações de faltas fase(a)-terra, que possuem como variáveis:

- a) a distância em quilômetros de aplicação da falta, em relação a um determinado barramento;
- b) a resistência de falta (ohm) e
- c) o ângulo de incidência da falta.

O que se espera e se comprova através do uso de redes neurais artificiais, como um classificador de padrões, é a definição de 96% do comprimento da linha de transmissão como sendo a zona de proteção primária do relé.

Para a implementação das possíveis arquiteturas de redes neurais a serem empregadas como um classificador de padrões, utilizou-se do *software* denominado por “Stuttgart Neural Network Simulator (SNNS)”, sendo suas principais funções e parâmetros descritos posteriormente.

Nos capítulos que seguem, serão abordados os aspectos teóricos e práticos no que dizem respeito ao assunto delineado. Para o capítulo 2, reserva-se uma revisão dos trabalhos publicados relacionados aos conhecimentos de redes neurais artificiais aplicados a sistemas elétricos de potência. Os fundamentos básicos da teoria sobre redes neurais artificiais, passando-se pelo neurônio biológico, modelagem matemática, reconhecimento de padrões, redes neurais de múltiplas camadas e regras de aprendizagem são abordados no capítulo 3. Já no capítulo 4, apresenta-se o sistema elétrico analisado denotando-se a sua configuração, modelagem da linha de transmissão e, dentre outros, as considerações referentes às variações nas simulações das condições de faltas aplicadas sobre o sistema. O que diz respeito a implementação de redes neurais artificiais através do *software* SNNS é delineado no capítulo 5, onde, apresenta-se também os resultados obtidos. As conclusões são apresentadas no capítulo 6, seguindo-se da apresentação das referências bibliográficas consideradas.

LEVANTAMENTO BIBLIOGRÁFICO

Como mencionado no capítulo anterior, um grande número de publicações em *journals* (locais e internacionais), *papers* e teses apontam o notável progresso dos trabalhos aplicando-se os conhecimentos referentes à área de Redes Neurais. A seguir serão comentados alguns destes trabalhos publicados, abordando a linha de pesquisa aplicada à proteção de distância de linhas de transmissão, passando pelas citações mais básicas.

2.1 Redes neurais artificiais aplicadas à proteção de sistemas elétricos de potência

Com respeito a aplicação de RNAs à proteção, destaca-se inicialmente o trabalho de KHAPARDE *et al.* (1991) que utilizaram desta ferramenta na proteção de linhas de transmissão, considerando o relé como um dispositivo de classificação de padrões. Um simples modelo sugerido por WIDROW* *apud* KHAPARDE *et al.* (1991), reconhecido como *Adaptative Linear* (ADALINE), é explorado, obtendo-se resultados encorajadores. As variáveis de entrada utilizadas pelos autores referem-se as amplitudes de tensão e corrente, que são quantificadas sobre a faixa de operação do relé, com as devidas atenuações, para o uso do microprocessador. O treinamento da rede neural é desenvolvido *off-line*, ou seja, com dados simulados ou registrados de situações reais, e após a convergência da rede neural, o conjunto de pesos trabalhados, que representam o conhecimento do sistema, são então armazenados no

* 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.

microprocessador para aplicações *on-line*, ou melhor dizendo, para aplicações acontecendo em tempo real. Como esperado pelos autores, o modelo ADALINE proposto foi capaz de localizar corretamente o ponto de operação no espaço de decisão formado pela tensão e corrente. Os mesmos afirmam ainda a possibilidade de implementação do relé adaptativo, onde entradas adicionais como direção da corrente e valores aproximados da resistência de falta deverão alterar as características de operação do relé.

KANOH *et al.* (1991) propuseram um método, baseado no processo de inferência, para a localização da seção de falta ao longo de uma determinada linha de transmissão, aplicando redes neurais para analisar a distribuição dos padrões da amplitude e o ângulo de fase da corrente no cabo pára-raios. A rede neural proposta compreende três conjuntos de redes neurais, com três camadas cada, as quais seguem o procedimento de aprendizagem *backpropagation*, sendo a distribuição dos padrões resultados de cálculos através de simulações usando-se o *software* EMTP e de medidas reais tomadas através de sensores acomodados ao longo da linha de transmissão analisada. Fica claro segundo os autores, que o método proposto pode localizar a seção de falta com alta precisão sobre o total da linha. Além do mais, segundo os mesmos, este método é de grande praticidade se comparado aos métodos convencionais, podendo ser aplicado para diagnóstico de falta em campo.

CHAKRAVARTHY *et al.* (1992a e 1992b) apresentaram um trabalho referente ao relé de distância como classificador de padrões. Introduz-se nestes trabalhos os conceitos referentes às características de operação quadrilateral do relé, pela aplicação do método de reconhecimento de padrões, bem como características de operação adaptativa sobre toda a linha .

A função de um sistema de proteção é causar a remoção imediata de qualquer seção com falta em sua zona de proteção pela atuação apropriada dos seus disjuntores, minimizando a interrupção do serviço de fornecimento de energia e limitando os danos aos equipamentos. Sobre esta idéia, YANG *et al.* (1994) expuseram um modelo de diagnóstico de faltas *on-line* utilizando-se de RNAs. O problema de diagnóstico de faltas foi formulado como um problema de reconhecimento de padrões pela identificação das diferentes combinações entre os

estados *on-off* dos relés e disjuntores. O modelo proposto é capaz de localizar a seção que apresente simples ou múltiplas falhas, sejam elas resultantes da operação do relé ou do disjuntor, ou ainda, resultantes da existência de erros na transmissão dos dados no sistema.

Cabe apontar ainda AGGARWAL *et al.* (1994) que descrevem em seu trabalho uma técnica para religamento automático adaptativo para sistemas de transmissão aplicando-se redes neurais. Incluem-se no estudo, para efeito de religamento automático, faltas temporárias e permanentes. Dos resultados apresentados, mostra-se que a configuração foi capaz de distinguir com precisão os casos de faltas apresentados mesmo quando da apresentação de sinais ruidosos para análise.

DALSTEIN & KULICHE (1995) expuseram o problema da classificação de faltas para sistemas de proteção com alta velocidade de atuação. A análise consiste na classificação de faltas com e sem arco procurando-se obter sucesso no religamento automático do sistema. Ótimos resultados indicam que esta aproximação, aplicando-se redes neurais, pode ser usada atendendo as características dos sistemas de proteção que apresentem alta velocidade de atuação. Conforme salientam os autores, faltas sobre linhas de transmissão devem ser detectadas, classificadas e localizadas com precisão para serem eliminadas o mais rápido possível. Dentre estes pontos, o mais importante referente a este trabalho é a rapidez e segurança da classificação da falta.

SIDHU *et al.* (1995) descrevem em seu artigo um relé direcional, que usa uma rede neural artificial para a proteção de linhas de transmissão. O relé usa vários atributos para obter uma decisão e se inspira na operação convencional (com vantagens), usando-se de amostras instantâneas de tensões e correntes de linha do sistema de potência. A rede neural proposta foi treinada através de padrões gerados por simulações no *software* EMTP, sendo aplicadas faltas trifásicas-terra e faltas fase-terra em várias localizações à frente e em direção reversa a um determinado ponto no sistema em estudo. Os resultados mostram a correta classificação da direção da falta e que as mesmas não são afetadas pelo tipo de falta, fases envolvidas, localização da falta, fluxo de carga e outros parâmetros. Contudo, não são questionadas mudanças de operação do sistema nesta proposta.

DALSTEIN *et al.* (1996) abordam o problema da estimação da localização da falta para sistema de proteção com alta velocidade de atuação utilizando-se de redes neurais *feedforward* para solucioná-lo. Apresenta-se no trabalho, para fins de comparação, algoritmos convencionais para a proteção de distância baseados na solução de equações diferenciais e análise de Fourier. Estes algoritmos tentam determinar a área de atuação do relé pela estimação da impedância ou distância entre o relé e a localização da falta. Empregando-se redes neurais, esta área de atuação do relé, conforme os autores, é determinada pelas características dos vetores formados por medidas de tensões e correntes trifásicas, bem como pelo conhecimento do tipo de falta ocorrido. O método foi testado por simulações de diferentes tipos de faltas adicionadas ou não de ruídos, harmônicas e saturação da corrente nos transformadores, apresentando bons resultados.

COURY & JORGE (1997) propuseram a aplicação de RNAs para proteção de distância para linhas de transmissão. A RNA implementada trabalha como um classificador de padrões para as operações do relé digital de distância, sendo capaz de reconhecer as alterações nas condições de operação do sistema e, conseqüentemente proporcionar melhorias a este. Os resultados obtidos pelos autores são encorajadores, mostrando que a RNA pode operar corretamente quando sujeita as variações do sistema de potência, mesmo quando da variação na configuração da rede analisada. No entanto, como somente faltas tipo fase-terra foram consideradas, melhoramentos devem ser introduzidos para que o sistema se aproxime mais de um relé de distância digital a ser aplicado na prática.

Ainda na linha de relés de distância, JONGEPIER & SLUIS (1997) desenvolveram uma proteção de distância adaptativa especificamente para linhas de transmissão com circuito duplo, usando RNAs.

Em KEERTHIPALA *et al.* (1997) encontramos novamente a aplicação de RNAs para classificar as faltas sobre um sistema de potência em tempo real para então serem tomadas decisões por parte dos dispositivos de proteção empregados. Os mesmos afirmam que o modelo apresentado pode ser implementado para monitorar e atuar sobre os sistemas de potências atuais.

Procurou-se através das publicações citadas, apresentar alguns comentários referentes a trabalhos que aplicam os conhecimentos da teoria de redes neurais artificiais em problemas diretamente relacionados à proteção de sistemas elétricos de potência. Destaca-se que para a maioria das aplicações utilizou-se de redes neurais *feedforward* empregando-se o *algoritmo de treinamento backpropagation*, cujos valores do conjunto de treinamento e teste, que representam situações do sistema analisado, foram obtidos através de simulações em reconhecidos *softwares*, como é o caso do “Eletromagnetic Transients Program - EMTP”.

REDES NEURAIS ARTIFICIAIS

Aplicações bem sucedidas usando-se redes neurais artificiais em áreas de engenharia têm demonstrado que esta ferramenta pode ser empregada como um método alternativo para se resolver problemas convencionais com precisão e eficiência. As características inerentes a redes neurais, tais como aprendizagem, generalização e processamento paralelo entre outras, é que tornam possíveis e viáveis muitas das aplicações. Com os próximos itens, procura-se mostrar os fundamentos básicos desta teoria, colocando-se a sua origem e alguns passos pesquisados até a obtenção de uma rede neural artificial com várias camadas, que faz parte da implementação em estudo.

3.1 O neurônio biológico

Originalmente, tal como o termo rede neural indica, as pesquisas e estudos para este modelo computacional foram direcionados à modelagem do neurônio biológico. Os modelos são extremamente simplificados quando vistos pelo lado neurofisiológico, conforme salientam HERTZ *et al.* (1991).

O neurônio biológico apresenta uma fina membrana celular que, dentre as suas funções, possui propriedades que são necessárias para o funcionamento elétrico da célula nervosa. Na figura 3, apresentada por KOVÁCS (1996), observa-se o corpo celular ou soma, que é o centro dos processos metabólicos da célula nervosa. A partir deste projeta-se uma rede de filamentos nervosos designados por dentritos e um longo e simples filamento chamado axônio, o qual eventualmente ramifica-se em filamentos

e subfilamentos. Como apresentado por Kovács, os dendritos cobrem um volume muitas vezes maior do que o próprio corpo celular e, por isto, por semelhança, formam uma árvore dendrital. O axônio, também referido como fibra nervosa, conecta a célula nervosa a outras do sistema nervoso.

Através dos estudos realizados, passou-se a entender o neurônio biológico como sendo um dispositivo computacional do sistema nervoso, que possui muitas entradas e uma saída. As entradas ocorrem através das junções sinápticas ou sinapses que conectam a árvore dendrital aos axônios de outras células nervosas. Os sinais que chegam por estes axônios são pulsos elétricos conhecidos como impulsos nervosos ou potenciais de ação e constituem a informação que o neurônio processará de alguma forma para produzir como saída um impulso nervoso no seu axônio. A transmissão do sinal de uma célula para outra na sinapse é um processo químico complexo em que substâncias transmissoras específicas são liberadas no lado emissor da junção. A consequência é um aumento ou diminuição do potencial elétrico interior do corpo da célula receptora. Se este potencial alcançar um determinado limiar, um pulso, com intensidade e duração fixas, é enviado pelo axônio. Dizemos então, que a célula está ativa ou estimulada e o pulso é enviado para as ramificações nas junções sinápticas de outras células.

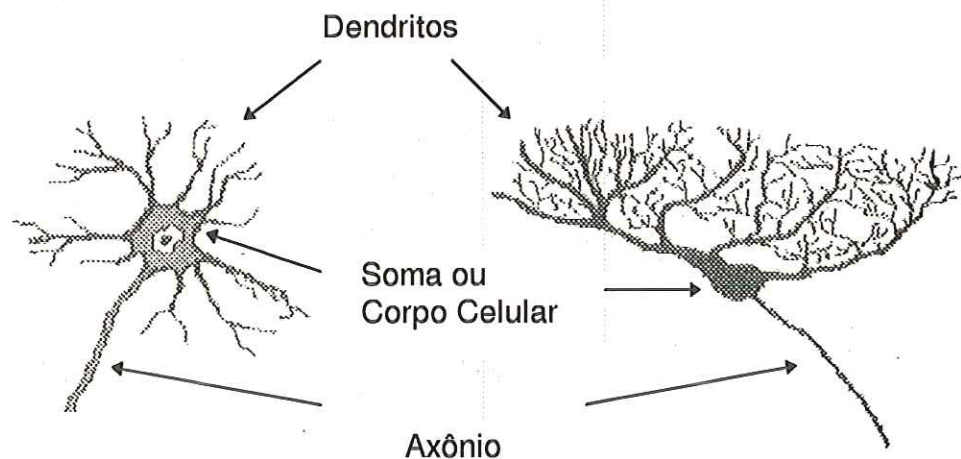


FIGURA 3 - Neurônios do sistema nervoso central dos vertebrados.

Como visto, os neurônios são unidades básicas no processamento da informação. Mostra-se a seguir um dos modelos mais utilizados para representá-lo, procurando-se sempre alcançar plausibilidade biológica.

3.2 Modelagem matemática do neurônio biológico

O elemento básico de uma rede neural artificial é o **neurônio artificial** também denominado **elemento de processamento**. Um dos modelos mais utilizados para representá-lo é mostrado na figura 4, conforme apresenta BERNIERE *et al.* (1994) e que com certeza é inspirado no modelo proposto por Warren McCulloch e Walter Pitts em 1943.




FIGURA 4 - Diagrama esquemático de um neurônio artificial.

Basicamente o modelo considera as entradas (x_i) fornecidas ao neurônio por conexões relacionadas a pesos (w_i), sendo b a característica *offset* do neurônio ou, também designada na literatura por *bias*, ou ainda *threshold* como em HERTZ *et al.* (1991). Este parâmetro (b) refere-se ao limiar ou potencial de ação característico de cada célula nervosa anteriormente citado. A saída do neurônio (y) dá-se através de uma função de ativação (f) que em geral para muitas aplicações deve ser contínua.

O processamento do neurônio é geralmente um artifício simples, que tem um número de sinais de entradas e sinais de saída. Cada sinal de entrada (x_i) é associado a um peso relativo (w_i). Assim, a entrada efetiva do neurônio é a **entrada total** considerando os pesos, ou seja, $I = \Sigma(w_i \cdot x_i)$. O modelo simplificado compara este ao *threshold* característico de cada neurônio. Se o somatório (I) for maior que o limiar

especificado (b), o neurônio está ativo e produz um sinal de saída cujo valor será considerado pela função de ativação (f). Caso contrário, se o somatório (I) for menor do que o limiar pré especificado, o neurônio não está ativo sendo o seu sinal de saída dependente da aplicação específica. Tais considerações estão representadas na equação abaixo, onde y (eq. 1) representa a saída do neurônio mostrada na figura 4,

$$y = f\left[\left(\sum w_i x_i\right) - b\right] \quad (1)$$

sendo f a função de ativação. Em geral, para aplicações que requerem uma rede neural com saídas contínuas, a função de ativação empregada é a função sigmoideal (eq. 2) representada na figura 5, onde:

$$f(.) = \frac{1}{1 + e^{-(\sum w_i x_i - b)}} \quad (2)$$

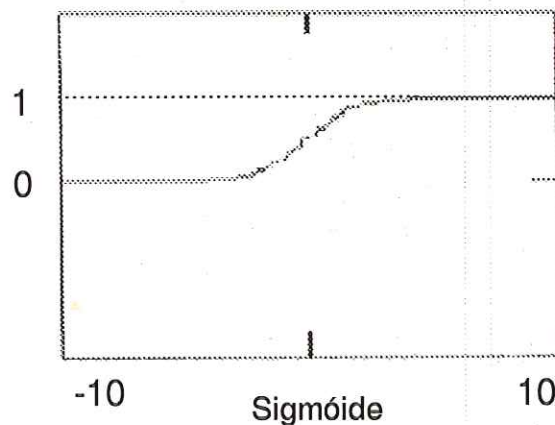


FIGURA 5 - Função sigmoideal.

Uma rede neural artificial, no entanto, compreende um conjunto destes elementos de processamento conectados e organizados em camadas. Um típico exemplo de arquitetura mais utilizado é a rede *feedforward* que será abordada no item 3.4.

3.3 Redes neurais aplicadas ao problema de reconhecimento de padrões

Em termos gerais, reconhecimento de padrões é a área do conhecimento que compreende a **identificação** e **classificação** da informação em categorias. Categorias estas que devem representar entidades ou padrões de informações estruturais que podem ser usados para a descrição de padrões e sua classificação. Para que haja o processo de classificação de padrões é necessário que exista o mapeamento dos padrões de entrada em um espaço de classificação. Esse espaço é definido por regiões de decisão que separam as classes de padrões uma das outras pela definição de fronteiras, o que pode ser realizado através de funções discriminantes que definem regras de decisão.

Como exemplo de um caso particular de discriminador linear, transcreve-se no que segue, com base em KOVÁCS (1996) a modelagem do neurônio de McCulloch e Pitts cujas entradas são binárias. Conforme apresentado pelo autor, um discriminador linear genérico de n entradas $\{x_1, x_2, \dots, x_n\}$ e uma saída y é definido pela expressão:

$$y = f \left[\sum_{i=1}^n w_i x_i - b \right] = f(w^t x - b) \rightarrow y \in [0;1]$$

$$y = \text{sgn} \left[\sum_{i=1}^n w_i x_i - b \right] = \text{sgn}(w^t x - b) \rightarrow y \in [-1;1] \quad (3)$$

onde os componentes do vetor w $\{w_1, w_2, \dots, w_n\}$ representam os pesos associados às entradas x_i , b é o limiar (*bias ou threshold*), $f(\cdot)$ é a função degrau unitário e $\text{sgn}(\cdot)$ é o operador do sinal. A eq.(4) representa um hiperplano que divide o espaço em duas regiões A e B.

Assim, um vetor x de componentes $\{x_1, x_2, \dots, x_n\}$ estará em uma destas regiões na medida que se verificar

$$w^t x - b > 0 \Rightarrow x \in A$$

$$w^t x - b < 0 \Rightarrow x \in B$$

enquanto que o valor da saída y será:

$$y = 1 \text{ se } x \in A \text{ e } y = 0 \text{ ou } -1 \text{ se } x \in B \quad (4)$$

Esta situação está representada na figura 6 para o caso em que a dimensão do espaço (n) é 2.




FIGURA 6 - Discriminador linear que separa o espaço em duas regiões A e B.

Podemos ilustrar o discriminador linear como um classificador de padrões assumindo $\Theta_1 = \{u_1, u_2, \dots, u_k\}$ de k vetores n -dimensionais e $\Theta_2 = \{z_1, z_2, \dots, z_m\}$ de m vetores n -dimensionais. Suponha que se queira implementar um discriminador linear que separe estes conjuntos de vetores no sentido da eq.(5), isto é:

$$y = 1 \text{ se } x \in \Theta_1 \text{ e } y = 0 \text{ ou } -1 \text{ se } x \in \Theta_2$$

Isto só será possível se Θ_1 e Θ_2 formarem aglomerados no espaço R^n , tal que seja possível passar um hiperplano:

$$\sum_{i=1}^n w_i x_i = w^t x = \Theta \quad (5)$$

que separe os dois aglomerados. Se Θ_1 e Θ_2 forem tais que isto seja possível então são ditas coleções *linearmente separáveis*. Caso contrário, não serão separáveis linearmente e não existirá nenhum discriminador linear capaz de executar esta função.

O neurônio de McCulloch é um discriminador linear com a simplificação adicional de que os componentes do vetor de entrada x são também binários, isto é, $x_i \in [0,1]$. Como exemplos, citam-se as funções booleanas **E**, **OU** e **OU Exclusivo** de duas variáveis, sendo que as funções **E** e **OU** são linearmente separáveis e é possível encontrar retas que separem os vetores de entrada em regiões, tal que a saída reflita corretamente o resultado das funções desejadas. O mesmo não acontece com a função **OU Exclusivo**, pois seriam necessárias duas retas discriminatórias para separar corretamente o resultado, mostrando que esta função não é linearmente separável.

Contudo, seguindo ainda o apresentado pelo autor, coloca-se que, embora neurônios simples não tenham a capacidade de implementar todas as funções booleanas, sempre existirá alguma rede de múltiplos neurônios que implementará qualquer função booleana.

3.4 Redes neurais artificiais de múltiplas camadas

Dando prosseguimento às idéias de McCulloch, ROSEMBLATT* *apud* HERTZ *et al.* (1991) criou uma rede de múltiplos neurônios do tipo discriminador linear e chamou de **perceptron**. Houve melhoras qualitativas no modelo de Rosenblatt com relação ao de McCulloch e Pitts, destacando-se no primeiro caso a regra de treinamento para os perceptrons. No entanto, devido às limitações de perceptrons simples, como por exemplo a impossibilidade de se implementar o **OU Exclusivo**, Rosenblatt não conseguiu estender à redes a lei de treinamento do perceptron.

Na mesma época em que Rosenblatt trabalhava no perceptron, WIDROW[†] *apud* KOVÁCS (1996) desenvolveu um modelo simplificado do perceptron designado por ADALINE (ADaptive LINEar Element) que mais tarde recebeu a designação de MADALINE (Múltipla Adaline) devido a sua generalização multidimensional. A contribuição de Widrow diz respeito ao princípio de treinamento por este desenvolvido, conhecido como **Regra Delta**, que mais tarde foi generalizado para redes com modelos mais elaborados. Utilizando-se do perceptron de multicamadas, o modelo original é modificado de modo a resolver problemas mais complexos. As limitações de um perceptron simples desaparecem quando se utilizam camadas intermediárias ou escondidas entre as camadas de entrada e saída. O modelo é disposto em camadas, como mostrado na figura 7, onde apresenta-se um conjunto de unidades (nós ou neurônios) divididos em três camadas.




FIGURA 7 - Uma arquitetura *feedforward*.

As unidades são ordenadas e classificadas pela sua topologia e a propagação natural da informação é da camada de entrada para a de saída, sem realimentação para as unidades anteriores, caracterizando assim, o modelo de redes neurais *feedforward*.

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

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

Neste modelo as conexões existem entre elementos de camadas diferentes, mas não entre elementos da mesma camada.

As unidades que são conectadas diretamente nas entradas da rede pertencem a uma mesma camada conhecida como **camada de entrada** e não possuem um *offset* (*bias* ou *threshold*). As unidades que fornecem as saídas da rede também pertencem a uma simples camada designada por **camada de saída**. As outras unidades são organizadas em uma ou mais camadas **intermediárias** ou **ocultas** devido a não serem diretamente alcançadas. Deve-se notar que o número de unidades das camadas de entrada e saída dependem da aplicação específica do modelo de sistema a ser analisado e que, a determinação do número de unidades das camadas intermediárias é empírico, obtido através da análise do desempenho da rede neural.

A operação da rede de multicamadas consiste da apresentação de um padrão de entrada, representado na figura 7 pelo vetor de entrada x , com componentes $\{x_1, x_2, x_3\}$, à camada de entrada, que somente redistribui este padrão às unidades da camada adjacente (no caso em exemplo, à camada intermediária), que associado a um peso relativo (w_{ij}) será considerado como parte da entrada desta. A entrada total

($I_j = \sum_{i=1}^3 w_{ij} \cdot x_i$) de cada unidade individual da camada intermediária provocará

novos estados de ativação, representado pelo vetor a , com componentes $\{a_1, a_2, a_3, a_4\}$, que serão transmitidos para as unidades da camada de saída, gerando, do mesmo modo citado, novos estados de ativação nesta última, representados pelo vetor b ($\{b_1, b_2\}$). Estes estados de ativação, conforme a aplicação, resultam em respostas na camada de saída (vetor y , com componentes $\{y_1, y_2\}$). Compara-se então as saídas obtidas e desejadas para o padrão de entrada apresentado para ajustar-se os valores das conexões (pesos e *bias*) através de um algoritmo apropriado de treinamento, que será abordado no próximo item. Uma vez que o treinamento esteja completo, a rede neural é capaz de fornecer as saídas desejadas não somente para entradas conhecidas que foram apresentadas na fase de treinamento, mas também a resposta mais plausível para qualquer entrada. Esta característica denota a capacidade de **generalização** da rede a partir de exemplos conhecidos, desde que sejam representativos, evidenciando a tolerância a ruídos que porventura possam ocorrer no sistema em estudo. Dentre

outras características, além da **aprendizagem a partir de exemplos**, pela mudança de seu comportamento em resposta a mudança no meio em que atua, a rede neural deve também apresentar a capacidade de **abstração** de características essenciais de entradas que contêm dados redundantes e ou irrelevantes. As redes neurais exibem ainda **tolerância a faltas**, uma vez que a informação é processada por elementos com processamento paralelo e distribuídos, logo, danos parciais podem não causar mudanças significativas nas respostas da rede.

3.5 Regra de aprendizagem

A mudança de valores das conexões (pesos e *bias*) envolve o processo de aprendizagem, que é um dos aspectos mais explorados em redes neurais. Em princípio, as conexões podem ser modificadas através do aparecimento de novas conexões, da perda de conexões existentes ou modificação das conexões já existentes. Em qualquer representação, unidades podem tornar-se ativas ou inativas, manipulando-se seus valores de ativação, sendo a magnitude das conexões modificadas através de experiência. Para obtenção desta **experiência** faz-se uso de algoritmos de treinamento que podem ser por:

a) **treinamento supervisionado**, cuja principal característica é o prévio conhecimento da informação sobre as classes a que pertence cada um dos padrões na fase de treinamento. Aqui, a aprendizagem é realizada com base direta na comparação da saída ou saídas da rede com a resposta desejada. Para ajuste das conexões utiliza-se deste erro (diferença entre a resposta desejada e a resposta obtida) como orientador, e por isto, este treinamento supervisionado é algumas vezes denominado *learning with teach*;

b) **treinamento não supervisionado** apresenta como principal característica o desenvolvimento do aprendizado da rede sem a supervisão de um orientador para indicar a que classe cada padrão pertence. Este tipo de treinamento aplica-se em situações onde a informação a respeito das classes não é disponível durante o treinamento. Neste caso a rede neural, por si só, deve agrupar os vários padrões existentes em diferentes classes a medida que os mesmos são apresentados durante o

aprendizado, de acordo com algum critério de similaridade definido. É esperado que a rede avalie as correlações entre os dados de entrada e produza sinais de saídas correspondentes às categorias de entrada;

c) **treinamento supervisionado e não supervisionado** oferece uma combinação dos métodos acima onde define-se uma arquitetura que utiliza aprendizado supervisionado para a representação inicial das classes conhecidas *a priori* e durante a fase de uso da rede novas classes são adicionadas ao sistema através de aprendizado não supervisionado.

Um dos algoritmos de treinamento supervisionado mais utilizado é conhecido como *backpropagation* e pode ser aplicado a redes neurais *feedforward* com no mínimo uma camada intermediária.

O algoritmo de **retropropagação** ou *backpropagation* para redes de múltiplas camadas, também referenciado como **Regra Delta Generalizada**, foi desenvolvido independentemente por vários pesquisadores conforme relata HERTZ *et al.* (1991) resolvendo limitações fundamentais para o treinamento de redes complexas.

A operação da rede na fase de treinamento possui dois passos distintos: um de **propagação**, onde um padrão conhecido é apresentado na entrada da rede e as unidades de processamento computam camada após camada, funções de ativação até chegar na camada de saída, e um passo de **retropropagação**, onde os erros computados na camada de saída são utilizados para atualizar, da camada de saída para a camada de entrada, as conexões da rede.

Como já mencionado, o algoritmo busca minimizar o erro entre uma saída obtida pela rede e uma saída desejada e, para tal, usa o método do gradiente descendente, que requer funções de ativação que variem suavemente, como é o caso da função sigmoidal (figura 5).

Apresenta-se no que segue o algoritmo de treinamento *backpropagation* segundo HERTZ *et al.* (1991) para redes neurais com múltiplas camadas sendo a sua formulação detalhada apresentada no apêndice.

3.5.1 Algoritmo *backpropagation*

a) Inicialização dos pesos e *bias*

Com uma distribuição inicial dos pesos e *bias*, para o instante de tempo $k = 0$, atribui-se valores a estes parâmetros da rede que, por exemplo, podem ser pequenos valores aleatórios.

b) Apresentação do padrão de entrada e obtenção da saída

Para um dado conjunto de entradas, as saídas da rede $y_j(k)$, no passo k são geradas. Para cada camada acha-se a saída das respectivas unidades pela eq. 7:

$$y_j(k) = S_j \left[\left(\sum_{i=1}^m w_{ij} x_i \right) - b \right] \quad (6)$$

$$S_j(.) = \frac{1}{1 + e^{-\left(\sum_{i=1}^m w_{ij} x_i - b \right)}} \quad (7)$$

onde w_{ij} representa a conexão entre a unidade i e a unidade j no instante de tempo k e m representa o número de unidades que pertencem a camada posterior a unidade j em análise.

Assim, as saídas das unidades de uma camada são passadas adiante como entradas da próxima camada até chegar-se à camada de saída.

c) Cálculo do erro encontrado (δ_j)

• para as unidades da camada de saída:

$$\delta_j(k) = S'_j(.) \left(y_j^*(k) - y_j(k) \right)$$

$$\delta_j(k) = y_j(k)[1 - y_j(k)] \left[y_j^*(k) - y_j(k) \right] \quad (8)$$

onde:

$S'_j(k)$ é a derivada da função sigmoideal para as unidades da camada de saída ;

$y_j^*(k)$ representa a saída desejada no passo k e

$y_j(k)$ representa a saída encontrada pela rede no passo k .

• para as unidades das camadas intermediárias:

$$\delta_j(k) = S'_j(k) \left[\sum_{p=1}^n \delta_p(k) w_{jp}(k) \right]$$

$$\delta_j(k) = y_j(k)[1 - y_j(k)] \left[\sum_{p=1}^n \delta_p(k) w_{jp}(k) \right] \quad (9)$$

onde:

S'_j é a derivada da função sigmoideal para as unidades das camadas intermediária;

$\delta_p(k)$ representa o erro no passo k para as unidades da camada adjacente e

n representa o número de unidades que a compõe.

d) Adaptação dos pesos e bias

Os erros determinados no passo (c) são então usados para reajustar os valores dos pesos e *bias* de cada unidade, respeitando a topologia da rede em análise pelas seguintes equações:

$$w_{ij}(k+1) = w_{ij}(k) + \alpha \delta_j(k) y_j(k) \quad (10)$$

$$b_j(k+1) = b_j(k) + \alpha \delta_j(k) \quad (11)$$

onde α é a taxa constante de aprendizagem.

Através da interação entre as etapas (a, b, c e d) acima descritas, que correspondem ao algoritmo de treinamento, usando-se de novos conjuntos de entradas e saídas desejadas (que constituem os exemplos para o treinamento supervisionado), a distribuição dos valores dos pesos e *bias* pode ser alcançada minimizando os erros apresentados nas equações 9 e 10. Logo as interações podem ser efetuadas até atingir-se um valor do erro $(\delta_j(k))$ pré-definido ou até um certo número de interações desejável. Na primeira situação podemos tentar garantir a convergência do erro para um mínimo, utilizando-se do método do gradiente descendente. Nesta situação de convergência a rede foi capaz de aprender através dos exemplos a ela apresentados e pode ser utilizada em estágios posteriores para calcular as saídas que correspondam a qualquer entrada, desde que estas guardem certa coerência com o conjunto utilizado para o treinamento.

SISTEMA ELÉTRICO ANALISADO

Com o objetivo de testar a aplicabilidade das arquiteturas de RNAs a serem propostas, utilizou-se da simulação de um sistema de transmissão em condição faltosa. Para tal, o *software* ATP foi empregado. Deve ser mencionado que a técnica descrita é baseada em simulações computacionais e que considerações práticas tais como o efeito dos transdutores (TC's e TP's), filtros *anti-aliasing* e quantização sobre os dados de faltas do sistema primário foram também incluídos na simulação, fazendo com que os dados obtidos aproximem-se dos reais. Foi também considerada as características dos condutores e suas respectivas disposições geométricas nas torres de transmissão.

Apresenta-se nos próximos itens a configuração do sistema elétrico considerado neste estudo.

A topologia da linha de transmissão de 400 kV é encontrada no manual *ALTERNATIVE transients program rule book* (1987). Após a modelagem da linha de transmissão, seguem-se as simulações que dizem respeito às situações de operações analisadas através do uso do *software* ATP, cujos resultados apresentados serão empregados no capítulo 5, quando da aplicação em Redes Neurais Artificiais à proteção de distância de linhas de transmissão.

4.1 Configuração do sistema de potência

Observa-se na figura 8 a representação do sistema elétrico estudado com a especificação das fontes, barramentos e comprimentos das linhas de transmissão.




FIGURA 8 - Representação do sistema elétrico analisado.

Considera-se neste trabalho uma proteção de distância de 96% do comprimento da linha de transmissão de 150 km, o que corresponde a 144 km sobre a mesma (região pontilhada na figura 8). Com isto, procura-se definir a zona de proteção primária do relé aplicando-se situações de faltas fase(a)-terra entre os barramentos PT, TQ e TR. A rede neural implementada, que será posteriormente apresentada, deverá capturar o conhecimento da atuação do relé de distância digital. Para efeito de treinamento da rede neural, situações de faltas que pertencem a zona de proteção primária do relé foram relacionadas ao valor um (1), indicando que devem ser tomadas decisões para excluir o ocorrido. Caso contrário, para situações que caracterizem a não atuação do relé de distância digital, a resposta relacionada deste ao sistema elétrico deve ser zero (0). Para a aplicação de RNAs à proteção digital de distância convencionou-se, para as respostas das redes que, saídas $< 0,5$ referem-se a situações de faltas ocorridas fora da zona de proteção primária do relé e que, saídas $\geq 0,5$ pertenceriam a zona de atuação do relé.

4.2 Modelagem da linha de transmissão

Como mencionado, a topologia da linha de transmissão de 400 kV foi obtida do manual *ALTERNATIVE transients program rule book* sendo que a mesma é apresentada na figura 9. Apresenta-se no que segue, as especificações referentes aos condutores empregados, denotando-se as suas principais características, bem como a resistividade do solo considerada.

Condutores de fase

- a) tipo do condutor: Bluejay 45x7 - ACSR;
- b) relação entre a espessura e o diâmetro externo do condutor (T/D): 0.231;
- c) diâmetro interno do condutor: 7.98 mm;
- d) diâmetro externo do condutor: 31.98 mm;
- e) resistência em corrente contínua: 0.051370 Ω /km.

Pára-raios

- a) tipo do condutor: Guinea 12x7 - ACSR;
- b) relação entre a espessura e o diâmetro externo do condutor (T/D): 0.5;
- c) diâmetro externo do condutor: 14.6 mm;
- e) resistência em corrente contínua: 0.35961 Ω /km.

Resistividade do solo

R_{solo} : 250 Ω /km.




FIGURA 9 - Topologia da linha de transmissão definindo seus principais parâmetros.

4.2.1 Parâmetros do sistema elétrico

Para se efetuar as devidas simulações do sistema elétrico proposto, utilizando-se do *software* ATP, adotou-se considerações necessárias para os cálculos dos parâmetros da linha de transmissão, considerando-se as características dos condutores e suas respectivas disposições geométricas nas torres de transmissão, como mostrado na figura 9. Dentre as considerações, optou-se por **linhas transpostas**, já que a transposição compensa os desequilíbrios dos campos magnéticos entre fases, cabo de cobertura, ferragens e solo sob a linha de transmissão conforme apresenta KINDERMANN (1992). O resultado esperado da transposição, segundo STEVENSON (1978), será a mesma indutância média para cada condutor. Uma observação prática feita por WEEDY (1973) nos diz que raramente as linhas são transpostas em intervalos regulares, sendo a transposição executada onde for

fisicamente conveniente, como por exemplo, em subestações. A transposição de uma linha de transmissão qualquer é ilustrada na figura 10.




FIGURA 10 - Transposição de uma linha de transmissão.

Outra das considerações permite analisar a linha de transmissão com **parâmetros distribuídos** e **constantes** em relação à frequência, utilizando-se da rotina *Line Constants* apresentada pelo *software* ATP, que será posteriormente abordada.

Para se obter uma solução exata para os parâmetros de qualquer linha de transmissão segundo STEVENSON (1978), bem como um alto grau de precisão, deve-se considerar o fato de que os parâmetros de uma linha não estão concentrados em um ponto, e sim, uniformemente distribuídos ao longo de todo o seu comprimento. Na figura 11 mostra-se um esquema monofásico representando uma pequena seção (Δx) de uma linha de transmissão, sendo os parâmetros (R , L e C), distribuídos e constantes, determinados pela rotina *Line Constants* do *software* ATP. Nesta, L é a indutância da linha por unidade de comprimento, R é a resistência por unidade de comprimento em corrente alternada e C é a capacitância da linha por unidade de comprimento.




FIGURA 11 - Representação de uma seção de uma linha de transmissão por parâmetros distribuídos.

4.2.2 Rotina *Line Constant* e a interface gráfica DESTRO

Após a caracterização da topologia das linhas de transmissão desejadas, passa-se ao início dos cálculos dos parâmetros que referem-se as mesmas. Apresenta-se na figura 12 o arquivo de entrada para a rotina *Line Constant*, presente no *software* ATP, que descreve a topologia do sistema analisado. Observa-se nesta os principais parâmetros já apresentados na figura 9. Dentre eles, os espaçamentos e alturas relativas entre condutores, número de condutores por fase, resistividade do solo, frequência em que os parâmetros foram calculados, condições da linha (com ou sem transposição), etc. Da execução da rotina *Line Constant* interessa-nos, dentre as inúmeras informações, os valores de seqüência zero e positiva das grandezas referentes às resistências, reatâncias e susceptâncias, considerando a linha de transmissão com transposição.

```

BEGIN NEW DATA CASE
LINE CONSTANTS
METRIC
BRANCH PA  BUSTA PB  BUSTB PC  BUSTC

1 .231 .05137 4    3.198 -12.2  21.63  9.83
  |-----|-----|-----|-----> espaçamentos horizontais
  |-----|-----|-----|-----> e alturas relativas
  |-----|-----|-----> T/D
  |-----|-----> (skin)
  |-----> diâmetro externo (cm)
  |-----> resistência CC do condutor
  |-----> fase do condutor

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 :
  |-----|-----|-----|-----> cabos pára-raios

BLANK card ending conductor cards within "LINE CONSTANTS" data
250. 600.0        1  1  0  150.        0
  |-----|-----> frequência
  |-----> resistividade do solo

BLANK card ending frequency cards of "LINE CONSTANTS" data
BLANK card ending "LINE CONSTANTS" data cases
BEGIN NEW DATA CASE
BLANK

```

FIGURA 12 - Arquivo de entrada para a rotina *Line Constant* descrevendo a topologia da linha de transmissão analisada.

Com os resultados obtidos através da rotina *Line Constant*, considerando as linhas de transmissão com transposição e parâmetros distribuídos, fez-se uso da interface gráfica DESTRO (1996). Esta interface possibilita ao usuário facilidades em gerar um arquivo de entrada, descrevendo a situação em que se encontra o sistema elétrico, a ser executado pelo *software* ATP.

4.3 Variações nas simulações das condições de faltas

Para a aplicação de redes neurais artificiais ao problema de reconhecimento de padrões, relacionado a proteção de distância de linhas de transmissão, é indispensável a elaboração de um conjunto de padrões que represente as situações de operação do sistema elétrico analisado. Este conjunto de padrões, que neste caso descreverá situações de faltas em que o sistema de proteção deve ou não atuar, é utilizado como mencionado no item 3.5, para o treinamento supervisionado da rede neural através do algoritmo de treinamento *backpropagation*. Salienta-se que a formação deste conjunto deve, da melhor maneira possível, apresentar à rede neural as possíveis situações que a mesma possa encontrar, ou seja, situações representativas que definam claramente a zona de atuação primária do relé de proteção digital de distância. Devido às inúmeras situações de faltas que podem ou não ser previstas no sistema elétrico, da escolha de um conjunto representativo de treinamento dependerá o desempenho da rede neural a ser implementada. Para a formação deste conjunto de treinamento foram aplicadas 400 situações de faltas no sistema elétrico, variando-se a distância e o ângulo de incidência da falta em relação ao barramento P (figura 8) e a resistência de falta. Todas estas situações foram simuladas pelo *software* ATP caracterizando situações de operação ou não do sistema de proteção. As variações consideradas compreendem os seguintes parâmetros:

a) Distâncias em que as faltas foram aplicadas para obtenção do conjunto de treinamento (figura 8):

- distâncias entre os barramentos P e T (km): 10, 40, 70, 100, 120, 130, 135, 138, 141, 144 e 147.
- distâncias entre os barramentos T e Q (km): 160, 170, 185 e 205.
- distâncias entre os barramentos T e R (km): 155, 165, 175, 195 e 215.

b) resistências de faltas consideradas (Ω): 0.1, 17.0, 50.0, 80.0 e 100.

c) ângulos de incidência de falta ($^\circ$): 0 (zero), 45, 90 e 110.

Como resposta da simulação de cada situação de falta no *software* ATP, obtêm-se os valores de tensão e corrente trifásicos em relação ao barramento P. O arquivo de dados descrevendo cada situação de falta é apresentado pelo *software* a

um passo de integração correspondente a $20 \mu\text{s}$, o que nos deixa com uma frequência amostral de 50 KHz requerendo uma reamostragem dos dados, já que a frequência amostral empregada pelo relé de proteção digital é próxima a 4 KHz. Além disto, é de interesse para esta aplicação uma filtragem dos valores amostrados, reduzindo-se os componentes de alta frequência do sinal amostrado. Para tal, o filtro digital passa-baixa empregado refere-se ao filtro Butterworth e alguns comentários sobre o mesmo seguem abaixo.

4.4 Filtro digital passa-baixa Butterworth

Com o objetivo de reduzir as componentes harmônicas de alta frequência do sinal amostrado, com frequências superiores a 2 KHz, evitando-se a sobreposição de espectros (efeito *aliasing*), conforme apresentado por PHADKE (1988), faz-se necessário a implementação de um filtro digital passa-baixa Butterworth.

Para a implementação de um filtro digital passa-baixa Butterworth inicia-se do projeto do filtro analógico Butterworth, sendo que o filtro passa-baixa ideal caracteriza-se pela figura 13, onde a amplitude da função de transferência é constante de $w = 0$ até $w = w_c$ (frequência de corte) e zero para todo w maior do que w_c conforme mostram ANTONIOU (1979) e CHEN (1986).




FIGURA 13 - Característica do filtro ideal passa-baixa, onde b_p representa a banda ou faixa de passagem.

Assim, o filtro deixará passar somente componentes de baixa frequência. Sua característica de “perdas” é da forma mostrada na figura 14, ressaltando a perda zero na faixa de passagem e perda infinita após a frequência de corte.

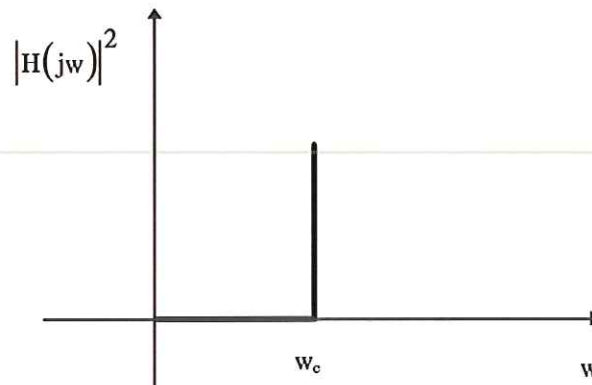


FIGURA 14 - Característica das perdas de um filtro passa-baixa ideal.

As diferenças entre um filtro passa-baixa real e um filtro passa-baixa ideal mostram-se na faixa de passagem, sendo que no primeiro caso a perda não é zero nesta faixa e, no final da mesma, a perda não tende a infinito. A diferença caracteriza-se também pelo fato de que a transição da faixa de passagem é gradual no filtro passa-baixa real, conforme ilustra a figura 15, onde w_p indica a frequência final da faixa de passagem, w_c a frequência de corte e w_a a frequência de atenuação.




FIGURA 15 - Característica das perdas em um filtro passa-baixa real*.

* ANTONIOU (1979).

Escolheu-se a aproximação Butterworth para o filtro por esta prover a máxima planura na faixa de passagem, com um valor máximo de atenuação igual a 1 dB e um decréscimo monotônico do ganho até a frequência desejada com atenuação de 60 dB (para o caso projetado).

Como ilustração da aplicação do filtro digital Butterworth implementado, apresenta-se na figura 16 o sinal trifásico amostrado da tensão para uma falta ocorrida a 10 km do barramento P (item 4.1, figura 8) envolvendo a fase a à terra, com uma resistência de falta de 0.1Ω e com um ângulo de incidência da falta de 90° . Na figura 17, a saída do filtro passa-baixa aplicado para a mesma situação.




FIGURA 16 - Valores amostrados (**não filtrados**) referentes a tensão quando uma falta envolvendo a fase a à terra é aplicada a 10 km do barramento P (item 4.1, figura 10), com um ângulo de incidência de 90° e com uma resistência de falta de 0.1Ω .




FIGURA 17 - Valores amostrados (filtrados - filtro Butterworth) referentes a tensão quando uma falta envolvendo a fase a à terra é aplicada a 10 km do barramento P (item 4.1, figura 10), com um ângulo de incidência de 90° e com uma resistência de falta de 0.1Ω .

4.5 Análise dos valores amostrados

Para o objetivo da pesquisa, trabalha-se com os dados reamostrados, de duas maneiras distintas. Em uma situação reamostra-se os dados a 4kHz. Após este procedimento aplica-se a Transformada Discreta de Fourier de meio ciclo, analisando 34 amostras pós-falta, para se obter os módulos de tensão e corrente nas fases a, b e c e obtendo-se também o valor representativo da corrente à terra ($I_o = (I_A + I_B + I_C)/3$) para utilização nas arquiteturas analisadas. Outra situação é através da análise de uma nova reamostragem dos valores pós-falta do sinal considerado (tensão e corrente nas fases a e b). Nesta situação, a frequência amostral resultante corresponde a 590 Hz, fornecendo cinco valores no período considerado para as outras arquiteturas consideradas. As duas formas de análise foram adotadas para se verificar qual abordagem descreveria melhor os sinais analisados, já que o problema estudado, redes neurais artificiais - uma alternativa para proteção de linhas de

transmissão, é abordado como um caso de reconhecimento de padrões. Maiores detalhes a respeito das arquiteturas consideradas serão dados no próximo capítulo.

Em ambos os casos os valores de tensão e corrente foram normalizados sendo que, para a tensão, todos os valores foram divididos pela tensão base (400 kV) e, para os valores de corrente, os mesmos foram divididos por um fator comum de 33 kA. Desta maneira, todos os possíveis valores de entrada para as arquiteturas das redes neurais estudadas permanecem no intervalo $[0, 1]$, não dificultando a sua convergência, como comprovado na literatura.

APLICAÇÃO DO SOFTWARE SNNS

O SNNS (versão 4.1) destina-se à simulação de redes neurais artificiais, possibilitando um ambiente flexível para pesquisa e aplicação das técnicas que o envolvem. Este foi desenvolvido pela Universidade de Stuttgart e foi disponibilizado como um sistema de “domínio público”.

Em todas as arquiteturas *feedforward* que seguem, foram utilizadas funções pré-definidas pelo *software* SNNS, sendo as principais funções comentadas abaixo:

a) método de aprendizagem:

- *Std_Backpropagation* (Backpropagation) parâmetros:

α → taxa de aprendizagem, especifica o passo de aproximação considerado pelo método do gradiente descendente. Valores típicos situam-se entre 0 (zero) e 1;

d_j → diferença máxima que é tolerada entre o valor de aprendizado (t_j) e da saída desejada (y_j);

- *BackpropMomentum* (Backpropagation com o termo *momentum*) parâmetros:

α → taxa de aprendizagem;

μ → termo *momentum*, especifica o quanto altera-se o peso anterior, sendo este valor adicionado a variação corrente. Os valores utilizados também situam-se entre 0 (zero) e 1;

d_j → diferença máxima que é tolerada entre o valor de aprendizado (t_j) e da saída desejada (y_j).

A fórmula geral utilizada por este último método apresenta-se como segue.

$$\Delta w_{ij}(k+1) = \alpha \delta_j(k) y_j(k) + \mu \Delta w_{ij}(k) \quad (13)$$

b) função de atualização (*Topological_Order*): as unidades que compõem as camadas da rede neural são ordenadas pela sua topologia (camadas de entrada, intermediárias e de saída) e a propagação natural da atividade (informação) é a partir das unidades de entrada para as unidades de saída.

c) função de inicialização (*Randomize_Weights*): inicializa os pesos da rede neural a ser treinada com valores aleatórios que pertencem ao intervalo [-1, 1].

d) função de ativação: função sigmoideal (item 3.2).

e) função de saída (*Out_Identify*): atribui o valor de ativação da unidade em questão, como saída desta.

Para a aplicação de redes neurais artificiais à proteção digital de distância convencionou-se, para as respostas das redes, que saídas < 0,5 referem-se a situações de faltas ocorridas fora da zona de proteção primária do relé e que saídas ≥ 0,5 pertenceriam a zona de atuação do relé.

Para análise das principais características inerentes a redes neurais (generalização, abstração e tolerância a faltas), formulou-se dois conjuntos de testes perfazendo 1050 novos casos de situações de faltas fase(a)-terra aplicados sobre o sistema de transmissão mostrado na figura 8 (item 4.1). Salienta-se que estas situações de faltas diferem das apresentadas à rede quando do seu treinamento. Dessa maneira, as arquiteturas foram treinadas com um conjunto constituído por 400 padrões, e testadas com 1050 diferentes situações caracterizadas pelos parâmetros mostrados na Tabela 2. Como observa-se nessa tabela, as situações de faltas(a)-terra simuladas sobre o sistema diferem, com relação ao conjunto de treinamento, nas distâncias de aplicação da falta, com relação ao barramento P (figura 8), resistência e ângulos de incidência da falta. Observando que, por exemplo, a combinação entre a aplicação da falta a 25 km do barramento P, com uma resistência de falta de 1,0 Ω e ângulo de incidência da falta de 20°, apresenta à rede um parâmetro não conhecido,

devendo a mesma classificar esta situação de falta como pertencendo a zona de proteção primária do relé digital.

Nos próximos itens apresentam-se as arquiteturas das redes neurais analisadas, bem como as suas principais características apresentadas por tabelas, as quais descrevem o desempenho das arquiteturas frente ao conjunto de teste com 600 padrões, sendo que, posteriormente, será comentado o índice de acertos das arquiteturas para o conjunto de teste com 450 padrões.

Com o intuito da análise de uma generalização para todos os tipos de faltas (item 1.1), formulou-se um novo conjunto de treinamento e teste que foram aplicados às arquiteturas de RNAs, cujos resultados serão comentados no item 5.5. Esta etapa do trabalho teve como principal objetivo a verificação da necessidade ou não de uma classificação das faltas antes dos sinais (tensão e corrente trifásicos) serem analisados.

TABELA 2 - Conjuntos de treinamento e testes aplicados às arquiteturas

Número de padrões	TREINAMENTO				TESTES									
	400				450				600					
Distâncias (km)	barramento PT				barramento PT				barramento PT					
	10	40	70	100	25	55	85	115	25	55	85	115		
	120	130	135	138	132	137	141	142	132	137	141	142		
	141	144	e 147		e 144				e 147					
	barramento TQ				barramento TQ				barramento TQ					
	160	170	185	e 205	160 180 e 190				160 180 e 190					
	barramento TR				barramento TR				barramento TR					
	155	165	175	195 e 215	170 200 e 210				170 200 e 210					
Resistências (Ω)	0,1	17,0	50,0		0,1	17,0	50,0		1,0	10,0	30,0			
	80,0 e 100,0				80,0 e 100,0				70,0 e 90,0					
Ângulos de incid. ($^{\circ}$)	0 45 90 e 110				30	45	60	75	105	20	30	40	50	60
					e 135				70 80 e 100					

5.1 Primeira arquitetura analisada

O primeiro caso refere-se aos valores reamostrados a 590 Hz, sendo que cinco valores de cada grandeza, tensões e correntes trifásicas (fases a e b), são tomados para análise das situações de faltas na linha de transmissão, o que corresponde a uma análise de meio-ciclo pós-falta.

Informações resumidas sobre a arquitetura:

a) nº de unidades de entrada: 20;

nº de unidades intermediárias: 2 camadas com 20 unidades cada;

nº de unidades de saída: 1

b) duração do treinamento: 1h 10 min. (método *Backpropagation*) em uma estação de trabalho *Sun-SPARCstation*;

c) nº de ciclos de treinamento: 15100 ciclos, sendo que todos os padrões de treinamento foram apresentados uma única vez a cada ciclo;

d) Soma Quadrática dos Erros (SSE)

$$SSE = \sum_{p=1}^P \sum_{j=1}^J (t_{pj} - y_{pj})^2 \quad (14)$$

$$SSE = 0.00640$$

onde p pertence ao conjunto de padrões utilizados no treinamento; j diz respeito a unidade de saída; t_{pj} é o valor desejado para a saída do neurônio j quando da apresentação do padrão p ; e y_{pj} é a saída atual do neurônio.

Ilustra-se na figura 18 a arquitetura da rede neural, denotando-se suas camadas de entrada, intermediárias e de saída. Como entrada da rede, temos cinco valores amostrados das tensões, e cinco valores amostrados das correntes pós-falta, nas fases a e b; e como saída, a rede deve apresentar valores iguais a 1 ou 0 (zero), representando respectivamente se a falta ocorrida pertence ou não a zona primária do relé.

Já na figura 19, visualiza-se o gráfico de convergência para esta arquitetura apresentada.

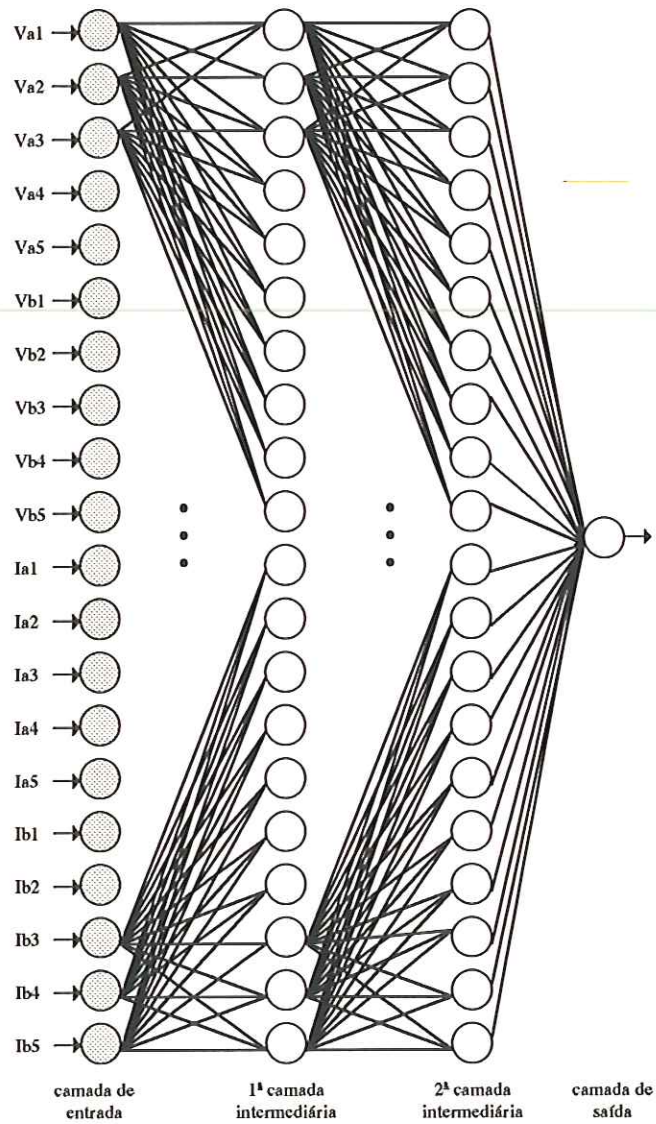


FIGURA 18 - Primeira arquitetura analisada.




FIGURA 19 - Convergência da rede neural analisada para os 15100 ciclos de treinamento.

5.1.1 Resultados

Como apresentado no item 5.1, esta arquitetura possui 20 unidades na camada de entrada, 2 camadas intermediárias com 20 unidades cada e uma unidade de saída caracterizando se a situação de falta ocorrida pertence ou não a zona de proteção primária do relé. Representaremos esta arquitetura nos pontos que seguem pela numeração **20-20-20-1**, indicando respectivamente as unidades das camadas de entrada, intermediárias e de saída. Nos itens 5.2.1, 5.3.1 e 5.4.1 esta forma de representação será mantida, respeitando as características particulares de cada arquitetura.

Relembrando o objetivo prático desta aplicação, proteger 96% do comprimento da linha de transmissão de 150 km (barramento PT, figura 8), definiu-se por convenção que as saídas das redes menores a 0,5 referem-se a situações de faltas ocorridas fora da zona de proteção primária do relé, e que saídas maiores ou iguais a 0,5 pertenceriam a esta zona de atuação do relé. No entanto, a interpretação de valores próximos a 0,5 merece a definição de uma zona de transição, na qual incertezas com respeito as respostas da rede neural implementada são aceitáveis. Diante disto, definiu-se uma zona de transição que compreende o intervalo de 94 a



TABELA 8 - Resultados obtidos pela arquitetura 20-20-20-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 70°.

Dist. da falta em relação ao barramento P (km)	% em relação a LT de 150 km	R _r = 1,0 (Ω)	R _r = 10,0 (Ω)	R _r = 30,0 (Ω)	R _r = 70,0 (Ω)	R _r = 90,0 (Ω)	Resposta correta
25	17,67	0,999	1,000	1,000	1,000	1,000	1,000
55	36,67	1,000	1,000	1,000	1,000	1,000	1,000
85	56,67	1,000	1,000	1,000	1,000	1,000	1,000
115	76,67	1,000	1,000	1,000	1,000	1,000	1,000
132	88,00	1,000	1,000	1,000	1,000	1,000	1,000
137	91,33	1,000	1,000	1,000	1,000	1,000	1,000
141	94,00	1,000	1,000	1,000	1,000	1,000	1,000
142	94,67	1,000	1,000	1,000	1,000	1,000	1,000
147	98,00	0,000	0,000	0,000	0,000	0,000	0,000
160	106,67	0,000	0,000	0,000	0,001	0,100	0,000
170	113,33	0,000	0,000	0,000	0,006	0,026	0,000
180	120,00	*0,999	*1,000	*1,000	*1,000	*1,000	0,000
190	126,67	*0,998	*1,000	*1,000	*0,999	*0,999	0,000
200	133,33	0,000	0,000	0,000	0,000	0,000	0,000
210	140,00	0,000	0,000	0,000	0,000	0,000	0,000

TABELA 9 - Resultados obtidos pela arquitetura 20-20-20-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 80°.

Dist. da falta em relação ao barramento P (km)	% em relação a LT de 150 km	R _r = 1,0 (Ω)	R _r = 10,0 (Ω)	R _r = 30,0 (Ω)	R _r = 70,0 (Ω)	R _r = 90,0 (Ω)	Resposta correta
25	17,67	1,000	1,000	1,000	1,000	1,000	1,000
55	36,67	1,000	1,000	1,000	1,000	1,000	1,000
85	56,67	1,000	1,000	1,000	1,000	1,000	1,000
115	76,67	1,000	1,000	1,000	1,000	1,000	1,000
132	88,00	0,675	1,000	1,000	1,000	1,000	1,000
137	91,33	1,000	1,000	1,000	1,000	1,000	1,000
141	94,00	1,000	1,000	1,000	1,000	1,000	1,000
142	94,67	1,000	1,000	1,000	1,000	1,000	1,000
147	98,00	0,000	0,000	0,000	0,000	0,000	0,000
160	106,67	0,000	0,000	0,000	0,000	0,001	0,000
170	113,33	0,004	0,184	*0,796	*0,508	*0,671	0,000
180	120,00	*0,995	*1,000	*1,000	*1,000	*1,000	0,000
190	126,67	0,000	*0,972	*1,000	*1,000	*1,000	0,000
200	133,33	0,001	0,036	0,002	0,000	0,000	0,000
210	140,00	0,000	0,025	0,177	0,403	*0,677	0,000

TABELA 10 - Resultados obtidos pela arquitetura 20-20-20-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 100°.

Dist. da falta em relação ao barramento P (km)	% em relação a LT de 150 km	$R_f = 1,0$ (Ω)	$R_f = 10,0$ (Ω)	$R_f = 30,0$ (Ω)	$R_f = 70,0$ (Ω)	$R_f = 90,0$ (Ω)	Resposta correta
25	17,67	1,000	1,000	1,000	1,000	1,000	1,000
55	36,67	1,000	1,000	1,000	1,000	1,000	1,000
85	56,67	1,000	1,000	1,000	1,000	1,000	1,000
115	76,67	1,000	1,000	1,000	1,000	1,000	1,000
132	88,00	0,995	1,000	1,000	0,873	*0,000	1,000
137	91,33	1,000	1,000	1,000	1,000	0,985	1,000
141	94,00	1,000	1,000	1,000	1,000	1,000	1,000
142	94,67	1,000	1,000	1,000	1,000	1,000	1,000
147	98,00	0,000	0,000	0,000	0,000	0,000	0,000
160	106,67	0,000	0,000	0,000	0,000	0,000	0,000
170	113,33	0,000	0,000	0,000	0,000	0,000	0,000
180	120,00	0,000	0,000	0,000	0,000	0,000	0,000
190	126,67	0,000	0,168	*0,757	0,040	0,018	0,000
200	133,33	0,000	0,000	0,000	0,000	0,000	0,000
210	140,00	0,000	0,000	0,000	0,000	0,000	0,000

Pelos resultados apontados, observa-se um desempenho não aceitável desta arquitetura, pois a mesma não apresentou coerência na definição da suposta zona de transição, encontrando-se erros nas classificações das situações de faltas de forma aleatória em toda a extensão do sistema elétrico analisado.

5.2 Segunda arquitetura analisada

O segundo caso também refere-se aos valores reamostrados a 590 Hz, pós-falta, sendo que cinco valores de cada grandeza, tensões e correntes trifásicas, são tomados para análise das situações de faltas na linha de transmissão.

Informações resumidas sobre a arquitetura:

a) nº de unidades de entrada: 20;

nº de unidades intermediárias: 1 camada com 15 unidades cada,

1 camada com 10 unidades cada;

nº de unidades de saída: 1;

b) duração do treinamento: 50 min. (*Sun-SPARCstation* - método *Backpropagation*);

- c) nº de ciclos de treinamento: 26500 ciclos;
- d) SSE = 0.00585.

A arquitetura da rede neural, denotando-se suas camadas, é ilustrada pela figura 20. Salienta-se que as mesmas considerações adotadas para a arquitetura do item (5.1), que referem-se às grandezas de entrada e saída, empregam-se também neste caso. No caso da figura 21, observa-se a convergência da rede para os 26500 ciclos de treinamento sendo os resultados, referentes aos testes, comentados posteriormente.




FIGURA 20 - Segunda arquitetura analisada.




FIGURA 21 - Convergência da rede neural analisada para os 26500 ciclos de treinamento.

5.2.1 Resultados

Como apresentado no item 5.2, esta arquitetura apresenta 20 unidades na camada de entrada, duas camadas intermediárias com 15 e 10 unidades cada e uma unidade de saída (20-15-10-1).

Nas tabelas que seguem, Tabelas 11, 12, 13, 14, 15, 16, 17 e 18, encontram-se os resultados obtidos por esta arquitetura, referentes as situações de faltas aplicadas sobre o sistema, correspondendo aos ângulos de incidência da falta de 20, 30, 40, 50, 60, 70, 80 e 100°. Atenta-se ao fato, de que todas as observações e exemplos apresentados no item 5.1 são também aplicáveis para esta e demais arquiteturas a serem discutidas.

Comparando-se esta arquitetura com a anterior (item 5.1.1) observa-se uma sensível melhora na classificação das situações de faltas apresentadas. Com a redução do número de unidades intermediárias, a arquitetura em questão (20-15-10-1) deixou de ser “especialista”, caso em que reconhecia somente os valores dos padrões de teste próximos aos padrões apresentados na fase de treinamento (arquitetura 20-20-20-1), para valorizar a capacidade de generalização, característica esta, inerente à RNAs. Mesmo assim, esta arquitetura ainda deixa a desejar para uma futura aplicação em proteção de linhas de transmissão.

5.3 Terceira arquitetura analisada

Este caso refere-se aos valores amostrados aplicando-se a Transformada Discreta de Fourier de meio-ciclo. Como entrada da rede (figura 22) observam-se os módulos das tensões e correntes trifásicas para meio-ciclo pós-falta, obtidos através da Transformada Discreta, e como saída, a rede deve apresentar valores iguais a 1 ou 0 (zero), representando se a falta ocorrida pertence a zona de proteção primária do relé ou não respectivamente.

Informações resumidas sobre a arquitetura:

a) nº de unidades de entrada: 6;

nº de unidades intermediárias: 1 camada com 6 unidades,
1 camada com 2 unidades;

nº de unidades de saída: 1.

b) duração do treinamento: 5h 40 min. (*Sun-SPARCstation* - método *BackpropMomentum*);

c) nº de ciclos de treinamento: 395000 ciclos;

d) SSE = 0.35776.

Na figura 23 encontra-se o gráfico da convergência para esta arquitetura, considerando-se os seus 395000 ciclos de treinamento.




FIGURA 22 - Terceira arquitetura analisada.




FIGURA 23 - Convergência da rede neural analisada para os 395000 ciclos de treinamento.

TABELA 26 - Resultados obtidos pela arquitetura 6-6-2-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 100°.

Dist. da falta em relação ao barramento P (km)	% em relação a LT de 150 km	$R_r = 1,0$ (Ω)	$R_r = 10,0$ (Ω)	$R_r = 30,0$ (Ω)	$R_r = 70,0$ (Ω)	$R_r = 90,0$ (Ω)	Resposta correta
25	17,67	1,000	1,000	1,000	1,000	1,000	1,000
55	36,67	1,000	1,000	1,000	1,000	1,000	1,000
85	56,67	1,000	1,000	1,000	1,000	1,000	1,000
115	76,67	1,000	1,000	1,000	1,000	1,000	1,000
132	88,00	0,989	1,000	1,000	1,000	1,000	1,000
137	91,33	1,000	1,000	1,000	1,000	0,999	1,000
141	94,00	0,989	1,000	0,998	0,779	0,820	1,000
142	94,67	0,989	1,000	0,657	0,649	0,696	1,000
147	98,00	0,000	0,000	0,000	0,000	0,000	0,000
160	106,67	0,000	0,000	0,000	0,001	0,000	0,000
170	113,33	0,000	0,000	0,000	0,001	0,000	0,000
180	120,00	0,000	0,000	0,000	0,000	0,000	0,000
190	126,67	0,000	0,000	0,000	0,000	0,000	0,000
200	133,33	0,000	0,000	0,000	0,000	0,000	0,000
210	140,00	0,000	0,000	0,000	0,000	0,000	0,000

Para esta arquitetura, observa-se uma melhor definição da suposta zona de transição anteriormente mencionada, bem como, uma redução do número de classificações errôneas das situações de faltas apresentadas. Ressalta-se que esta arquitetura utilizou-se para o treinamento e testes dos módulos das tensões e correntes trifásicos.

5.4 Quarta arquitetura analisada

Como padrões de entrada para esta arquitetura (figura 24), também consideram-se os valores amostrados de tensões e correntes trifásicos trabalhados pela Transformada Discreta de Fourier de meio-ciclo, acrescidos de uma entrada representando o módulo da corrente à terra (I_0).

Com isto, a arquitetura é caracterizada por:

a) nº de unidades de entrada: 7;

nº de unidades intermediárias: 2 camadas com 7 unidades cada;

nº de unidades de saída: 1.

b) duração do treinamento: aproximadamente 5h 30 min. (*Sun-SPARCstation* - método *BackpropMomentum*);

c) nº de ciclos de treinamento: 380000 ciclos;

d) SSE = 0.43114.

O gráfico representativo da convergência da rede neural neste período (380000 ciclos) pode ser observado na figura 25.




FIGURA 24 - Quarta arquitetura analisada.




FIGURA 25 - Convergência da rede neural analisada para os 380000 ciclos de treinamento.

5.4.1 Resultados

Chega-se agora a última arquitetura analisada, sendo que, pelos resultados já apresentados, observa-se uma considerável melhora no desempenho das redes, comparando-se esta última arquitetura (item 5.3) com as anteriores (itens 5.1 e 5.2). A arquitetura agora em questão, conforme o item 5.4, apresenta 7 unidades na camada de entrada, pois inclui o módulo da corrente a terra (I_o), duas camadas intermediárias com 7 unidades cada e uma unidade de saída (7-7-7-1). Nas tabelas (27, 28, 29, 30, 31, 32, 33 e 34) registra-se o desempenho da arquitetura para situações referentes aos ângulos de incidência da falta de 20, 30, 40, 50, 60, 70, 80 e 100°. Chama-se a atenção para o número reduzido de classificações errôneas apresentado pela rede situando-se na região de transição anteriormente definida.

TABELA 27 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 20°.

Dist. da falta em relação ao barramento P (km)	% em relação a LT de 150 km	$R_r = 1,0$ (Ω)	$R_r = 10,0$ (Ω)	$R_r = 30,0$ (Ω)	$R_r = 70,0$ (Ω)	$R_r = 90,0$ (Ω)	Resposta correta
25	17.0	1.000	1.000	1.000	1.000	1.000	1.000
55	36.7	1.000	1.000	1.000	1.000	1.000	1.000
85	56.7	1.000	1.000	1.000	1.000	1.000	1.000
115	76.7	1.000	1.000	1.000	1.000	1.000	1.000
132	88.0	1.000	1.000	1.000	1.000	1.000	1.000
137	91.3	0.998	1.000	0.997	1.000	1.000	1.000
141	94.0	0.970	1.000	0.995	1.000	1.000	1.000
142	94.7	0.895	1.000	0.988	1.000	1.000	1.000
147	98.0	0.000	0.000	0.000	0.000	0.000	0.000
160	106.7	0.003	0.000	0.000	0.001	0.000	0.000
170	113.3	0.000	0.000	0.001	*0.570	0.322	0.000
180	120.0	0.000	0.000	0.001	0.001	0.000	0.000
190	126.7	0.000	0.000	0.001	0.000	0.000	0.000
200	133.3	0.000	0.000	0.001	0.000	0.000	0.000
210	140.0	0.000	0.000	0.001	0.000	0.001	0.000

TABELA 28 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 30°.

Dist. da falta em relação ao barramento P (km)	% em relação a LT de 150 km	$R_r = 1,0$ (Ω)	$R_r = 10,0$ (Ω)	$R_r = 30,0$ (Ω)	$R_r = 70,0$ (Ω)	$R_r = 90,0$ (Ω)	Resposta correta
25	17.0	1.000	1.000	1.000	1.000	1.000	1.000
55	36.7	1.000	1.000	1.000	1.000	1.000	1.000
85	56.7	1.000	1.000	1.000	1.000	1.000	1.000
115	76.7	1.000	1.000	1.000	1.000	1.000	1.000
132	88.0	1.000	1.000	1.000	1.000	1.000	1.000
137	91.3	1.000	1.000	0.998	1.000	1.000	1.000
141	94.0	0.989	1.000	0.995	1.000	1.000	1.000
142	94.7	0.919	1.000	0.987	1.000	1.000	1.000
147	98.0	0.000	0.000	0.000	0.000	0.000	0.000
160	106.7	0.000	0.000	0.000	0.002	0.003	0.000
170	113.3	0.000	0.000	0.000	0.078	0.048	0.000
180	120.0	0.000	0.000	0.001	0.046	0.000	0.000
190	126.7	0.000	0.000	0.001	0.000	0.001	0.000
200	133.3	0.000	0.000	0.001	0.000	0.000	0.000
210	140.0	0.000	0.000	0.001	0.000	0.000	0.000

TABELA 29 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 40°.

Dist. da falta em relação ao barramento P (km)	% em relação a LT de 150 km	$R_r = 1,0$ (Ω)	$R_r = 10,0$ (Ω)	$R_r = 30,0$ (Ω)	$R_r = 70,0$ (Ω)	$R_r = 90,0$ (Ω)	Resposta correta
25	17.0	1.000	1.000	1.000	1.000	1.000	1.000
55	36.7	1.000	1.000	1.000	1.000	1.000	1.000
85	56.7	1.000	1.000	1.000	1.000	1.000	1.000
115	76.7	1.000	1.000	1.000	1.000	1.000	1.000
132	88.0	1.000	0.999	1.000	1.000	1.000	1.000
137	91.3	0.994	1.000	0.985	0.985	1.000	1.000
141	94.0	0.959	1.000	*0.053	*0.039	0.990	1.000
142	94.7	0.930	1.000	*0.022	*0.023	0.988	1.000
147	98.0	0.000	0.000	0.000	0.000	0.000	0.000
160	106.7	0.003	0.000	0.000	0.002	0.000	0.000
170	113.3	0.000	0.000	0.001	0.382	0.001	0.000
180	120.0	0.000	0.000	0.000	0.000	0.000	0.000
190	126.7	0.000	0.000	0.000	0.000	0.000	0.000
200	133.3	0.000	0.000	0.000	0.000	0.000	0.000
210	140.0	0.000	0.000	0.001	0.000	0.000	0.000

TABELA 30 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 50°.

Dist. da falta em relação ao barramento P (km)	% em relação a LT de 150 km	R _r = 1,0 (Ω)	R _r = 10,0 (Ω)	R _r = 30,0 (Ω)	R _r = 70,0 (Ω)	R _r = 90,0 (Ω)	Resposta correta
25	17,67	1,000	1,000	1,000	1,000	1,000	1,000
55	36,67	1,000	1,000	1,000	1,000	1,000	1,000
85	56,67	1,000	1,000	1,000	1,000	1,000	1,000
115	76,67	1,000	1,000	1,000	1,000	1,000	1,000
132	88,00	1,000	1,000	1,000	1,000	1,000	1,000
137	91,33	1,000	1,000	0,993	0,993	0,995	1,000
141	94,00	1,000	1,000	*0,320	*0,434	*0,338	1,000
142	94,67	1,000	1,000	*0,095	*0,139	*0,293	1,000
147	98,00	0,000	0,000	0,000	0,000	0,000	0,000
160	106,67	0,000	0,000	0,000	0,001	0,000	0,000
170	113,33	0,000	0,000	0,001	0,000	0,000	0,000
180	120,00	0,000	0,000	0,000	0,000	0,000	0,000
190	126,67	0,000	0,000	0,001	0,000	0,000	0,000
200	133,33	0,000	0,000	0,001	0,000	0,000	0,000
210	140,00	0,000	0,000	0,001	0,000	0,000	0,000

TABELA 31 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 60°.

Dist. da falta em relação ao barramento P (km)	% em relação a LT de 150 km	R _r = 1,0 (Ω)	R _r = 10,0 (Ω)	R _r = 30,0 (Ω)	R _r = 70,0 (Ω)	R _r = 90,0 (Ω)	Resposta correta
25	17,67	1,000	1,000	1,000	1,000	1,000	1,000
55	36,67	1,000	1,000	1,000	1,000	1,000	1,000
85	56,67	1,000	1,000	1,000	1,000	1,000	1,000
115	76,67	1,000	1,000	1,000	1,000	1,000	1,000
132	88,00	1,000	1,000	1,000	1,000	1,000	1,000
137	91,33	1,000	1,000	0,995	0,998	0,996	1,000
141	94,00	1,000	1,000	0,938	0,987	0,823	1,000
142	94,67	1,000	1,000	0,690	0,969	0,653	1,000
147	98,00	0,000	0,000	0,000	0,000	0,000	0,000
160	106,67	0,000	0,000	0,000	0,001	0,000	0,000
170	113,33	0,000	0,000	0,001	0,000	0,000	0,000
180	120,00	0,000	0,000	0,000	0,000	0,000	0,000
190	126,67	0,000	0,000	0,001	0,000	0,000	0,000
200	133,33	0,000	0,000	0,001	0,000	0,000	0,000
210	140,00	0,000	0,000	0,001	0,000	0,000	0,000

TABELA 32 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 70°.

Dist. da falta em relação ao barramento P (km)	% em relação a LT de 150 km	R _r = 1,0 (Ω)	R _r = 10,0 (Ω)	R _r = 30,0 (Ω)	R _r = 70,0 (Ω)	R _r = 90,0 (Ω)	Resposta correta
25	17,67	1,000	1,000	1,000	1,000	1,000	1,000
55	36,67	1,000	1,000	1,000	1,000	1,000	1,000
85	56,67	1,000	1,000	1,000	1,000	1,000	1,000
115	76,67	1,000	1,000	1,000	1,000	1,000	1,000
132	88,00	1,000	1,000	1,000	0,997	0,999	1,000
137	91,33	1,000	1,000	0,985	0,995	0,980	1,000
141	94,00	1,000	1,000	*0,020	*0,064	*0,057	1,000
142	94,67	1,000	0,976	*0,012	*0,020	*0,032	1,000
147	98,00	0,000	0,000	0,000	0,000	0,000	0,000
160	106,67	0,000	0,000	0,001	0,005	0,000	0,000
170	113,33	0,000	0,000	0,001	0,000	0,000	0,000
180	120,00	0,000	0,000	0,000	0,000	0,000	0,000
190	126,67	0,000	0,000	0,000	0,000	0,000	0,000
200	133,33	0,000	0,000	0,001	0,000	0,000	0,000
210	140,00	0,000	0,000	0,001	0,000	0,000	0,000

TABELA 33 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 80°.

Dist. da falta em relação ao barramento P (km)	% em relação a LT de 150 km	R _r = 1,0 (Ω)	R _r = 10,0 (Ω)	R _r = 30,0 (Ω)	R _r = 70,0 (Ω)	R _r = 90,0 (Ω)	Resposta correta
25	17,67	1,000	1,000	1,000	1,000	1,000	1,000
55	36,67	1,000	1,000	1,000	1,000	1,000	1,000
85	56,67	1,000	1,000	1,000	1,000	1,000	1,000
115	76,67	1,000	1,000	1,000	1,000	1,000	1,000
132	88,00	1,000	1,000	1,000	0,999	1,000	1,000
137	91,33	1,000	1,000	0,994	0,997	0,997	1,000
141	94,00	1,000	1,000	*0,102	*0,379	*0,259	1,000
142	94,67	1,000	0,998	*0,042	*0,126	*0,138	1,000
147	98,00	0,000	0,000	0,000	0,000	0,000	0,000
160	106,67	0,000	0,000	0,000	0,003	0,000	0,000
170	113,33	0,000	0,000	0,001	0,000	0,000	0,000
180	120,00	0,000	0,000	0,000	0,000	0,000	0,000
190	126,67	0,000	0,000	0,001	0,000	0,000	0,000
200	133,33	0,000	0,000	0,001	0,000	0,000	0,000
210	140,00	0,000	0,000	0,001	0,000	0,000	0,000

TABELA 34 - Resultados obtidos pela arquitetura 7-7-7-1 na apresentação dos 600 padrões de teste, para um ângulo de incidência de 100°.

Dist. da falta em relação ao barramento P (km)	% em relação a LT de 150 km	$R_r = 1,0$ (Ω)	$R_r = 10,0$ (Ω)	$R_r = 30,0$ (Ω)	$R_r = 70,0$ (Ω)	$R_r = 90,0$ (Ω)	Resposta correta
25	17,67	1,000	1,000	1,000	1,000	1,000	1,000
55	36,67	1,000	1,000	1,000	1,000	1,000	1,000
85	56,67	1,000	1,000	1,000	1,000	1,000	1,000
115	76,67	1,000	1,000	1,000	1,000	1,000	1,000
132	88,00	1,000	1,000	1,000	0,997	1,000	1,000
137	91,33	1,000	1,000	0,996	0,998	1,000	1,000
141	94,00	1,000	1,000	0,967	0,977	0,992	1,000
142	94,67	1,000	0,998	0,804	0,994	0,978	1,000
147	98,00	0,000	0,000	0,000	0,000	0,000	0,000
160	106,67	0,000	0,000	0,001	0,088	0,000	0,000
170	113,33	0,000	0,000	0,000	0,004	0,000	0,000
180	120,00	0,000	0,000	0,001	0,000	0,000	0,000
190	126,67	0,000	0,000	0,000	0,000	0,000	0,000
200	133,33	0,000	0,000	0,001	0,000	0,000	0,000
210	140,00	0,000	0,000	0,001	0,000	0,000	0,000

5.5 Generalização para todos os tipos de faltas

Somando-se as condições aleatórias das faltas em um sistema elétrico de potência, pode-se encontrar diversos tipos de ocorrência de faltas sobre uma linha de transmissão. Seria desejável através das arquiteturas de RNAs já apresentadas (itens 5.1 a 5.4), que as mesmas pudessem responder corretamente para todos os eventuais tipos de faltas frente aos sinais trifásicos de tensões e correntes a elas apresentados. Com este objetivo, formulou-se um novo conjunto de treinamento consistindo de 1620 padrões assim distribuídos:

- 405 padrões representando situações de atuação ou não atuação do relé de distância digital para faltas fase(a)-terra;
- 405 padrões caracterizando faltas fase(b)-fase(c);
- 405 padrões referentes as situações de faltas fase(b)-fase(c)-terra;
- 405 padrões de situações de faltas trifásicas, envolvendo as fases a, b e c.

Para este conjunto de treinamento observou-se a variação dos mesmos parâmetros já descritos no item 4.3, ou seja:

- a) as distâncias de aplicação das situações de faltas entre os barramentos PT, TQ e TR (km);
- b) as resistências de faltas: 0, 25, 50, 75 e 100 (Ω);
- c) o ângulo de incidência da falta: 0, 45 e 90 ($^\circ$).

Desta maneira acreditava-se que todos os 11 (onze) possíveis tipos de faltas estariam representados sobre o conjunto formulado.

A busca da arquitetura que atendesse ao princípio de operação do relé de distância digital, iniciou-se sobre a arquitetura que apresentou o melhor desempenho quando da aplicação de situações faltosas fase(a)-terra, conforme observa-se no item 5.4. Desta arquitetura, em virtude da difícil convergência observada, variaram-se os seus principais parâmetros, como: número de camadas e unidades intermediárias, taxas de aprendizagem utilizando-se dos algoritmos de treinamento *Std_Backpropagation* e *BackpropMomentum* (item 5) e diferença máxima tolerada entre o valor de aprendizado e da saída desejada.

Para a análise da generalização apresentada pelas arquiteturas, um novo conjunto de teste foi elaborado, apresentando 189 padrões para cada possível tipo de falta, perfazendo um total de 2079 padrões. Este conjunto apresenta diferentes situações de faltas, variando-se do conjunto de treinamento as distâncias de aplicação das situações de faltas entre os barramentos, as resistências (30, 60 e 90 Ω) e ângulos de incidência das faltas (30, 60 e 90 $^\circ$).

Quando da análise do desempenho das arquiteturas encontradas sobre o conjunto de teste, observou-se a má classificação das situações de faltas, não correspondendo as corretas atuações do relé de distância digital. Mesmo para as arquiteturas que apresentaram uma boa convergência (SSE próximo a 0,005) observou-se a não definição da zona de proteção primária do relé, com erros aleatórios sobre toda a extensão do sistema elétrico analisado (Fig. 8).

Com base no desempenho apresentado e nas condições que foram elaborados os conjuntos de treinamentos e testes, conclui-se a necessidade de um classificador do tipo de faltas, similar ao apresentado por DALSTEIN e KULICHE (1995) com um novo processo de treinamento para os demais tipos de faltas possibilitando o emprego das arquiteturas anteriormente apresentadas (itens 5.1 a 5.4).

5.6 Hardware de um relé de distância usando RNAs

Considerando-se os resultados apresentados no item 5.4.1, observa-se que é possível desenvolver um relé de distância digital com todo o seu sistema baseado em Redes Neurais Artificiais.

Na figura 26 apresenta-se um diagrama de blocos de um relé de distância baseado na aplicação de RNAs. Os sinais de entrada são os sinais de tensões e correntes “*on-line*”, obtidos através de transdutores (TP’s e TC’s) que atenuam os mesmos, para um nível computacionalmente aceitável. Os sinais atenuados após a ocorrência da falta, apresentam componentes de frequência fundamental, que são de interesse, e componentes indesejáveis, caracterizados como ruídos (componente CC e harmônicas), que podem ser removidos através de uma filtragem. Desta etapa os sinais são então convertidos à forma digital (discreta) através de um conversor analógico/digital. Pela aplicação apresentada, trabalha-se então com a Transformada Discreta de Fourier para meio ciclo pós-falta, obtendo-se os módulos das tensões e correntes do sinal analisado. Estes valores obtidos serão relacionados aos “pesos” e “*bias*” encontrados após o processo de treinamento “*off-line*” da rede neural artificial. Considerando-se a função de transferência ou função de ativação escolhida para a representação da saída da rede neural artificial, o valor de saída poderá ser considerado diretamente sobre o comando da chave que abrirá ou não os terminais da linha de transmissão quando da ocorrência sobre o sistema elétrico analisado.

Considerando-se o tempo de resposta da rede neural implementada, estima-se que o relé de distância digital poderá operar em um tempo igual ou inferior a 11ms após a ocorrência da falta. Tal tempo refere-se a tomada dos sinais sobre o sistema e da aplicação das técnicas anteriormente descritas.

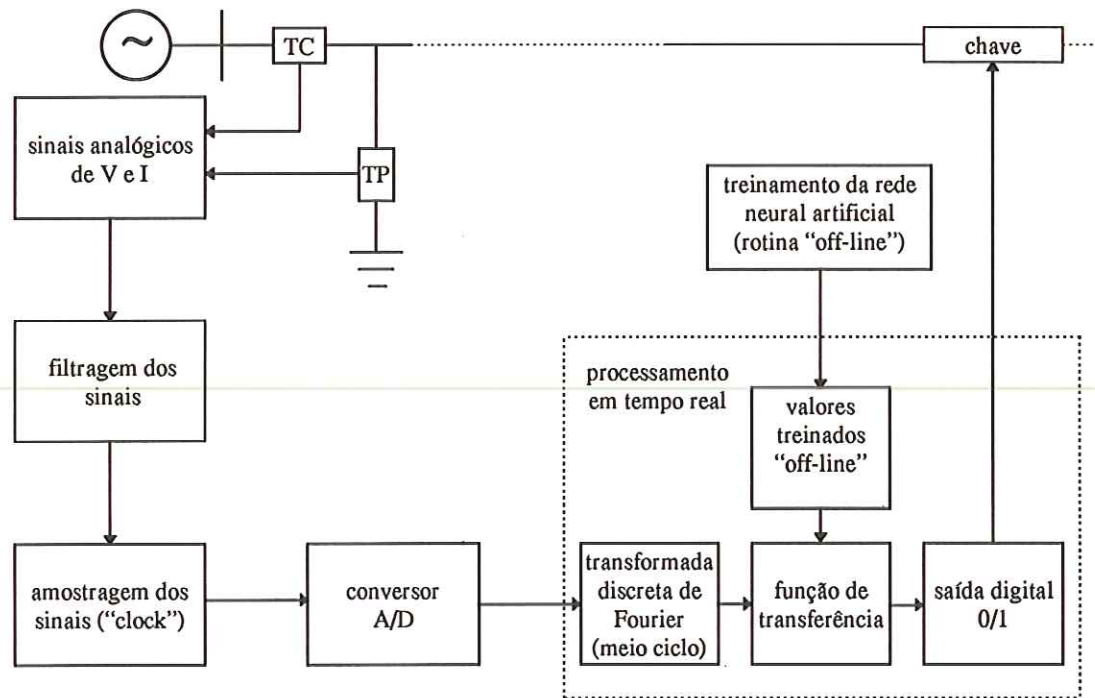


FIGURA 26 - Diagrama de blocos de um relé de distância digital baseado em RNA

CONCLUSÕES

Apesar da utilização neste trabalho de uma configuração específica de um sistema elétrico, o *software* ATP permite a simulação de transitórios eletromagnéticos em redes polifásicas com configurações arbitrárias, por um método que utiliza a matriz de admitância de barras. Acredita-se que com a iniciação obtida sobre este *software* torna-se possível futuras simulações e, conseqüentemente, aplicações em busca de melhores resoluções e entendimento dos possíveis estudos relacionados a sistemas elétricos de potência. Observou-se no decorrer do uso deste *software* que grande parte das tarefas exigidas para a execução do mesmo foram simplificadas pela utilização da interface gráfica DESTRO, que dentre outras vantagens possibilitou o acesso direto a todos os parâmetros relacionados a modelagem da linha de transmissão.

Quanto ao uso do *software* SNNS, a principal limitação encontrada refere-se a impossibilidade de se aplicar os algoritmos de treinamento com parâmetros variáveis utilizando-se apenas da interface do simulador, já que para algumas das arquiteturas analisadas (itens 5.3 e 5.4), aplicaram-se variações na taxa de aprendizagem. Contudo, o *software* SNNS apresenta facilidades na manipulação de arquivos de dados e de resultados, na criação e aprendizagem de redes neurais, possuindo um grande número de algoritmos de treinamento e permitindo acompanhar a evolução do erro de aprendizagem através de sua saída gráfica.

Da aplicação do *software* SNNS observou-se que as arquiteturas de redes neurais artificiais apresentadas nos capítulos anteriores foram capazes de captar, das situações de faltas apresentadas, a correta atuação do relé de proteção digital. Constata-se, no entanto, através dos resultados apresentados no capítulo 5, que houve

diferenças consideráveis quanto ao número de classificações corretas das situações de faltas entre as arquiteturas analisadas.

Para a arquitetura do item 5.1, que apresentava **20** unidades de entrada, duas camadas intermediárias com **20** unidades cada e **1** unidade de saída (representada como arquitetura **20-20-20-1**), considerando-se os 1050 padrões de testes a ela apresentados, aponta-se um erro total de 16,57% sendo que, destes, somente 4,67% situam-se na suposta zona de transição que corresponde a faixa de 94 a 98% do comprimento da linha de transmissão de 150 km, situada entre os barramentos P e T (figura 8).

Já para a arquitetura do item 5.2, com **20** unidades de entrada, duas camadas intermediárias com **15** e **10** unidades cada e **1** unidade de saída (arquitetura **20-15-10-1**), adotando-se os mesmos 1050 padrões de testes observa-se um erro total que corresponde a 6,48% e, deste, somente 1,52% referem-se as classificações errôneas aceitáveis na zona de transição. Salienta-se que para estas arquiteturas (itens 5.1 e 5.2) trabalhou-se com cinco valores amostrados de tensões e correntes trifásicos correspondendo a meio-ciclo pós-falta dos sinais analisados.

Referente a arquitetura do item 5.3, apresentando **6** unidades de entrada, duas camadas intermediárias (uma camada com **6** e a outra com **2** unidades cada) e **1** unidade de saída (arquitetura **6-6-2-1**), constata-se um erro total de 5,14% para os 1050 padrões de testes, onde 4,57% destas classificações errôneas situam-se na suposta zona de transição. Para esta arquitetura adotou-se como padrões de entrada os módulos das tensões e correntes trifásicos calculados através da Transformada Discreta de Fourier de meio-ciclo pós-falta.

Para a última arquitetura analisada (item 5.4), apresentando **7** unidades de entrada, duas camadas intermediárias com **7** unidades cada e **1** unidade de saída (arquitetura **7-7-7-1**), obteve-se os melhores resultados para a aplicação. Esta arquitetura apresentou um erro total de 2,67%, onde 2,57% das classificações errôneas pertencem a suposta zona de transição. Para esta análise utilizou-se os módulos das tensões e correntes trifásicos acrescidos de uma unidade de entrada representando o módulo da corrente a terra. Todos estes valores foram obtidos através da Transformada Discreta de Fourier considerando-se meio ciclo pós-falta dos

sinais analisados. Na tabela 35, observa-se o desempenho das quatro arquiteturas analisadas denotando-se os seus índices de acertos e erros com relação a suposta zona de transição.

TABELA 35 - Desempenho geral das quatro arquiteturas de redes neurais analisadas.

Arquitetura	Nº de padrões de testes	Erros fora da zona de transição (%)	Erros dentro da zona de trans. (%)	Erro total (%)
20-20-20-1	1050	11,90	4,67	16,57
20-15-10-1	1050	4,96	1,52	6,48
6-6-6-1	1050	0,57	4,57	5,14
7-7-7-1	1050	0,10	2,57	2,67

Por esta tabela evidencia-se a melhor arquitetura encontrada, comparando-se o erro total apresentado entre as demais arquiteturas. Ressalta-se que para esta aplicação, não se tomou o número de ciclos de treinamento para a convergência das redes neurais analisadas (itens 5.1 a 5.4) como quesito de avaliação já que, as mesmas foram treinadas com situações de faltas simuladas (*off-line*).

Dos resultados apresentados observa-se também o melhor desempenho das arquiteturas que utilizaram como parâmetros de entrada no treinamento os módulos das tensões e correntes trifásicos adicionados ou não do módulo da corrente à terra. Já para as demais arquiteturas, que utilizaram-se dos cinco valores trifásicos de tensões e correntes referentes a meio ciclo pós-falta, observa-se um desempenho não aceitável, pois estas, como visto nas tabelas apresentadas nos itens 5.1 e 5.2, não apresentaram coerência na definição da suposta zona de transição, encontrando-se erros nas classificações das situações de faltas de forma aleatória em toda a extensão do sistema elétrico analisado.

Ressalta-se que através do uso de RNAs uma extensão da zona primária do relé para 96% do comprimento da linha de transmissão foi alcançado, aumentando-se a confiabilidade do sistema.

Deve ser notado que este estudo toma somente faltas relacionadas com a fase(a)-terra no que diz respeito a localização à frente do relé de proteção digital. Para estender o esquema proposto para situações reais, um classificador do tipo de faltas, similar ao apresentado por DALSTEIN & KULICHE (1995) deve ser usado e um processo similar de treinamento deve ser realizado para os demais tipos de faltas.

Com respeito ao tempo de resposta, estima-se que para as arquiteturas implementadas, o relé poderá operar em um tempo menor do que 11 ms após a ocorrência da falta.

O reconhecimento e interesse demonstrados, tanto pelo aluno como pelo professor orientador, refletem-se em parte nos trabalhos apresentados em dois congressos no segundo semestre de 1997. Um referindo-se ao *XVIII Congresso Íbero Latino-Americano de Métodos Computacionais em Engenharia* (OLESKOVICZ & COURY, 1997a) realizado em Brasília (29-31/10/97) e o outro ao *III Latin-American Congress: Electricity Generation and Transmission* (OLESKOVICZ & COURY, 1997b) realizado em Campos do Jordão (09-13/11/97).

Ressalta-se que a aplicação desta ferramenta, redes neurais artificiais, abre uma nova dimensão para a filosofia de aplicação de relés, o qual merece futuras investigações, podendo resolver muitos problemas relacionados a proteção de distância de linhas de transmissão.

REFERÊNCIAS BIBLIOGRÁFICAS

AGGARWAL, R. K.; JOHNS, A. T.; SONG, Y. H.; DUNN, R. W.; FITTON, D. S. (1994). Neural-network based adaptive single-pole autoreclosure technique for EHV transmission systems. *IEE Proc.-Gener. Transm. Distrib.*, v. 141, n.2, p.-155-160, Mar.

ALTERNATIVE Transients Program Rule Book (1987). Leuven EMTP Center (LEC).

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

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, Dec.

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, Jul.

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, Jul.

CHEN, Wai-Kai. (1986). *Passive and active filters*. New York, John Wiley & Sons.

COURY, D. V.; JORGE, D. C. (1997). Artificial Neural Network Approach to Distance Protection. *IEEE Summer Meeting*, Berlin, Jul.

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

DALSTEIN, T.; FRIEDRICH, T.; KULICHE, B.; SOBAJIC, D. (1996). Multi neural network based fault area estimation for high speed protective relaying. *IEEE Transactions on Power Deelivery*, v.11, n.2, p.740-747, Apr.

DILLON, T. S.; NIEBUR, D. (1996). *Neural networks applications in power systems*. CRL Publishing, London, Inglaterra.

DESTRO - Manual do usuário. (1996). MYRA Engenharia Elétrica e Consultoria Ltda.

HEDMAN, D. E. (1979). *Teoria das linhas de transmissão - I, Curso de engenharia em sistemas elétricos de potência*. Santa Maria. Convênio ELETROBRÁS/UFSM.

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.

JONGEPIER, A. G.; SLUIS, L. (1997). Adaptative distance protection for high speed protective relaying. *IEEE Transactions on Power Delivery*, v.12, n1, Jan.

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, p.84-92, Jul.

KEERTHIPALA, W. W. L.; WAI, C. T.; HUISHENG, W. (1997). Neural network based classifier for power system protection. *Electric Power Systems Research*, v.42, p.109-114.

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

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

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

OLESKOVICZ, M. e COURY, D. V. (1997a). Arquiteturas de redes neurais artificiais aplicadas a proteção de sistemas de transmissão. *XVIII Congresso Íbero Latino-Americano de Métodos Computacionais em Engenharia*, Brasília, Anais v.3, p. 1457-1464.

OLESKOVICZ, M. e COURY, D. V. (1997b). Redes neurais artificiais: uma alternativa para proteção digital a distância. *III Latin-American Congress: Electricity Generation and Transmission*, Campos do Jordão, Anais, p. 430-435.

PHADKE, A. G. and THORP, J. S. (1988). *Computer relaying for power systems*. England, Research Studies Press Ltd.

SIDHU, T. S.; SINGH, H.; SACHDEV, M. S. (1995). Design, implementation and testing of an artificial neural network based fault direction discriminator for

protecting transmission lines. *IEEE Transactions on Power Delivery*, v.10, n.2, p.697-706, Apr.

SNNS (1995). User Manual. *Institute for Parallel and Distributed High Performance Systems (IPVR)*. University of Stuttgart.

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

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

WARRINGTON, A. R. Van C. (1968). *Protective relays. Their theory and practice*. London, Chapman & Hall, v.2, 3 ed.

WARWICK, K.; EKWUE, A.; AGGARWAL, R. (1997). *Artificial intelligence techniques in power systems*. The Institution of Electrical Engineers.

WEEDY, B. M. (1973). *Sistemas elétricos de potência*. São Paulo, Editora Polígono.

YANG, H.; CHANG, W.; HUANG, C. (1994). A new neural networks 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, Jan.

APÊNDICE

FORMULAÇÃO DO ALGORITMO BACKPROPAGATION

O algoritmo *backpropagation* busca determinar um vetor de parâmetros w que minimize o erro quadrático sobre um dado conjunto de treinamento, ou seja, que minimize o erro entre a saída desejada e a saída apresentada pela rede. Para tal, o algoritmo utiliza-se do método do gradiente descendente, o qual requer funções de ativação que variem suavemente.

No que segue, apresenta-se a formulação matemática do algoritmo *backpropagation* conforme HERTZ *et al.* (1991), aproveitando-se de seus exemplos e comentários.

Para ilustração, considera-se uma rede neural de três camadas, como mostrado na figura 1, sendo as unidades de saídas denotadas por O_i , as unidades intermediárias por V_j e as unidades de entradas por ξ_k .

Observa-se na figura as conexões w_{jk} entre as unidades de entradas e unidades intermediárias, bem como conexões W_{ij} entre as unidades intermediárias e unidades de saídas. Salienta-se que o índice i sempre refere-se a uma unidade de saída, j a uma unidade intermediária e k a uma unidade da camada de entrada. Para um conjunto de padrões de entradas, formado por μ padrões distintos, a sua notação será ξ_k^μ indicando que μ padrões estão sendo apresentados para a rede neural. Representa-se o número de unidades de entradas por N e por p o número do padrão de entrada considerado ($\mu = 1, 2, \dots, p$).




FIGURA 1 - Rede neural *feedforward*

Fornecendo-se μ padrões diferentes a rede, a unidade intermediária j terá como entrada:

$$h_j^\mu = \sum_k w_{jk} \xi_k^\mu \quad (1)$$

e produzirá a saída

$$V_j^\mu = g(h_j^\mu) = g\left(\sum_k w_{jk} \xi_k^\mu\right) \quad (2)$$

onde $g(\cdot)$ representa a função de ativação considerada.

A unidade de saída i receberá

$$h_i^\mu = \sum_j W_{ij} V_j^\mu = \sum_j W_{ij} g\left(\sum_k w_{jk} \xi_k^\mu\right) \quad (3)$$

e produzirá a saída final

$$O_i^\mu = g(h_i^\mu) = g\left(\sum_j W_{ij} V_j^\mu\right) = g\left(\sum_k W_{ij} g\left(\sum_l w_{il} \xi_l^\mu\right)\right) \quad (4)$$

Define-se a função erro como sendo

$$E[w] = \frac{1}{2} \sum_{\mu i} [\xi_i^\mu - O_i^\mu]^2 \quad (5)$$

o que torna-se, considerando a equação 4,

$$E[w] = \frac{1}{2} \sum_{\mu i} \left[\xi_i^\mu - g \left(\sum_j W_{ij} g \left(\sum_k w_{jk} \xi_k^\mu \right) \right) \right]^2 \quad (6)$$

a qual é uma função diferenciável e contínua, podendo ser aplicado o método do gradiente descendente. Verificamos nesta equação que o erro varia com a mudança dos pesos e que, para as conexões entre as unidades intermediárias e as unidades de saídas, aplicando-se o método do gradiente descendente, obtém-se:

$$\Delta W_{ij} = -\eta \frac{\delta E}{\delta W_{ij}} = \eta \sum_{\mu} [\xi_i^\mu - O_i^\mu] g' (h_i^\mu) V_j^\mu$$

$$\Delta W_{ij} = \eta \sum_{\mu} \delta_i^\mu V_j^\mu \quad (7)$$

onde:

$$\delta_i^\mu = g' (h_i^\mu) [\xi_i^\mu - O_i^\mu] \quad (8)$$

Para as conexões entre as unidades de entradas e unidades intermediárias, diferenciamos o erro (E) em função de w_{jk} . Usando o método do gradiente descendente obtemos:

$$\Delta w_{jk} = -\eta \frac{\delta E}{\delta w_{jk}} = -\eta \sum_{\mu} \frac{\delta E}{\delta V_j^\mu} \frac{\delta V_j^\mu}{\delta w_{jk}}$$

$$\Delta w_{jk} = \eta \sum_{\mu i} [\xi_i^\mu - O_i^\mu] g' (h_i^j) W_{ij} g' (h_j^\mu) \xi_k^\mu$$

$$\Delta w_{jk} = \eta \sum_{\mu} \delta_i^{\mu} W_{ij} g'(h_j^{\mu}) \xi_k^{\mu}$$

$$\Delta w_{jk} = \eta \sum_{\mu} \delta_j^{\mu} \xi_k^{\mu} \quad (9)$$

com

$$\delta_j^{\mu} = g'(h_j^{\mu}) \sum_i W_{ij} \delta_i^{\mu} \quad (10)$$

Logo, das equações 7 e 8, pode-se calcular a variação nos pesos que chegam nas unidades da camada de saída. Já para as camadas intermediárias, a variação do erro através das equações 9 e 10 reflete o conceito de *retropropagação* do erro das unidades da camada de saída.