

Serviço de Pós-Graduação EESC/USP

EXEMPLAR REVISADO

Data de entrada no Serviço: 13 / 02 / 02

Ass.: *Guilherme*

APLICAÇÃO DE REDES NEURAIAS ARTIFICIAIS NA PROTEÇÃO DE DISTÂNCIA



MÁRIO OLESKOVICZ

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

ORIENTADOR: Prof. Dr. Denis V. Coury

DEDALUS - Acervo - EESC



31100036871

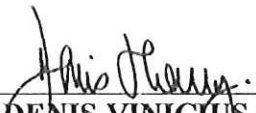
São Carlos

2001

FOLHA DE JULGAMENTO


Candidato: Engenheiro **MARIO OLESKOVICZ**

Tese defendida e julgada em 19-12-2001 perante a Comissão Julgadora:



Prof. Assoc. **DENIS VINICIUS COURY (Orientador)**
(Escola de Engenharia de São Carlos/USP)

APROVADO




Prof. Assoc. **GERALDO ROBERTO MARTINS DA COSTA**
(Escola de Engenharia de São Carlos/USP)

APROVADO



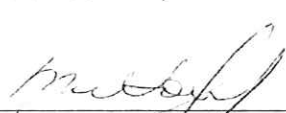
Prof. Assoc. **ANDRÉ CARLOS PONCE DE LEON FERREIRA DE CARVALHO**
(Instituto de Ciências Matemáticas e Computação/USP)

APROVADO



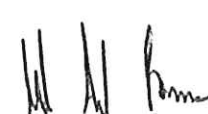
Prof. Dr. **EDUARDO CÉSAR SENGER**
(Escola Politécnica/USP)

APROVADO

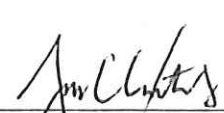


Prof. Tit. **MILTON ITSUO SAMESIMA**
(Universidade Federal de Uberlândia)

APROVADO



Prof. Doutor **MURILO ARAUJO ROMERO**
Coordenador do Programa de Pós-Graduação
em 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 vida..*

*“Para realizar, planeje, pensando grande e fazendo pequeno,
um pouco a cada dia e todos os dias um pouco,
porque são pequenas gotas d’água que fazem todo grande oceano”*

Autor desconhecido

AGRADECIMENTOS

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

Ao Departamento de Engenharia Elétrica, da Escola de Engenharia de São Carlos – Universidade de São Paulo (EESC-USP), pela utilização e fácil acesso aos seus laboratórios.

Ao Departamento de Engenharia Elétrica e Eletrônica da Universidade de Bath (Inglaterra) na pessoa do Prof. Dr. Raj K. Aggarwal, pelas facilidades e orientação proporcionadas quando do desenvolvimento de parte deste trabalho.

Agradecimentos ao auxílio financeiro fornecido por parte da FAPESP - Fundação de Amparo à Pesquisa do Estado de São Paulo durante todo o período de realização deste trabalho, sem o qual o mesmo não seria possível.

Além destes, os agradecimentos à empresa NeuralWare - *Aspen Technology* da qual provém o *software NeuralWorks* empregado neste trabalho.

À Maria Cristina Dias Tavares pela prontidão e auxílio na solução e discussão de problemas relacionadas à aplicação e uso do *software* “Eletromagnetic Transients Program - ATP”.

Ao meu pai, Fabiano, que teve a iniciativa e paciência de ler o trabalho apresentado.

Aos amigos que souberam entender a dificuldade de se realizar um trabalho sério e, ao mesmo tempo, dosar os momentos de descontração conseguindo arrancar sorrisos mesmo nas horas mais difíceis.

A todos os colegas, professores e funcionários do Departamento de Engenharia Elétrica da EESC-USP pela colaboração.

A todos, muito obrigado.

SUMÁRIO

LISTA DE FIGURAS	i
LISTA DE TABELAS	vii
LISTA DE ABREVIATURAS E SIGLAS	xiv
LISTA DE SÍMBOLOS	xvi
RESUMO	xviii
<i>ABSTRACT</i>	xx
<hr/>	
1 INTRODUÇÃO	1
2 O ESTADO DA ARTE	5
2.1 Redes neurais artificiais aplicadas à proteção de linhas de transmissão ...	6
3 REDES NEURAIS ARTIFICIAIS	25
3.1 O neurônio biológico	25
3.2 Modelagem matemática do neurônio biológico	27
3.3 Redes neurais artificiais de múltiplas camadas	29
3.4 Regras de aprendizagem	31
3.4.1 Algoritmo <i>BackPropagation</i>	33
3.5 Alguns apontamentos sobre RBF	36
3.5.1 Arquitetura de uma rede RBF	38
3.5.2 Treinamento de uma rede RBF.....	39
4 VISÃO GERAL DO TRABALHO	42
5 O SISTEMA ELÉTRICO ANALISADO	49
5.1 Configuração do sistema de potência	49
5.2 Modelagem da linha de transmissão	51
5.2.1 Parâmetros do sistema elétrico	51
5.2.2 Rotina <i>Line Constant</i> e arquivo de entrada para o <i>software</i> ATP ..	54

5.3 Filtro digital passa-baixa Butterworth	56
5.4 Conversão analógica/digital dos valores amostrados	58
6 DETECÇÃO DE FALTAS EM LINHAS DE TRANSMISSÃO	
UTILIZANDO RNAS	60
6.1 Simulações sobre o sistema analisado	62
6.2 A utilização do software NeuralWorks para a detecção de faltas	67
6.3 Resultados observados pela aplicação do módulo de detecção implementado pela RNA1	71
7 CLASSIFICAÇÃO DE FALTAS EM LINHAS DE TRANSMISSÃO	
UTILIZANDO RNAS	76
7.1 Simulações sobre o sistema analisado	77
7.2 A utilização do software NeuralWorks para a classificação de faltas	81
7.3 Observações gerais	89
8 LOCALIZAÇÃO DE FALTAS EM LINHAS DE TRANSMISSÃO	
UTILIZANDO RNAS	91
8.1 A localização de faltas fase - terra	95
8.1.1 A arquitetura escolhida	96
8.1.2 Ordem dos dados apresentados à RNA3 em cada janela de dados, tanto para o processo de treinamento quanto para o de teste	99
8.1.3 Resultados observados	100
8.2 A localização de faltas fase – fase sem e com conexão a terra	102
8.2.1 A arquitetura escolhida	102
8.2.2 Ordem dos dados apresentados à RNA4 em cada janela de dados	103
8.2.3 Resultados observados	104
8.3 A localização de faltas trifásicas.....	107
8.3.1 A arquitetura escolhida	109
8.3.2 Resultados observados	110

9 A LÓGICA COMPUTACIONAL IMPLEMENTADA	111
9.1 Os sinais de entrada e de saída do módulo de detecção	112
9.2 A conexão com o módulo de classificação	116
9.3 O módulo de localização e suas considerações.....	118
10 OS RESULTADOS OBSERVADOS PELA IMPLEMENTAÇÃO DO ALGORITMO COMPUTACIONAL	121
10.1 Resultados para as situações de faltas fase - terra	124
10.1.1 Faltas envolvendo a fase “A” com conexão a terra	124
10.2 Resultados para as situações de faltas envolvendo duas fases	129
10.2.1 Faltas envolvendo as fases “A” e “B”	129
10.3 Resultados para as situações de faltas envolvendo duas fases com conexão a terra	133
10.3.1 Faltas envolvendo as fases “A” e “B” com conexão a terra	133
10.4 Resultados para as situações de faltas envolvendo as três fases	137
10.5 Situações aplicadas considerando um alto valor para a resistência de falta	140
10.6 Variações no fluxo de energia	145
10.7 Resultados finais do algoritmo computacional proposto	147
10.7.1 Resultados considerando-se o mesmo fluxo de energia da fase de treinamento	147
10.7.2 Resultados considerando-se variações de $\pm 2^\circ$ no fluxo de energia	151
10.7.3 Comentários gerais.....	162
10.7.4 O estudo do esquema proposto para linhas com circuito duplo ..	164
10.7.5 Evolução de faltas envolvendo duas fases sem conexão a terra para faltas envolvendo duas fases com conexão a terra.....	166
11 O EMPREGO DE REDES DE FUNÇÕES BASE RADIAIS NA LOCALIZAÇÃO DA FALTA	168
11.1 RBF aplicada à localização de faltas fase - terra	169

11.2 Resultados observados pela aplicação de RBF	173
11.3 Observações gerais	177
12 CONCLUSÕES	179
ANEXO – RESULTADOS COMPLEMENTARES	184
Faltas envolvendo a fase “B” com conexão a terra.....	184
Faltas envolvendo a fase “C” com conexão a terra.....	188
Faltas envolvendo as fases “A” e “C”.....	192
Faltas envolvendo as fases “B” e “C”.....	196
Faltas envolvendo as fases “A” e “C” com conexão a terra	200
Faltas envolvendo as fases “B” e “C” com conexão a terra.....	204
REFERÊNCIAS BIBLIOGRÁFICAS	207
APÊNCICE - TRABALHOS PUBLICADOS E/OU EM AVALIAÇÃO	

LISTA DE FIGURAS

FIGURA 1 – Neurônios do sistema nervoso central dos vertebrados	26
FIGURA 2 – Diagrama esquemático de um neurônio artificial	27
FIGURA 3 – Uma arquitetura <i>feedforward</i>	30
FIGURA 4 – Obtenção e análise dos dados	45
FIGURA 5 – Modelo alternativo para a proteção aplicando-se RNAs	47
FIGURA 6 – Sistema elétrico analisado	49
FIGURA 7 – Situações de faltas sobre o sistema	50
FIGURA 8 – Estrutura da linha de transmissão (440 kV) definindo seus principais parâmetros	52
FIGURA 9 – Transposição de uma linha de transmissão	53
FIGURA 10 – Representação de um trecho de uma linha de transmissão por parâmetros distribuídos	53
FIGURA 11 – Arquivo de entrada para a rotina <i>Line Constant</i> descrevendo a topologia da linha de transmissão analisada	55
FIGURA 12 – Circuito básico de um transformador de potencial capacitivo	56
FIGURA 13 – Característica do filtro ideal passa-baixa onde b_p representa a banda ou faixa de passagem	57

FIGURA 14 – Característica das perdas de um filtro passa-baixa ideal.....	58
FIGURA 15 – Característica das perdas de um filtro passa-baixa real	58
FIGURA 16 – As três janelas de dados empregadas para o módulo de detecção.....	65
FIGURA 17 – Janelas de dados onde F representa o instante em que a falta foi aplicada	66
FIGURA 18 – Arquitetura da RNA1 implementada para o módulo de detecção.....	69
FIGURA 19 – As cinco janelas de dados empregadas para o módulo de classificação	79
FIGURA 20 – Janelas de dados utilizadas para o módulo de classificação	80
FIGURA 21 – Arquitetura da RNA2 implementada para o módulo de classificação	82
FIGURA 22 – Situação de falta aplicada à fase A - terra	85
FIGURA 23 – Situação de falta aplicada às fases BC.....	86
FIGURA 24 – Situação de falta aplicada às fases AC - terra.....	87
FIGURA 25 – Situação de falta aplicada às fases ABC.....	88

FIGURA 26 – Impedância medida pelo relé devido as considerações elétricas.....	93
FIGURA 27 – Primeira janela de dados acusando a ocorrência da situação faltosa.....	114
FIGURA 28 – Segunda janela de dados acusando a ocorrência da situação faltosa.....	115
<hr/>	
FIGURA 29 – Com a detecção da falta em até 3 ms a terceira janela de dados poderá ser apresentada ao módulo de classificação	117
FIGURA 30 – Ativação do módulo de localização dispondo-se de 9 ms após a ocorrência da falta	120
FIGURA 31 – Resultados do <u>módulo de detecção</u> para faltas envolvendo a fase A com conexão a terra.....	126
FIGURA 32 – Resultados do <u>módulo de classificação</u> para faltas envolvendo a fase A com conexão a terra.....	127
FIGURA 33 – Resultados do <u>módulo de localização</u> para faltas envolvendo a fase A com conexão a terra.....	128
FIGURA 34 – Resultados do <u>módulo de detecção</u> para faltas envolvendo as fases A e B sem conexão a terra	130
FIGURA 35 – Resultados do <u>módulo de classificação</u> para faltas envolvendo as fases A e B sem conexão a terra	131
FIGURA 36 – Resultados do <u>módulo de localização</u> para faltas envolvendo	

as fases A e B sem conexão a terra	132
FIGURA 37 – Resultados do <u>módulo de detecção</u> para faltas envolvendo as fases A e B com conexão a terra	134
FIGURA 38 – Resultados do <u>módulo de classificação</u> para faltas envolvendo as fases A e B com conexão a terra.....	135
FIGURA 39 – Resultados do <u>módulo de localização</u> para faltas envolvendo as fases A e B com conexão a terra.....	136
FIGURA 40 – Resultados do <u>módulo de detecção</u> para faltas envolvendo as fases A, B e C	137
FIGURA 41 – Resultados do <u>módulo de classificação</u> para faltas envolvendo as fases A, B e C	138
FIGURA 42 – Resultados do <u>módulo de localização</u> para faltas envolvendo as fases A, B e C	139
FIGURA 43 – Resultados do <u>módulo de detecção</u> para faltas envolvendo as fases A, B, C, AB, AC e BC, todas com conexão a terra (alta impedância)	143
FIGURA 44 – Resultados do <u>módulo de classificação</u> para faltas envolvendo as fases A, B, C, AB, AC e BC, todas com conexão a terra (alta impedância)	143
FIGURA 45 – Resultados do <u>módulo de localização</u> para faltas envolvendo as fases A, B, C, AB, AC e BC, todas com conexão a terra (alta impedância)	144

FIGURA 46 – Quadro geral dos erros considerando-se altos valores de resistência de falta.....	144
FIGURA 47 – Tensão e corrente superpostas geradas por uma condição de falta: a) sistema atual sob condição de falta; b) a rede em regime permanente (pré-falta) e c) a rede superposta	146
FIGURA 48 – Resultados do <u>módulo de detecção</u> para faltas envolvendo a fase B com conexão a terra	185
FIGURA 49 – Resultados do <u>módulo de classificação</u> para faltas envolvendo a fase B com conexão a terra	186
FIGURA 50 – Resultados do <u>módulo de localização</u> para faltas envolvendo a fase B com conexão a terra	187
FIGURA 51 – Resultados do <u>módulo de detecção</u> para faltas envolvendo a fase C com conexão a terra	189
FIGURA 52 – Resultados do <u>módulo de classificação</u> para faltas envolvendo a fase C com conexão a terra	190
FIGURA 53 – Resultados do <u>módulo de localização</u> para faltas envolvendo a fase C com conexão a terra	191
FIGURA 54 – Resultados do <u>módulo de detecção</u> para faltas envolvendo as fases A e C sem conexão a terra	193
FIGURA 55 – Resultados do <u>módulo de classificação</u> para faltas envolvendo as fases A e C sem conexão a terra	194

FIGURA 56 – Resultados do <u>módulo de localização</u> para faltas envolvendo as fases A e C sem conexão a terra	195
FIGURA 57 – Resultados do <u>módulo de detecção</u> para faltas envolvendo as fases B e C sem conexão a terra	197
FIGURA 58 – Resultados do <u>módulo de classificação</u> para faltas envolvendo as fases B e C sem conexão a terra	198
<hr/>	
FIGURA 59 – Resultados do <u>módulo de localização</u> para faltas envolvendo as fases B e C sem conexão a terra	199
FIGURA 60 – Resultados do <u>módulo de detecção</u> para faltas envolvendo as fases A e C com conexão a terra	201
FIGURA 61 – Resultados do <u>módulo de classificação</u> para faltas envolvendo as fases A e C com conexão a terra.....	202
FIGURA 62 – Resultados do <u>módulo de localização</u> para faltas envolvendo as fases A e C com conexão a terra.....	203
FIGURA 63 – Resultados do <u>módulo de detecção</u> para faltas envolvendo as fases B e C com conexão a terra	204
FIGURA 64 – Resultados do <u>módulo de classificação</u> para faltas envolvendo as fases B e C com conexão a terra.....	205
FIGURA 65 – Resultados do <u>módulo de localização</u> para faltas envolvendo as fases B e C com conexão a terra.....	206

LISTA DE TABELAS

TABELA 1 – Conjunto de dados e testes utilizados para a detecção.....	63
TABELA 2 – Respostas esperadas por parte da RNA1	67
TABELA 3 – Resposta da RNA1 frente ao conjunto de teste	71
TABELA 4 – Análise global das respostas apresentadas pela RNA1 frente ao conjunto de teste	72
TABELA 5 – Análise global das respostas apresentadas pela RNA1 analisando-se as situações de faltas em sentido reverso ao barramento E	73
TABELA 6 – Análise global das respostas apresentadas pela RNA1 analisando-se as situações de faltas em sentido à frente ao barramento E.....	73
TABELA 7 – Valores das respostas apresentadas e esperadas por parte da RNA1 frente a algumas situações de faltas aplicadas em sentido reverso ao barramento E.....	74
TABELA 8 – Valores das respostas apresentadas e esperadas por parte da RNA1 frente a algumas situações de faltas aplicadas em sentido à frente ao barramento E	75
TABELA 9 – Conjunto de dados e testes utilizados para a o módulo de classificação	77
TABELA 10 – Respostas esperadas por parte da RNA2.....	80

TABELA 11 – Resposta da RNA2 frente ao conjunto de teste	83
TABELA 12 – Análise global das respostas apresentadas pela RNA2 frente ao conjunto de teste	84
TABELA 13 – Respostas esperadas por parte da RNA para a localização	95
TABELA 14 – Conjunto de dados e testes utilizados para a localização (RNA3)	97
TABELA 15 – Análise das respostas apresentadas pela RNA3 para faltas que envolvem a fase “A” com conexão a terra	100
TABELA 16 – Análise das respostas apresentadas pela RNA3 para faltas que envolvem a fase “B” com conexão a terra	101
TABELA 17 – Análise das respostas apresentadas pela RNA3 para faltas que envolvem a fase “C” com conexão a terra	101
TABELA 18 – Conjunto de dados utilizados para representar as situações de faltas entre duas fases com e sem conexão a terra (RNA4).	103
TABELA 19 – Análise das respostas apresentadas pela RNA4 para faltas que envolvem as fases “AB”	105
TABELA 20 – Análise das respostas apresentadas pela RNA4 para faltas que envolvem as fases “AC”	105
TABELA 21 – Análise das respostas apresentadas pela RNA4 para faltas que envolvem as fases “BC”	106

TABELA 22 – Análise das respostas apresentadas pela RNA4 para faltas que envolvem as fases “AB” com conexão a terra.....	106
TABELA 23 – Análise das respostas apresentadas pela RNA4 para faltas que envolvem as fases “AC” com conexão a terra.....	107
TABELA 24 – Análise das respostas apresentadas pela RNA4 para faltas que envolvem as fases “BC” com conexão a terra.....	107
<hr/>	
TABELA 25 – Conjunto de dados utilizado para representar as situações de faltas trifásicas (RNA5)	109
TABELA 26 – Análise das respostas apresentadas pela RNA5 para faltas que envolvem as fases “ABC”	110
TABELA 27 – Respostas esperadas por parte das RNAs.....	113
TABELA 28 – Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados.....	123
TABELA 29 – Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados para faltas envolvendo uma fase com conexão a terra	149
TABELA 30 – Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados para faltas envolvendo duas fases com e sem conexão a terra.	150
TABELA 31 – Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados	

para faltas envolvendo as três fases..... 151

TABELA 32 – Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados para faltas envolvendo a fase “A” com conexão a terra e com uma variação de + 2° no fluxo de energia adotado 153

TABELA 33 – Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados para faltas envolvendo a fase “B” com conexão a terra e com uma variação de - 2° no fluxo de energia adotado 154

TABELA 34 – Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados para faltas envolvendo a fase “C” com conexão a terra e com uma variação de + 2° no fluxo de energia adotado 154

TABELA 35 – Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados para faltas envolvendo as fases “AB” com conexão a terra e com uma variação de - 2° no fluxo de energia adotado 156

TABELA 36 – Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados para faltas envolvendo as fases “AC” com conexão a terra e com uma variação de + 2° no fluxo de energia adotado 157

TABELA 37 – Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados para faltas envolvendo as fases “BC” com conexão a terra e com uma variação de - 2° no fluxo de energia adotado 158

TABELA 38 – Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados para faltas envolvendo as fases “AB” sem conexão a terra e com uma variação de + 2° no fluxo de energia adotado.....	159
TABELA 39 – Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados para faltas envolvendo as fases “AC” sem conexão a terra e com uma variação de - 2° no fluxo de energia adotado.....	160
TABELA 40 – Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados para faltas envolvendo as fases “BC” sem conexão a terra e com uma variação de + 2° no fluxo de energia adotado.....	161
TABELA 41 – Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados para faltas envolvendo as três fases e com uma variação de - 2° no fluxo de energia adotado	162
TABELA 42 – Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados considerando-se o mesmo fluxo de energia adotado quando da fase de treinamento das RNAs	163
TABELA 43 – Saídas desejadas e esperadas para as cinco janelas de dados analisadas, considerando-se uma falta envolvendo a fase “A” com conexão a terra, aplicada a 90 km do barramento D, com uma resistência de falta de 30 Ω e um ângulo de incidência de 0°	174

- TABELA 44 – Saídas desejadas e esperadas para as cinco janelas de dados analisadas, considerando-se uma falta envolvendo a fase “A” com conexão a terra, aplicada a 210 km do barramento D, com uma resistência de falta de 60 Ω e um ângulo de incidência de 45° 175
- TABELA 45 – Saídas desejadas e esperadas para as cinco janelas de dados analisadas, considerando-se uma falta envolvendo a fase “A” com conexão a terra, aplicada a 240 km do barramento D, com uma resistência de falta de 90 Ω e um ângulo de incidência de 90° 175
- TABELA 46 – Saídas desejadas e esperadas para as cinco janelas de dados analisadas, considerando-se uma falta envolvendo a fase “A” com conexão a terra, aplicada a 260 km do barramento D, com uma resistência de falta de 90 Ω e um ângulo de incidência de 90° 175
- TABELA 47 – Saídas desejadas e esperadas para as cinco janelas de dados analisadas, considerando-se uma falta envolvendo a fase “A” com conexão a terra, aplicada a 300 km do barramento D, com uma resistência de falta de 30 Ω e um ângulo de incidência de 0° 176
- TABELA 48 – Saídas desejadas e esperadas para as cinco janelas de dados analisadas, considerando-se uma falta envolvendo a fase “A” com conexão a terra, aplicada a 220 km do barramento D, com uma resistência de falta de 60 Ω e um ângulo de incidência de 45° (falta situada sobre a primeira zona de transição) 176

TABELA 49 – Saídas desejadas e esperadas para as cinco janelas de dados analisadas, considerando-se uma falta envolvendo a fase “A” com conexão a terra, aplicada a 278 km do barramento D, com uma resistência de falta de 90 Ω e um ângulo de incidência de 90° (<u>falta situada sobre a segunda zona de transição</u>)	176
TABELA 50 – Valores comparativos entre as redes MLP e RBF, para conjuntos de testes aproximados	179

LISTA DE ABREVIATURAS E SIGLAS

ATP	- Alternative Transients Program
ACSR	- Aluminium Cable Steel Reinforced
BP	- Backpropagation
CC	- Corrente Contínua
CESP	- Companhia Energética de São Paulo
CP	- Counter Propagation
CPN	- Counter Propagation Networks
EESC	- Escola de Engenharia de São Carlos
EMTDC	- Eletromagnetic Transients Simulation Program
EMTP	- Eletromagnetic Transients Program
FAPESP	- Fundação de Amparo à Pesquisa do Estado de São Paulo
FM	- Feature Map
IELTS	- International English Testing System
LVQ	- Learning Vector Quantization
MLP	- Multi Layer Perceptron
MOV	- Metal Oxide Varistor
RBF	- Radial Basis Function
RNA	- Rede Neural Artificial
RNAs	- Redes Neurais Artificiais
RNA1	- Rede Neural Artificial 1
RNA2	- Rede Neural Artificial 2
RNA3	- Rede Neural Artificial 3
RNA4	- Rede Neural Artificial 4
RNA5	- Rede Neural Artificial 5
RMS	- Root Mean Square
SOM	- Self-Organization Mapping
TCs	- Transformadores de Corrente
TDNN	- Time-Delay Neural Network
TOEFL	- Test of English as a Foreign Language

TPC - Transformador de Potencial Capacitivo
TPs - Transformadores de Potencial
USP - Universidade de São Paulo

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 sigmoidal considerada para a unidade j em um determinado instante k
 $S'_j(k)$ - derivada de primeira ordem da função de ativação sigmoidal 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_{11} - impedância da linha de transmissão do sistema considerado
 Z_{12} - 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
 $\hat{y}_j(k)$ - 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

RESUMO

OLESKOVICZ, M. *Aplicação de redes neurais artificiais na proteção de distância*. São Carlos, 2001. 215p. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo.

O presente trabalho visa apresentar um modelo alternativo e completo de proteção para linhas de transmissão utilizando-se de Redes Neurais Artificiais (RNAs). Pela aplicação, busca-se um modelo que venha a realizar a **detecção** do defeito, a **classificação** quanto ao tipo de falta ocorrido e a **localização** da mesma no que diz respeito à verificação das zonas de proteção em um menor tempo se comparado com as propostas convencionais.

As grandezas analisadas referem-se a valores amostrados de tensões e correntes do sistema elétrico, cujos valores foram obtidos através de simulações computacionais utilizando o *software Alternative Transients Program (ATP)*. O desenvolvimento do trabalho está dividido em módulos, que dizem respeito à implementação das arquiteturas para a **detecção**, **classificação** e a **localização** da falta. Ressalta-se que o objetivo de treinar os módulos foi o de se obter arquiteturas de RNAs fixas (*software NeuralWorks*), as quais representam todo o conhecimento armazenado do sistema de proteção. Com estas arquiteturas fixas, através de um algoritmo computacional apropriado e implementado na linguagem de programação "C", pode-se então obter as respostas sobre todas as prováveis condições de operação do sistema de transmissão. Os resultados alcançados pela aplicação deste modelo alternativo de proteção ilustram que o desempenho global das arquiteturas de RNAs é altamente satisfatório e condizente para uma possível aplicação prática. Deve ser enfatizado que o esquema proposto se mostra altamente preciso, com alta velocidade de atuação, apresentando características bastante desejáveis para um sistema de proteção moderno.

Deve ser mencionado que esta pesquisa foi desenvolvida em cooperação com o Departamento de Engenharia Elétrica e Eletrônica da Universidade de Bath/Inglaterra.

Palavras chave: Proteção de distância, sistemas de potência, redes neurais artificiais, detecção, classificação, localização da falta.

ABSTRACT

OLESKOVICZ, M. *Artificial neural networks applied to distance protection*. São Carlos, 2001. 215p. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo.

This work presents an alternative Artificial Neural Network (ANN) approach to simulate a complete scheme for a transmission line protection. From this application, we intend to obtain a complete model to **detect** the fault, to **classify** the fault type occurred and to **locate** it on the protection zones as quickly as possible when compared to conventional approaches.

The voltage and current sampled values from the electric power system are analyzed and they are generated by computational simulation using the *Alternative Transients Program* (ATP) software. In order to perform the simulation, the study was subdivided into different neural network modules for fault **detection**, fault **classification** as well as fault **location**. It should be pointed out that the modules training objective was to obtain the appropriate fixed ANNs architectures (software NeuralWorks), which represent all stored knowledge from the protection system operation. With these fixed architectures, by an appropriate computational algorithm implemented in a C code language, all expected correct responses described above for different operation conditions can be obtained. The results obtained by application of this alternative protection approach, show that the global performance of the ANNs architecture was highly satisfactory and suitable to a practical application. It should be emphasized that the scheme proposed is highly precise with high speed of response, showing desirable characteristics to a modern protection system.

It should be mentioned that this research was developed in cooperation with the Department of Electronic and Electrical Engineering – University of Bath/England.

Key words: Distance Protection, Power Systems, Artificial Neural Networks, Detection, Classification and Fault Location.

1 INTRODUÇÃO

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.

Dentre os componentes de um sistema elétrico de potência, a linha de transmissão é o elemento mais susceptível a faltas. Esta fica exposta a uma grande margem de riscos como intempéries, descargas atmosféricas e outros.

Conforme HEDMAN (1979), das principais causas de faltas em linhas de transmissão, destacam-se as descargas atmosféricas. O seu efeito é de iniciar um arco tanto entre fases (o mais comum), quanto entre mais fases à terra, ou ainda através de uma porção aterrada da estrutura da linha. Estas situações são também as principais fontes de riscos e perigos para todos os outros equipamentos elétricos. A faixa de valores das possíveis correntes de faltas, o efeito da carga sobre o sistema, a questão da direcionalidade e o impacto sobre a configuração do sistema, são apenas alguns dos quesitos a serem considerados nos problemas relacionados às linhas de transmissão. Desde que as linhas fisicamente representam a conexão com os demais componentes adjacentes e equipamentos do sistema, a proteção provida às mesmas deve ser compatível e analisada como um todo. Com esta ideologia, faz-se necessário uma correta e precisa coordenação entre os diversos sistemas de proteção, considerando-se os tempos individuais de operação e características particulares a cada modelo empregado.

Considerando-se os diferentes tipos de faltas sobre linhas de transmissão, as mesmas 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.

A prática demonstra, de acordo com STEVENSON (1986), 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 as três fases, em torno de 5%. Para a proteção de linhas de transmissão frente às possíveis situações de faltas, diferentes tipos de relés convencionais são utilizados. Dentre eles, os mais 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. Sobre estes valores, o dispositivo 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. Com a crescente disponibilidade dos circuitos integrados e uso de microprocessadores, observou-se a possibilidade da aplicação do processador digital para desempenhar as funções atribuídas ao modelo convencional. Dentre as vantagens do uso do relé digital, apontam-se a diminuição em custo e a flexibilidade alcançada através do uso de um sistema digital. Além destas, constatou-se, pelo emprego do dispositivo digital, a possibilidade de uma auto-checagem, ou seja, um auto-diagnóstico a fim de detectar possíveis falhas nos componentes do relé tão logo aconteçam (PHADKE & THORP, 1988).

Das técnicas empregadas para a proteção de linhas, podemos recorrer a diversas fontes na literatura, como por exemplo, BLACKBURN (1997), HOROWITZ & PHADKE (1996) e ZIEGLER (1999) e citarmos a proteção por sobrecorrente com atuação instantânea e não direcional, por sobrecorrente com características de tempo-inverso e não direcional, por sobrecorrente instantâneo e direcional, por sobrecorrente de tempo-inverso e direcional, por balanço de corrente, de distância direcional (instantâneo e/ou de tempo-inverso) e por fio piloto com canais de comunicação entre os terminais. Todas estas técnicas podem ser utilizadas individualmente ou em várias combinações para a proteção de linhas.

A proteção digital de distância é usualmente empregada e definida sobre uma característica fixa de atuação do relé. As incertezas do alcance de sua zona de

proteção primária são de 5%, sendo usual a definição de sua zona de proteção como sendo 80 a 90% do comprimento da linha de transmissão a ser protegida (STANLEY & PHADKE, 1992). Deve estar claro que somente a zona de proteção primária não protege a totalidade da linha de transmissão. Consequentemente, 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.

Diante das evidências apresentadas em artigos técnicos nacionais e internacionais, aplicações bem sucedidas em áreas de engenharia, usando-se Redes Neurais Artificiais (RNAs), têm demonstrado que esta pode ser empregada como um método alternativo para se resolver problemas convencionais com precisão e eficiência. As referências (DILLON & NIEBUR, 1996) e (WARWICK et al., 1997) ilustram aplicações de RNAs em problemas relacionados a Sistemas Elétricos de Potência.

A proposta, que a seguir será apresentada, traz como objetivo a implementação de um sistema de proteção aplicando-se a teoria de RNAs. Através das características inerentes às RNAs, propõe-se por uma implementação, o emprego desta ferramenta que, considerando as possíveis variações operacionais do sistema, proporcionará uma devida proteção para linhas de transmissão. As grandezas a serem analisadas na implementação referem-se a valores amostrados de tensão e corrente do sistema elétrico. O banco de dados, gerado através de simulações, descreverá situações em que o sistema de proteção deverá ou não atuar. Desta maneira, as arquiteturas de RNAs a serem implementadas terão como função capturar ou abstrair o conhecimento da atuação do sistema de proteção, para posteriormente atuar com melhores resultados frente às situações de operações que porventura venham a ocorrer. O que se espera através do emprego de RNAs é a construção de um modelo completo de proteção para linhas de transmissão (**detecção, classificação e localização da falta** com a consequente atuação do sistema de proteção), atentando ao princípio de funcionamento do relé digital de distância e imprimindo ao mesmo uma característica adaptativa no que diz respeito às mudanças operacionais.

A seguir, serão abordados alguns itens necessários para um melhor esclarecimento do trabalho. Para o capítulo 2, reserva-se uma revisão dos trabalhos publicados, relacionados à aplicação de RNAs à proteção de sistemas elétricos de

potência. No capítulo 3, alguns dos fundamentos da teoria de redes neurais são apresentados, ilustrando-se a modelagem do neurônio biológico, bem como uma arquitetura de rede neural. Já no capítulo 4, uma visão geral do projeto é apresentado. No capítulo 5, o sistema elétrico analisado, bem como a configuração do mesmo, modelagem da linha de transmissão empregada e demais considerações pertinentes são detalhadas. O capítulo 6 traz os apontamentos referentes ao módulo de detecção, onde todas as considerações adotadas, tanto para o processo de treinamento como para o de teste, serão claramente expostas. O mesmo ocorre nos capítulos seguintes, 7 e 8, sendo que, desta vez, os módulos de classificação e de localização serão detalhados. O capítulo 9 destina-se a lógica computacional implementada, sendo que os resultados observados pela implementação são extensamente comentados no capítulo 10. Um modelo alternativo para o módulo de localização é apresentado no capítulo 11, restando para o capítulo 12, as conclusões e observações finais do trabalho como um todo. Em anexo, apresentam-se alguns resultados complementares, seguindo-se a este, as referências bibliográficas. Finalizando a apresentação, inclui-se um apêndice que traz uma relação dos trabalhos publicados e/ou em submissão em revistas e congressos nacionais e internacionais.

2 O ESTADO DA ARTE

Dentre as possíveis aplicações de Redes Neurais Artificiais (RNAs), destacamos o seu emprego como reconhecimento de padrões que, em termos gerais, é a ciência que compreende a identificação e classificação da informação em categorias.

Uma RNA compreende um conjunto de elementos de processamento conectados e organizados em camadas. Um dos modelos de RNAs (*feedforward*) é disposto em camadas, onde 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.

A mudança de valores das conexões entre os elementos de processamento, pesos e *bias*, envolve o processo de aprendizagem, onde utiliza-se de algoritmos de treinamentos que podem ser supervisionados, não supervisionados ou uma combinação destes. O algoritmo supervisionado apresenta como principal característica o prévio conhecimento da informação sobre as classes a que pertence cada um dos padrões na fase de treinamento. 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 busca minimizar o erro entre uma saída obtida pela rede e uma saída desejada. Os erros determinados para as unidades da camada de saída e camadas intermediárias são então usados para reajustar os valores dos pesos e *bias* de cada unidade, respeitando a topologia da rede em análise.

Diante das evidências apresentadas em artigos técnicos, indicando a confiança depositada pela comunidade científica na teoria referente a RNAs, 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 RNAs 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. Um grande número de publicações locais e internacionais apontam o notável progresso dos trabalhos aplicando-se os conhecimentos referentes a RNAs. A seguir serão comentados alguns destes trabalhos publicados e ou apresentados em congressos, abordando a linha de pesquisa aplicada à proteção de sistemas de transmissão.

2.1 RNAs aplicadas à proteção de linhas de transmissão

Com respeito à 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 às 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 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

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

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 (*Electromagnetic Transients Program*) 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 .

Em 1992 FERNANDO & WATSON mostram em seu trabalho que é possível obter um desempenho similar aos algoritmos empregados para a detecção de faltas com alta impedância quando se aplicam técnicas referentes a RNAs. Os mesmos destacam que a grande vantagem da aplicação deste novo conceito, redes neurais, seria na capacidade de aprender e de se adaptar às diversas situações de operações que um sistema de energia possa apresentar. Salienta-se que este tipo de falta com alta impedância não pode ser detectada usando-se os relés de sobrecorrentes convencionais e fusíveis (distribuição) em virtude do baixo nível de corrente proporcionado pela situação de falta. Estes baixos níveis de correntes de falta podem geralmente ser confundidos com situações de cargas e barramentos que possuam características similares.

KANDIL *et al.* (1992) exploram em seu trabalho a possibilidade do uso de redes neurais para identificar situações de faltas sobre um sistema de energia de corrente contínua e alternada. Baseado na habilidade destas redes em distinguir confiavelmente entre os tipos de faltas, espera-se uma otimização dos parâmetros de controle, o que vem a melhorar o procedimento dinâmico sobre o sistema de energia. No artigo, três diferentes arquiteturas de redes neurais são analisadas para distinguir entre os tipos de faltas sobre o sistema proposto e apresentam-se comentários a respeito das mesmas. As arquiteturas empregadas (*Counter Propagation Networks – CPN*) constroem um mapeamento sobre o conjunto de vetores de entrada resultando em um conjunto de vetores de saída. A arquitetura atua como um modelo hetero-associativo e compreende uma camada de entrada, uma camada intermediária designada como “camada *Kohonen*” e uma “camada *Grossberg*” que atua como uma camada de saída. Todas as simulações foram executadas empregando-se o *software* EMTDC (*Electromagnetic Transients Simulation Program*) tomando-se os valores médios (rms), ângulos de fases e valores instantâneos das tensões sobre o sistema em análise.

Cabe apontar 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.

Também em 1994, FRIEDRICH *et al.* expõem seu trabalho para determinar ou classificar a zona de ocorrência de uma situação de falta usando-se de RNAs. Quando algoritmos tradicionais são empregados, tenta-se determinar a zona de ocorrência de determinada falta estimando-se a impedância ou distância entre o relé e a localização da falta. Dois algoritmos são citados no trabalho. O de *Bornard/Bastide*, baseado na solução de equações diferenciais e o de *Phadke/Ibrahim*, que determinam os fasores fundamentais dos sinais de tensões e correntes pelo uso de filtros digitais (análise de *Fourier*). O que foi proposto pelos autores em substituição a estes algoritmos é o emprego de RNAs para se determinar a localização da falta, na primeira ou segunda zona de proteção, dispondo-se das

características apresentadas pelos sinais de tensões e correntes analisados. Somando-se as características dos sinais, a informação de um módulo de classificação do tipo de falta envolvida, anteriormente implementado pelos mesmos, também foi utilizada. As vantagens e características obtidas na localização da falta com o emprego de RNAs são evidenciadas e ilustradas na apresentação do trabalho.

HANDSCHIN *et al.* (1994) colocam em seu trabalho alguns problemas encontrados na obtenção e interpretação dos sinais e alarmes provenientes de um sistema de proteção que ainda não apresentam ou foram solucionados satisfatoriamente. Dentre as inúmeras técnicas de abordagem do problema, muitos trabalhos propõem a aplicação de RNAs para diagnosticar condições de faltas. Pelos autores, mesmo estas recentes aplicações de RNAs possuem limitações, principalmente no fato de retrainar a arquitetura escolhida a cada alteração da topologia do sistema, o que compromete a flexibilidade e uma real aplicação dos trabalhos. Neste trabalho, módulos que representam a topologia do sistema são implementados através de RNAs com o objetivo de diagnosticar faltas através de um processo iterativo. Durante cada interação, os alarmes associados a um específico dispositivo elétrico e o diagnóstico gerado durante prévias interações com os módulos adjacentes são processados e considerados na implementação por RNAs. Sendo assim, pela implementação de módulos de RNAs, os problemas relacionados à adaptação, as alterações da topologia do sistema, treinamento e complexidade do conjunto de dados são superados. Segundo os autores, esta distribuição da informação do sistema em módulos pode ser aplicada a qualquer topologia, visto que cada dispositivo de proteção estará associado e interagindo somente com a sua vizinhança.

LAI *et al.* em 1994 apresentaram um trabalho para determinar seções com simples ou múltiplas faltas em um sistema de energia. O trabalho envolve redes neurais e algoritmos genéticos. Tal combinação justifica-se pelo fato de que o desempenho da aplicação de redes neurais na solução de qualquer problema, está altamente relacionado à escolha adequada de sua arquitetura (tamanho, estrutura, conectividade) e parâmetros a serem empregados na fase de treinamento da rede. Empregou-se algoritmo genético com o intuito de se reduzir o tempo gasto na fase de treinamento já que, alterando-se qualquer parâmetro na rede, o procedimento desta

fase deve ser repetido até se alcançar uma rede que atenda ao problema formulado. O modelo proposto apresenta bons resultados, mesmo sujeito a falhas de operação dos relés e disjuntores, ou ainda a erros na transmissão de dados.

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.

Hardware e software direcionados à detecção e classificação de faltas em um sistema de distribuição são desenvolvidos e testados por CHEN *et al.* (1995), aplicando-se os conhecimentos da teoria de redes neurais. No trabalho, abordagens combinando-se a proteção por relés de sobrecorrente e técnicas de releamento para a classificação de faltas como um modelo comum de proteção são apresentadas. Os resultados satisfatórios observados demonstram a eficiência e capacidade do modelo proposto para o diagnóstico e classificação tanto para faltas permanentes ou transitórias como para múltiplas faltas.

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.

Considerando a complexidade dos possíveis tipos de faltas e o efeito mútuo encontrados nos sistemas de transmissão, FERNANDO & MCLAREN (1995) abordam o tema testando um algoritmo de relé de distância digital, designado para uso em linhas de transmissão de circuitos trifásicos simples, sobre uma configuração

de circuito duplo. A versão do algoritmo apresentada compensa as correntes mútuas de seqüência zero, evitando-se os problemas de sub e sobre alcance da zona de proteção na operação dos elementos de impedância. Uma arquitetura de rede neural foi integrada ao estudo com o objetivo de identificar as fases envolvidas nas diferentes condições de faltas sobre o sistema para determinados pontos de operação.

GHOSH & LUBKEMAN (1995) descrevem uma metodologia baseada em RNAs para classificar os distúrbios encontrados nas formas de ondas dos sinais que representam o estado de um sistema de energia. Segundo os mesmos, este “classificador” seria o centro da tecnologia empregada para o registro e análise dos distúrbios de um sistema em análise. O uso de uma arquitetura de RNAs com atraso de tempo (*Time-Delay Neural Network – TDNN*), que não é comumente aplicada em problemas de transmissão, é explorada e comparada com o desempenho de uma arquitetura *feedforward*. Ainda conforme os autores, a arquitetura TDNN apresenta a habilidade de aprender reconhecendo a relação temporal existente nos conjuntos de dados registrados, o que é desejável para a classificação do problema. Esta particular característica da TDNN permitiu um melhor desempenho da mesma, quando comparada à arquitetura *feedforward*.

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.

Relembrando a importância da seleção da fase faltosa para a estabilidade do sistema e da necessidade da correta operação na abertura e fechamento de pólos simples, AL-HASSAWI *et al.* (1996) expõem sua pesquisa para a classificação e

seleção da fase faltosa baseado na aplicação de RNAs. A estrutura de RNAs *feedforward* compreende dois níveis, cada qual responsável por uma das funções mencionadas. Os resultados observados tanto na fase de treinamento como na de testes indicam alta capacidade de aprendizagem e precisão nos resultados por parte da configuração analisada. Este trabalho, com algumas inclusões, vem novamente a ser apresentado pelos autores em 1997 sendo que outros comentários serão posteriormente colocados.

A aplicação de diferentes arquiteturas de redes neurais (Kohonen e *backpropagation*) para a detecção e classificação de situações de faltas é descrita por CHOWDHURY & WANG em 1996. Os autores empregam os componentes fundamentais das correntes e tensões obtidos por simulações tanto para a fase de treinamento como para a de testes das arquiteturas consideradas. Comparando-se os resultados obtidos sobre linhas de transmissão de alta tensão, Kohonen apresentou-se mais propício ao diagnóstico de faltas quando comparado ao outro modelo utilizado. No entanto, esta justificativa colocada pelos autores é bem aceita se o treinamento da rede neural for realizado com dados *on-line*, caso contrário, os dois modelos analisados apresentaram um bom índice de precisão. Os mesmos salientam que estes métodos de aplicação de redes neurais (Kohonen ou *backpropagation*) podem ser estendidos a qualquer sistema de energia, visto que as grandezas consideradas são disponíveis nos centros de controle.

DALSTEIN *et al.* (1996) abordam o problema da estimação da localização da falta para sistemas de proteção com alta velocidade de atuação, utilizando-se de redes neurais *feedforward* para solucioná-lo. Apresentam-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.

Uma das técnicas comumente utilizada para a análise de faltas é baseada na teoria dos “componentes simétricos”. Esta técnica requer a consideração dos fasores dos componentes simétricos, os quais, por sua vez, requerem cuidados apropriados no processamento dos dados quando usados em aplicações de proteção digital. Destas considerações nos cálculos dos fasores do sistema de potência, destacam-se a taxa de amostragem dos dados, filtros *antialiasing* bem como número de amostras consideradas (tamanho da janela de dados utilizada). KEZUNOVIC & RIKALO (1996) trazem a aplicação de RNAs na detecção e classificação de faltas, utilizando-se de amostras dos sinais de tensão e corrente obtidos sobre o sistema em análise. Pelo que é apresentado no trabalho, os autores buscaram identificar uma arquitetura de RNA que atendesse a uma rápida detecção e classificação da falta. Os mesmos empregaram uma arquitetura de RNA a que se sobrepõem as limitações apresentadas pelas redes de multi-camadas (redes *feedforward*) e toma vantagens sobre as redes auto-associativas. A técnica utiliza-se dos procedimentos de treinamento supervisionado e não-supervisionado. Com respeito ao treinamento supervisionado, um agrupamento ou uma classe inicial de padrões é apresentada à rede com seus respectivos sinais de entrada. Após esta fase, o processo segue com o treinamento não supervisionado o qual será executado apresentando-se à rede novos sinais do sistema em análise. Se estes sinais forem semelhantes à classe já existente de padrões, estes serão incorporados à mesma, senão, uma nova classe de padrões será designada. Um dos pontos que merece ser destacado diz respeito ao tamanho da janela de dados utilizada - 16.67 ms com uma frequência amostral de 2 kHz, o que corresponde a 33 amostras por ciclo. A entrada da RNA consistiu do sinal trifásico das correntes do sistema, dando à rede uma camada de entrada com 99 unidades de processamento (neurônios). Após o treinamento da RNA uma nova situação de falta pode ser classificada considerando-se a mínima distância Euclidiana entre o novo padrão e todas as classes ou aglomerações existentes.

Como atribuir características adaptativas ao relé, permitindo ao mesmo ajustar-se automaticamente às várias funções e situações de proteção, prevalecendo as condições do sistema de energia é o assunto explorado por KHAPARDE *et al.* em 1996. O trabalho apresentado trata de compensar a resistência de falta usando-se de técnicas adaptativas com auxílio RNAs. Uma arquitetura de RNA *feedforward* é

treinada para ajustar-se à característica da impedância (círculo no plano R-X com o centro na origem) e outra à característica formada pelo plano V-I (tensão e corrente). Neste último caso, considerou-se como sinais de entrada para a rede os sinais de tensões e correntes com o respectivo ângulo de fase, supondo este disponível. Uma das vantagens apontadas no uso dos valores de tensões e correntes é a não necessidade de comunicação entre os terminais da linha, já que estes sinais são disponíveis localmente.

Compensação série controlável de linhas de transmissão é o assunto abordado por SONG *et al.* (1996). O tema é apresentado denotando-se os problemas que esta compensação causa nos modelos de proteção de distância convencionais, visto que há uma rápida alteração da impedância aparente medida quando a técnica é aplicada. A principal idéia do trabalho é empregar RNAs como um classificador de padrões, para que estas venham a tomar decisões baseadas na extração de importantes características presentes no espectro em análise (tensões e correntes trifásicas) e ângulos de disparo (*firing angle*) sob condições de falta. Este modelo, segundo os autores, é diferente das abordagens convencionais, as quais são baseadas nas derivadas implícitas de equações matemáticas envolvendo técnicas de filtragem complexas.

Um detetor de faltas implementado por RNAs é assunto da pesquisa de VÁZQUEZ *et al.* em 1996. Colocado como um problema de reconhecimento de padrões, a pesquisa é baseada na alteração sofrida na amplitude e fase dos sinais de correntes de um sistema elétrico em virtude de uma situação de falta. Na presença de sinais de pré-falta e de componentes transitórios (pós-falta), as arquiteturas de RNAs foram treinadas para reconhecer a situação faltosa no seu instante de ocorrência e os resultados encontrados demonstram a rapidez, robustez e precisão da ferramenta utilizada.

Cabe comentar o trabalho de AGGARWAL *et al.* (1997a) que descreve uma técnica para localização da falta empregando-se uma combinação da Lógica Fuzzy com RNAs. A abordagem utiliza-se dos valores de fases dos sinais de tensão e corrente de situações faltosas sobre uma linha de transmissão e, pode ser definida basicamente em dois estágios: no primeiro, uma RNA é utilizada no sentido de classificar os tipos de faltas e no segundo estágio, emprega-se a Lógica Fuzzy para

treinar outra RNA com o propósito de localizar a falta sobre a linha considerada. Segundo os mesmos, a precisão na localização da falta é significativamente melhorada, se comparada às técnicas que se utilizam somente de arquiteturas de RNAs. Apesar de ter-se utilizado de várias arquiteturas de RNAs no segundo estágio (uma arquitetura para cada tipo de falta), uma das vantagens apresentada é a simplicidade destas arquiteturas levando a um fácil treinamento, devido a um menor conjunto de dados utilizado.

O problema da detecção da falta em linhas com circuitos duplos considerando-se o acoplamento mútuo sob várias condições de faltas é abordado por AGGARWAL *et al.* (1997b). Uma técnica empregando treinamento não supervisionado (para extração das características) e supervisionado (para classificação das características) provê a habilidade para classificar o tipo de falta identificando diferentes padrões associados aos sinais trifásicos de tensões e sobre as seis correntes de ambos os circuitos. Utiliza-se de redes neurais com mapeamento auto-organizável (*Self-Organization Mapping - SOM*) e uma comparação com uma arquitetura que se utilizou somente do treinamento supervisionado (*Backpropagation*). Dentre as desvantagens do uso do treinamento supervisionado, os autores destacam o grande número de padrões necessários para cobrir as diversas situações de faltas, o tempo consumido na fase de treinamento da arquitetura e a facilidade de se atingir mínimos locais. Além destes itens apontados, fica difícil retreinar a arquitetura com um novo conjunto de dados. Com respeito à rede SOM, esta arquitetura não requer um grande conjunto de treinamento e este é muito rápido. Outra vantagem é a robustez do modelo frente as variações nos parâmetros, tais como, localização, resistência e ângulo de injeção da falta, bem como as variações nas impedâncias das fontes e ângulos de carga. Todos os resultados denotam que o classificador de faltas proposto é apropriado para circuitos duplos. Soma-se às características apresentadas o fato de que as regiões de decisão entre as classes dos tipos de faltas no modelo são bem claras e definidas. Um comentário, já observado em outros trabalhos, diz respeito à afirmação de que não se deve misturar as “tarefas” quando se trabalha com redes neurais. Por exemplo, os autores tentaram incluir, além das saídas para a classificação da falta, uma variável para indicar se a falta era interna ou externa a determinada zona de proteção. A rede neural não conseguiu

atingir um nível de convergência aceitável. Para uma correta aplicação, estas duas tarefas - classificação e localização da falta - devem ser implementadas em níveis hierárquicos distintos.

AGGARWAL & SONG expõem uma série de três tutoriais onde o tema de RNAs em sistemas de potência é particionado em uma introdução geral (Parte 1, 1997c), tipos de redes neurais (Parte 2, 1998a) e exemplos de aplicações (Parte 3, 1998b). Nestes três tutoriais, voltados a uma visão geral e formulado sobre conceitos básicos de redes neurais, encontram-se também exemplos de aplicação da ferramenta na resolução de complexos problemas relacionados a sistemas de potência. Deixa-se claro pelas situações ilustradas, principalmente no que se refere a Parte 3 do trabalho, que a aplicação de redes busca uma melhor abordagem aos problemas, quando comparadas aos métodos tradicionais que encontram certa dificuldade, seja em termos de velocidade de processamento ou em alcançar a precisão e a eficiência desejadas.

Encontramos em AL-HASAWI *et al.* (1997) uma aplicação de RNAs que mostra um modelo para a detecção e discriminação direcional da falta (faltas à frente ou reversas a um determinado ponto), classificação da falta (fase-terra, bifásica, bifásica-terra, trifásica-terra) e seleção das fases envolvidas para cada tipo de falta. O modelo proposto é baseado em uma estrutura de redes neurais com três níveis hierárquicos distintos, onde os valores normalizados dos valores de fase das tensões e correntes transitórias induzidas por uma situação de falta no ponto do relé são analisados. Salienta-se que a técnica empregada pelos autores é baseada na superposição dos espectros e não nos componentes de frequência do sistema, logo não é considerado o efeito “*anti-aliasing*”. A taxa amostral empregada é de 3 kHz, com a frequência do sistema de 60 Hz, o que acarreta em 50 amostras por ciclo. Utilizou-se uma janela de dados contendo 10 amostras dos sinais de tensão e corrente (fases a, b e c) pós-falta. Observa-se pelo modelo apresentado que os mesmos sinais de tensões e correntes (10 amostras de cada fase) são apresentados tanto para a detecção como para a classificação da falta. Os resultados encontrados, tanto na fase de treinamento como na de teste, indicam uma alta velocidade e seletividade do modelo, bem como a obtenção de características adaptativas sobre o sistema.

Ainda relativo ao relé direcional, encontramos uma nova abordagem ao problema apresentado por BO *et al.* (1997a). Dos estudos já realizados, constata-se que um sistema de proteção baseado na teoria das “ondas viajantes” proporciona uma rápida atuação dos relés para a maioria dos sistemas e condições de faltas. A questão levantada pelos autores diz respeito a lapsos ou falhas que estas implementações podem apresentar, como por exemplo, quando uma falta ocorre com um ângulo de incidência próximo a zero graus, já que, para esta situação, não serão gerados componentes significativos de ondas viajantes. Além deste problema, há a limitação da banda de passagem dos transdutores empregados, especialmente dos de tensão, a qual afeta a precisão e confiabilidades dos esquemas utilizados. O trabalho apresenta uma técnica alternativa para o relé direcional utilizando-se dos transitórios gerados sobre os sinais de tensão e corrente do sistema. Empregando-se transdutores especialmente projetados para trabalhar com componentes de alta frequência, após certas modelagens, uma comparação entre as polaridades dos transitórios dos sinais de tensão e corrente, indicará a direção da situação de falta. Ao contrário dos estudos anteriores, baseados em medidas sobre os sinais de frequência do sistema e ondas viajantes iniciadas pela falta, esta técnica dá mais atenção aos sinais de alta frequência associados à falta. Como comprovado pelos autores, os estudos realizados por esta técnica mostram-se insensíveis ao tipo, posição, resistência e ângulo de injeção da falta.

Preocupados com o problema da seleção das fases envolvidas em uma situação de falta e com a otimização das conexões e arquiteturas de RNAs empregadas, BO *et al.* (1997b) desenvolveram uma nova técnica de análise empregando algoritmo genético. Os sinais analisados pelo seletor de fases são provenientes das situações transitórias (ruídos) em alta frequência, gerados pela falta, que são extraídos do sistema pelo emprego de detectores de transitórios especialmente projetados para tal. Pela otimização das conexões e arquiteturas, há uma redução do trabalho computacional (menor espaço de memória utilizada) com um aumento da velocidade de resposta da rede neural empregada. Somam-se a estas características o bom e eficiente desempenho da técnica empregada na seleção das fases envolvidas, que é claramente demonstrada no trabalho. Pela adequada seleção das fases, esta aplicação traz bons resultados para o chaveamento de pólos simples.

BO *et al.* (1997c) empregaram recentemente RNAs para distinguir entre surtos provenientes de descargas atmosféricas e faltas a terra ocorridas sobre linhas de transmissão. Na técnica utilizada, um detector de transitórios é empregado para capturar o efeito das descargas e transitórios induzidos pelo surto, bem como os sinais ruidosos de alta frequência gerados por uma situação de falta a terra. As saídas deste detector são usadas para treinar uma arquitetura de rede neural com três camadas. Os resultados apresentados evidenciam que a RNA é capaz de discriminar entre uma falta à terra e um surto atmosférico sobre vários sistemas e condições de faltas. Das principais características dos sinais analisados, surto atmosférico e falta a terra, no primeiro, as formas de onda da tensão e corrente irão conter relativamente uma grande porção de componentes de alta frequência. Para uma falta a terra, embora esta também gere componentes em diversas frequências, esta irá envolver grandes correntes de falta a terra, as quais são predominantemente na frequência do sistema de energia. Segundo os mesmos, esta técnica se aplicada a situações reais, poderá prover preciosas informações para o projeto de novos relés baseados na detecção dos transitórios gerados por situações de faltas e melhorar o desempenho dos relés convencionais nas suas principais funções tais como na localização, discriminação e religamento sob uma situação de falta.

Tendo como informação os ruídos de alta frequência presentes nas formas de ondas de situações faltosas, BO *et al.* (1997d) nos apresentam uma nova abordagem ao problema da seleção de fases envolvidas pelo uso de RNAs. A correta seleção das fases envolvidas terá como consequência direta uma bem sucedida operação na abertura e/ou fechamento de pólos simples, como também já foi justificado por AGGARWAL *et al.* (1994) e AL-HASSAWI *et al.* (1996). O trabalho, baseado em simulações computacionais, considera, entre outras variantes, a posição da situação faltosa, o efeito do ângulo de inepção da falta, faltas apresentando alta resistência e faltas envolvendo duas fases. Após extensivos estudos, os autores relatam um índice de 99% de correta classificação para o esquema proposto.

BO & JOHNS (1997) apresentam outro trabalho que diz respeito à detecção da falta empregando-se os componentes transitórios de alta frequência gerados por uma situação de falta. O trabalho intitulado “*Transient based protection – a new concept in power system protection*” tem como justificativa o fato de que os

componentes de alta frequência contêm inúmeras informações sobre o tipo de falta, localização, direção e sobre o tempo de permanência da falta sobre o sistema. As vantagens dos modelos de proteção baseados nos transitórios sobre os modelos baseados na frequência do sistema e ondas viajantes são ilustrados pela apresentação de várias pesquisas que estão atualmente em desenvolvimento. A proteção baseada nos transitórios de alta frequência, detecta a ocorrência de uma situação de falta baseada nos sinais de tensão ou corrente observados. Estes sinais em alta frequência são obtidos diretamente das saídas dos transformadores de corrente (TCs). Devido à limitação da banda de passagem dos convencionais transformadores de potencial (TPs), os sinais de tensão em alta frequência são medidos por um transdutor especialmente projetado para tal aplicação. Algoritmos rápidos de processamento de sinais são então implementados para medir os sinais com a conseqüente aplicação na identificação e localização da falta para a devida proteção dos sistemas utilizados.

Ainda na linha de relés de distância, JONGEPIER & SLUIS (1997) desenvolveram uma proteção de distância adaptativa especificamente para linhas de transmissão em circuito paralelo, usando RNAs. A proteção adaptativa oferece uma modelagem para compensar a influência das condições operacionais dos sistemas de energia. Primeiramente, mostra-se no trabalho que a precisão dos relés de distância pode ser significativamente melhorada pela aplicação da proteção adaptativa. Com isto, a seletividade do sistema de proteção é incrementada com o conseqüente aumento da confiabilidade dos sistemas de energia. Pela aplicação de RNAs, chega-se à conclusão de que estas são capazes de estimar a condição geral do sistema de energia pelo uso de medidas locais e então atuar de maneira adaptativa sobre o sistema.

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. O presente trabalho emprega inicialmente um conjunto de dados, gerado pelo emprego do *software* EMTDC, que descreve as formas de ondas de tensão e corrente de uma situação faltosa, bem como a sua localização sobre determinado sistema. O modelo de RNA é então treinado para extrair as principais características do estado do sistema incluindo a estas, a situação dos relés. Uma vez concluído o treinamento, o

modelo responde frente às situações do sistema (falta, sobrecarga ou situação normal de operação). Os mesmos afirmam que o modelo apresentado pode ser implementado para monitorar e atuar sobre os sistemas de potências atuais com um razoável grau de precisão.

Problemas encontrados na aplicação de relés de distância convencionais (adaptabilidade às condições normais e anormais de operação) são abordados por QI *et al.* em um recente trabalho (1997). O modelo apresentado, relé de distância implementado pela aplicação de RNAs, apresenta bons resultados relacionando as faltas fase-terra aplicadas sobre determinada linha de transmissão a corretas categorias e identificando as resistências de faltas sobre específicas zonas de proteção. Tal modelo possui capacidade para se adaptar às condições de carga de pré-falta, impedância da fonte variável e resistência de aterramento, reduzindo os erros de alcance nas zonas de proteção do dispositivo.

SIDHU (1997) traz outra aplicação de RNAs na proteção de linhas de transmissão. O mesmo aborda os procedimentos e principais fatores que dizem respeito a RNAs aplicadas à proteção. Descreve-se quatro trabalhos relacionados à proteção, incluindo-se nestes a direção e classificação da falta, proteção de linhas de transmissão com compensação série e o relé de distância. Comentam-se neste trabalho as vantagens do uso de RNAs à proteção bem como as barreiras observadas para a sua efetiva aplicação em situações reais. Dentre as vantagens, destaca-se a habilidade por parte das redes em trabalhar com modelos complexos e interações não lineares, adaptabilidade e capacidade de considerar ruídos nos sinais analisados. Contrário a estas vantagens, comenta-se a necessidade de um melhor conhecimento de tal ferramenta para se elaborar regras concisas que permitam implementar e analisar as arquiteturas, tirando-se do contexto designações como: procedimento empírico ou determinado por tentativas, como é o caso do número de elementos e camadas intermediárias.

Recentemente SU *et al.* (1997) apresentaram um trabalho envolvendo RNAs na detecção de faltas em circuitos de transmissão compostos, ou seja, em um sistema de transmissão de 400 kV composto por 70 km de uma linha de transmissão aérea e 30 km por um sistema subterrâneo de cabos. Tal modelagem foi realizada empregando-se o *software* EMTP sob diversas condições de faltas, considerando-se

uma alta capacitância *shunt* do cabo. Os valores trifásicos das tensões e correntes obtidos por simulação são empregados para treinar e testar uma arquitetura de RNA multi-camadas. Fica claro, pelos resultados apresentados, que a técnica empregada proporciona uma alta precisão na detecção de faltas para todos os pontos sobre a linha composta, mesmo sob várias condições de falta, tais como: tipo, localização e ângulo de injeção da falta.

COURY & JORGE (1998) 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 às variações do sistema de potência, mesmo quando da variação na configuração da rede analisada. No entanto, como somente faltas do 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.

Também em 1998 COURY & OLESKOVICZ ilustram a aplicação de RNAs como um classificador de padrões nas operações de um relé de distância. As grandezas analisadas referem-se aos valores trifásicos de tensões e correntes do sistema elétrico, incluindo a seqüência zero. Para se observar o desempenho do relé de distância implementado, duas formas de utilização dos valores amostrados trifásicos foram adotadas. A primeira utiliza como entrada os cinco valores amostrados em meio ciclo pós-falta do sinal analisado e a segunda, emprega a amplitude dos fasores de tensões e correntes (incluindo a seqüência zero). Deve ser notado que neste trabalho utilizaram-se somente faltas relacionadas com a fase(a)-terra. Segundo os autores, a segunda arquitetura apresentou um melhor desempenho se comparada à primeira, no que diz respeito a faltas à frente da localização do relé. Em adição, a maioria dos erros apresentados por esta arquitetura está concentrada em uma suposta zona de transição, onde respostas incorretas podem ser toleradas. No trabalho, apresenta-se uma extensão da zona primária do relé para 96% do comprimento da linha de transmissão analisada, o que vem a aumentar a confiabilidade do sistema. Informações complementares podem ser encontradas no

documento de dissertação de mestrado “*Redes neurais artificiais: uma alternativa para proteção de linhas de transmissão*”, (OLESKOVICZ, 1997). Desta referência, decorrem também os principais fundamentos teóricos e práticos que são empregados no desenvolvimento deste.

Preocupados em obter uma estrutura neural otimizada, VENKATESAN & BALAMURUGAN (2001) expõem uma nova abordagem à tarefa de detecção de uma situação de falta em tempo real dispondo-se de RNAs. Regido pelas características básicas de um sistema de proteção, o modelo proposto deve ser capaz de diferenciar entre situações de faltas momentâneas ou sustentadas, além de ser capaz de isolar somente a parte do sistema que está sob uma situação anormal de operação. Como dados disponíveis para a análise, os valores instantâneos das magnitudes das tensões e correntes trifásicos em várias condições de faltas foram consideradas. Um simulador de RNAs, implementado na linguagem de programação C++ foi desenvolvido, o qual busca otimizar o sistema neural, no que diz respeito ao tempo requerido para a fase de treinamento o qual diretamente incide sobre a complexidade do hardware empregado e a velocidade de processamento dos sistemas digitais. Conforme ressaltado no trabalho, da aplicação de RNAs ao problema, resulta uma maior velocidade de operação do sistema frente as diversas situações e adaptações de operações do mesmo, bem como da possibilidade de aplicação do modelo discutido em tempo real.

Até então, na maioria dos trabalhos apresentados empregando-se RNAs à proteção, utilizaram-se de arquiteturas *feedforward* em conjunto com o algoritmo de treinamento supervisionado *backpropagation*. Em 1997 SONG *et al.* registram novos estudos no sentido da aplicação de diferentes arquiteturas de redes, combinando-se principalmente os algoritmos supervisionados e não supervisionados aplicados a um problema específico de classificação de faltas em linhas de transmissão complexas, como por exemplo, em linhas com compensação série. Métodos convencionais de reconhecimento de padrões não apresentam soluções satisfatórias quando aplicados a este problema devido às inúmeras situações de faltas possíveis e principalmente pela operação não linear dos dispositivos de proteção em tais condições de falta, como por exemplo é o caso do *Metal Oxide Varistor* (MOV). O estudo compreende as arquiteturas de redes com treinamento supervisionado - *backpropagation* (BP), não

supervisionado - *feature map* (FM), supervisionado/não supervisionado - *radial basis function* (RBF), *counter-propagation* (CP) e *learning vector quantization* (LVQ). Dentre as conclusões apuradas pelos autores, em geral os algoritmos de treinamento supervisionado/não supervisionado combinados oferecem um melhor desempenho quando comparados ao uso exclusivo do algoritmo de treinamento supervisionado para esta específica aplicação. Como exposto no trabalho, as redes que se utilizaram de FM, RBF, CP e LQV apresentaram uma rápida aprendizagem, taxa de erro similares, melhor robustez para o sistema e a variações operacionais requerendo um menor conjunto de dados de treinamento quando comparados a rede BP. No entanto, como frisado pelos autores, vale ressaltar que a rede BP é mais compacta, com relação às unidades e camadas intermediárias, esperando-se ser mais rápida quando aplicada a situações em tempo real.

Focalizando-se na dificuldade das técnicas convencionais em classificar o tipo de falta em sistemas compostos por circuitos duplos/paralelos, AGGARWAL *et al.* (1999) apresentam uma nova técnica para o problema, dispondo-se de algoritmos de treinamento compostos (supervisionados e não supervisionados) visando à aplicação de RNAs. O que se busca pela aplicação é transpor a dificuldade encontrada em classificar uma condição anormal de operação em circuitos duplos devido ao acoplamento mútuo existente entre os circuitos, o qual é naturalmente variável. Considerando-se várias condições normais e anormais de operação, a nova abordagem empregando *Self-Organization Map based network* – (SOM *based network*) é comparada com uma outra arquitetura *Multi Layer Perceptron* (MLP) que se utiliza somente do algoritmo de treinamento supervisionado. Dos apontamentos conclusivos, destaca-se que a composição entre treinamento supervisionado e não supervisionado (dispondo-se de uma arquitetura SOM) não necessita de um grande conjunto de treinamento, é menos vulnerável às variações dos parâmetros do sistema como, localização, resistência e ângulo de injeção da situação faltosa, além de corretamente responder às variações da impedância e ângulo de carga. Segundo os autores, apenas uma pequena desvantagem é observada no modelo proposto, já que o número de neurônios (unidades de processamento na camada Kohonen) é muito dependente do número de padrões no conjunto de treinamento. Os mesmos relembram que tal desvantagem pode ser facilmente transposta, já que um menor

número de padrões para o conjunto de treinamento será empregado, quando comparado à arquitetura MLP.

Procurou-se, através das publicações citadas, apresentar alguns comentários referentes a trabalhos que aplicam os conhecimentos da teoria de RNAs em problemas diretamente relacionados à proteção de sistemas de transmissão. Como observado nos trabalhos apresentados, o processamento digital e novas técnicas computacionais são áreas de pesquisas de grande potencial. Nestas áreas, RNAs têm sido aplicadas na proteção de sistemas, objetivando resolver inúmeros problemas e limitações que os modelos convencionais apresentam. Isto pode ser notado especialmente na proteção de distância, onde dispõe-se somente das informações locais dos sistemas.

3 REDES NEURAIS ARTIFICIAIS

Aplicações bem sucedidas usando-se RNAs 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 RNA 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 1, 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 dentritos 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 1 - Neurônios do sistema nervoso central dos vertebrados

Como apresentado, os neurônios são as 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 2, conforme apresenta BERNIERE et al. (1994) e que com certeza é inspirado no modelo proposto por Warren McCulloch & Walter Pitts em 1943.




FIGURA 2 - 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 sinal 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, $\mathbf{I} = \Sigma(w_i \cdot x_i)$. O modelo simplificado compara este ao *threshold* característico de cada neurônio. Se o somatório (\mathbf{I}) for maior que o limiar especificado (\mathbf{b}), o neurônio está ativo e produz um sinal de saída cujo valor será considerado pela função de ativação (\mathbf{f}). Caso contrário, se o somatório (\mathbf{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 2,

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

sendo \mathbf{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) ou a função tangente hiperbólica (eq. 3).

$$f(.) = \frac{1}{1 + e^{-t}} \quad (2)$$

$$f(.) = \frac{e^t - e^{-t}}{e^t + e^{-t}} \quad (3)$$

onde: $t = \Sigma w_i x_i - b$

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 que segue.

3.3 RNAs de múltiplas camadas

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.

Dando prosseguimento às idéias de McCulloch, ROSEBLATT¹ *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 a redes a lei de treinamento do perceptron.

Na mesma época em que Rosenblatt trabalhava no perceptron, Widrow desenvolveu um modelo simplificado do perceptron designado por ADALINE (**AD**Aptive **L**INear **E**lement) 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 3, onde apresenta-se um conjunto de unidades (nós ou neurônios) divididos em três camadas.

¹ ROSENBLATT, F. (1962). *Principles of neurodynamics*. New York, Spartan.

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

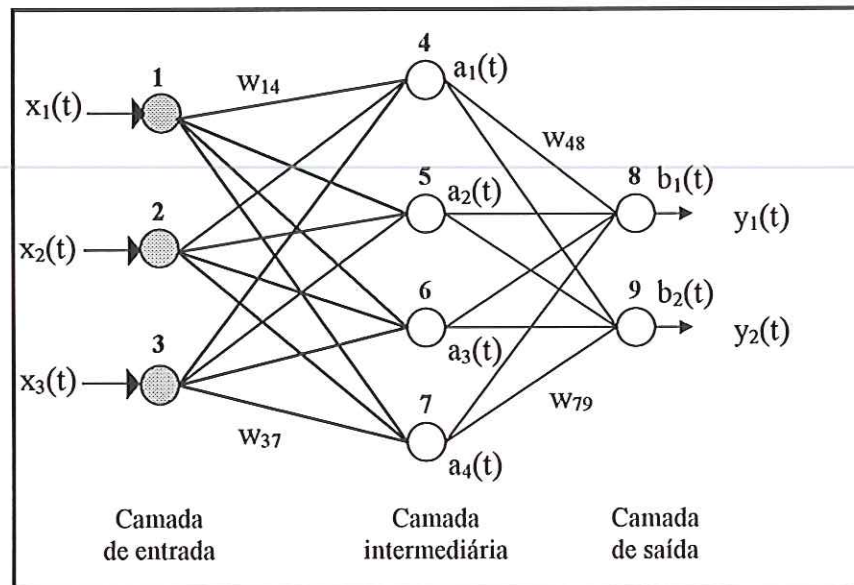


FIGURA 3 - Uma arquitetura *feedforward*

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 na apresentação de um padrão de entrada, representado na Figura 3 pelo vetor de entrada \mathbf{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 \mathbf{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 \mathbf{b} ($\{b_1, b_2\}$). Estes estados de ativação, conforme a aplicação, resultam em respostas na camada de saída (vetor \mathbf{y} , com componentes $\{y_1, y_2\}$). Comparam-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.

3.4 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 à 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 e durante a fase de uso da rede novas classes são adicionadas ao sistema através de aprendizado não supervisionado e

d) **treinamento por reforço** onde a única informação de realimentação fornecida a rede é se uma determinada saída está correta ou não, isto é, não é fornecida a rede a resposta correta para o padrão de entrada.

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 *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 sigmoideal e da função tangente hiperbólica.

Apresenta-se no que segue o algoritmo de treinamento *backpropagation* segundo HERTZ et al. (1991) para redes neurais com múltiplas camadas, considerando-se no desenvolvimento deste a função de ativação sigmoideal.

3.4.1 Algoritmo *backpropagation*

a) Inicialização dos pesos e *bias*

Com uma distribuição inicial dos pesos e *bias*, para o instante de tempo $k = 0$, atribuem-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. 4:

$$y_j(k) = S_j \left[\left(\sum_{i=1}^m w_{ij} x_i \right) - b \right] \quad (4)$$

onde

$$S_j(.) = \frac{1}{1 + e^{-\left(\sum_{i=1}^m w_{ij}x_i - b\right)}} \quad (5)$$

e 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 à camada posterior à 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:

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

$$\delta_j(k) = y_j(k) [1 - y_j(k)] [y_j^*(k) - y_j(k)] \quad (6)$$

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:

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

$$\delta_j(k) = y_j(k) [1 - y_j(k)] \left[\sum_{p=1}^n \delta_p(k) w_{jp}(k) \right] \quad (7)$$

onde:

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

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

n representa o número de unidades que a compõem.

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:

$$w_{ij}(k+1) = w_{ij}(k) + \alpha \delta_j(k) y_j(k) \quad (8)$$

$$b_j(k+1) = b_j(k) + \alpha \delta_j(k) \quad (9)$$

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 6 e 7. 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.

Como será posteriormente evidenciado (capítulo 11), buscou-se uma abordagem alternativa para a função de localizar uma situação faltosa. Esta

abordagem traz em especial a aplicação de redes de Função de Base Radiais (*Radial Basis Function* - RBF) na localização de faltas que envolvem uma fase com conexão a terra. Por este objetivo, um sucinto estudo teórico será apresentado no que segue.

3.5 Alguns apontamentos sobre RBF

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

Uma rede RBF, em termos gerais, é qualquer rede que possui uma representação interna dos elementos de processamento da camada intermediária (unidades padrão) que são radialmente simétricos. Para uma unidade padrão ser radialmente simétrica, esta deve apresentar os seguintes componentes (NEURAL COMPUTING – A technology Handbook for NeuralWorks Professional II/PLUS and NeuralWorks Explorer, 1998):

- um centro, o qual é um vetor do espaço de entrada e é tipicamente armazenado no vetor de peso da camada de entrada para a unidade padrão;
- uma distância mensurável, para determinar o quanto distante um vetor de entrada está do centro. Tipicamente, a medida padrão é a distância Euclidiana;
- uma função de transferência, a qual é uma função de uma simples variável, que determina a saída do elemento de processamento da camada intermediária pelo mapeamento de sua saída em função da distância medida. Uma função usualmente empregada é a função Gaussiana que apresenta valores confiáveis para as saídas quando a distância é pequena. Em outras palavras, a saída de uma unidade padrão de uma rede RBF é função somente da distância entre um vetor de entrada e o centro armazenado.

Redes RBF podem ser usadas na maioria das situações nas quais podemos considerar o emprego de uma rede *back-propagation* (REFERENCE GUIDE – A software reference for NeuralWorks Professional II/PLUS and NeuralWorks

Explorer, 1998). Propostas do emprego de redes RBF abrangem uma variedade de problemas que incluem:

- a modelagem de sistemas;
- a predição e
- a classificação, entre outros.

Dentre as principais vantagens no uso de uma rede RBF ao invés de uma rede *back-propagation* estão:

- um treinamento mais rápido,
- o emprego de um número reduzido de padrões de treinamento e
- uma melhor definição dos limites de resolução, quando redes RBF são empregadas a problemas de classificação e de decisão.

Das suas desvantagens destacamos:

- a necessidade de uma primeira fase de aprendizagem da função base radial que é uma fase de *clustering* não supervisionada. Nesta etapa, importantes informações discriminatórias podem ser perdidas e
- o fato de que, uma rede *back-propagation* pode apresentar uma representação mais compacta.

A rede RBF implementada pelo *software NeuralWorks* é o modelo proposto por Moody e Darken (REFERENCE GUIDE – A software reference for NeuralWorks Professional II/PLUS and NeuralWorks Explorer, 1998). Este modelo apresenta três camadas: uma camada de entrada, uma camada protótipo/intermediária e uma camada de saída. A primeira fase de treinamento da rede RBF compreende uma fase de *clustering*. Nesta fase, que será novamente abordada no que segue, os valores dos pesos que chegam à camada intermediária aprendem a ser os centros dos *clusters* dos vetores de entrada. Este agrupamento é implementado no *software NeuralWorks* dispondo-se do algoritmo referenciado como *Dynamic K-Means*. Do término desta primeira fase, o raio das funções Gaussianas centradas nos núcleos dos *clusters* são determinados usando a heurística “2 Nearest Neighbor”. O raio de uma dada função Gaussiana é determinado pela distância média dos dois centros dos *clusters* mais próximos. A segunda fase do treinamento ainda será exposta no que segue.

3.5.1 Arquitetura de uma rede RBF

Este tipo de RNA possui normalmente duas camadas, sem considerar nesta contagem, a camada de entrada que somente irá distribuir os padrões de entrada para a camada subsequente. A primeira camada, cujos elementos de processamento utilizam funções de base radiais, agrupa os dados de entrada em *clusters*. Esta camada transforma um conjunto de padrões de entrada não linearmente separáveis em um conjunto de saídas linearmente separáveis. A segunda camada, a camada de saída, procura classificar os padrões recebidos da camada anterior, sendo que estes são, em virtude da atuação da primeira camada, linearmente separáveis. Sendo assim, esta camada possui normalmente como função de ativação funções lineares

$$(y_j = \sum_i w_{ji} x_i).$$

Funções de base radial representam um tipo de função cujo valor diminui ou aumenta em relação à distância de um ponto central. Diversas funções podem ser utilizadas em redes RBF, sendo as mais comuns as funções Gaussiana (eq. 10), Multiquadrática (eq. 11) e a *Thin-Plate-Spline* (eq. 13), as quais possuem parâmetros básicos como o centro (μ) e a largura (σ) da função radial e são apresentadas no que segue.

$$\phi(x) = e^{-\left(\frac{v^2}{2\sigma^2}\right)} \quad (10)$$

$$\phi(x) = \sqrt{(v^2 + \sigma^2)} \quad (11)$$

$$\phi(x) = v^2 \log(v) \quad (12)$$

onde a distância Euclidiana $v = \|x - \mu\|$ do vetor de entrada x ao centro μ_i serve de entrada para a função, que retorna o valor de ativação da unidade intermediária. A resposta gerada por um neurônio de saída j , será (eq. 13):

$$y_j = \sum_{i=1}^K w_{ji} \phi(\|x - \mu_i\|) \quad (13)$$

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

3.5.2 Treinamento de uma rede RBF

Vários métodos são encontrados na literatura para o treinamento de redes RBF, sendo que na maioria das vezes o treinamento é classificado como híbrido, uma vez que este é dividido em dois estágios. No primeiro estágio, o número de funções radiais e seus parâmetros são determinados por métodos não supervisionados (métodos que se utilizam apenas dos dados de entrada). Esta etapa pode ser realizada escolhendo-se entre duas abordagens. Na primeira abordagem, os padrões de treinamento estão distribuídos de uma maneira representativa para o problema considerado, ou seja, os padrões são capazes de capturar as principais características do problema. Na segunda abordagem, técnicas de *clustering* são empregadas, onde, através de um aprendizado não supervisionado, os centros são estrategicamente posicionados em regiões no espaço onde estão situados os vetores de entrada mais representativos. A finalidade do algoritmo de treinamento para este primeiro estágio é de minimizar a soma dos quadrados das distâncias entre os vetores de entrada e o centro do conjunto ao qual eles pertencem.

Como já delineado, a função da camada intermediária da rede RBF é transformar um conjunto de exemplos não linearmente separável em um conjunto linearmente separável, o que simplifica o processamento realizado pela camada de saída. Para o segundo estágio do treinamento, ajusta-se os pesos das unidades de saída através de modelos lineares, já que o problema a ser solucionado reduz-se então a um problema linear. Diversos métodos têm sido desenvolvidos para ajustar os pesos desta camada como a Regra Delta e a Decomposição em Valores Singulares (BRAGA *et al.*, 1999).

A seguir, apresenta-se o algoritmo de treinamento para redes RBF. Para a primeira fase, utiliza-se o algoritmo de *clustering* conhecido como *K-Means-Clustering*, ou K-Médias (BRAGA, *et al.*, 1999), sendo que na segunda fase os pesos são ajustados através do cálculo da pseudo-inversa da matriz de ativação.

Primeiro estágio
(*K-Means-Clustering*)

Passo 1

Escolha o número de agrupamentos K

Passo 2

Associe aleatoriamente K vetores x^n aos K centros

Passo 3

Para todo vetor x^n associe o centro mais próximo através da distância Euclidiana

$$\text{distância} = \|x^n - \mu_j\|$$

Passo 4

Para cada subconjunto S_j calcule o novo centro

$$\mu_i = \frac{1}{N_j} \sum_{n \in S_j} x^n$$

onde N_j representa o número de vetores pertencentes ao conjunto S_j

Passo 5

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

Onde:

- K é o número de agrupamentos;
- N é o número de vetores,
- x^n é o conjunto de vetores de entrada a serem agrupados ($n = 1, \dots, N$);
- μ^j é o conjunto de vetores correspondentes aos centros dos agrupamentos ($j = 1, \dots, K$) e
- S_j é o conjunto dos vetores pertencentes ao agrupamentos j ($j = 1, \dots, K$).

Segundo estágio
(Ajuste dos pesos)

Considerando que as saídas da rede RBF são dadas por:

$$y_k(x) = \sum_{j=1}^K w_{kj} \phi_j(x) \quad (14)$$

Esta equação pode ser reescrita na notação matricial como:

$$y(x) = W\phi \quad (15)$$

onde $W = (w_{kj})$ e $\phi = (\phi_j)$. Como as funções de base radial são consideradas fixas, a rede RBF pode ser considerada equivalente a uma rede de uma única camada (BISCHOP, 1995) sendo que os seus pesos podem ser determinados através das seguintes equações lineares:

$$W^T = \Phi^T D \quad (16)$$

$$(D)_{nk} = d_k^n \quad (17)$$

$$(\Phi)_{nj} = \phi_j(x^n) \quad (18)$$

onde

- Φ^T simboliza a matriz pseudo-inversa de Φ ;
- k, j são símbolos utilizados como índices dos vetores y e ϕ e da matriz W ;
- y é o vetor de saída da rede RBF;
- W é a matriz de pesos da rede RBF;
- ϕ é o vetor de ativação da rede RBF,
- Φ é a matriz de ativação para todo o conjunto de treinamento e
- D é a matriz dos valores desejados para todo o conjunto de treinamento.

A demonstração dos algoritmos apresentados, bem como maiores detalhes podem ser encontrados em BISCHOP (1995).

4 VISÃO GERAL DO TRABALHO

A proteção de sistemas de energia é projetada para salvaguardar os equipamentos do sistema tais como geradores, transformadores, cabos e além disto, manter a integridade que é necessária para o fornecimento contínuo e econômico da energia elétrica. Se sobre determinado componente ocorrer uma situação de falta, este deve ser isolado tão rapidamente quanto possível do resto do sistema, preservando assim, a estabilidade do mesmo.

Para a proteção de linhas de transmissão, utilizam-se convencionalmente os valores das tensões e correntes trifásicas registrados para detectar, classificar e localizar determinada falta e então enviar um sinal para os circuitos de interrupção que irão desconectar a linha faltosa. Em um sistema interconectado, o sistema de transmissão restante poderá então operar normalmente ou pelo menos trabalhar o mais próximo possível das condições normais.

Frente às considerações apresentadas, para a implementação de um modelo completo de proteção de distância para linhas de transmissão é necessário, como primeiro passo, a **detecção** do defeito, ou seja, da situação de falta. Seguindo a esta, a confirmação e discriminação das fases envolvidas na falta (**classificação**) e finalmente a **localização** da mesma no que diz respeito à verificação das zonas de proteção deve ser efetuada. Assim, após esta seqüência de operações, haverá ou não a atuação dos disjuntores, quando conveniente.

Através da aplicação de RNAs, propõe-se um método alternativo para a proteção de linhas de transmissão, baseado em modelos que realizem as suas funções em um tempo menor, quando comparados aos dispositivos convencionais e que sejam imunes a mudanças operacionais do sistema. O incentivo para a aplicação de tal ferramenta vem da possibilidade de classificarmos a atuação de um sistema de proteção, como um problema de reconhecimento de padrões. Trabalhando com a

identificação e classificação da informação em categorias, acredita-se que seja possível **detectar, classificar e localizar** uma situação de falta utilizando-se da capacidade de generalização, abstração e tolerância a faltas, características estas inerentes a um sistema de redes neurais.

Para a aplicação de RNAs ao problema de reconhecimento de padrões, relacionado à 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, neste caso designado por *conjunto de dados*. Este conjunto de padrões que descreverá situações de faltas em que o sistema de proteção deverá ou não atuar, pode ser utilizado para o *treinamento supervisionado* ou *híbrido* (combinação entre um algoritmo não-supervisionado com um supervisionado) de RNAs. 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 operação do sistema de proteção.

Outro aspecto importante para a análise das principais características inerentes a RNAs é a elaboração de um segundo conjunto de padrões, caracterizando um *conjunto de teste* a ser aplicado sobre a arquitetura de RNA após a fase de treinamento. Sendo estas situações de faltas pertencentes ao conjunto de teste diferentes das situações utilizadas na fase de treinamento, será possível verificar a capacidade de generalização e adaptação da RNA às operações do sistema elétrico.

Sendo assim, uma vez completa a fase de treinamento e a de teste, a rede neural será capaz de fornecer as saídas desejadas não somente para entradas conhecidas, mas também a resposta mais plausível para qualquer entrada relacionada aos padrões treinados. Esta característica denota a capacidade de *generalização* da rede a partir de exemplos conhecidos, desde que estes sejam representativos. Dentre outras características, além da aprendizagem a partir de exemplos, a arquitetura da rede neural deve também apresentar a capacidade de abstração de características essenciais das 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.

Neste trabalho em específico, o *software NeuralWorks* será empregado para implementar as topologias de RNAs, treinando-as com o objetivo de se obter uma matriz de pesos fixos que descrevam todas as informações de operações presentes no sistema de transmissão. O *software* provê um ambiente flexível para a pesquisa, bem como para a aplicação das técnicas que envolvem a teoria de RNAs.

Devido às inúmeras situações aleatórias de faltas no sistema elétrico, o desempenho das redes neurais implementadas depende e muito da escolha de um conjunto representativo de treinamento e teste. Com relação ao sistema elétrico em condição faltosa, dispõe-se de simulações utilizando o *software ATP (Alternative Transients Program)* para obtenção do conjunto de dados. Por meio destas simulações busca-se uma aproximação às situações e características encontradas na prática. Com o uso de ferramentas destinadas às simulações, viabiliza-se a obtenção de dados próximos aos reais, já que estes, por condições técnicas ou financeiras, não são disponíveis de imediato. Deve ser mencionado que embora a técnica descrita é baseada em simulações computacionais, considerações práticas como o transformador de potencial capacitivo, amostragem do sinal (frequência de 1 kHz), filtro *anti-aliasing* (frequência de corte de 300 Hz) e erros de quantização da conversão analógico/digital, conforme ilustra a Figura 4, também foram incluídas. A técnica também considera o arranjo físico e características dos condutores, acoplamento mútuo e linhas transpostas.

A inclusão do filtro *anti-aliasing*, no sistema ilustrado, tem como objetivo reduzir as componentes harmônicas de alta frequência do sinal amostrado com frequências superiores a 1 kHz, evitando-se a sobreposição de espectros (efeito *aliasing*), segundo apresentado por PHADKE & THORP (1988). Conforme ilustra a Figura 4, faz parte do processamento dos dados uma conversão dos valores de tensões e correntes analógicos para os seus respectivos valores digitais. Neste estudo, empregou-se uma aproximação ao Conversor Analógico/Digital de 12 Bits, incluindo aos valores analisados de tensões e correntes os erros ou ruídos provenientes do processo.

A topologia do sistema elétrico analisado em todos os módulos é a representada na Figura 6 (capítulo 5 – a ser apresentado). Nas simulações, consideram-se também as características dos condutores e suas respectivas

disposições geométricas nas torres de transmissão. A estrutura da linha de transmissão de 440 kV (Figura 8, capítulo 5) corresponde a uma linha típica da CESP (Companhia Energética de São Paulo), empregada entre as cidades de Araraquara – Bauru e Jupia – Ilha Solteira.

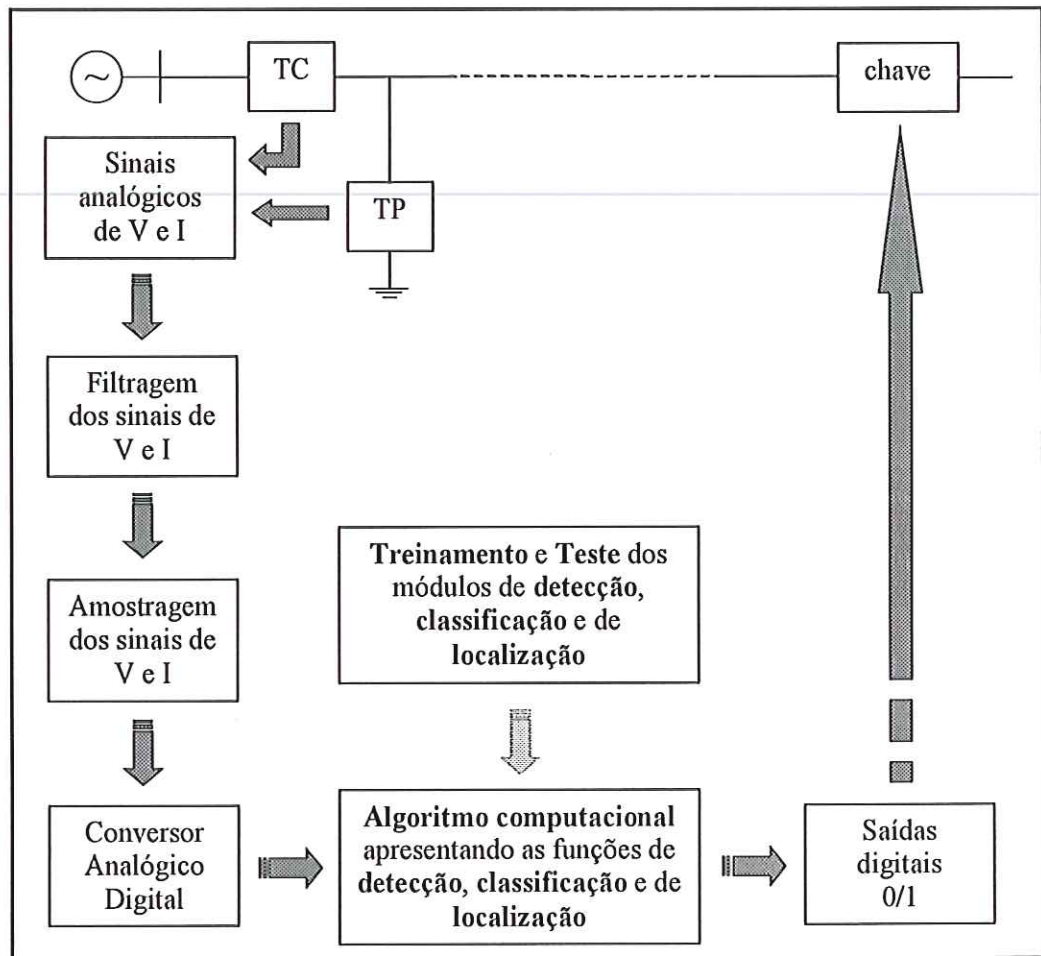


FIGURA 4 – Obtenção e análise dos dados

Todas as simulações foram realizadas sobre o sistema de transmissão (Figura 6, capítulo 5) tendo como variáveis:

- a distância em quilômetros de aplicação da falta, em relação a um determinado barramento;
- a resistência de falta entre fases e fase a terra;
- o ângulo de incidência da falta;

- o tipo de falta considerada e
- a condição de operação do sistema elétrico.

Lembra-se de que o objetivo de treinar os módulos de redes neurais é o de se obter as matrizes de pesos fixas (treinamento das RNAs, rotina *off-line*) as quais representarão todo o conhecimento armazenado do sistema de proteção. Com estas matrizes de pesos fixas, pode-se considerá-las através de um algoritmo computacional e obter as respostas desejadas sobre todas as condições de operação do sistema de transmissão (Figura 4).

Como apresentado anteriormente, o desenvolvimento do trabalho está dividido em módulos, que dizem respeito à implementação das arquiteturas de redes neurais para a **detecção, classificação e localização** da falta com a conseqüente atuação do sistema de proteção se necessário.

Na Figura 5, apresenta-se um modelo alternativo para a proteção no que diz respeito à aplicação de RNAs, o qual é o objetivo do trabalho. Para a Rede Neural Artificial 1 (RNA1), referente à **detecção** da falta, os valores trifásicos das tensões e correntes amostrados a uma frequência de 1 kHz, considerando-se amostras de pré e pós falta foram utilizados para treinar e testar a arquitetura. Observa-se pelos resultados encontrados que, com no máximo três amostras pós falta (3 ms), a rede é capaz de distinguir entre uma situação de falta à frente ou reversa a um determinado ponto do sistema ou ainda, se for o caso, acusar uma condição normal de operação. Com a confirmação de uma situação de falta em sentido reverso ou a frente do ponto escolhido, o módulo de classificação (RNA2) atua distinguindo as fases envolvidas entre os dez (10) tipos de faltas (dispondo-se de 4 a 9 ms após a ocorrência do surto). Consideram-se faltas equilibradas para o caso trifásico. Resta agora determinar as zonas de atuação dos relés de distâncias (a partir de 9 ms após a ocorrência da falta), para a conseqüente operação do sistema de proteção, as quais são indicadas pelas redes RNA3, RNA4 e RNA5.

Como será posteriormente evidenciado, considerando-se a frequência de amostragem empregada, estima-se um tempo médio computacional de todo o processo (**detecção + classificação + localização**) de 12 ms. Associada a esta “rapidez” na análise do sistema, espera-se obter altos índices de acertos nas respostas por parte das arquiteturas de RNAs implementadas. De antemão podemos informar

que um índice geral de acertos próximo a 97% para todos os 4050 diferentes situações de faltas analisadas foi obtido.

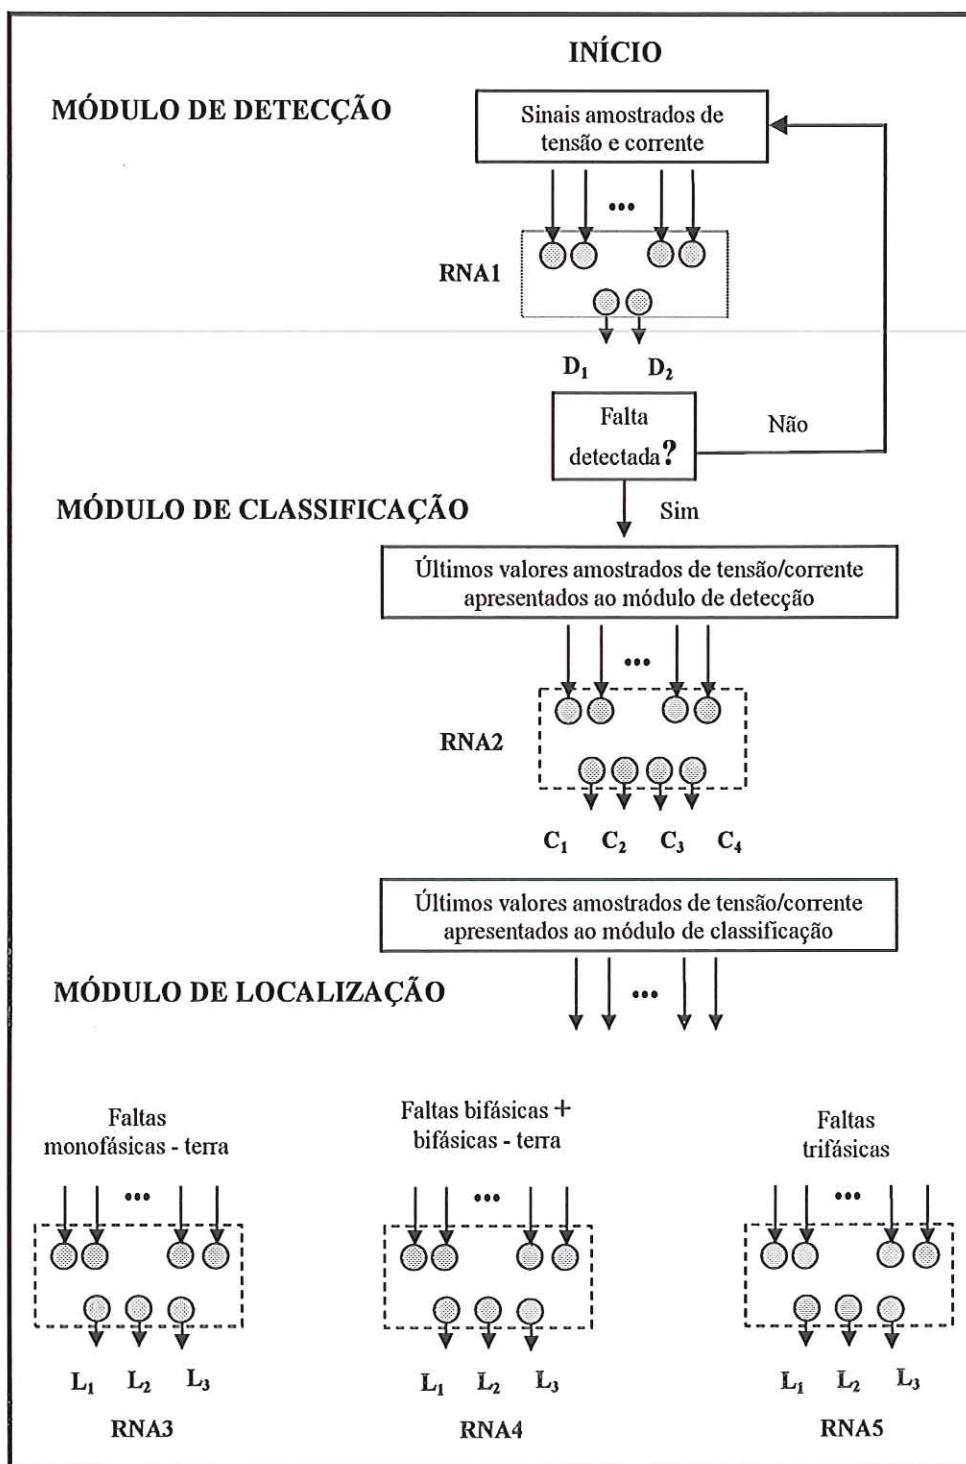


FIGURA 5 – Modelo alternativo para a proteção aplicando-se RNAs

Cabe mencionar que esta pesquisa foi desenvolvida em cooperação com o departamento de Engenharia Elétrica e Eletrônica da Universidade de Bath – Inglaterra. Desta interação, houve a possibilidade de realização, por parte do aluno, de um estágio na Universidade de *Bath* (13/08/98 a 05/02/99). A pessoa indicada para o acompanhamento das atividades no exterior foi o Professor Dr. Raj K. Aggarwall, tendo este, ampla experiência na área de aplicações de RNAs em proteção. Destes meses de estágio, além da revisão bibliográfica, definição do sistema a ser analisado e de tomar conhecimento do *software NeuralWorks*, iniciaram-se também, os trabalhos de treinamento e testes da arquitetura referente ao módulo de classificação. Acredita-se que a troca de informações e técnicas de abordagens neste período de estágio resultaram em uma melhor interpretação e solução para o problema exposto.

No que segue, serão apresentadas as considerações adotadas para o treinamento e um prévio teste das arquiteturas destinadas aos módulos de detecção (capítulo 6), classificação (capítulo 7) e de localização (capítulo 8). Para o capítulo 9, o principal enfoque será sobre o algoritmo computacional implementado em linguagem de programação “C”, cujos resultados obtidos serão apresentados e discutidos. Este algoritmo computacional visa à conexão de todos os módulos de redes neurais implementados e traz uma lógica seqüencial de análise dos sinais de tensões e correntes que também será convenientemente abordada.

5 O SISTEMA ELÉTRICO ANALISADO

Com o objetivo de treinar e 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 Alternative Transient Program* (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. Foram também consideradas as características dos condutores e suas respectivas disposições geométricas nas torres de transmissão.

5.1 Configuração do sistema de potência

O sistema elétrico em análise está representado na Figura 6, onde observam-se os seus quatro barramentos (D, E, F e G) que juntos representam três linhas de transmissão.




FIGURA 6 - Sistema elétrico analisado

Considerando-se os diferentes tipos de faltas que podem ocorrer sobre as linhas de transmissão, as simulações sobre o sistema apresentado foram geradas tomando-se as faltas entre:

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

Tais situações de faltas foram implementadas no *software* ATP conforme as combinações apresentadas na Figura 7.




FIGURA 7 – Situações de faltas sobre o sistema

* Combinações obtidas da tese de doutorado “*A practical approach to accurate fault location on extra high voltage teed feeders*”, Denis Vinicius Coury, Tese C858p – Biblioteca Central da Escola de Engenharia de São Carlos - Figura B.5.

5.2 Modelagem da linha de transmissão

A estrutura da linha de transmissão de 440 kV (Figura 8) corresponde a uma linha típica da CESP (Companhia Energética de São Paulo), empregada entre as cidades de Araraquara – Bauru e Jupiá – Ilha Solteira. Apresentam-se, no que segue, as especificações referentes aos condutores, denotando-se as suas principais características, bem como a resistividade do solo considerada.

Condutor de fase: cabo Grosbeak

- a) raio externo do condutor: 12,57 mm;
- b) raio interno do condutor: 4,635 mm;
- c) resistência em corrente contínua: 0.08998 Ω /km.

Cabos Pára-raios: EHS 3/8"

- a) raio externo do condutor: 4,572 mm;
- b) resistência em corrente contínua: 4,188 Ω /km.

Resistividade do solo

R_{solo} : 1000 Ω .km

Flecha a meio vão

fase: 13,43 m

pára-raios: 6,4 m

5.2.1 Parâmetros do sistema elétrico

Para se efetuar as devidas simulações do sistema elétrico proposto, utilizando-se do *software* ATP, adotaram-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 8. 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. O resultado esperado da transposição, segundo STEVENSON (1986),

será a mesma indutância média para cada condutor. Uma observação prática 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 9.




FIGURA 8 - Estrutura da linha de transmissão (440 kV) definindo seus principais parâmetros

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, 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 10 mostra-se um esquema monofásico representando um pequeno trecho (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 9 - Transposição de uma linha de transmissão

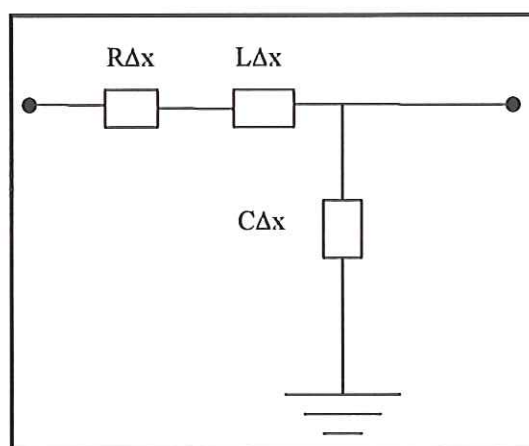


FIGURA 10 - Representação de um trecho de uma linha de transmissão por parâmetros distribuídos

5.2.2 Rotina *Line Constant* e arquivo de entrada para o *software* ATP

Após a caracterização da topologia das linhas de transmissão desejadas, passa-se ao início dos cálculos dos parâmetros que referem-se às mesmas. Apresenta-se na Figura 11 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 8. 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.

Com os resultados obtidos através da rotina *Line Constant*, considerando as linhas de transmissão com transposição e parâmetros distribuídos, elaborou-se um arquivo de entrada a ser executado pelo *software* ATP, o qual descreve a situação em que se encontra o sistema elétrico. Neste arquivo de entrada, todas as conexões do sistema estão representadas, bem como as condições referentes ao tipo de falta aplicada (localização, resistência e ângulo de incidência da falta, fluxo de energia no sistema) e demais considerações adotadas.

Conforme apresentado na Figura 4, também faz parte das simulações computacionais o transformador de potencial capacitivo (TPC). No entanto, a aplicação deste dispositivo pode acarretar em sérios problemas na proteção de distância com alta velocidade de atuação. Este fato decorre dos sérios erros na transformação dos sinais analisados que o TPC pode introduzir, devido ao seu mau desempenho no período transitório que segue a uma situação de falta. Os erros são causados principalmente em virtude do TPC ser um dispositivo ajustado para atuar na frequência de operação do sistema. Para sobrepor este problema, dispõe-se de divisores capacitivos que eliminam este ajuste de frequência com o circuito e provêem um preciso desempenho no período transitório. Um circuito básico do TPC é apresentado na Figura 12, onde C_1 e C_2 representam a capacitância do divisor de tensão, L_1 é um reator ajustável, V e V_s são respectivamente as tensões de linha e secundária do sistema. Fixou-se então o valor de C_1 em 2000 pF e V_2 em 12 kV e,

conforme apresentado em WARRINGTON (1977), da equação $V_2 = \frac{VC_1}{C_1 + C_2}$ obteve-se um valor aproximado de C_2 a ser empregado nas simulações.

```

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

C Condutores da primeira fase
1 .316 .0899 4    2.514 -9.67 23.67 10.20
1 .316 .0899 4    2.514 -9.67 24.47 11.04
1 .316 .0899 4    2.514 -8.87 24.47 11.04
1 .316 .0899 4    2.514 -8.87 23.67 10.20

C Condutores da segunda fase
2 .316 .0899 4    2.514 -0.40 27.27 13.84
2 .316 .0899 4    2.514 -0.40 28.07 14.64
2 .316 .0899 4    2.514 0.40 28.07 14.64
2 .316 .0899 4    2.514 0.40 27.27 13.84

C Condutores da terceira fase
3 .316 .0899 4    2.514 8.87 23.67 10.20
3 .316 .0899 4    2.514 8.87 24.47 11.04
3 .316 .0899 4    2.514 9.67 24.47 11.04
3 .316 .0899 4    2.514 9.67 23.67 10.20

C Condutores dos cabos pára-raios
0.5 4.188 4    0.914 -7.51 35.00 28.60
0.5 4.188 4    0.914 7.51 35.00 28.60

BLANK card ending conductor cards within "LINE CONSTANTS" data
250. 600.00    1 1 0    0

BLANK card ending frequency cards of "LINE CONSTANTS" data
BLANK card ending "LINE CONSTANTS" data cases
BLANK card ending all EMTP cases
    
```

FIGURA 11 – Arquivo de entrada para a rotina *Line Constant* descrevendo a topologia da linha de transmissão analisada




FIGURA 12 – Circuito básico de um transformador de potencial capacitivo

Com respeito ao Transformador de Corrente (TC), não se considerou uma precisa modelagem do mesmo. Para a atenuação das amplitudes dos sinais analisados, somente a relação de transformação do TC foi considerada, sem entrar em pormenores com relação ao seu efeito de saturação.

5.3 Filtro digital passa-baixa Butterworth

Com o objetivo de reduzir as componentes harmônicas de alta frequência do sinal amostrado, 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 com o 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 mostra ANTONIOU (1979). 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.

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

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). O filtro Butterworth implementado em linguagem de programação *Fortran* possui como parâmetros básicos uma frequência da banda de passagem e de atenuação de 300 e 400 Hz respectivamente, empregando-se uma frequência de amostragem de 1 kHz.





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

FIGURA 15 - Característica das perdas em um filtro passa-baixa real¹

5.4 Conversão analógico/digital dos valores amostrados

Ainda com respeito à obtenção e análise dos dados (Figura 4), restam algumas observações com respeito ao Conversor Analógico/Digital (CAD) adotado.

Um CAD converte um sinal analógico para a sua representação digital. A habilidade do conversor em representar um sinal analógico através de uma representação digital suficientemente detalhada está diretamente relacionada a sua resolução (Q), que por sua vez é expressa em termos de *bits* (N). A resolução do

CAD é fornecida por $Q = \frac{FV}{2^N}$, onde FV é a faixa dos valores analógicos considerada e N é o número de *bits* do conversor. Como exemplo, podemos considerar um sinal analógico que é caracterizado por uma faixa de ± 10 V. Com um CAD de 12 *bits*, cada bit representará 10/2048 V, ou seja, 4,883 mV (PHADKE & THORP, 1994). Tal aproximação ao CAD inclui aos sinais analisados um erro de quantização. Este erro, definido basicamente sobre os níveis de quantização (2^N), corresponde a diferença entre a entrada e a saída quantizada (expressa como um valor analógico), que também é um sinal variando entre $+Q/2$ e $-Q/2$, sendo denominado de ruído de quantização.

Durante todo o desenvolvimento do trabalho, considerou-se uma aproximação ao CAD de 12 *bits* sendo tal característica implementada através de um algoritmo computacional (linguagem de programação *Fortran*).

Relembrando novamente a figura que descreve a aquisição e análise dos dados (Figura 4), do instante da simulação de cada condição de falta pelo *software* ATP, segue um pré-processamento dos sinais. Este pré-processamento, conforme descrito, inclui a aplicação de um filtro passa-baixa Butterworth e a conversão analógica digital dos sinais. Sendo assim, acredita-se que os dados empregados na continuação do trabalho aproximam-se e realmente caracterizam as situações de operação do sistema, que por ventura venham a ser questionadas.

Dispondo-se das considerações apresentadas neste capítulo, efetuou-se um grande número de simulações computacionais do sistema elétrico sob condição de falta que serão empregadas para as fases de treinamento e de teste de todos os módulos de RNAs. Tais simulações serão devidamente justificadas e apresentadas no decorrer do documento.

¹ ANTONIOU (1979).

6 DETECÇÃO DE FALTAS EM LINHAS DE TRANSMISSÃO UTILIZANDO RNAS

Uma das técnicas bastante empregadas para a detecção de faltas em sistemas elétricos é baseada na teoria dos componentes simétricos. Do uso desta técnica resultam os fasores de seqüência positiva, negativa e zero, que requerem um processamento adequado quando usado em relés digitais e outras aplicações computacionais. Dentre as mais importantes considerações na computação dos fasores do sistema de energia estão a taxa de amostragem, filtros *antialiasing* e o tamanho da janela de dados empregada. Uma vez calculados os fasores dos componentes simétricos, uma específica análise de faltas pode ser aplicada para se determinar a ocorrência e o tipo de falta (KEZUNOVIC & RIKALO, 1996).

De outros apontamentos confirmados por BO *et al.* (1997a), constata-se que um sistema de proteção baseado na teoria das “ondas viajantes” ou sobre os sinais de frequência do sistema proporciona uma rápida atuação dos relés para a maioria dos sistemas e condições de faltas. No entanto, lapsos ou falhas podem ocorrer nas implementações que dispõem da teoria de “ondas viajantes”, como por exemplo, quando uma falta ocorre com um ângulo de incidência próximo a zero graus, já que, para esta situação, não serão gerados componentes significativos de ondas viajantes. Além deste problema, há a limitação da banda de passagem dos transdutores empregados, especialmente dos de tensão, a qual afeta a precisão e confiabilidades dos esquemas utilizados. Já a proteção, baseada nos transitórios de alta frequência, detecta a ocorrência de uma situação de falta baseada nos sinais de tensão ou corrente observados. Estes sinais em alta frequência são obtidos diretamente das saídas dos transformadores de corrente (TCs) e de potencial (TPs). Devido à limitação da banda de passagem dos convencionais transformadores de potencial (TPs), os sinais de tensão em alta frequência são medidos por um transdutor

especialmente projetado para tal aplicação. Empregando-se estes transdutores especialmente projetados para trabalhar com componentes de alta frequência, após certas modelagens, uma comparação entre as polaridades dos transitórios dos sinais de tensão e corrente, indicará a direção da situação de falta. Segundo VÁZQUEZ *et al.* (1996), a análise da situação de falta pelo monitoramento transitório é um método muito sensível para a detecção da mesma, a qual pode ser baseada na comparação entre as amostras do sinal real com as amostras calculadas, como por exemplo, por uma estimação das amostras, empregando-se o método dos mínimos-quadrados.

Considerando que a ocorrência de uma situação faltosa introduz alterações abruptas na amplitude e fase dos sinais de tensão (oscilações com alta frequência) e corrente (decaimento exponencial do componente *CC-offset*), podemos abordar a questão da detecção da falta como um problema de reconhecimento de padrões. Na presença de sinais de pré-falta e de componentes transitórios (pós-falta), as arquiteturas de RNAs podem ser treinadas para reconhecer a situação faltosa no seu instante de ocorrência.

Apresentam-se, no que segue, as observações tomadas para se implementar o módulo de detecção de faltas em linhas de transmissão, visando se obter uma arquitetura de rede neural que venha a desempenhar tal função. Ressalta-se que todas as considerações apresentadas para se definir o sistema elétrico analisado e a modelagem da linha de transmissão considerada serão também empregadas neste e nos demais módulos de classificação (capítulo 7) e de localização da falta no capítulo 8. Características exclusivas a cada módulo serão explicitadas convenientemente.

Para a detecção da falta temos, como objetivo, propiciar ao sistema de proteção uma maior área de cobertura, bem como, uma adequada sensibilidade à falta sem ameaçar a estabilidade quando se considera a carga e condições transitórias sobre o sistema.

Para esta e para as demais aproximações, foram utilizados, como valores de entradas para as arquiteturas de RNAs, as tensões e correntes trifásicas de pré (detecção) e pós-falta (para a detecção, classificação e localização) das situações analisadas, que serão comentadas posteriormente.

6.1 Simulações sobre o sistema analisado

Como início do trabalho, procurou-se formar um conjunto de dados que viesse a apresentar da melhor maneira possível à RNA1, as possíveis situações de ocorrência de faltas em linhas de transmissão. Sendo assim, com base no sistema elétrico em análise (Figura 6), nas possíveis combinações de faltas (Figura 7) e na estrutura da linha de transmissão (Figura 8), situações de faltas em sentido reverso (barramentos DE) e faltas em sentido à frente (barramentos EG) foram simuladas através do *software* ATP. O objetivo deste módulo de detecção é reconhecer entre estas situações de faltas ocorrendo em sentido reverso a determinado ponto do sistema elétrico (barramento E - onde são tomados os sinais de tensões e correntes analisados) ou faltas ocorrendo à frente deste mesmo ponto, bem como ainda reconhecer as situações normais de operação. Logo, valores de tensões e correntes que representassem as situações normais de operação também foram incluídas no conjunto de dados.

O conjunto de dados empregado para este módulo de detecção está ilustrado na Tabela 1. O mesmo é formado fazendo-se as possíveis combinações entre as localizações de aplicação das faltas, os três ângulos de incidência da falta (0° , 45° e 90°) e as três resistências de faltas entre fase-terra (0,1; 50,0 e 100,0 Ω) ou com as três resistências de faltas entre fase-fase (0,1; 0,5 e 1,0 Ω) quando fosse o caso.

Nesta aplicação, as tensões e correntes trifásicas pré e pós-falta com relação ao barramento E foram tomadas a uma frequência amostral de 1 kHz (sendo a frequência do sistema de 60 Hz). Três janelas de dados com quatro amostras cada foram consideradas. Estas janelas serão posteriormente explicadas.

Para as situações em sentido reverso, entre os barramentos DE, 19 localizações de faltas foram empregadas, o que nos deu um total de 171 situações para cada falta (19 localizações x 3 ângulos de incidência x 3 resistências). Considerando as três janelas de dados empregadas temos um total de 513 padrões (171 situações x 3 janelas de dados) para cada tipo de falta. Como das combinações dos tipos de faltas ilustradas na Figura 7 provém 10 tipos de faltas, estas situações reversas estão representadas no conjunto de dados por 5130 padrões (513 padrões para cada tipo de falta x 10 tipos de faltas).

TABELA 1 – Conjuntos de dados e testes utilizados para a detecção

NÚMERO DE PADRÕES EMPREGADOS	CONJUNTO DE DADOS				TESTES		
		- barramento DE: 5130 - barramento EG: 4860 - situação normal: 2016 Total: 12006 padrões Onde: Treinamento (9606) Validação (2400)				- barramento DE: 1440 - barramento EG: 1980 - situação normal: 84 Total: 3504 padrões	
LOCALIZAÇÕES (km)	Barramento DE				Barramento DE		
	6	7	8	10	8	15	25
	15	20	25	30	35	45	55
	35	40	45	50	65	72	
	55	60	65	70			
	72	73	74				
	Barramento EF				Barramento EF		
	86	90	100		90	100	130
	125	150	175		160	190	220
	200	220	224				
	Barramento FG				Barramento FG		
	236	240	255		240	250	280
270	285	300		310	320		
315	320	324					
RESISTÊNCIA DE FALTA (Ω)							
FASE-TERRA	0,1	50,0	100,0		30,0	60,0	90,0
FASE-FASE	0,1	0,5	1,0		0,3	0,6	0,9
ÂNGULO DE INCIDÊNCIA DA FALTA ($^{\circ}$)	0	45	90		30	60	

Nos casos de faltas em sentido à frente, 18 localizações foram empregadas entre os barramentos EG, permitindo formar 162 situações para cada tipo de falta (18 localizações x 3 ângulos x 3 resistências). Seguindo-se as observações levantadas para as situações em sentido reverso, encontram-se, no conjunto de dados, 4860 padrões que descrevem as situações de faltas aplicadas à frente do barramento E.

Para caracterizar as condições normais de operação, foram incluídos no conjunto de dados, 2016 padrões/janelas descrevendo as características normais do sistema.

Sendo assim, o conjunto de dados é formado por 12006 padrões, conforme ilustra a Tabela 1.

Neste trabalho (módulo de detecção, classificação e localização), para cada módulo o conjunto de dados é subdividido em um conjunto de treinamento e em um conjunto de validação. Este último é usado para avaliar a RNA durante a fase de treinamento; este procedimento é necessário para se evitar o sobre treinamento da RNA. Nesta situação, o processo de treinamento deve ser interrompido quando se alcançar o menor erro (*Root Mean Square Error - RMS*) para o conjunto de validação ainda na fase de treinamento. O tamanho do conjunto de treinamento e de validação corresponde a 80% (9606 padrões) e 20% (2400 padrões) de todos os exemplos do conjunto de dados respectivamente. Nos conjuntos de treinamento e validação utilizados, as condições de faltas apresentadas à RNA foram dispostas no arquivo de maneira aleatória.

Conforme afirmado no item 3.3, após o treinamento utilizando-se do conjunto de treinamento e de validação descritos acima, a rede neural deverá ser 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. Para validar tal afirmação, formulou-se um segundo conjunto de dados, designado agora por conjunto de teste, aonde situações de faltas diferentes das empregadas no conjunto de treinamento e validação foram simuladas. Este conjunto de testes apresenta um total de 3504 padrões conforme pode ser observado na Tabela 1. Como observado nesta, as combinações entre as localizações das faltas aplicadas, ângulos de incidência e resistências de faltas fase-terra e fase-fase, descrevem situações totalmente diferentes das empregadas na fase de treinamento da RNA1.

Cabe agora exemplificar a utilização das três janelas de dados utilizadas. Para o módulo de detecção empregaram-se três janelas de dados contendo cada uma, quatro amostras dos valores de tensões e correntes trifásicos dos sinais analisados (Figura 16).

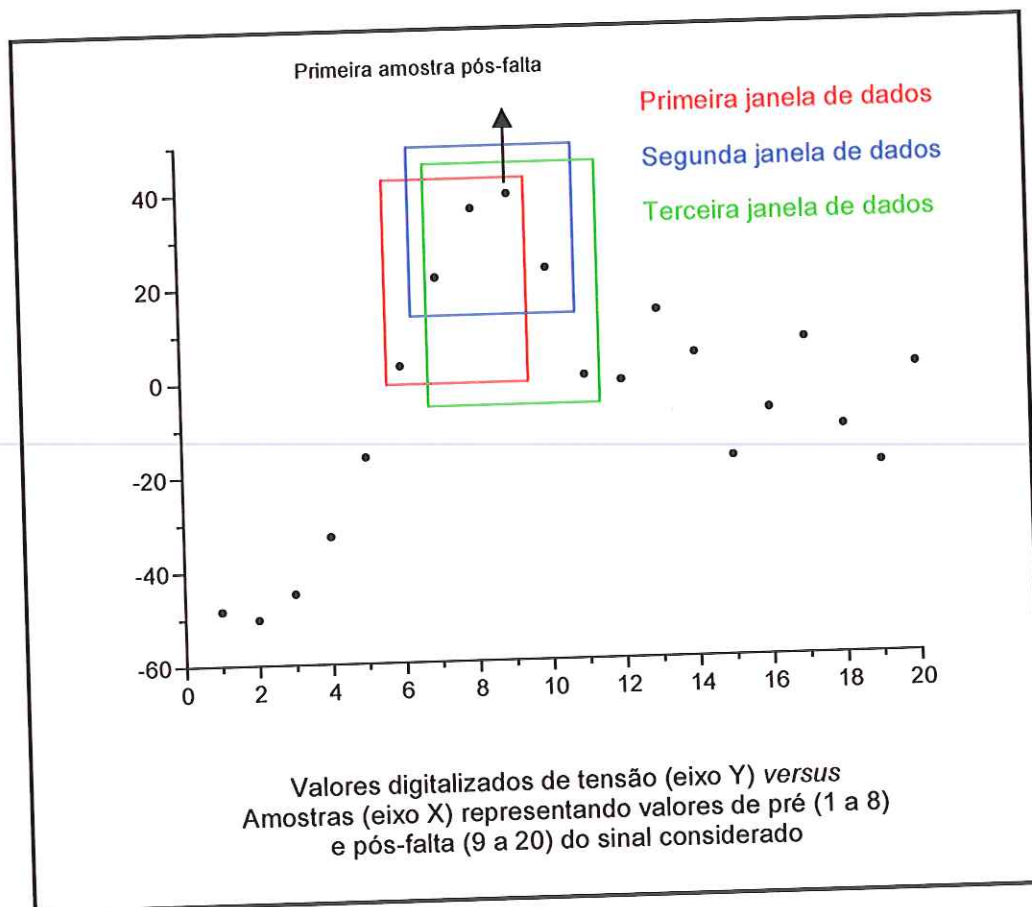


FIGURA 16 – As três janelas de dados empregadas para o módulo de detecção

Designando F como sendo o instante de aplicação da falta, a primeira janela de dados empregada contém os quatro valores amostrados das tensões nas fases A, B e C (VA_{F-2} , VA_{F-1} , VA_F , e VA_{F+1} , VB_{F-2} , VB_{F-1} , VB_F , e VB_{F+1} , VC_{F-2} , VC_{F-1} , VC_F , e VC_{F+1}), os quatro valores amostrados das correntes (IA_{F-2} , IA_{F-1} , IA_F , e IA_{F+1} , IB_{F-2} , IB_{F-1} , IB_F , e IB_{F+1} , IC_{F-2} , IC_{F-1} , IC_F , e IC_{F+1}), adicionando-se ainda à mesma janela, as duas respostas esperadas da RNA1 para a situação de falta apresentada (D_1 e D_2) que serão explicadas ainda neste item. Sendo F o instante de aplicação da falta, esta primeira janela de dados conterá então três valores amostrados de pré-falta (XX_{F-2} , XX_{F-1} e XX_F) e um valor amostrado de pós-falta (XX_{F+1}) dos sinais analisados, tanto para os valores amostrados de tensão como para os de corrente. Para a segunda janela de dados, deslocando-se 1 ms nas formas de ondas dos sinais avaliados, a mesma apresentará dois valores amostrados de pré e dois valores amostrados de pós-falta

dos sinais de tensões e correntes, bem como as respostas esperadas para tal situação, conforme pode ser observado na Figura 17.

Já para a terceira janela de dados, a mesma conterá 1 valor amostrado de pré e três valores amostrados de pós falta.

Assim, a intenção é de se obter uma correta avaliação do sistema (presença ou não de uma situação de falta em sentido reverso ou à frente de determinado ponto) em até, no máximo, 3 ms após a ocorrência do surto.

Primeira Janela	VA_{F-2}	VA_{F-1}	VA_F	VA_{F+1}	D_1	D_2
	VB_{F-2}	VB_{F-1}	VB_F	VB_{F+1}		
	VC_{F-2}	VC_{F-1}	VC_F	VC_{F+1}		
	IA_{F-2}	IA_{F-1}	IA_F	IA_{F+1}		
	IB_{F-2}	IB_{F-1}	IB_F	IB_{F+1}		
	IC_{F-2}	IC_{F-1}	IC_F	IC_{F+1}		
Segunda Janela	VA_{F-1}	VA_F	VA_{F+1}	VA_{F+2}	D_1	D_2
	VB_{F-1}	VB_F	VB_{F+1}	VB_{F+2}		
	VC_{F-1}	VC_F	VC_{F+1}	VC_{F+2}		
	IA_{F-1}	IA_F	IA_{F+1}	IA_{F+2}		
	IB_{F-1}	IB_F	IB_{F+1}	IB_{F+2}		
	IC_{F-1}	IC_F	IC_{F+1}	IC_{F+2}		
Terceira Janela	VA_F	VA_{F+1}	VA_{F+2}	VA_{F+3}	D_1	D_2
	VB_F	VB_{F+1}	VB_{F+2}	VB_{F+3}		
	VC_F	VC_{F+1}	VC_{F+2}	VC_{F+3}		
	IA_F	IA_{F+1}	IA_{F+2}	IA_{F+3}		
	IB_F	IB_{F+1}	IB_{F+2}	IB_{F+3}		
	IC_F	IC_{F+1}	IC_{F+2}	IC_{F+3}		

FIGURA 17 – Janelas de dados onde F representa o instante em que a falta foi aplicada

Na Tabela 2 ilustram-se as duas respostas esperadas por parte da RNA1. Nesta, se os padrões apresentados a RNA1, seja na fase de treinamento ou durante a fase de teste descreverem uma situação normal do sistema, a resposta deverá ser um valor próximo ou igual a 0 (zero) para as saídas D_1 e D_2 . Encontram-se também ilustradas na tabela, as respostas esperadas se situações de faltas reversas ou à frente forem observadas.

Para este módulo de detecção, convencionou-se que saídas D_1 e D_2 observadas no intervalo de 0 a 0,2 indicariam uma resposta igual a 0 (zero) e que valores situados entre o intervalo de 0,8 a 1,0, respostas iguais a 1 (um).

TABELA 2 – Respostas esperadas por parte da RNA1

SITUAÇÕES	D ₁	D ₂
Normal	0	0
Reversa (bar. DE)	1	0
À frente (bar. EG)	0	1

6.2 A utilização do software NeuralWorks para a detecção de faltas

O *software NeuralWorks* foi usado para implementar e treinar a topologia da RNA1 designada a este módulo de detecção, bem como para os demais (classificação e localização), para se obter os pesos apropriados que caracterizem as informações contidas nos conjuntos de dados.

Neste módulo específico, várias arquiteturas de redes neurais MLP (*Multi Layer Perceptron*) foram avaliadas, variando-se, como por exemplo, o número de elementos de processamentos (neurônios) na camada intermediária, taxas de aprendizagem e de momento, número de ciclos de treinamento e demais parâmetros quando convenientes. Ressalta-se que, além da procura de uma arquitetura que satisfizesse o esperado, a correta avaliação das condições do sistema, a escolha do número de situações/padrões e do número de janelas de dados empregadas para formar o conjunto de dados consumiu um tempo considerável. Apenas para ilustrar, treinando-se diversas arquiteturas de RNAs com apenas a primeira e a segunda janelas de dados descritas anteriormente, não se obteve nenhuma arquitetura que apresentasse um índice de acertos aceitável para o proposto.

Índices aceitáveis foram observados com uma arquitetura de rede neural que apresenta 24 unidades de processamento na sua camada de entrada (este número refere-se às 4 amostras empregadas para descrever cada um dos três valores de tensões e correntes amostrados), 9 unidades de processamento na camada intermediária e os 2 elementos na camada de saída (arquitetura 24-9-2). Esta arquitetura está representada na Figura 18.

Dos apontamentos anteriores relembra-se que a RNA1 foi treinada testando-se a mesma através de um conjunto de validação, cujo principal objetivo era de se

evitar o sobre treinamento. Assim, a arquitetura 24-9-2 alcançou um erro RMS mínimo (*Root Mean Square*) para o conjunto de validação de 0,0375 para todas as unidades na camada de saída, executado sobre um Pentium PC (333 MHz).

Utilizou-se do algoritmo supervisionado "*Norm-Cum-Delta Learning Rule*", uma variação do algoritmo *backpropagation* tanto para este módulo de detecção como para o de classificação e de localização, o qual é imune às alterações do tamanho da época (número de padrões aleatórios pertencentes ao conjunto de treinamento apresentados à arquitetura a cada iteração). Como uma alternativa para a função de transferência sigmoideal, a função de transferência tangente hiperbólica foi utilizada. A função de transferência tangente hiperbólica é muito similar à função sigmoideal em sua forma. Contudo, a faixa dos seus valores de saída compreende os valores de -1 a 1 , contrária a faixa da função sigmoideal que é de 0 a 1 . Observa-se, no entanto, que os valores de saída da função de transferência são usados como um multiplicador na equação de atualização dos pesos (algoritmo de treinamento *backpropagation* – HERTZ, 1991). Em virtude desta questão, uma faixa de valores de 0 a 1 significa um multiplicador pequeno, quando a soma total dos valores a serem consideradas em um determinado elemento de processamento possui um valor pequeno, ou, um alto multiplicador para valores elevados dessa soma. Desta análise, pode-se induzir a rede neural a uma predisposição em aprender somente as saídas desejadas com valores altos (aproximados a 1), já que as alterações nos pesos seriam maiores para valores altos da soma. No caso da função tangente hiperbólica, a mesma induz a uma distribuição dos pesos que favoreça tanto os valores baixos da soma a ser considerada pelo elemento como também para os valores altos.

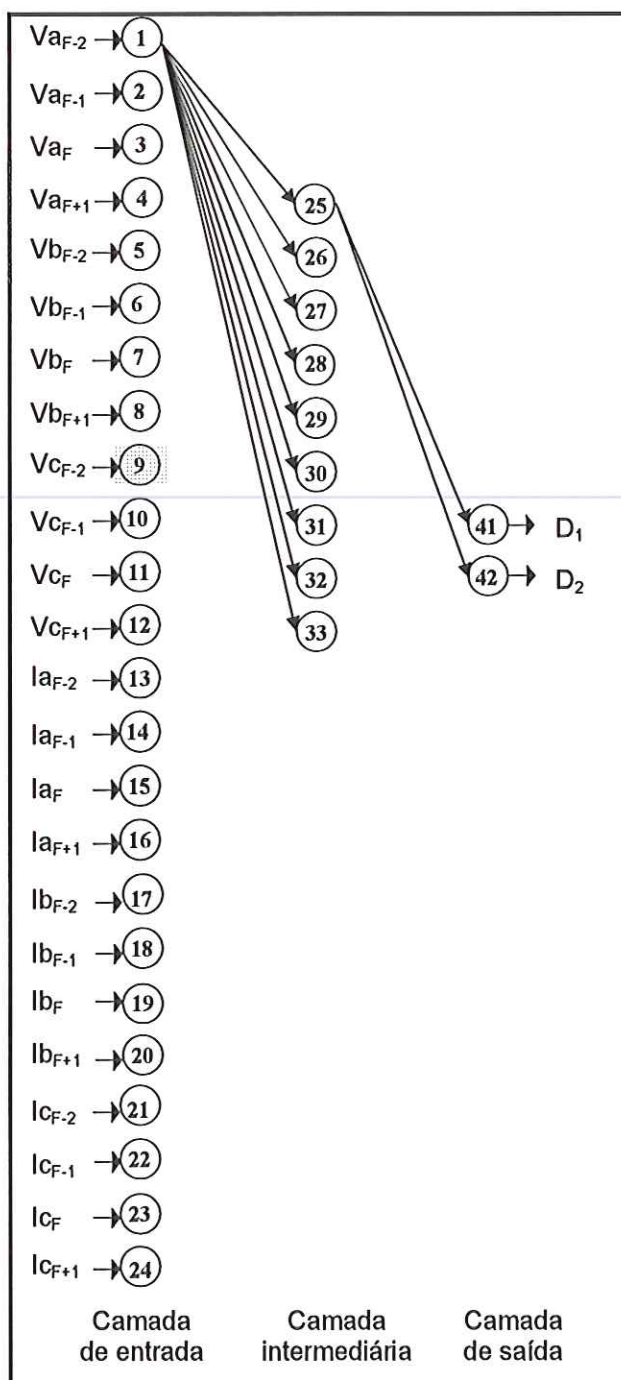


FIGURA 18 - Arquitetura da RNA1 implementada para o módulo de detecção

Uma causa comum de problemas encontrados no emprego de RNAs, além de uma faixa adequada de valores apresentados pelos dados, é que os valores devem ser apresentados em uma escala adequada para as funções de ativação e de saídas em uso. Por exemplo, uma rede *backpropagation* geralmente usa funções de transferência/ativação sigmoidal ou tangente hiperbólica. Se for apresentado à rede

valores tais como 10000, mesmo com pequenos pesos na rede, o somatório será grande e a função sigmoidal (ou tangente hiperbólica) se tornará saturada. Quando saturada, a derivada das duas funções comentadas é próximo a zero para grandes somas, tanto para valores positivos como negativos. Desde que a derivada é um multiplicador na equação de atualização dos pesos, a aprendizagem para os elementos de processamento com altos valores no somatório será seriamente comprometida. Estes elementos de processamento com a função sigmóide saturada, como exemplo, apresenta somas que são sempre muito baixas ou muito altas e a saída da função será sempre 0 ou 1.

O *software NeuralWorks* empregado neste trabalho aborda este problema com um simples pré processamento dos dados. O pré processamento registra os valores mínimos e máximos de cada campo do conjunto de dados do arquivo de entrada a ser usado com a rede. Sendo assim, para este trabalho, teremos sempre um valor de máximo e um de mínimo para cada um dos campos/variáveis utilizados (VA, VB, VC, IA, IB e IC). Estes valores de máximos e de mínimos são armazenados em uma tabela designada por "MinMax". Desta maneira são escolhidas quais as faixas de valores que a entrada e a saída devem ser escaladas para a apresentação à rede. Desta forma, uma escala adequada é considerada para cada campo/variável do conjunto de dados. Como já comentado neste item, empregou-se no trabalho a função de transferência tangente hiperbólica, que apresenta como saída valores contínuos entre -1 e 1. O *software NeuralWorks* dispõe então de um mapeamento dos valores de entrada do conjunto de dados onde todos permanecerão entre os valores de -1,0 e 1,0. Um ponto importante destas considerações, o uso dos valores de máximo e mínimo e do mapeamento em entradas bipolar, é que os mesmos valores que foram usados para escalar os valores durante a fase de treinamento são também utilizados para a fase de teste.

6.3 Resultados observados nos testes do módulo de detecção implementado pela RNA1

Na Tabela 3 apresentam-se os índices de acertos proporcionados pela RNA1 quando exposta ao conjunto de teste anteriormente formulado. O número entre parênteses nesta tabela, acima de cada percentagem, indica o número de acertos apresentados pela RNA1 frente ao número de padrões apresentados para cada tipo de falta.

Foram testados, além destes padrões do conjunto de teste, 84 padrões descrevendo as condições normais de operação do sistema, considerando-se ciclos completos dos sinais analisados. A RNA1 foi capaz de reconhecer todos os padrões (índice de acerto de 100%), classificando-os como condições normais de operação ($D_1 = 0$ e $D_2 = 0$).

TABELA 3 – Resposta da RNA1 frente ao conjunto de teste

PRIMEIRA JANELA DE DADOS – 114 PADRÕES PARA CADA TIPO DE FALTA (1 ms após a falta)										
Respostas	A-T*	B-T*	C-T*	AB	AC	BC	AB-T*	AC-T*	BC-T*	ABC
corretas	(114)	(110)	(92)	(103)	(108)	(114)	(112)	(114)	(114)	(90)
(%)	100,00	96,49	80,70	90,35	94,74	100,00	98,25	100,00	100,00	78,95
SEGUNDA JANELA DE DADOS – 114 PADRÕES PARA CADA TIPO DE FALTA (2 ms após a falta)										
Respostas	A-T*	B-T*	C-T*	AB	AC	BC	AB-T*	AC-T*	BC-T*	ABC
Corretas	(114)	(114)	(114)	(102)	(114)	(114)	(107)	(114)	(114)	(114)
(%)	100,00	100,00	100,00	89,47	100,00	100,00	93,86	100,00	100,00	100,00
TERCEIRA JANELA DE DADOS – 114 PADRÕES PARA CADA TIPO DE FALTA (3 ms após a falta)										
Respostas	A-T*	B-T*	C-T*	AB	AC	BC	AB-T*	AC-T*	BC-T*	ABC
Corretas	(114)	(112)	(114)	(114)	(114)	(90)	(114)	(114)	(90)	(114)
(%)	100,00	98,25	100,00	100,00	100,00	78,95	100,00	100,00	78,95	100,00

T* – falta a terra

Na Tabela 4 apresentam-se os índices gerais de acertos proporcionados pela RNA1 considerando-se que para cada janela de dados apresentada dispunha-se de 1140 padrões.

TABELA 4 – Análise global das respostas apresentadas pela RNA1 frente ao conjunto de teste

PRIMEIRA JANELA DE DADOS 1140 PADRÕES TESTADOS (114 PADRÕES x 10 TIPOS DE FALTAS) 1 ms após a falta	
Respostas	(1071)
Corretas	93,95%
SEGUNDA JANELA DE DADOS 1140 PADRÕES TESTADOS (114 PADRÕES x 10 TIPOS DE FALTAS) 2 ms após a falta	
Respostas	(1121)
Corretas	98,33%
TERCEIRA JANELA DE DADOS 1140 PADRÕES TESTADOS (114 PADRÕES x 10 TIPOS DE FALTAS) 3 ms após a falta	
Respostas	(1090)
Corretas	95,61%

Relembra-se que destes padrões apresentados à RNA1 durante a fase de teste, parte deles referem-se a situações de faltas aplicadas em sentido reverso ao barramento E e parte, referem-se às situações ditas à frente do mesmo barramento. Para melhor ilustrar os índices de acertos alcançados pela arquitetura 24-9-2 apresentam-se nas Tabelas 5 e 6 os índices observados para estas situações reversas e a frente do barramento E respectivamente.

Conforme a Tabela 1, verifica-se que foram aplicadas 48 situações de faltas em sentido reverso para cada tipo de falta (8 localizações x 2 ângulos x 3 resistências) perfazendo um total de 480 padrões (48 situações para cada tipo de falta x 10). Os índices de acerto observados para cada janela de dados são apresentados na Tabela 5.

Para as situações à frente, aplicaram-se 66 situações para cada tipo de falta (11 localizações x 2 ângulos x 3 resistências) o que nos leva a um conjunto de 660 padrões apresentados em cada janela de dados. Os índices observados para estas situações de faltas, encontram-se ilustrados na Tabela 6.

TABELA 5 – Análise global das respostas apresentadas pela RNA1 analisando-se as situações de faltas aplicadas em sentido reverso ao barramento E

PRIMEIRA JANELA DE DADOS 480 PADRÕES TESTADOS (48 PADRÕES x 10 TIPOS DE FALTAS) 1 ms após a falta	
Respostas	(421)
Corretas	87,71%
SEGUNDA JANELA DE DADOS 480 PADRÕES TESTADOS (48 PADRÕES x 10 TIPOS DE FALTAS) 2 ms após a falta	
Respostas	(461)
Corretas	96,04%
TERCEIRA JANELA DE DADOS 480 PADRÕES TESTADOS (48 PADRÕES x 10 TIPOS DE FALTAS) 3 ms após a falta	
Respostas	(430)
Corretas	89,58%

TABELA 6 – Análise global das respostas apresentadas pela RNA1 analisando-se as situações de faltas aplicadas em sentido à frente do barramento E

PRIMEIRA JANELA DE DADOS 660 PADRÕES TESTADOS (66 PADRÕES x 10 TIPOS DE FALTAS) 1 ms após a falta	
Respostas	(650)
Corretas	98,48%
SEGUNDA JANELA DE DADOS 660 PADRÕES TESTADOS (66 PADRÕES x 10 TIPOS DE FALTAS) 2 ms após a falta	
Respostas	(660)
Corretas	100,00%
TERCEIRA JANELA DE DADOS 660 PADRÕES TESTADOS (66 PADRÕES x 10 TIPOS DE FALTAS) 3 ms após a falta	
Respostas	(660)
Corretas	100,00%

Ainda exemplificando os índices observados, dispõem-se nas Tabelas 7 e 8 os valores apresentados pela arquitetura RNA1 quando sujeita a algumas situações de

faltas aplicadas em sentido reverso e à frente ao barramento E respectivamente. Comparando-se com valores apresentados na coluna “respostas esperadas”, verifica-se que as “respostas apresentadas” são muito próximas. Na maioria dos casos, esta proximidade já é constatada a partir da 2ª janela de dados.

Tendo-se uma correta avaliação da situação em que se encontra o sistema elétrico de potência em análise, faz-se necessário agora uma classificação no que diz respeito ao tipo de falta que ocorre sobre o mesmo. Se uma situação anormal for observada por este módulo de detecção, dispondo-se de até 3 ms após a falta, o módulo de classificação da falta será então ativado, sendo os valores de tensões e correntes trifásicos direcionados para tal análise. Esta será o assunto do próximo capítulo, que vem a abordar a classificação de faltas em linhas de transmissão utilizando redes neurais artificiais.

TABELA 7 – Valores das respostas apresentadas e esperadas por parte da RNAI frente a algumas situações de faltas aplicadas em sentido reverso ao barramento E

FALTA	JANELA	RESPOSTAS APRESENTADAS		RESPOSTAS ESPERADAS	
		S ₁	S ₂	S ₁	S ₂
A - terra	1ª	0,978871	0,028399	1,000000	0,000000
	2ª	0,999989	0,008933	1,000000	0,000000
	3ª	1,000000	0,000000	1,000000	0,000000
AB	1ª	0,780477	0,000111	1,000000	0,000000
	2ª	0,045203	0,008923	1,000000	0,000000
	3ª	0,999685	0,000000	1,000000	0,000000
AB - terra	1ª	0,999232	0,000000	1,000000	0,000000
	2ª	0,999587	0,000000	1,000000	0,000000
	3ª	1,000000	0,000000	1,000000	0,000000
AC	1ª	0,979101	0,002665	1,000000	0,000000
	2ª	1,000000	0,000000	1,000000	0,000000
	3ª	1,000000	0,000000	1,000000	0,000000
AC - terra	1ª	1,000000	0,000520	1,000000	0,000000
	2ª	1,000000	0,000000	1,000000	0,000000
	3ª	1,000000	0,000000	1,000000	0,000000
ABC	1ª	0,999166	0,000000	1,000000	0,000000
	2ª	0,999991	0,000000	1,000000	0,000000
	3ª	1,000000	0,000000	1,000000	0,000000

TABELA 8 – valores das respostas apresentadas e esperadas por parte da RNA1 frente a algumas situações de faltas aplicadas em sentido à frente ao barramento E

FALTA	JANELA	RESPOSTAS APRESENTADAS		RESPOSTAS ESPERADAS	
		S ₁	S ₂	S ₁	S ₂
A - terra	1 ^a	0,000000	1,000000	0,000000	1,000000
	2 ^a	0,000000	1,000000	0,000000	1,000000
	3 ^a	0,000000	1,000000	0,000000	1,000000
AB	1 ^a	0,000000	1,000000	0,000000	1,000000
	2 ^a	0,000000	1,000000	0,000000	1,000000
	3 ^a	0,000000	0,999974	0,000000	1,000000
AB - terra	1 ^a	0,000000	1,000000	0,000000	1,000000
	2 ^a	0,000000	1,000000	0,000000	1,000000
	3 ^a	0,000000	0,999994	0,000000	1,000000
AC	1 ^a	0,000006	0,999971	0,000000	1,000000
	2 ^a	0,000000	1,000000	0,000000	1,000000
	3 ^a	0,000000	1,000000	0,000000	1,000000
AC - terra	1 ^a	0,000000	1,000000	0,000000	1,000000
	2 ^a	0,000000	1,000000	0,000000	1,000000
	3 ^a	0,000000	1,000000	0,000000	1,000000
ABC	1 ^a	0,000000	1,000000	0,000000	1,000000
	2 ^a	0,000000	1,000000	0,000000	1,000000
	3 ^a	0,000000	0,999962	0,000000	1,000000

Apesar de termos encontrando uma arquitetura capaz de diferenciar corretamente uma situação normal de uma anormal no sistema, ressalta-se que o objetivo final para este módulo ainda não foi alcançado. Conforme apresentado no capítulo 4, tendo-se a matriz de peso fixa, a meta passa a ser a implementação de um algoritmo computacional que venha a reconhecer tais situações normais e/ou anormais. Este algoritmo, em conjunto com a implementação dos demais módulos (classificação e localização) é que deverá proporcionar uma completa proteção e atuação sobre o sistema de potência em análise. Tal algoritmo será apresentado posteriormente, com o seguimento da pesquisa.

7 CLASSIFICAÇÃO DE FALTAS EM LINHAS DE TRANSMISSÃO UTILIZANDO RNAs

Com respeito a classificação de uma situação faltosa, um considerável número de propostas convencionais é encontrado na literatura (PHADKE & THORP, 1988). Vários métodos utilizam-se do cálculo dos fasores das correntes de linha trifásicas e da corrente de seqüência zero dispendo da Transformada de *Fourier*. Apesar das limitações, em geral as rotinas de classificação da falta baseadas nesta transformada produzem uma correta classificação da falta frente as mais variadas condições em que o sistema se encontra. Outros métodos, como o apresentado por GIRGIS (1981), baseiam-se na estimação do estado da corrente pelo Filtro de *Kalman*, de onde também resultam bons resultados.

Nesta fase do trabalho, serão apresentadas as principais considerações e observações tomadas no uso de RNAs para a implementação do módulo classificador de faltas. Este módulo para a seleção da(s) fase(s) faltosa(s) é tão importante quanto o da detecção da falta, decorrendo da correta classificação a garantia da estabilidade e disponibilidade do sistema. Sendo assim, a RNA2 implementada deverá adquirir o conhecimento para a correta classificação das situações de faltas dentre as diversas ocorrências apresentadas.

Relembra-se que todas as observações do capítulo 5, que dizem respeito ao sistema elétrico em análise, bem como a modelagem da estrutura da linha de transmissão e demais parâmetros são também válidos e adotados no que segue.

7.1 Simulações sobre o sistema analisado

Para formar um conjunto de dados representativo foram simuladas 1380 diferentes situações de faltas sobre o sistema de transmissão, variando-se a localização da falta com relação ao barramento E (Figura 6), resistência e ângulo de incidência da falta (Tabela 9). Estas situações de faltas, 138 situações de cada possível tipo de falta, formaram o conjunto de treinamento e de validação que serão posteriormente comentados. O conjunto de teste foi formado por 840 diferentes situações de faltas variando-se os mesmos parâmetros como também pode ser observado na Tabela 9.

TABELA 9 – Conjuntos de dados e testes utilizados para o módulo de classificação

NÚMERO DE PADRÕES EMPREGADOS	CONJUNTO DE DADOS			TESTES		
	6900 Treinamento (5520) Validação (1380)			4200		
LOCALIZAÇÕES (km)	Barramento DE			Barramento DE		
	6	10	25	15	30	45
	40	55	70	60		
	74					
	Barramento EF			Barramento EF		
	86	100	125	90	115	140
	150	175	200	165	190	215
	220	224				
	Barramento FG			Barramento FG		
236	240	255	240	265	290	
270	285	300	315			
315	324					
RESISTÊNCIA DE FALTA (Ω)						
FASE-TERRA	0,1	50,0	100,0	30,0	60,0	90,0
FASE-FASE	0,1	0,5	1,0	0,3	0,6	0,9
ÂNGULO DE INCIDÊNCIA DA FALTA ($^{\circ}$)						
	0	90		30	60	

Para esta aplicação, as tensões e correntes trifásicas pós-falta com relação ao barramento E foram também tomadas a uma frequência amostral de 1 kHz (sendo a frequência do sistema de 60 Hz). Cinco janelas de dados com quatro amostras cada

foram consideradas. Fixaram-se as segundas amostras de tensões e correntes pós-faltas como sendo os valores iniciais a serem considerados na primeira janela de dados. A Figura 19 mostra as cinco janelas de dados adotadas para uma condição de falta. Nesta ilustração apresentam-se as cinco janelas correspondentes a fase A para uma situação de falta fase A - terra. Já na Figura 20, exemplifica-se como os valores dos sinais analisados foram alocados para a formação de um conjunto de dados. Nesta figura também é ilustrado o movimento dos dados nas janelas subsequentes onde há a troca das amostras consideradas. A janela 1 contém quatro amostras das tensões pós-falta ($VA_2, VA_3, VA_4, VA_5, VB_2, VB_3, VB_4, VB_5, VC_2, VC_3, VC_4$ e VC_5). Também estão inclusas, nesta janela, as quatro amostras relativas às correntes pós-falta ($IA_2, IA_3, IA_4, IA_5, IB_2, IB_3, IB_4, IB_5, IC_2, IC_3, IC_4$ e IC_5) com a respectiva resposta esperada por parte da rede neural para uma situação de falta ao longo da linha de transmissão (C_1, C_2, C_3 e C_4). Como um exemplo, uma situação que caracterize uma falta fase A – terra relaciona-se às respostas $C_1 = 1, C_4 = 1$ com C_2 e $C_3 = 0$. A Tabela 10 mostra as respostas esperadas por parte da arquitetura RNA2 relacionadas às fases A (C_1), B (C_2) e C (C_3) e a conexão a terra (C_4) para todas as condições de faltas consideradas.

Para esta aplicação, o intervalo dos valores de 0-0,2 foram considerados como uma resposta por parte da RNA2 igual a 0 (zero) e os valores compreendidos entre 0,8-1 como uma resposta igual a 1 (um). Os outros valores foram considerados como casos incertos.

Como ilustrado, cinco janelas de dados representam cada condição de falta. Assim, o conjunto de dados é formado através de 6900 situações (1380 situações de faltas x 5 janelas de dados).

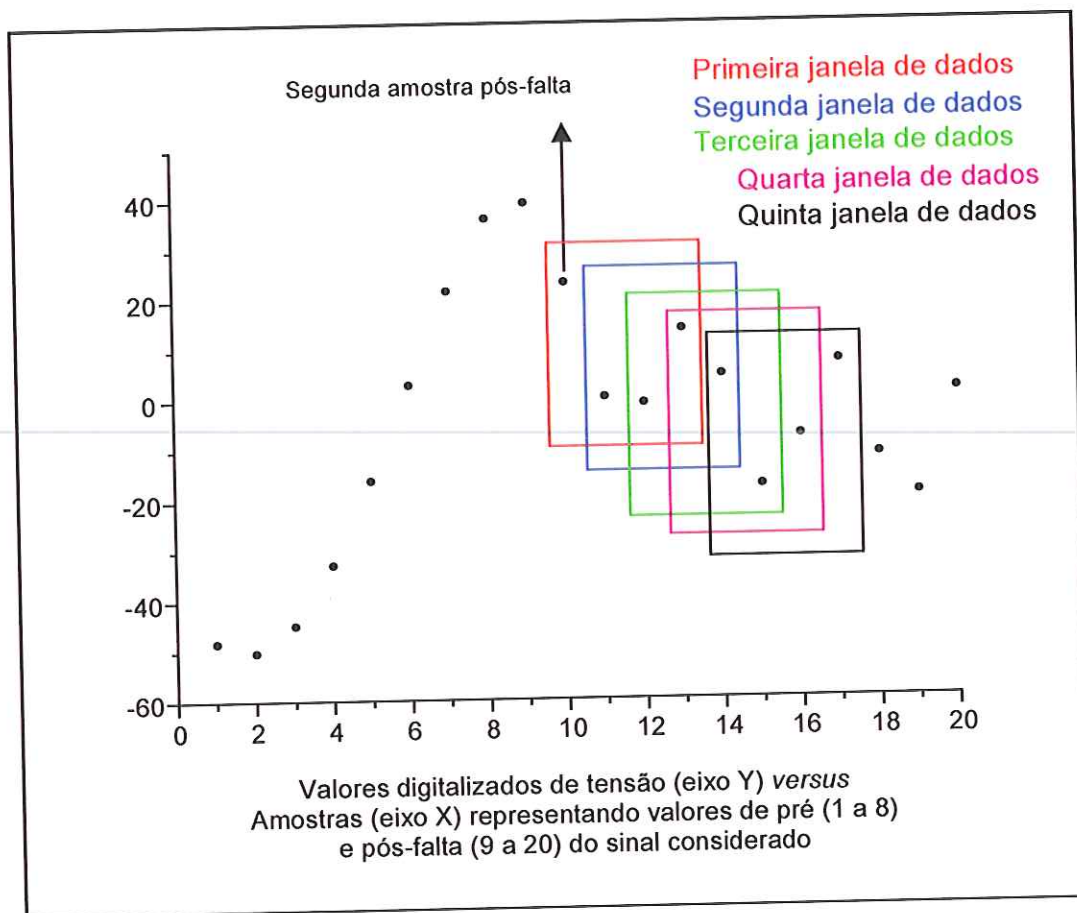


FIGURA 19 – As cinco janelas de dados empregadas para o módulo de classificação

Primeira Janela	VA ₂	VA ₃	VA ₄	VA ₅	C ₁ C ₂ C ₃ C ₄
	VB ₂	VB ₃	VB ₄	VB ₅	
	VC ₂	VC ₃	VC ₄	VC ₅	
	IA ₂	IA ₃	IA ₄	IA ₅	
	IB ₂	IB ₃	IB ₄	IB ₅	
	IC ₂	IC ₃	IC ₄	IC ₅	
Segunda Janela	VA ₃	VA ₄	VA ₅	VA ₆	C ₁ C ₂ C ₃ C ₄
	VB ₃	VB ₄	VB ₅	VB ₆	
	VC ₃	VC ₄	VC ₅	VC ₆	
	IA ₃	IA ₄	IA ₅	IA ₆	
	IB ₃	IB ₄	IB ₅	IB ₆	
	IC ₃	IC ₄	IC ₅	IC ₆	
Terceira Janela	VA ₄	VA ₅	VA ₆	VA ₇	C ₁ C ₂ C ₃ C ₄
	VB ₄	VB ₅	VB ₆	VB ₇	
	VC ₄	VC ₅	VC ₆	VC ₇	
	IA ₄	IA ₅	IA ₆	IA ₇	
	IB ₄	IB ₅	IB ₆	IB ₇	
	IC ₄	IC ₅	IC ₆	IC ₇	
Quarta Janela	VA ₅	VA ₆	VA ₇	VA ₈	C ₁ C ₂ C ₃ C ₄
	VB ₅	VB ₆	VB ₇	VB ₈	
	VC ₅	VC ₆	VC ₇	VC ₈	
	IA ₅	IA ₆	IA ₇	IA ₈	
	IB ₅	IB ₆	IB ₇	IB ₈	
	IC ₅	IC ₆	IC ₇	IC ₈	
Quinta Janela	VA ₆	VA ₇	VA ₈	VA ₉	C ₁ C ₂ C ₃ C ₄
	VB ₆	VB ₇	VB ₈	VB ₉	
	VC ₆	VC ₇	VC ₈	VC ₉	
	IA ₆	IA ₇	IA ₈	IA ₉	
	IB ₆	IB ₇	IB ₈	IB ₉	
	IC ₆	IC ₇	IC ₈	IC ₉	

FIGURA 20 – Janelas de dados utilizadas para o módulo de classificação

TABELA 10 – Respostas esperadas por parte da RNA2

SITUAÇÕES DE FALTAS	RESPOSTAS ESPERADAS			
	C ₁ Fase A	C ₂ Fase B	C ₃ Fase C	C ₄ Terra
Fase A – Terra	1	0	0	1
Fase B – Terra	0	1	0	1
Fase C – Terra	0	0	1	1
Fase AB	1	1	0	0
Fase AC	1	0	1	0
Fase BC	0	1	1	0
Fase AB – Terra	1	1	0	1
Fase AC – Terra	1	0	1	1
Fase BC – Terra	0	1	1	1
Fase ABC	1	1	1	0

7.2 A utilização do software NeuralWorks para a classificação de faltas

Como já comentado, utilizou-se dos valores pós-falta das tensões e correntes trifásicas amostrados a 1 kHz dispostos através de cinco janelas de dados. Como resposta, a arquitetura RNA2 implementada deve apresentar valores iguais ou próximos a um (1) ou zero (0), mostrando se a falta envolveu as fases A (C1), B (C2) e C (C3) ou não. A saída (C4) foi designada para indicar se a falta envolveu uma conexão a terra.

Diferentes topologias de redes neurais MLP (*Multi Layer Perceptron*) foram avaliadas em um total aproximado de 30 redes. O melhor desempenho observado refere-se a uma rede neural com uma camada escondida. Esta arquitetura apresenta 24 unidades de processamento na camada de entrada, 16 unidades na camada escondida e uma camada de saída com 4 unidades de processamento (Figura 21).

Para a fase de treinamento, utilizou-se do algoritmo supervisionado "*Norm-Cum-Delta Learning Rule*", empregando-se a função de transferência tangente hiperbólica.

O processo de treinamento alcançou um erro (RMS) de validação mínimo de 0.1041 para todas as unidades na camada de saída, executado sobre um Pentium PC (333 MHz). Os pesos da arquitetura após a convergência foram então armazenados, uma vez que o critério evitando-se o sobre-treinamento (menor erro para o conjunto de validação) foi respeitado.

A Tabela 11 mostra a percentagem de respostas corretas da arquitetura empregada sujeita ao conjunto de teste formado por cinco janelas de dados para cada condição de falta. Atenta-se ao fato de que os números colocados entre parênteses, acima da percentagem de respostas corretas, referem-se ao número de acertos apresentado pela arquitetura de RNA2 entre as amostras destinadas a cada janela (84 amostras para cada janela de dados e tipo de falta).

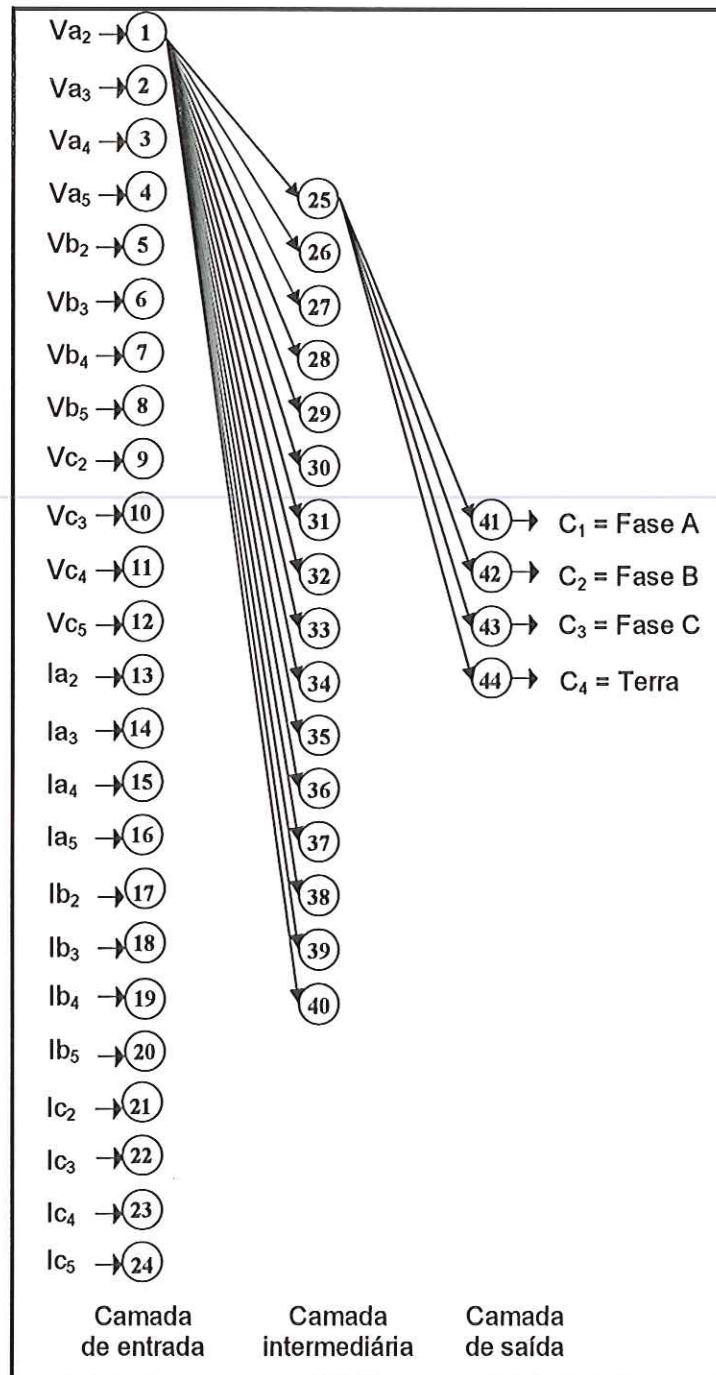


FIGURA 21 - Arquitetura da RNA2 implementada para o módulo de classificação

TABELA 11 – Resposta da RNA2 frente ao conjunto de teste

PRIMEIRA JANELA DE DADOS – 84 PADRÕES PARA CADA TIPO DE FALTA (5ms após a falta)										
Respostas	A-T*	B-T*	C-T*	AB	AC	BC	AB-T*	AC-T*	BC-T*	ABC
corretas	(82)	(83)	(83)	(74)	(67)	(44)	(54)	(84)	(84)	(72)
(%)	97,62	98,81	98,81	91,67	79,76	52,38	64,29	100,00	100,00	86,91
SEGUNDA JANELA DE DADOS – 84 PADRÕES PARA CADA TIPO DE FALTA (6ms após a falta)										
Respostas	A-T*	B-T*	C-T*	AB	AC	BC	AB-T*	AC-T*	BC-T*	ABC
Corretas	(81)	(84)	(82)	(70)	(81)	(73)	(64)	(84)	(84)	(69)
(%)	96,43	100,00	97,62	83,33	96,43	86,90	76,19	100,00	100,00	82,14
TERCEIRA JANELA DE DADOS – 84 PADRÕES PARA CADA TIPO DE FALTA (7ms após a falta)										
Respostas	A-T*	B-T*	C-T*	AB	AC	BC	AB-T*	AC-T*	BC-T*	ABC
corretas	(84)	(81)	(83)	(75)	(84)	(82)	(81)	(81)	(84)	(63)
(%)	100,00	96,43	98,81	89,29	100,00	97,62	96,43	96,43	100,00	75,00
QUARTA JANELA DE DADOS – 84 PADRÕES PARA CADA TIPO DE FALTA (8ms após a falta)										
Respostas	A-T*	B-T*	C-T*	AB	AC	BC	AB-T*	AC-T*	BC-T*	ABC
corretas	(84)	(84)	(84)	(84)	(84)	(79)	(84)	(83)	(78)	(73)
(%)	100,00	100,00	100,0	100,00	100,00	94,05	100,00	98,81	92,86	86,90
QUINTA JANELA DE DADOS – 84 PADRÕES PARA CADA TIPO DE FALTA (9ms após a falta)										
Respostas	A-T*	B-T*	C-T*	AB	AC	BC	AB-T*	AC-T*	BC-T*	ABC
corretas	(82)	(84)	(84)	(81)	(84)	(63)	(81)	(84)	(63)	(73)
(%)	97,62	100,00	100,00	96,43	100,00	75,00	96,43	100,00	75,00	86,90
RESPOSTAS CORRETAS FRENTE AOS 420 PADRÕES TESTADOS (5 JANELAS DE DADOS x 84 PADRÕES) PARA CADA TIPO DE FALTA										
Respostas	A-T*	B-T*	C-T*	AB	AC	BC	AB-T*	AC-T*	BC-T*	ABC
corretas	(413)	(416)	(416)	(387)	(400)	(341)	(364)	(416)	(393)	(350)
(%)	98,33	99,05	99,05	92,14	95,24	81,19	86,66	99,05	94,29	83,33

T* – falta a terra

Para a Tabela 12, reserva-se uma análise global das respostas apresentadas pela RNA2 frente ao conjunto de teste, apresentando-se os índices gerais de acertos para cada uma das cinco janelas de dados consideradas. Nota-se que para aproximadamente 92,77% de todos os 4200 padrões testados (840 padrões testados em cada janela de dados x 5 janelas de dados) encontrou-se a resposta esperada por parte da RNA2. Valor este observado quando da apresentação da quinta janela de dados.

TABELA 12 – Análise global das respostas apresentadas pela RNA2 frente ao conjunto de teste

PRIMEIRA JANELA DE DADOS	
840 PADRÕES TESTADOS (84 PADRÕES x 10 TIPOS DE FALTAS) - 5ms após a falta	
Respostas	(730)
Corretas	86,91%
SEGUNDA JANELA DE DADOS	
840 PADRÕES TESTADOS (84 PADRÕES x 10 TIPOS DE FALTAS) - 6ms após a falta	
Respostas	(772)
Corretas	91,91%
TERCEIRA JANELA DE DADOS	
840 PADRÕES TESTADOS (84 PADRÕES x 10 TIPOS DE FALTAS) - 7ms após a falta	
Respostas	(798)
corretas	95,00%
QUARTA JANELA DE DADOS	
840 PADRÕES TESTADOS (84 PADRÕES x 10 TIPOS DE FALTAS) - 8ms após a falta	
Respostas	(817)
corretas	97,26%
QUINTA JANELA DE DADOS	
840 PADRÕES TESTADOS (84 PADRÕES x 10 TIPOS DE FALTAS) - 9ms após a falta	
Respostas	(790)
corretas	94,05%
RESPOSTAS CORRETAS FRENTE AOS 4200 PADRÕES TESTADOS (5 JANELAS DE DADOS x 840 PADRÕES)	
Respostas	(3896)
Corretas	92,77%

Como ilustração, as Figuras 22 a 25 apresentam as respostas apresentadas pela RNA2 nas cinco consecutivas janelas de dados frente a uma situação de falta aplicada a (s) fase (s) **A - terra, BC, AC – terra e ABC** respectivamente. A situação diz respeito a uma falta aplicada a 6 km do barramento E (Figura 6), com uma resistência de falta fase – terra e fase – fase de $0,1 \Omega$, com um ângulo de incidência da falta de 90° . Tais respostas podem ser comparadas com os valores apresentados na Tabela 10. Como observado nesta tabela, para uma situação de falta que envolva a fase **A - terra**, as saídas C_1 e C_4 devem apresentar valores iguais ou próximos a um (1). Para as saídas C_2 e C_3 os mesmos devem ser próximos ou iguais a zero (0). Como pode ser visualizado, a RNA2 manteve estes valores próximos aos desejados

(Tabela 10) para as situações de faltas apresentadas (Figuras 22 - 25). Atenta-se ao fato de que estes padrões do conjunto de teste são completamente diferentes do conjunto de treinamento utilizado, conforme pode ser evidenciado pela Tabela 9 apresentada.

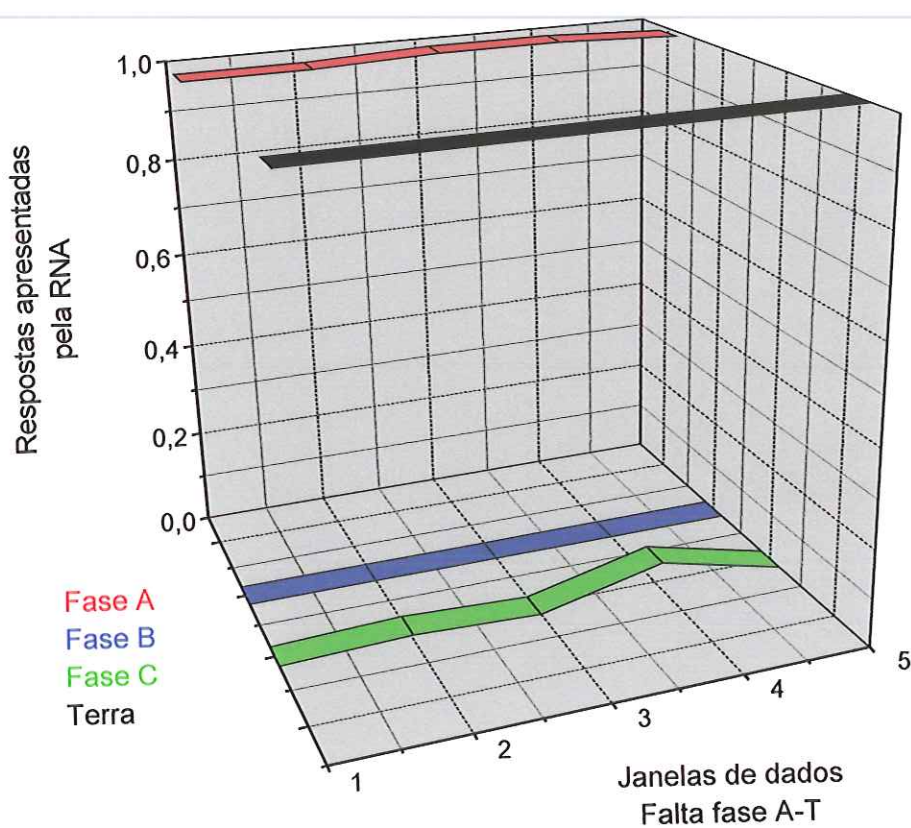


FIGURA 22 – Situação de falta aplicada à fase A – terra




FIGURA 23 – Situação de falta aplicada às fases BC

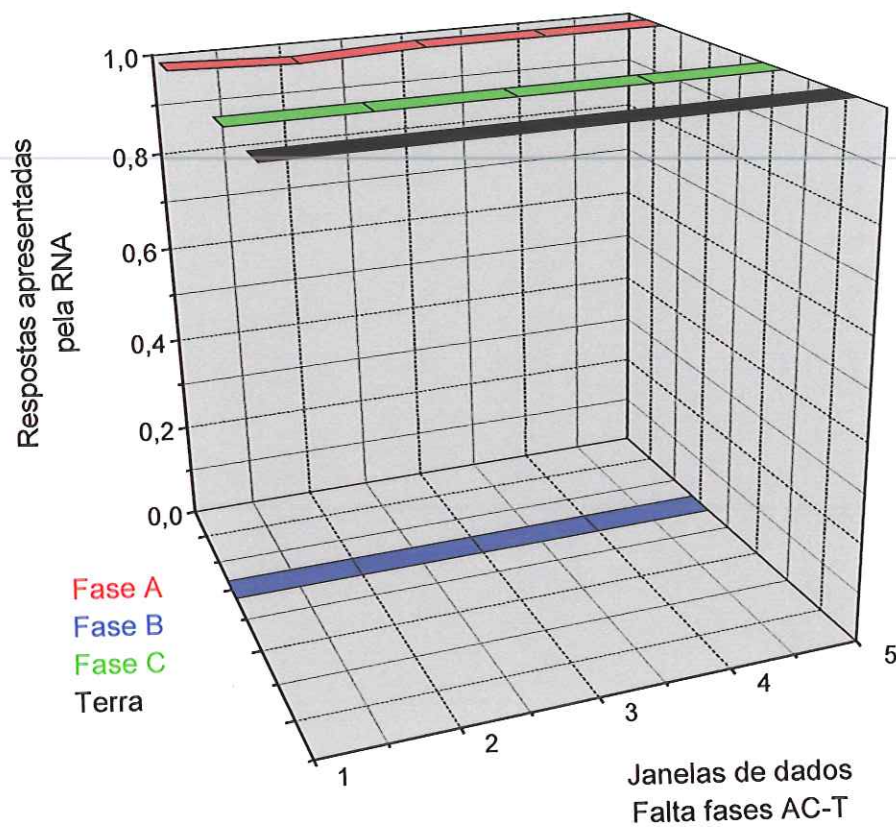


FIGURA 24 – Situação de falta aplicada às fases AC – terra

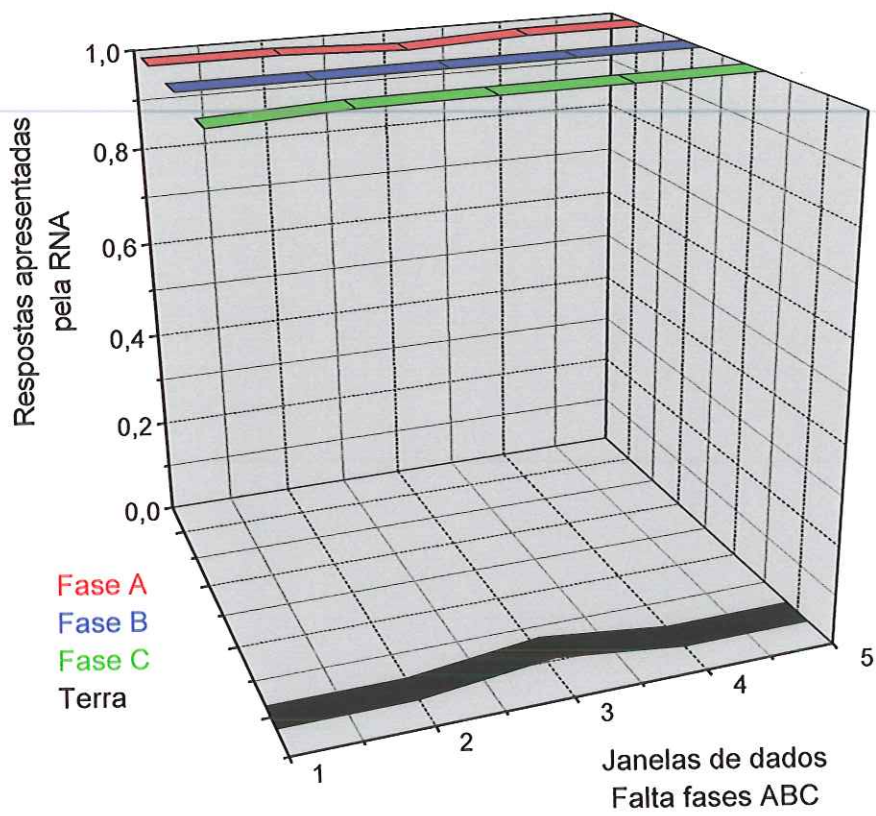


FIGURA 25 – Situação de falta aplicada às fases ABC

7.3 Observações gerais

Os resultados obtidos ilustram que o desempenho global da arquitetura é satisfatório para classificação de faltas no sistema. Deve ser destacado que, para aproximadamente 92,77% de todos os 4200 padrões testados, obteve-se as corretas respostas por parte da RNA2.

Nas respostas apresentadas pela rede, o que se verificou, na grande maioria das situações erroneamente classificadas, é o envolvimento do terra quando este não estava presente ou uma situação contrária. Como se consideraram 5 janelas de dados para representar cada situação de falta, a rede apresentou muitas das vezes um erro de classificação nas 5 janelas. Em outros casos, 3 acertos e dois erros para cada conjunto de 5 janelas. Analisando-se as respostas apresentadas pela RNA2, quando da apresentação da 1ª, 2ª, 3ª, 4ª e da 5ª janela de dados, podemos computar o número de acertos e erros para cada situação de falta. Sendo assim, obtendo-se a resposta final para a classificação desta análise*, temos os seguintes índices de acertos para a mesma:

- considerando-se somente a primeira janela de dados, 5 ms após a ocorrência da falta, um índice total de acertos correspondente a 86,90%;
- como comentado, em muitas situações a rede apresentou uma resposta errônea para a primeira janela, mas acertou nas segunda e terceira janelas, ou acertou na primeira e terceira janelas e errou na segunda. Analisando então até a terceira janela de dados e, computando as corretas e errôneas classificações das duas primeiras janelas, este índice de acertos total passa para 95,00% (7 ms após a ocorrência da falta);
- se tal análise for estendida à quarta e quinta janela de dados, temos ao final do processo um índice total de acertos de 99,16%. Este dispendo-se de 9 ms após a ocorrência da falta.

Como observado, com a terceira janela de dados, já encontramos um ótimo índice de acertos por parte da RNA2 (95,00%). Deste ponto, como apresentado na Figura 5 (capítulo 4) os sinais analisados de tensões e correntes poderiam ser

* Esta análise do número de acertos e erros da RNA2 frente as cinco janelas de dados foi empregada apenas como efeito ilustrativo, sendo diferente da lógica computacional implementada

direcionados para o(s) módulo(s) responsável (eis) pela localização da falta nas respectivas zonas de proteção do relé. A confirmação da(s) fase(s) envolvida(s) com ou sem o envolvimento do terra viria com a quinta janela de dados e assim, se ainda não fosse obtida a correta localização, só este módulo atuaria a partir deste momento.

Este tempo gasto para a tomada da decisão na classificação vem em muito melhorar o desempenho dos dispositivos de proteção já que, pelos métodos convencionais já referenciados neste capítulo, esta é realizada dispondo de no mínimo 8 a 10 ms com um índice geral de acertos em torno de 90%. Pela análise apresentada, poderíamos ter uma classificação do tipo de falta envolvido dispondo de 7 ms pós falta, com um índice total de acertos de 95,00%. Vale destacar que para a maioria das situações de faltas que ocorrem em um sistema de transmissão (faltas envolvendo uma fase a terra), o índice de acertos alcançados pela arquitetura RNA2 atinge aproximadamente 98%, já com a primeira janela de dados considerada. Ou seja, com 5 ms após a ocorrência da situação de falta a rede já foi capaz de classificar corretamente tais situações.

Volta-se, agora, ao objetivo do uso de RNAs na classificação de faltas sobre um sistema elétrico de potência. Procurou-se obter, através do já exposto, uma arquitetura de RNA que satisfizesse um índice satisfatório para a classificação correta entre os dez tipos de faltas consideradas. De posse de tal arquitetura, com a sua matriz de pesos fixa (que contém todas as informações do sistema), os próximos passos dizem respeito a implementar um algoritmo computacional que venha a repetir ou melhorar os índices alcançados na classificação. A implementação de tal algoritmo nos permitirá processar as informações das classificações apresentadas pela RNA2, acompanhando as suas respostas à medida que as janelas de dados forem sendo apresentadas à rede. A lógica da implementação computacional adotada será devidamente abordada no capítulo 9, sendo os resultados observados extensivamente ilustrados no capítulo 10.

8 LOCALIZAÇÃO DE FALTAS EM LINHAS DE TRANSMISSÃO UTILIZANDO RNAs

Para iniciarmos a apresentação deste tópico, ressaltamos que o progresso na área de proteção de sistemas é um pré-requisito vital para uma eficiente operação e desenvolvimento contínuo dos sistemas de energia como um todo.

Como já mencionado, para a proteção das linhas de transmissão, frente às possíveis situações de faltas, diferentes tipos de relés convencionais são utilizados. Os mais freqüentemente 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. Muitos algoritmos têm sido propostos para o cálculo da impedância aparente (PHADKE & THORP, 1988) sendo o algoritmo de *Fourier* (considerando um ciclo do sinal em análise) amplamente empregado. Este algoritmo dispõe dos valores amostrais consecutivos dos sinais das tensões e correntes e extrai os seus componentes na freqüência fundamental. Tal procedimento necessita da aplicação de técnicas de compensação para se evitar um sobre alcance da área de atuação do relé devido à presença da resistência de falta. O tempo de operação deste relé é de aproximadamente um ciclo na freqüência fundamental.

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 se explica 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 (1977), o relé

mede um valor de impedância superior a da linha, devido à impedância da carga conectada à mesma.

Se uma falta sólida ocorrer (Figura 26a), 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 (Figura 26b) 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_{l1}), 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 85 a 90% do comprimento da linha, segundo HOROWITZ & PHADKE (1996). 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. Consequentemente, 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. Tratando-se da zona de proteção secundária, usualmente a mesma é definida como tendo um alcance que varia de 120 a 150% do comprimento da linha de transmissão a ser protegida. Para a terceira zona de proteção um comprimento que corresponde de 120 a 180% do comprimento da próxima seção de linha é desejado, conforme ainda a última referência bibliográfica citada.

Neste trabalho em específico, tomando-se como referência o sistema elétrico apresentado na Figura 6, as zonas de proteção foram consideradas com as seguintes proporções:

- a) Zona de proteção primária: até 142,5 km a partir do barramento E, o que corresponde a 95% da LT2 de 150 km;
- b) Primeira zona de transição: $142,5 \pm 2,85$ km a partir do barramento E, o que corresponde a um índice de incerteza de $\pm 2\%$ sobre os 142,5 km considerados para a zona de proteção primária;
- c) Zona de proteção secundária: até 195 km a partir do barramento E, o que corresponde a 130% da LT2 de 150 km;

- d) Segunda zona de transição: $195 \pm 3,9$ km a partir do barramento E ($\pm 2\%$ de 195 km) e
- e) Zona de proteção terciária: até 240 km a partir do barramento E o que corresponde a 150% da LT2 de 150 km.
 160%

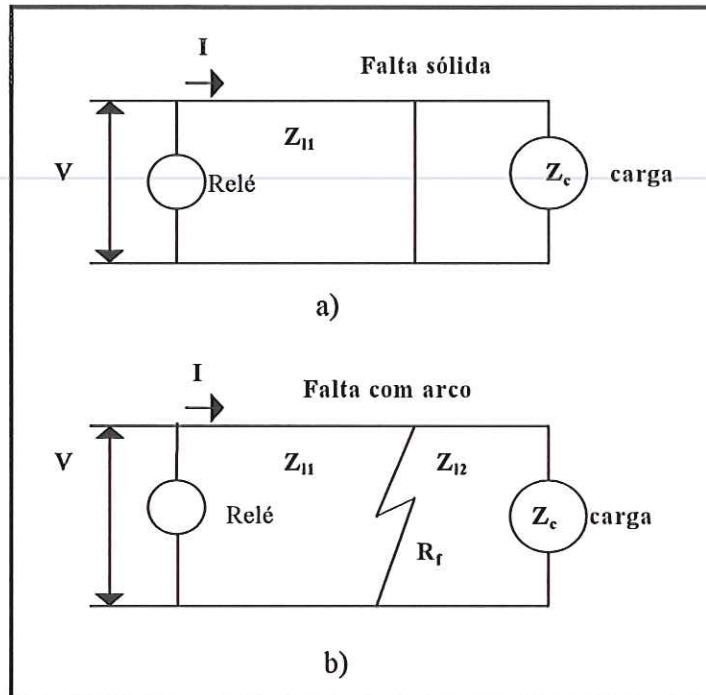


FIGURA 26 - Impedância medida pelo relé devido as considerações elétricas

As duas zonas de transição mencionadas (primeira e segunda zonas de transição) resultam do fato da alteração dos valores próximos ou iguais a 0 (zero) para valores próximos ou iguais a 1 (um), ou vice-versa, que devem ser apresentados pela RNA quando da mudança entre as zonas de proteção. O que caracteriza esta transição à rede é a passagem pelo ponto (distância) de 142,5 km para a zona de proteção primária e o ponto (distância) de 195 km para a zona de proteção secundária, ambas tomadas com relação ao barramento E. Assim sendo, como há a alteração entre os valores esperados como respostas, há uma pequena área de transição para a rede onde valores ou localizações errôneas são esperadas. Esta área para a zona de proteção primária está definida como $\pm 2\%$ de 142,5 km (variando de 139,65 km a 145,35 km) e para a zona de proteção secundária variando de 191,1 a 198,9 km ($\pm 2\%$ de 195 km).

Para a implementação do módulo de localização, três RNAs foram treinadas e implementadas, conforme mostra o projeto de pesquisa apresentado no capítulo 4, Figura 5. As três RNAs referem-se aos três agrupamentos a que foram alocados os diversos tipos de falta. A RNA3 designa-se a localizar as faltas do tipo fase – terra (A – terra, B – terra e C – terra) sobre o sistema elétrico em questão. O segundo grupo refere-se às faltas do tipo fase – fase (AB, AC e BC) e fase – fase – terra (AB – terra, AC – terra e BC – terra), sendo a RNA4 elaborada para tal objetivo. O terceiro grupo refere-se às faltas trifásicas (fases ABC) e está representado pela RNA5. No tocante a este trabalho, somente os valores amostrados dos sinais de tensões e correntes pós-falta foram empregados para a distinção dentre as zonas de proteção (zona 1, 2 ou 3) que incide determinada situação de falta. Índices razoáveis de acertos foram obtidos pelo modelo proposto. No modelo apresentado, as zonas de atuação dos relés de distâncias eram indicadas pelas redes RNA3, RNA4 e RNA5 a partir de 9 ms após a ocorrência da falta.

Como será posteriormente apresentado, as cinco redes neurais (RNA1, 2, 3, 4 e 5) responderam com bons índices de acertos frente às novas situações de testes, onde parâmetros como a localização, resistência e ângulo de incidência da falta foram alterados após o processo de treinamento pertinente a cada rede. Mesmo para faltas apresentando um alto valor de resistência fase-terra (até 400 Ω) o conjunto de redes apresentou um desempenho condizente com o esperado, já que as mesmas, foram condicionadas a um valor máximo de resistência de falta de 100 Ω durante o treinamento. No entanto, variando-se o fluxo de energia sobre o sistema em -3° , houve um sobre alcance entre as zonas de proteção, principalmente com relação ao limite da primeira zona de proteção. A solução para tal problema veio então da aplicação da teoria de Componentes Superpostos, que também será convenientemente abordada no que segue.

Nos itens que seguem, será apresentado como estas implementações foram realizadas e os resultados esperados/encontrados para cada agrupamento de faltas. Lembra-se que para este módulo, têm-se como objetivo encontrar arquiteturas de redes neurais que apresentem uma localização confiável das situações de faltas. Sendo assim, após o processo de treinamento, com a conseqüente convergência em torno de parâmetros comuns à rede (pesos e demais parâmetros fixos), espera-se que

as redes possam ser implementadas e agrupadas aos demais módulos - detecção e classificação - em um algoritmo computacional final, que será apresentado brevemente.

8.1 A localização de faltas fase – terra

Como apontado anteriormente, para esta rede (RNA3) designa-se a localização de situações de faltas envolvendo uma fase a terra sobre o sistema. Sendo assim, a rede neural associada apresenta três unidades de processamento em sua camada de saída, cada uma sendo responsável por uma área de localização. A saída L_1 relaciona-se à zona de proteção primária e as saídas L_2 e L_3 às zonas de proteções secundária e terciária respectivamente. Esta mesma associação às zonas de proteção também será mantida para as demais redes que compõem este módulo (RNA4 e RNA5). Neste módulo, saídas com valores próximos ou iguais a 0 (zero) indicam o não envolvimento da área de proteção e saídas com valores iguais ou próximos a 1 (um) o envolvimento, ou seja, a ocorrência de uma situação de falta na zona de proteção indicada. Os valores intermediários a 0,2 e 0,8 indicam a indecisão da rede em localizar a situação de falta apresentada. As respostas esperadas, por parte da rede neural, estão ilustradas na Tabela 13 que segue. Para as demais redes que compreendem o módulo de localização (para faltas fase - fase, fase – fase – terra e faltas trifásicas) esta tabela também será válida, conforme será evidenciado.

TABELA 13 – Respostas esperadas por parte da RNA para a localização

ZONAS DE PROTEÇÃO	L_1	L_2	L_3
PRIMÁRIA	1	0	0
SECUNDÁRIA	0	1	0
TERCIÁRIA	0	0	1

Para formular o conjunto de dados utilizado para o treinamento da arquitetura RNA3, fez-se a combinação dos parâmetros apresentados na Tabela 14. Desta combinação, resulta um número total de 14700 padrões que descrevem as três situações de faltas fase - terra estudadas. Na tabela, observam-se as localizações (km)

das situações de faltas simuladas com relação ao barramento E, os cinco valores de resistências de faltas fase - terra empregados, bem como, os cinco valores de ângulos de incidência da falta adotados para este tópico. O conjunto de treinamento corresponde a 80% do conjunto de dados (80% de 14700 padrões) e o conjunto de validação a 20% do mesmo (20% de 14700 padrões).

Para uma prévia análise do desempenho das redes neurais que compõem este módulo de localização (RNA3, 4 e 5), um conjunto de teste formado por 324 diferentes situações para cada tipo de falta foi elaborado. Na Tabela 14 apresentam-se as variações dos dados empregados e a combinação entre os mesmos é realizada como no conjunto de treinamento. Estes mesmos parâmetros foram utilizados para formar os conjuntos de testes para as demais redes (RNA4 e RNA5), observando-se no entanto, os diferentes valores de resistências de faltas pertinentes a cada tipo de falta considerada.

A primeira janela de dados apresentada às redes 3, 4 e 5 durante o processo de treinamento corresponde a 10ª janela de dados. Durante o processo de treinamento das redes, os sinais analisados foram considerados dispondo-se de 5 a 7 janelas de dados, com quatro valores amostrados de cada sinal trifásico, o que corresponde a um tempo situado entre 7 e 13 ms pós-falta. Já para o conjunto de teste, o número de janelas de dados apresentadas à rede corresponde a três.

8.1.1 A arquitetura escolhida

Uma observação coerente diz respeito ao número de camadas intermediárias empregadas na tarefa de localização. Constatou-se, pela análise do desempenho das arquiteturas treinadas, que mesmo considerando somente um tipo de falta (como por exemplo, faltas envolvendo a fase A com conexão a terra), são necessárias duas camadas intermediárias para a rede apresentar resultados aceitáveis, os quais se comparam aos apresentados por uma rede treinada englobando os três tipos de faltas fase – terra.

TABELA 14 – Conjuntos de dados e testes utilizados para a localização (RNA3)

NÚMERO DE PADRÕES EMPREGADOS	CONJUNTO DE DADOS					TESTES		
		1225 situações por tipo de falta - 4 janelas de dados - faltas fase - terra Total: 14700 padrões - Treinamento: 11760 - Validação: 2940					324 situações por tipo de falta - 3 janelas de dados Total: 2916 padrões (faltas fase - terra)	
LOCALIZAÇÕES (KM)	Barramento EF					Barramento EF		
	86	90	95			88	105	115
	100	110	120			125	135	145
	130	140	150			155	165	175
	160	170	180			185	195	202
	190	200	205			208	212	218
	210	215	218			222	223	225
	220	221	222,5					
	224	225	228					
	Barramento FG					Barramento FG		
	233	235	240			238	243	248
	245	250	255			253	258	263
	260	265	270			268	273	278
	273	275	278			282	288	293
	280	285	290			298	302	308
295	300	305			313	318	320	
310	315	316						
317	318	319						
320								
RESISTÊNCIA DE FALTA (Ω)								
FASE – TERRA	1	25	50	75	100	30	60	90
FASE - FASE						0,3	0,6	0,9
ÂNGULO DE INCIDÊNCIA DA FALTA ($^{\circ}$)	0	30	45	60	90	20	50	80

Resultados não satisfatórios foram também encontrados treinando-se a RNA3 dispondo-se dos valores trifásicos das tensões e correntes como empregados nos módulos anteriores de detecção e classificação. Ou seja, nos módulos citados, apresentaram-se às arquiteturas as quatro amostras da tensão na fase A, as quatro amostras da tensão na fase B seguidas das quatro amostras para a fase C. A mesma seqüência de apresentação foi empregada para os valores trifásicos das correntes (fase A, fase B e fase C) totalizando 24 unidades de processamento na camada de entrada. Seguindo esta ordem de apresentação, as redes não foram capazes de convergir para as respostas desejadas para todos os três tipos de faltas fase - terra

consideradas. A possível explicação para tal dificuldade em aprender, vem da proximidade existente entre os valores de tensões e correntes trifásicos das situações de faltas fase - terra. Assim, considerando uma falta fase A – terra, como exemplo, estaríamos apresentando valores de tensões para as quatro primeiras unidades de processamento da camada de entrada da rede neural, unidades de 1 a 4, e valores de correntes para as unidades de 13 a 16 afirmando (através das respostas esperadas) que esta falta pode ser localizada como pertencendo à zona de proteção primária. Para uma outra situação de falta, agora entre a fase B – terra, estaríamos apresentando nas unidades de entrada de 5 a 8, valores de tensão e, para as unidades de 17 a 20, valores de correntes próximos aos já apresentados quando da situação de uma falta fase A – terra, e que, estes também pertenceriam à zona de proteção primária, o mesmo ocorrendo com as amostras referentes à fase C (unidades de processamento na camada de entrada de 9 a 12 e 21 a 24). Pelo exposto, estaríamos associando valores próximos de tensões e correntes apresentados em diferentes unidades de entrada à mesma resposta desejada, o que é, provavelmente, a causa da dificuldade apresentada pelas RNAs em aprender e generalizar os padrões considerados.

Ao total foram avaliadas (treinadas) 63 arquiteturas, variando-se todos os possíveis parâmetros da rede, desde número de camadas intermediárias, número de elementos em cada camada, taxas de aprendizagem, conjunto de dados e ordem da apresentação dos valores amostrados na camada de entrada.

A arquitetura da RNA3 escolhida, apresenta 24 unidades na camada de entrada, duas camadas intermediárias com 48 e 44 unidades cada e uma camada de saída com 3 unidades (arquitetura 24-48-44-3). A arquitetura encontrada atende aos três possíveis tipos de faltas fase - terra (fase A – terra, B – terra e C – terra). No entanto, tanto para o processo de treinamento quanto para o de teste, os valores amostrados das fases foram invertidos quando da apresentação para a rede conforme é apresentado no que segue.

8.1.2 Ordem dos dados apresentados à RNA3 em cada janela de dados, tanto para o processo de treinamento quanto para o de teste

Para as situações de faltas que representam o envolvimento da fase A com conexão a terra, os dados apresentados às 24 unidades de processamento da camada de entrada da RNA3 foram dispostos na seguinte ordem:

- * 4 amostras dos valores de tensão na fase A;
- * 4 amostras dos valores de tensão na fase B;
- * 4 amostras dos valores de tensão na fase C;
- * 4 amostras dos valores de corrente na fase A;
- * 4 amostras dos valores de corrente na fase B e
- * 4 amostras dos valores de corrente na fase C.

Para faltas envolvendo a fase B com conexão a terra, as fases A e B foram invertidas conforme relaciona-se abaixo:

- * 4 amostras dos valores de tensão na fase B;
- * 4 amostras dos valores de tensão na fase A;
- * 4 amostras dos valores de tensão na fase C;
- * 4 amostras dos valores de corrente na fase B;
- * 4 amostras dos valores de corrente na fase A e
- * 4 amostras dos valores de corrente na fase C.

Para as faltas entre a fase C e a terra, a inversão ocorreu respeitando a seguinte ordem:

- * 4 amostras dos valores de tensão na fase C;
- * 4 amostras dos valores de tensão na fase B;
- * 4 amostras dos valores de tensão na fase A;
- * 4 amostras dos valores de corrente na fase C;
- * 4 amostras dos valores de corrente na fase B e
- * 4 amostras dos valores de corrente na fase A.

Sendo que esta disposição entre as fases não acarreta um atraso no processamento do sinal após a classificação do tipo de falta ocorrido, os sinais em análise podem então ser direcionados para os módulos de localização. Esta mesma ordem de apresentação dos dados será também mantida quando da implementação do algoritmo computacional.

8.1.3 Resultados observados

A seguir serão expostos os resultados observados quando da apresentação do conjunto de teste à arquitetura RNA3. Nas Tabelas 15, 16 e 17 que seguem, na primeira coluna estão representadas as devidas zonas de proteção e de transição, bem como o número de situações de faltas simuladas que recaem sobre as mesmas. Nas colunas de 2 a 4, apresentam-se os devidos números de acertos apresentados pela rede e a sua percentagem em relação ao número de situações de faltas consideradas. Na quinta coluna, são mostrados os índices considerando-se todas as 3 janelas de dados empregadas no conjunto de teste. Esta análise refere-se ao número de acertos e erros que a rede apresentou para determinada situação de falta considerando-se as 3 janelas de dados. Ressalta-se que estes resultados estarão disponíveis após 12 ms da ocorrência da falta, que é o tempo requerido para preencher a terceira janela de dados empregada no conjunto de teste.

TABELA 15 – Análise das respostas apresentadas pela RNA3 para faltas que envolvem a fase “A” com conexão a terra

ZONAS	1ª Janela	2ª Janela	3ª Janela	Analisando as 3 janelas
1ª zona prot. (126 faltas)	126 acertos 100,00%	126 acertos 100,00%	126 acertos 100,00%	126 acertos 100,00%
1ª zona trans. (36 faltas)	29 acertos 80,55%	27 acertos 75,00%	27 acertos 75,00%	27 acertos 75,00%
2ª zona prot. (54 faltas)	54 acertos 100,00%	52 acertos 96,30%	53 acertos 98,15%	53 acertos 98,15%
2ª zona trans. (27 faltas)	22 acertos 81,48%	17 acertos 62,96%	17 acertos 62,96%	20 acertos 74,07%
3ª zona prot. (81 faltas)	81 acertos 100,00%	81 acertos 100,00%	81 acertos 100,00%	81 acertos 100,00%
Total em 324 faltas	312 acertos 96,30%	303 acertos 93,52%	304 acertos 93,82%	307 acertos 94,75%



TABELA 16 – Análise das respostas apresentadas pela RNA3 para faltas que envolvem a fase “B” com conexão a terra

ZONAS	1ª Janela	2ª Janela	3ª Janela	Analisando as 3 janelas
1ª zona prot. (126 faltas)	126 acertos 100,00%	126 acertos 100,00%	126 acertos 100,00%	126 acertos 100,00%
1ª zona trans. (36 faltas)	18 acertos 50,00%	19 acertos 52,78%	17 acertos 47,22%	20 acertos 55,55%
2ª zona prot. (54 faltas)	52 acertos 96,30%	53 acertos 98,15%	54 acertos 100,00%	54 acertos 100,00%
2ª zona trans. (27 faltas)	11 acertos 40,74%	12 acertos 44,44%	15 acertos 55,55%	12 acertos 44,44%
3ª zona prot. (81 faltas)	76 acertos 93,83%	81 acertos 100,00%	81 acertos 100,00%	81 acertos 100,00%
Total em 324 faltas	283 acertos 87,35%	291 acertos 89,81%	293 acertos 90,43%	293 acertos 90,43%

TABELA 17 – Análise das respostas apresentadas pela RNA3 para faltas que envolvem a fase “C” com conexão a terra

ZONAS	1ª Janela	2ª Janela	3ª Janela	Analisando as 3 janelas
1ª zona prot. (126 faltas)	126 acertos 100,00%	126 acertos 100,00%	126 acertos 100,00%	126 acertos 100,00%
1ª zona trans. (36 faltas)	19 acertos 52,78%	21 acertos 58,33%	21 acertos 58,33%	21 acertos 58,33%
2ª zona prot. (54 faltas)	50 acertos 92,59%	52 acertos 96,30%	54 acertos 100,00%	54 acertos 100,00%
2ª zona trans. (27 faltas)	18 acertos 66,67%	17 acertos 62,96%	16 acertos 59,26%	17 acertos 62,96%
3ª zona prot. (81 faltas)	81 acertos 100,00%	81 acertos 100,00%	81 acertos 100,00%	81 acertos 100,00%
Total em 324 faltas	294 acertos 90,74%	297 acertos 91,67%	298 acertos 91,97%	299 acertos 92,28%

Nestas 3 últimas tabelas vale chamar a atenção para o fato de que, nas situações de faltas aplicadas sobre a primeira, segunda e terceira zona de proteção, para as três fases, a arquitetura apresentou praticamente 100% de acerto. Os erros observados, dizem respeito às zonas de transição onde, conforme já comentado, erros na localização são esperados. Como para os demais módulos (detecção e localização), com a matriz de pesos fixa, o próximo passo vem a ser a implementação de um algoritmo computacional que venha a melhorar ou simplificar a análise dos padrões apresentados ao sistema de proteção.

8.2 A localização de faltas fase - fase com e sem conexão a terra

Para estes tipos de faltas, inicialmente pensava-se em trabalhar com duas redes neurais distintas. A primeira arquitetura seria destinada à localização de faltas ocorridas entre duas fases e a segunda relacionada a situações de faltas que envolvessem duas fases com conexão a terra. Várias arquiteturas MLP (Multi Layer Perceptron) foram avaliadas isoladamente para cada caso que podem ser quantificadas em aproximadamente 35 arquiteturas para as situações faltosas entre duas fases e 40 arquiteturas para faltas entre duas fases com conexão a terra. Nestas, procurou-se avaliar o seu desempenho frente a variações no conjunto de treinamento, parâmetros e taxas de aprendizagem, números de épocas de treinamento, etc. Para as situações de faltas entre duas fases com conexão a terra, a melhor arquitetura obtida (arquitetura 24-44-40-3) respondia satisfatoriamente ao conjunto de teste formulado, o que não se evidenciava para as arquiteturas avaliadas para as situações de faltas entre duas fases sem conexão a terra.

Sendo assim, pela formulação de um conjunto de dados que respondesse a esses tipos de faltas (Tabela 18), uma única rede neural foi treinada e avaliada. Ao final deste processo, constatou-se que uma única rede neural atendia razoavelmente a todos os referidos tipos de faltas. Assim sendo, no que segue, apresenta-se a arquitetura escolhida e suas principais características, juntamente com uma prévia avaliação do seu desempenho frente ao conjunto de teste formulado.

8.2.1 A arquitetura escolhida

A arquitetura treinada e escolhida apresenta as suas 24 unidades de processamento da camada de entrada conectadas às suas duas camadas intermediárias com 42 e 40 unidades de processamento e à sua camada de saída com 3 unidades de processamento (arquitetura 24-42-40-3, RNA4). O conjunto de treinamento foi formulado pela combinação das variáveis apresentadas na Tabela 18 e o processo de treinamento, considerando um conjunto de validação, seguiu como para as demais redes já apresentadas. O erro mínimo (RMS) para todas as unidades na camada de saída referentes ao conjunto de validação foi da ordem de 0,15 para os

5070 padrões apresentados (1845 referentes às situações entre duas fases com conexão a terra e 3225 referentes às outras situações – Tabela 18).

TABELA 18 - Conjuntos de dados utilizados para representar as situações de faltas entre duas fases com e sem conexão a terra (RNA4)

NÚMERO DE PADRÕES EMPREGADOS	FALTAS FASE - FASE			FALTAS FASE - FASE - TERRA						
	615 situações por tipo de falta - 5 janelas de dados 9225 padrões - treinamento: 7380 - validação: 1845				1075 situações por tipo de falta - 7 janelas de dados 22575 padrões - treinamento: 18060 - validação: 4515					
LOCALIZAÇÕES (KM)	Barramento EF			Barramento EF						
	86	90	110	86	90	95				
	130	150	170	100	110	120				
	185	195	200	140	160	180				
	205	210	215	200	210	215				
	220	222,5	225	220	222,5	225				
	228			228						
	Barramento FG			Barramento FG						
	233	235	240	233	235	240				
	245	250	255	245	250	255				
	260	265	270	260	265	270				
	272,5	275	277,5	272,5	273	275				
	280	285	290	277,5	278	280				
	295	300	305	285	290	295				
310	315	316	300	305	310					
317	318	319	315	316	317					
320			318	319	320					
RESISTÊNCIA DE FALTA (Ω)										
FASE - FASE	0,10	0,50	1,0							
FASE - FASE - TERRA				0,1	25	50	75	100		
ÂNGULO DE INCIDÊNCIA DA FALTA ($^{\circ}$)	0	30	45	60	90	0	30	45	60	90

8.2.2 Ordem dos dados apresentados à RNA4 em cada janela de dados

Para as situações de faltas entre as fases AB e AB - terra, os dados apresentados às 24 unidades de processamento da camada de entrada da RNA4, tanto para o processo de treinamento quanto para o de teste, foram dispostos na seguinte ordem:

- * 4 amostras dos valores de tensão na fase A;
- * 4 amostras dos valores de tensão na fase B;

- * 4 amostras dos valores de tensão na fase C;
- * 4 amostras dos valores de corrente na fase A;
- * 4 amostras dos valores de corrente na fase B e
- * 4 amostras dos valores de corrente na fase C.

Já para as situações de faltas entre as fases AC e AC – terra, as fases B e C foram invertidas conforme se relaciona abaixo:

- * 4 amostras dos valores de tensão na fase A;
- * 4 amostras dos valores de tensão na fase C;
- * 4 amostras dos valores de tensão na fase B;
- * 4 amostras dos valores de corrente na fase A;
- * 4 amostras dos valores de valores da corrente na fase C e
- * 4 amostras dos valores de corrente na fase B.

Para as situações de faltas entre as fases B e C com e sem a conexão a terra, a inversão ocorreu respeitando a seguinte ordem:

- * 4 amostras dos valores de tensão na fase B;
- * 4 amostras dos valores de tensão na fase C;
- * 4 amostras dos valores de tensão na fase A;
- * 4 amostras dos valores de corrente na fase B;
- * 4 amostras dos valores de corrente na fase C e
- * 4 amostras dos valores de corrente na fase A.

Procedimento este, que é similar ao caso anterior (item 8.1.2)

8.2.3 Resultados observados

Nas seis tabelas que seguem (19 a 24) apresentam-se os resultados da arquitetura 24-42-40-3 frente ao conjunto de teste formulado (Tabela 18) para as situações de faltas envolvidas.

Estes números de acertos e índices apresentados referem-se às respostas da rede para as situações consideradas dispondo-se de 3 janelas de dados. Seguindo para uma análise das três janelas de dados, dispõem-se os resultados encontrados na quinta coluna. Nestas tabelas, observam-se os bons resultados que indicam um índice geral de acerto próximo a 97% para todos os casos testados que recaem sobre a primeira

zona de proteção (média calculada entre os seis tipos de faltas apresentados que recaem sobre a primeira zona de proteção – Tabelas 19 - 24). Já para a zona de proteção secundária e terciária ambos os índices ficam aproximadamente em 94%.

Cabe destacar que os menores índices de acertos encontram-se nas supostas zonas de transição onde, conforme já explicado, respostas errôneas por parte da RNA4 eram esperadas.

TABELA 19 - Análise das respostas apresentadas pela RNA4 para faltas que envolvem as fases “AB”

ZONAS	1ª Janela	2ª Janela	3ª Janela	Analisando as 3 janelas
1ª zona prot. (126 faltas)	103 acertos 81,75%	118 acertos 93,65%	112 acertos 88,89%	118 acertos 93,65%
1ª zona trans. (36 faltas)	17 acertos 47,22%	21 acertos 58,33%	22 acertos 61,11%	19 acertos 52,78%
2ª zona prot. (54 faltas)	40 acertos 74,07%	43 acertos 79,63%	42 acertos 77,78%	46 acertos 85,18%
2ª zona trans. (27 faltas)	09 acertos 33,33%	13 acertos 48,15%	15 acertos 55,55%	10 acertos 37,04%
3ª zona prot. (81 faltas)	75 acertos 92,59%	70 acertos 86,42%	71 acertos 87,65%	74 acertos 91,36
Total em 324 faltas	244 acertos 75,31%	265 acertos 81,79%	262 acertos 80,86%	267 acertos 82,41%

TABELA 20 - Análise das respostas apresentadas pela RNA4 para faltas que envolvem as fases “AC”

ZONAS	1ª Janela	2ª Janela	3ª Janela	Analisando as 3 janelas
1ª zona prot. (126 faltas)	121 acertos 96,03%	121 acertos 96,03%	126 acertos 100%	124 acertos 98,41%
1ª zona trans. (36 faltas)	16 acertos 44,44%	22 acertos 61,11%	16 acertos 44,44%	08 acertos 22,22%
2ª zona prot. (54 faltas)	48 acertos 88,89%	51 acertos 94,44%	49 acertos 90,74%	51 acertos 94,44%
2ª zona trans. (27 faltas)	12 acertos 44,44%	12 acertos 44,44%	14 acertos 51,85%	12 acertos 44,44%
3ª zona prot. (81 faltas)	53 acertos 65,43%	65 acertos 80,25%	72 acertos 88,89%	72 acertos 88,89%
Total em 324 faltas	250 acertos 77,16%	271 acertos 83,64%	277 acertos 85,49%	267 acertos 82,41%

TABELA 21 - Análise das respostas apresentadas pela RNA4 para faltas que envolvem as fases “BC”

ZONAS	1ª Janela	2ª Janela	3ª Janela	Analisando as 3 janelas
1ª zona prot. (126 faltas)	117 acertos 92,86%	114 acertos 90,48%	118 acertos 93,65%	120 acertos 95,24%
1ª zona trans. (36 faltas)	18 acertos 50,00%	15 acertos 41,67%	17 acertos 47,22%	17 acertos 47,22%
2ª zona prot. (54 faltas)	51 acertos 94,44%	36 acertos 66,67%	41 acertos 75,92%	45 acertos 83,33%
2ª zona trans. (27 faltas)	12 acertos 44,44%	19 acertos 70,37%	16 acertos 59,26%	18 acertos 66,67%
3ª zona prot. (81 faltas)	71 acertos 87,65%	69 acertos 85,18%	69 acertos 85,18%	72 acertos 88,89%
Total em 324 faltas	269 acertos 83,02%	253 acertos 78,08%	261 acertos 80,55%	272 acertos 83,95%

TABELA 22 - Análise das respostas apresentadas pela RNA4 para faltas que envolvem as fases “AB” com conexão a terra

ZONAS	1ª Janela	2ª Janela	3ª Janela	Analisando as 3 janelas
1ª zona prot. (126 faltas)	122 acertos 96,82%	122 acertos 96,82%	123 acertos 97,62%	122 acertos 96,82%
1ª zona trans. (36 faltas)	19 acertos 52,78%	20 acertos 55,55%	17 acertos 47,22%	19 acertos 52,78%
2ª zona prot. (54 faltas)	50 acertos 92,59%	52 acertos 96,30%	51 acertos 94,44%	54 acertos 100,00%
2ª zona trans. (27 faltas)	5 acertos 18,52%	16 acertos 59,26%	17 acertos 62,96%	11 acertos 40,74%
3ª zona prot. (81 faltas)	81 acertos 100,00%	75 acertos 92,59%	78 acertos 96,30%	79 acertos 97,53%
Total em 324 faltas	277 acertos 85,49%	285 acertos 87,96%	286 acertos 88,27%	285 acertos 87,96%

TABELA 23 - Análise das respostas apresentadas pela RNA4 para faltas que envolvem as fases “AC” com conexão a terra

ZONAS	1ª Janela	2ª Janela	3ª Janela	Analisando as 3 janelas
1ª zona prot. (126 faltas)	125 acertos 99,21%	122 acertos 96,82%	126 acertos 100,00%	126 acertos 100,00%
1ª zona trans. (36 faltas)	18 acertos 50,00%	25 acertos 69,44%	14 acertos 38,89%	24 acertos 66,67%
2ª zona prot. (54 faltas)	49 acertos 90,74%	49 acertos 90,74%	49 acertos 90,74%	54 acertos 100,00%
2ª zona trans. (27 faltas)	12 acertos 44,44%	11 acertos 40,74%	9 acertos 33,33%	11 acertos 40,74%
3ª zona prot. (81 faltas)	71 acertos 87,65%	76 acertos 93,82%	76 acertos 93,82%	77 acertos 95,06%
Total em 324 faltas	275 acertos 84,88%	283 acertos 87,34%	274 acertos 84,57%	292 acertos 90,12%

TABELA 24 - Análise das respostas apresentadas pela RNA4 para faltas que envolvem as fases “BC” com conexão a terra

ZONAS	1ª Janela	2ª Janela	3ª Janela	Analisando as 3 janelas
1ª zona prot. (126 faltas)	120 acertos 95,24%	123 acertos 97,62%	124 acertos 98,41%	124 acertos 98,41%
1ª zona trans. (36 faltas)	25 acertos 69,44%	15 acertos 41,67%	16 acertos 44,44%	20 acertos 55,55%
2ª zona prot. (54 faltas)	47 acertos 87,04%	54 acertos 100,00%	52 acertos 96,30%	54 acertos 100,00%
2ª zona trans. (27 faltas)	19 acertos 70,37%	16 acertos 59,26%	20 acertos 74,07%	19 acertos 70,37%
3ª zona prot. (81 faltas)	76 acertos 93,83%	78 acertos 96,30%	79 acertos 97,53%	81 acertos 100,00%
Total em 324 faltas	287 acertos 88,58%	286 acertos 88,27%	291 acertos 89,81%	298 acertos 91,97%

8.3 A localização de faltas trifásicas

Com respeito à localização das faltas trifásicas, poucas alterações foram efetuadas comparando-se aos itens anteriores (8.1 e 8.2). Para alcançar a arquitetura RNA5 desejada, basicamente a disposição dos sinais de entrada à rede diverge das anteriores, pois neste caso, não houve a necessidade da inversão entre as fases. As 24 unidades de processamento da camada de entrada recebem os quatro valores

trifásicos amostrados dos sinais de tensão (fases A, B e C) e os sinais de corrente nas respectivas fases.

Quatro janelas de dados contendo 4 amostras de cada sinal analisado (tensões e correntes trifásicas) foram empregadas no processo de treinamento. O conjunto de dados foi formado por 1525 situações de faltas decorrentes da combinação entre a localização de aplicação da falta (61 posições), as resistências de falta (5 valores) e os ângulos de injeção da falta (5 valores), conforme é evidenciado na Tabela 25. Assim, considerando-se as 4 janelas de dados, o conjunto final apresenta 6100 padrões. Destes padrões, 80% foram empregados para formar o conjunto de treinamento (4880 padrões) e 20% designados para compor o conjunto de validação (1220 padrões). Como em todos os conjuntos empregados no trabalho, os padrões foram dispostos de maneira aleatória quando do processo de treinamento da RNA5. Para a fase de teste, a combinação dos mesmos parâmetros já apresentados na Tabela 14 foram adotados para a composição de um novo conjunto. Apenas o campo “resistência de falta (Ω)” recebeu novos valores passando para 0,3, 0,6 e 0,9. Estes dizem respeito as resistências de falta entre fases. Considerando-se as 3 janelas de dados, 972 padrões diferentes de faltas foram avaliados (324 situações x 3 janelas de dados).

TABELA 25 - Conjuntos de dados utilizado para representar as situações trifásicas (RNA5)

NÚMERO DE PADRÕES EMPREGADOS	CONJUNTO DE DADOS				
	1525 situações de faltas 4 janelas de dados Total: 6100 padrões				
LOCALIZAÇÕES (KM)	Barramento EF				
	86	90	95	100	
	110	120	130	140	
	150	160	170	180	
	185	190	195	200	
	205	210	215	220	
	221	222	222,5	223	
	224	225	226	227	
	228				
	Barramento FG				
	233	235	238	240	
	245	250	255	260	
	265	270	271	272	
	273	274	275	276	
	277	278	279	280	
285	290	295	300		
305	310	315	316		
317	318	319	320		
RESISTÊNCIA DE FALTA (Ω) FASE - FASE	0,10	0,25	0,50	0,75	1,00
ÂNGULO DE INCIDÊNCIA DA FALTA ($^{\circ}$)	0	30	45	60	90

8.3.1 A arquitetura escolhida

Na busca de uma arquitetura, várias topologias de redes neurais MLP (*Multi Layer Perceptron*) também foram avaliadas, com o intuito de se encontrar uma que melhor atendesse em resposta a localização das situações de faltas apresentadas. Ao total, 25 arquiteturas foram analisadas variando-se parâmetros como: números de elementos de processamento nas diversas camadas, conjuntos de treinamento, taxas de aprendizagem, etc. A arquitetura que apresentou um aceitável índice de respostas corretas apresenta 24 unidades de processamento na camada de entrada e 3 unidades de processamento na camada de saída (como em todas as demais já apresentadas). Para as duas camadas intermediárias, foram alocados 24 unidades de processamento

para a primeira camada intermediária e 20 unidades de processamento para a segunda camada intermediária (arquitetura 24-24-20-3, RNA5). Quando da apresentação à rede do conjunto de validação, a arquitetura apresentou um erro mínimo (RMS) para todas as unidades na camada de saída no valor de 0,04. Todas as demais observações feitas no trabalho com respeito as arquiteturas, processo de treinamento e de teste são também aplicáveis a este item.

8.3.2 Resultados observados

Na Tabela 26, apontam-se os índices de acertos proporcionados pela arquitetura 24-24-20-3 quando sujeita ao conjunto de teste anteriormente formulado. Nesta, observam-se resultados satisfatórios que indicam um índice geral de acertos próximo a 92% para todos os casos testados. Cabe ressaltar que os menores índices de acertos encontram-se nas supostas zonas de transição onde, conforme já explicado, respostas errôneas por parte da RNA5 são esperadas. O que mais ressalta a precisão nas respostas apresentadas pela rede é que, analisando-se em conjunto as 3 janelas de dados, para as três zonas de proteção (primária, secundária e terciária) o índice apresentado de acertos é de 100%.

TABELA 26 – Análise das respostas apresentadas pela RNA5 para faltas que envolvem as fases “ABC”

ZONAS	1ª Janela	2ª Janela	3ª Janela	Analisando as 3 janelas
1ª zona prot. (126 faltas)	123 97,62%	123 97,62%	123 97,62%	126 100,00%
1ª zona trans. (36 faltas)	21 58,33%	24 66,67%	16 44,44%	24 66,67%
2ª zona prot. (54 faltas)	44 81,48%	54 100,00%	48 88,89%	54 100,00%
2ª zona trans. (27 faltas)	15 55,55%	12 44,44%	13 48,15%	12 44,44%
3ª zona prot. (81 faltas)	78 96,30%	81 100,00%	78 96,30%	81 100,00%
Total em 324 faltas	281 86,73%	294 90,74%	278 85,80%	297 91,67%

9 A LÓGICA COMPUTACIONAL IMPLEMENTADA

Pelo que foi apresentado e observado nas implementações dos módulos anteriores – detecção, classificação e localização, nota-se que as redes neurais empregadas convergiram rapidamente para uma resposta esperada. No entanto, tomando-se como exemplo um conjunto de cinco respostas do módulo de classificação, muitas das vezes estas respostas divergem em um número de classificações corretas e errôneas. Tendo este fato em análise, procurou-se então melhorar a tomada de decisão frente aos módulos implementados, optando-se em não analisar unicamente uma resposta da rede neural e sim, o conjunto das respostas pertinentes a cada módulo de detecção, classificação e de localização.

Para o módulo de detecção conforme apresentado, verifica-se que são necessários no máximo 3 ms pós-falta para a tomada de decisão e, conseqüentemente, as respostas das três janelas de dados serão analisadas. Já para o módulo de classificação, o número de janelas de dados necessárias varia de três a cinco, o mesmo ocorrendo para o módulo de localização. Claro que este número de respostas/janelas consideradas em cada módulo vem e muito a influenciar no desempenho do sistema como um todo. Sendo assim, no que segue, será apresentado a lógica do algoritmo computacional implementado, tomando-se como base para a análise, o número de respostas corretas ou não, apresentadas por cada módulo.

9.1 Os sinais de entrada e de saída do módulo de detecção

No que se refere aos sinais de entrada direcionados ao algoritmo computacional, os mesmos estão dispostos em um arquivo de dados, onde são apresentados, em cada linha, os 24 valores amostrados dos sinais trifásicos em análise. Assim, para uma situação de operação simulada, linha por linha, os dados são apresentados ao algoritmo. Para todas as situações de teste simuladas, em um total de 4050 novos casos como será posteriormente evidenciado, as primeiras linhas de dados de todos os arquivos indicarão uma condição normal de operação do sistema, até o instante em que uma situação de falta foi aplicada. Consequentemente, o módulo responsável pela detecção deverá reconhecer as primeiras linhas como uma condição normal de operação. Se uma condição anormal é constatada, o módulo ativo (detecção) indicará então, se esta situação de falta é em posição reversa ou à frente do barramento E. Ressalta-se que este módulo implementado está capacitado para detectar situações de faltas em sentido reverso ou à frente do barramento E, considerando os 10 possíveis tipos de faltas sobre um sistema de linhas de transmissão. Para os sinais que representem uma condição normal de operação do sistema, as respostas esperadas por parte da RNA1 devem ser: $D_1 = D_2 = 0$. Já para uma falta reversa ao barramento E (Figura 6), as respostas aceitáveis são valores próximos a $D_1 = 1$ e $D_2 = 0$. No caso de faltas situadas à frente do mesmo barramento os valores próximos a $D_1 = 0$ e $D_2 = 1$ são esperados. Estes valores esperados por parte da RNA1 empregada estão novamente ilustrados na Tabela 27 que segue.

Retornando ao arquivo de dados que representa a situação de operação/falta em questão, os valores amostrados dos sinais analisados são continuamente apresentados ao módulo de detecção. Não havendo a detecção de uma situação faltosa ($D_1 = D_2 = 0$) os demais módulos de classificação e de localização não serão ativados. Sendo assim, não há a necessidade de se propagar os sinais amostrados de tensões e correntes para os mesmos.

Sendo detectada uma condição anormal no sistema, caracterizada na Figura 27 pela primeira janela de dados acusando a situação, onde F representa o instante de

aplicação da falta, a janela seguinte ou as duas janelas seguintes serão aguardadas para a confirmação do evento.

TABELA 27 – Respostas esperadas por parte das RNAs

MÓDULO DE DETECÇÃO		MÓDULO DE CLASSIFICAÇÃO RNA2 (24-16-4)				MÓDULO DE LOCALIZAÇÃO					
Situação	D ₁	D ₂	Tipo de falta	C ₁	C ₂	C ₃	C ₄	Localização da falta	L ₁	L ₂	L ₃
Normal	0	0	A-E	1	0	0	1	Zona 1	1	0	0
Falta reversa	1	0	B-E	0	1	0	1	Zona 2	0	1	0
Falta à frente	0	1	C-E	0	0	1	1	Zona 3	0	0	1
RNA1 (24-9-2)			AB	1	1	0	0	RNA3 (24-48-44-3) RNA4 (24-42-40-3) RNA5 (24-24-20-3)			
			AC	1	0	1	0				
			BC	0	1	1	0				
			AB-E	1	1	0	1				
			AC-E	1	0	1	1				
			BC-E	0	1	1	1				
		ABC	1	1	1	0					

No entanto, mesmo ocorrendo uma situação de falta, a rede RNA1 poderá não detectar ou detectar erroneamente o tipo de falta encontrado. Diante de um lapso da rede em detectar ou não a situação de falta, já na primeira janela de dados, faz-se necessário de alguma forma computar a sua resposta para esta janela de dados, bem como as respostas subsequentes. Como por exemplo, se for detectado na primeira janela de dados o caso de uma falta em situação à frente do barramento E ($D_1 = 0$ e $D_2 = 1$), variáveis criadas e implementadas no algoritmo recebem os seguintes valores:

Det_normal=0	Det_reversa=0	Det_afrente=1
--------------	---------------	---------------

Dispondo-se da segunda janela de dados, conforme ilustra a Figura 28 e, se a falta for detectada novamente como em sentido à frente do barramento E, as variáveis anteriormente definidas passam então a apresentar os seguintes valores:

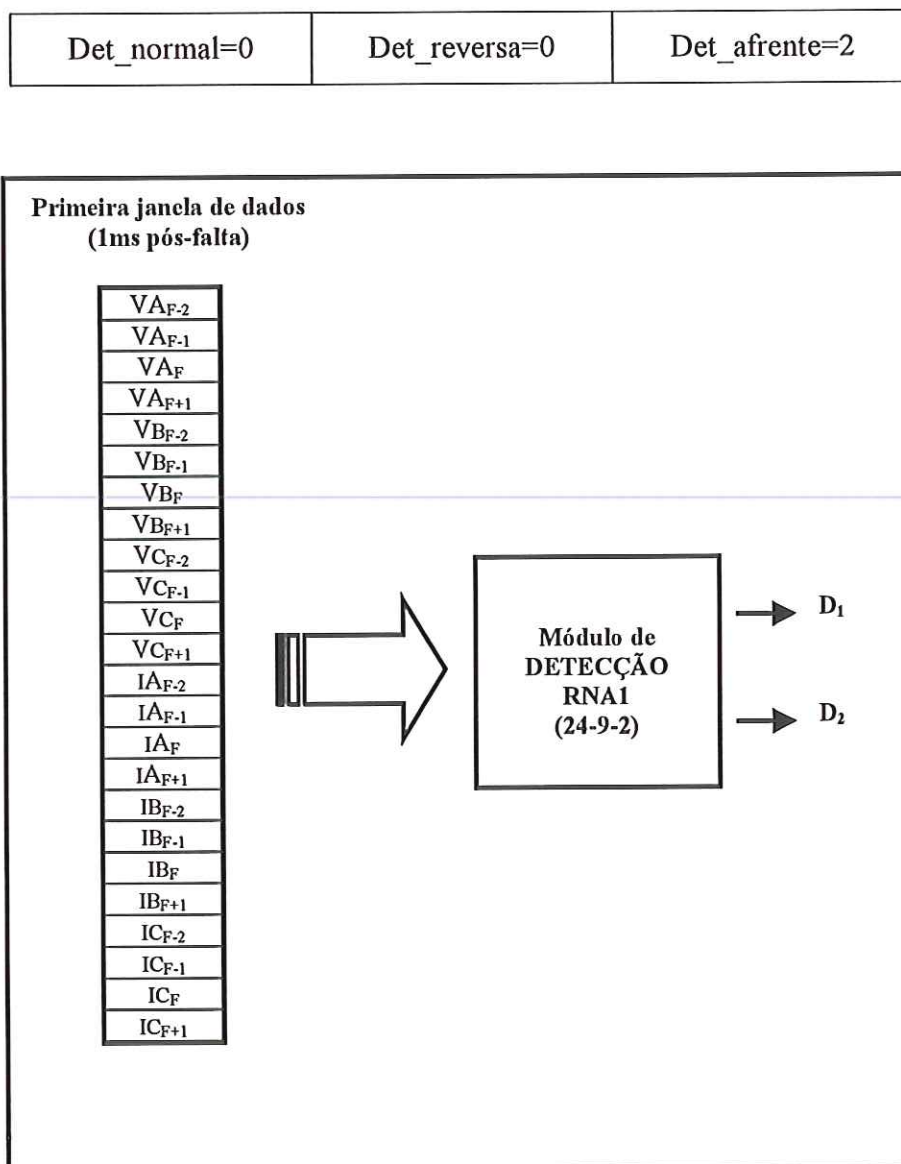


FIGURA 27 - Primeira janela de dados acusando a ocorrência da situação faltosa

Pela análise exposta, analisando-se até este ponto duas janelas de dados, já temos uma decisão por parte da RNA1, detectando esta situação de falta como situada à frente do barramento E.

Contudo, para a segunda janela de dados, a RNA1 pode apresentar respostas que diferem das apresentadas quando da primeira janela de dados. Sendo assim, como ilustração, podemos encontrar agora uma detecção em sentido reverso e as variáveis do algoritmo assumem os seguintes valores:

Det_normal=0	Det_reversa=1	Det_afrente=1
--------------	---------------	---------------

Com as respostas apresentadas pela rede frente à segunda janela de dados, houve um empate nos valores das variáveis do algoritmo e uma terceira janela de dados faz-se necessária para resolver a situação.

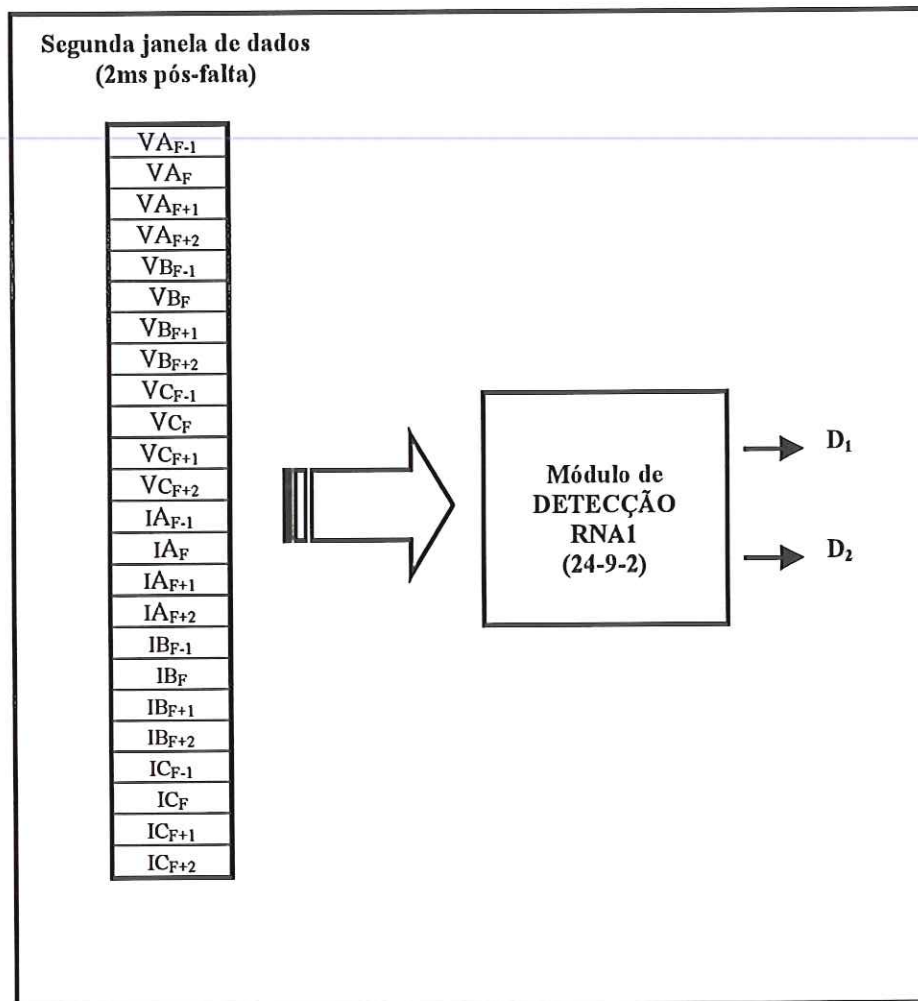


FIGURA 28 - Segunda janela de dados acusando a ocorrência da situação faltosa

Para a implementação do algoritmo, considerou-se que duas respostas idênticas indicariam uma correta tomada de decisão por parte da RNA1. Assim, a correta avaliação do sistema (presença ou não de uma situação de falta em sentido reverso ou à frente de determinado ponto) é alcançada dispondo-se de 2 a 3 ms após a ocorrência do surto.

Aplicando-se tal análise, conforme será evidenciado pelos resultados encontrados, a RNA1 apresenta um índice de 100% de acerto tanto na análise de condições normais de operação quanto na análise de situações de faltas, sejam elas em situação reversa ou à frente de determinado ponto. Salienta-se que este índice de 100% de acertos é mantido para os 10 tipos de faltas analisados.

9.2 A conexão com o módulo de classificação

Em virtude das duas respostas idênticas exigidas no módulo de detecção, para este módulo de classificação, os valores amostrados das tensões e correntes trifásicos estarão disponíveis a partir de 2 ou 3 ms após a ocorrência da falta. Apenas lembrando, a RNA2 designada para o módulo de classificação foi treinada utilizando-se como ponto inicial a 2ª amostra pós-falta dos sinais analisados. Tal procedimento considerou para o treinamento 5 janelas de dados, as quais consomem um tempo que varia de 5 a 9 ms. No entanto, com a implementação do algoritmo computacional observa-se que os mesmos últimos valores de dados pós-falta empregados pelo módulo de detecção podem ser direcionados para o módulo de classificação. Assim sendo, os dados iniciais para o módulo de classificação estarão disponíveis (completos) dispondo-se na grande maioria dos casos testados de 2 ou 3 ms após a ocorrência da falta. Com isto, a partir deste tempo, somente o módulo classificador atuará (RNA2), sendo que o módulo anterior (detector) estará desativado (Figura 29).

Como ilustrado, a arquitetura da RNA2 deve devolver como resposta à sua excitação (conjunto de valores trifásicos das tensões e correntes) quatro valores (C_1 , C_2 , C_3 e C_4) que indicarão o envolvimento da(s) fase(s) com ou sem conexão a terra na situação de falta detectada (Tabela 27).

Agora, retornamos ao ponto em que a RNA2 pode classificar corretamente ou não, a partir de 2 ou 3 ms (pós-falta) à situação apresentada. Como para a detecção, podemos então dispor das janelas de dados subsequentes, analisar o conjunto de respostas apresentadas pela rede e então, tomarmos a decisão da(s) fase(s) envolvida(s) com ou sem conexão a terra. A nível do algoritmo computacional, as

variáveis foram inicializadas e a cada resposta de classificação apresentada pela RNA2 os valores envolvidos foram computados.

AT=0	BT=0	CT=0	AB=0	AC=0	BC=0	ABT=0	ACT=0	BCT=0	ABC=0
------	------	------	------	------	------	-------	-------	-------	-------

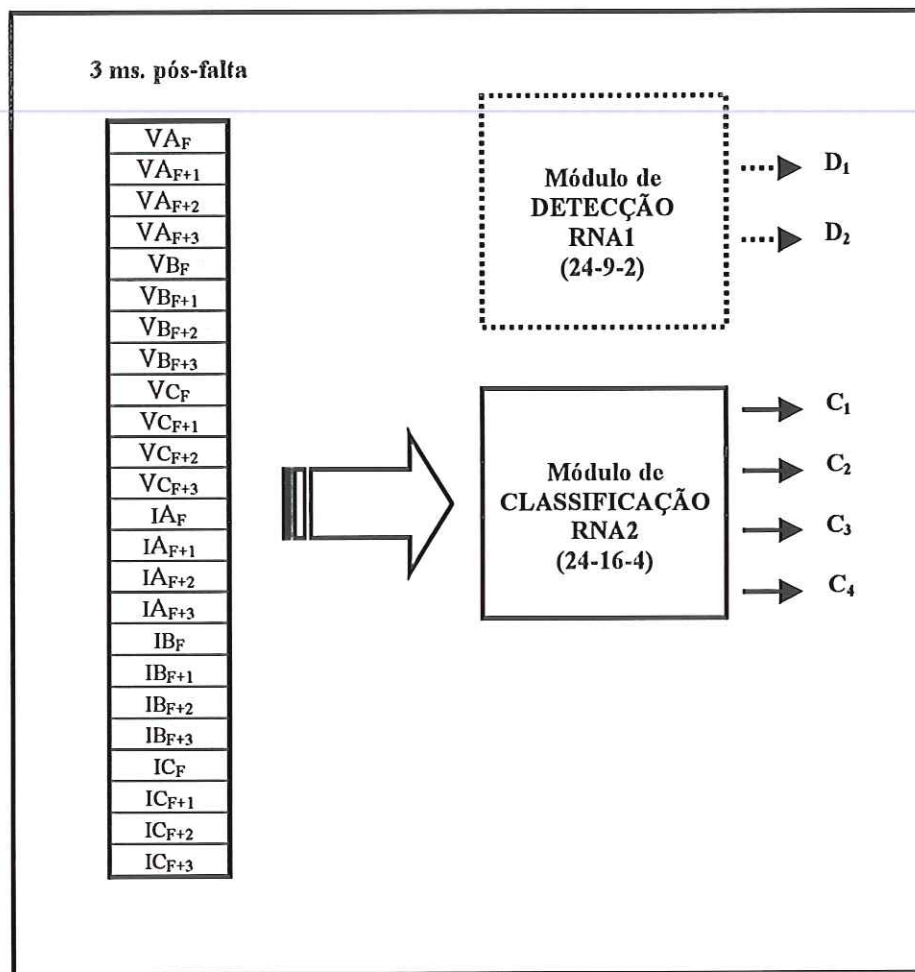


FIGURA 29 – Com a detecção da falta em até 3 ms, a terceira janela de dados poderá ser apresentada ao módulo de classificação

Por exemplo, se para a 2ª janela de dados pós-falta a rede classificar a situação como sendo uma falta envolvendo a fase A com conexão a terra ($C_1 = C_4 = 1$ e $C_2 = C_3 = 0$) as variáveis podem assumir os seguintes valores:

AT=1	BT=0	CT=0	AB=0	AC=0	BC=0	ABT=0	ACT=0	BCT=0	ABC=0
------	------	------	------	------	------	-------	-------	-------	-------

Para a 3ª janela de dados pós-falta a rede poderá confirmar ou divergir das respostas apresentadas para a 2ª janela de dados. Se divergir, classificando a falta como sendo entre as fases A e B teremos agora as variáveis atualizadas com os seguintes valores:

AT=1	BT=0	CT=0	AB=1	AC=0	BC=0	ABT=0	ACT=0	BCT=0	ABC=0
------	------	------	------	------	------	-------	-------	-------	-------

Podemos então, computar as respostas apresentadas pela RNA2 até atingirmos um número qualquer, mas, conforme será evidenciado pelos testes aplicados, um número de 3 a 5 respostas idênticas garantem um índice de acertos próximo a 100% para todos os tipos de faltas analisados. Pelos testes efetuados a grande maioria das situações de faltas foram classificadas dispondo-se de um tempo situado entre 6 a 9 ms pós-falta. Uma análise detalhada dos resultados observados será convenientemente apresentada.

Obtendo-se a resposta do módulo de classificação, os últimos sinais amostrados utilizados por este módulo podem então ser direcionados para o módulo de localização, conforme será explanado no que segue.

9.3 O módulo de localização e suas considerações

Havendo a correta designação da(s) fase(s) envolvida(s) o módulo de localização da falta é ativado, por exemplo, 9 ms após a ocorrência do evento (Figura 30). Este módulo, por sua vez, contém três redes neurais e, com a classificação do tipo de falta ocorrido, somente a rede neural condizente às fases envolvidas será ativada. A primeira rede (RNA3) será responsável pela localização das faltas envolvendo uma fase com conexão a terra (A - terra, B - terra e C - terra). Outra rede (RNA4) pelas faltas entre duas fases com ou sem conexão a terra (fases AB - terra, AC - terra, BC - terra, AB, AC e BC) e a terceira rede responderá pelas faltas trifásicas (RNA5).

Cada rede deverá indicar a zona de proteção em que a falta ocorreu para posteriormente haver o seccionamento da porção afetada, sendo as zonas caracterizadas como 1^a, 2^a e 3^a zonas de proteção.

Como nos itens anteriores (9.1 e 9.2), a rede neural ativada para a localização poderá ou não determinar corretamente a zona de ocorrência da falta já com a primeira janela de dados apresentada. No entanto, para evitar situações duvidosas, as respostas das demais janelas de dados também serão consideradas. Este processo também visa à criação de variáveis que irão computar as respostas de cada janela de dados e, frente às respostas destas janelas, indicar a correta localização da falta. As variáveis inclusas no algoritmo são designadas por:

Loc_zona1=0	Loc_zona2=0	Loc_zona3=0
-------------	-------------	-------------

Adotando-se tal prática e considerando que um número de quatro a cinco respostas idênticas indicam uma correta posição por parte da RNA, constata-se que a situação final de localização do distúrbio sobre a linha de transmissão ocorrerá dispondo-se em média de 13 ms após a ocorrência do mesmo. Sendo este também o tempo aproximado de todo o processo – detecção, classificação e localização de uma situação anormal sobre o sistema.

Por último, cabe ressaltar que a metodologia de análise empregada no algoritmo computacional implementado diverge da empregada nos processos de treinamento e de teste anteriormente abordados (capítulos 6, 7 e 8) no que diz respeito aos valores que indicam uma resposta indecisa por parte das RNAs (valores maiores que 0,2 e menores que 0,8). Na grande maioria dos casos onde as RNAs apresentaram erros, seja para o módulo de detecção, classificação ou de localização, os valores apresentados como respostas foram bem caracterizados, longe dos limiares de 0,2 ou de 0,8 como sugeridos. Em virtude de tal situação, para a implementação do algoritmo computacional, o intervalo de respostas indecisas por parte das RNAs passa a ter valores maiores de 0,3 e menores de 0,7. Qualquer resposta (S_i) que recaia neste intervalo ($0,3 < S_i < 0,7$) será fixada em um valor genérico de 0,5. O mesmo ocorrerá com a faixa dos valores decisivos. Para qualquer resposta (S_i) pertencente ao intervalo ($0,0 \leq S_i \leq 0,3$) será atribuído o valor 0,0 (zero) e no caso da resposta

pertencer ao intervalo $(0,7 \leq S_i \leq 1,0)$, será atribuída à mesma o valor 1,0 (um). Como as respostas que podem ser apresentadas pelas saídas das RNAs pertencem a um intervalo contínuo, tais considerações vêm a simplificar o manuseio das variáveis no algoritmo computacional implementado.

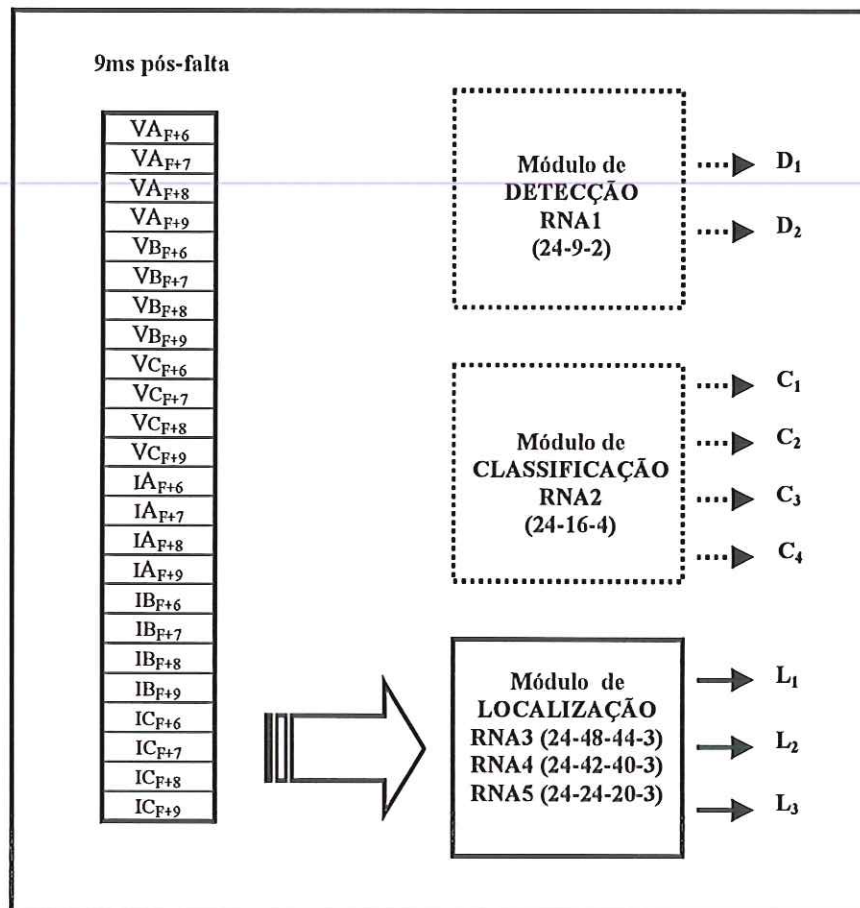


FIGURA 30 – Ativação do módulo de localização dispo-ndo-se de 9 ms após a ocorrência da falta

10 OS RESULTADOS OBSERVADOS PELA IMPLEMENTAÇÃO DO ALGORITMO COMPUTACIONAL

Como anteriormente evidenciado, o algoritmo computacional implementado em linguagem de programação “C”, obedece a uma forma seqüencial de ativação dos módulos considerados. Sendo assim, para uma fase de teste do mesmo, 4050 novos casos de prováveis situações que possam vir a ocorrer sobre o sistema de transmissão em análise, foram simulados e apresentados, caso a caso, ao algoritmo em fase de experimento.

O conjunto de testes formulado compreende 405 diferentes casos para cada um dos dez tipos de faltas. As situações de faltas analisadas são compostas pela combinação das seguintes variáveis:

- Localização da falta (km) – 6, 10, 15, 30, 45, 60, 65, 70, 74, 88, 105, 115, 125, 135, 145, 155, 165, 175, 185, 195, 202, 208, 212, 218, 222, 223, 225, 238, 243, 248, 253, 258, 263, 268, 273, 278, 282, 288, 293, 298, 302, 308, 313, 318, e 320;
- Resistência de falta (Ω) - fase - terra: 30, 60, 90 e fase - fase: 0,3, 0,6, e 0,9;
- Ângulo de inserção da falta ($^{\circ}$) - 20, 50, e 80.

Como no processo de treinamento, quatro amostras dos valores de tensões e correntes trifásicas (valores de pré e de pós-falta), amostrados a uma frequência de 1 kHz, foram dispostos como valores de entrada.

Apresentando-se as situações simuladas caso a caso, as respostas por parte do algoritmo computacional foram registradas à medida que cada módulo implementado era ativado e desativado, passando os sinais amostrados em análise para o módulo seguinte.

A Tabela 28 apresenta em síntese todos os resultados registrados, onde o Tempo de Processamento (T.P.) em destaque, provém basicamente da soma dos intervalos de tempo entre cada valor amostrado do sinal considerado (1 ms) A percentagem de Respostas Corretas (R.C.) também está evidenciada, sendo que, para os módulos de detecção e de classificação, observam-se índices muito próximos a 100%. Apenas esclarecendo como estes dados foram registrados, dos casos representativos de situações de faltas que envolvam uma fase com conexão a terra (A – terra, B – terra e C – terra), 71,94% dos casos foram detectados, dispondo-se de 2 ms pós-falta. 23,29% foram corretamente detectados considerando-se até 3 ms e 4,77% tomando-se um tempo de 4 a 5 ms pós-falta. Destaca-se que, mesmo para as situações detectadas em um tempo maior do que 3 ms os demais módulos, ainda assim, apresentaram respostas corretas as suas funções.

Vale destacar que todos os arquivos que representam as 4050 situações de faltas simuladas foram apresentados ao algoritmo implementado linha por linha, sendo que, até o instante de aplicação da falta, os parâmetros apresentados caracterizavam uma situação normal de operação. A RNA1 foi capaz de reconhecer esta condição normal de operação para todos os padrões apresentados (100% de acerto).

Relembrando da filosofia adotada para as zonas de proteção, temos definido sobre o sistema de transmissão duas áreas de transição onde valores incorretos na localização da falta são esperados. Conforme apresentado, estas áreas de incertezas correspondem a um índice de $\pm 2\%$ sobre o comprimento considerado e já foram definidas anteriormente. Este fato contudo vem e muito a esclarecer os índices apresentados pelo módulo de localização, já que, a grande maioria das respostas incorretas deste módulo recaem sobre estas supostas áreas de transição. Como exemplo, afirmamos que 4,94% dos erros ocorridos na localização de situações de faltas que envolvam duas fases sem conexão a terra recaem nas duas áreas de transição anteriormente definidas. Com isto, o índice geral de acertos para estas situações passa de 88,78% para 93,72%. Este último índice é encontrado considerando-se somente o número de respostas corretas apresentadas pelo módulo referentes às zonas de proteção primária, secundária e terciária. Assim sendo, a

mesma análise será adotada para os demais tipos de faltas e os resultados, apresentados no seguimento do trabalho.

TABELA 28 - Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados

Percentagem (%) de Respostas Corretas (R.C.) e o Tempo de Processamento (T.P.) para cada módulo					
MÓDULO	T.P. (ms)	Faltas fase - terra	Faltas fase - fase	Faltas fase - fase - terra	Faltas trifásicas
	R.C.	100	100	100	100
DETECÇÃO 4050 padrões testados	2	71,94	76,46	82,14	84,44
	3	23,29	22,63	16,79	15,56
	4 - 5	4,77	0,91	1,07	-
	R.C.	99,92	100	99,26	99,52
CLASSIFICAÇÃO 4050 padrões testados	4	24,20	-	-	-
	5	37,94	4,44	6,18	-
	6	31,36	21,89	12,92	-
	7	5,60	17,12	31,28	30,37
	8	0,58	31,93	35,48	26,91
	9	0,24	13,58	10,54	24,70
	10 - 17	-	11,04	2,86	17,54
	R.C.	94,65	88,78	95,97	92,84
LOCALIZAÇÃO 3240 padrões testados	8	0,61	-	0,31	-
	9	4,12	2,06	6,50	-
	10	14,10	6,38	15,53	5,03
	11	19,60	22,02	27,01	17,61
	12	21,13	18,11	23,46	21,07
	13	17,39	20,06	13,89	28,63
	14	12,34	8,54	5,02	13,59
15	4,42	7,41	2,76	3,72	
16 - 18	0,94	4,20	1,49	3,19	

Vale ressaltar que este modelo proposto está atuando como um identificador direcional de faltas, um classificador de faltas (sejam as situações de faltas em sentido reverso ou a frente de um determinado ponto) e ainda como um localizador. Pelos índices apresentados na tabela, constata-se que o tempo médio de todo o processo (detecção, classificação e localização) para a grande maioria dos casos analisados é de 13 ms, o que difere de apenas 1 ms do suposto, quando da inicialização da pesquisa.

10.1 Resultados para as situações de faltas “fase – terra”

Neste e nos demais itens que seguem, podem ser observados gráficos que procuram ilustrar o comportamento do modelo quando da apresentação do conjunto de teste às arquiteturas de RNAs. Na abordagem, os resultados são apresentados evidenciando-se em específico às áreas (zonas) em que as faltas foram aplicadas, distinguindo-os entre a percentagem de acertos que recaem sobre as zonas de proteção primária, secundária ou terciária e sobre as duas zonas de transição.

10.1.1 Faltas envolvendo a fase “A” com conexão a terra

No primeiro gráfico da Figura 31, observam-se os índices de respostas corretas (100%) apresentado pelo modelo (módulo de detecção), para as situações de faltas aplicadas em sentido reverso e sobre as zonas de proteção primária, secundária e terciária. Conforme observado, todas as situações foram corretamente avaliadas e o modelo foi capaz de acusar o defeito, na maioria dos casos, em 2 ms pós-falta. No outro gráfico, os índices de acertos para as faltas aplicadas sobre as zonas de transição podem ser observados. 100% de respostas corretas também foi constatado para estes casos, respeitando um tempo de processamento máximo de 3 ms.

Na mesma linha de apresentação, a Figura 32 traz os índices de 100% de acertos para o módulo de classificação, sujeito às situações de faltas entre a fase A com conexão a terra. O tempo máximo para este módulo apresentar uma correta avaliação do sistema foi de 9 ms pós-falta. Contudo, o tempo médio para a grande maioria dos casos foi de 6 ms. A RNA2 apresentou um erro de classificação para uma situação de falta aplicada sobre a terceira zona de proteção. Esta condição de falta foi classificada como envolvendo a fase C com conexão a terra.

O último módulo que compõe o modelo para este tipo de falta, refere-se à localização da situação faltosa. Para as condições de faltas simuladas e apresentadas à RNA3, a mesma apresentou um índice de acertos próximo a 98% para as faltas sobre as zonas de proteção e, como já era esperado, um índice menor (71,30%) para as situações restritas às zonas de transição (Figura 33). Nesta etapa, o tempo de

processamento pertence ao intervalo de 8 a 16 ms, com um valor médio situado entre 12 e 14 ms.

A RNA3 apresentou três erros na localização das situações de faltas. Estas situações recaem sobre a segunda zona de proteção e foram alocadas como pertencendo à primeira zona de proteção.

Outro apontamento com respeito a esta RNA3 é que, mesmo para a situação avaliada erroneamente pelo módulo de classificação, a rede foi capaz de localizá-la corretamente, como pertencendo a terceira zona de proteção.

Os resultados observados para as demais situações de faltas fase - terra analisadas encontram-se ilustradas no anexo.




FIGURA 31 – Resultados do módulo de detecção para faltas envolvendo a fase A com conexão a terra




FIGURA 32 – Resultados do módulo de classificação para faltas envolvendo a fase A com conexão a terra




FIGURA 33 – Resultados do módulo de localização para faltas envolvendo a fase A com conexão a terra

10.2 Resultados para as situações de faltas envolvendo duas fases

10.2.1 Faltas envolvendo as fases A e B

No grupo de figuras que segue (34, 35 e 36), observam-se os índices de acertos para os módulos de detecção, classificação e de localização quando expostos às situações de faltas que envolvam as fases A e B sem conexão a terra. Novamente, tanto para o módulo de detecção (Figura 34) como para o de classificação (Figura 35), o índice alcançado não poderia ser melhor (100%). Já para o módulo de localização um índice de 90% de acerto foi observado (Figura 36). O localizador (RNA4) apresentou trinta erros sobre as zonas de proteção, sendo que destes, vinte estavam alocados sobre a primeira zona de proteção (treze foram erroneamente localizados como pertencendo à segunda e sete como pertencendo à terceira zona de proteção). Dos erros restantes, oito foram localizados como pertencendo à terceira zona de proteção, quando na realidade eram da segunda zona de proteção e os dois últimos erros em situação contrária (foram localizados como sendo da segunda zona de proteção quando de fato eram da terceira). Um índice de acertos também baixo foi observado para as situações de faltas situadas sobre as duas zonas de transição (69%, Figura 36).

As demais situações de faltas aplicadas entre as fases AC e BC sem conexão a terra estão ilustradas e comentadas em anexo.




FIGURA 34 – Resultados do módulo de detecção para faltas envolvendo as fases A e B sem conexão a terra

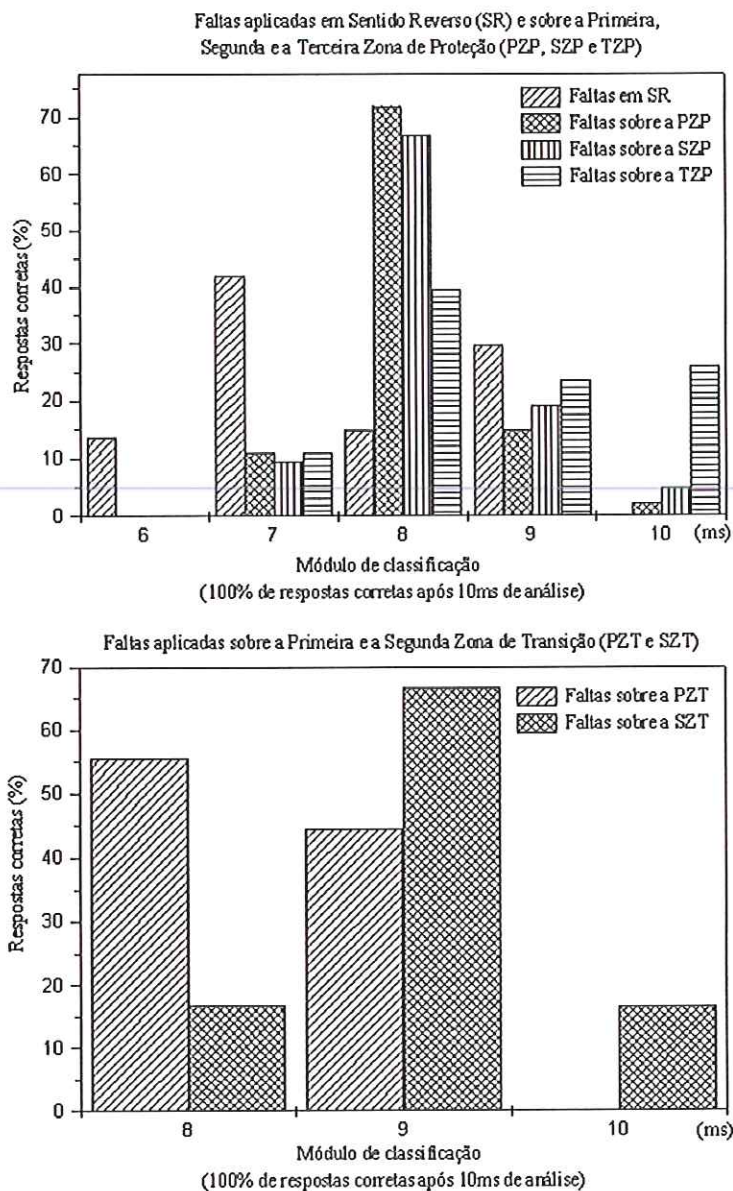


FIGURA 35 – Resultados do módulo de classificação para faltas envolvendo as fases A e B sem conexão a terra




FIGURA 36 – Resultados do módulo de localização para faltas envolvendo as fases A e B sem conexão a terra

10.3 Resultados para as situações de faltas envolvendo duas fases com conexão a terra

10.3.1 Faltas envolvendo as fases A e B com conexão a terra

A Figura 37 traz em seus dois gráficos o comportamento da RNA1 frente às situações de testes que se referem às faltas envolvendo as fases A e B com conexão a terra. Índices de 100% de acerto foram garantidos por esta arquitetura para todas as condições analisadas. Como nas ilustrações anteriormente apresentadas, novamente o tempo médio de processamento desta arquitetura, para a grande maioria das situações, manteve-se em 2 ms.

Já para a Figura 38, um índice de 97% é registrado para a RNA2 com respeito às situações de faltas aplicadas em sentido reverso e para as que se situam sobre as zonas de proteção. Este índice decorre do número de dez padrões/situações erroneamente classificados pelo módulo, sendo que cinco referem-se às situações em sentido reverso (quatro classificadas como envolvendo a fase A e uma as fases BC, ambas com conexão a terra). Do total, duas classificações errôneas recaem sobre a primeira zona de proteção (a RNA2 classificou as situações como envolvendo a fase B com conexão a terra) e três recaem sobre a terceira zona de proteção (dois padrões foram classificados pelo tipo AC com conexão a terra e um como do tipo AB). Para as situações de faltas aplicadas sobre as supostas zonas de transição, o modelo apresentou um índice de 100% de acerto.

Com respeito às situações de faltas que envolvam as fase A e B com conexão a terra, resta agora discutir os resultados observados quando da apresentação do conjunto de teste à RNA4 (Figura 39). Pelos gráficos apresentados, constata-se um índice geral de acertos de aproximadamente 97% para as situações de faltas aplicadas sobre as três zonas de proteção e um índice de 73% para as situações localizadas sobre as duas zonas de transição. 3% dos erros sobre as áreas de proteção, referem-se a seis erros sobre a primeira zona de proteção (padrões localizados como pertencendo à segunda zona de proteção), quatro erros atribuídos à segunda (um caracterizado como pertencente à primeira zona e três à terceira zona) e os três outros

erros limitados à terceira zona de proteção, sendo que estes foram alocados erroneamente à primeira zona de proteção.

Em anexo, apresentam-se os gráficos referentes as demais situações de faltas que envolvem duas fases com conexão ao terra.





FIGURA 37 – Resultados do módulo de detecção para faltas envolvendo as fases A e B com conexão a terra




FIGURA 38 – Resultados do módulo de classificação para faltas envolvendo as fases A e B com conexão a terra




FIGURA 39 – Resultados do módulo de localização para faltas envolvendo as fases A e B com conexão a terra

10.4 Resultados para as situações de faltas envolvendo as três fases

Índice de 100% de acerto para o módulo de detecção também é afirmado pela RNA1 quando valores de tensões e correntes, que caracterizam faltas trifásicas, são direcionadas às suas unidades de processamento na camada de entrada (Figura 40).




FIGURA 40 – Resultados do módulo de detecção para faltas envolvendo as fases A, B e C

Da ilustração seguinte, Figura 41, constata-se que para a função de classificação a RNA2 comprova o seu auto desempenho, apresentando um índice de acerto próximo a 98% para as situações de faltas consideradas. Seis situações de faltas foram classificadas como envolvendo somente as fases B e C quando, na realidade, além destas, o envolvimento da fase A também deveria ser acusado. Três erros situam-se sobre a segunda e três erros sobre a terceira zona de proteção. Para as demais situações em análise, a RNA2 proporcionou um índice de 100% de acerto.

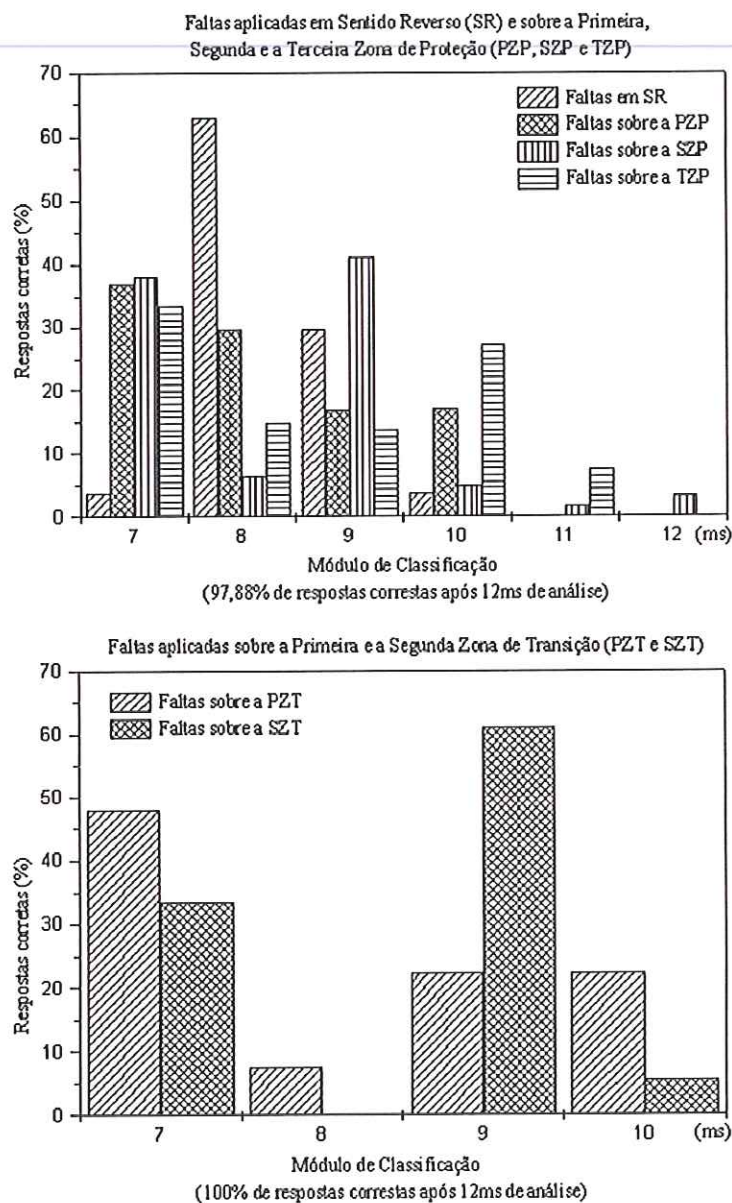


FIGURA 41 – Resultados do módulo de classificação para faltas envolvendo as fases A, B e C

Para finalizar os índices observados quando da apresentação do conjunto de teste, apresentam-se, na Figura 42, os valores que descrevem o comportamento da RNA5 que vêm a desempenhar a tarefa de localizar as situações de faltas sobre áreas delimitadas do sistema. Ao total, nove erros foram cometidos por esta arquitetura, sendo que todos recaem sobre a segunda zona de proteção. Destes, três foram indevidamente alocados à primeira e seis à terceira zona de proteção. Na mesma figura, um índice de 70% de acerto pode ser evidenciado para as demais situações de faltas.




FIGURA 42 – Resultados do módulo de localização para faltas envolvendo as fases A, B e C

10.5 Situações aplicadas considerando um alto valor para a resistência de falta

A maioria das faltas que ocorrem nos sistemas de potência são assimétricas e podem consistir de curtos-circuitos assimétricos, de faltas assimétricas através de impedâncias ou condutores abertos. As faltas assimétricas ocorrem entre linhas, entre linha e terra, ou podem ser entre duas linhas e terra. O caminho da corrente de falta de linha à linha ou de linha à terra pode ou não conter impedância (STEVENSON, 1986).

Faltas em linhas geralmente resultam do rompimento dos isoladores causados pela indução das descargas atmosféricas ou simplesmente pela falha dos mesmos. O caminho da corrente para faltas a terra passa pela resistência do arco e pela resistência da torre e de sua base, caso não forem utilizados cabos de aterramento. Faltas entre fases sobre as linhas resultam freqüentemente da grande oscilação/balanço dos condutores que estão próximos o suficiente para exceder o arco.

Sendo assim, a possibilidade de significantes valores de resistências de faltas existe, o que por sua vez, pode afetar ou inibir o desempenho dos relés de proteção. Das variáveis envolvidas, o arco e a base da torre à terra possuem características resistivas, sendo que as torres e os condutores aterrados são variáveis complexas. A resistência de arco entre 70 e 20.000 A pode ser expressa como

$$R_{arc} = \frac{440l}{I} \Omega \quad (19)$$

onde l é o comprimento do arco em “pés” e I é a corrente de arco (BLACKBURN, 1987). Na realidade, os valores dos arcos são variáveis, tendendo a começar com baixos valores e a crescer exponencialmente até valores altos, para então retornar a baixos valores com a sua extinção. Valores típicos de 1 a 2 Ω existem para aproximadamente os 0,5 s iniciais, com valores de pico variando de 25 a 50 Ω . A resistência da base da torre a terra pode variar de 1 a várias centenas de ohms e dependem das condições do solo. Do exposto, com tantas variáveis envolvidas, torna-se complicado representar a resistência de falta com um certo grau de exatidão ou realidade.

Para averiguar o desempenho do modelo proposto no trabalho, um novo conjunto de teste foi formulado e aplicado sobre o algoritmo computacional implementado. Estas novas situações de faltas, tentam ilustrar o comportamento dos módulos de detecção (RNA1), classificação (RNA2) e de localização (RNAs 3, 4 e 5) quando expostas a condições anormais de operação caracterizadas por uma elevada resistência de falta a terra de 100, 200, 300 e 400 Ω .

O conjunto de teste foi formado pela combinação das variáveis que representam a localização da falta (20, 40, 60, 90, 120, 150, 180, 210, 240, 250, 260, 280, 290 e 300 km), os ângulos de incidência da falta (20, 50 e 80°) e pelas quatro resistências de faltas a terra anteriormente citadas.

Ao total, 168 novas situações de cada tipo de faltas foram aplicadas sobre o modelo completo, sendo consideradas faltas envolvendo as fases A, B, C, AB, AC e BC com conexão a terra.

Para o módulo de detecção, 1008 diferentes padrões dos empregados no processo de treinamento (168 situações x 6 tipos de faltas) foram avaliados pelo algoritmo, e destes, apenas 20 padrões foram erroneamente interpretados. Dos erros, 1 encontra-se entre as linhas DE (Sentido Reverso – Figura 6), 9 sobre a Segunda Zona de Proteção e 10 sobre a Terceira Zona de Proteção. Sendo assim, um índice geral de acertos, que corresponde a aproximadamente 98% dos casos testados, pode ser observado pela Figura 43.

Como o algoritmo computacional implementado possui uma lógica seqüencial, as mesmas 1008 situações apresentadas ao módulo de detecção, foram também direcionadas ao módulo de classificação. Destas situações, apenas 5 foram erroneamente classificadas, recaindo 2 delas entre as linhas DE (Sentido Reverso) e 3 sobre a Terceira Zona de Proteção. Na Figura 44, observam-se os índices de acertos sobre as áreas delimitadas (Sentido Reverso e sobre as Zonas de Proteção Primária, Secundária e Terciária), bem como o tempo para a tomada de decisão por este módulo. Na figura, um índice geral de acertos de 97% é apresentado. No entanto, justificamos que, para este índice, consideraram-se os acertos deste módulo até um tempo de 11 ms. Na realidade, para cinco situações de faltas que incidem sobre a Terceira Zona de Proteção, a RNA2 propiciou uma correta classificação dispondo de

um maior tempo. Se estes acertos forem também considerados, o índice geral de acertos passa de 97% para 99,5% sobre os 1008 casos avaliados.

Para o módulo de localização, 792 situações de faltas (1008 situações simuladas – 216 situações de faltas aplicadas em Sentido Reverso) foram seqüencialmente apresentadas. Destas, 21 más localizações recaíram sobre a Primeira Zona de Proteção, 22 sobre a Segunda Zona de Proteção e 18 sobre a Terceira Zona de Proteção. Um índice geral de acertos próximo a 92% é apresentado na Figura 45. Este total de 61 erros, a priori, parece um tanto que elevado, mas cabe salientar que, destes, somente 2 erros são referentes a situações de faltas com uma resistência de falta de 100 Ω . Nove erros são referentes às situações de faltas com uma resistência de falta de 200 Ω , 16 considerando-se resistências de faltas de 300 Ω e 25 considerando-se resistências de faltas de 400 Ω . Uma ilustração geral dos “erros” cometidos pelos módulos avaliados (detecção, classificação e localização) é apresentado na Figura 46. Esta tem como propósito de somente explicitar que a grande maioria dos erros cometidos e observados estão associados aos altos valores de resistência de falta empregados, lembrando que o valor máximo utilizado em todo o processo de treinamento foi limitado a 100 Ω .




FIGURA 43 – Resultados do módulo de detecção para faltas envolvendo as fases A, B, C, AB, AC e BC, todas com conexão a terra (alta impedância)




FIGURA 44 – Resultados do módulo de classificação para faltas envolvendo as fases A, B, C, AB, AC e BC, todas com conexão a terra (alta impedância)




FIGURA 45 – Resultados do módulo de localização para faltas envolvendo as fases A, B, C, AB, AC e BC, todas com conexão a terra (alta impedância)




FIGURA 46 – Quadro geral de erros considerando-se altos valores de resistência de falta.

10.6 Variações no fluxo de energia

Quando um sistema de potência é exposto a uma condição de falta, a tensão e a corrente total em qualquer ponto sobre o mesmo pode ser considerada como consistindo de dois componentes: um devido ao componente senoidal em condição de regime permanente e outro devido à aplicação da falta. Este último é também muitas vezes designado como *quantidade superposta* e simplesmente é igual a variação ocorrida nos valores de tensão e corrente em virtude da inserção de uma determinada falta. A idéia de quantidades superpostas é melhor ilustrada referindo-nos à Figura 47. Considere nesta, o ponto R , onde a tensão $v_{Rf}(t)$ e a corrente $i_{Rf}(t)$ são as atuais quantidades existentes na presença de uma situação faltosa (Figura 47.a). Estas quantidades podem ser separadas entre quantidades senoidais de pré-falta $v_{RS}(t)$ e $i_{RS}(t)$ que são mostradas na Figura 47.b, e nas quantidades superpostas $\Delta v_R(t)$ e $\Delta i_R(t)$ mostradas na Figura 47.c (JOHNS & SALMAN, 1995).

Então

$$v_{Rf}(t) = v_{RS}(t) + \Delta v_R(t) \quad (20)$$

$$i_{Rf}(t) = i_{RS}(t) + \Delta i_R(t) \quad (21)$$

Deve ser notado que a soma dos valores das quantidades de pré e de pós-falta é igual à variação total em todos os pontos da rede. A rede superposta é portanto uma rede com todas as fontes de tensão levadas a zero (curto-circuito). A tensão superposta no ponto da falta é portanto zero para todo o tempo até o momento do distúrbio. A tensão das fontes superpostas fictícias na(s) fase(s) faltosa(s) é então igual em magnitude e oposta em sinal à tensão de pré-falta no ponto de falta (isto é, $v_f(t)$).

No trabalho, a aplicação destes conceitos decorre da dificuldade em se obter bons resultados para o módulo de localização quando da variação do fluxo de energia sobre o sistema. Dos testes preliminares aplicados sobre o módulo, não se conseguiu manter bem definidas as três áreas de atuação do relé de distância, sendo que, para a maioria dos erros cometidos, houve um sobre-alcance da primeira zona de proteção. Para exemplificar, das 600 situações de faltas testadas que incidem sobre a zona de proteção primária (60 situações de faltas para cada um dos 10 tipos de faltas), o

modelo apresentou um índice geral de acertos próximo a 98%. Já para as 360 situações incidentes sobre a segunda zona de proteção, este índice encontra-se próximo a 50% de acertos e para a última área a ser protegida, o mesmo atinge 67%. O índice geral, para as três áreas protegidas, fica em torno de 71%. Para os demais módulos de detecção e de classificação, os índices gerais de acertos são próximos a 99% para ambos os módulos. Estas situações de faltas foram aplicadas considerando-se uma variação de -3° sobre o fluxo de energia no sistema.

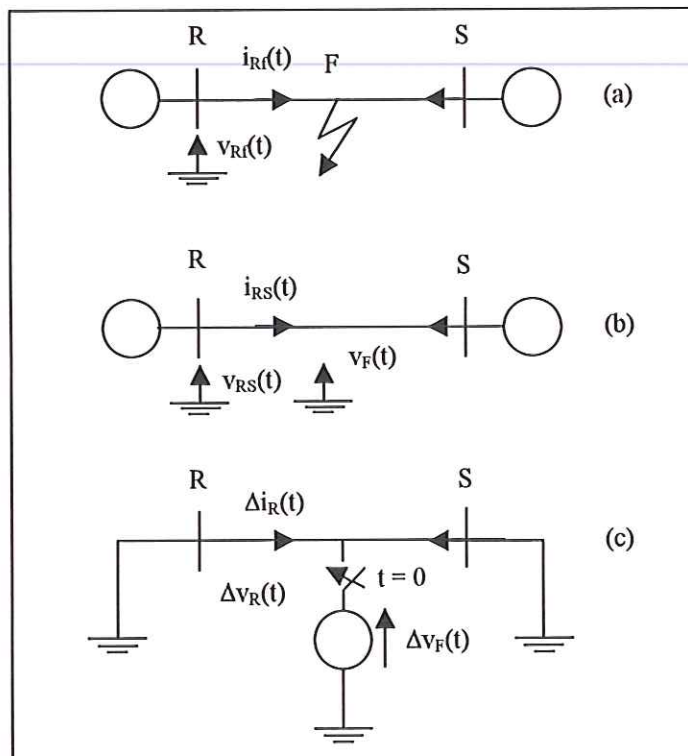


FIGURA 47 – Tensão e corrente superpostas geradas por uma condição de falta: (a) sistema atual sob uma condição de falta; (b) a rede em regime permanente (pré-falta) e (c) a rede superposta

Com a utilização de componentes superpostos, todas as três redes que compõem o módulo de localização (RNA3, 4 e 5) foram retreinadas, considerando-se as mesmas variações dos parâmetros (localização, resistência e ângulo de incidência da falta) utilizadas em seu treinamento anterior (itens 8.1-3). A única diferença é que os valores amostrados das tensões e correntes trifásicos passaram agora por um pré-processamento, onde o efeito da carga sobre os mesmos é atenuado. Assim, os valores amostrados empregados referem-se à diferença entre os valores trifásicos de

pós-falta e seus respectivos valores de pré-falta, conforme apresentado nas equações 20 e 21 deste item.

10.7 Resultados finais do algoritmo computacional proposto

Como análise final dos resultados apresentados pelo algoritmo computacional, apresenta-se, no que segue, dois novos conjuntos de testes formulados e apresentados seqüencialmente ao modelo completo de proteção proposto. Salienta-se que, nesta fase do trabalho, o algoritmo computacional implementado encontra-se completo, fazendo parte do mesmo os módulos de detecção, classificação e localização. O que diferencia este modelo final do modelo testado até então, é a inclusão de um pré-processamento dos dados direcionados ao módulo de localização, considerando-se neste a teoria de componentes superpostos.

10.7.1 Resultados considerando-se o mesmo fluxo de energia da fase de treinamento

Este conjunto de teste foi formado pela combinação das variáveis que representam a localização da falta (20, 40, 60, 90, 120, 150, 180, 210, 240, 260, 280, e 300 km), os ângulos de incidência da falta (20, 50 e 80°) e pelas quatro resistências de faltas a terra (40, 80, 120, 160 e 200 Ω) e fase-fase (0,40, 0,80, 1,20, 1,60 e 2,00 Ω), considerando-se as condições gerais de fluxo apresentadas na Figura 6.

Ao total, 180 novas situações de cada tipo de falta foram aplicadas sobre o modelo completo, sendo consideradas faltas envolvendo as fases A, B, C, AB, AC e BC com e sem conexão a terra, adicionando-se ainda as situações trifásicas.

Para esclarecer a composição das tabelas que seguem, da Tabela 29 coloca-se que para os módulos de detecção e classificação, em específico, foram simulados 540 novos padrões de testes (180 novas situações para cada um dos 3 tipos de faltas fase-terra). Destes 540 padrões, 135 foram aplicados em sentido reverso ao barramento E (Figura 6), 225 padrões recaíram sobre a primeira zona de proteção (PZP) e 90 padrões sobre a segunda e terceira zonas de proteção (SZP e TZP). Lembra-se que

estes 540 padrões foram apresentados seqüencialmente para os módulos de detecção, classificação e de localização. Para o último módulo (localização), foram apresentados 405 padrões, já que, do total de situações consideradas, 135 padrões dizem respeito às situações aplicadas em sentido reverso, não havendo a necessidade de atuação deste módulo.

Como das tabelas já apresentadas, afirma-se que para as faltas aplicadas em sentido reverso ao barramento E, 99,26% dos 135 padrões considerados, foram corretamente detectados dispendo-se de 2 ms após a ocorrência do evento e que, 0,74% das situações foram corretamente detectadas em até 3 ms. Da tabela, constata-se o alto desempenho apresentado pelas RNAs 1, 2 e 3 para todos os três módulos apresentados, evidenciando-se um tempo total do processo, para a grande maioria dos casos analisados, de 14 ms após a ocorrência da situação de falta.

Para a Tabela 30, reservam-se os resultados referentes às simulações de faltas entre duas fases com e sem conexão a terra. Novamente, 180 padrões para cada tipo de falta foram analisados (180×6 tipos de faltas = 1080 padrões) para os módulos de detecção e classificação. Já para o módulo de localização, 810 padrões foram aplicados, desconsiderando-se as 270 situações aplicadas em sentido reverso. Pelos resultados encontrados, um alto desempenho é observado pelas RNAs 1, 2 e 4, sendo que índices de acertos muito próximos de 100% foram proporcionados pelos três módulos avaliados. Cabe ainda salientar que também para estas situações de faltas aplicadas, para a grande maioria dos casos, o tempo total de processamento permaneceu em 14 ms após a ocorrência do defeito.

TABELA 29 - Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados para faltas envolvendo uma fase com conexão a terra.

Percentagem (%) de Respostas Corretas (R.C.) e o Tempo de Processamento (T.P.) para cada módulo FALTAS FASE – TERRA					
MÓDULO	T.P. (ms)	Sentido Reverso (135 padrões)	PZP (225 padrões)	SZP (90 padrões)	TZP (90 padrões)
DETECÇÃO 540 padrões testados	R.C.	100,00	100,00	98,89	98,89
	2	99,26	99,11	98,89	98,89
	3	0,74	0,89	-	-
CLASSIFICAÇÃO 540 padrões testados	R.C.	100,00	100,00	100,00	100,00
	4	-	45,33	-	-
	5	45,18	34,67	41,11	41,11
	6	33,33	20,00	36,67	36,67
	7	20,74	-	22,22	17,78
LOCALIZAÇÃO 405 padrões testados	8	0,74	-	-	4,44
	R.C.	-	94,21	94,44	97,78
	10	-	3,11	1,11	24,44
	11	-	8,89	10,00	30,00
	12	-	23,55	14,44	28,89
	13	-	38,67	31,11	8,89
	14	-	13,33	30,00	2,22
15	-	4,44	3,33	2,22	
16-20	-	2,22	4,44	1,11	

Finalizando a apresentação deste conjunto de testes, resta apenas apresentar os resultados obtidos pelo esquema completo de proteção frente às situações de faltas trifásicas. A Tabela 31 vem então ilustrar tais resultados, mostrando os índices gerais de acertos para as RNAs 1, 2 e 5 anteriormente apresentadas. Comparando-se com os demais índices de acertos já apresentados, os módulos de detecção (RNA1) e de classificação (RNA2) continuam apresentando um ótimo desempenho. No entanto, o módulo de localização (RNA5) manteve um índice médio de acertos em torno de 93%, apresentando no geral, um tempo médio de processamento de 14 ms.

TABELA 30 - Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados para faltas envolvendo duas fases com e sem conexão a terra.

Percentagem (%) de Respostas Corretas (R.C.) e o Tempo de Processamento (T.P.) para cada módulo FALTAS FASE – FASE e FASE – FASE - TERRA					
MÓDULO	T.P. (ms)	Sentido Reverso (270 padrões)	PZP (450 padrões)	SZP (180 padrões)	TZP (180 padrões)
DETECÇÃO 1080 padrões testados	R.C.	100,00	100,00	100,00	100,00
	2	100,00	92,22	94,44	94,44
	3	-	7,78	5,56	5,56
CLASSIFICAÇÃO 1080 padrões testados	R.C.	99,26	99,33	100,00	100,00
	5	1,85	4,44	5,55	5,56
	6	9,26	13,11	13,89	16,67
	7	45,55	31,78	35,00	31,67
	8	39,63	34,44	28,89	29,44
	9-13	2,96	15,55	16,66	16,67
LOCALIZAÇÃO 810 padrões testados	R.C.	-	97,54	96,11	97,78
	8	-	-	-	1,11
	9	-	-	-	3,89
	10	-	4,44	5,55	16,67
	11	-	12,22	5,00	28,89
	12	-	28,89	8,33	31,11
	13	-	24,22	22,78	9,44
	14	-	23,11	37,78	3,89
15	-	4,00	12,78	2,22	
	16-17	-	0,66	3,89	0,55

TABELA 31 - Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados para faltas envolvendo as três fases

Percentagem (%) de Respostas Corretas (R.C.) e o Tempo de Processamento (T.P.) para cada módulo FALTAS TRIFÁSICAS					
MÓDULO	T.P. (ms)	Sentido Reverso (45 padrões)	PZP (75 padrões)	SZP (30 padrões)	TZP (30 padrões)
DETECÇÃO 180 padrões testados	R.C.	100,00	100,00	100,00	100,00
	2	100,00	100,00	100,00	100,00
	3	-	-	-	-
CLASSIFICAÇÃO 180 padrões testados	R.C.	100,00	93,33	100,00	96,67
	7	33,33	26,67	-	53,33
	8	55,56	33,33	83,33	26,67
	9	11,11	26,67	6,67	16,67
	11	-	6,67	10,00	-
LOCALIZAÇÃO 135 padrões testados	R.C.	-	93,33	93,33	93,33
	10	-	-	-	53,33
	11	-	-	-	23,33
	12	-	8,00	-	16,67
	13	-	33,33	50,00	-
	14	-	41,33	43,33	-
	15	-	6,67	-	-
16	-	4,00	-	-	

10.7.2 Resultados considerando-se variações de $\pm 2^\circ$ no fluxo de energia

Tomando-se como base as variáveis que representam a localização da falta (20, 40, 60, 90, 120, 150, 180, 210, 240, 260, 280, e 300 km), os ângulos de incidência da falta (0, 45 e 90°), as três resistências de faltas a terra (40, 60 e 80Ω) e fase-fase (0,40, 0,60, e $0,80 \Omega$) e, as condições gerais do fluxo de energia variando de $\pm 2^\circ$, um novo conjunto de testes foi formulado e apresentado ao algoritmo final.

Ao total, 108 novas situações de cada tipo de falta foram aplicadas sobre o modelo completo, sendo consideradas faltas envolvendo as fases A, B, C, AB, AC e BC com e sem conexão a terra, adicionando-se ainda as situações trifásicas. Neste item, somente serão apresentados os resultados que dizem respeito a uma variação no fluxo de $+ 2^\circ$ quando os tipos de faltas A – terra, C - terra, AB – terra, BC – terra e AC – terra foram consideradas. Para uma variação no fluxo de $- 2^\circ$, os tipos de faltas analisados referem-se às situações que envolvem a fase B, as fases AB e as fases BC com conexão a terra, e as fases AC e ABC sem conexão a terra. Ressalta-se que a escolha desta forma de apresentação é tão somente pelos bons resultados já

encontrados, evitando-se com isto, um grande número de novas simulações (índices de acertos para variações de $\pm 3^\circ$ e $\pm 5^\circ$ serão posteriormente comentados).

Nas três tabelas que seguem (32 a 34), os resultados que dizem respeito as situações de faltas envolvendo as fases A, B e C com conexão a terra são apresentados. Para todos os casos em análise, tanto para o módulo de detecção como para o de classificação, um índice de 100% de acertos foi alcançado. Os únicos índices que destoam são os apresentados pelo módulo de localização que dizem respeito a três localizações errôneas, uma situação envolvendo a fase A com conexão a terra e as outras duas situações com respeito à fase B com conexão a terra. No primeiro caso, a situação de falta fase A - terra recai sobre a segunda zona de proteção e foi alocada como fazendo parte da primeira zona de proteção após 18 ms pós-falta de análise. Dos outros dois erros, as situações foram alocadas como pertencendo à segunda zona de proteção em 15 ms após a ocorrência do surto, quando na realidade pertenciam à terceira zona de proteção.

TABELA 32 - Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados considerando-se faltas envolvendo a fase A com conexão a terra e com uma variação de + 2° no fluxo de energia adotado

Percentagem (%) de Respostas Corretas (R.C.) e o Tempo de Processamento (T.P.) para cada módulo FALTAS FASE A –TERRA (+ 2°)					
MÓDULO	T.P. (ms)	Sentido Reverso (27 padrões)	PZP (45 padrões)	SZP (18 padrões)	TZP (18 padrões)
DETECÇÃO 108 padrões testados	R.C.	100,00	100,00	100,00	100,00
	2	100,00	73,33	100,00	66,67
	3	-	26,67	-	33,33
		R.C.	100,00	100,00	100,00
CLASSIFICAÇÃO 108 padrões testados	5	7,41	37,77	55,55	44,44
	6	37,04	28,89	27,78	16,67
	7	14,81	6,67	16,67	33,33
	8	40,74	26,67	-	5,55
		R.C.	-	100,00	94,34
LOCALIZAÇÃO 81 padrões testados	9	-	-	-	5,55
	10	-	-	-	50,00
	11	-	4,44	16,67	11,11
	12	-	37,78	16,67	33,33
	13	-	17,78	27,78	-
	14	-	31,11	22,22	-
	15	-	8,89	-	-
	16-17	-	-	11,00	-

TABELA 33 - Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados considerando-se faltas envolvendo a fase B com conexão a terra e com uma variação de - 2° no fluxo de energia adotado

Percentagem (%) de Respostas Corretas (R.C.) e o Tempo de Processamento (T.P.) para cada módulo FALTAS FASE B –TERRA (- 2°)					
MÓDULO	T.P. (ms)	Sentido Reverso (27 padrões)	PZP (45 padrões)	SZP (18 padrões)	TZP (18 padrões)
DETECÇÃO 108 padrões testados	R.C.	100,00	100,00	100,00	100,00
	2	100,00	82,22	66,67	83,33
	3	-	17,78	33,33	16,67
CLASSIFICAÇÃO 108 padrões testados	R.C.	100,00	100,00	100,00	100,00
	5	55,55	82,22	33,33	66,67
	6	33,33	13,33	66,67	33,33
LOCALIZAÇÃO 81 padrões testados	7	11,11	4,44	-	-
	R.C.	-	100,00	100,00	83,33
	9	-	-	-	5,55
	10	-	2,22	-	27,78
	11	-	17,78	5,55	16,67
	12	-	42,22	38,89	16,67
	13	-	22,22	22,22	5,55
14	-	11,11	16,67	11,11	
15	-	4,44	16,67	-	

TABELA 34 - Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados considerando-se faltas envolvendo a fase C com conexão a terra e com uma variação de + 2° no fluxo de energia adotado

Percentagem (%) de Respostas Corretas (R.C.) e o Tempo de Processamento (T.P.) para cada módulo FALTAS FASE C –TERRA (+ 2°)					
MÓDULO	T.P. (ms)	Sentido Reverso (27 padrões)	PZP (45 padrões)	SZP (18 padrões)	TZP (18 padrões)
DETECÇÃO 108 padrões testados	R.C.	100,00	100,00	100,00	100,00
	2	100,00	100,00	100,00	100,00
CLASSIFICAÇÃO 108 padrões testados	R.C.	100,00	100,00	100,00	100,00
	5	51,85	42,22	50,00	38,89
	6	48,15	31,11	33,33	38,89
LOCALIZAÇÃO 81 padrões testados	7	-	26,67	16,67	22,22
	R.C.	-	100,00	100,00	100,00
	9	-	-	-	5,55
	10	-	-	-	55,55
	11	-	-	-	11,11
	12	-	33,33	16,67	22,22
	13	-	33,33	38,89	5,55
	14	-	13,33	33,33	-
15	-	17,78	-	-	
16-17	-	2,22	11,11	-	

Para as Tabelas 35, 36 e 37 os resultados que dizem respeito às situações de faltas entre duas fases com conexão a terra são apresentados.

Na Tabela 35, o módulo de classificação apresentou um índice de acertos abaixo dos demais, sendo que 3 das 27 situações de faltas aplicadas em sentido reverso ao barramento E (Figura 6) foram classificadas como envolvendo somente a fase A como conexão a terra quando deveriam ser classificadas como envolvendo as fases A e B com conexão a terra.

Já na Tabela 36 o módulo de localização voltou a apresentar erros quando situações de faltas que envolvem as fases A e C com conexão a terra foram avaliadas. Para duas situações de faltas apresentadas, pertencendo à segunda zona de proteção, uma situação foi alocada como recaindo sobre a primeira zona de proteção e a outra sobre a terceira zona de proteção após 15 e 17 ms de ocorrência da falta respectivamente.

Com respeito a Tabela 37 vale ressaltar que um erro foi observado para o módulo de detecção para uma situação de falta que descreve o envolvimento das fases B e C com conexão a terra, sendo a mesma detectada como sendo em sentido reverso, quando era em sentido a frente do barramento E (primeira zona de proteção). Este erro no módulo de detecção levou a uma não atuação do módulo de localização para esta situação de falta, o que vêm a refletir no índice de acertos apresentado por tal módulo para as faltas que recaem sobre a primeira zona de proteção. Das situações avaliadas sobre a segunda zona de proteção, a RNA4 apresentou dois erros alocando os mesmos como pertencendo à primeira zona de proteção.

TABELA 36 - Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados considerando-se faltas envolvendo as fases AC com conexão a terra e com uma variação de + 2° no fluxo de energia adotado

Percentagem (%) de Respostas Corretas (R.C.) e o Tempo de Processamento (T.P.) para cada módulo FALTAS FASE AC -TERRA (+ 2°)					
MÓDULO	T.P. (ms)	Sentido Reverso (27 padrões)	PZP (45 padrões)	SZP (18 padrões)	TZP (18 padrões)
DETECÇÃO 108 padrões testados	R.C.	100,00	100,00	100,00	100,00
	2	100,00	66,67	88,89	66,67
	3	-	33,33	11,11	33,33
CLASSIFICAÇÃO 108 padrões testados	R.C.	100,00	100,00	100,00	100,00
	5	-	13,33	38,89	27,78
	6	14,81	44,44	38,89	38,89
	7	33,33	15,55	22,22	33,33
	8	37,04	26,67	-	-
	9	11,11	-	-	-
LOCALIZAÇÃO 81 padrões testados	10	3,70	-	-	-
	R.C.	-	100,00	88,89	88,88
	8	-	-	-	11,11
	9	-	-	-	22,22
	10	-	13,33	-	16,67
	11	-	20,00	16,67	11,11
	12	-	17,78	27,78	16,67
	13	-	33,33	11,11	5,55
14	-	15,55	16,67	-	
15	-	-	-	-	
16-17	-	-	16,66	5,55	

TABELA 37 - Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados considerando-se faltas envolvendo as fases BC com conexão a terra e com uma variação de - 2° no fluxo de energia adotado

Percentagem (%) de Respostas Corretas (R.C.) e o Tempo de Processamento (T.P.) para cada módulo FALTAS FASE BC -TERRA (- 2°)					
MÓDULO	T.P. (ms)	Sentido Reverso (27 padrões)	PZP (45 padrões)	SZP (18 padrões)	TZP (18 padrões)
DETECÇÃO 108 padrões testados	2	100,00	97,78	100,00	100,00
	3	100,00	86,67	100,00	100,00
	3	-	11,11	-	-
CLASSIFICAÇÃO 108 padrões testados	5	100,00	100,00	100,00	100,00
	5	-	-	-	-
	6	11,11	6,67	11,11	33,33
	7	81,48	53,33	72,22	44,44
	8	7,41	31,11	16,67	22,22
LOCALIZAÇÃO 81 padrões testados	9	-	8,89	-	-
	9	100,00	97,78	88,89	100,00
	9	-	-	-	27,78
	10	-	-	-	22,22
	11	-	11,11	5,55	-
	12	-	33,33	44,44	33,33
	13	-	26,67	22,22	5,55
	14	-	17,78	5,55	11,11
15	-	8,89	5,55	-	
16	-	-	5,55	-	

Agrupando novamente as próximas três tabelas (38, 39 e 40) podemos atestar um bom desempenho para os três módulos avaliados no que se refere às situações de faltas envolvendo as faltas entre duas fases sem conexão a terra.

Quanto aos módulos de detecção e classificação, os índices de acertos apresentados na Tabela 38 são evidentes, deixando a desejar somente com respeito ao módulo de localização. O módulo apresentou 3 erros de localização sobre a segunda zona de proteção e 3 erros sobre a terceira zona de proteção, sendo que as situações foram erroneamente alocadas como pertencendo à terceira e à segunda zonas de proteção respectivamente.

TABELA 38 - Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados considerando-se faltas envolvendo as fases A e B com uma variação de + 2° no fluxo de energia adotado

Percentagem (%) de Respostas Corretas (R.C.) e o Tempo de Processamento (T.P.) para cada módulo FALTAS FASE AB (+ 2°)					
MÓDULO	T.P. (ms)	Sentido Reverso (27 padrões)	PZP (45 padrões)	SZP (18 padrões)	TZP (18 padrões)
DETECÇÃO 108 padrões testados	R.C.	100,00	100,00	100,00	100,00
	2	100,00	100,00	100,00	100,00
	3	-	-	-	-
CLASSIFICAÇÃO 108 padrões testados	R.C.	100,00	100,00	100,00	100,00
	7	33,33	60,00	16,67	16,67
	8	66,67	33,33	50,00	16,67
	9	-	6,67	16,67	50,00
LOCALIZAÇÃO 81 padrões testados	10	-	-	16,67	16,67
	11	-	13,33	-	-
	12	-	26,67	-	50,00
	13	-	24,44	44,44	-
	14	-	28,89	27,78	-
	15	-	6,67	5,55	-
	16-17	-	-	5,55	16,66

Para a Tabela 39 errôneas atuações também foram observadas para o módulo de localização (RNA4) onde três situações foram alocadas como pertencendo à segunda zona de proteção, quando na realidade, pertenciam à terceira zona de proteção. Estas errôneas localizações foram executadas pelo módulo de localização dispondo-se de 10 ms após a ocorrência do surto.

TABELA 39 - Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados considerando-se faltas envolvendo as fases A e C com uma variação de - 2° no fluxo de energia adotado

Percentagem (%) de Respostas Corretas (R.C.) e o Tempo de Processamento (T.P.) para cada módulo FALTAS FASE AC (- 2°)					
MÓDULO	T.P. (ms)	Sentido Reverso (27 padrões)	PZP (45 padrões)	SZP (18 padrões)	TZP (18 padrões)
DETECÇÃO 108 padrões testados	R.C.	100,00	100,00	100,00	100,00
	2	100,00	73,33	66,67	66,67
	3	-	26,67	33,33	33,33
CLASSIFICAÇÃO 108 padrões testados	R.C.	100,00	100,00	100,00	100,00
	5	-	13,33	50,00	44,45
	6	-	66,67	50,00	55,55
	7	40,74	13,33	-	-
	8	40,74	6,67	-	-
LOCALIZAÇÃO 81 padrões testados	R.C.	-	100,00	100,00	83,33
	10	-	26,67	-	16,67
	11	-	60,00	16,67	11,11
	12	-	6,67	16,67	22,22
	13	-	-	33,33	16,67
	14	-	6,67	-	16,67
	15	-	-	16,67	-
16	-	-	16,67	-	

Nas Tabelas 40 e 41 que seguem o desempenho do algoritmo completo é avaliado frente às situações de faltas que envolvem as fases BC (+2°) e ABC (-2°) respectivamente.

No que diz respeito às faltas envolvendo as fases B e C (Tabela 40), para o módulo de detecção, observam-se três situações erroneamente detectadas como sendo em sentido reverso quando as mesmas recaem sobre a primeira zona de proteção. O mesmo ocorre com uma situação de falta que está alocada sobre a segunda zona de proteção. Com respeito ao módulo de localização, o mesmo não pôde localizar quatro situações (três sobre a primeira zona de proteção e uma sobre a segunda zona de proteção) em virtude dos erros provindos do módulo de detecção. Além destes erros, o módulo ainda apresentou um erro sobre a SZP, localizando a situação como pertencendo a TZP e um erro sobre a TZP, alocando a ocorrência sobre a SZP.

Dos resultados apresentados na tabela seguinte (Tabela 41), observam-se ótimos índices de acertos para os módulos de detecção e de classificação (100%).

Contudo, sete erros foram observados na aplicação do módulo de localização. Dois destes sobre a PZP (as duas sendo alocadas sobre a TZP), outros dois pertencendo a SZP (alocados como pertencendo também a TZP) e os três últimos erros, localizados sobre a TZP, sendo reconhecidos pelo módulo como recaídos sobre a SZP.

TABELA 40 - Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados considerando-se faltas envolvendo as fases B e C com uma variação de + 2° no fluxo de energia adotado

Percentagem (%) de Respostas Corretas (R.C.) e o Tempo de Processamento (T.P.) para cada módulo FALTAS FASE BC (+ 2°)					
MÓDULO	T.P. (ms)	Sentido Reverso (27 padrões)	PZP (45 padrões)	SZP (18 padrões)	TZP (18 padrões)
DETECÇÃO 108 padrões testados	R.C.	100,00	93,33	94,44	100,00
	2	100,00	93,33	94,44	100,00
CLASSIFICAÇÃO 108 padrões testados	R.C.	100,00	100,00	100,00	100,00
	7	11,11	6,67	16,67	50,00
	8	77,78	46,67	33,33	27,78
	9	-	33,33	50,00	22,22
	10	11,11	8,89	-	-
	11	-	4,44	-	-
LOCALIZAÇÃO 81 padrões testados	R.C.	-	93,33	88,89	94,44
	11	-	-	-	16,67
	12	-	40,00	-	-
	13	-	17,78	38,89	27,78
	14	-	28,89	33,33	33,33
	15	-	6,67	16,67	5,55
16	-	-	-	11,11	

TABELA 41 - Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados considerando-se faltas envolvendo as fases A, B e C com uma variação de - 2° no fluxo de energia adotado

Percentagem (%) de Respostas Corretas (R.C.) e o Tempo de Processamento (T.P.) para cada módulo FALTAS FASE ABC (- 2°)					
MÓDULO	T.P. (ms)	Sentido Reverso (27 padrões)	PZP (45 padrões)	SZP (18 padrões)	TZP (18 padrões)
DETECÇÃO 108 padrões testados	R.C.	100,00	100,00	100,00	100,00
	2	100,00	100,00	100,00	100,00
CLASSIFICAÇÃO 108 padrões testados	R.C.	100,00	100,00	100,00	100,00
	7	-	42,22	50,00	33,33
	8	55,55	37,78	5,55	-
	9	33,33	13,33	44,44	27,77
	10	11,12	6,67	-	22,22
LOCALIZAÇÃO 81 padrões testados	11	-	-	-	16,67
	R.C.	-	95,55	88,89	83,33
	10	-	-	-	33,33
	11	-	-	-	-
	12	-	20,00	5,55	-
	13	-	33,33	-	27,78
	14	-	40,00	55,55	16,67
15	-	2,22	16,67	5,55	
16	-	-	11,11	-	

10.7.3 Comentários gerais

Com respeito a um desempenho geral do modelo proposto, cabe destacar que, considerando todos os tipos de faltas analisadas e o mesmo fluxo de energia empregado quando da fase de treinamento, 1800 novos e diferentes padrões foram apresentados e avaliados pelos módulos de detecção e de classificação. Já para o módulo de localização, este número de novos e diferentes padrões é de 1350. Pela Tabela 42, observa-se o alto índice de acertos para tais módulos e vale ainda lembrar que as situações de faltas analisadas diferem e muito das aplicadas na fase de treinamento. Isto, em virtude das diferentes localizações das faltas, resistências de faltas fase – terra (40, 80, 120, 160 e 200 Ω), resistências de faltas entre fases (0,4, 0,80, 1,20, 1,60 e 2,00 Ω) e ângulos de incidência das faltas (20, 50 e 80°) aplicadas.

O módulo de detecção (RNA1) apresentou um pequeno número de errôneas decisões com respeito a situações de faltas reversas, quando na realidade as mesmas eram a frente do barramento E (Figura 6). O módulo de classificação (RNA2) também foi acometido de um pequeno número de erros onde, em certas situações,

classificou as faltas como envolvendo as fases B e C, quando envolviam as fases A e B ou as fases A, B e C. Outro erro atribuído a este módulo é a incorreta classificação de situações que envolviam as fases A e B com conexão a terra e, infelizmente, foram classificadas como envolvendo a fase A com conexão a terra. Um maior número de erros foi observado para o módulo de localização (RNAs 3, 4 e 5). O maior número destes erros dizem respeito a situações de faltas que pertenciam às zonas de proteção primária e ou secundária e foram erroneamente alocadas para a zona de proteção terciária (9 situações para o primeiro caso e 13 para o segundo). Ou ainda, localizações equivocadas sobre a SZP, quando na realidade pertenciam à primeira e à terceira zona de proteção (2 e 3 casos respectivamente). Ainda sobre este módulo, duas situações foram erroneamente alocadas como incidindo sobre a PZP, quando na realidade as mesmas recaiam sobre a TZP.

TABELA 42 - Respostas corretas para os módulos de detecção, classificação e localização integrados considerando-se o mesmo fluxo de energia adotado quando da fase de treinamento das RNAs

Módulo	Tipos de faltas analisadas, considerando-se o mesmo fluxo de energia quando da fase de treinamento das RNAs		
	Fase - terra	Duas fases com e sem conexão a terra	Trifásicas
Detecção (RNA1)	99,44%	100,00%	100,00%
Classificação (RNA2)	100,00%	99,65%	97,50%
Localização (RNAs 3, 4 e 5)	96,00%	97,30%	93,33%

Das Tabelas 32 a 41, as mesmas por si só ilustram o desempenho dos módulos de detecção, classificação e de localização frente às situações de faltas aplicadas, que diferem do conjunto de treinamento empregado, caracterizadas principalmente pelas variações de $\pm 2^\circ$ no fluxo de energia considerado.

No entanto, vale ressaltar que para a grande maioria dos casos testados (itens 10.7.1 e 10.7.2), o tempo médio de processamento, considerando-se os três módulos acima referenciados, permanece em torno de 14 ms após a ocorrência do defeito.

Para complementar a análise do desempenho do módulo de localização (redes RNA3, 4 e 5), comenta-se que previamente aos testes efetuados nestes dois últimos itens, um conjunto de teste foi formulado considerando-se variações de $\pm 3^\circ$ e $\pm 5^\circ$ sobre as condições de operação do sistema. Para cada um dos 10 tipos de faltas, 11 pontos de faltas sobre o sistema foram aplicados, tomando-se 3 valores para as resistências e 3 valores para os ângulos de incidência da falta (11 pontos x 3 resistências de faltas x 3 ângulos de incidência da falta = 99 novas situações de faltas para cada variação de -3° , $+3^\circ$, -5° e $+5^\circ$). Para o processo de teste, 5 janelas de dados foram empregadas para cada situação de falta aplicada. Assim, ao total temos 495 padrões para cada tipo de falta em análise (99 situações de faltas x 5 janelas de dados). Na ocasião destes testes somente o módulo de localização de faltas foi analisado, independentemente dos demais (detecção e de classificação). Estima-se que o tempo máximo disposto para se obter as respostas deste módulo em análise, encontra-se em 7 ms após a tomada de decisão do módulo de classificação. Comenta-se que o índice geral de acertos para os 10 tipos de faltas listados, considerando-se uma variação de -3° nas condições de operação do sistema é próximo a 95,7%. Já para uma variação de $+3^\circ$, o mesmo é de 93,4%. Os demais índices refletem 91,51% e 89,39% de acertos para variações de -5° e $+5^\circ$ no fluxo de energia, respectivamente. Comparando-os com os anteriormente apresentados ($\pm 3^\circ$) fica claro uma considerável diminuição na percentagem de acertos já que as situações de faltas testadas começam a destoar e muito das que foram empregadas no processo de treinamento.

10.7.4 O estudo do esquema proposto para linhas com circuito duplo

A grande maioria dos sistemas de proteção designados a linhas de transmissão são projetados dispondo-se da proteção de distância. A proteção de distância, no entanto, apresenta certa dificuldade quando aplicada a linhas paralelas

devido à complexidade do acoplamento mútuo existente entre os seus condutores, refletidos principalmente nos circuitos de seqüência zero. Se o efeito do acoplamento mútuo não for de alguma maneira compensado, teremos associado a esta condição um erro no cálculo da impedância aparente e, como consequência, uma incorreta atuação dos relés de distância. Em particular, se este erro propiciar um sobre-alcance na área de proteção, uma maior seção do sistema poderá ser desligado, ocasionando grandes perdas e ou distúrbio no sistema de potência. Nesta condição, uma das principais propriedades de um sistema de proteção - a seletividade, ficará comprometida. Segundo JONGEPIER & SLUIS (1997), o procedimento comum dos relés de distância aplicados a circuitos múltiplos é que estes apresentam um sub-alcance quando os circuitos paralelos estão em serviço e um sobre-alcance quando os mesmos estão fora de serviço e aterrados em ambos os lados. Esta inexatidão causada pela influência dos circuitos paralelos é normalmente contornada aplicando-se margens de segurança aos limites das zonas de proteção. Tipicamente, 15% ou mais do comprimento da linha é coberto por zonas de proteção de retaguarda. Tais procedimentos consideram a porção a ser protegida do sistema como sendo estática, ou seja, sem variações nas condições de operações.

Sobre toda a dificuldade acima delineada, cabe para o momento citar o trabalho defendido por AGGARWAL *et al.* (1999), onde a classificação das situações de faltas sobre um circuito duplo de linhas é realizado dispondo-se da teoria de RNAs. Fica claro pela aplicação, a necessidade de se representar o sistema, considerando-se as tensões trifásicas juntamente com as seis correntes de fase de ambos os circuitos expostos às várias situações de faltas. Comparando-se então o circuito duplo empregado por Aggarwal com o sistema simples analisado neste trabalho (Figura 6), poderíamos adaptar este último para verificarmos o seu comportamento se um segundo sistema trifásico fosse acoplado, por exemplo, entre o barramento EF.

Da aplicação de RNAs, como característica inerente ao modelo, espera-se um sistema adaptativo com grande capacidade de generalização frente às diversas condições de operação do sistema. Salientamos que tal generalização somente pode ser alcançada se uma correta representação do sistema e de suas variáveis for repassado ao modelo neural durante um longo processo de treinamento. Em nosso

caso, o conhecimento descrevendo as diversidades que o sistema possa vir a enfrentar foi repassado tomando-se somente os valores amostrados das tensões e correntes trifásicas na localização do relé, ou seja, no barramento E. No entanto, com esta nova situação de linhas paralelas, o sentimento adquirido durante o desenvolvimento do trabalho, acredita-se que este novo sistema com um circuito duplo a ser avaliado perde totalmente a relação com os parâmetros que foram repassados quando do treinamento do sistema neural. Para realmente caracterizarmos este novo sistema de transmissão, um novo processo de treinamento deveria ser efetuado, considerando-se as tensões trifásicas e, como já citado, as seis correntes provenientes de ambos os circuitos. Um extensivo estudo do efeito do acoplamento mútuo sobre os componentes de seqüência também seria desejável.

Ótimo seria se todo o processo de aquisição e simulação dos dados, representação do sistema, escolha das arquiteturas neurais, processos de treinamento e de teste fossem o mais generalizados possíveis. Mas para o momento, acreditamos que cada problema deva ser abordado com uma específica modelagem, respeitando os diversos graus de dificuldades associados.

10.7.5 Evolução de faltas envolvendo duas fases sem conexão a terra para faltas envolvendo duas fases com conexão a terra

Para ilustrar o comportamento do algoritmo proposto frente à evolução de faltas, um número de dez novas situações (dez diferentes situações para cada tipo de faltas AB, AC e BC) foram aplicadas sobre o sistema. Destas, cinco fazendo a evolução de faltas fase-fase para fase-fase-terra considerando um tempo de pós-falta de 3 ms, ou seja, estaríamos com o módulo de classificação ativo e, cinco situações após 10 ms, onde o módulo de localização estaria ativo. As novas situações de faltas foram aplicadas considerando-se a localização da falta a 20, 120, 180, 260 e 280 km, com uma resistência entre fases de $0,1 \Omega$ e 50Ω entre fases a terra, com um ângulo de incidência da falta de 90° . Para os trinta casos em análise, o módulo de detecção (RNA1), apresentou 100% de acerto. Já o módulo de classificação (RNA2) apresentou duas decisões errôneas mantendo para as vinte e oito demais situações, respostas corretas ao esperado (93,3 % de acerto). Para o módulo de localização

(RNA4), um número de três incorretas decisões foram observadas (90% de acerto). Em uma delas, o módulo alocou a situação (falta envolvendo as fases A e B com conexão a terra) como pertencendo à primeira zona de proteção quando a mesma incidia sobre a segunda zona de proteção. Para as outras duas ocorrências, uma envolvendo as fases A e C e a outra envolvendo as fases B e C, ambas com conexão a terra, as situações de faltas consideradas pertenciam a terceira zona de proteção e foram apontadas como pertencendo à segunda zona de proteção.

Do número de situações apresentadas, constata-se que o algoritmo computacional respondeu adequadamente para a evolução de faltas. O tempo médio de processamento para a maioria dos casos permaneceu em 2 ms após a ocorrência do surto para o módulo de detecção (RNA1), 8 ms para o módulo de classificação (RNA2) e 12 ms para o de localização (RNA4).

Cabe salientar que, conforme o modelo proposto, independente do módulo de classificação acusar corretamente ou não uma situação de falta envolvendo duas fases com ou sem conexão a terra, a mesma RNA4 atuará com a função de localizar o defeito. Ou seja, sendo detectada uma condição anormal, se a RNA2 classificar tal situação como uma falta envolvendo somente duas fases ou duas fases com conexão a terra, a RNA4 será ativada com a função de localizar a situação, havendo uma considerável possibilidade de fazê-la corretamente.

11 O EMPREGO DE REDES DE FUNÇÕES BASE RADIAIS NA LOCALIZAÇÃO DA FALTA

Pelos resultados observados até então, as arquiteturas Multi Layer Perceptron (MLP) empregadas, apresentaram uma boa solução no desempenho da função de proteção de distância no sistema de transmissão. No entanto, cabe ainda algumas observações importantes, principalmente no que se refere ao grande número de padrões necessários para a fase de treinamento quando do emprego destas arquiteturas. Este grande número de padrões de treinamento necessário é, em grande parte, responsável pela lentidão do algoritmo (normalmente emprega-se o algoritmo *back-propagation* ou uma variação do mesmo) em alcançar uma convergência aceitável. Mesmo para problemas relativamente simples, o algoritmo *back-propagation* geralmente requer que todos os padrões de treinamento sejam apresentados centenas ou até milhares de vezes (BRAGA *et al.*, 1999). Como também reafirmado por BRAGA, o algoritmo *back-propagation* procura minimizar o erro obtido pela rede ajustando pesos e limiares para que eles correspondam às coordenadas dos pontos mais baixos da superfície de erro. A convergência esperada em torno de um “mínimo global” é então, muitas vezes, confundida com obtenção de mínimos locais, que são pontos na superfície de erro que apresentam uma solução estável, embora não sejam a saída correta. Outro problema a ser considerado, que também ocorre durante a fase de treinamento de redes MLP, é a possível ocorrência da memorização dos padrões de treinamento, onde a rede implementada grava as peculiaridades e ruídos a ela apresentados (ocorrência de *overfitting*).

Para exemplificar um modelo de rede neural que vem a sobrepor alguns dos problemas acima delineados, citamos, para o momento, o trabalho defendido por DASH *et al.* (2001) onde os mesmos, aplicam uma rede de Função Base Radial

(*Radial Basis Function* – RBF) na proteção de distância. Neste estudo, o modelo de rede neural é empregado às funções de classificação e de localização do ponto exato de situações de faltas sobre um determinado sistema. Através de um procedimento de aprendizagem seqüencial, os dados de entradas (valores de picos de pós-falta das amostras da tensão e corrente fundamental, componente de seqüência zero da corrente e a freqüência de operação do sistema, todos normalizados) são empregados para formar os conjuntos de treinamento e de teste do sistema neural. Para a função de localização de falta em específico, 70 padrões/situações de faltas foram aplicadas sobre o sistema, tendo como variáveis a carga de pré-falta, as impedâncias das fontes, a localização e a resistência da falta, os tipos de faltas e os ângulos de injeção das mesmas. Dos ótimos resultados apontados para a função de localização da falta, fica claro, quando comparado às arquiteturas que se utilizam do algoritmo de treinamento *back-propagation*, a acentuada redução do tempo computacional e do número de padrões empregados no processo de treinamento.

Considerando-se as observações anteriores e na busca de uma abordagem alternativa para a função de localizar a falta, este capítulo traz em especial, a aplicação de redes RBF na localização de faltas que envolvem uma fase com conexão a terra. Para esta nova abordagem da aplicação de RNAs, todas as observações e considerações adotadas serão apresentadas no que segue.

11.1 RBF aplicada a localização de faltas fase – terra

Considerando-se o que talvez seria uma barreira para o emprego de redes MLPs à função de localizar uma situação de falta, a necessidade de um grande número de padrões de treinamento, apresenta-se, no que segue, uma arquitetura de rede RBF alternativa, que vem a desempenhar e a apresentar resultados promissores para tal função. Ressalta-se que este modelo alternativo é baseado em um estudo inicial para a aplicação, e que, um maior aprofundamento no que se refere ao modelo a ser realmente empregado é ainda desejável.

Conforme apresentado na Figura 5 (Capítulo 4), o módulo de localização é composto por três redes MLPs. Uma designada para localizar faltas que envolvam uma fase a terra (RNA3), outra arquitetura (RNA4) que responde pelas faltas que

envolvam duas fases com e sem conexão a terra e uma terceira rede (RNA5) que atende a localização de faltas trifásicas. Para o momento, a idéia é formar um módulo de localização alternativo com dez redes neurais, ao invés de somente três. Cada rede neural seria então responsável pela localização de um específico tipo de falta. Assim sendo, uma rede neural atenderia as situações de faltas que envolvam a fase “A” com conexão a terra, outra a fase “B” com conexão a terra e assim por diante, para os demais possíveis tipos de faltas sobre o sistema de transmissão. Tal implementação é coerente com os demais módulos já implementados (detecção e classificação), já que o módulo de classificação (RNA2) estaria acusando o tipo de falta ocorrido e conseqüentemente, qual das dez redes neurais deveria ser ativada. Desta maneira, dispondo-se ainda das mesmas 24 unidades de processamento na camada de entrada (4 amostras trifásicas de cada um dos sinais de tensão e corrente sob análise) e com um mesmo número de unidades da camada de saída (três unidades), busca-se por este modelo alternativo uma melhor caracterização do problema, procurando reduzir o número de padrões empregados quando da fase de treinamento. Somente para relembrar, no caso de faltas que envolveram uma fase com conexão a terra, foram empregados para formar o conjunto de treinamento, um número aproximado de 1200 situações para cada um dos três possíveis tipos de faltas (Tabela 14).

Na busca de uma arquitetura de rede RBF que atendesse a função desejada, localizar corretamente uma situação de falta sobre as três zonas de proteção delimitadas (Capítulo 8), elaborou-se um conjunto de treinamento e um pequeno conjunto de validação para acompanhar e avaliar o desempenho das arquiteturas em análise.

O conjunto de treinamento é formado considerando-se as seguintes variáveis:

- a localização da falta medida a partir do barramento D (Figura 6): 90, 155, 222, 228, 250, 275, 280, 300 e 324 (km);
- a resistência de falta: 1, 25, 50, 75 e 100 (Ω) e
- o ângulo de incidência da falta: 0, 45 e 90 ($^{\circ}$).

Da combinação destas variáveis resulta um conjunto de padrões composto por 135 diferentes situações de faltas (aproximadamente 11% do número de 1200 amostras anteriormente mencionadas). Estas diferentes situações de faltas foram apresentadas as arquiteturas de redes RBF em análise, dispondo-se de uma a cinco

janelas de dados. Pela análise do desempenho das redes, observou-se que duas janelas de dados são suficientes para a arquitetura assimilar as informações quanto a localização da falta. A primeira janela de dados empregada engloba da nona a décima segunda amostra pós-falta dos valores trifásicos de tensão e corrente (4 amostras por fase dos sinais analisados) e a segunda janela de dados engloba da décima segunda a décima quinta amostra pós-falta dos mesmos valores em análise. Deste modo, adotando-se os padrões de treinamentos apresentados através de duas janelas de dados, o conjunto total é formado por 270 diferentes padrões (135 distintas situações de faltas x 2 janelas de dados).

Um conjunto de validação para uma prévia análise do desempenho das arquiteturas em treinamento também foi elaborado. Este é formado pela combinação de nove posições de aplicação da falta (situadas a 90, 120, 150, 180, 210, 240, 260, 280 e 300 km do barramento D) com as três resistências de falta (30, 60 e 90 Ω) e com os três ângulos de incidência da falta (0, 45 e 90 $^\circ$). Da combinação entre as variáveis mencionadas, resulta um conjunto de validação com 54 novas e diferentes situações de faltas, sendo que as mesmas foram consideradas por duas consecutivas janelas de dados (54 situações de faltas x 2 janelas de dados = 108 novos e diferentes padrões de validação). Este conjunto foi aplicado em conjunto com o treinamento das arquiteturas, sendo este caracterizado como um conjunto de validação para se evitar o sobre-treinamento das arquiteturas (*overfitting*).

Várias arquiteturas de redes RBF foram treinadas e analisadas, alterando-se os principais parâmetros do processo como:

- número de padrões empregados na fase de treinamento;
- número de janelas de dados apresentados às arquiteturas no processo de treinamento;
- número de ciclos (épocas) de treinamento que os padrões foram apresentados, tanto no primeiro como no segundo estágio e
- taxa de aprendizagem e *cluster threshold* para o primeiro estágio e taxa de aprendizagem e *momentum* para o segundo estágio de treinamento, entre outros.

Ao total, 59 diferentes arquiteturas de redes RBF foram treinadas e avaliadas quanto a sua capacidade em aprender frente ao conjunto de treinamento e ao seu desempenho frente ao conjunto de validação formulado.

Dentre todas, a arquitetura que melhor se enquadrou às expectativas apresenta 24 unidades de processamento na camada de entrada e 3 unidades de processamento na camada de saída, como em todas as outras redes MLPs já implementadas. No entanto, esta arquitetura, em específico, apresenta 240 unidades de processamento na sua camada protótipo ou intermediária. Cabe ressaltar que este número de unidades intermediárias foi determinado de forma empírica, variando-se este número de 40 a 400 unidades, dependendo do número de padrões empregados no conjunto de treinamento. Para o número de padrões de treinamento acima mencionado (270), observou-se que um número inferior a 240 elementos de processamento, a rede RBF apresenta um erro RMS (*Root Mean Square Error*) não desprezível tanto para os padrões de treinamento como para os de validação. Um número acima de 270 elementos de processamento acarreta um pequeno erro RMS com respeito ao conjunto de treinamento e um alto valor para o erro RMS quando sujeito ao conjunto de validação (*overfitting*). Para a arquitetura escolhida o erro RMS para o conjunto de treinamento, considerando as três unidades da camada de saída, permaneceu próximo a 0,1 e para o conjunto de validação, na ordem de 0,04.

Cabe evidenciar alguns dos parâmetros que foram ajustados quando da implementação da arquitetura de rede RBF pelo *software NeuralWorks*. Como já evidenciado, o número de padrões empregados na fase de treinamento corresponde a um total de 135 diferentes situações de faltas envolvendo a fase “A” com conexão a terra, sendo empregadas duas janelas de dados, o que nos deixa com um total de 270 diferentes padrões. O número de ciclos (épocas) de treinamento que os padrões foram apresentados à rede, foi para primeiro estágio de treinamento de 40.000 e, para o segundo estágio, em torno de 560.000 ciclos. Ressalta-se que a rede RBF foi treinada considerando-se um conjunto de validação e a melhor característica de generalização, por parte da arquitetura escolhida, foi alcançada com aproximadamente 350.000 ciclos de treinamento. Os valores dos erros RMS anteriormente apresentados referem-se a esta situação. Para a camada intermediária os valores da taxa de aprendizagem e *cluster threshold* para o primeiro estágio foram alterados, com o passar dos 40.000 ciclos de treinamento, entre os valores de 0,3 a 0,15 para ambas as variáveis. Para a taxa de aprendizagem e *momentum* do segundo estágio do processo de treinamento (treinamento supervisionado), os valores situam-

se entre 0,2 a 0,05 para a primeira variável e 0,4 a 0,1 para a segunda, respectivamente.

É válido destacar que para as 54 novas e diferentes situações de faltas reapresentadas à rede RBF por duas janelas de dados (conjunto de validação), 108 diferentes padrões dos empregados no processo de treinamento, o índice de acertos obtido foi de 100%, para as três zonas de proteção.

11.2 Resultados observados pela aplicação de RBF

Procurando validar o desempenho da rede RBF, um amplo conjunto de teste foi formulado e aplicado sobre a mesma. As variações das situações de faltas aplicadas consistem da combinação entre a localização da falta (90, 120, 150, 180, 210, 220, 240, 260, 280 e 300 km) com a resistência de falta (30, 60 e 90 Ω) e os ângulos de incidência da falta (0, 45 e 90°). Da combinação entre estas variáveis resultam 90 novas e diferentes situações de faltas aplicadas sobre o sistema. Como para os demais testes realizados sobre o módulo de localização, 5 janelas de dados foram avaliadas para a decisão final da rede frente a cada situação de falta em análise, o que nos deixa com um conjunto de 450 novos padrões para o tipo de falta aplicada.

A rede RBF foi analisada independente dos demais módulos de redes neurais (detecção e classificação) sendo que as respostas obtidas para algumas situações em específico, considerando-se as 5 janelas de dados, estão relatadas nas tabelas que seguem (Tabelas 43 a 49).

Na Tabela 43 apresentam-se as respostas da rede RBF frente as cinco janelas de dados que descrevem uma situação de falta envolvendo a fase “A” com conexão a terra, aplicada a 90 km do barramento D, com uma resistência de falta de 30 Ω e um ângulo de incidência de 0°. Nesta, observam-se tanto as três saídas desejadas para o modelo quanto as três saídas obtidas frente a situação acima descrita. Seguindo a idéia de analisar as cinco janelas de dados, como constata-se pelos resultados apresentados, a rede RBF localiza corretamente a situação apresentada como alocada sobre a zona de proteção primária.

Para o novo conjunto de teste avaliado, a rede RBF apresentou 34 erros de localização, considerando-se cada janela de dados apresentada de forma independente (índice de 92,44% de acerto em 450 padrões). No entanto, da análise das 5 janelas de dados, somente 4 erros foram constatados, o que nos permite destacar um índice de acerto de 95,55% para as 90 situações de faltas avaliadas. Uma localização errônea situada a 210 km do barramento D e as outras três a 260 km da mesma referência.

TABELA 43 – Saídas desejadas e esperadas para as cinco janelas de dados analisadas, considerando-se uma falta envolvendo a fase “A” com conexão a terra, aplicada a 90 km do barramento D, com uma resistência de falta de 30Ω e um ângulo de incidência de 0° (falta situada sobre a primeira zona de proteção)

Situação de falta fase “A “ - terra	Saídas desejadas			Saída obtidas		
	L ₁	L ₂	L ₃	L ₁	L ₂	L ₃
1ª janela de dados	1,000	0,000	0,000	0,699	0,000	0,877
2ª janela de dados	1,000	0,000	0,000	0,780	0,000	0,669
3ª janela de dados	1,000	0,000	0,000	0,999	0,000	0,000
4ª janela de dados	1,000	0,000	0,000	0,999	0,000	0,000
5ª janela de dados	1,000	0,000	0,000	0,999	0,000	0,000
90 km		30 Ω		0°		

Para as demais tabelas (44 a 49), segue-se o mesmo modo de apresentação, de onde observa-se o bom desempenho da rede RBF frente às situações apresentadas. Destaque deve ser levantado para as Tabelas 48 e 49, as quais ilustram situações de faltas situadas sobre as zonas de transição anteriormente definidas (capítulo 8).

TABELA 44 – Saídas desejadas e esperadas para as cinco janelas de dados analisadas, considerando-se uma falta envolvendo a fase “A” com conexão a terra, aplicada a 210 km do barramento D, com uma resistência de falta de 60 Ω e um ângulo de incidência de 45° (falta situada sobre a primeira zona de proteção)

Situação de falta fase “A” - terra	Saídas desejadas			Saída obtidas		
	L ₁	L ₂	L ₃	L ₁	L ₂	L ₃
1ª janela de dados	1,000	0,000	0,000	0,999	0,000	0,000
2ª janela de dados	1,000	0,000	0,000	0,999	0,000	0,000
3ª janela de dados	1,000	0,000	0,000	0,999	0,000	0,000
4ª janela de dados	1,000	0,000	0,000	0,999	0,000	0,000
5ª janela de dados	1,000	0,000	0,000	0,999	0,000	0,000
210 km		60 Ω		45°		

TABELA 45 – Saídas desejadas e esperadas para as cinco janelas de dados analisadas, considerando-se uma falta envolvendo a fase “A” com conexão a terra, aplicada a 240 km do barramento D, com uma resistência de falta de 90 Ω e um ângulo de incidência de 90° (falta situada sobre a segunda zona de proteção)

Situação de falta fase “A” - terra	Saídas desejadas			Saída obtidas		
	L ₁	L ₂	L ₃	L ₁	L ₂	L ₃
1ª janela de dados	0,000	1,000	0,000	0,216	0,901	0,000
2ª janela de dados	0,000	1,000	0,000	0,044	0,996	0,000
3ª janela de dados	0,000	1,000	0,000	0,018	0,997	0,000
4ª janela de dados	0,000	1,000	0,000	0,171	0,852	0,000
5ª janela de dados	0,000	1,000	0,000	0,056	0,976	0,000
240 km		90 Ω		90°		

TABELA 46 – Saídas desejadas e esperadas para as cinco janelas de dados analisadas, considerando-se uma falta envolvendo a fase “A” com conexão a terra, aplicada a 260 km do barramento D, com uma resistência de falta de 90 Ω e um ângulo de incidência de 90° (falta situada sobre a segunda zona de proteção)

Situação de falta fase “A” - terra	Saídas desejadas			Saída obtidas		
	L ₁	L ₂	L ₃	L ₁	L ₂	L ₃
1ª janela de dados	0,000	1,000	0,000	0,000	0,998	0,000
2ª janela de dados	0,000	1,000	0,000	0,000	0,999	0,000
3ª janela de dados	0,000	1,000	0,000	0,000	0,997	0,000
4ª janela de dados	0,000	1,000	0,000	0,022	0,897	0,000
5ª janela de dados	0,000	1,000	0,000	0,006	0,982	0,000
260 km		90 Ω		90°		

TABELA 47 – Saídas desejadas e esperadas para as cinco janelas de dados analisadas, considerando-se uma falta envolvendo a fase “A” com conexão a terra, aplicada a 300 km do barramento D, com uma resistência de falta de 30 Ω e um ângulo de incidência de 0° (falta situada sobre a terceira zona de proteção)

Situação de falta fase “A” - terra	Saídas desejadas			Saída obtidas		
	L ₁	L ₂	L ₃	L ₁	L ₂	L ₃
1ª janela de dados	0,000	0,000	1,000	0,000	0,000	0,999
2ª janela de dados	0,000	0,000	1,000	0,000	0,000	1,000
3ª janela de dados	0,000	0,000	1,000	0,000	0,000	1,000
4ª janela de dados	0,000	0,000	1,000	0,000	0,000	1,000
5ª janela de dados	0,000	0,000	1,000	0,000	0,000	1,000
300 km		30 Ω		0°		

TABELA 48 – Saídas desejadas e esperadas para as cinco janelas de dados analisadas, considerando-se uma falta envolvendo a fase “A” com conexão a terra, aplicada a 220 km do barramento D, com uma resistência de falta de 60 Ω e um ângulo de incidência de 45° (falta situada sobre a primeira zona de transição)

Situação de falta fase “A” - terra	Saídas desejadas			Saída obtidas		
	L ₁	L ₂	L ₃	L ₁	L ₂	L ₃
1ª janela de dados	1,000	0,000	0,000	0,979	0,008	0,000
2ª janela de dados	1,000	0,000	0,000	0,984	0,007	0,000
3ª janela de dados	1,000	0,000	0,000	0,990	0,006	0,000
4ª janela de dados	1,000	0,000	0,000	0,998	0,001	0,000
5ª janela de dados	1,000	0,000	0,000	0,999	0,000	0,000
220 km		60 Ω		45°		

TABELA 49 – Saídas desejadas e esperadas para as cinco janelas de dados analisadas, considerando-se uma falta envolvendo a fase “A” com conexão a terra, aplicada a 278 km do barramento D, com uma resistência de falta de 90 Ω e um ângulo de incidência de 90° (falta situada sobre a segunda zona de transição)

Situação de falta fase “A” - terra	Saídas desejadas			Saída obtidas		
	L ₁	L ₂	L ₃	L ₁	L ₂	L ₃
1ª janela de dados	0,000	0,000	1,000	0,000	0,071	0,941
2ª janela de dados	0,000	0,000	1,000	0,000	0,088	0,964
3ª janela de dados	0,000	0,000	1,000	0,000	0,316	0,825
4ª janela de dados	0,000	0,000	1,000	0,001	0,453	0,665
5ª janela de dados	0,000	0,000	1,000	0,000	0,407	0,864
278 km		90 Ω		90°		

11.3 Observações gerais

Do estudo preliminar apresentado, verifica-se a grande capacidade da rede RBF para realizar a função de localização da falta. A mesma apresenta uma estrutura topológica com 240 unidades de processamento na camada intermediária, o que a torna muito densa, e a habilidade em revelar de uma maneira explícita como se procede o processo de aprendizagem. Outra característica importante e que realmente deve ser destacada é que a escolha do número de unidades intermediárias não é tão arbitrária/empírica como para as demais redes, já que este número depende e muito do número de padrões empregados para formar o conjunto de treinamento. Os elementos das entradas representam medidas das características selecionadas a serem usadas para a distinção entre as classes. Nesta idéia, “os padrões de entrada podem ser vistos como pontos em um espaço multi-dimensional, definido pelas medidas das características de entrada” (DASH *et al.*, 2001).

Outro quesito na avaliação da rede RBF diz respeito à rapidez observada no processo de treinamento. Executando tal procedimento sobre o mesmo equipamento (Pentium II, 333 MHz), o processo de treinamento da rede RBF é aproximadamente 10 vezes mais rápido do que quando executado para a rede MLP (RNA3) designada para a mesma função. Esta rapidez é em grande parte definida em função da estrutura topológica empregada e do reduzido número de padrões utilizados para formar o conjunto de treinamento. Novamente, comparando-se com a rede MLP (RNA3), praticamente obteve-se bons resultados para a mesma função com 11% do número de padrões anteriormente empregados. Este número denota uma grande vantagem no emprego do modelo alternativo de rede RBF, já que, se não for possível dispor de simulações computacionais, a obtenção de um número reduzido de padrões reais para a fase de treinamento fica simplificada.

Do conjunto de testes formulado e apresentado a rede RBF, 90 novas e diferentes situações foram avaliadas. Deste número de situações, podemos computar um índice geral de acertos de 95,55% para todos os padrões apresentados (Tabela 50).

O que deve ser ressaltado é que a rede RBF apresentou uma boa convergência e rapidez no processo de treinamento caracterizados pelos bons resultados

observados. Isto, tomando-se um número reduzido de padrões de treinamento e com 240 unidades de processamento na camada intermediária. Em comparação com a rede MLP, esta também apresentou bons resultados, uma arquitetura de rede neural com um menor número de elementos de processamento na camada intermediária, apesar de possuir duas camadas intermediárias com 48 e 44 unidades cada. O que deve ser lembrado é que, após o processo de treinamento “*off-line*”, o modelo MLP apresenta um mínimo esforço e uma alta rapidez computacional, deixando a desejar somente no que diz respeito ao grande número de padrões de treinamento empregado.

Na Tabela 50, apresentam-se alguns dados relevantes que caracterizam o desempenho dos dois modelos de redes neurais artificiais empregados para a função de proteção de distância no sistema de transmissão em análise.

TABELA 50 – Valores comparativos entre as redes MLP e RBF, para conjuntos de testes aproximados

REDE	Arquitetura	Nº de situações de faltas empregadas (conj. de treinamento)	Tempo aproximado do treinamento (h)	Índice de acerto (%)
MLP	24-48-44-3	1225	12	96,07
RBF	24-240-3	135	1 1/2	95,55

12 CONCLUSÕES

A proposta apresentada teve como objetivo a implementação de um sistema de proteção aplicando-se a teoria de Redes Neurais Artificiais (RNAs). As grandezas analisadas na implementação referem-se a valores amostrados de tensão e corrente do sistema elétrico. O banco de dados, gerado através de simulações computacionais dispondo-se do *software Alternative Transients Program (ATP)*, descreveu então, situações em que o sistema de proteção deveria ou não atuar. Analisou-se, através do emprego de RNAs implementadas pelo uso do *software NeuralWorks*, a possibilidade da aplicação de um modelo completo de proteção para linhas de transmissão (**detecção, classificação e localização da falta**), atentando-se ao princípio de funcionamento do relé digital de distância e imprimindo ao mesmo uma característica adaptativa no que diz respeito às mudanças operacionais. Deve ser destacado que a proteção de distância baseada em RNAs não usa explicitamente a informação da impedância como base de informação, mas sim, aprende de exemplos apresentados durante o processo de treinamento. A aproximação por RNAs trabalha como um classificador de padrões e está hábil a detectar, classificar e localizar rápida e precisamente alterações nas condições de operação do sistema e conseqüentemente, resulta em melhoramento no desempenho dos relés digitais convencionais.

Dos módulos implementados e testados, observa-se um bom desempenho do modelo de proteção frente às diversas situações de operação que o mesmo possa vir a enfrentar. Tais situações levam em consideração as variações de distância de aplicação da falta, resistência e ângulo de incidência da falta, variações no fluxo de energia do sistema e a evolução de faltas bifásicas para faltas bifásicas com conexão a terra.

/Com respeito ao módulo de detecção, o mesmo atua também como um discriminador direcional de faltas, que vem a acusar situações de surtos tanto em

situação reversa como a frente de determinado barramento. O mesmo também analisa constantemente o sistema no sentido de monitorar as condições normais de operação. Para todos os casos analisados (itens 10.7.1 e 2), podemos afirmar que um índice de acerto muito próximo a 100% foi encontrado para a função associada a este módulo. O mesmo índice aproximado foi constatado para o módulo de classificação. Este, por sua vez, analisa e classifica a situação de falta acusada pelo módulo prévio (detecção), entre os dez tipos de faltas que podem vir a ocorrer sobre o sistema de transmissão. Cabe ressaltar que esta função, implementada por uma rede neural, classifica o tipo de falta caracterizado tanto entre as situações a frente como em sentido reverso ao barramento de referência.

Um índice de aproximadamente 97% de acertos é apresentado pelo módulo de localização. As três arquiteturas Multi Layer Perceptrons (MLPs) que formam este módulo atuam com bons resultados, alocando a situação apresentada em uma das três zonas de proteção: primária, secundária e/ou terciária, definindo-se áreas respectivas com 95%, 120% e 150% do comprimento da linha de transmissão protegida. Índices de incertezas de $\pm 2\%$ sobre o alcance das zonas de proteção anteriormente definidas foram considerados. Uma característica deste módulo que merece ser ressaltada, diz respeito ao emprego de uma única rede de localização para situações de faltas bifásicas com e sem envolvimento a terra. Da maneira apresentada, no caso de faltas evolutivas, independentemente da correta atuação ou não do módulo de classificação, acusando a falta como sendo bifásica com ou sem o envolvimento do terra, a mesma rede neural será ativada no módulo de localização, com grandes chances de apresentar uma correta localização do evento.

Referindo-se ao contexto do estudo apresentado, a grande vantagem observada da aplicação de RNAs na proteção de distância é que, 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 capacidade de **generalização** das redes neurais implementadas a partir de exemplos conhecidos, evidenciando a tolerância a ruídos que porventura possam ocorrer no sistema analisado, imprime à proteção digital uma característica adaptativa. Somando-se as características inerentes ao modelo neural, destaca-se a flexibilidade

alcançada através do uso de um sistema digital. O algoritmo computacional desenvolvido, que considera uma lógica de ativação seqüencial dos módulos neurais implementados, pode ser facilmente incorporado na implementação de um *hardware*. Um modelo de um protótipo poderia então ser baseado, por exemplo, no processador de sinal digital ADSP 2181. Este processador combina um alto desempenho com um baixo custo e permite a aplicação descrita neste contexto. O mesmo provê ainda todos os requisitos de memória e *interfaces* de entradas e saídas em um único *chip*. Ainda associada à utilização deste dispositivo, um conversor analógico/digital de 16 bits poderia ser considerado, o que viria a melhorar a precisão dos sinais digitalizados, acarretando uma minimização do erro de quantização.

Sendo assim, dispendo de um sistema digital, todas as arquiteturas MLPs empregadas e convertidas em um código de linguagem computacional, podem ser implementadas em *hardware*, garantindo um processamento rápido e simples, acarretando um pequeno esforço computacional do método. A única restrição prática para uma aplicação direta do modelo proposto, diz respeito ao número de padrões de treinamento (exemplos) necessários para o processo de aprendizagem, quando do emprego destas arquiteturas. Esta restrição está associada principalmente ao módulo de localização, onde uma arquitetura de rede neural com duas camadas intermediárias foi necessária para atender a função desejada. No entanto, para transpor o que seria uma restrição para a aplicação, há a possibilidade do uso de outras arquiteturas neurais que podem vir a apresentar bons e confiáveis resultados, como o modelo alternativo apresentado no capítulo 11. Contudo, para a escolha entre uma rede MLP ou uma rede RBF (Radial Basis Function), por exemplo, devemos nos condicionar ao que realmente é esperado e o que nos interessa da aplicação em questão. Interessa-nos então, devido às reais restrições do problema, um conjunto de treinamento reduzido com um rápido processo de aprendizagem, ou uma rede compacta e simples? A primeira opção nos deixa com a possibilidade de uso de uma rede menos compacta, como, por exemplo, uma rede RBF, e a segunda opção com uma rede MLP, que exige por natureza um conjunto de treinamento mais representativo e, conseqüentemente, um processo de aprendizagem mais demorado. Ambas as arquiteturas, sejam elas MLPs ou RBFs apresentam características desejáveis a um sistema de proteção adaptativo que dependem exclusivamente da

aplicação e problema prático a ser abordado. Cabe ressaltar, no entanto, que o estudo apresentado para a aplicação de redes RBF é um estudo preliminar e que tanto um aprofundamento teórico, como testes mais generalizados são desejáveis ao modelo.

Para finalizar o trabalho apresentado, permito-me um último questionamento. Pode-se destacar ganhos para a área de pesquisa, em específico para a proteção de sistemas elétricos?

Acredito que de uma forma subjetiva, a qualquer área sob estudo científico somam-se ganhos, desde que determinado estudo seja realizado de forma coerente e com seriedade. Neste caso em específico, o que deve ser assimilado é a realização de um estudo de aplicação de redes neurais na proteção de distância. A experiência adquirida na análise do problema exposto e a simples abordagem realizada por si só trazem e permitem enumerar ganhos relacionados à proteção de sistemas. Mesmo não apresentando índices de 100% de acertos para todas as situações apresentadas, evidencia-se a possibilidade de aplicação de tal ferramenta para solucionar de uma forma simples os problemas levantados e denotados no desenvolver do trabalho. De imediato, poderíamos apresentar resultados confiáveis para todos os módulos implementados, mas é certo que, por mais que testado, outras infundáveis situações ainda devem ser consideradas antes de uma aplicação real. Dentre as vantagens já ressaltadas no decorrer da apresentação, como a simplicidade na abordagem, adaptabilidade do sistema digital e um rápido processamento digital após a fase de treinamento, destaca-se ainda que, para a grande maioria dos casos analisados, todo o processo apresentou um tempo médio de atuação situado entre 12 e 14 ms após a ocorrência da falta (considerando a atuação dos três módulos implementados: detecção, classificação e localização). Este tempo vem melhorar muito o desempenho de um sistema de proteção digital, quando comparado aos métodos convencionais empregados. Também deve ser destacado que mesmo merecendo um estudo mais aprofundado, observa-se a possibilidade de extensão das zonas de proteções do sistema. Neste trabalho em específico, uma extensão da zona de proteção primária foi alcançada, permitindo um valor de 95% do comprimento da linha de transmissão analisada. Tal acréscimo desta zona de proteção, vem a melhorar a confiabilidade e, novamente, o desempenho do sistema de proteção como um todo.

Apresenta-se no apêndice uma série de participações do trabalho, sejam eles contendo os resultados observados quando da implementação dos módulos isolados ou do trabalho por completo em congressos nacionais e/ou internacionais e publicações em revistas nacionais e/ou internacionais.

ANEXO

Resultados complementares

Faltas envolvendo a fase “B” com conexão a terra

Nas Figuras 48 e 49, um índice de acerto de 100% pode ser observado para os módulos de detecção e de classificação, quando os mesmos estão sujeitos às situações de faltas que envolvam a fase B com conexão a terra. Novamente, a grande maioria dos casos apresentados à RNA1 foram corretamente avaliados dispondo-se de até 3 ms após a ocorrência da falta. Detectada a condição anormal, o módulo de classificação foi ativado, e o seu tempo de resposta está na ordem de 6 ms, conforme se ilustra a Figura 49.

Pela Figura 50, um índice aproximado a 97,5% de respostas corretas pode ser afirmado para o módulo de localização, atuando sobre faltas que recaiam sobre a primeira, segunda ou terceira zona de proteção. O mesmo apresentou quatro erros de localização na segunda zona de proteção e um erro sobre a terceira zona de proteção. Todas estas cinco situações foram localizadas como pertencendo à primeira zona de proteção. Para as situações de faltas sobre as supostas zonas de transição, a arquitetura de RNA3, apresentou um índice de 55,55% de acertos.





FIGURA 48 – Resultados do módulo de detecção para faltas envolvendo a fase B com conexão a terra





FIGURA 49 – Resultados do módulo de classificação para faltas envolvendo a fase B com conexão a terra




FIGURA 50 – Resultados do módulo de localização para faltas envolvendo a fase B com conexão a terra

Faltas envolvendo a fase “C” com conexão a terra

Para as Figuras 51 e 52 reservam-se os índices de acertos para os módulos de detecção (100%) e de classificação (100%) quando sujeitos às situações de faltas que envolvam a fase C com conexão a terra. O tempo médio de processamento para cada módulo pode ser analisado destas, o que vem a ressaltar a velocidade e a eficiência do modelo proposto até então.

Com respeito ao módulo de localização, a RNA3 apresentou um índice de acerto aproximado a 96% para as situações que envolvam o tipo de falta em questão, fase C com conexão a terra (Figura 53). Um número total de oito erros foi observado sobre a segunda zona de proteção, sendo que, destes, sete foram alocados como pertencendo à primeira zona de proteção e um como pertencendo à terceira zona.

Como observado pelos resultados obtidos, todos os módulos responderam satisfatoriamente para os três tipos de faltas avaliados neste item. Uma observação coerente diz respeito ao módulo de localização. Para os três tipos de faltas, a RNA3 apresentou um número total de 16 erros em 972 padrões testados (98,35% de acertos). Vale ainda ressaltar que 15 destes erros foram alocados como pertencendo à primeira zona de proteção, quando na verdade, pertenciam à segunda ou à terceira zona de proteção.





FIGURA 51 – Resultados do módulo de detecção para faltas envolvendo a fase C com conexão a terra




FIGURA 52 – Resultados do módulo de classificação para faltas envolvendo a fase C com conexão a terra




FIGURA 53 – Resultados do módulo de localização para faltas envolvendo a fase C com conexão a terra

Faltas envolvendo as fases “A” e “C”

Como para as situações de faltas anteriores, um índice de 100% de acerto também pôde ser observado quando os módulos de detecção e de classificação foram avaliados (Figuras 54 e 55). Para estes módulos, as RNAs 1 e 2 reagiram muito bem frente às situações de faltas que envolvam as fases A e C sem conexão a terra. Índices de acerto próximos a 95% e 65% foram constatados para a RNA4 quando da sua exposição às situações de faltas que descrevessem o tipo de falta analisado, sejam elas pertencentes às zonas de proteção, bem como às zonas de transição (Figura 56). Onze erros sobre as zonas de proteção foram observados na localização do tipo de falta citado. Destes, três pertenciam à primeira e três à segunda zona de proteção e foram erroneamente designados como sendo da terceira zona de proteção. Os cinco erros restantes, situavam-se sobre a terceira zona de proteção e foram mal alocados como sendo da segunda zona de proteção.

Não esquecendo de um fator muito importante nesta aplicação, o tempo de processamento, observa-se que o tempo médio de todo o processo permanece entre 11 e 13 ms, como já evidenciado anteriormente. Deste tempo de processamento, 2 ms foram destinados à tarefa de detecção na grande maioria das situações avaliadas, 6 ms para a classificação, ficando a localização com um tempo situado entre 5 e 7 ms.




FIGURA 54 – Resultados do módulo de detecção para faltas envolvendo as fases A e C sem conexão a terra




FIGURA 55 – Resultados do módulo de classificação para faltas envolvendo as fases A e C sem conexão a terra




FIGURA 56 – Resultados do módulo de localização para faltas envolvendo as fases A e C sem conexão a terra

Faltas envolvendo as fases “B” e “C”

As Figuras 57, 58 e 59 ilustram o comportamento das RNAs 1, 2 e 4 frente às ocorrências de faltas que envolvam as fases B e C sem conexão a terra. Para a grande maioria das situações apresentadas à RNA1, um tempo médio de processamento de 2 ms foi constatado (Figura 57), garantindo um índice de acerto de 100%. O mesmo ocorrendo para a RNA2 (com um tempo médio de processamento igual a 8 ms, Figura 58). Para os 324 padrões apresentados ao módulo de localização, 92,50% foram corretamente alocados sobre as três zonas de proteção e aproximadamente 66% corretamente alocados como pertencendo às duas zonas de transição, Figura 59.

O índice percentual dos erros observados para este módulo (7,5%), diz respeito a um total de 22 padrões que foram indevidamente alocados sobre as três zonas de proteção. Destes, oito e cinco padrões que pertenciam à primeira zona de proteção foram alocados como pertencendo à segunda e terceira zona de proteção respectivamente. Cinco situações que deveriam pertencer à segunda zona de proteção foram alocadas como restritas à terceira zona de proteção. Os quatro últimos erros, dizem respeito a situações ocorridas sobre a terceira zona de proteção mas que foram infelizmente alocadas à segunda zona de proteção.




FIGURA 57 – Resultados do módulo de detecção para faltas envolvendo as fases B e C sem conexão a terra

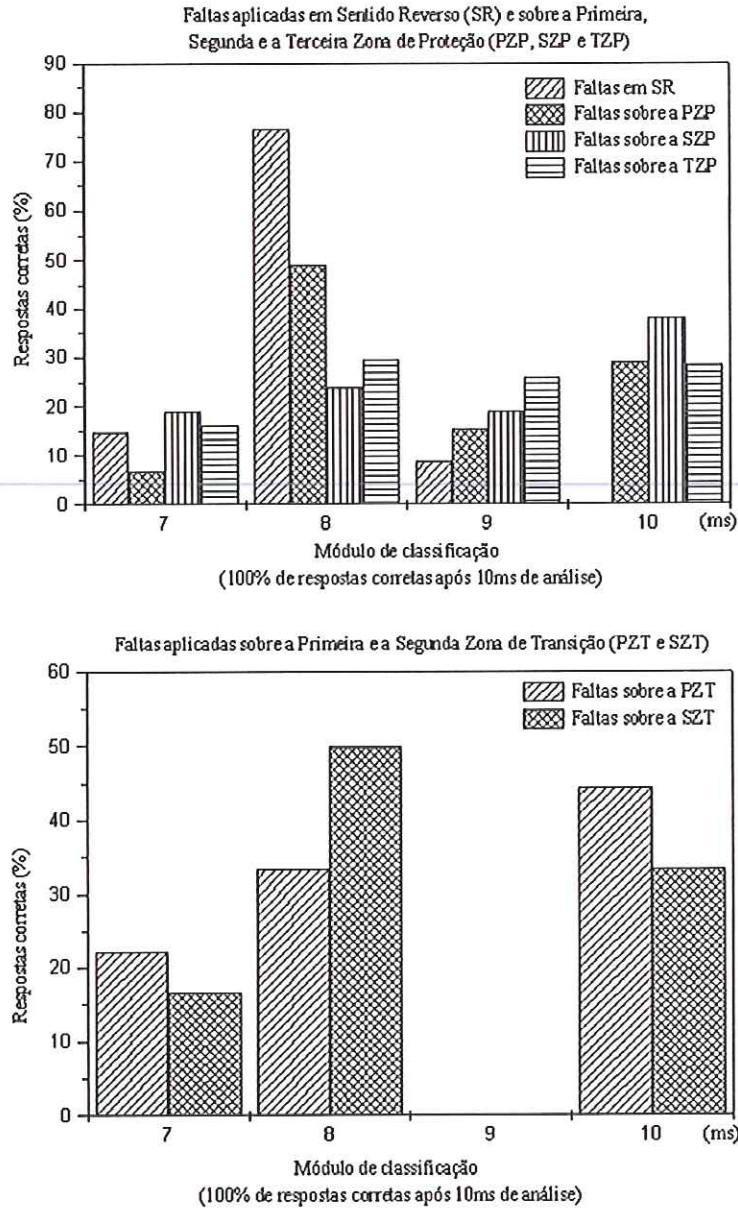


FIGURA 58 – Resultados do módulo de classificação para faltas envolvendo as fases B e C sem conexão a terra




FIGURA 59 – Resultados do módulo de localização para faltas envolvendo as fases B e C sem conexão a terra

Faltas envolvendo as fases “A” e “C” com conexão a terra

Para as Figuras 60, 61 e 62 reservam-se os índices obtidos das arquiteturas RNA1, RNA2 e RNA4 quando sujeitas ao conjunto de testes formulado que representa as situações de faltas que envolvam as fases A e C com conexão a terra.

Com um tempo médio de processamento de 2 ms, o módulo de detecção (RNA1) apresenta um índice de 100% de acerto para todas as situações analisadas (Figura 60). Cabe lembrar que, como para todas as demais situações apresentadas, este módulo garante também um índice de 100% de acerto no reconhecimento das situações normais de operação do sistema.

Com um tempo de processamento situado entre 5 e 8 ms (Figura 61), o módulo de classificação (RNA2) também apresenta um ótimo desempenho frente às situações comentadas (100% de acerto).

Na Figura 62, índices aproximados a 99,5% e 58% são ilustrados para as situações de faltas que recaem sobre as zonas de proteção e de transição respectivamente. Com um tempo de processamento bem caracterizado, somente um erro de localização foi observado sobre a segunda zona de proteção, sendo que este foi erroneamente alocado à terceira zona.






FIGURA 60 – Resultados do módulo de detecção para faltas envolvendo as fases A e C com conexão a terra




FIGURA 61 – Resultados do módulo de classificação para faltas envolvendo as fases A e C com conexão a terra




FIGURA 62 – Resultados do módulo de localização para faltas envolvendo as fases A e C com conexão a terra

Faltas envolvendo as fases “B” e “C” com conexão a terra

Sem alteração nos índices de respostas corretas (100%), as Figuras 63 e 64 caracterizam o comportamento dos módulos implementados que dizem respeito à detecção (RNA1) e classificação (RNA2) quando deparados a situações de faltas que envolvam as fases B e C com conexão a terra.




FIGURA 63 – Resultados do módulo de detecção para faltas envolvendo as fases B e C com conexão a terra




FIGURA 64 – Resultados do módulo de classificação para faltas envolvendo as fases B e C com conexão a terra

O módulo de localização (RNA4) apresenta um índice próximo de 94% de acerto para as faltas alocadas sobre as zonas de proteção e um índice de 74% para as demais áreas delimitadas (zonas de transição), Figura 65. Como para as demais figuras já apresentadas neste item, atenção especial deve ser dada ao tempo médio de processamento dos referidos módulos. Neste caso em específico, a maioria dos padrões analisados foram corretamente alocados às suas respectivas áreas dispondose de até 15 ms após a ocorrência do defeito. Quatro situações de faltas que realmente pertencem à primeira zona de proteção foram destinadas à segunda zona e

nove padrões, que pertencem à segunda zona, foram erroneamente localizadas como pertencendo à terceira zona de proteção.




FIGURA 65 – Resultados do módulo de localização para faltas envolvendo as fases B e C com conexão a terra

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.
- AGGARWAL, R. K.; JOORABIAN, M.; SONG, Y. H. (1997a). Fuzzy neural network approach to accurate transmission line fault location. *International Journal of Engineering Intelligent Systems for Electrical Engineering and Communications*, v.5, n.4, p.251-258, dec.
- AGGARWAL, R. K.; XUAN, Q. Y.; JOHNS, A. T. (1997b). Fault classification for double-circuits using self-organization mapping neural network. *UPEC'97 - 32nd Universities Power Engineering Conference*, v.2, p.440-443, sep.
- AGGARWAL, R. K. and SONG, Y. (1997c). Artificial neural networks in power systems. Part 1 – General introduction to neural computing. *Power Engineering Journal*, v.11, n.3, p.129-134, jun.
- AGGARWAL, R. K. and SONG, Y. (1998a). Artificial neural networks in power systems. Part 2 – Types of artificial neural networks. *Power Engineering Journal*, v.12, n.1, p.41-47, feb.
- AGGARWAL, R. K. and SONG, Y. (1998b). Artificial neural networks in power systems. Part 3 – Examples of applications in power systems. *Power Engineering Journal*, v.12, n.6, p.279-287, dec.

- AGGARWAL, R. K.; XUAN, Q. Y.; DUNN, R. W.; JOHNS, A. T. and BENNETT, A. (1999). A novel fault classification technique for double-circuit lines based on a combined unsupervised/supervised neural network. *IEEE Transaction on Power Delivery*, v.14, n.4, p.1250-1256, oct.
- AL-HASAWI, W. M.; ABBASY, N. H.; MANSOUR, M. M. (1996). A neural network based approach for fault classification and faulted phase selection. *IEEE CCECE'96 – Canadian Conference in Electrical and Computer Engineering*, v.1, p.384-387.
- AL-HASAWI, W. M.; ABBASY, N. H.; MANSOUR, M. M. (1997). Using fault induced transients and neural networks for T. L. ultra high speed fault detection and classification. *IPST'97 - International Conference on Power Systems Transients*, Seattle, p.412-417, jun.
- ALTERNATIVE Transients Program (1987). Rule Book, 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.
- BISHOP, C. (1995). *Neural networks for pattern recognition*. Oxford, Oxford Press.
- BLACKBURN, J. L. (1997). *Protective relaying: principles and applications*. New York: Marcel Dekken.

- BO, Z. Q.; JOHNS, A. T. (1997). Transient based protection - A new concept in power system protection. *IPST'97 International Conference on Power Systems Transients Seattle*, p.401-406, jun.
- BO, Z. Q.; MOORE, P. J.; AGGARWAL, R. K.; JOHNS, A. T. (1997a). A new directional relay based on the measurement of transient voltage and current signals. *UPEC'97 - 32nd Universities Power Engineering Conference*, v.1, p.97-100, sep.
- BO, Z. Q.; LI, H. Y.; AGGARWAL, R. K.; JOHNS, A. T. (1997b). Current transients based faulted phase selection technique using a genetic algorithm involved neural network. *UPEC'97 - 32nd Universities Power Engineering Conference*, v.2, p.959-962, sep.
- BO, Z. Q.; SU, W. B.; HEWETT, R. K.; AGGARWAL, R. K.; JOHNS, A. T.; MOORE, P. J.; REDFERN, M. A. (1997c). Distinguishing between lightning strokes and earth faults on transmission line using artificial neural network. *IPST'97 International Conference on Power Systems Transients Seattle*, p.407-411, jun.
- BO, Z. Q.; AGGARWAL, R. K.; JOHNS, A. T.; LI, H. Y.; SONG, Y. H. (1997d). A new approach to phase selection using fault generated high frequency noise and neural networks. *IEEE Transactions on Power Delivery*, v.12, n.1, p.106-115, jan.
- BRAGA, A. P.; CARVALHO, A. C. P. L. F. C.; LUDERMIR, T. B. (1998). *Fundamentos de Redes Neurais*. XI Escola Brasileira de Computação.
- CHAKRAVARTHY, S. K.; NAYAR, C. V.; ACHUTHAN, N. R. (1992a). 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. (1992b). Applying pattern recognition in distance relaying. Part 2: Feasibility. *IEE Proceedings-C*, v.139, n.4, p.306-314, jul.
- CHEN, Z.; KALAM, A.; ZAYEGH, A. (1995). Advanced microprocessor based power protection system using artificial neural network techniques. *IEEE - Proceedings of the International Conference on Energy Management and Power Delivery – EMPD*, v.1, p.439-444.
- CHOWDHURY, B. H.; WANG, K. (1996). Fault classification in power systems using artificial neural networks. *International Journal of Engineering Intelligent Systems for Electrical Engineering and Communications*, v.4, n.2, p.101-112, jun.
- COURY, D. V.; JORGE, D. C. (1998). Artificial neural network approach to distance protection. *IEEE Transactions on Power Delivery*, v.13, n.1, p.102-108, jan.
- COURY, D. V.; OLESKOVICZ, M. (1998). Multi-layer neural networks applied to distance relaying. *International Journal of Electrical Power and Energy Systems*, Elsevier Science, England, ISSN: 0142-0615, v.20, n. 8, p. 539-542, sep.
- 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 Delivery*, v.11, n.2, p.740-747, apr.

- DASH, P. K.; PRADHAN, A. K.; PANDA, G. (2001) . Application of minimal radial basis function neural network to distance protection. *IEEE Transactions on Power Delivery*, v. 16, n. 1, jan.
- DILLON, T. S.; NIEBUR, D. (1996). *Neural networks applications in power systems*. CRL Publishing, London, England.
- FERNANDO, I. T.; MCLAREN P. G. (1995). Single ended protection scheme for three phase double circuit lines. *IEEE Wescanex'95 - Proceedings of Communications, Power, and Computing Conference*, v.1, p.117-121, may.
- FERNANDO, R. S.; WATSON, K. L. (1992). High impedance fault detection using artificial neural network techniques. *Proceedings of the Intersociety Energy Conversion Engineering Conference*, v.1, p.1191-1196.
- FRIEDRICH, T.; DALSTEIN, T.; KULICKE, B. (1994). A neural time zone classifier for high speed protective relaying. *Proceedings of the 29th Universities Power Engineering Conference*, v.1, p.220-223.
- GIRGIS A. A. (1981). *Application of Kalman filtering in computer relaying of power systems*. Iowa State University, Ames, Iowa.
- GHOSH, A. K.; LUBKEMAN, D. L. (1995). The classification of power systems disturbance waveforms using a neural network approach. *IEEE Transactions on Power Delivery*, v.10, n.1, p.109-115, jan.
- HANDSCHIN, E.; KUHLMANN, D.; HOFFMAN, W. (1994). Fault diagnosis in electrical energy systems using device-specific artificial neural networks. *International Journal of Engineering Intelligent Systems for Electrical Engineering and Communications*, v.2, n.4, p.255-262, dec.

- HEDMAN, D. E. (1979). *Teoria das linhas de transmissão - I, Curso de engenharia em sistemas elétricos de potência*. Santa Maria. Convênio ELETROBRÁS/UFMS.
- 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.
- HOROWITZ, S. and PHADKE, A. G. (1996). *Power system relaying*. Research Studies Press Ltd., England, 2^a Ed.
- JOHNS, A. T and SALMAN, S. K. (1995). *Digital protection for power systems*. Peter Peregrinus Ltd. on behalf of The Institution of Electrical Engineers.
- JONGEPIER, A. G.; SLUIS, L. (1997). Adaptive distance protection for high speed protective relaying. *IEEE Transactions on Power Delivery*, v.12, n1, p.97-103, jan.
- KANOH, 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.
- KANDIL, N.; SOOD, V. K.; KHORASANI, K.; PATEL, R.V. (1992). Fault identification in AC-DC transmission system using neural networks. *Transactions on Power Systems*, v.7, n.2, p.812-819, may.
- KEERTHIPALA, W. W. L.; WAI, C. T.; HUIHENG, W. (1997). Neural network based classifier for power system protection. *Electric Power Systems Research*, v.42, p.109-114.
- KEZUNOVIC, M.; RIKATO, I. (1996). Detect and Classify Faults using neural nets. *IEEE Computer Applications in Power*, p.42-47, oct.

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

KHAPARDE, S. A.; WARKE, N.; AGARWAL, S. H. (1996). An adaptive approach in distance protection using an artificial neural network. *Electric Power Systems Research*, v.37, p.39-44, apr.

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

LAI, L.L.; NDEH-CHE, F.; CHU, K.; RAJROOP,P.; WANG, X. F. (1994). Design neural networks with genetic algorithms for fault section estimation. *Proceedings of the 29th Universities Power Engineering Conference*, v.1, p.596-599.

NEURAL COMPUTING - A technology Handbook for NeuralWorks Professional II/PLUS and NeuralWorks Explorer (1998), NEURALWARE, a subsidiary of Aspen Technology, Inc.

NEURALWORKS Professional II/PLUS (1998). Version 5.23, NEURALWARE, a subsidiary of Aspen Technology, Inc.

OLESKOVICZ, M. (1997). *Redes neurais artificiais: uma alternativa para proteção de linhas de transmissão*, Dissertação (mestrado) 045r – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos – SP.

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

QI W.; SWIFT, G.; MCLAREN, P.; CASTRO, A. (1997). Distance protection using an artificial neural network. *IEE Developments in Power System Protection – Conference Publication*, n.434, p.286-290, mar.

- REFERENCE GUIDE – A software reference for NeuralWorks Professional II/PLUS and NeuralWorks Explorer (1998), NEURALWARE, a subsidiary of Aspen Technology, Inc.
- SIDHU, T. S. (1997). Transmission line protection using ANNs: proposed applications, advantages and roadblocks to acceptance. *Engineering Intelligent Systems*, v.5, n.4, p.213-220, dec.
- 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.
- SONG, Y. H.; JOHNS, A. T.; XUAN, Q. Y. (1996). Artificial neural-network-based protection scheme for controllable series-compensated EHV transmission lines. *IEE Proc.-Gener. Transm. Distrib.*, v. 143, n.6, p.535-540, nov.
- SONG, Y. H.; XUAN, Q. Y.; JOHNS, A. T. (1997). Comparison studies of five neural network based fault classifiers for complex transmission lines. *Electric Power Systems Research*, v. 43, n.2, p.125-132, nov.
- STANLEY, H. H.; PHADKE, A. G. (1992). *Power system relaying*. England, Research Studies Press Ltd.
- STEVENSON JR., W. D. (1986). *Elementos de análise de sistemas de potência*. 2^a ed., Rio de Janeiro, McGraw-Hill do Brasil.
- SU, W. B.; MAO, P. L.; BO, Z. Q.; AGGARWAL, R. K.; JOHNS, A. T. (1997). A fault detection technique for composite transmission circuits using artificial neural networks. *UPEC '97 - 32nd Universities Power Engineering Conference*, v.1, p.291-294, Sep.

- VÁZQUEZ, E.; ALTUVE, H. J.; CHACÓN, O. L. (1996). Neural network approach to fault detection in electric power systems. *IEEE International Conference on Neural Network – Conference Proceedings*, v.4, p.2090-2095.
- VENKATESAN, R. and BALASUBRAMANIAN, B. (2001). A real-time hardware fault detector using an artificial neural network for distance protection. *IEEE Transaction on Power Delivery*, v.16, n.1, p.75-82, jan.
- WARRINGTON, A. R. Van C. (1977). *Protective relays. Their theory and practice*. London, Chapman & Hall.
- WARWICK, K.; EKWUE, A.; AGGARWAL, R. (1997). *Artificial intelligence techniques in power systems*. The Institution of Electrical Engineers.
- 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.
- ZIEGLER, G. (1999). *Numerical Distance Protection – Principles and Applications*. Siemens – Erlangen: Publicis-MCD-Verl.

APÊNDICE

TRABALHOS PUBLICADOS E/OU EM AVALIAÇÃO

Como pode ser observado neste Apêndice, procurou-se da melhor maneira possível divulgar o trabalho realizado nos principais congressos e revistas que envolvam a comunidade científica.

Publicações internacionais e nacionais

“An ANN routine for fault detection, classification and location in transmission lines”, *Electric Power Components & Systems*, Taylor & Francis. /no prelo/

“Redes neurais artificiais aplicadas à classificação rápida de faltas em sistemas elétricos de potência”, *SBA Controle & Automação*, Brasil, v.11, n. 2, 12/2000.

“Multi-layer neural networks applied to distance relaying”, *International Journal of Electrical Power and Energy Systems*, Elsevier Science, England, v.20, n. 8, p. 539-542, ISSN: 0142-0615, 02/09/1998.

Trabalhos que se encontram sob avaliação

“Applying pattern recognition to fault classification for power system protection”, *The International Association of Science and Technology for Development – IASTED* (trabalho aceito).

“O emprego de redes neurais artificiais na detecção, classificação e localização de faltas em linhas de transmissão”, *Revista Controle & Automação*, Sociedade Brasileira de Automática – SBA (em revisão).

Participações em congressos internacionais e nacionais

“Um esquema completo para detecção, classificação e localização de faltas em linhas utilizando redes neurais”, *XVI Seminário Nacional de Produção e Transmissão de Energia Elétrica – XVI SNPTEE*, Campinas, Brasil, Anais (CD), 21-26/10/2001.

“An ATP simulation of Shunt capacitor switching in an electrical distribution system”, *International Conference on Power Systems Transients – IPST 2001*, Rio de Janeiro, Brasil, Anais (CD), 24-28/06/2001.

“A complete scheme for fault detection, classification and location in transmission lines using neural networks”, *Seventh International Conference on Developments in Power System Protection*, RAI, Amsterdam, The Netherlands, Anais (CD), 9-12/04/2001.

“O emprego de redes neurais artificiais na detecção e classificação de faltas em linhas de transmissão”, *XIIIth Congresso Brasileiro de Automática*, Universidade Federal de Santa Catarina, Florianópolis, SC, Brasil, Anais (CD), 11-14/09/2000.

“Aplicação de redes neurais artificiais na proteção de distância”, *I Oficina da Pós-Graduação*, Escola de Engenharia de São Carlos (EESC/ USP), Departamento de Engenharia Elétrica, São Carlos, SP, Brasil, Anais (CD), 16-18/08/2000.

“Applying pattern recognition to fault classification for power system protection“, *Third International Conference on Power and Energy Systems*, Proceedings of the IASTED International Conference on Power and Energy Systems, 8-10 November 1999, Las Vegas, Nevada USA, pp. 333-337, ISBN: 0-88986-278-8.

“Neural network approach to fault classification for power system protection“, *Artificial Intelligence and Soft Computing Conference - ASC'99*, Proceedings of the IASTED International Conference Artificial Intelligence and Soft Computing (ASC'99), 9-12 August 1999, Honolulu, Hawaii - USA, pp. 272-276.

“Artificial Neural Network Applied to Power System Protection“, *Vth Brazilian Symposium on Neural Networks (SBRN'98)*, Belo Horizonte, MG, Brasil, Anais, v. 1, p. 247-252, ISBN: 0-8186-8629-4, 9-11/12/1998.

“Arquiteturas de Redes Neurais Multicamadas para Simulação de Relés de Distância“, *XIIIth Brazilian Automatic Control Conference*, Uberlândia, MG, Brasil, Anais, p. 1855-1860, ISBN: 85-87022-07-5, 14-18/09/1998.

“Applying Pattern Recognition in Distance Protection“, *International Conference on Power System Tecnology – POWERCON'98*, Beijing, China, Anais, v. 2, p. 1148-1152, ISBN: 0-7803-4754-4 (*softbound*), 0-7803-4755-2 (*microfiche*), Library of Congress Number: 98-8436, 18-21/08/1998.

“Neural Network Archicteture Applied to Transmission Line Protection“, *Artificial Intelligence and Soft Computing*, Proceedings of the International Association of Science and Technology for Development - IASTED, Cancun, México, p.333-336, ISBN: 0-88986-256-7, ISSN: 1482-7913, 27-30/05/1998.

“Redes Neurais Artificiais: uma Alternativa para Proteção Digital a Distância“, *III Latin-American Congress: Eletriciry Generation and Transmission*, Campos do Jordão, SP, Brasil, Anais, p. 430-435, 09-13/11/1997.

“Arquiteturas de Redes Neurais Artificiais Aplicadas a Proteção de Sistemas de Transmissão“, *XVIII Congresso Íbero Latino-Americano de Métodos Computacionais em Engenharia*, Brasília, DF, Brasil, Anais v.3, p. 1457-1464, 29-31/10/1997.