Universidade do Estado do Rio de Janeiro

Centro de Tecnologia e Ciências

Faculdade de Engenharia

Richard Henrique Ribeiro Antunes

Detecção e classificação de VTCDs em sistemas de distribuição de energia elétrica usando redes neurais artificiais

Rio de Janeiro

2012

Richard Henrique Ribeiro Antunes

Detecção e classificação de VTCDs em sistemas de distribuição de energia elétrica usando redes neurais artificiais

Dissertação apresentada como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes e Automação.

Orientador: Prof. Dr. Lisandro Lovisolo
Coorientador: Prof. Dr. Pedro Henrique Gouvêa Coelho

Rio de Janeiro
2012

Richard Henrique Ribeiro Antunes

Detecção e classificação de VTCDs em sistemas de distribuição de energia elétrica usando redes neurais artificiais

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes e Automação.

Aprovado em: 28 de março de 2012
Banca Examinadora:

Prof. Dr. Lisandro Lovisolo (Orientador)
Faculdade de Engenharia - UERJ

Prof. Dr. Pedro Henrique Gouvêa Coelho (Coorientador)
Faculdade de Engenharia - UERJ

Prof. Dr. Luís Fernando Corrêa Monteiro
Faculdade de Engenharia - UERJ

Prof.ª Dr.ª Marley Maria Bernardes Rebuzzi Vellasco
Faculdade de Engenharia - UERJ

Prof. Dr. João Amin Moor Neto
Centro Federal de Educação Tecnológica do Rio de Janeiro - CEFET/RJ - Faculdade de Engenharia

Rio de Janeiro
2012

Dedico este trabalho aos meus Pais,
que acreditam nos meus projetos,
sempre estão ao meu lado e são
meus incentivadores permanentes.

AGRADECIMENTOS

A Deus, em primeiro lugar, por todas as ricas oportunidades que me concedeu ao longo desta caminhada e sem Ele não seria possível cumprir mais uma etapa na minha vida.

À Congregação Judaico Messiânica Beit Tefila Yeshua, por ter me acolhido, pelos ensinamentos dados e o principal que obtive deles, as Orações.

Ao orientador, professor Lisandro Lovisolo, pela oportunidade de ter trabalhado comigo neste projeto e pela dedicação em suas orientações durante o transcorrer desta pesquisa. Não se esquecendo dos imperdíveis momentos de descontrações.

Ao orientador, professor Pedro Henrique, pelas sábias orientações no desenvolvimento desta dissertação.

Aos amigos e professores do PEL que, de algum modo, colaboraram, direta ou indiretamente, com esta pesquisa e pelas intermináveis conversas político-filosóficas.

À UERJ, à Faculdade de Engenharia, ao departamento de pós-graduação em engenharia eletrônica e aos seus funcionários por garantirem uma infra-estrutura adequada para realizar esse trabalho.

À FAPERJ por subsidiar esta pesquisa e acreditar que a base para o desenvolvimento do país é a formação dentro das universidades.

Aos meus amados pais, que sempre me incentivaram e me apoiaram, nunca medindo esforços para que este trabalho fosse concretizado.

À minha querida irmã e meu estimado cunhado, pelo constante incentivo e pelo carinho que sempre recebi deles.

Aos familiares e amigos, que de uma forma ou de outra me apoiaram nesta jornada.

Em especial, à minha prima Juliana e seu esposo João, pelo carinho e apoio em todos os momentos.

Ao grande amigo Rogério Marques e família, que sempre estava disposto a ouvir e discutir boas idéias empreendedoras, além de sempre ter boas sugestões para os negócios.

Os remos batem nas águas: têm de ferir, para andar.
As águas vão consentindo - esse é o destino do mar.

Cecília Meireles

RESUMO

ANTUNES, Richard Henrique Ribeiro. *Detecção e classificação de VTCDs em sistemas de distribuição de energia elétrica usando redes neurais artificiais*. 2012. 140f. Dissertação (Mestrado em Engenharia Eletrônica) - Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2012.

O objetivo deste trabalho é conhecer e compreender melhor os imprevistos no fornecimento de energia elétrica, quando ocorrem as variações de tensão de curta duração (VTCD). O banco de dados necessário para os diagnósticos das faltas foi obtido através de simulações de um modelo de alimentador radial através do *software* PSCAD/EMTDC. Este trabalho utiliza um *Phase-Locked Loop* (PLL) com o intuito de detectar VTCDs e realizar a estimativa automática da frequência, do ângulo de fase e da amplitude das tensões e correntes da rede elétrica. Nesta pesquisa, desenvolveram-se duas redes neurais artificiais: uma para identificar e outra para localizar as VTCDs ocorridas no sistema de distribuição de energia elétrica. A técnica aqui proposta aplica-se a alimentadores trifásicos com cargas desequilibradas, que podem possuir ramais laterais trifásicos, bifásicos e monofásicos. No desenvolvimento da mesma, considera-se que há disponibilidade de medições de tensões e correntes no nó inicial do alimentador e também em alguns pontos esparsos ao longo do alimentador de distribuição. Os desempenhos das arquiteturas das redes neurais foram satisfatórios e demonstram a viabilidade das RNAs na obtenção das generalizações que habilitam o sistema para realizar a classificação de curtos-circuitos.

Palavras-chave: redes neurais artificiais, variação de tensão de curta duração, VTCD, phase-locked loop, PLL, sistema de distribuição de energia elétrica, PSCAD/EMTDC.

ABSTRACT

The objective of this work is to know and understand the unforeseen in the supply of electricity, when there are short duration voltage variations (SDVV). The required database for the diagnosis of faults were obtained through simulations of a model of radial feeder through software PSCAD/EMTDC. This work uses a Phase-Locked Loop (PLL) in order to detect and perform the estimation SDVV automatic frequency, phase angle and amplitude of the voltage and current from the power grid. This research is developing two artificial neural networks: one to identify and another to locate the SDVV occurred in the distribution system of electricity. The technique proposed here applies to three-phase feeders with unbalanced loads, which can have side extensions triphasic, biphasic and monophasic. In developing the same, it is considered that there is availability of measurements of voltages and currents at the node of the initial feeder and also in some points scattered along the distribution feeder. The performances of the architectures of neural networks were satisfactory and demonstrate the feasibility of ANNs in obtaining the generalizations that enables the system for the classification of short circuits.

Keywords: artificial neural networks. short duration voltage variations. SDVV. phase-locked loop. PLL. distribution electric power system. PSCAD/EMTDC.

LISTA DE FIGURAS

Figura 1 - Processo de detecção e classificação das faltas. 23

Figura 2 - Principais distúrbios associados a QEE. 28

Figura 3 - Curva de suportabilidade para computadores - ITIC. 31

Figura 4 - Curva de suportabilidade para semicondutores - SEMI F47. 32

Figura 5 - Diagrama esquemático de uma sistema elétrico de potência. 38

Figura 6 - Diagrama unifilar da rede de distribuição no PSCAD. 43

Figura 7 - Resultante da falta de A, B e C para o terra. 44

Figura 8 - Tipos de falta. 44

Figura 9 - Arquivo de dados. 45

Figura 10 - Arquivo de configuração. 46

Figura 11 - Diagrama de blocos dos módulos do algoritmo de detecção do ponto de incidência. 48

Figura 12 - Diagrama de blocos do PLL. 49

Figura 13 - Taxa de variação média. 50

Figura 14 - Exemplo de registro oscilográfico. 51

Figura 15 - Gráfico do deslocamento do instante de incidência. 51

Figura 16 - Arquivo de saída que contém os valores estimados dos 6 sinais. 52

Figura 17 - Histograma da amplitude extraída da fundamental quando todas as fases estão envolvidas nas faltas. 55

Figura 18 - Histograma da fase extraída da fundamental quando todas as fases estão envolvidas nas faltas. 56

Figura 19 - Histograma da frequência extraída da fundamental quando todas as fases estão envolvidas nas faltas. 56

Figura 20 - Histograma da Amplitude extraída da fundamental quando a fase B está envolvida nas faltas. 57

Figura 21 - Histograma da Amplitude extraída da fundamental quando a fase B não está envolvida nas faltas. 57

Figura 22 - Histograma da Fase extraída da fundamental quando a fase B está envolvida nas faltas. 58
Figura 23 - Histograma da Fase extraída da fundamental quando a fase B não está envolvida nas faltas. 58
Figura 24 - Histograma da Frequência extraída da fundamental quando a fase B está envolvida nas faltas. 59
Figura 25 - Histograma da Frequência extraída da fundamental quando a fase B não está envolvida nas faltas. 59
Figura 26 - Neurônio biológico. 61
Figura 27 - Modelo matemático do neurônio. 63
Figura 28 - Função de transferência Linear. 64
Figura 29 - Função de transferência Degrau. 65
Figura 30 - Função de transferência Log-Sigmoid. 65
Figura 31 - Função de transferência Tan-Sigmoid. 66
Figura 32 - Função de transferência Radbas. 67
Figura 33 - Função de transferência Compet. 68
Figura 34 - Diagrama em blocos da aprendizagem supervisionada. 69
Figura 35 - Rede de múltiplas camadas. 71
Figura 36 - Rede de base radial. 72
Figura 37 - Rede probabilística. 74
Figura 38 - Etapas no ciclo de desenvolvimento de uma RNA. 75
Figura 39 - Treinamento da identificação dos tipos das faltas caso Levenberg-Marquardt. 84
Figura 40 - Treinamento da identificação dos tipos das faltas caso Resilient. 84
Figura 41 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de corrente caso Levenberg-Marquardt. 85
Figura 42 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de corrente caso Resilient. 85
Figura 43 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de corrente caso Levenberg-Marquardt. 86

Figura 44 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de corrente caso Resilient. 86
Figura 45 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de corrente caso Levenberg-Marquardt. 87
Figura 46 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de corrente caso Resilient. 87
Figura 47 - Treinamento da identificação dos tipos das faltas caso Levenberg-Marquardt. 89
Figura 48 - Treinamento da identificação dos tipos das faltas caso Resilient. 89
Figura 49 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de tensão caso Levenberg-Marquardt. 90
Figura 50 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de tensão caso Resilient. 90
Figura 51 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de tensão caso Levenberg-Marquardt. 91
Figura 52 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de tensão caso Resilient. 91
Figura 53 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de tensão caso Levenberg-Marquardt. 92
Figura 54 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de tensão caso Resilient. 92
Figura 55 - Treinamento da identificação dos tipos das faltas caso RBF. 94
Figura 56 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de corrente caso RBF. 94
Figura 57 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de corrente caso RBF. 95
Figura 58 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de corrente caso RBF. 95
Figura 59 - Treinamento da identificação dos tipos das faltas caso RBF. 96

Figura 60 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de tensão caso RBF. 97
Figura 61 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de tensão caso RBF. 97
Figura 62 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de tensão caso RBF. 98
Figura 63 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de corrente caso PNN. 100
Figura 64 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de corrente caso PNN. 100
Figura 65 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de corrente caso PNN. 101
Figura 66 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de tensão caso PNN. 102
Figura 67 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de tensão caso PNN. 103
Figura 68 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de tensão caso PNN. 103
Figura 69 - Treinamento da localização do instante de incidência das faltas caso Levenberg-Marquardt. 107
Figura 70 - Treinamento da localização do instante de incidência das faltas caso Resilient. 107
Figura 71 - Matriz de Confusão de Treinamento da RNA 2 usando os parâmetros de corrente caso Levenberg-Marquardt. 108
Figura 72 - Matriz de Confusão de Treinamento da RNA 2 usando os parâmetros de corrente caso Resilient. 108
Figura 73 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de corrente caso Levenberg-Marquardt. 109

Figura 74 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de corrente caso Resilient. 109
Figura 75 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de corrente caso Levenberg-Marquardt. 110
Figura 76 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de corrente caso Resilient. 110
Figura 77 - Treinamento da localização do instante de incidência das faltas caso Levenberg-Marquardt. 112
Figura 78 - Treinamento da localização do instante de incidência das faltas caso Resilient. 112
Figura 79 - Matriz de Confusão de Treinamento da RNA 2 usando os parâmetros de tensão caso Levenberg-Marquardt. 113
Figura 80 - Matriz de Confusão de Treinamento da RNA 2 usando os parâmetros de tensão caso Resilient. 113
Figura 81 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de tensão caso Levenberg-Marquardt. 114
Figura 82 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de tensão caso Resilient. 114
Figura 83 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de tensão caso Levenberg-Marquardt. 115
Figura 84 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de tensão caso Resilient. 115
Figura 85 - Treinamento da localização do instante de incidência das faltas caso RBF. 116
Figura 86 - Matriz de Confusão de Treinamento da RNA 2 usando os parâmetros de corrente caso RBF. 117
Figura 87 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de corrente caso RBF. 117
Figura 88 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de corrente caso RBF. 118

Figura 89 - Treinamento da localização do instante de incidência das faltas caso RBF. 119
Figura 90 - Matriz de Confusão do treinamento da RNA 2 usando os parâmetros de tensão caso RBF. 120
Figura 91 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de tensão caso RBF. 120
Figura 92 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de tensão caso RBF. 121
Figura 93 - Matriz de Confusão de Treinamento da RNA 2 usando os parâmetros de corrente caso PNN. 122
Figura 94 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de corrente caso PNN. 123
Figura 95 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de corrente caso PNN. 123
Figura 96 - Matriz de Confusão de Treinamento da RNA 2 usando os parâmetros de tensão caso PNN. 124
Figura 97 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de tensão caso PNN. 125
Figura 98 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de tensão caso PNN. 125
Figura 99 - Diagrama unifilar do alimentador - Primeira Parte. 139
Figura 100 Diagrama unifilar do alimentador - Segunda Parte. 140

LISTA DE TABELAS

Tabela 1 - Classificação das VTCDs, segundo IEEE 1159. 29
Tabela 2 - Classificação das VTCDs, segundo ANEEL e ONS. 30
Tabela 3 - Distância entre a carga e o alimentador. 40
Tabela 4 - Exemplos de alguns casos simulados. 42
Tabela 5 - Quando a fase B está envolvida nas faltas. 54
Tabela 6 - Quando a fase B não está envolvida nas faltas. 55
Tabela 7 - Características das MLP utilizadas. 77
Tabela 8 - Características das RBF utilizadas. 77
Tabela 9 - Características das PNN utilizadas. 77
Tabela 10- Saída da RNA 1. 78
Tabela 11- Saída da RNA 2. 78
Tabela 12- Desempenho das RNA 1 utilizando diferentes métodos. 105
Tabela 13- Desempenho das RNA 1 utilizando diferentes métodos. 105
Tabela 14- Desempenho das RNA 2 utilizando diferentes métodos. 126
Tabela 15- Desempenho das RNA 2 utilizando diferentes métodos. 127

LISTA DE ABREVIATURAS E SIGLAS

FNDCT	Fundo Nacional de Desenvolvimento Científico e Tecnológico
MME	Ministério de Minas e Energia
QEE	Qualidade da Energia Elétrica
P&D	Pesquisa e Desenvolvimento
IEEE	Institute of Electrical and Electronics Engineers
CIGRÉ	Congrès International des Grands Réseaux Électriques
CIRED	Congrès International des Réseaux Electriques de Distribution
UIE	International Union for Electricity
VTCD	Variação de Tensão de Curta Duração
SDE	Sistema de Distribuição de Energia Elétrica
RNA	Redes Neurais Artificiais
ANEEL	Agência Nacional de Energia Elétrica
PRODIST	Procedimentos de Distribuição de Energia Elétrica no Sistema Nacional
ONS	Operador Nacional do Sistema Elétrico
SEP	Sistema Elétrico de Potência
ITIC	Information Tecnology Industry Council
CBEMA	Computer Business Equipment Manufacturers Association
SEMI	Semiconductor Equipment and Materials Institute
EE	Energia Elétrica
SE	Subestação
PSCAD	Power System Computer Aided Design
EMTDC	Electromagnetic Transients including DC
ATP	Alternative Transients Program
CELESC	Centrais Elétricas de Santa Catarina S.A.
IEC	Institute Electrotechnical Commission
COMTRADE	Common Format for Transient Data Exchange
ASCII	American Standard Code for Information Interchange
RDP	Registradores Digitais de Pertubações
DFR	Digital Fault Recorder
PLL	Phase Locked Loop
SDF	Sistema de Detecção de Falta
ABNT	Associação Brasileira de Normas Técnicas
SIN	Sistema Interligado Nacional
MSE	Mean Square Error
EQM	Erro Quadrático Médio
MLP	Multi Layer Perceptron
RBF	Radial Basis Functions
PNN	Probabilistic Neural Networks

LISTA DE SÍMBOLOS

s	Segundos
ms	Milissegundos
m	Metro
A	Ampère
V	Volts
c	Ciclo
CC	Corrente Contínua
CA	Corrente Alternada
Hz	Hertz
Scc	Potência Aparente
p.u.	Por Unidade

SUMÁRIO

	INTRODUÇÃO	21
1	**QUALIDADE DA ENERGIA ELÉTRICA**	25
1.1	**Distúrbios Elétricos**	26
1.1.1	Afundamento de Tensão	26
1.1.2	Elevação de Tensão	26
1.1.3	Desequilíbrio de Tensões	27
1.1.4	Micro-interrupção	27
1.1.5	Cortes	27
1.1.6	Harmônicos	27
1.1.7	Oscilações Transitórias	28
1.2	**Variações de Tensão de Curta Duração**	28
1.3	**Tolerância dos Equipamentos a VTCDs**	30
2	**DETECÇÃO DE FALTAS**	33
3	**SISTEMA DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA**	37
3.1	**Caracterização do Simulador**	38
3.2	**Definição do Alimentador**	39
3.2.1	Sistema Piloto	39
3.3	**Rede Simulada**	40
3.3.1	Parâmetros da Simulação	40
3.4	**Composição dos Registros Digitais de Pertubação**	41
4	**METODOLOGIA DE DETECÇÃO DA FALTA**	47
4.1	**Sistema de Sincronismo**	47
4.2	**Algoritmo de Detecção das Faltas**	48
4.2.1	Carregar Arquivo	48
4.2.2	Análise Fundamental	48
4.2.3	Comparador	49

4.2.4 Guardar Arquivo . . . 51
4.3 **Análise Exploratória dos Dados Extraídos pelo PLL** . . . 52
5 **INTRODUÇÃO ÀS REDES NEURAIS ARTIFICIAIS** . . . 60
5.1 **Características da RNAs** . . . 61
5.1.1 Aprendizagem . . . 61
5.1.2 Generalização . . . 61
5.1.3 Paralelismo . . . 62
5.1.4 Não-Linearidade . . . 62
5.1.5 Adaptação . . . 62
5.1.6 Resposta a Evidências . . . 62
5.1.7 Tolerância a Falhas . . . 62
5.1.8 Robustez . . . 63
5.2 **Neurônio Artificial** . . . 63
5.3 **Tipos de Função de Ativação** . . . 64
5.3.1 Função Linear . . . 64
5.3.2 Função Degrau . . . 64
5.3.3 Função Logística . . . 65
5.3.4 Função Tangente Hiperbólica . . . 66
5.3.5 Função Gaussiana . . . 66
5.3.6 Função Competitiva . . . 67
5.4 **Algoritmos de Treinamento** . . . 67
5.4.1 Aprendizado Supervisionado . . . 68
5.4.2 Correção de Erros . . . 69
5.5 **Arquitetura da Rede Neural** . . . 70
5.5.1 Perceptron de Múltiplas Camadas . . . 70
5.5.2 Função de Base Radial . . . 71
5.5.3 Probabilística . . . 72
6 **METODOLOGIA DE CLASSIFICAÇÃO DA FALTA** . . . 75
6.1 **Dados Coletados** . . . 75

6.2 **Extração das Características** . . . 76
6.3 **Definição da RNA** . . . 76
6.3.1 Treinamento . . . 78
6.3.1.1 Identificação da falta . . . 79
6.3.1.2 Localização da falta . . . 80
6.3.2 Teste . . . 80
7 **ANÁLISE DOS RESULTADOS OBTIDOS** . . . 82
7.1 **Identificação dos tipos das faltas** . . . 82
7.1.1 Primeira Abordagem - Identificação caso MLP . . . 82
7.1.1.1 Parâmetro da Fundamental de Corrente . . . 82
7.1.1.2 Parâmetro da Fundamental de Tensão . . . 88
7.1.2 Segunda Abordagem - Identificação caso RBF . . . 93
7.1.2.1 Parâmetro da Fundamental de Corrente . . . 93
7.1.2.2 Parâmetro da Fundamental de Tensão . . . 96
7.1.3 Terceira Abordagem - Identificação caso PNN . . . 99
7.1.3.1 Parâmetro da Fundamental de Corrente . . . 99
7.1.3.2 Parâmetro da Fundamental de Tensão . . . 102
7.1.4 Comparação dos Resultados da Identificação . . . 104
7.2 **Localização dos instantes de incidências das faltas** . . . 105
7.2.1 Primeira Abordagem - Localização caso MLP . . . 105
7.2.1.1 Parâmetro da Fundamental de Corrente . . . 106
7.2.1.2 Parâmetro da Fundamental de Tensão . . . 111
7.2.2 Segunda Abordagem - Localização caso RBF . . . 116
7.2.2.1 Parâmetro da Fundamental de Corrente . . . 116
7.2.2.2 Parâmetro da Fundamental de Tensão . . . 119
7.2.3 Terceira Abordagem - Localização caso PNN . . . 122
7.2.3.1 Parâmetro da Fundamental de Corrente . . . 122
7.2.3.2 Parâmetro da Fundamental de Tensão . . . 124
7.2.4 Comparação dos Resultados da Localização . . . 126

8 **CONCLUSÕES E TRABALHOS FUTUROS** 128

REFERÊNCIAS 132

INTRODUÇÃO

Nos últimos anos, devido ao desenvolvimento do País, houve um grande incremento na demanda por energia elétrica por parte do setor industrial e por consumidores de um modo geral. A finalidade de um sistema de potência é gerar, transmitir e distribuir energia elétrica para uma multiplicidade de pontos, para diversas aplicações.

Tal sistema deve ser projetado e operado para entregar esta energia obedecendo a dois requisitos básicos: qualidade e economia. Apesar de serem relativamente antagônicos são possíveis de conciliar, utilizando conhecimentos técnicos e bom senso. Uma das ocorrências com maior impacto no fornecimento da energia elétrica consiste em curto-circuitos (ou falta) em um dos componentes do sistema de potência, que resulta em contingências severas à rede elétrica.

Os aparelhos que utilizam controle digital em geral são bastante sensíveis a variações de tensão na rede elétrica e dependem de suprimento de energia elétrica confiável e de boa qualidade para operarem satisfatoriamente. Já os dispositivos de potência, chaveados eletronicamente, costumam figurar entre os principais responsáveis pela geração de distúrbios na tensão, degradando a qualidade da energia elétrica, devido ao processo não-linear de chaveamento de corrente e de tensão.

Dentre os distúrbios que afetam a qualidade da energia elétrica, a variação de tensão tem se destacado perante profissionais de engenharia, pois a ocorrência desse distúrbio pode levar à interrupção de processos industriais gerando produtos inadequados e, consequentemente, perdas econômicas.

Nesse sentido, um dos grandes desafios das concessionárias de distribuição hoje em dia é a melhoria no fornecimento da energia elétrica aos seus consumidores de uma forma contínua com confiabilidade e qualidade. Logo, é necessário o acompanhamento e gerenciamento de indicadores de qualidade, e a identificação de eventuais violações dos padrões estabelecidos visando a correção das anomalias e a aplicação das medidas de correções cabíveis.

Motivação

As variações de tensão de curta duração (VTCDs) em um sistema de distribuição não podem ser totalmente evitadas, e sua total supressão é extremamente difícil. Contudo, a magnitude e a duração do evento podem ser limitadas, com a finalidade de diminuir as interrupções dos processos industriais.

O diagnóstico de curto-circuitos, em sistemas de distribuição de energia, é fortemente vinculado à experiência de operadores humanos. Através de alarmes presentes em painéis de controle e telas de sistemas supervisórios, as decisões devem ser tomadas o mais rápido e eficientemente possíveis pelos operadores, sempre buscando a extinção da falta no menor intervalo de tempo possível.

Deve-se ressaltar, porém, que tais ações são praticamente impossíveis de serem baseadas apenas na experiência e percepção de operadores. Deste modo, torna-se necessária a automatização do processo de análise dos dados, propiciando uma melhor apresentação do estado do sistema de distribuição de energia.

Neste sentido, busca-se, através de metodologias baseadas em Inteligência Artificiais, técnicas para combinar a experiência do operador e a habilidade de executar rotinas com a máxima rapidez e segurança. Desta forma, poder-se-ia produzir um diagnóstico eficiente de classificação de distúrbios no ambiente da subestação automatizada, além de indicar aos operadores as possíveis alternativas para minimizar os efeitos causados por uma contingência.

Objetivos

O objetivo desta dissertação é propor uma metodologia para a localização da origem do distúrbio e classificação das fases envolvidas em variações de tensão de curta duração em uma rede de distribuição de energia elétrica. Esta metodologia deverá basear-se nos valores estimados da frequência, amplitude e fase da fundamental das fases individuais. Para

isso utiliza-se redes neurais artificiais. Como parte da metodologia de desenvolvimento, realiza-se simulações computacionais utilizando-se o programa PSCAD/EMTDC e para a detecção das VTCDs utiliza-se um *Phase Locked Loop* (PLL), com o objetivo de produzir tensões sincronizadas com a componente da fundamental.

A Figura 1 ilustra essa metodologia: um bloco de entrada captura dois sinais (tensão e corrente), dois blocos de processamento (detecção do início da pertubação e extração dos parâmetros da fundamental e a rede neural) e dois blocos de saída (contendo o tipo e o local da falta para o padrão de entrada apresentado à RNA). Os sinais de tensão e corrente ($V_a, V_b, V_c, I_a, I_b\, e\, I_c$) são apresentados a um PLL. Através desta técnica pode-se extrair-se do sinal no domínio do tempo os parâmetros (frequência, amplitude e fase) estimados da fundamental.

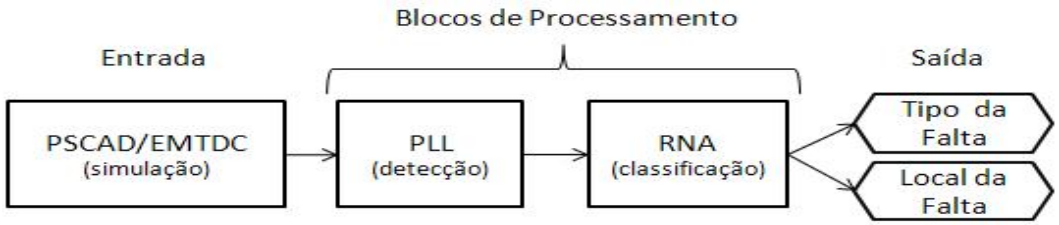

Figura 1 - Processo de detecção e classificação das faltas.

Organização do Texto

Na sequência, no **capítulo 1**, abordam-se conceitos e definições sobre a qualidade de energia elétrica. Inicialmente a relevância do tema é discutida, em seguida são apresentados os conceitos dos principais distúrbios elétricos, situando o tipo de distúrbio que é abordado no decorrer desta dissertação e a tolerância dos equipamentos eletrônicos frente a esses distúrbios.

Em seguida, no **capítulo 2**, são descritos alguns métodos e técnicas de localização e classificação de faltas pesquisados durante o desenvolvimento desta dissertação. Na literatura, encontra-se uma grande variedade de trabalhos relacionados com este tema, dessa forma, apenas alguns trabalhos relacionados à distribuição de energia elétrica são

apresentados nesta seção.

No **capítulo 3**, descrevem-se as características do simulador da rede elétrica, a definição do alimentador de energia, os parâmetros da rede simulada e a composição dos registros digitais de pertubação para cada falta simulada no PSCAD/EMTDC.

No **capítulo 4**, apresenta-se a metodologia adotada neste trabalho para a detecção do ponto de incidência das faltas em alimentadores de distribuição de energia elétrica, baseado no uso de um circuito de sincronismo *(Phase Locked Loop)*.

No **capítulo 5**, apresentam-se aspectos gerais sobre as redes neurais artificiais e discutem-se aspectos como os vários tipos de aprendizados existentes, as funções de ativações e as arquiteturas das redes neurais adotadas nesta pesquisa.

No **capítulo 6**, propõem-se duas redes neurais, uma para identificar e a outra para localizar os tipos das faltas ocorridas no sistema de distribuição de energia elétrica aqui estudado. Para cada uma das redes neurais propostas, foram desenvolvidas três diferentes arquiteturas com o objetivo de comparar seus desempenhos na generalização. As características das estruturas e a otimização visando a redução do banco de dados que será apresentado às redes neurais também são discutidas nesse capítulo.

No **capítulo 7**, são apresentados os resultados obtidos para as diferentes arquiteturas de redes neurais artificiais desenvolvidas para a identificação do tipo e a localização da falta, de forma a validar a técnica proposta.

No **capítulo 8**, são apresentadas as **conclusões** sobre os resultados obtidos nos testes realizados e recomendações e sugestões para trabalhos futuros.

1 QUALIDADE DA ENERGIA ELÉTRICA

Entende-se que a Qualidade da Energia Elétrica é dada pela disponibilidade de energia através de uma forma de onda senoidal pura, sem alterações de amplitude e/ou frequência. Com isso, a busca por essa qualidade passou a ser preocupação de empresas, agentes e consumidores do setor elétrico nacional [30].

Nos últimos anos houve grandes mudanças no setor elétrico brasileiro devido à modernização dos equipamentos eletrônicos cada vez mais complexos e sensíveis aos distúrbios na alimentação [19]. Uma energia de baixa qualidade pode levar à paralisação ou redução de um processo industrial gerando grandes perdas na produção, causando um prejuízo quantificável [30]. Diante das novas características dos consumidores, as concessionárias de energia elétrica veem-se obrigadas a melhorar a qualidade do fornecimento de seu produto.

A par da importância da Qualidade da Energia Elétrica (QEE), a Agência Nacional de Energia Elétrica (ANEEL), responsável por regular e fiscalizar a produção, transmissão, distribuição e comercialização de energia elétrica no Brasil, publicou uma resolução exigindo das empresas concessionárias o melhoramento de certos indicadores de qualidade no fornecimento. Dentre as resoluções da ANEEL, as de números [1, 2] são destacadas no Diário Oficial da União. A primeira trata da continuidade do fornecimento de energia elétrica e, a segunda, da conformidade de tensão em regime permanente [51].

A ANEEL, ONS (Operador Nacional de Sistema) e representantes do setor elétrico elaboraram um conjunto de diretrizes denominadas "Procedimentos de Distribuição de Energia Elétrica no Sistema Nacional - PRODIST" [3], que visa regulamentar os serviços de distribuição de energia elétrica das empresas concessionárias e permissionárias. Cabe informar que o PRODIST está dividido em oito módulos, sendo que o oitavo [4] está relacionado aos aspectos da qualidade do produto e a qualidade do serviço.

Os aspectos da QEE em regime permanente ou transitório, considerados pelo PRODIST são: tensão em regime permanente, fator de potência, distorções harmônicas, desequilíbrio de tensão, flutuação de tensão, VTCD e variação da frequência.

Dentre os distúrbios que ocorrem na rede elétrica, a variação de tensão de curta duração possui maior importância na avaliação da QEE, porque ela é rapidamente percebida por parte dos consumidores industriais, comerciais e residenciais. A monitoração da Energia Elétrica (EE) é necessária para caracterizar fenômenos eletromagnéticos em um determinado local no Sistema de Distribuição de Energia (SDE).

1.1 **Distúrbios Elétricos**

Os distúrbios aos quais o sistema elétrico está exposto podem ser caracterizados de diversas maneiras: em função da duração do evento (curta, média ou longa duração), da faixa de frequência envolvidas (baixa, média ou alta frequência), dos efeitos causados (aquecimento, vibrações, cintilação luminosa, erro de medidas, perda de eficiência, redução da vida útil) ou de acordo com a intensidade do impacto (pequeno, médio ou grande impacto) [15].

Os distúrbios se devem a desvios em regime permanente da forma de onda em relação à onda "teórica" sem componentes harmônicos. Na sequência são apresentadas algumas definições clássicas dos distúrbios mais frequentes e na Figura 2 são mostrados os principais distúrbios envolvendo a QEE.

1.1.1 Afundamento de Tensão

O afundamento de tensão é definido como o evento em que o valor eficaz da tensão ou da corrente é superior a 0.1 e inferior a 0.9 p.u. da tensão nominal, com duração de meio ciclo até 1 minuto e é tipicamente provocado pela entrada de uma carga temporária, de porte significativo em relação ao nível local de curto-circuito [3, 7, 39]. Em geral, seu efeito desaparece depois que a causa direta é removida.

1.1.2 Elevação de Tensão

A elevação do valor eficaz da tensão ou da corrente do sistema de potência na frequência fundamental é um evento em que os valores eficazes estão entre 1.1 e 1.8 p.u.

da tensão nominal, com duração entre meio ciclo e 1 minuto [3, 39]. Trata-se do efeito contrário ao do afundamento, sendo as principais causas as saídas temporárias de cargas ou a conexão de um banco de capacitores, a presença da compensação capacitiva leva a uma elevação da tensão, até que o banco seja desconectado [7].

1.1.3 Desequilíbrio de Tensões

O desequilíbrio de tensão é a diferença nas amplitudes entre as três tensões das fases ou no desvio da defasagem de 120 ° entre essas tensões trifásicas e são causadas pela conexão desigual de cargas mono ou bifásicas em sistemas trifásicos [3, 39]. Cargas trifásicas não-lineares de grande porte também podem produzir desequilíbrios [15].

1.1.4 Micro-interrupção

A micro-interrupção é a perda completa da alimentação por até meio ciclo da frequência da rede onde o valor eficaz da tensão é inferior a 0.1 p.u. da tensão nominal em uma ou mais fases [3, 39]. Esse tipo de defeito em geral é devido a um curto-circuito com extinção rápida em sistemas de distribuição de energia. Fontes de alimentação CC com capacitores dimensionados adequadamente podem suportar esse tipo de distúrbio sem afetar o dispositivo alimentado [15].

1.1.5 Cortes

Os cortes são transições sucessivas e bruscas de tensão ou corrente entre diferentes níveis com duração menor do que meio ciclo e são normalmente associados a curtos-circuitos momentâneo da fonte. Ocorre, principalmente, devido à comutação de chaves eletrônicas de potências quando a corrente é comutada de uma fase para outra. Por exemplo, conversores trifásicos são fontes de ruídos e interferências [3, 15, 39].

1.1.6 Harmônicos

Os harmônicos são distúrbios na forma de onda da tensão ou corrente em função da interferência de outras ondas senoidais, com frequências correspondentes a múltiplos

inteiros da frequência fundamental do sistema. Em geral, são medidas pela distorção harmônica total, que representa a decomposição percentual em relação à corrente fundamental do sistema [3, 15, 39]. São causados geralmente por equipamentos e cargas ligados ao sistema de potência com características não lineares.

1.1.7 Oscilações Transitórias

São oscilações de curta duração devidas a manobras de disjuntores e em geral são causadas por chaveamento de capacitores na rede devido aos elevados valores de variações de corrente di/dt provocados pela brusca energização de um capacitor. São excitadas ressonâncias em alta frequência, que se convertem em oscilações rápidas da tensão no ponto de conexão do capacitor. Essas oscilações podem provocar a atuação da proteção ou produzir sobre-tensões em outros equipamentos próximos [3, 15, 39].

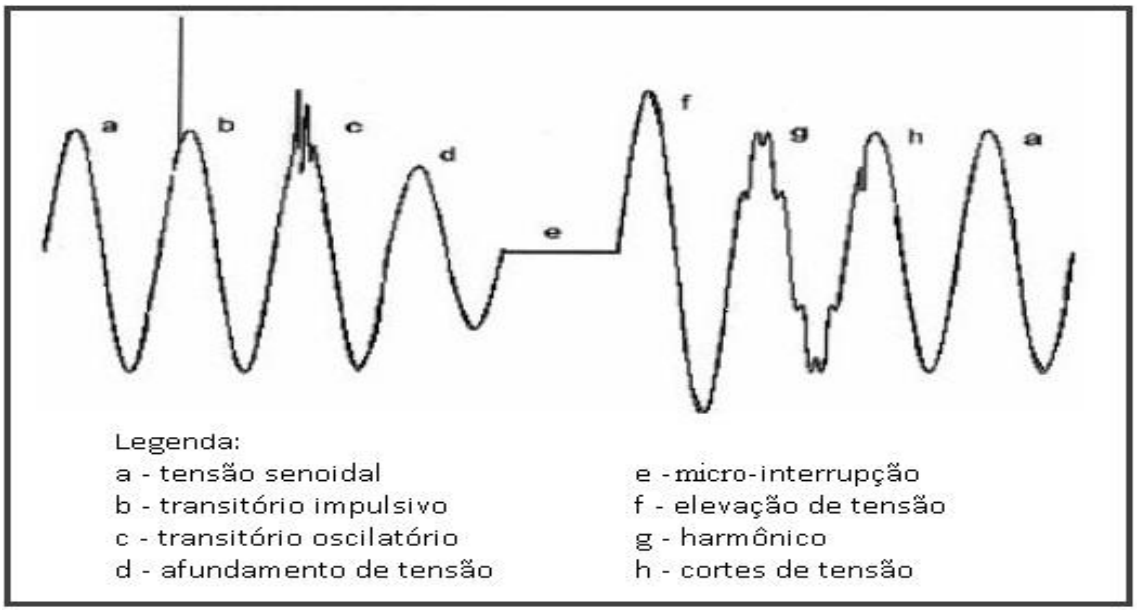

Figura 2 - Principais distúrbios associados a QEE.
[20, 46]

1.2 **Variações de Tensão de Curta Duração**

São definidos como VTCDs, os eventos aleatórios de tensão caracterizados por um desvio maior do que 10% em relação à da tensão de referência e com duração entre um

ciclo da fundamental e 1 minuto [39]. Eventos com durações superiores são considerados como de longa duração. Suas principais causas são: curtos-circuitos, manobras de rede, atuação indevida da proteção e instabilidade ambiental [51]. Uma vez que a tensão pode variar significativamente durante o evento, é usual definir a magnitude da VTCD através do valor extremo (mínimo ou máximo) da tensão eficaz remanescente, enquanto perdurar o evento.

A duração da VTCD, por sua vez, é definida pelo intervalo de tempo decorrido entre o instante em que a tensão eficaz ultrapassa a faixa de tolerância e o instante em que a mesma retorna para a faixa [16]. Em geral, as VTCDs são associadas a faltas no Sistema Elétrico de Potência (SEP), falhas em equipamentos de proteção, chaveamento capacitivo ou indutivo e à entrada ou saída temporária de cargas de porte significativo em relação ao nível de curto-circuito do sistema [16].

A recomendação IEEE 1159 [20] classifica os eventos de curta duração quanto à magnitude como sendo: elevação *(swell)*, afundamento *(sag)* ou interrupção *(interruption)*; e quanto à duração como sendo: instantâneo, momentâneo ou temporário, de acordo com a Tabela 1. Já no Brasil, a ANEEL e o ONS classifica a VTCDs de acordo com a Tabela 2.

Classificação		Magnitude (m)	Duração (d)
Instantâneo	Elevação	1,1 pu < m ≤ 1,8 pu	0,5 c < d ≤ 30 c
	Afundamento	0,1 pu ≤ m < 0,9 pu	
Momentâneo	Elevação	1,1 pu < m ≤ 1,4 pu	30 c < d ≤ 3 s
	Afundamento	0,1 pu ≤ m < 0,9 pu	
	Interrupção	m < 0,1 pu	0,5 c < d ≤ 3 s
Temporário	Elevação	1,1 pu < m ≤ 1,2 pu	3 s < d ≤ 60 s
	Afundamento	0,1 pu ≤ m < 0,9 pu	
	Interrupção	m < 0,1 pu	

Tabela 1 - Classificação das VTCDs, segundo IEEE 1159.
[16, 20]

As durações das três categorias da recomendação IEEE 1159 estão intencionalmente correlacionadas com o tempo de atuação da proteção e a divisão das durações

Classificação		Magnitude (m)	Duração (d)
Momentâneo	Elevação (EMT)	$m > 1{,}1$ pu	1 c $< d \leq 3$ s
	Afundamento (AMT)	$0{,}1$ pu $\leq m < 0{,}9$ pu	
	Interrupção (IMT)	$m < 0{,}1$ pu	$d \leq 3$ s
Temporário	Elevação (ETT)	$m > 1{,}1$ pu	3 s $< d \leq 60$ s
	Afundamento (ATT)	$0{,}1$ pu $\leq m < 0{,}9$ pu	
	Interrupção (ITT)	$m < 0{,}1$ pu	

Tabela 2 - Classificação das VTCDs, segundo ANEEL e ONS. [4, 16]

recomendadas por organismos técnicos internacionais, como o CIGRÉ/UIE [20].

O intervalo de tempo de 30 ciclos está relacionado ao tempo de atuação dos religadores para limitar curtos-circuitos não-permanentes. Já o intervalo de tempo compreendido entre 30 ciclos e 3 segundos, está associado tipicamente ou tempo de eliminação do efeito da falta em todos os barramentos [16, 20].

1.3 **Tolerância dos Equipamentos a VTCDs**

Com a expansão do uso de equipamentos de informática e eletrônicos domésticos, que são bastante sensíveis às variações da tensão de alimentação, tornou-se necessário padronizar as condições de teste para verificar a suportabilidade dos equipamentos aos distúrbios provenientes da rede. Com o intuito de normatizar a fabricação desses equipamentos, foi determinada a curva ITIC/CBEMA [23, 34], que fornece limites de tolerância típica de diferentes computadores a variação de tensão tanto em magnitude quanto em duração do evento.

A curva ITIC é dividida em três áreas, região dano físico, região de operação normal e região de operação sem dano físico, conforme Figura 3, [23, 34]. A análise da curva CBEMA, destaca dois pontos principais: o primeiro é 0.5 ciclo que corresponde ao tempo de 8.3[ms] no qual, qualquer equipamento tem que ser capaz de absorver uma

interrupção de energia por este período; o segundo é o ponto de 2[s]: a partir deste tempo, todos os equipamentos devem suportar, continuamente, quedas de até 13% ou acréscimos até 6%, no valor da tensão nominal. Para atender à curva ITIC, os equipamentos devem operar sem falhas na região de operação normal.

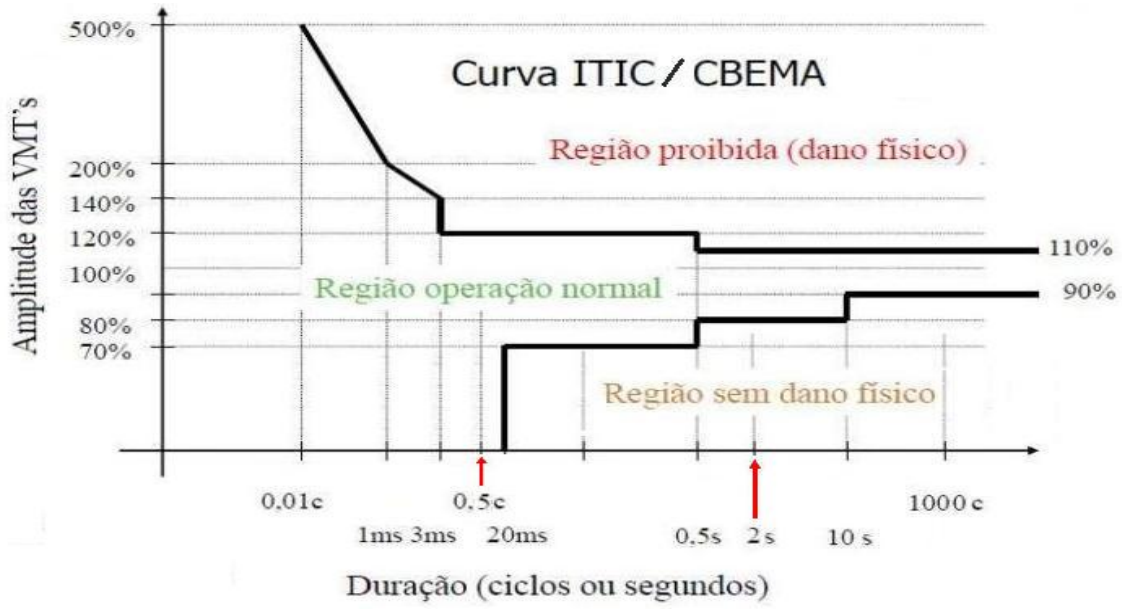

Figura 3 - Curva de suportabilidade para computadores - ITIC.
[23, 34]

A curva de suportabilidade dos equipamentos semicondutores é definida pela norma SEMI F47 [45], que especifica os limites de tolerância requerida para os fabricantes como critério de projeto para condições mínimas de suportabilidade dos equipamentos por eles fabricados [34, 45]. Para atender a norma, os equipamentos devem operar sem falhas na região acima da curva mostrada na Figura 4.

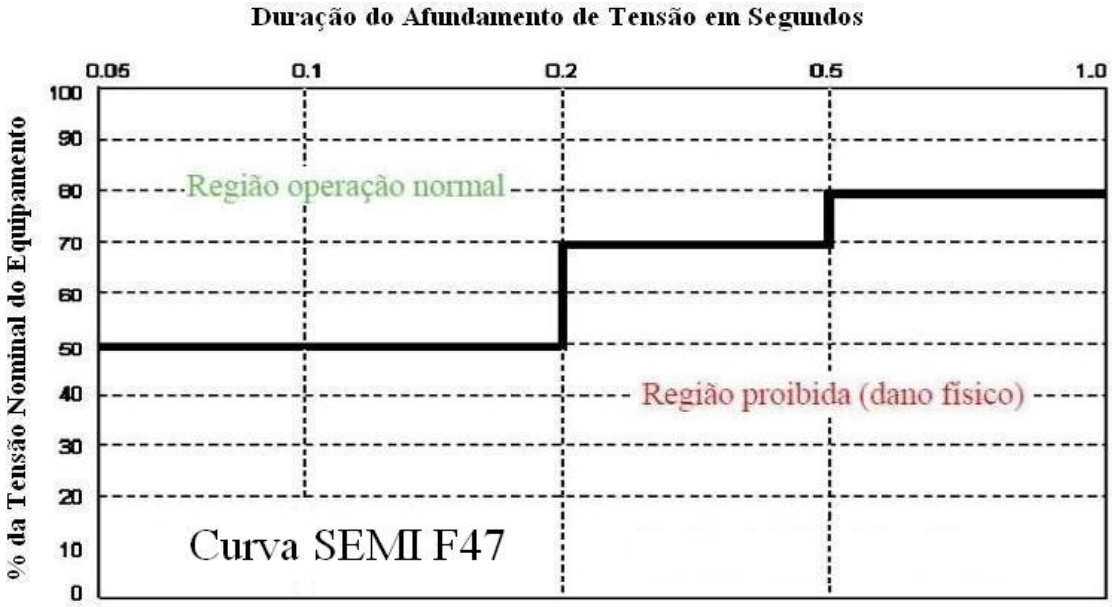

Figura 4 - Curva de suportabilidade para semicondutores - SEMI F47. [34, 45]

2 DETECÇÃO DE FALTAS

Historicamente o Brasil, a França e a Inglaterra foram os pioneiros no desenvolvimento de trabalhos na área da Qualidade da Energia Elétrica (QEE) nas décadas 70 e 80. Esse desenvolvimento deveu-se no Brasil a grandes projetos, como por exemplo a *"Ferrovia de Carajás"* e o *"Sistema de Transmissão de Itaipu"*, resultando na formação de uma equipe especialista em solucionar problemas na área da qualidade da energia que surgiram ao longo desses projetos [9, 34].

O *Institute of Electrical and Electronics Engineers* (IEEE) publicou, em 1995, uma recomendação para o monitoramento da QEE, onde pode ser encontrada a definição de Variação de Tensão de Curta Duração (VTCD) [20, 34].

Em 1998, o IEEE [21] publicou uma recomendação para avaliação da compatibilidade de sistemas elétricos de potência com equipamentos eletrônicos de processos industriais com o objetivo de melhorar a qualidade do fornecimento da energia elétrica.

O grupo de trabalho internacional CIGRÉ, CIRED e UIE, publicou, em 2010 [10], a recomendação a cerca da imunidade de equipamentos e instalações para a monitoração de VTCDs. Este documento contém a descrição dos afundamentos, a avaliação de equipamentos e processos, a caracterização de testes de imunidade, os aspectos econômicos e estatísticos e a aplicação das classes de imunidade [34].

Em [36] é feita uma revisão de diferentes técnicas propostas para localização de faltas em Sistema de Distribuição de Energia Elétrica (SDE). Em geral, esses métodos podem ser classificados em três grandes categorias, que são: i) Impedância e métodos baseado na frequência fundamental, ii) componentes de alta frequência e métodos de onda viajantes e iii) baseados em especialista. A última categoria pode ser dividida em três grandes grupos: Inteligência Artificial baseada em análise estatística, dispositivos distribuídos e métodos híbridos.

Em [53] mostram-se resultados obtidos com o IdentSis, programa de identificação de origem de VTCDs devido a curto-circuitos. São descritas as metodologias utilizadas para processamento de sinais de tensões fase-neutro, caracterização e classificação de

VTCD e a determinação de um diagnóstico do local mais provável de origem da falta.

Em [44] foi desenvolvido um programa computacional para localização de faltas em redes de distribuição a partir de estudos da rede combinados com a monitoração remota de dispositivos de proteção. O programa computacional proposto combina as informações provenientes de pontos de monitoramento ao longo dos alimentadores com resultados de cálculos de curto-circuitos, variação da curva de carga e probabilidade de falhas. A originalidade do *software* reside na combinação de técnicas de análise da rede (fluxo de carga e estimação de estados), confiabilidade e monitoramento.

Em [42] descreve-se o desenvolvimento de um sistema de medição de baixo custo voltado para a localização de faltas em alimentadores de distribuição de energia elétrica, baseado em uma rede de sensores sem fio padrão IEEE 802.15.4 para a aquisição dos dados de tensão e corrente de cada fase do alimentador. De posse de várias dessas medições, o setor sob defeito pode ser localizado, reduzindo assim o tempo de desligamento e os custos de manutenção.

Em [37] a técnica chamada de *k-Nearest Neighbors* (k-NN) foi utilizada como uma estratégia integrada para a localização de faltas em um sistema de distribuição de energia elétrica. Isso ajuda a superar as desvantagens individuais dos métodos: estimativa da impedância equivalente e regressão pela aproximação, evitando a possível ambiguidade na localização da área devido ao seu tamanho, no caso da abordagem de classificação. Além disso, o uso da técnica de aprendizagem reduz a dependência do modelo do SDE, pois este se baseia principalmente nas informações obtidas dos bancos de dados das falhas de tensão e corrente.

Em [26] calcula-se a energia de diversas sub-bandas de frequência do sinal de corrente e aplica-se os valores à entrada de uma RNA com o objetivo de detectar a falta de alta impedância em um sistema de distribuição de energia elétrica.

Em [6] apresenta-se um processo de identificação e classificação de faltas em sistemas elétricos de transmissão bem como um estudo comparativo de aplicação de metodologias de Redes Neurais Artificiais no processo de classificação dos tipos de curto-circuitos.

Em [5] a falta de alta impedância em um sistema de distribuição de energia elétrica

é detectada utilizando redes neurais artificiais aplicadas ao espectro de frequência da corrente do alimentador de energia. O algoritmo de aprendizado *Backpropagation* foi usado para ajustar os pesos das camadas ocultas da rede neural, minimizando o erro de previsão com relação aos pesos de conexão da mesma.

Em [35] a metodologia proposta é baseada em três passos distintos: i) As correntes de linha são transformadas em coordenadas dos eixos (α-eixo), (β-eixo) e (0-eixo) e aplicada a Transformação Clarke-Concordia [24], ii) é realizada à análise dos autovalores e autovetores das matrizes e iii) desenvolvimento de uma rede neural adaptativa. As principais características e particularidades do método proposto foram: redução do número de sinais de entrada (este foi um importante aspecto para a não utilização dos detectores de tensão), reconhecimento do tipo de faltas e identificação da linha com defeito. A localização da falta, independentemente de sua presença no momento da análise, quase não foi influenciada pelos harmônicos. A simulação dos resultados apresentados mostram que a RNA proposta foi uma técnica promissora para localização das faltas em um sistema de distribuição de energia elétrica.

Em [38] a localização de faltas de alta impedância em sistema de distribuição é baseado em Redes Neurais Artificiais. O sistema desenvolvido é capaz de obter uma estimativa precisa da localização tanto de faltas lineares, quanto de faltas de alta impedância em alimentadores de distribuição.

Em [11] apresenta-se um processo de classificação das faltas em um sistema elétrico de distribuição baseado na combinação das técnicas de redes neurais (mapas auto-organizáveis de Kohonen) e transformada de *Wavelet*, os dados utilizados para a classificação das faltas são provenientes do programa de simulação PSCAD/EMTDC e a rede neural obteve um desempenho entre 85% e 92%.

Em [43] propõe uma metodologia para a localização das faltas (da fase para o terra) em um sistema de distribuição de energia elétrica através da propagação das ondas viajantes em ambos os sentidos, refletidas nas terminações das linhas entre os pontos de intersecção dos alimentadores laterais e o instante de incidência da falta. Dependendo dos caminhos por onde as ondas viajantes passam, o sinal transiente em cada nó contém

certas características de frequências por caminho e o espectro de energia do sinal transitório tem alta densidade em torno das frequência características dos caminhos. Os dados utilizados para a localização das faltas foram provenientes de um programa de simulação ATP/EMTP e neste trabalho foi utilizado a combinação das técnicas de redes neurais e transformada de *Wavelet* para decompor a tensão transitória em diferentes níveis de espectro de energia.

Em [49] a localização das faltas em um sistema elétrico de distribuição e realizada através da combinação das técnicas de redes neurais e *Support Vector Machine* (SVM). Diferente dos tradicionais métodos de estimativa das faltas, a abordagem proposta neste trabalho, utiliza medidas disponíveis na subestação, disjuntor e status de relé. Os dados são analisados utilizando a técnica de análise das componentes principais e as faltas são classificadas de acordo com as reatâncias de seu caminho usando uma combinação de classificadores de vetor de suporte e redes neurais *feedforward* e os resultados demonstram a viabilidade de aplicação do método proposto em diagnosticar as faltas do sistema elétrico de distribuição.

3 SISTEMA DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA

O sistema elétrico de potência, de modo geral, pode ser dividido basicamente em: geração, transmissão e distribuição. Em diferentes pontos do sistema elétrico há necessidade de se reduzir ou elevar os níveis de tensão de modo que o transporte de energia elétrica seja técnica e economicamente viável.

A energia elétrica disponível em enrolamentos de média tensão das estações de transformação alta/média tensão é introduzida nas linhas aéreas ou em cabos subterrâneos e com uma eventual transformação posterior, de forma a ser fornecida aos consumidores.

A rede de distribuição é definida de forma geral como: i) O sistema de média tensão da estação de transformação que compreende as barras de redistribuição de energia e os respectivos aparelhos de comando, proteção e controle, ii) as linhas de média tensão (aéreas e subterrâneas), iii) as cabines de transformação média/baixa tensão, com os transformadores e os aparelhos de comando e proteção e iv) as linhas de baixa tensão (aéreas e subterrâneas) [50].

A rede de distribuição de média tensão pode ser implantada segundo dois esquemas fundamentais, o radial e o em malha. Na distribuição radial, a rede se desenvolve segundo linhas dorsais e derivações; se desejarmos uma maior segurança de serviço, podemos prever duas linhas em paralelo para as ligações mais importantes. Essa prerrogativa é garantida também pela distribuição do tipo em malha, na qual as cabines de transformação são alimentadas por duas partes; na forma mais simples, o esquema em malha é representado por um anel, que congrega as diversas cabines de transformação [8, 50].

Caso a região de interesse seja alimentada por duas estações diferentes de transformação, pode-se executar diversos esquemas derivados dos supra-indicados. O sistema de distribuição do tipo radial é amplamente empregado nas zonas rurais, e naquelas em que a densidade dos consumidores é relativamente pequena. Por outro lado, o sistema de distribuição do tipo malha é adotado nos centros urbanos e industriais [8, 50].

A rede é implantada mediante linhas aéreas ou em cabos subterrâneos; onde for possível, prefere-se as primeiras, em razão do seu menor custo, enquanto que os cabos

subterrâneos são empregados preferencialmente em centros urbanos e industriais, e em todos os casos em que a presença de condutores aéreos não é aconselhável [50]. A Figura 5 ilustra um típico sistema elétrico de potência.

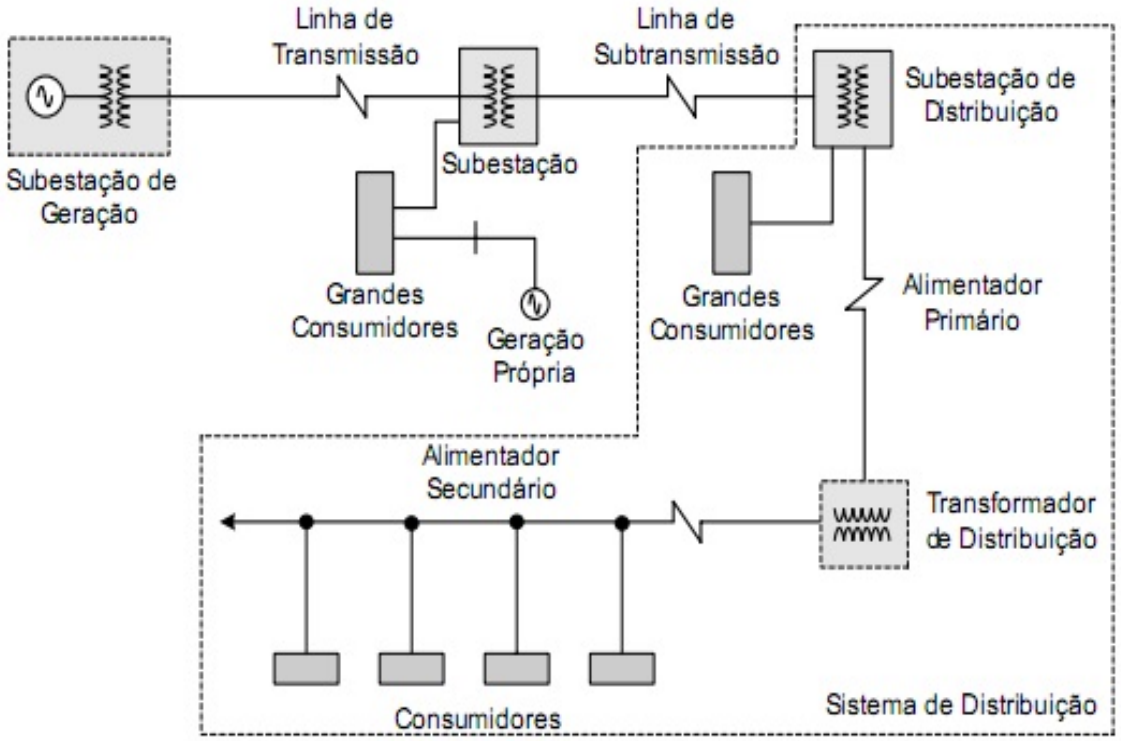

Figura 5 - Diagrama esquemático de uma sistema elétrico de potência.
[13]

3.1 **Caracterização do Simulador**

Devido à dificuldade de gerar distúrbios e realizar testes e análises em uma rede elétrica real (por exemplo, um curto entre a fase A e a fase B), e obter dados suficientes para identificar a alteração ocorrida na rede, um sistema de distribuição de energia elétrica foi simulado em *software* de computador. Utilizou-se o programa PSCAD/EMTDC para simular uma rede de distribuição de energia de forma a que se pudesse obter dados em quantidade satisfatória para estudar e desenvolver técnicas para localizar e classificar faltas do tipo VTCDs [31].

O PSCAD/EMTDC [14] é uma ferramenta profissional de grande capacidade de simulação e análise de circuito e sistemas, sendo sua principal aplicação os sistemas elétri-

cos de potência. O PSCAD é a interface gráfica do usuário enquanto o EMTDC é o *software* de simulação em si.

Eles são considerados meios apropriados de simulação de respostas instantâneas no domínio do tempo, os chamados transientes eletromagnéticos de sistemas elétricos [14]. A interface gráfica do PSCAD facilita a interação entre o EMTDC e o usuário. Essa permite construir esquematicamente o circuito, processar a simulação, analisar os resultados e administrar os dados num ambiente completamente integrado.

Neste trabalho foi empregado um modelo de sistema elétrico de potência composto de uma subestação de distribuição e uma malha contendo várias cargas representando pequenas indústrias, conforme a Figura 6 [33]. Assim, as faltas podem ser simuladas em cada ponto da rede com características distintas e se pode capturar e registrar as formas de ondas resultantes em cada fase, tanto em tensão ou em corrente, da rede trifásica, quando da ocorrência da falta conforme o exemplo da Figura 7.

3.2 **Definição do Alimentador**

O estudo deste trabalho foi baseado no alimentador BSO-01 (subestação 319 - SALTO) do sistema de distribuição da CELESC. No Anexo A estão apresentadas as principais especificações do referido alimentador, que foram obtidos junto à CELESC no projeto de P&D [33]. No Anexo B pode ser visto o diagrama unifilar da primeira parte do citado alimentador, onde estão destacados em vermelho o trecho 1 (saída da SE - CD 1124) e em verde o trecho 2 (CD 1124 - CD 1095). Já no Anexo C pode ser vista a segunda parte do diagrama unifilar do mesmo alimentador, onde está em destaque a continuação do trecho 2 e o trecho 3 (CD 1095 - CDE 1466) demarcado em lilás.

3.2.1 Sistema Piloto

As diversas ramificações presentes no sistema original foram agregadas e substituídas por cargas equivalentes. Por isso, é importante ressaltar que o sistema piloto analisado foi modelado com um número reduzido de barramentos concentrando as cargas em 13 pontos distintos. Nesses pontos, se aplicaram 10 diferentes tipos de curto-circuitos

com o objetivo de compreender melhor os imprevistos no fornecimento de energia elétrica, quando ocorrem as faltas.

Também foi definido que as faltas ocorreriam com três diferentes intervalos de tempo e três diferentes valores de impedâncias. As medições utilizadas para analisar os resultados consistiram de um registrador digital de perturbação (RDP) no início, outro no meio, e um no final da linha de distribuição. Conforme mostrado na Figura 6, e na Tabela 3 são descritas as distâncias em que o instante de incidência da falta se encontra em relação ao alimentador de energia elétrica.

Tabela 3 - Distância entre a carga e o alimentador.

Carga	**Distância**
P01	6,755 km
P02	7,615 km
P03	6,210 km
P04	5,715 km
P05	5,715 km
P06	5,505 km
P07	5,085 km
P08	3,945 km
P09	3,915 km
P10	3,225 km
P11	3,500 km
P12	5,050 km
P13	1,120 km

3.3 **Rede Simulada**

A malha apresentada na Figura 6 é composta por amperímetros, voltímetros, medidores de potência, banco de capacitores, filtros, linhas de transmissão de diferentes comprimentos e geradores lógicos de faltas TFL *(Timed Fault Logic)* conectados aos TPF *(Three Phase Fault)* [30].

Os TFLs são utilizados para controlar a duração e o momento em que a falta ocorre. As fases envolvidas e a resistência da falta são definidas nos TPFs. Cada trecho da linha de distribuição, representada no diagrama unifilar da Figura 6, foi construído respeitando os pré-requisitos necessários para a construção de uma linha real [30].

3.3.1 Parâmetros da Simulação

No alimentador de distribuição da Figura 6 implementado no *software* EMTDC, nos trechos entre os barramentos foram considerados os dados geométricos dos cabos e

postes, sendo que adotou-se o modelo *frequency dependent (Phase)* [14]. A potência de curto-circuito do barramento representativo da subestação é de Scc = 115[MVA] e as cargas inclusas nos barramentos foram do tipo impedância constante com ligação em Y, sendo o terminal de neutro aterrado e com uma potência total de 3.24[MVA] e com um fator de potência de 0.92 indutivo.

Os segmentos de linha do alimentador foram modelados como circuito RL série, sem consideração de acoplamento entre as fases do sistema trifásico. As faltas lineares foram modeladas como simples resistências e a frequência de amostragem para captura utilizada foi de 24.390 amostras por segundo, resultando em 7.318 amostras por ciclo de 60 Hz.

O tempo total de cada simulação foi de 0.3[s]. Foi definido que a ocorrência da falta iniciaria após o sistema elétrico entrar em regime permanente. As faltas assumiram três diferentes durações de forma a diversificar a base de dados, estas foram: 8.33, 16.67 e 25.00[ms] [30].

Nos TPFs as faltas simuladas envolvendo as diferentes fases foram AB, AC, BC, ABC, AG, BG, CG, ABG, ACG e BCG totalizando 10 tipos de faltas diferentes [30]. Os tipos de falta estão ilustrados na Figura 8. Essas podem ocorrer em cada um dos treze pontos destacados na malha, o que fornece 130 diferentes faltas no SDE. Assim, para cada uma das 130 combinações de tipos e locais de falta foram geradas faltas com diferentes durações e resistências num total de 9 diferentes características.

Desta forma, obtêm-se registros correspondentes a 1170 faltas distintas, registradas em três locais diferentes. Foram utilizados três valores para a resistência da falta, alta impedância de 40[Ω], média de 25[Ω] e baixa impedância de 10[Ω]. A Tabela 4 apresenta uma relação com alguns dos casos simulados, a título de exemplo.

3.4 **Composição dos Registros Digitais de Pertubação**

Neste trabalho foi escolhido o padrão COMTRADE [22], por ser um formato comumente utilizado em sistemas de potência, proposto pelo IEEE para representação de sinais de alta tensão.

Tabela 4 - Exemplos de alguns casos simulados.

Ponto	Tipo de Falta	Modelo da Falta	Carregamento
P1	AB	10 ohm	100%
P1	AC	40 ohm	100%
P2	BC	25 ohm	100%
P2	ABC	10 ohm	100%
P3	AG	25 ohm	100%
P3	BG	40 ohm	100%
P4	CG	10 ohm	100%
P4	ABG	40 ohm	100%
P5	ACG	25 ohm	100%
P5	BCG	10 ohm	100%
P6	AB	10 ohm	100%
P6	BC	40 ohm	100%
P7	AC	25 ohm	100%
P7	ABC	10 ohm	100%
P8	BG	25 ohm	100%
P8	AG	40 ohm	100%
P9	CG	10 ohm	100%
P9	ACG	40 ohm	100%
P10	ABG	25 ohm	100%
P10	BCG	10 ohm	100%
P11	AC	25 ohm	100%
P11	AB	40 ohm	100%
P12	CG	10 ohm	100%
P12	ACG	40 ohm	100%
P13	BC	25 ohm	100%
P13	BCG	10 ohm	100%

Os arquivos gerados pelo mesmo estão no formato ASCII definido como arquivo de Configuração (CFG) que possui informações que permitem interpretar corretamente os dados do transitório e de Dados (DAT) que armazena os valores de cada amostra de cada canal medido.

Para cada falta simulada, o PSCAD/EMTDC gera um arquivo DAT, ilustrado na Figura 9, com oito colunas de sinais de saída: a primeira contém os números das amostras, a segunda o tempo em milissegundos, da terceira à quinta os valores de tensão e da sexta à oitava os valores de corrente.

Além disso, o PSCAD/EMTDC gera um arquivo CFG ilustrado na Figura 10 que possui informações tais como: número total de canais, informação de cada canal, valor da frequência nominal da linha, taxa de amostragem utilizada, números de amostras salvas, formato do arquivo e etc, correspondentes ao representativo de cada registro.

O número armazenado no arquivo está no formato inteiro, normalmente correspondente ao formato do equipamento digitalizador. No arquivo de configuração são especificados meios de traduzir esses valores adequadamente para grandezas reais, tais como, normalizações e faixas de volts e amperes. Essas informações estão nas descrições de cada um dos canais.

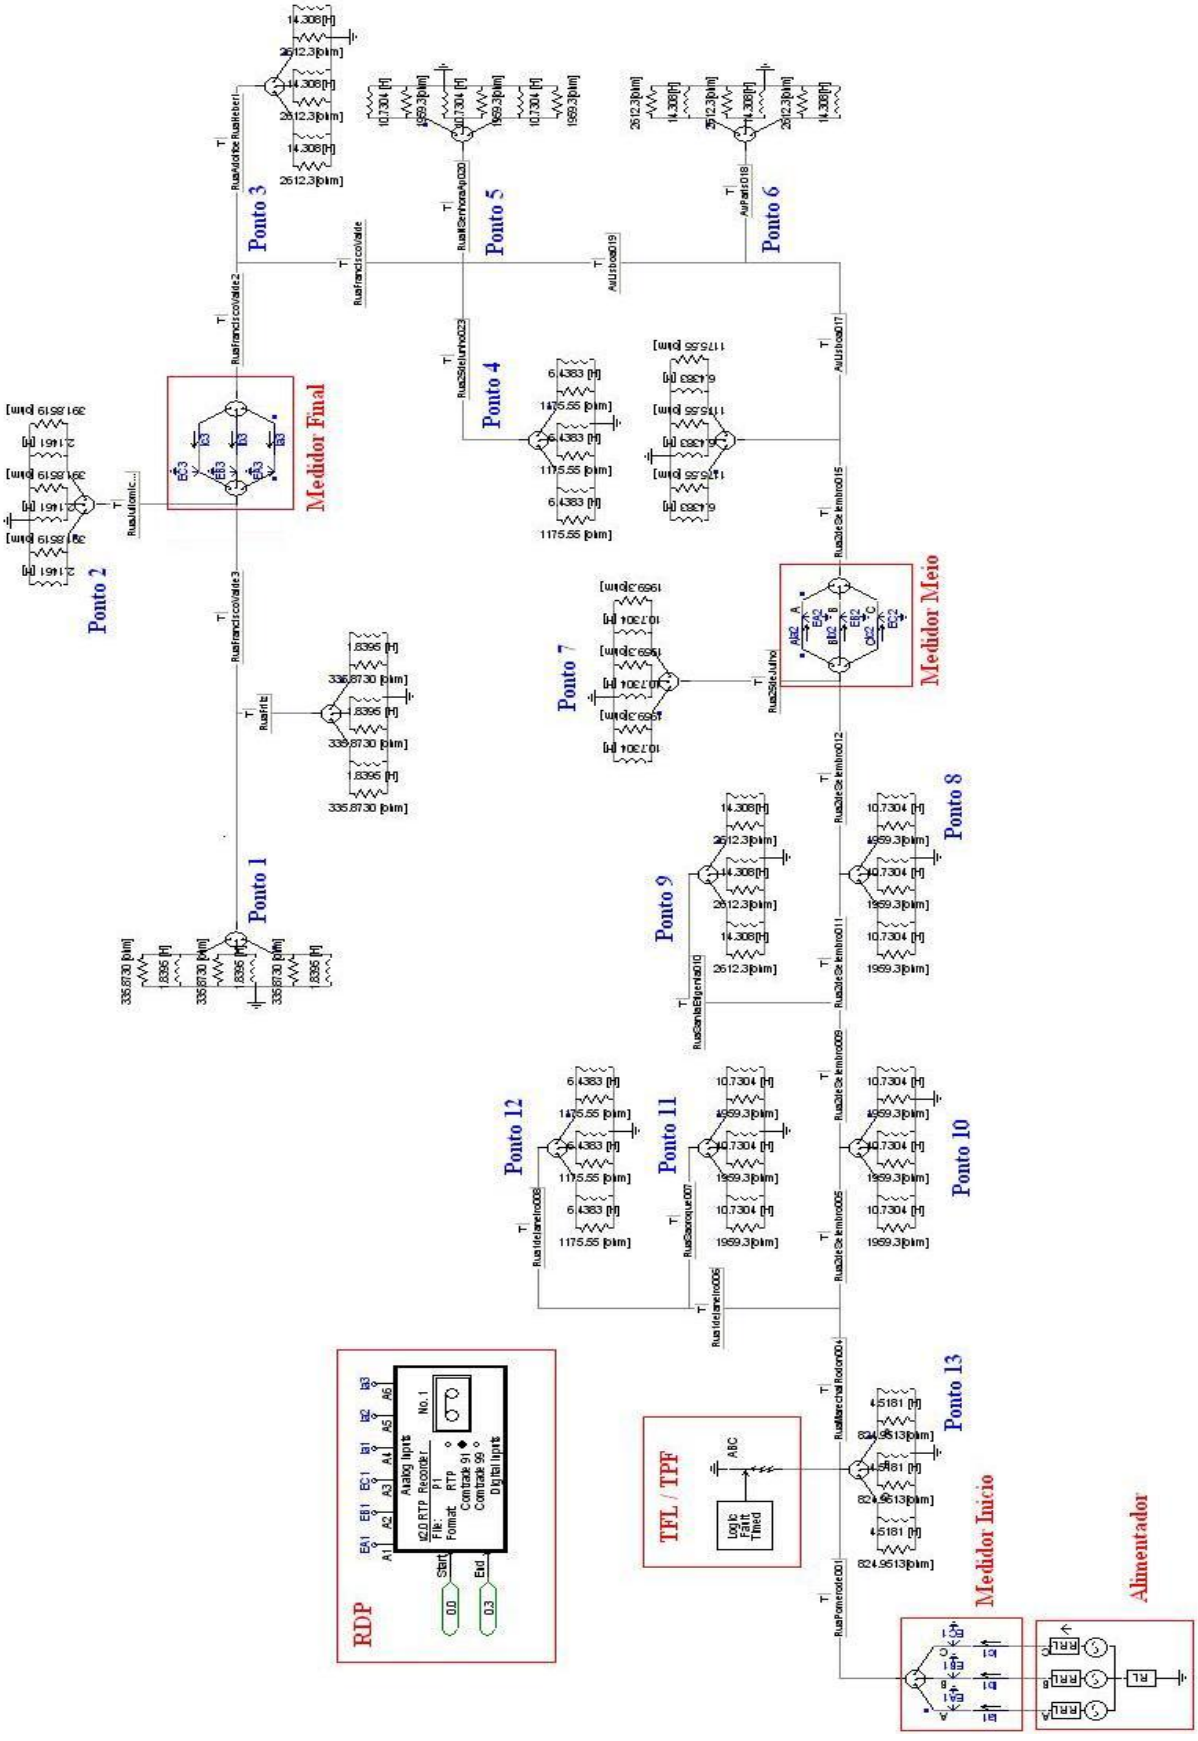

Figura 6 - Diagrama unifilar da rede de distribuição no PSCAD.

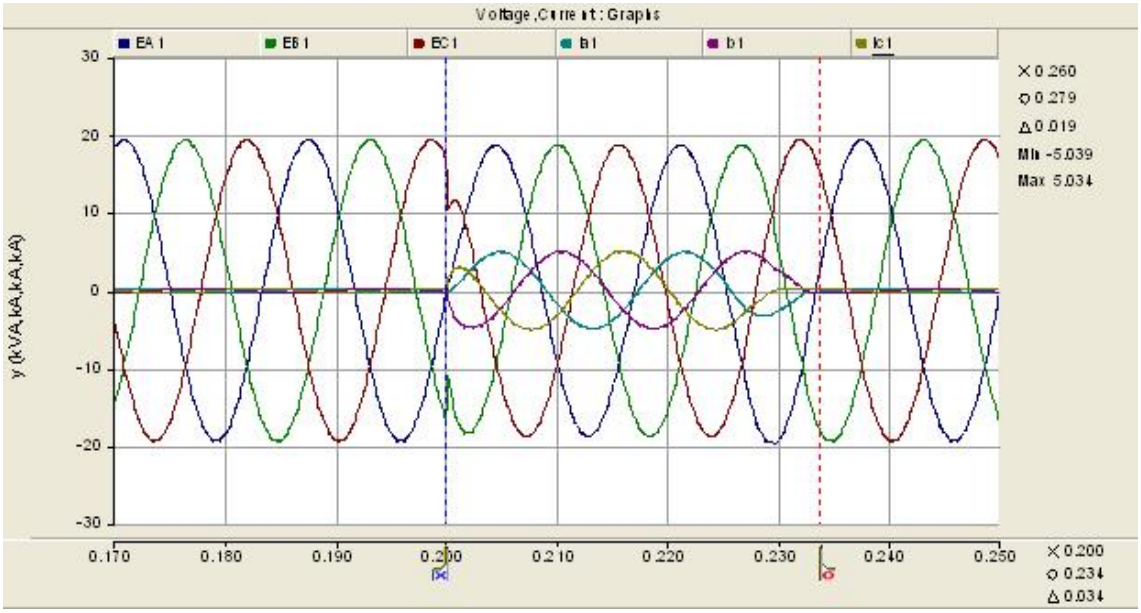

Figura 7 - Resultante da falta de A, B e C para o terra.

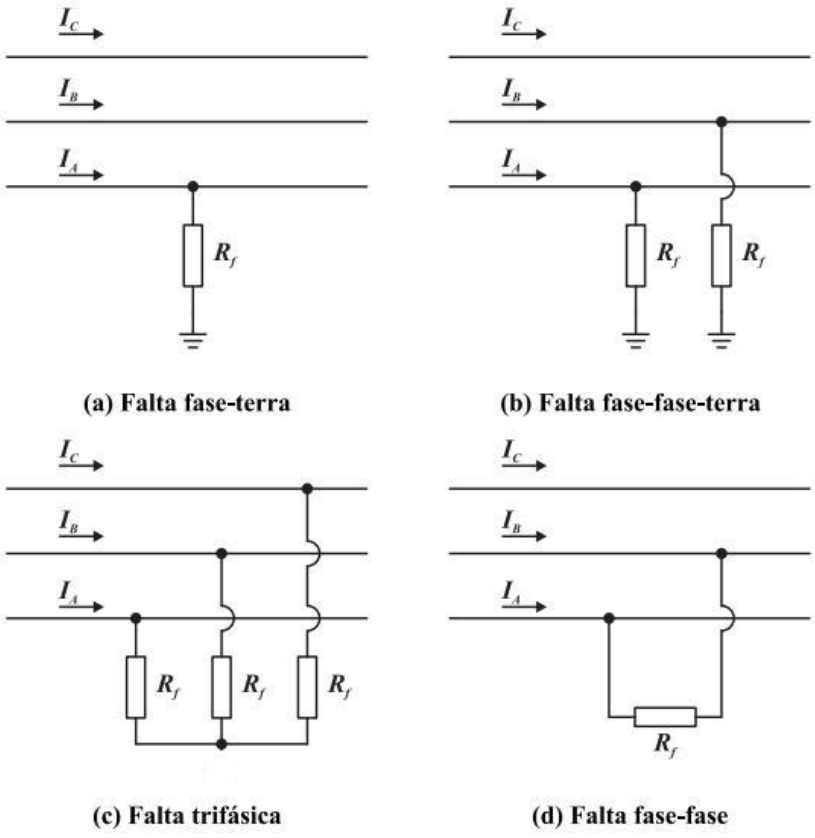

Figura 8 - Tipos de falta.
[38]

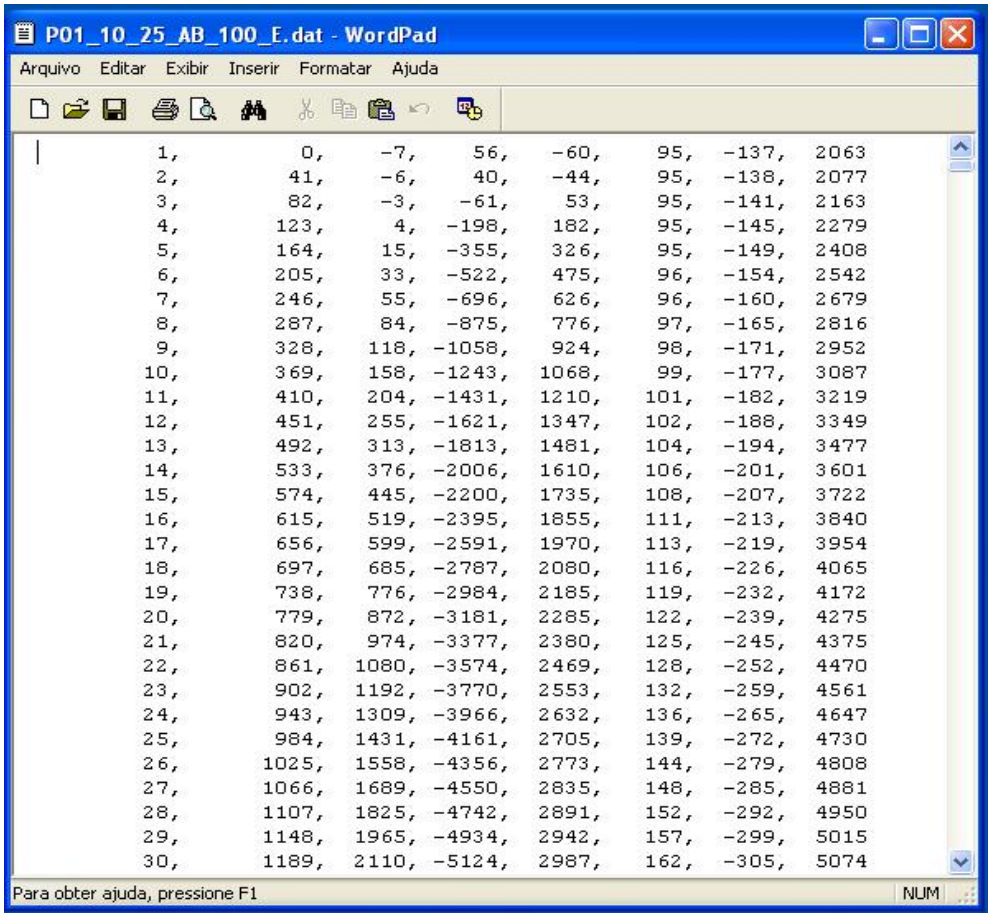

Figura 9 - Arquivo de dados.

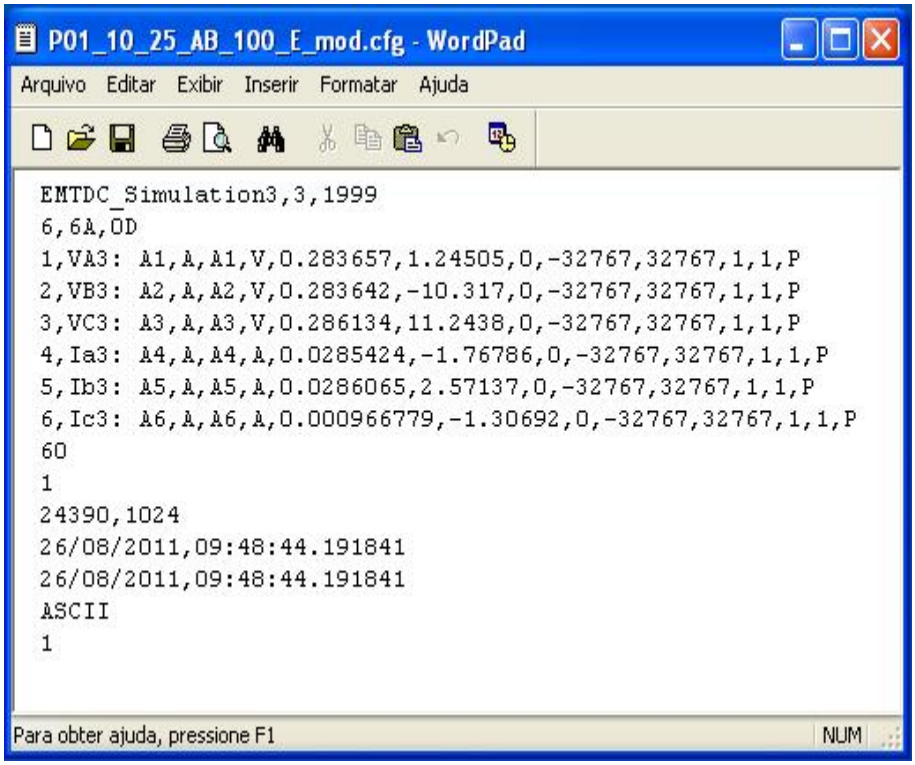

Figura 10 - Arquivo de configuração.

4 METODOLOGIA DE DETECÇÃO DA FALTA

A etapa de detecção da falta baseia-se no ajuste da fase e da frequência de um sinal de saída de maneira que os erros entre a fase e a frequência do sinal de saída e o sinal de entrada sejam minimizados. Por isso, este trabalho implementa um sistema de sincronismo, descrito abaixo em linha gerais.

4.1 Sistema de Sincronismo

A estimação da frequência, do ângulo de fase e da amplitude da tensão e/ou corrente da rede elétrica é de grande interesse para muitos equipamentos de condicionamento de energia, tais como filtros ativos de potência, compensadores estáticos de reativos, fontes ininterruptas de energia, entre outros, que necessitam ser sincronizados com a componente fundamental da rede [32].

Devido às características dinâmicas do sistema elétrico de potência, o método de sincronismo deve ser capaz de rejeitar diversas pertubações inerentes ao sistema, tais como, distorções harmônicas ou transitórios, sobre ou sub-tensão, desequilíbrio, variações de frequência, ruídos de medidas, entre outros efeitos [32].

Este trabalho utiliza um circuito de sincronismo monofásico que se caracteriza por fornecer informações do ângulo de sincronismo, da frequência e também da amplitude da componente fundamental. Este gera um sinal em fase com a componente fundamental da tensão e/ou corrente da rede, ou seja, a projeção do sinal de entrada sobre um subespaço complexo gerado a partir da estimativa da componente desejada que é a frequência fundamental f, no próprio sinal de entrada, essa projeção foi utilizada para corrigir a estimativa da componente estimada [32].

Uma técnica em malha fechada que responde às variações de fase e de frequência dos sinais de referências amplamente utilizada, para a extração da informação do ângulo de fase, é capaz de gerar um sinal sincronizado com um dado sinal de tensão e/ou corrente é o PLL [25]. O mesmo apresenta um alto grau de imunidade a pertubações de forma de onda, assimétricas, desvios de frequência fundamental, apresenta uma resposta dinâmica

satisfatória e uma ótima precisão em regime permanente [32].

4.2 **Algoritmo de Detecção das Faltas**

Para localizar o instante de ocorrência da falta, que é denominado de *"instante de incidência da falta"*, é necessário extrair do sinal de tensão e corrente, provenientes da simulação do sistema piloto no programa de transitório eletromagnéticos, o instante em que a falta ocorreu. Para isso foi utilizado o algoritmo de detecção [32] implementado em C++ [48]. Para entender como funciona o algoritmo de detecção, a análise do seu funcionamento foi realizada em módulos.

A Figura 11 apresenta o diagrama de blocos com os módulos que compõem o algoritmo de detecção da falta e, em seguida, cada um desses módulos serão descritos.

Figura 11 - Diagrama de blocos dos módulos do algoritmo de detecção do ponto de incidência.

[32]

4.2.1 Carregar Arquivo

Nessa simples etapa, o arquivo de saída padrão do PSCAD (Cfg e Dat) é carregado em uma série de vetores, cada qual correspondendo a cada sinal amostrado (tensão e corrente de cada uma das três fases do sistema) [32].

4.2.2 Análise Fundamental

O PLL foi empregado para estimar a frequência, a amplitude e a fase dos 6 sinais (3 de tensão e 3 de corrente) dos registros das faltas. O algoritmo aqui utilizado é baseado no PLL proposto em [32]. A ideia principal é a determinação da informação da fase usando a projeção do sinal de entrada sobre um subespaço complexo $e^{-j2\pi ft}$ gerado a partir da estimativa da frequência fundamental *f*, no próprio sinal de entrada [32]. Ou

seja, alterando a frequência de um oscilador controlado, até que o sinal produzido por este esteja sincronizado, com a mesma fase e a mesma frequência do sinal de referência.

A Figura 12 representa o diagrama de blocos do PLL monofásico proposto neste trabalho.

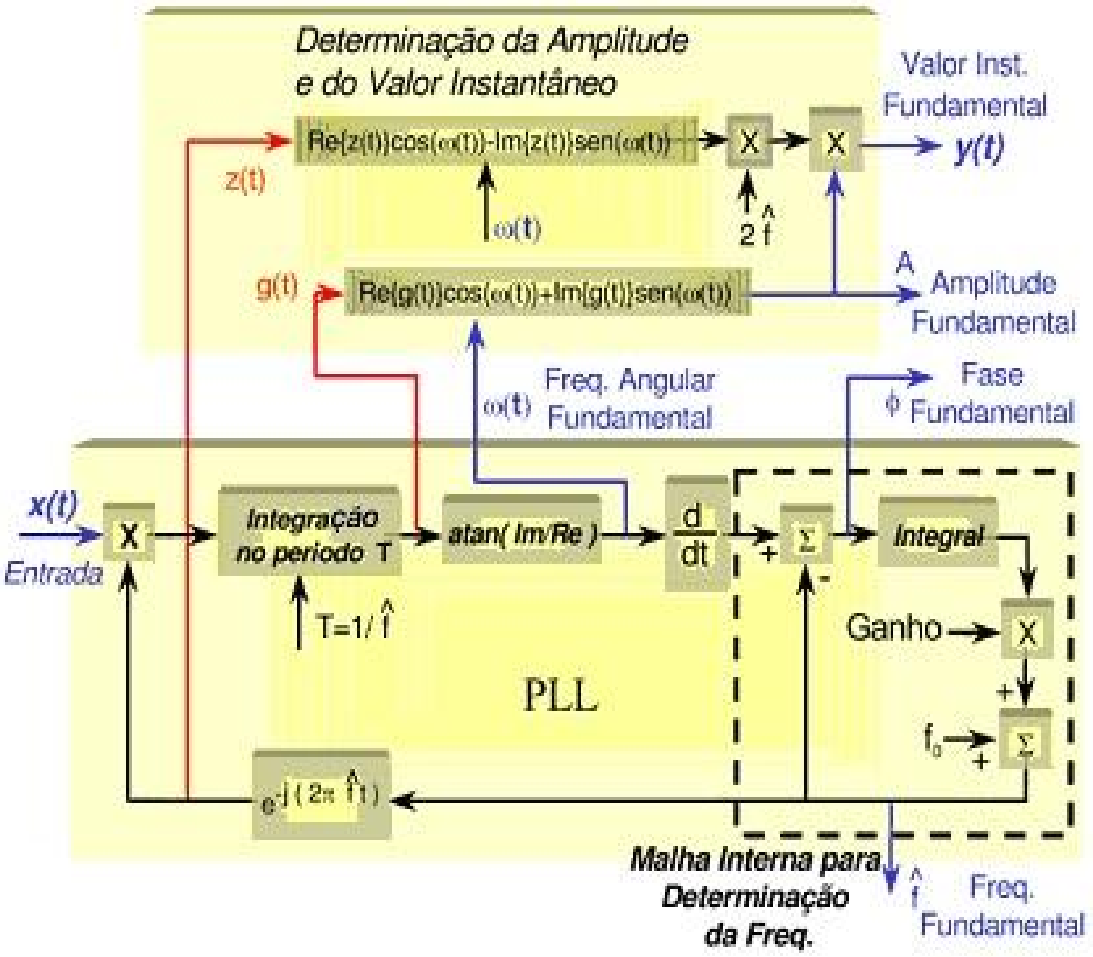

Figura 12 - Diagrama de blocos do PLL.
[32]

4.2.3 Comparador

Suponha que y seja uma função de x, ou seja, $y=f(x)$. Se x variar de um valor x_0 até um valor x_1, representaremos esta variação de x, que também é chamada de incremento de x, por $\Delta_x=x_1-x_0$, e a variação de y é dada por $\Delta_y=x_1-x_0$, o que é ilustrado na Figura 13.

O quociente das diferenças, dado pela equação (1), é dito taxa de variação média de y em relação a x, no intervalo $[x_0,x_1]$.

$$\frac{\Delta_y}{\Delta_x} = \frac{f(x_1) - f(x_0)}{x_1 - x_0} \tag{1}$$

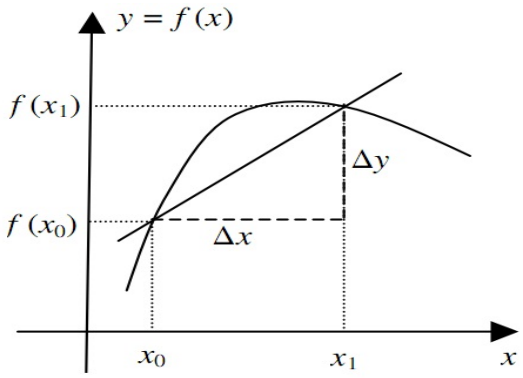

Figura 13 - Taxa de variação média.
[47]

Neste trabalho foi configurado um fator de 0.1% para a taxa de variação média que é denominada de *"afastamento máximo"* no qual a frequência fundamental se afasta do padrão de 60 Hz. Quando detectada uma ultrapassagem deste fator de afastamento do máximo, retrocede em um número de amostras igual a um ciclo da fundamental para que o registro da falta possua informações do pré-falta, falta e pós-falta conforme demostrando na Figura 14 e efetua-se o registro das próximas 1024 amostras a partir desse ponto, armazenando essas amostras em uma variável para o módulo seguinte utilizar.

Com o intuito de avaliar o histórico das faltas, o algoritmo antes de retroceder um número de amostras igual a um ciclo da fundamental conforme já citado acima, o mesmo desloca o instante de incidência detectado em mais: $\frac{1}{2}$ ciclo, $\frac{3}{4}$ de ciclo, 1 ciclo e 1 ciclo $\frac{1}{2}$ conforme descrito na Figura 15.

Separadamente cada um desses registros são guardados e assim para cada tipo de falta ocorrida são gerados 5 registros distintos.

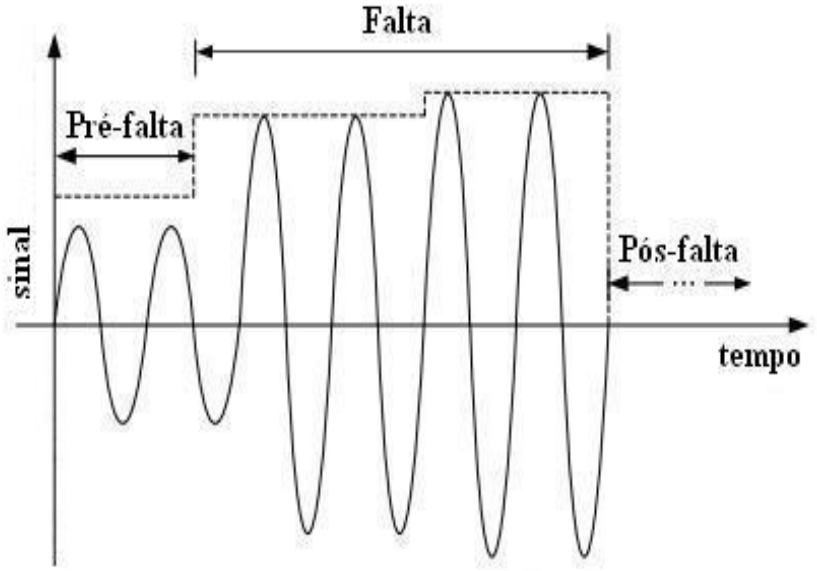

Figura 14 - Exemplo de registro oscilográfico.

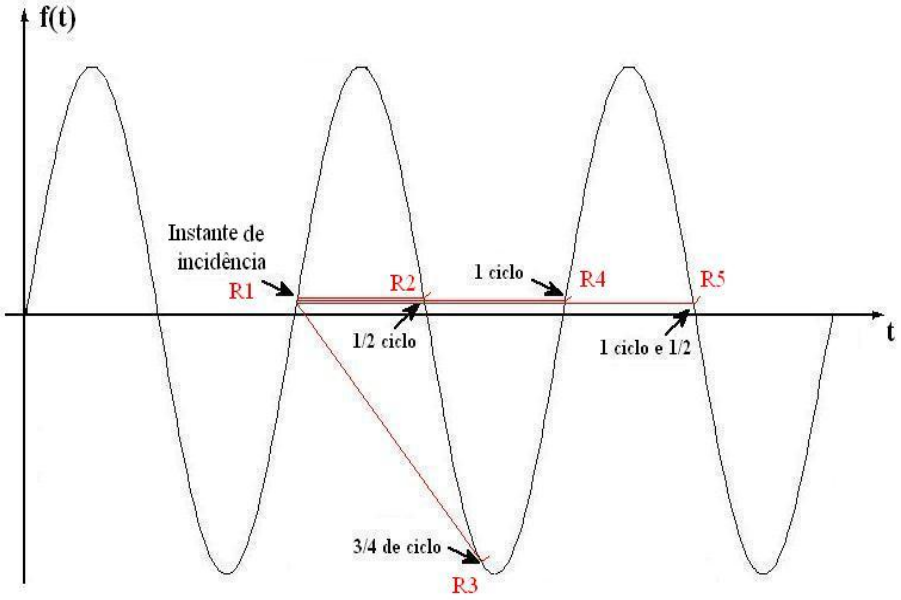

Figura 15 - Gráfico do deslocamento do instante de incidência.

4.2.4 Guardar Arquivo

Ao final do processo de detecção, extrai-se no instante de incidência da falta os valores estimados da frequência, da amplitude e da fase dos 6 sinais (3 de tensão e 3 de corrente) dos registros das faltas conforme ilustrado na Figura 16 e guarda-os em um arquivo padrão.

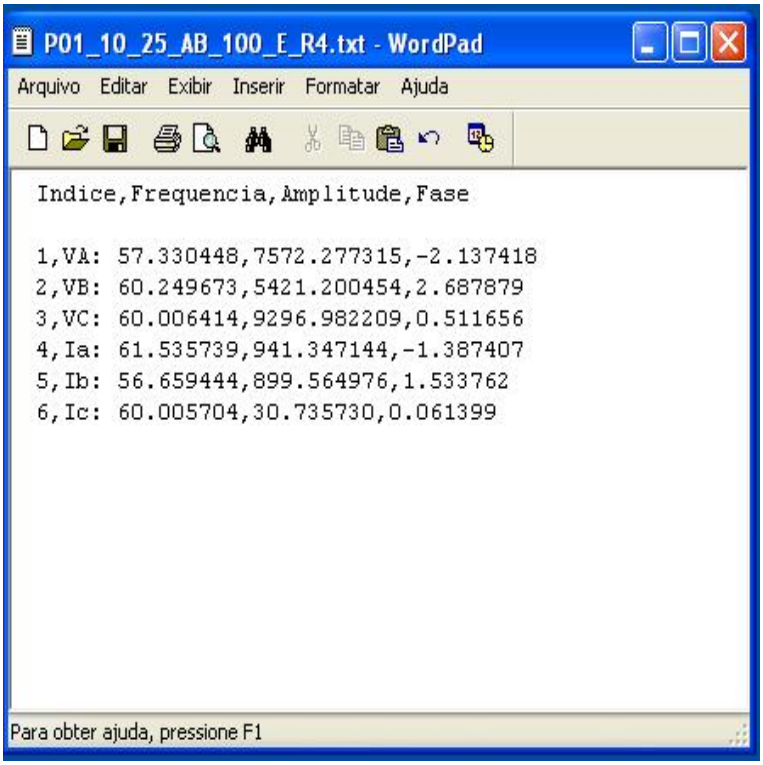

Figura 16 - Arquivo de saída que contém os valores estimados dos 6 sinais.

4.3 Análise Exploratória dos Dados Extraídos pelo PLL

O histograma é uma ferramenta estatística utilizada para representar graficamente uma grande quantidade de dados numéricos e através da sua análise é possível interpretar padrões de forma mais simples, se comparada à análise de uma tabela. Assim, utilizou-se histogramas como ferramentas para a interpretação do comportamento dos parâmetros das fundamentais extraídos dos sinais capturados nos diferentes pontos de coleta.

Ao observar detalhadamente duas ou mais curvas de distribuição de frequência de uma série de dados, constatou-se que é muito difícil existirem duas curvas exatamente iguais. As diferenças entre essas diversas curvas decorrem da dispersão, a qual de alguma forma governa o padrão estatístico da distribuição de frequência das ocorrências.

A Figura 17 mostra o histograma obtido para o parâmetro da amplitude da fundamental extraído dos registros quando todas as fases estão envolvidas nas faltas. O histograma tende a seguir uma assimetria com apenas um pico e a taxa de ocorrência

para as fases de corrente e tensão decrescem bruscamente em um dos lados e de forma gradual no outro, produzindo uma curva mais longa em um dos lados. Da análise do histograma, verifica-se que este alongamento da curva possui uma dispersão nas baixas frequências, a provável causa é a influência de um distúrbio na magnitude da amplitude.

A Figura 18 mostra o histograma obtido para o parâmetro da fase extraído da fundamental quando todas as fases estão envolvidas nas faltas. Neste caso, o histograma tende a seguir uma assimetria com dois picos devido ao semiciclo positivo e negativo da forma de onda alternada, tanto para a fase de tensão quanto para a fase de corrente. Da análise do histograma, verifica-se que há uma dispersão nas bases das curvas, a provável causa é que, após a incidência da falta, o ângulo de fase entre os fasores são alterados nas baixas ocorrências.

A Figura 19 mostra o histograma obtido para o parâmetro da frequência extraído dos registros da fundamental quando todas as fases estão envolvidas nas faltas. O histograma tende a seguir uma pequena simetria, em que a taxa de ocorrência é mais alta próximo de 60 Hz para a tensão e 63 Hz para a corrente e decresce gradualmente para as bases das curvas. Da análise do histograma, verifica-se que a distribuição da frequência apresenta um ligeiro enviesamento para ambos os lados. A provável causa é que, após a incidência da falta, a frequência teve uma pequena variação.

A Figura 20 mostra o histograma obtido para o parâmetro da amplitude extraído da fundamental quando a fase B está envolvida nas faltas e a Figura 21 mostra o histograma obtido para o parâmetro da amplitude extraído da fundamental quando a fase B não está envolvida nas faltas. Na comparação entre estes dois histogramas, verifica-se que há uma diferença significativa entre os alongamentos das curvas.

A Figura 22 mostra o histograma obtido para o parâmetro da fase extraído da fundamental quando a fase B está envolvida nas faltas e a Figura 23 mostra o histograma obtido para o parâmetro da fase extraído da fundamental quando a fase B não está envolvida nas faltas. Na comparação entre estes dois histogramas, verifica-se que há uma diferença significativa entre as amplitudes dos picos do semiciclo positivo.

A Figura 24 mostra o histograma obtido para o parâmetro da frequência extraído da fundamental quando a fase B está envolvida nas faltas e a Figura 25 mostra o histograma obtido para o parâmetro da frequência extraído da fundamental quando a fase B não está envolvida nas faltas. Na comparação entre estes dois histogramas, verifica-se que há uma diferença significativa entre as variações da frequências.

A Tabela 5 e a Tabela 6 mostram os valores das médias e das variâncias dos parâmetros extraídos dos registros, quanto maior a variância, maior a dispersão dos dados.

As áreas das dispersões são os locais mais apropriados para realizar as classificações das faltas através das redes neurais, porque nelas, cada parâmetro tem sua própria particularidade.

Já nas áreas onde encontram-se os picos, os parâmetros possuem valores muitos semelhantes uns dos outros dificultando as redes neurais em classificá-los.

Tabela 5 - Quando a fase B está envolvida nas faltas.

Parâmetros	**Média**	**Variância**
VA Amp	9.0203×10^3	9.5584×10^5
VB Amp	8.4854×10^3	1.2471×10^6
VC Amp	9.0776×10^3	9.6984×10^5
Ia Amp	238.2553	1.1013×10^5
Ib Amp	347.8400	1.3761×10^5
Ic Amp	224.0076	1.0121×10^5
VA Fase	-0.4269	1.3174
VB Fase	2.2060	0.9085
VC Fase	-0.3141	1.2316
Ia Fase	-0.8266	1.3180
Ib Fase	2.1405	0.1680
Ic Fase	-0.6474	1.5598
VA Freq	59.7634	0.3663
VB Freq	59.4389	0.3687
VC Freq	59.7889	0.3095
Ia Freq	60.1701	0.8609
Ib Freq	59.8624	2.0159
Ic Freq	60.0709	0.8053

Tabela 6 - Quando a fase B não está envolvida nas faltas.

Parâmetros	Média	Variância
VA Amp	8.9812×10^3	7.6813×10^5
VB Amp	9.4985×10^3	2.1381×10^5
VC Amp	8.9593×10^3	7.3366×10^5
Ia Amp	234.9863	7.0644×10^4
Ib Amp	94.1438	8.5302×10^3
Ic Amp	221.3598	6.3593×10^4
VA Fase	-0.6799	1.2912
VB Fase	2.2389	1.7033
VC Fase	-0.4525	1.3527
Ia Fase	-0.9488	1.6309
Ib Fase	2.0128	0.7701
Ic Fase	-0.7139	1.7247
VA Freq	59.6738	0.3043
VB Freq	60.1141	0.0454
VC Freq	59.7070	0.2967
Ia Freq	59.9656	1.2484
Ib Freq	60.1410	0.1771
Ic Freq	60.3145	1.5108

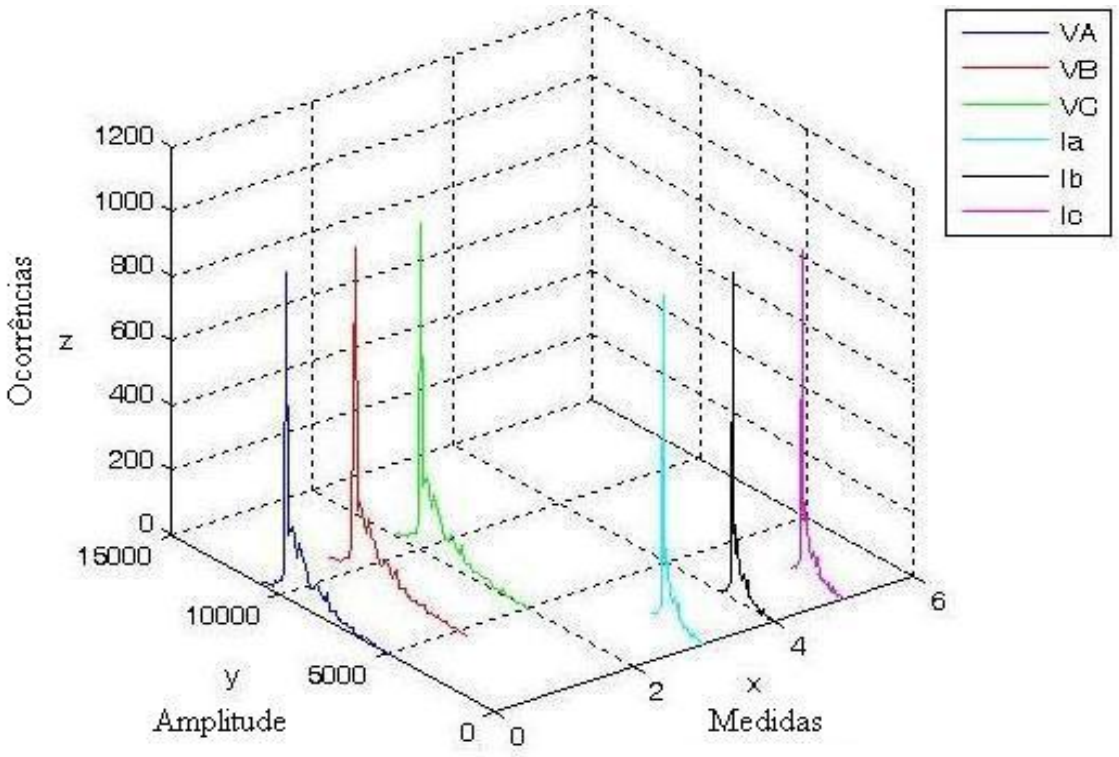

Figura 17 - Histograma da amplitude extraída da fundamental quando todas as fases estão envolvidas nas faltas.

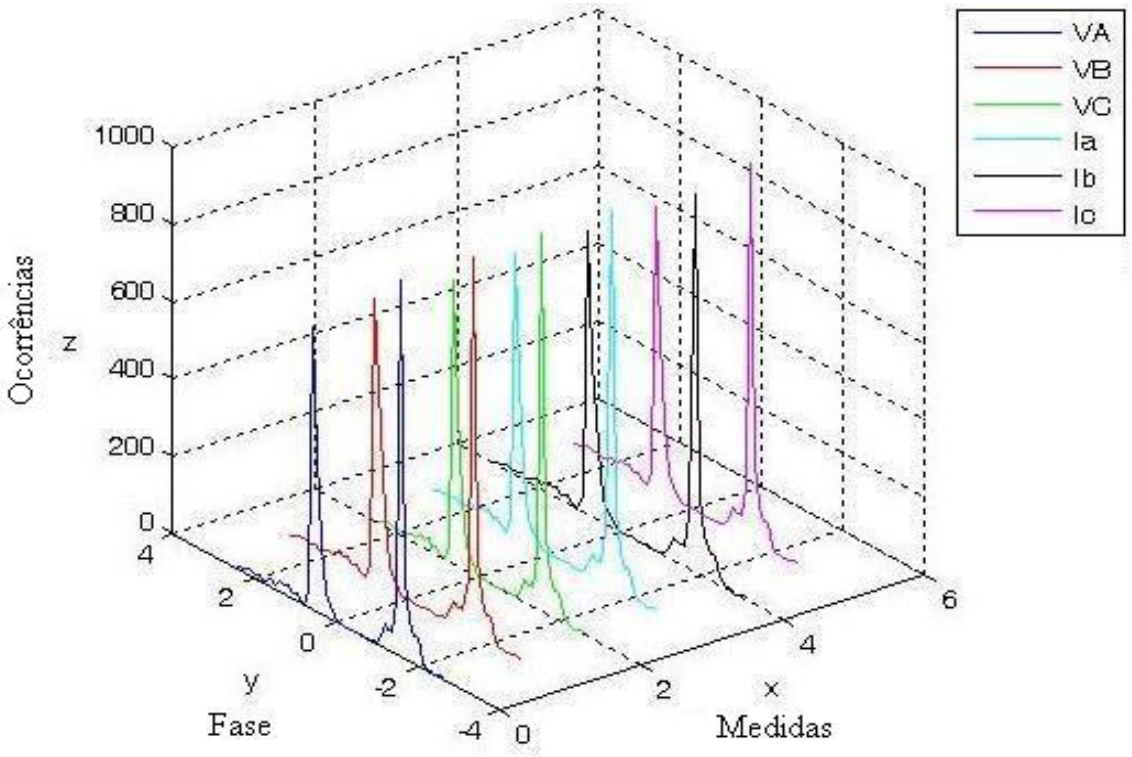

Figura 18 - Histograma da fase extraída da fundamental quando todas as fases estão envolvidas nas faltas.

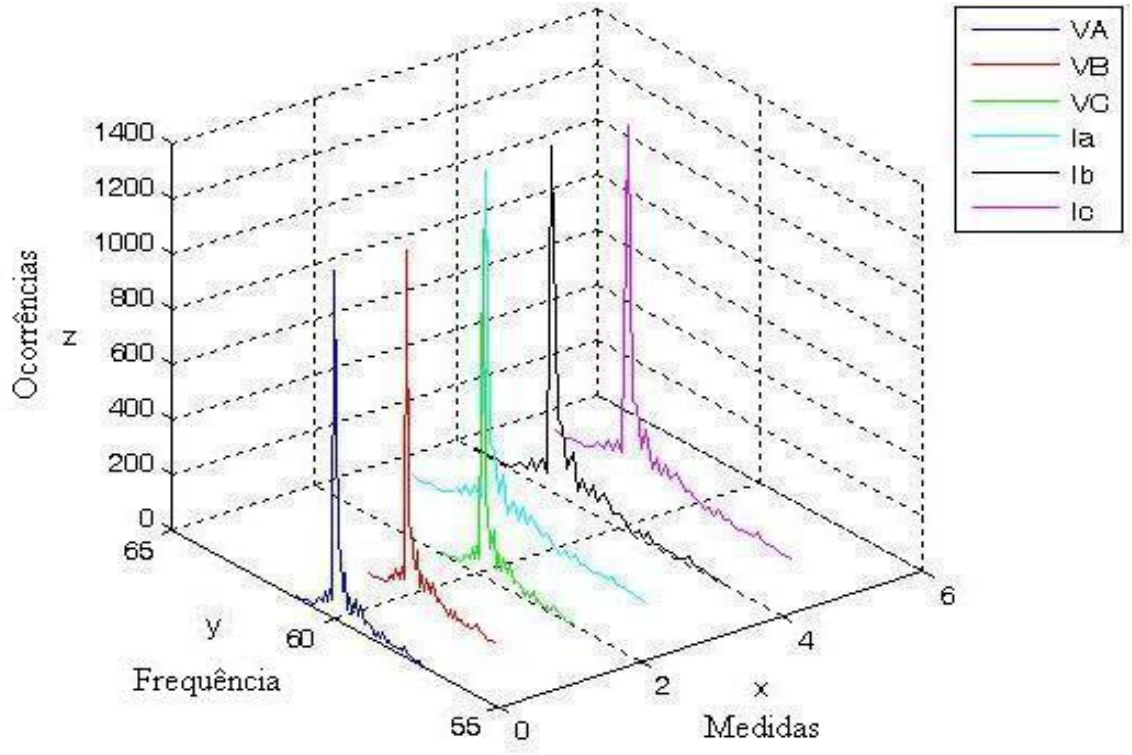

Figura 19 - Histograma da frequência extraída da fundamental quando todas as fases estão envolvidas nas faltas.

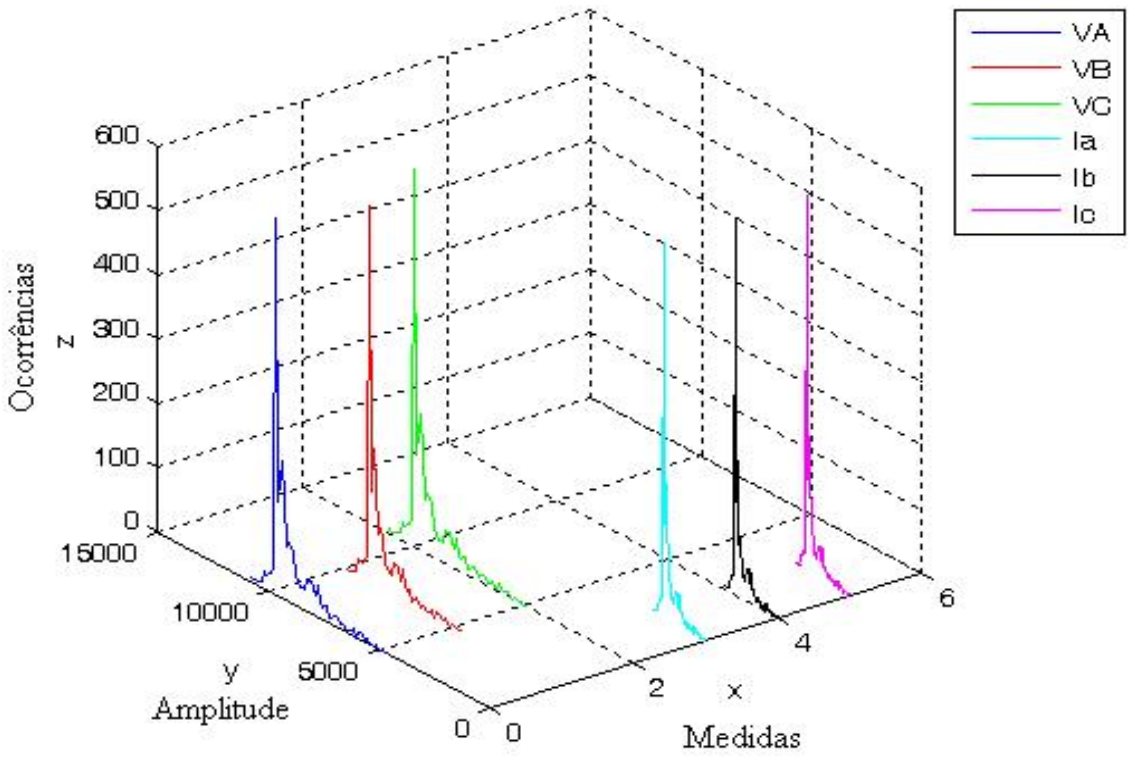

Figura 20 - Histograma da Amplitude extraída da fundamental quando a fase B está envolvida nas faltas.

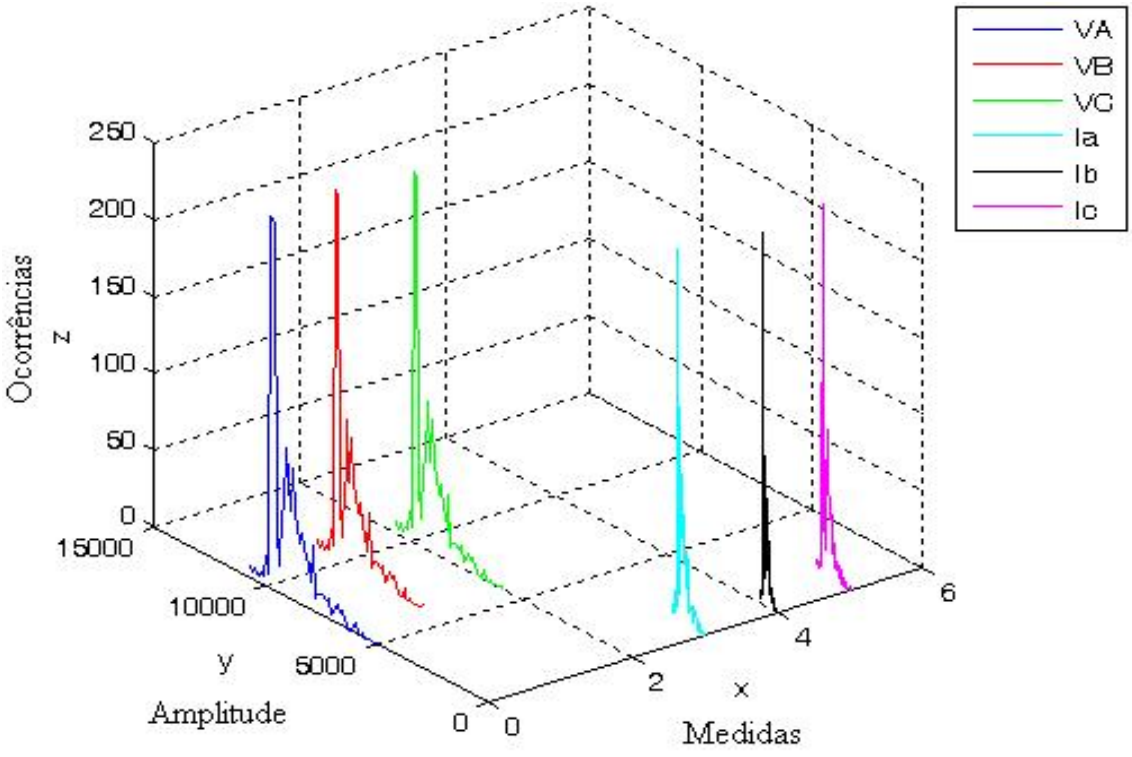

Figura 21 - Histograma da Amplitude extraída da fundamental quando a fase B não está envolvida nas faltas.

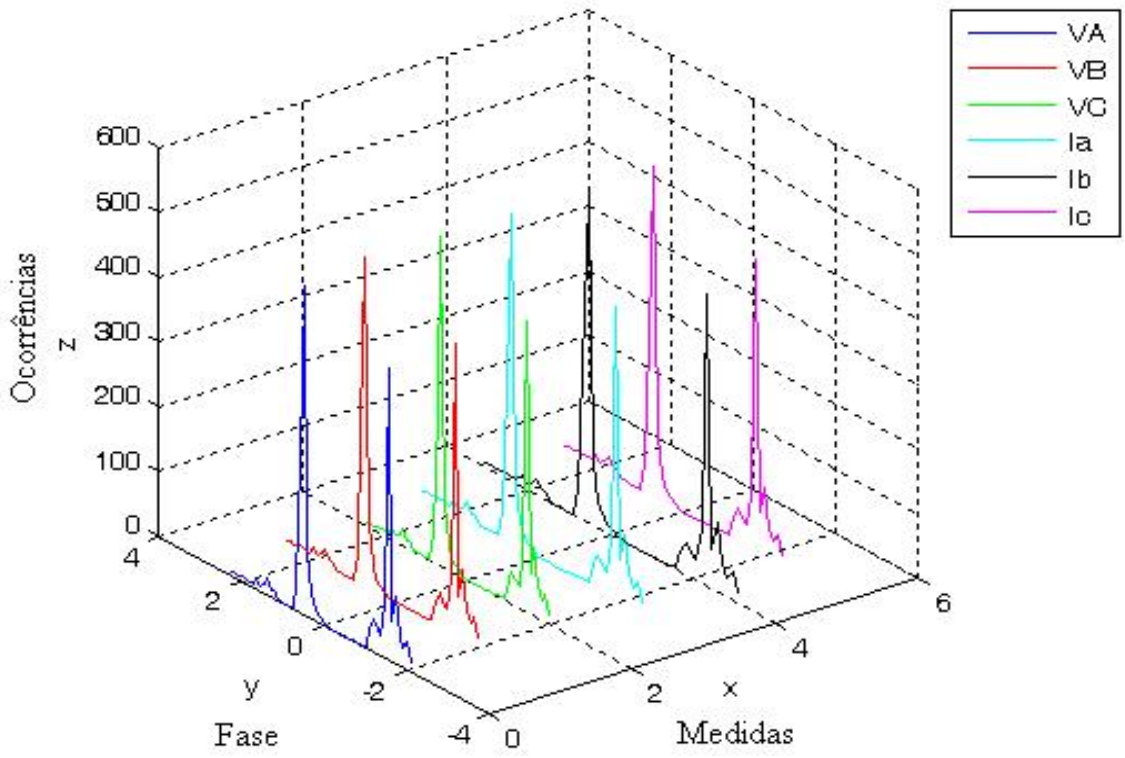

Figura 22 - Histograma da Fase extraída da fundamental quando a fase B está envolvida nas faltas.

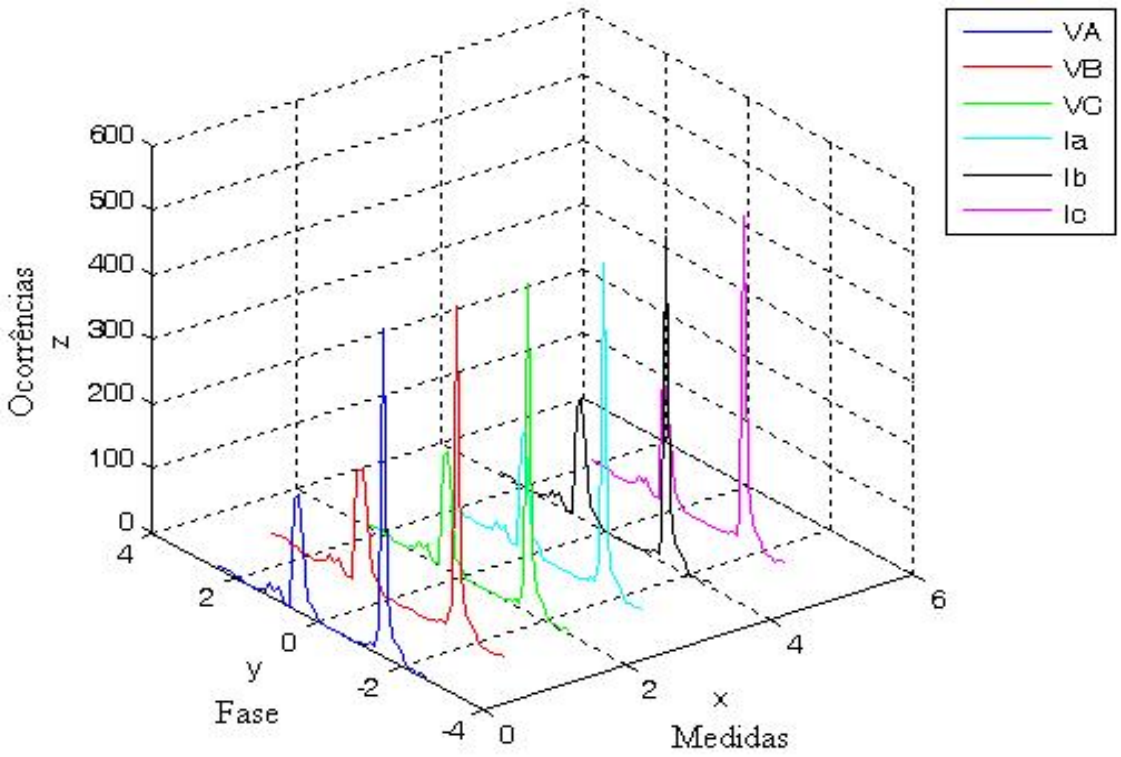

Figura 23 - Histograma da Fase extraída da fundamental quando a fase B não está envolvida nas faltas.

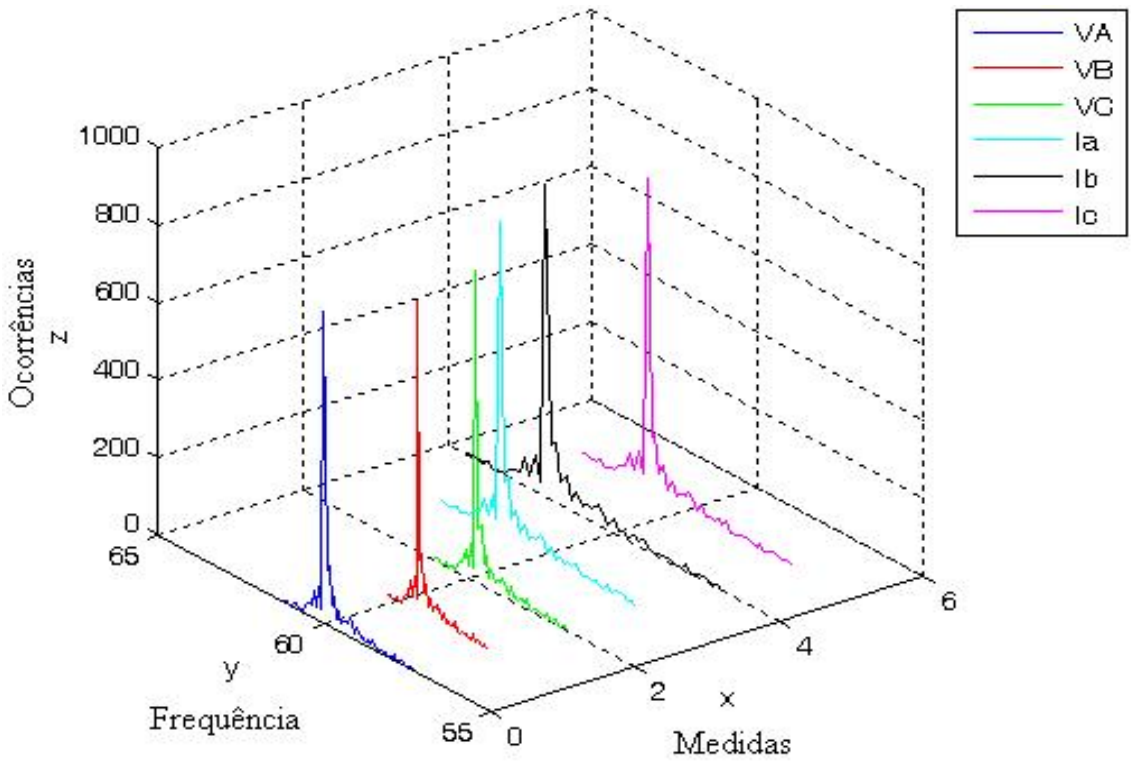

Figura 24 - Histograma da Frequência extraída da fundamental quando a fase B está envolvida nas faltas.

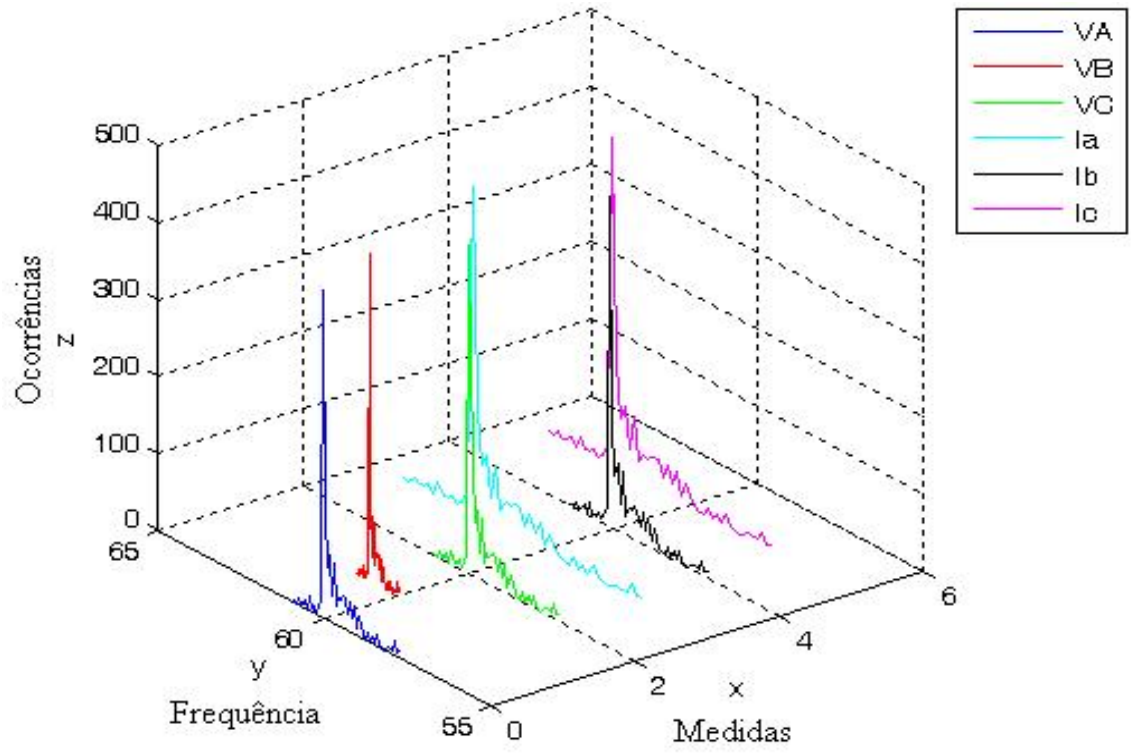

Figura 25 - Histograma da Frequência extraída da fundamental quando a fase B não está envolvida nas faltas.

5 INTRODUÇÃO ÀS REDES NEURAIS ARTIFICIAIS

Um estudo sobre redes neurais artificiais, também conhecidas como métodos conexionistas, não pode deixar de citar três, das mais importantes publicações iniciais, desenvolvidas por McCulloch e Pitts em 1943, Hebb em 1949 e Rosemblatt 1958. Estas publicações introduzem o primeiro modelo matemático para redes neurais simulando "máquinas", o modelo básico de rede de auto-organização, e o modelo Perceptron de aprendizado supervisionado, respectivamente [17].

Uma rede neural artificial tem o propósito de simular de maneira simplificada alguns componentes do sistema nervoso humano através de programas de computador *("software")*. Uma RNA é composta por várias interconexões de elementos simples de processamento, denominados neurônios, através de um grande número de conexões, denominadas sinapses. As sinapses são geralmente, conectadas por canais de comunicação que estão associados a pesos determinados e ela proporciona uma fabulosa capacidade de processamento e armazenamento de informações [41, 52].

O comportamento das RNAs é baseado no funcionamento do cérebro humano, cujo sistema nervoso detecta estímulos (informações de entrada) e os envia para o cérebro, através dos neurônios. Nos neurônios, a informação (recebida através dos dendritos) é processada e uma resposta é fornecida através dos axônios [17]. Sua modelagem é inspirada na estrutura do neurônio biológico que pode ser visto de forma ilustrativa na Figura 26. A seguir serão descritas as partes constituintes do neurônio biológico:

Os **dendritos** são os dispositivos que formam uma rede para recebimento de informações exteriores ao neurônio, ou seja, vindo de outros neurônios através de conexões sinápticas;

Os **axônios** são os dispositivos de saída, que transportam os sinais nervosos do corpo celular para o próximo neurônio;

As **conexões sinápticas** são as interjeições entre as saídas de um neurônio e as entradas de outros, onde ocorre comunicação do sinal neural através de processos eletroquímicos específicos;

O **corpo celular** é responsável pelo processamento dos sinais de entrada em um neurônio. Quando os valores das entradas atingem um determinado valor, o neurônio emite um impulso elétrico que flui do corpo para o axônio.

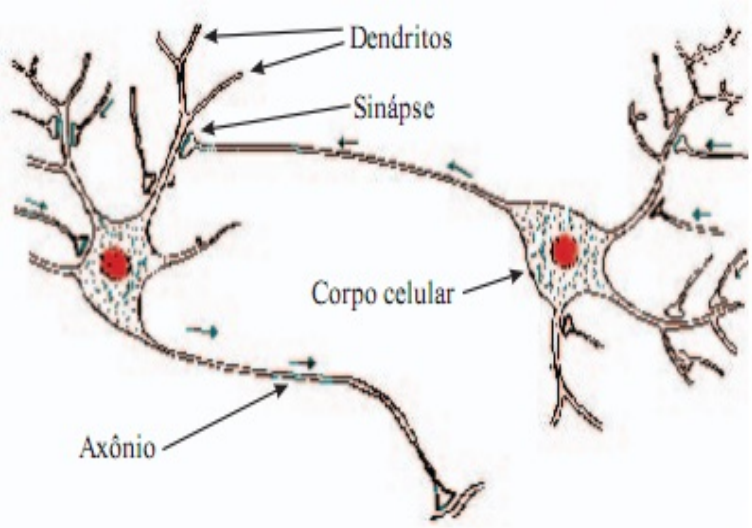

Figura 26 - Neurônio biológico.
[38]

5.1 Características da RNAs

A grande motivação para a utilização de redes neurais artificiais para solucionar problemas complexos provém de algumas propriedades e capacidades úteis das RNAs, descritas a seguir [17, 38].

5.1.1 Aprendizagem

É a capacidade de uma RNA em aprender novas tarefas através de um processo interativo de adaptação dos pesos sinápticos em resposta a estímulos produzidos pelo ambiente [12, 17];

5.1.2 Generalização

É a capacidade de uma RNA em se adaptar a novas situações, apresentando uma saída adequada para uma entrada não presente no processo de aprendizagem [12, 17];

5.1.3 Paralelismo

Cada sinapse na rede neural pode realizar isoladamente e paralelamente o processamento necessário, enviando seu resultado para outras unidades através das conexões entre elas [12, 17];

5.1.4 Não-Linearidade

Uma RNA é não-linear se for constituída de neurônios artificiais também não-lineares. Essa é uma importante característica, pois, apesar de nossa tendência a linearizar tudo, a maioria dos sistemas físicos é não-linear [12, 17];

5.1.5 Adaptação

É a capacidade que uma rede neural possui em adaptar seus pesos sinápticos perante modificações do processo, gerando valores de saída consistentes com os esperados. A capacidade de adaptação é vital para a aplicabilidade do modelo em um ambiente do mundo real [12, 17];

5.1.6 Resposta a Evidências

Em sua utilização como classificadora de padrões, uma RNA pode fornecer, em sua saída, não somente a informação relativa a qual conjunto pertence a entrada, mas também uma informação sobre a confiança do resultado. Desta forma, pode-se utilizar essa informação para rejeitar padrões ambíguos [12, 17];

5.1.7 Tolerância a Falhas

Como o conhecimento está distribuído pelas diferentes sinapses da RNA, uma parte das conexões pode torna-se inoperante e ainda assim não causar perda significativa no desempenho do sistema [12, 17];

5.1.8 Robustez

É a capacidade de uma RNA em permanecer estável, havendo uma queda de desempenho gradual na eventualidade de mal funcionamento ou até mesmo inutilização de parte da rede [12, 17].

Estas características dotam as redes neurais artificiais com a capacidade de resolver problemas de classificação de padrões, na qual deseja-se classificar entre várias classes pré-definidas um determinado padrão de entrada para o qual não se conhece o modelo estatístico. [12, 17].

5.2 **Neurônio Artificial**

O modelo geral de um neurônio pode ser visto na Figura 27. Esse modelo utiliza uma função de ativação $\varphi(.)$ que pode ser definida de várias formas, e em *bias*, representado por b, que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação. O princípio de funcionamento e operação pode ser resumido da seguinte forma: i) Os sinais são apresentados nas entrada x_k, ii) cada sinal é multiplicado por um peso w_k, que indica a sua influência na saída do neurônio, iii) é feita a soma ponderada dos sinais, produzindo um nível de atividade v_k, iv) se este nível de atividade exceder um certo limiar, a unidade ativa sua saída y_k. Assim como os neurônios biológicos, os neurônios artificiais, principais componentes de uma rede neural artificial, basicamente trabalham com entrada e saída de informações.

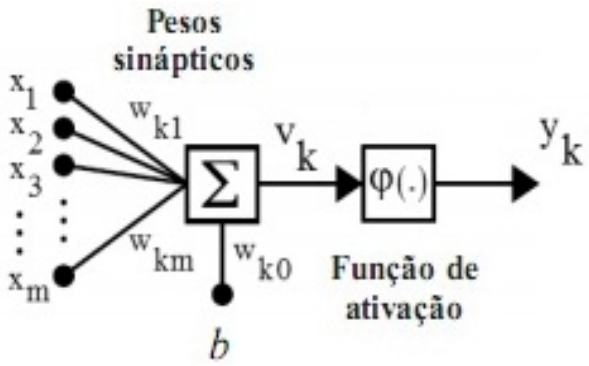

Figura 27 - Modelo matemático do neurônio.
[17, 18]

5.3 **Tipos de Função de Ativação**

A função de ativação é uma função de transferência regida por uma operação matemática, e são utilizadas para generalizar a saída da rede neural. Na sequência são descritas algumas função de ativações clássicas.

5.3.1 Função Linear

A função linear é definida pela equação (2), onde a e um número real qualquer e b é igual a 0, porque a reta nesse caso passa pela origem. A Figura 28 ilustra a função linear.

$$f(n) = an + b \tag{2}$$

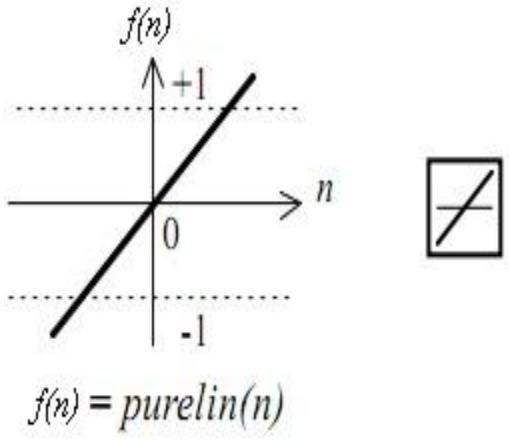

Figura 28 - Função de transferência Linear.
[18]

5.3.2 Função Degrau

Nos neurônios construídos com essa função, a saída será igual a 0, caso o valor de ativação seja negativo e 1 nos casos em que o valor de ativação seja positivo. A Figura 29 ilustra a função degrau unitário.

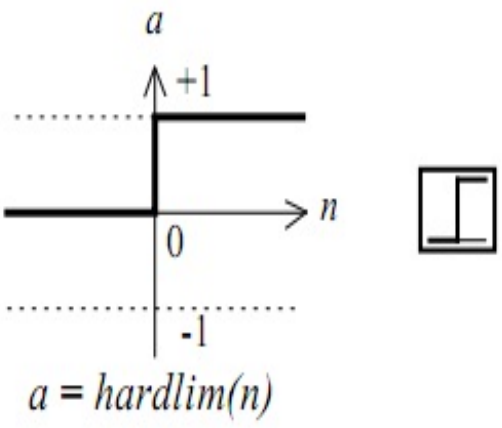

Figura 29 - Função de transferência Degrau.
[18]

5.3.3 Função Logística

Esta função, ou contrário da função linear, pode assumir qualquer valores entre 0 e 1. A apresentação mais utilizada para esta função é a função logística, definida pela equação (3), onde a é o parâmetro de inclinação da função sigmóide e v é o valor de ativação do neurônio. A Figura 30 ilustra a função logística.

$$f(n) = \frac{1}{1 + e^{-av}} \tag{3}$$

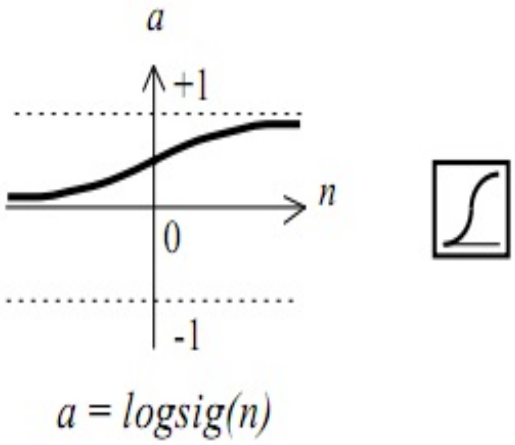

Figura 30 - Função de transferência Log-Sigmoid.
[18]

5.3.4 Função Tangente Hiperbólica

A função tangente assume valores entre 1 e -1, sendo representada pela equação (4), onde a é o parâmetro de inclinação da curva, b são os limites inferiores e superiores e v o valor de ativação da unidade. A Figura 31 ilustra a função tangente.

$$f(n) = a\frac{e^{bv} - e^{-bv}}{e^{bv} + e^{bv}} \tag{4}$$

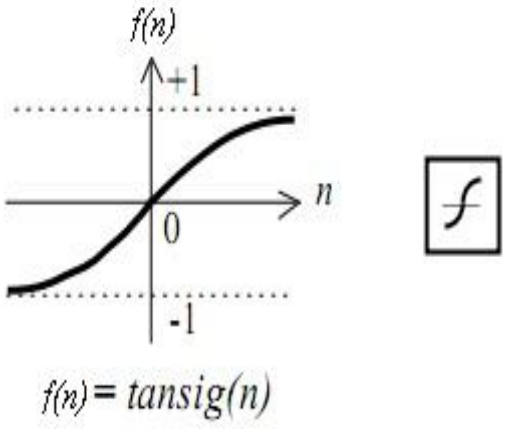

Figura 31 - Função de transferência Tan-Sigmoid.
[18]

5.3.5 Função Gaussiana

As funções de base radiais representam uma classe especial de funções cujo valor diminui ou aumenta conforme a distância a um ponto central. Essas funções são utilizadas nos nós da camada oculta das redes de funções de bases radiais(RBF) [18]. Diferentes funções de base radiais têm sido utilizadas em RBF. As mais comuns são: função Gaussiana demostrada na equação (5), função multiquadrática da forma da equação (6) e a função *thin-plate-spline* conforme a equação (7).

$$f(v) = exp(-\frac{v^2}{2\sigma^2}) \tag{5}$$

$$f(v) = \sqrt{v^2 + \sigma^2} \tag{6}$$

$$f(v) = v^2 log(v) \tag{7}$$

Nas expressões acima, v=$\|x - \mu\|$, refere-se à distância euclidiana, x é o vetor de entrada, μ e σ são respectivamente o centro e a largura da função base radial. As funções radiais mais utilizadas possuem dois parâmetros: o centro e o raio. A distância euclidiana, do vetor de entrada x ao vetor de centro μ serve como entrada para a função, que retorna o valor de ativação dos nós da camada intermediária. A Figura 32 ilustra a função de base radial.

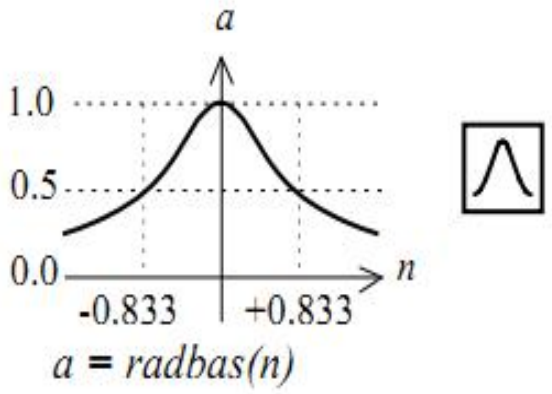

Figura 32 - Função de transferência Radbas.
[18]

5.3.6 Função Competitiva

Os neurônios competem entre si pelo direito de resposta a um vetor de entrada, ou seja, a função competitiva retorna uma saída binária igual a 1 para o nó que define a classe mais provável do padrão de entrada e 0 para os demais nós. A Figura 33 ilustra a função competitiva.

5.4 **Algoritmos de Treinamento**

A propriedade mais importante para uma Rede Neural Artificial é a sua habilidade para aprender a partir do ambiente no qual ela está inserida, isto é, a aprendizagem [17].

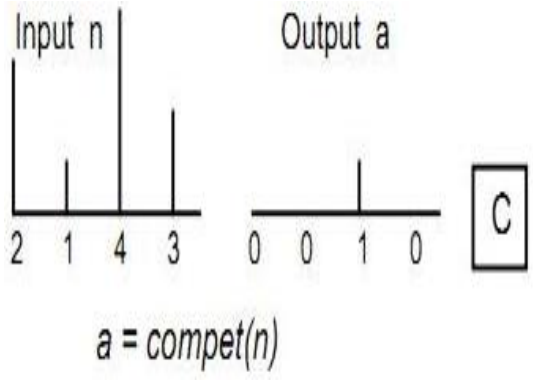

Figura 33 - Função de transferência Compet.
[18]

5.4.1 Aprendizado Supervisionado

O aprendizado supervisionado se dá com intervenção externa, como indicado na Figura 34. Este é o método de treinamento mais comum empregado para o "projeto" de RNAs.

O objetivo do aprendizado consiste em otimizar os parâmetros de uma rede neural (os pesos sinápticos e as tendenciosidades/bias), objetivando encontrar a ligação mais adequada entre pares de estímulos (conjunto de valores de entrada) e saída conhecidas.

Para cada padrão de entrada submetido, compara-se a resposta desejada e a calculada pela RNA, ajustando-se os pesos das conexões em função dessa comparação, de forma a minimizar o erro entre as respostas [17].

O sinal de saída da RNA é então comparado com a resposta desejada, gerando um sinal de erro que é utilizado para ajustar os pesos sinápticos da rede neural de modo que esta, após o ajuste, apresente em sua saída uma resposta tão próxima quanto possível daquela desejada. Esse processo é repetido para cada exemplo de treinamento até que a RNA emule o professor.

Dessa forma, o conhecimento do professor foi, de certa maneira, transferido para os pesos sinápticos da rede neural, e este não se faz mais necessário, pois a RNA já é capaz de lidar com o ambiente por si mesma [27, 28].

Os exemplos mais conhecidos de algoritmos para aprendizado supervisionado são a Regra Delta e a sua generalização o algorítimo *Backpropagation* [17].

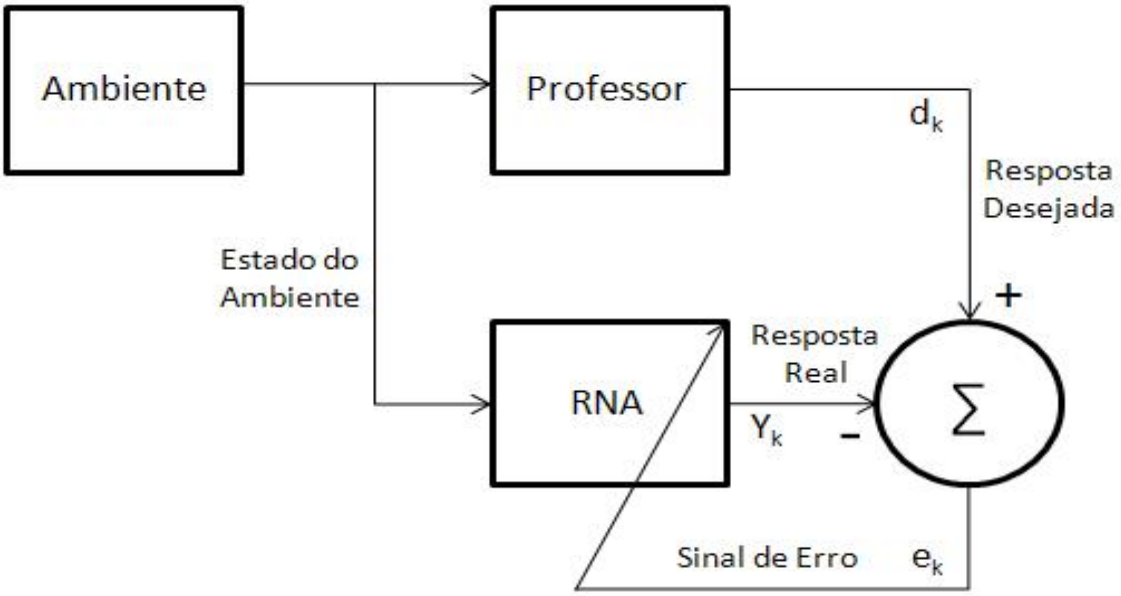

Figura 34 - Diagrama em blocos da aprendizagem supervisionada.
[17]

5.4.2 Correção de Erros

O sinal de saída do neurônio, representado por y_k, é comparado com a resposta desejada, representa por d_k. Consequentemente é produzido um sinal de erro, representado por e_k [17]. A equação (8) define esse sinal de erro, onde: e_k é o sinal de erro, y_k é o sinal de saída e d_k é a resposta desejada.

O sinal de erro aciona um mecanismo de realimentação cujo propósito é fazer ajustes corretivos nos pesos sinápticos. Os ajustes são feitos buscando-se aproximar passo-a-passo o sinal de saída à resposta desejada. Este objetivo é alcançado minimizando-se uma função de custo. Os ajustes dos pesos continuam até que o sistema atinja um estado estável, ponto no qual o processo é encerrado [17].

$$e_k = d_k - y_k \tag{8}$$

5.5 **Arquitetura da Rede Neural**

A escolha da arquitetura de uma RNA envolve a definição de alguns parâmetros importantes: número de camadas, número de neurônios por camada, tipos de conexões entre neurônios e a topologia da rede. Quanto ao número de camadas as redes neurais podem ser de camada única, com apenas um neurônio entre qualquer par entrada-saída, ou de múltiplas camadas, com mais de um neurônio entre algum par entrada-saída.

Em relação ao tipo de conexão entre os neurônios as redes podem ser acíclicas *(ou feedforward)*, nas quais não há realimentação das saídas, ou cíclicas (ou recorrentes), nas quais pelo menos uma saída é realimentada para a rede. Assim, pode-se afirmar que existem basicamente três grandes classes de arquiteturas de rede: redes acíclicas com camada única, redes acíclicas com múltiplas camadas e redes recorrentes [17, 28].

5.5.1 Perceptron de Múltiplas Camadas

A perceptron de múltiplas camadas (MLP) são redes acíclicas de múltiplas camadas, cujos neurônios apresentam função de ativação não-linear e diferenciável, também são compostas por uma camada de entrada, uma os mais camadas escondidas e uma camada de saída. Um sinal de entrada é propagado, de camada em camada, da entrada para saída conforme demostrado na Figura 35.

Estas redes são treinadas através de um algoritmo supervisionado denominado algoritmo de retropropagação do erro. O algoritmo baseia-se no método do gradiente decrescente cuja ideia central é fazer modificações proporcionais ao gradiente do erro.

Este algoritmo apresenta duas etapas distintas: i) na primeira etapa é apresentado à rede um padrão de entrada, este se propaga através da rede, camada por camada, até produzir a resposta final da rede (saídas dos neurônios da última camada) e ii) na segunda etapa, que se realiza da última camada (saídas) para a primeira camada (entradas), os pesos sinápticos dos neurônios de cada camada são reajustados [27, 28].

O sinal do erro é definido como a diferença entre a saída real da rede e uma saída desejada. O objetivo é fazer com que a saída da rede se aproxime gradativamente da saída desejada [17].

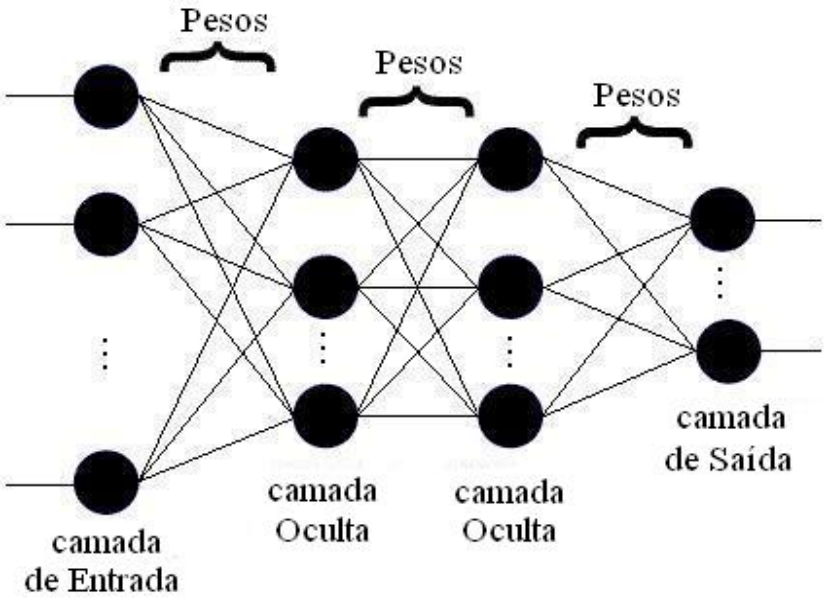

Figura 35 - Rede de múltiplas camadas.
[17]

5.5.2 Função de Base Radial

As redes de funções de bases radiais (RBF), como as redes MLP, são redes multicamadas, alimentadas adiante. As principais diferenças entre os dois tipos de redes são: as redes RBF sempre apresentam uma única camada intermediária, os neurônios da camada intermediária têm apenas funções de base radial como função de ativação, ao invés de funções sigmoidais ou outras e os neurônios de saída são sempre lineares [16, 27].

A construção de uma rede RBF, em sua forma mais básica, envolve três camadas com papéis totalmente diferentes. A camada de entrada é constituída de nós que conectam a rede a seu ambiente e não executam nenhuma função sobre os dados de entrada [27].

A segunda camada, a única camada oculta da rede, ou invés da ativação interna de cada neurônio da camada intermediária se dar pelo emprego do produto escalar entre o vetor de entrada e o vetor de pesos, como no caso do *perceptron*, ela é obtida a partir de uma norma ponderada da diferença entre ambos os vetores [27].

A camada de saída é sempre linear e procura classificar os padrões recebidos da camada anterior. A Figura 36 mostra a arquitetura básica de uma rede RBF.

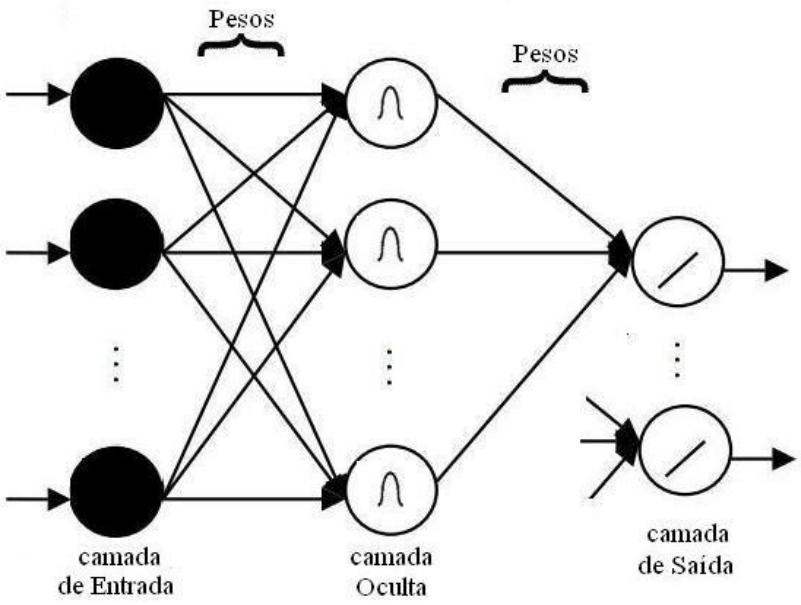

Figura 36 - Rede de base radial.
[17]

5.5.3 Probabilística

As redes neurais probabilísticas (PNN) basicamente trata-se de uma implementação, via uma RNA, de um mecanismo Classificador de Parzen (classificador assintoticamente ótimo de Bayes, com as densidades de probabilidade da população em cada classe estimadas pelo método da Janela de Parzen) [40].

As principais vantagens das Redes Neurais Probabilísticas são: i) o treinamento é realizado em apenas um passo e ii) a garantia de que a superfície de decisão se aproxima dos limites de uma decisão *Bayesiana* ótima, à medida que o número de exemplos de treinamento cresce. Outra grande motivação para a utilização das redes PNN é o curto tempo necessário para treiná-las quando comparado ao tempo necessário para treinar redes MLP [12, 17]. A Figura 37 mostra a arquitetura básica de uma rede PNN.

As redes PNN são divididas em quatro camadas: camada de unidades de entrada, camada de unidades de padrões, camada de unidades de soma e camada de unidades de saída. Na primeira camada, cada nó apresenta por vez um componente do vetor p-dimensional x, observado na amostra e utilizado como padrão no treinamento da rede. Esta camada tem como papel simplesmente prover os dados de entrada aos neurônios da

camada seguinte.

A camada de padrões é treinada objetivando criar uma unidade para cada um dos padrões do conjunto de treinamento, deste modo, cada unidade de padrão armazena um vetor do conjunto de treinamento, assim como a sua verdadeira classe [12, 17].

Essas unidades já mencionadas representam, portanto, os vetores do conjunto de treinamento onde serão centradas funções *kernel* utilizadas no método de estimação de densidades de probabilidade conhecido como método da Janela de Parzen [12, 17].

Assim, cada função *kernel* utilizada na estimação não–paramétrica das densidades de probabilidade de X em cada classe terá como média um vetor observado no conjunto de treinamento.

As conexões que comunicam os nós na camada de entrada com os neurônios de padrões na camada imediatamente seguinte são ponderadas por pesos sinápticos, de tal forma que, a cada neurônio i da segunda camada existe um vetor de pesos i_W a ele associado, ligando este neurônio i a todos os nós da camada de entrada.

A seguir, as unidades de padrão mandam esses resultados para as unidades de soma. Existem em uma PNN tantas unidades de soma quanto classes no problema abordado.

Deste modo, as unidades de padrão só se comunicam com apenas um nó de soma, correspondente à verdadeira classe dos vetores armazenados nas primeiras. Os nós da camada de soma então procedem à soma desses resultados. Assumindo-se que existam N padrões a serem apresentados à rede no conjunto de treinamento, e que desses N padrões N_k correspondam à classe k e N_j correspondam à classe j, então N_k unidades de padrão irão enviar seus sinais a uma das unidades de soma. As outras N_j unidades de padrão irão enviar seus sinais à outra unidade de soma.

Finalmente, os resultados obtidos nas unidades de soma são enviados às unidades de saída, que irão comparar os resultados recebidos e decidir por associar x a uma das classes possíveis, ou seja, a rede estima a função de probabilidade de cada classe [12, 17].

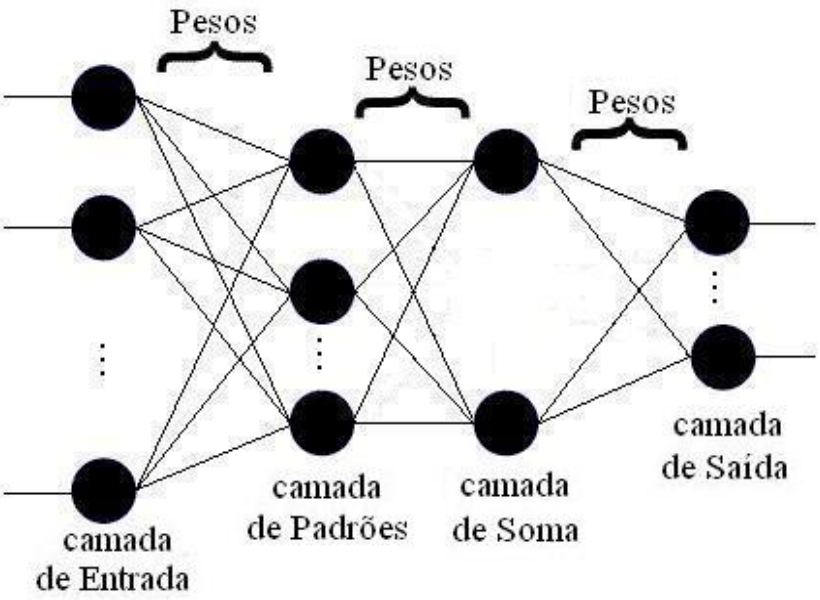

Figura 37 - Rede probabilística.
[17]

6 METODOLOGIA DE CLASSIFICAÇÃO DA FALTA

Para o desenvolvimento de uma modelo baseado em RNAs, foi seguida uma estratégia que contemplasse várias etapas: definição do problema, coleta dos dados, extração das características, definição da rede neural, treinamento, validação e teste. A Figura 38 ilustra as etapas do processo de desenvolvimento de uma RNA.

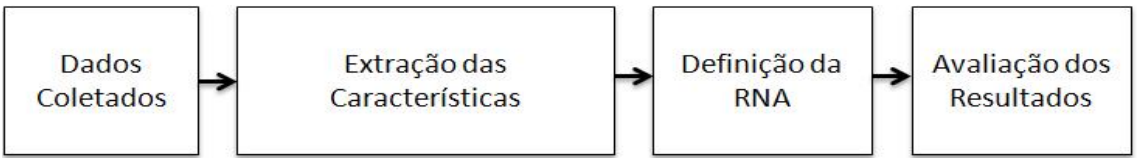

Figura 38 - Etapas no ciclo de desenvolvimento de uma RNA.
[29]

6.1 Dados Coletados

Na primeira etapa do processo foi utilizada uma base de dados com os valores estimados da frequência, da amplitude e da fase dos 6 sinais (3 de tensão e 3 de corrente) dos registros das faltas proveniente do algoritmo de detecção do instante de incidência da falta descrito no capítulo 4, seção 4.2. Os dados coletados são divididos em três conjuntos para diferentes finalidades: treinamento, validação e teste.

A utilização de procedimentos de validação cruzada é geralmente feita da seguinte maneira: i) divida o conjunto de dados em treinamento, validação e teste; ii) treine somente com o conjunto de treinamento e avalie o erro do conjunto de validação a cada k iterações (épocas); iii) interrompa o treinamento quando o erro do conjunto de validação for maior do que era k iterações atrás, e iv) utilize o conjunto de pesos anteriores como o resultado do treinamento [12, 17].

Esta abordagem utiliza o conjunto de validação para antecipar o comportamento em situações reais (ou em um conjunto de teste), assumindo que o erro em ambos os casos será semelhante: o erro de validação geralmente é uma estimativa do erro de generalização [12, 17].

6.2 **Extração das Características**

A segunda etapa tem como objetivo selecionar criteriosamente os dados que deverão ser apresentados às redes neurais, extraídos dos 6 sinais de entrada, de forma a preservar características que permitam a classificação com elevada confiabilidade. Os vetores de dados a serem aplicados à entrada da rede neural são constituído pela estimativa da frequência, da amplitude e da fase dos 6 sinais dos registros das faltas.

6.3 **Definição da RNA**

Foram desenvolvidas, na terceira etapa, duas redes neurais artificiais: uma para identificação do tipo da falta (RNA 1) e uma outra para localização do instante de incidência da falta (RNA 2). Essas RNAs foram implementadas no *software* $MatLAB^{®}$ R2010a, utilizando-se para isso o conjunto de funções chamado de *Neural Network Toolbox* fornecido com o *software*.

Foram criadas 3 diferentes arquiteturas de redes neurais para investigar as topologias mais adequadas em função dos melhores resultados obtidos na classificação. As arquiteturas utilizadas nesse trabalho foram: a *Perceptron* de Múltiplas Camadas, a Função de Base Radial e a Probabilística, sendo todas as arquiteturas totalmente conectadas e alimentadas no sentido camada de entrada-camada de saída *(feedforward Multi-Layer Perceptron)*.

Os vetores de entradas são compostos dos 3 parâmetros (frequência, amplitude e fase) das 3 fases (A, B e C) para os 3 medidores (início, meio e fim), gerando um total de 27 entradas.

O algoritmo usado para o treinamento da rede MLP foi o *backpropagation*. As características básicas de cada rede neural MLP estão resumidas na Tabela 7, as RBF na Tabela 8 e as PNN na Tabela 9. O número de neurônios presentes na camada oculta de cada MLP foi escolhido de forma empírica, análise de diversas tentativas.

Tabela 7 - Características das MLP utilizadas.

Característica	**RNA 1**	**RNA 2**
Número de entradas	27	27
Número de saídas	10	13
Camadas ocultas	2	2
Neurônios ocultos na primeira camada	39	65
Neurônios ocultos na segunda camada	21	52
Função de ativação da camada oculta	logsig	logsig
Função de ativação da camada de saída	tansig	tansig

Tabela 8 - Características das RBF utilizadas.

Característica	**RNA 1**	**RNA 2**
Número de entradas	27	27
Número de saídas	10	13
Camadas ocultas	1	1
Função de ativação da camada oculta	radbas	radbas
Função de ativação da camada de saída	linear	linear

Tabela 9 - Características das PNN utilizadas.

Característica	**RNA 1**	**RNA 2**
Número de entradas	27	27
Número de saídas	10	13
Camada de padrões	1	1
Camada de soma	1	1
Função de ativação da camada de saída	compet	compet

A RNA 1 utilizada na identificação do tipo da falta possui dez saídas. Uma das saídas é ativada para cada possível tipo de falta, conforme a Tabela 10.

Tabela 10 - Saída da RNA 1.

Tipo da Falta	**Saída Correspondente**									
	1	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**
AG	0	0	0	0	0	0	0	0	0	1
BG	0	0	0	0	0	0	0	0	1	0
CG	0	0	0	0	0	0	0	1	0	0
ABG	0	0	0	0	0	0	1	0	0	0
ACG	0	0	0	0	0	1	0	0	0	0
BCG	0	0	0	0	1	0	0	0	0	0
AB	0	0	0	1	0	0	0	0	0	0
AC	0	0	1	0	0	0	0	0	0	0
BC	0	1	0	0	0	0	0	0	0	0
ABC	1	0	0	0	0	0	0	0	0	0

A RNA 2 utilizada na localização do instante de incidência da falta possui treze saídas. Uma das saídas é ativada para cada possível ponto de ocorrência da falta, conforme a Tabela 11.

Tabela 11 - Saída da RNA 2.

Ponto de Ocorrência da falta	**Saída Correspondente**												
	1	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**	**12**	**13**
P01	0	0	0	0	0	0	0	0	0	0	0	0	1
P02	0	0	0	0	0	0	0	0	0	0	0	1	0
P03	0	0	0	0	0	0	0	0	0	0	1	0	0
P04	0	0	0	0	0	0	0	0	0	1	0	0	0
P05	0	0	0	0	0	0	0	0	1	0	0	0	0
P06	0	0	0	0	0	0	0	1	0	0	0	0	0
P07	0	0	0	0	0	0	1	0	0	0	0	0	0
P08	0	0	0	0	0	1	0	0	0	0	0	0	0
P09	0	0	0	0	1	0	0	0	0	0	0	0	0
P10	0	0	0	1	0	0	0	0	0	0	0	0	0
P11	0	0	1	0	0	0	0	0	0	0	0	0	0
P12	0	1	0	0	0	0	0	0	0	0	0	0	0
P13	1	0	0	0	0	0	0	0	0	0	0	0	0

6.3.1 Treinamento

O processo de treinamento de uma RNA é um passo de fundamental importância para que se consiga bons modelos neurais. Diversas questões estão envolvidas no processo de treinamento de uma RNA, tal como a definição do tipo de algoritmo de aprendizado, a decisão do erro admissível e o número máximo de interações [29].

6.3.1.1 Identificação da falta

Para o treinamento da arquitetura MLP utilizou-se os algoritmos de otimização: Resilient (RProp) e Levenberg-Marquardt (LM) que se encontram implementados no *Neural Network Toolbox* do *software* $MatLAB^{®}$ R2010a.

Para o treinamento das topologias RBF e PNN, utilizou-se o algoritmo Gaussiano que também se encontra implementado no *Neural Network Toolbox*. O conjunto de treinamento utilizado para RNA responsável pela identificação da falta foi constituído de modo a englobar todos os 10 tipos de falta considerados, os três tipos diferentes de resistência e os treze pontos de aplicação da falta.

Na fase de treinamento, o processo somente é interrompido por dois mecanismos pré-determinados. O primeiro diz respeito a um limite de erro na saída, determinado no caso em foco, na fase de retropropagação, pelo erro quadrático médio (EQM), definido pela equação (9), onde E é o valor esperado, $\overline{x}$ é o valor estimado e x é o valor real da frequência fundamental.

$$EQM = E[(\overline{x} - x)^2] \tag{9}$$

O segundo mecanismo de interrupção é devido ao número máximo de iterações permitidas (épocas). Uma Época consiste no intervalo correspondente à apresentação de todos os N vetores-exemplos do conjunto de treino à camada de entrada do MLP [17,27].

Foi pré-definido que para todas as redes testadas seriam fixados valores de tolerância do EQM no treinamento iguais a 10^{-3} e limites de 1.500 épocas.

Cada vez que um padrão é apresentado à rede, os pesos que levam a um nó de saída são levemente modificados durante o aprendizado na direção requerida para produzir um menor erro a próxima vez que o mesmo padrão for apresentado. A quantidade de modificação de pesos é a taxa de aprendizagem [12, 17].

Por exemplo, se um taxa de aprendizagem é 0.5, a mudança de peso é só 50% do erro. Quanto maior a taxa de aprendizagem, maiores as mudanças de pesos, e mais rápido o aprendizado será procedido. Oscilação ou não convergência pode ocorrer se a taxa de aprendizagem é muito grande.

Grandes taxas de aprendizado frequentemente levam à oscilação de mudanças de pesos e o aprendizado nunca se completa, ou o modelo converge a uma solução que não é ótima. Uma maneira que permite mais rápido aprendizado sem oscilação é fazer a mudança de peso uma função da prévia mudança de peso para permitir um efeito suavizador [12, 17].

O fator *momentum* determina a proporção da última mudança de peso que é adicionada na nova mudança de peso.

Para estes dois importantes parâmetros que auxiliam na aceleração e assertividade do processo de treinamento, assume-se por utilizar uma taxa de aprendizado de 3%, e para o *momentum* foi escolhido utilizar o *"default"* do $MatLAB^{®}$ R2010a, ou seja, automaticamente o programa altera e adapta os valores do *momentum* à medida que o EQM diminui [17].

Os dados originais foram particionados aleatoriamente em 3 conjuntos, sendo 60% dos dados para treinamento, 20% para validação e 20% para teste.

6.3.1.2 Localização da falta

A RNA 2 foi desenvolvida para localizar o instante em que há a incidência da falta e seu treinamento foi realizado com parâmetros configurados igualmente aos apresentados no item anterior.

6.3.2 Teste

Nesta fase utiliza-se o conjunto de teste, que foi previamente extraído aleatoriamente da base de dados original, para que se possa determinar o desempenho das RNAs.

Esta etapa é muito importante pois, através dela, consegue-se visualizar a capacidade de generalização da rede neural a partir de novos dados que possuem informações com características semelhantes aos dados que a rede foi treinada, mas que não foram empregados no treinamento das RNAs [17].

A partir do momento que esses padrões são apresentados para a rede neural e ela consegue reconhecer os mesmos através de dados da sua fase de treinamento, pode-se dizer

que as etapas de treinamento e teste foram bem sucedidas. O desempenho da rede neural testada é um bom indicativo de seu desempenho real [17, 29].

7 ANÁLISE DOS RESULTADOS OBTIDOS

Foi constatado, através da análise dos registros das faltas no capítulo 4, que os parâmetros da fundamental de corrente variam consideravelmente e os parâmetros da fundamental de tensão variam muito pouco em função dos distúrbios na rede elétrica aqui ajustados. Logo, este trabalho classifica os padrões extraídos dos registros de faltas separando os parâmetros das fundamentais de corrente e de tensão, visando minimizar o erro de classificação e obter uma melhor generalização das RNAs, ou seja, maior capacidade de responder corretamente a dados que não foram utilizados no processo de treinamento.

7.1 Identificação dos tipos das faltas

7.1.1 Primeira Abordagem - Identificação caso MLP

Foi criada uma rede neural MLP com 27 entradas, 2 camadas ocultas com o número de neurônios escolhido de forma aleatória e 10 saídas que correspondem aos tipos de faltas aqui simuladas, conforme descrito no capítulo 6, seção 6.3. O acréscimo do número de neurônios das camadas intermediárias aumentou significativamente o tempo de treinamento da rede neural, porém a redução do erro de classificação não foi muito expressiva, o que não tornou-se atraente o aumento da quantidade desses neurônios.

Para o treinamento da rede neural que atualiza os valores dos pesos e viéses, utilizou-se dois métodos, Levenberg-Marquardt e Resiliente, que são ambos considerados aprendizados por Retro-Propagação do erro [17, 27].

7.1.1.1 Parâmetro da Fundamental de Corrente

O melhor treinamento convergiu em 56 épocas com o MSE de $8.15x10^{-3}$ como mostrado na Figura 39 e o melhor desempenho obtido no conjunto de treinamento que foi realizado com o número total de 702 registros foram: 692 acertos com porcentagem de 98.6% e 10 erros com porcentagem de 1.4% para o algoritmo de treinamento Levenberg-Marquardt. Já para o algoritmo Resiliente foram: 673 acertos com porcentagem de 95.9% e 29 erros com porcentagem de 4.1%.

A seguir as matrizes de confusões geradas pelos algoritmos, ou seja, a matriz de confusão contém informações sobre o número de classificações corretas versus as classificações preditas para cada classe sobre um conjunto de exemplos [12, 27]. O número de acertos para cada classe se localiza na diagonal principal da matriz e os demais elementos representam os erros na classificação. As matrizes de confusões do treinamento podem ser vistas na Figura 41 e na Figura 42.

O conjunto de validação foi avaliado com 234 registros e obteve 221 acertos com porcentagem de 94.4% e 13 erros com porcentagem de 5.6% para o algoritmo de treinamento Levenberg-Marquardt. O algoritmo Resiliente obteve 205 acertos com porcentagem de 87.6% e 29 erros com porcentagem de 12.4%. As matrizes de confusões da validação podem ser vistas na Figura 43 e na Figura 44.

O conjunto de teste também foi avaliado com 234 registros e obteve 222 acertos com porcentagem de 94.9% e 12 erros com porcentagem de 5.1% para o algoritmo de treinamento Levenberg-Marquardt e para o algoritmo Resiliente obteve 213 acertos com porcentagem de 91.0% e 21 erros com porcentagem de 9.0%.

Na matriz de confusão Figura 45, o classificador estimou a classe de entrada 2 (BC) como sendo as classes de saídas 3 (AC), 4 (AB) e 10 (AG) e na matriz de confusão Figura 46, o classificador estimou as classes de entradas 2 (BC), 6 (ACG) e 7 (ABG) como sendo a classe de saídas 3 (AC).

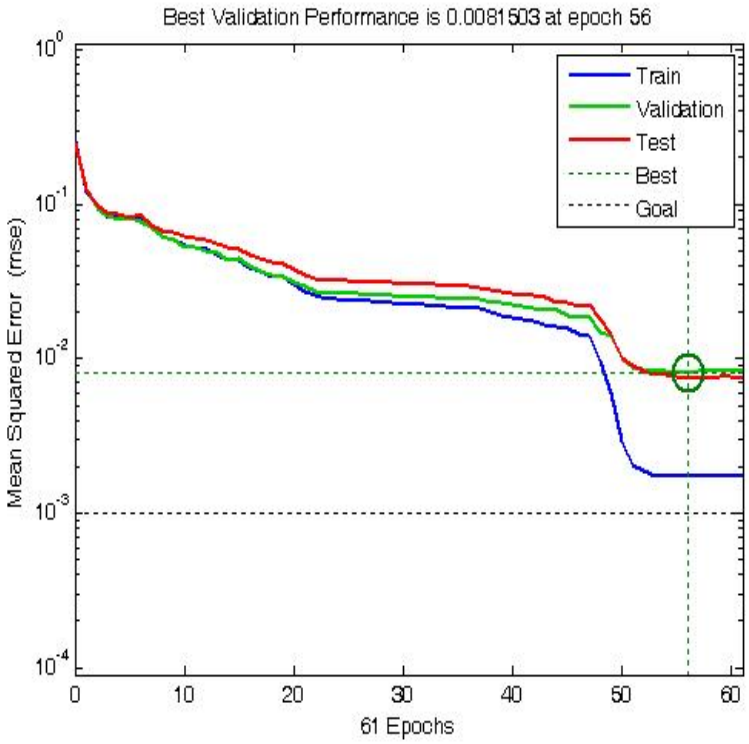

Figura 39 - Treinamento da identificação dos tipos das faltas caso Levenberg-Marquardt.

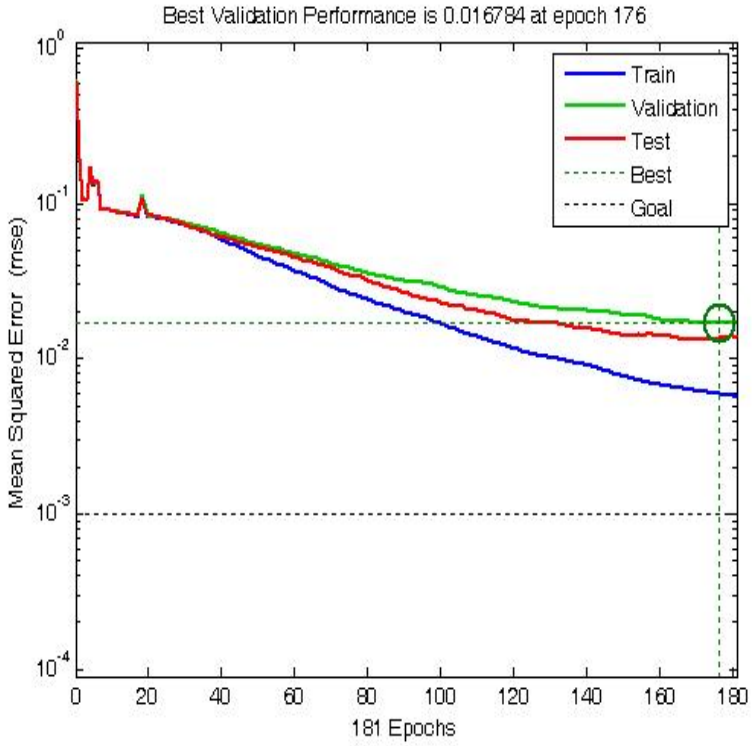

Figura 40 - Treinamento da identificação dos tipos das faltas caso Resilient.

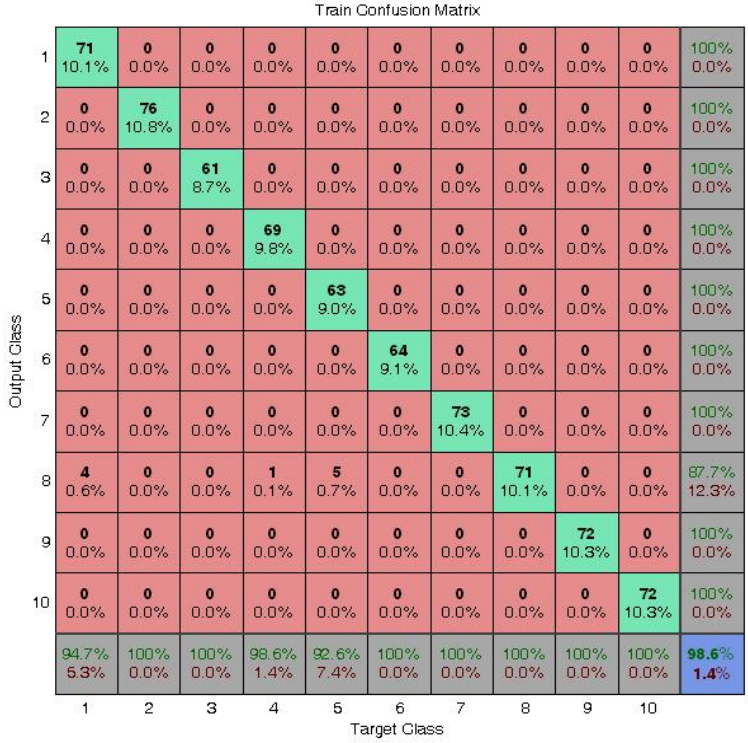

Figura 41 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de corrente caso Levenberg-Marquardt.

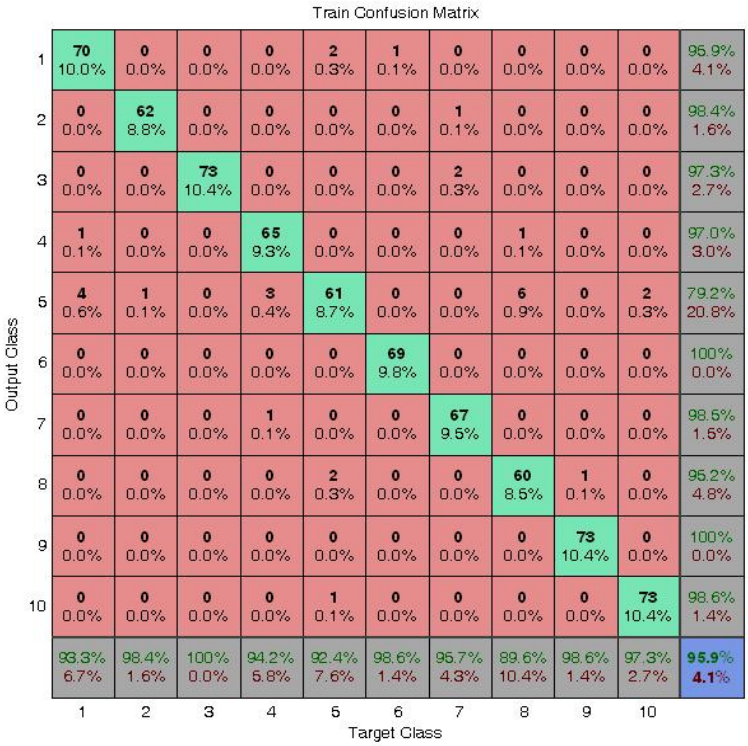

Figura 42 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de corrente caso Resilient.

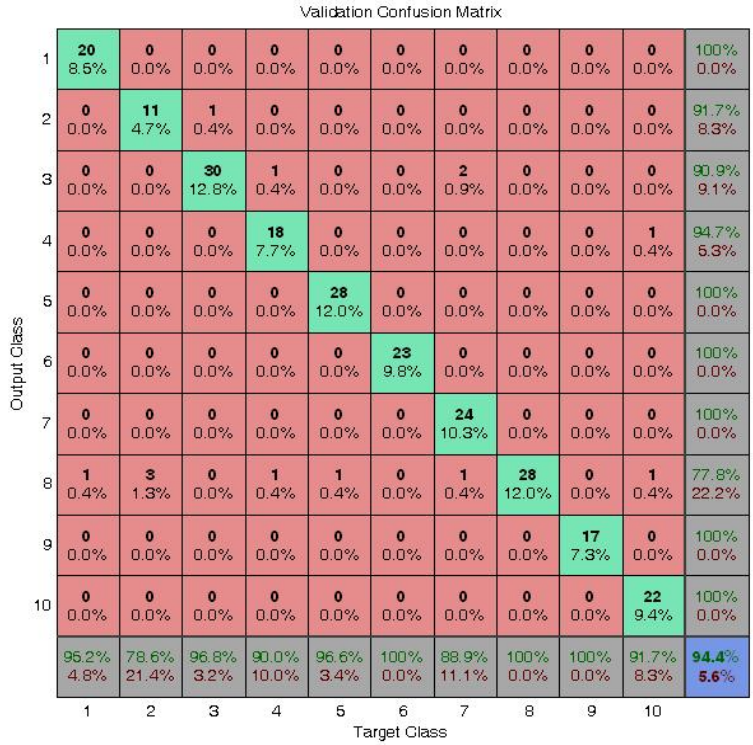

Figura 43 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de corrente caso Levenberg-Marquardt.

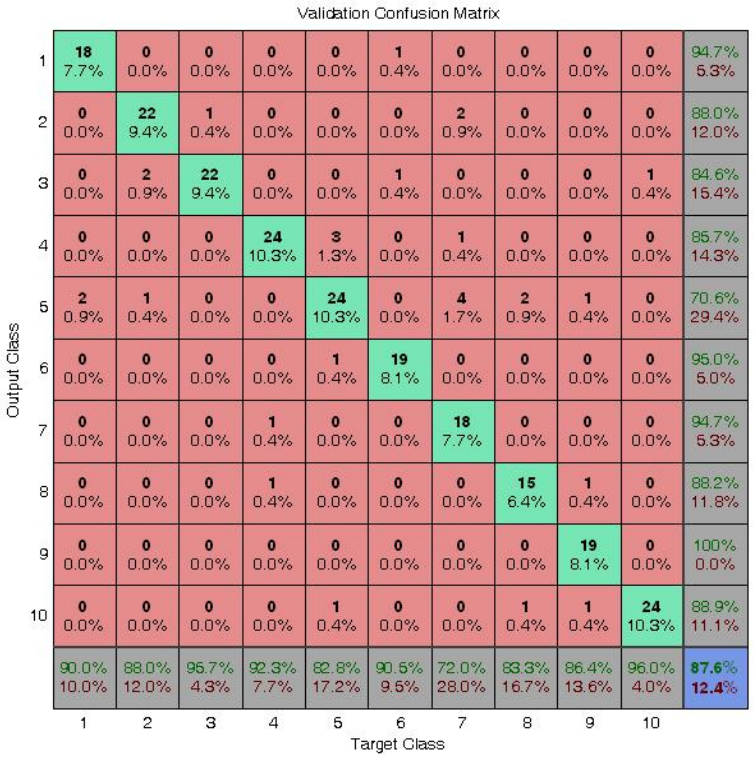

Figura 44 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de corrente caso Resilient.

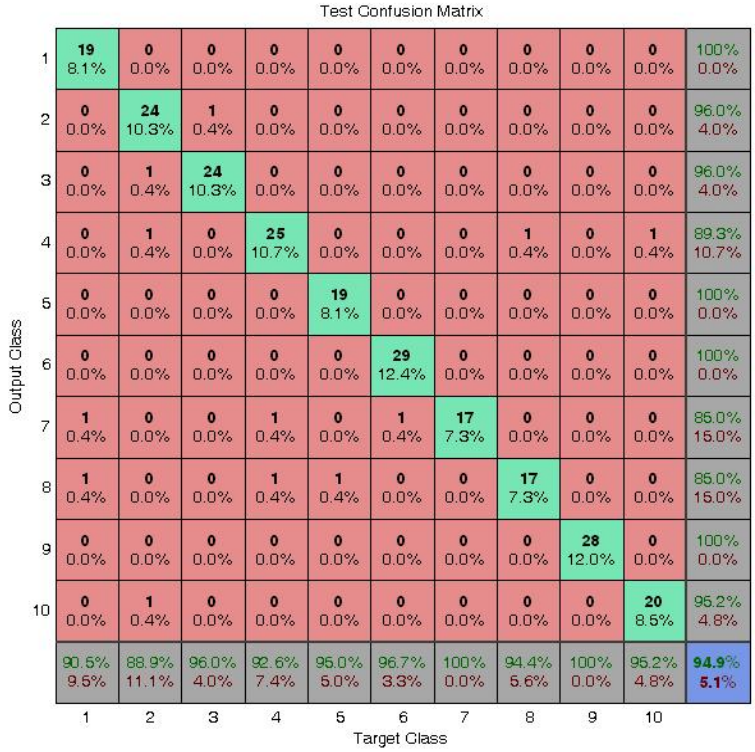

Figura 45 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de corrente caso Levenberg-Marquardt.

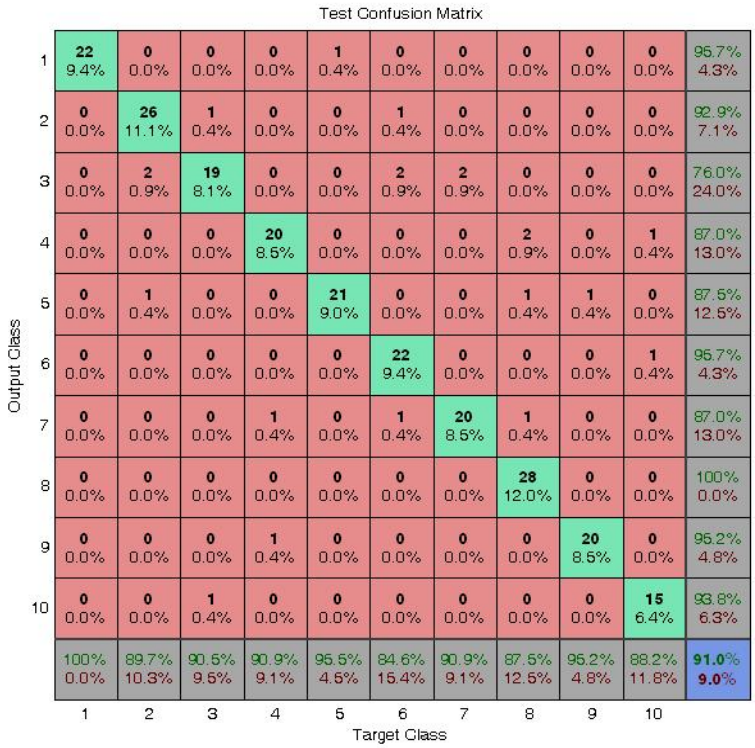

Figura 46 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de corrente caso Resilient.

7.1.1.2 Parâmetro da Fundamental de Tensão

O melhor treinamento convergiu em 50 épocas com o MSE de $18.05x10^{-3}$ como mostrado na Figura 47 e o melhor desempenho obtido no conjunto de treinamento que foi realizado com o número total de 702 registros foram: 679 acertos com porcentagem de 96.7% e 23 erros com porcentagem de 3.3% para o algoritmo de treinamento Levenberg-Marquardt. Já para o algoritmo Resiliente foram: 646 acertos com porcentagem de 92.0% e 56 erros com porcentagem de 8.0%. As matrizes de confusões do treinamento podem ser vistas na Figura 49 e na Figura 50.

O conjunto de validação foi avaliado com 234 registros e obteve 209 acertos com porcentagem de 89.3% e 25 erros com porcentagem de 10.7% para o algoritmo de treinamento Levenberg-Marquardt. O algoritmo Resiliente obteve 186 acertos com porcentagem de 79.5% e 48 erros com porcentagem de 20.5%. As matrizes de confusões da validação podem ser vistas na Figura 51 e na Figura 52.

O conjunto de teste também foi avaliado com 234 registros e obteve 207 acertos com porcentagem de 88.5% e 27 erros com porcentagem de 11.5% para o algoritmo de treinamento Levenberg-Marquardt e para o algoritmo Resiliente obteve 208 acertos com porcentagem de 88.9% e 26 erros com porcentagem de 11.1%.

Na matriz de confusão Figura 53, o classificador estimou a maioria das classes de entradas como sendo a classe de saída 8 (CG) e a classe de entrada 5 (BCG) como sendo a classes de saídas 1 (ABC), 2 (BC) e 8 (CG) e na matriz de confusão Figura 54, o classificador estimou a classes de entrada 6 (ACG) como sendo as classes de saídas 2 (BC), 3 (AC) e 5 (BCG).

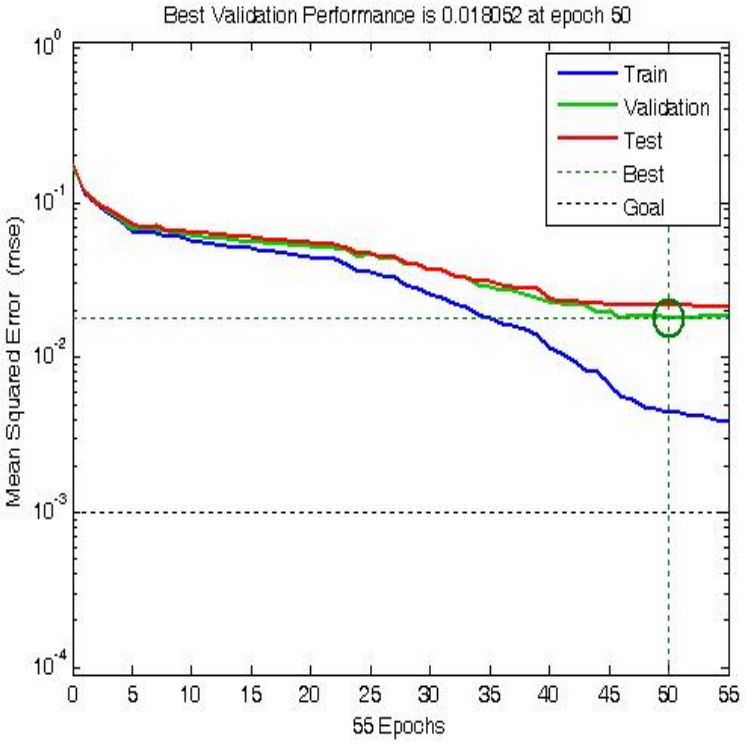

Figura 47 - Treinamento da identificação dos tipos das faltas caso Levenberg-Marquardt.

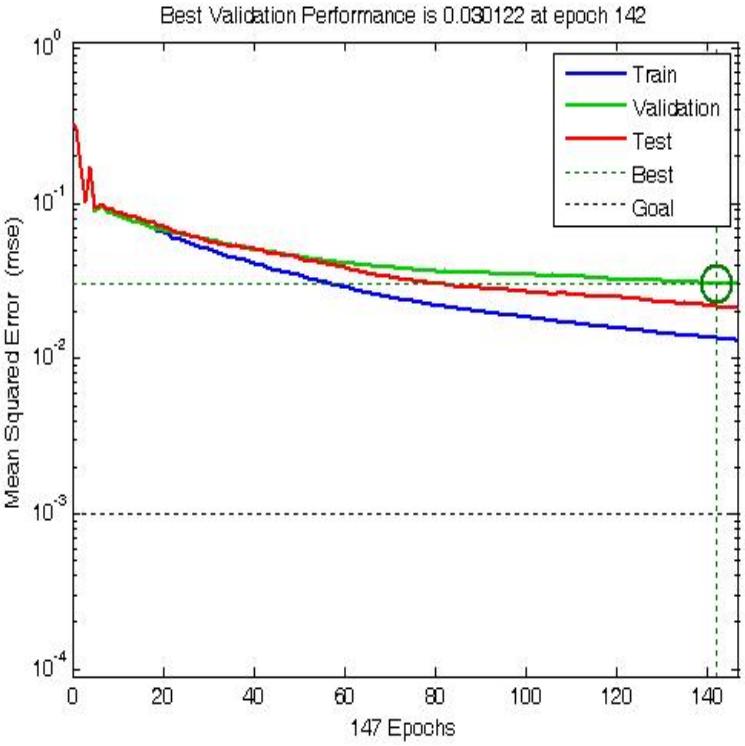

Figura 48 - Treinamento da identificação dos tipos das faltas caso Resilient.

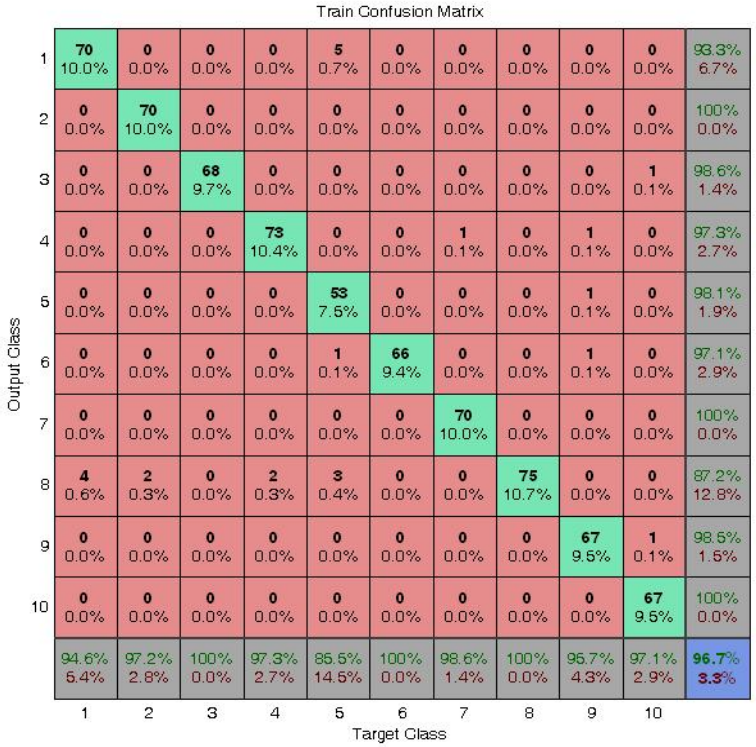

Figura 49 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de tensão caso Levenberg-Marquardt.

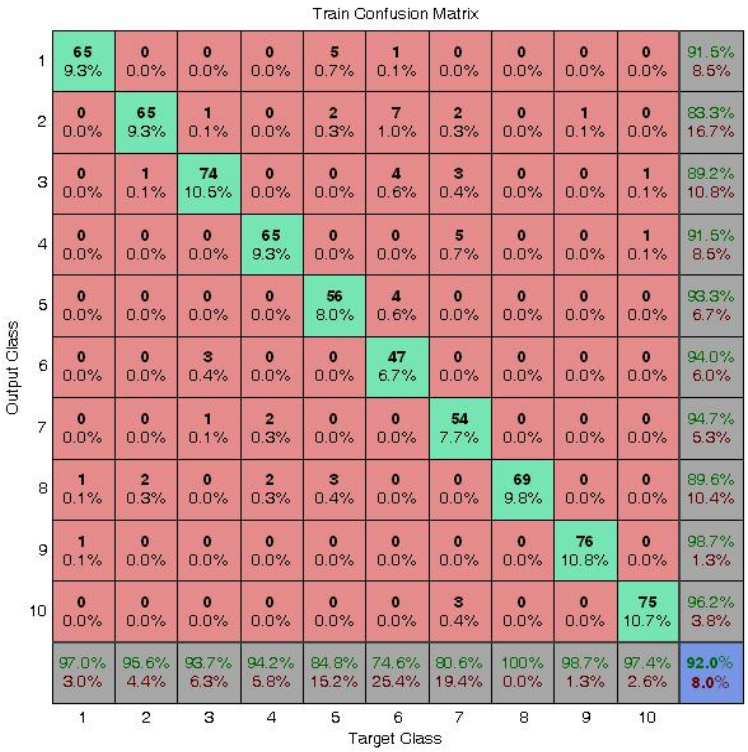

Figura 50 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de tensão caso Resilient.

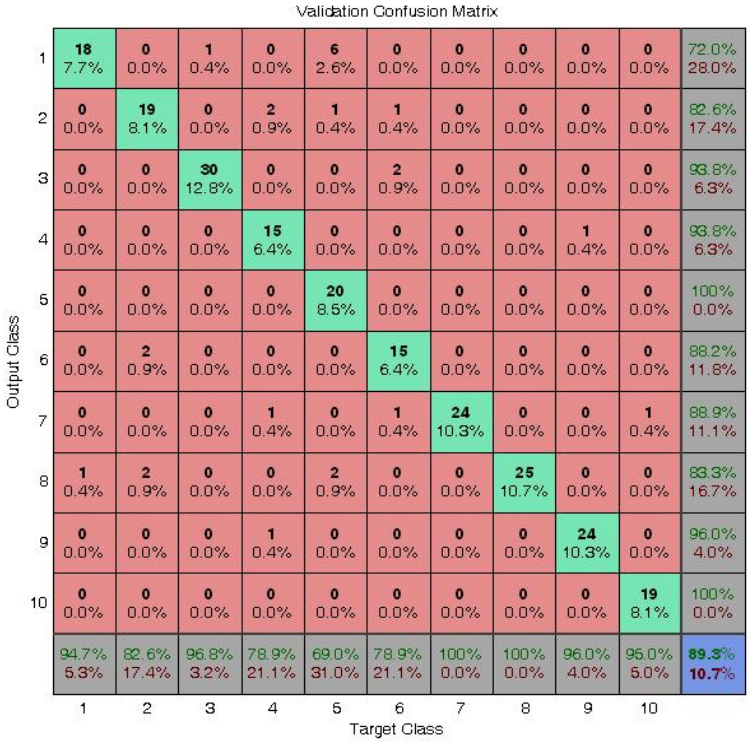

Figura 51 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de tensão caso Levenberg-Marquardt.

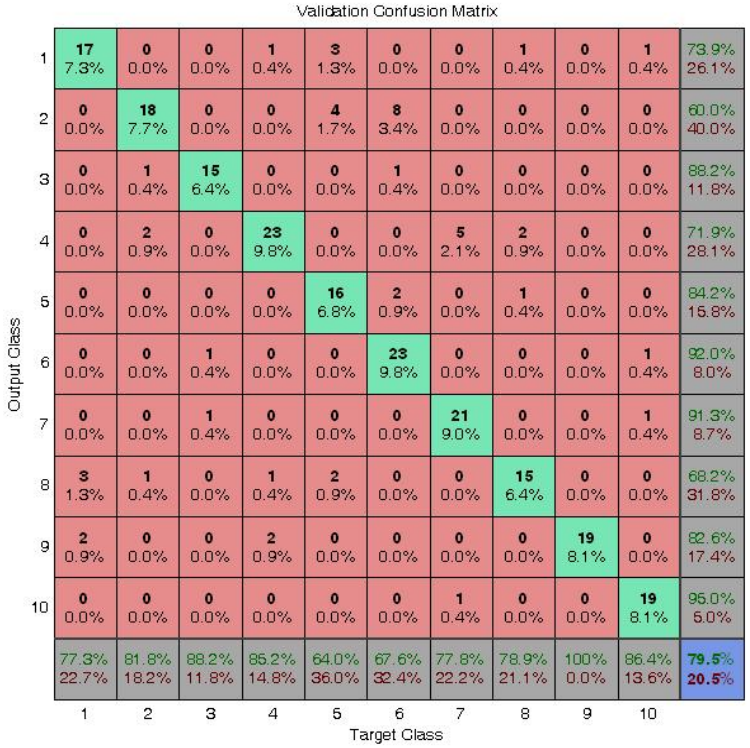

Figura 52 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de tensão caso Resilient.

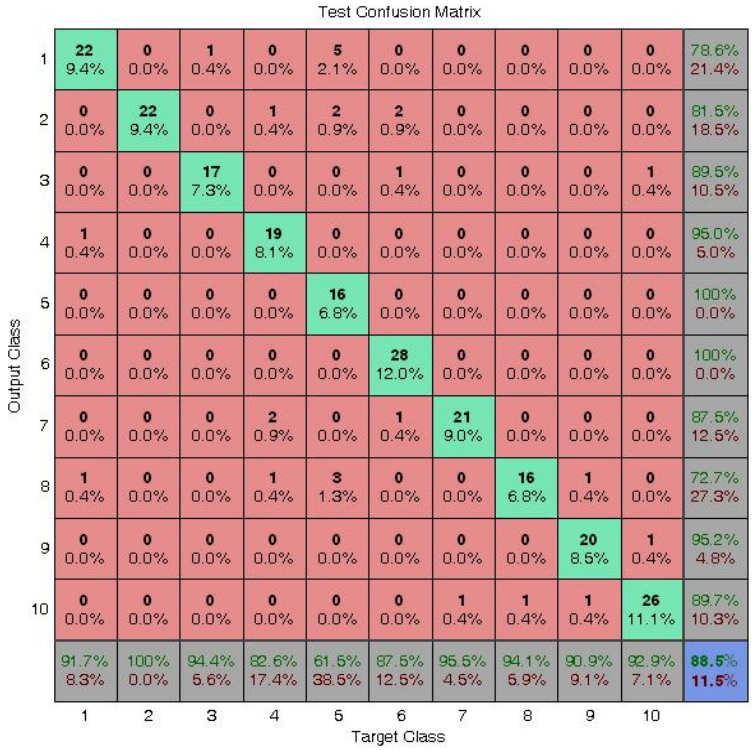

Figura 53 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de tensão caso Levenberg-Marquardt.

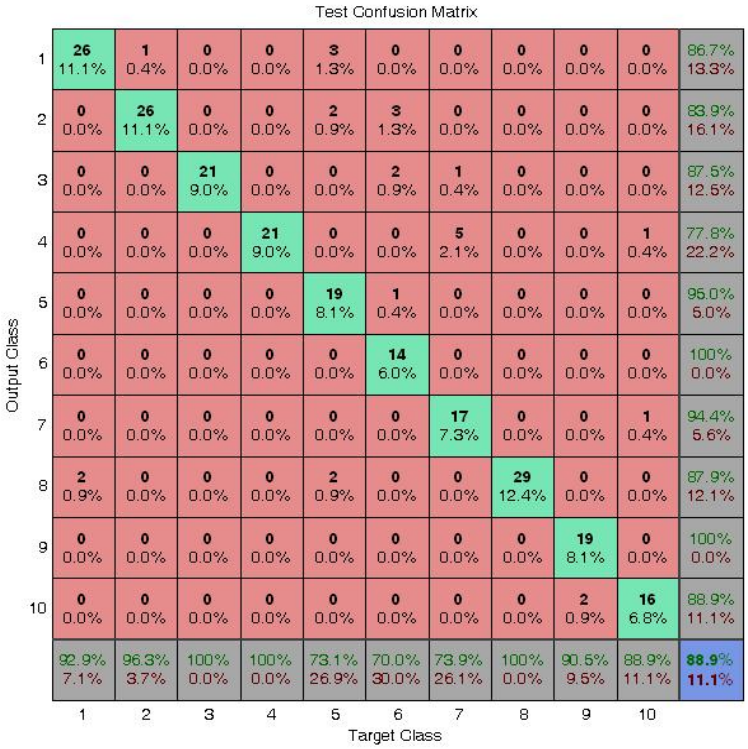

Figura 54 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de tensão caso Resilient.

7.1.2 Segunda Abordagem - Identificação caso RBF

Optou-se por utilizar o valor do *SPREAD* igual a 15. O *SPREAD* define a suavidade da função de aproximação descrita no capítulo 5, subseção 5.3.5, valores muito grandes significam que poucos nós serão necessários para ajustar uma função de ativação e valores muito pequenos significam que muitos nós serão necessários para ajustar uma função que muda suavemente e a rede pode não generalizar bem [16, 27].

Foi observado que quanto menor for o valor do erro final desejado (*GOAL*) para a generalização da rede neural, maior será a quantidade de nós criados na camada oculta e maior será o tempo de treinamento da rede neural.

7.1.2.1 Parâmetro da Fundamental de Corrente

O melhor treinamento convergiu em 360 épocas com o MSE de 0.0033 como mostrado na Figura 55 e o melhor desempenho obtido no conjunto de treinamento que foi realizado com o número total de 702 registros foram: 689 acertos com porcentagem de 98.1% e 13 erros com porcentagem de 1.9%. A matriz de confusão do treinamento pode ser vista na Figura 56.

O conjunto de validação foi avaliado com 234 registros e obteve 194 acertos com porcentagem de 82.9% e 40 erros com porcentagem de 17.1% e o conjunto de teste também foi avaliado com 234 registros e obteve 184 acertos com porcentagem de 78.6% e 50 erros com porcentagem de 21.4%. A matrize de confusão da validação pode ser vista na Figura 57.

Na matrizes de confusões do teste Figura 58, o classificador estimou a maioria das classes de entradas como sendo a classe de saída 6 (ACG).

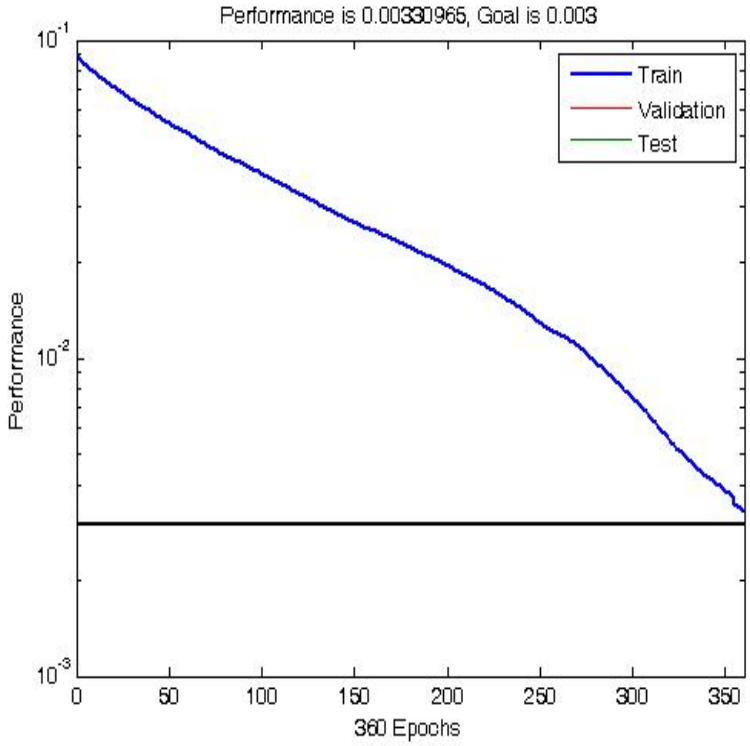

Figura 55 - Treinamento da identificação dos tipos das faltas caso RBF.

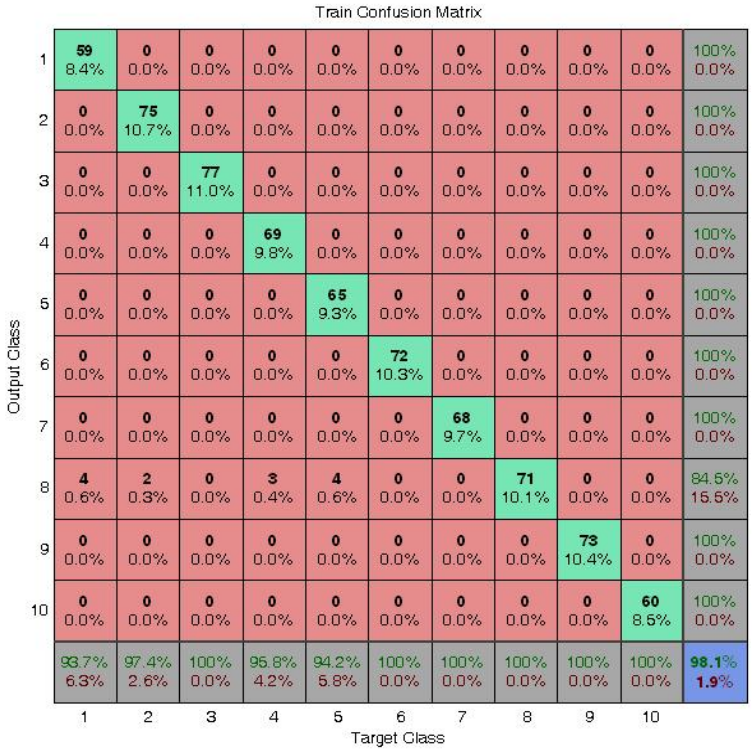

Figura 56 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de corrente caso RBF.

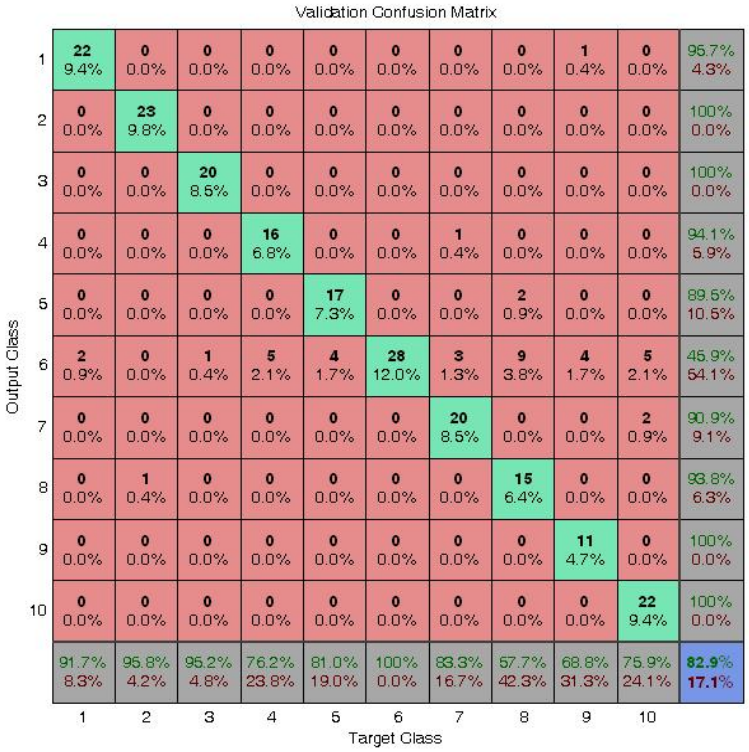

Figura 57 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de corrente caso RBF.

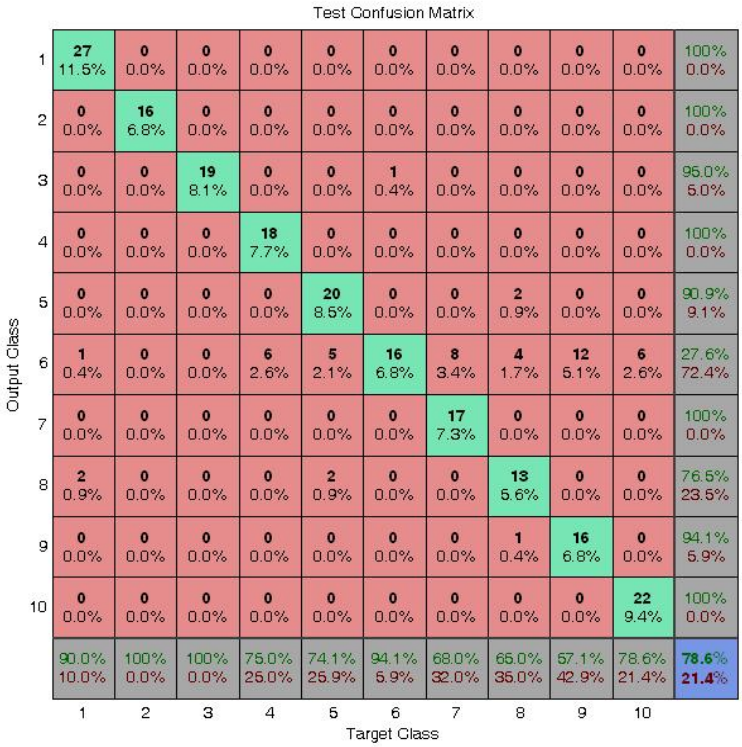

Figura 58 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de corrente caso RBF.

7.1.2.2 Parâmetro da Fundamental de Tensão

O melhor treinamento convergiu em 480 épocas com o MSE de 0.0031 como mostrado na Figura 59 e o melhor desempenho obtido no conjunto de treinamento que foi realizado com o número total de 702 registros foram: 688 acertos com porcentagem de 98.0% e 14 erros com porcentagem de 2.0%. A matriz de confusão do treinamento pode ser vista na Figura 60.

O conjunto de validação foi avaliado com 234 registros e obteve 177 acertos com porcentagem de 75.6% e 55 erros com porcentagem de 24.4% e o conjunto de teste também foi avaliado com 234 registros e obteve 179 acertos com porcentagem de 76.5% e 52 erros com porcentagem de 23.5%. A matriz de confusão da validação pode ser vista na Figura 61.

Na matriz de confusão do teste Figura 62, o classificador estimou a maioria das classes de entradas como sendo a classes de saídas 5 (BCG).

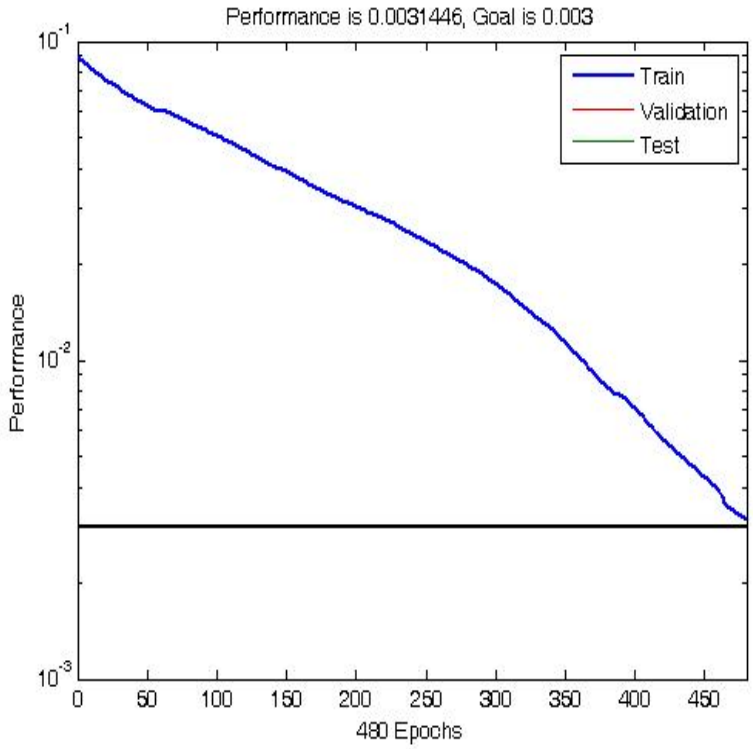

Figura 59 - Treinamento da identificação dos tipos das faltas caso RBF.

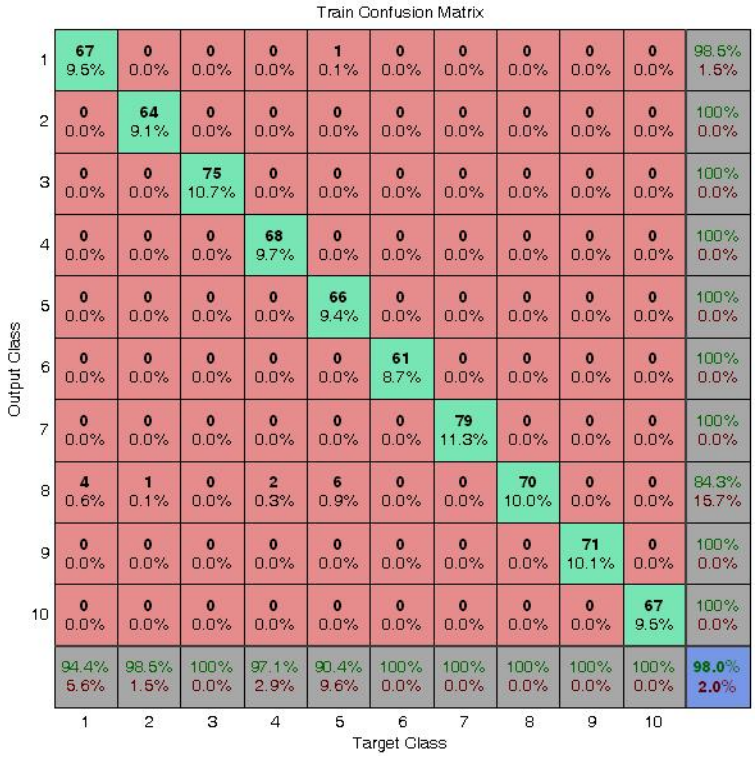

Figura 60 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de tensão caso RBF.

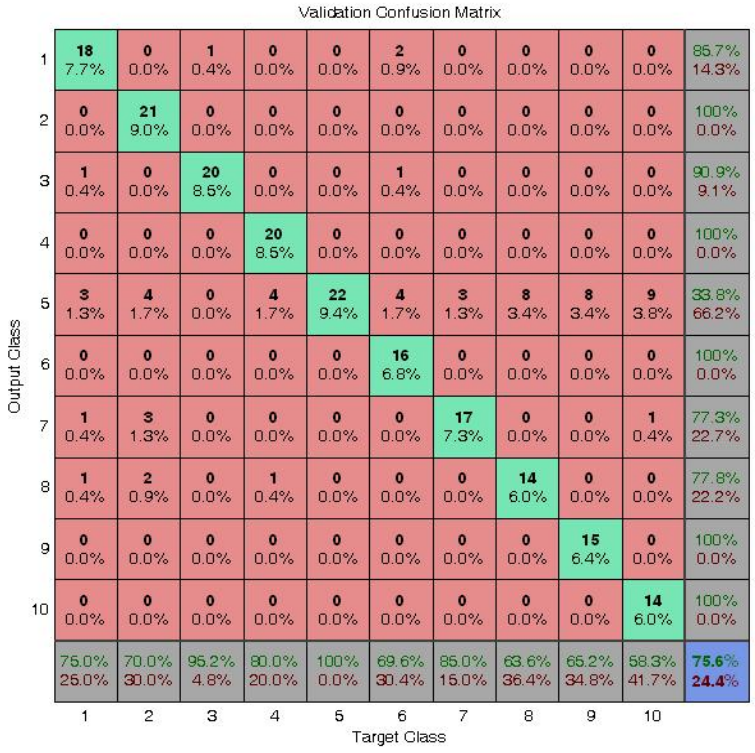

Figura 61 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de tensão caso RBF.

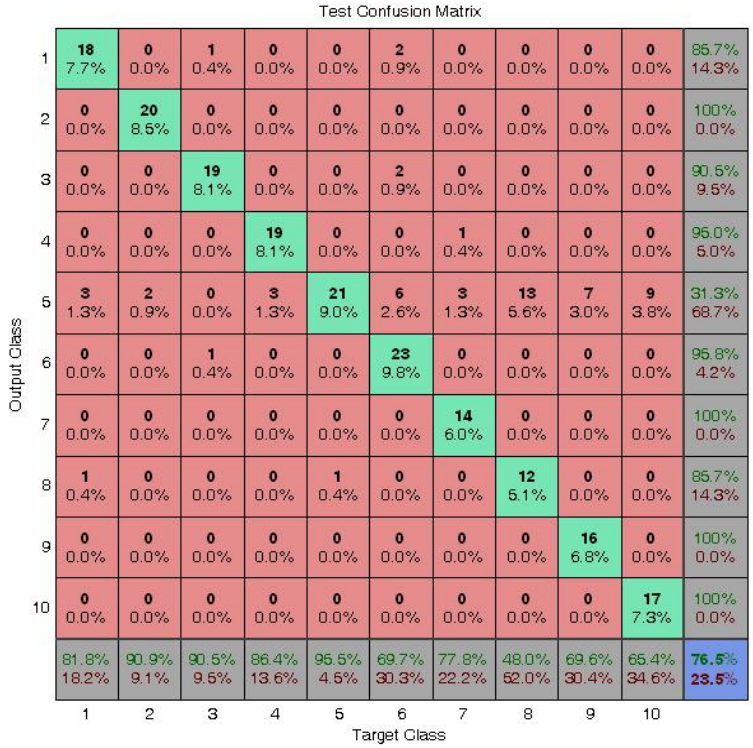

Figura 62 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de tensão caso RBF.

7.1.3 Terceira Abordagem - Identificação caso PNN

Nesta abordagem também optou-se por utilizar o valor de *SPREAD* igual a 15. Em geral, essa rede neural tem o tempo de treinamento mais rápido que o das outras arquiteturas, mas em contra-partida elas precisam de mais neurônios em suas camadas escondidas, assim é preciso um número maior de padrões para o treinamento [17, 27].

7.1.3.1 Parâmetro da Fundamental de Corrente

O melhor desempenho obtido no conjunto de treinamento que foi realizado com o número total de 702 registros foram: 674 acertos com porcentagem de 96.0% e 28 erros com porcentagem de 4.0%. A matriz de confusão do treinamento pode ser vista na Figura 63.

O conjunto de validação foi avaliado com 234 registros e obteve 208 acertos com porcentagem de 88.9% e 26 erros com porcentagem de 11.1%. A matriz de confusão da validação pode ser vista na Figura 64.

O conjunto de teste também foi avaliado com 234 registros e obteve 204 acertos com porcentagem de 87.2% e 30 erros com porcentagem de 12.8%. O classificador estimou as classes de entradas 4 (AB), 6 (ACG), 8 (CG) e 9 (BG) como sendo a classe de saída 5 (BCG) e a classe de entrada 5 (BCG) como sendo as classes de saídas 1 (ABC), 8 (CG) e 9 (BG), conforme mostrado na Figura 65.

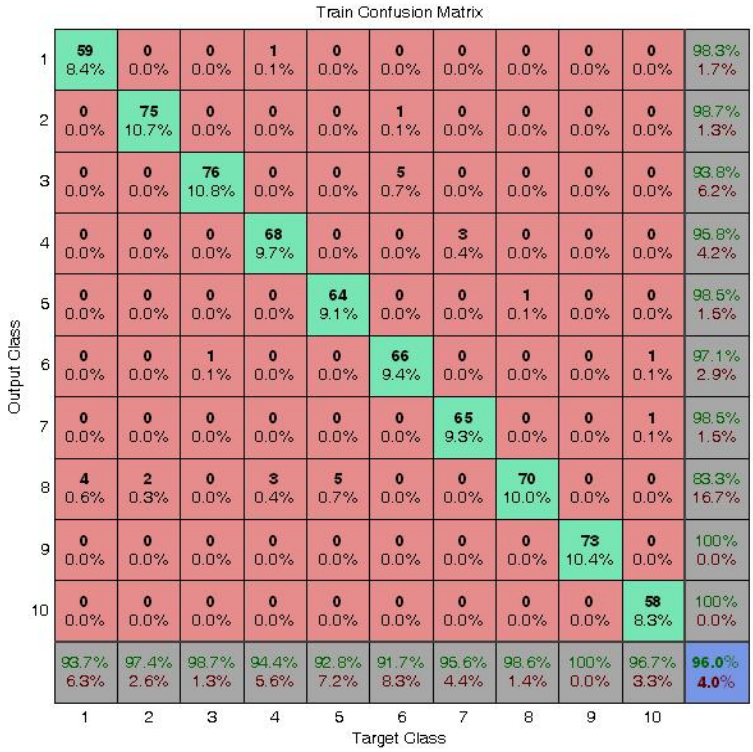

Figura 63 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de corrente caso PNN.

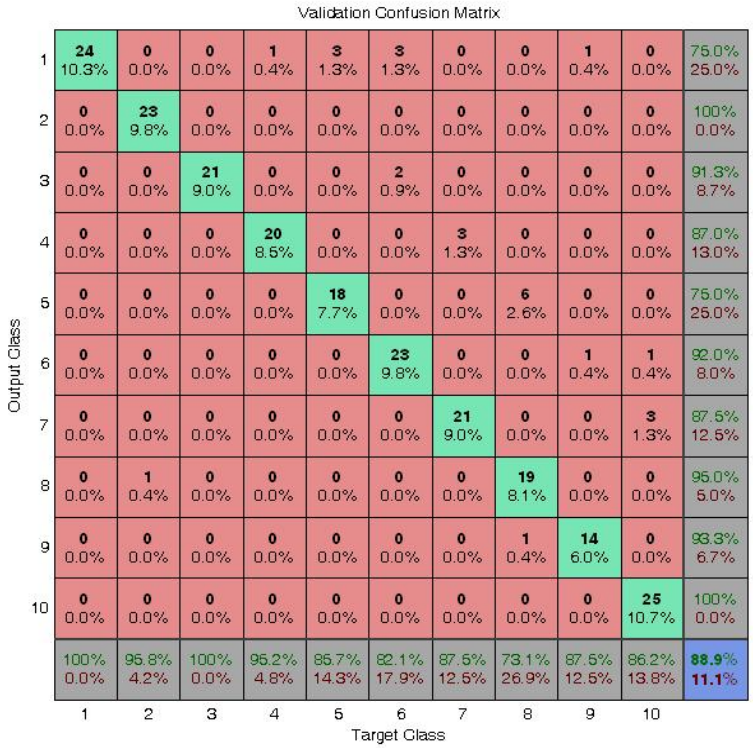

Figura 64 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de corrente caso PNN.

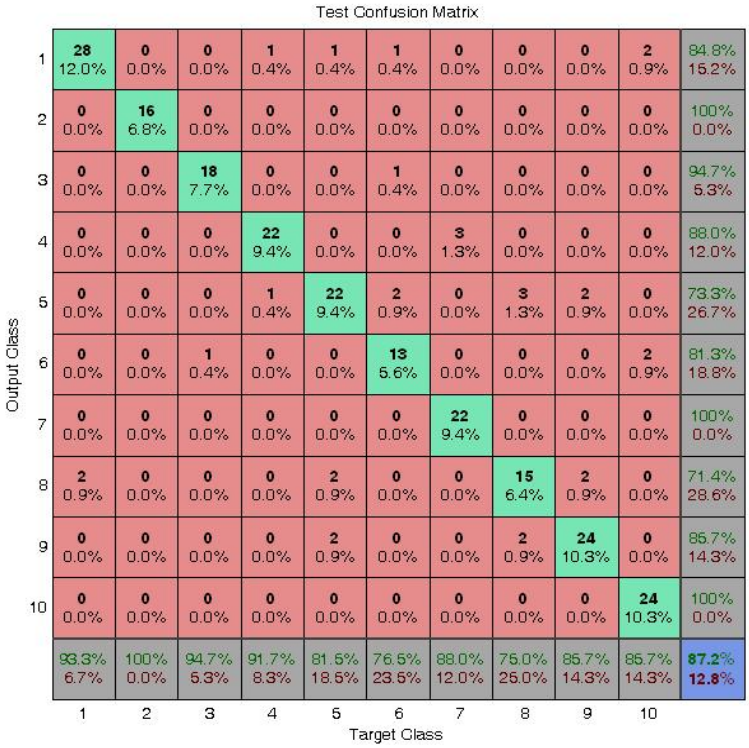

Figura 65 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de corrente caso PNN.

7.1.3.2 Parâmetro da Fundamental de Tensão

O melhor desempenho obtido no conjunto de treinamento que foi realizado com o número total de 702 registros foram: 689 acertos com porcentagem de 98.1% e 13 erros com porcentagem de 1.9%. A matriz de confusão do treinamento pode ser vista na Figura 66.

O conjunto de validação foi avaliado com 234 registros e obteve 206 acertos com porcentagem de 88.0% e 28 erros com porcentagem de 12.0%. A matriz de confusão da validação pode ser vista na Figura 67.

O conjunto de teste também foi avaliado com 234 registros e obteve 203 acertos com porcentagem de 86.8% e 31 erros com porcentagem de 13.2%. O classificador estimou a maioria das classes de entradas como sendo a classe de saída 1 (ABC) e a classe de entrada 1 (ABC) como sendo a classes de saídas 3 (AC), 4 (AB), 5 (BCG) e 8 (CG), conforme mostrado na Figura 68.

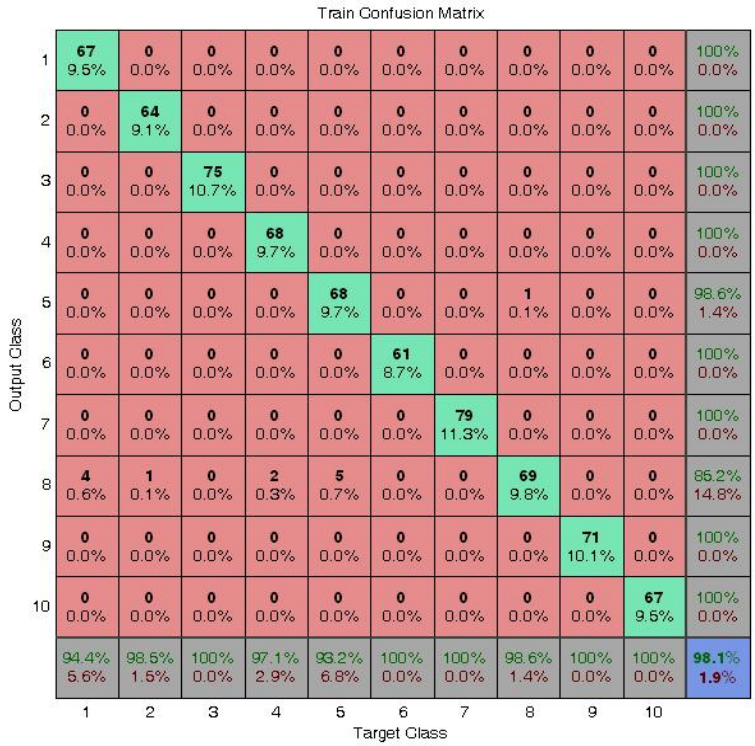

Figura 66 - Matriz de Confusão de Treinamento da RNA 1 usando os parâmetros de tensão caso PNN.

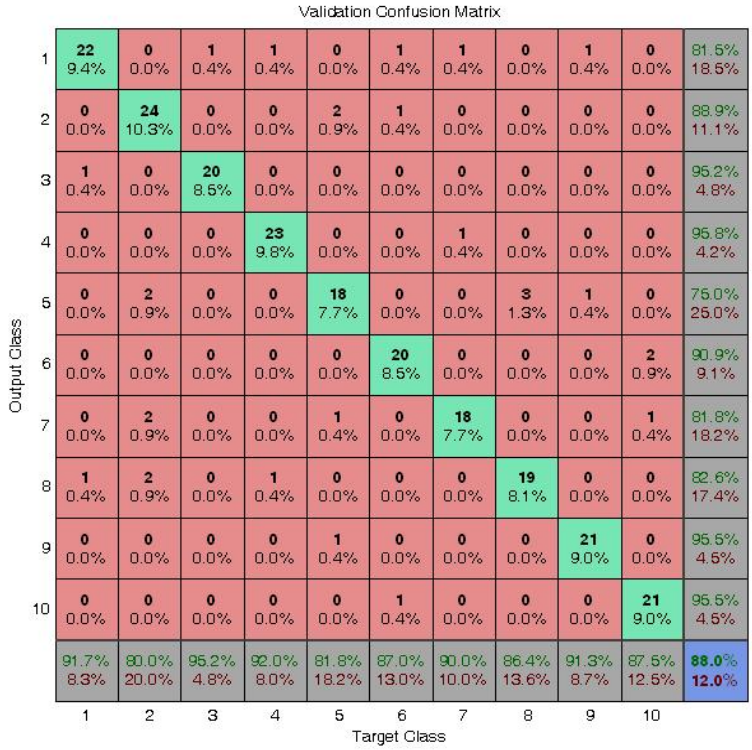

Figura 67 - Matriz de Confusão da validação da RNA 1 usando os parâmetros de tensão caso PNN.

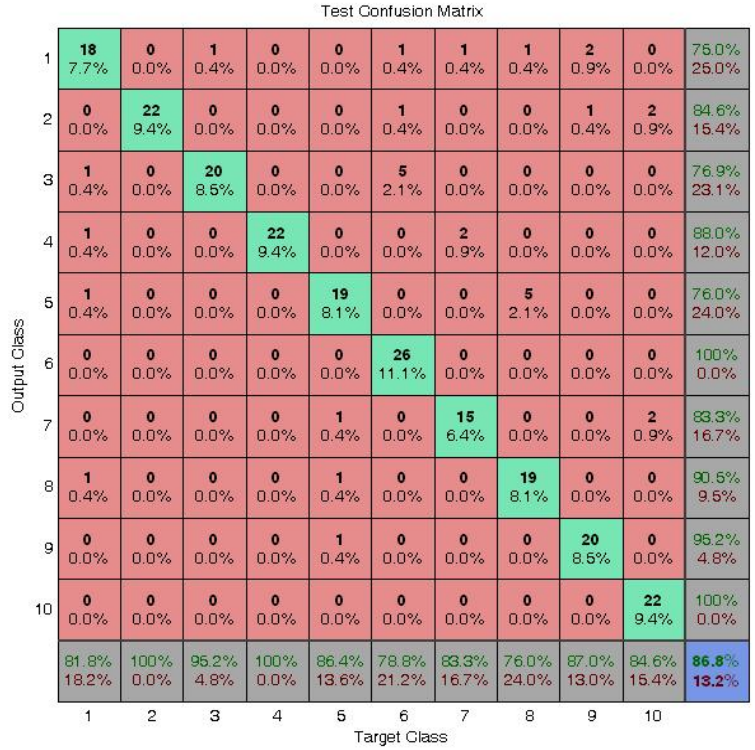

Figura 68 - Matriz de Confusão do teste da RNA 1 usando os parâmetros de tensão caso PNN.

7.1.4 Comparação dos Resultados da Identificação

O objetivo desta subseção é comparar o desempenho obtido pelos classificadores descritos nas 3 subseções anteriores. A comparação realizada entre os classificadores é uma comparação idônea, pois os classificadores foram treinados e testados com os mesmos dados originais. A avaliação da qualidade de um classificador é de suma importância para que se possa estimar quanto este classificador é adequado para a classificação de futuros exemplos.

Os parâmetros utilizados para a avaliação comparativa são: o erro médio quadrático, o erro de classificação e a acurácia, obtidos nos treinamentos, validações e testes de cada um dos classificadores já mencionados acima.

A precisão de um classificador é dada pela razão entre o número de erros ocorridos durante a classificação realizada em um conjunto de exemplos e a quantidade total de casos. A equação (10) define a acurácia (Ac), que é a capacidade de classificar corretamente os exemplos e a equação (11) define o erro de classificação (EC), ou seja, o percentual de exemplos que foram classificados de forma incorreta.

$$Ac = 100 * \frac{Numero\ de\ acertos}{Numero\ total\ de\ casos} \tag{10}$$

$$EC = 100 * \frac{Numero\ de\ erros}{Numero\ total\ de\ casos} \tag{11}$$

Com a aplicação de diferentes classificadores descritos nas seções anteriores para o mesmo problema, a Tabela 12 apresenta o desempenho obtido para a acurácia do treinamento, validação e teste.

O treinamento obteve um desempenho superior a 92% para todos os métodos dos parâmetros de corrente e tensão, demostrando a eficiência da generalização das redes neurais.

Na validação os parâmetros de corrente tiveram um desempenho acima de 82% em todos os métodos e o desempenho dos parâmetros de tensão variaram entre 75.6% e 89.3%, demostrando a baixa capacidade de avaliar a generalização das redes em comparação aos

parâmetros de corrente.

No teste os parâmetros de corrente tiveram um desempenho acima de 78% em todos os métodos e o desempenho dos parâmetros de tensão variaram entre 76.5% e 88.9%. Os teste dos classificadores não foram satisfatórios para os parâmetros de tensão comparados como os parâmetros de corrente.

Tabela 12 - Desempenho das RNA 1 utilizando diferentes métodos.

Parâmetros	**Métodos**	**Acurácia Treinamento**	**Acurácia Validação**	**Acurácia Teste**
Corrente	MLP (LM)	98.6 %	94.4 %	94.9 %
Corrente	MLP (RProp)	95.9 %	87.6 %	91.0 %
Corrente	RBF	98.1 %	82.9 %	78.6 %
Corrente	PNN	96.0 %	88.9 %	87.2 %
Tensão	MLP (LM)	96.7 %	89.3 %	88.5 %
Tensão	MLP (RProp)	92.0 %	79.5 %	88.9 %
Tensão	RBF	98.0 %	75.6 %	76.5 %
Tensão	PNN	98.1 %	88.0 %	86.8 %

Pode ser observado na Tabela 13 que o erro de classificação nos testes foram melhores para os parâmetros de corrente, que variaram entre 5.1% e 21.4%, do que os parâmetros de tensão, que variaram entre 11.1% e 23.5%.

Tabela 13 - Desempenho das RNA 1 utilizando diferentes métodos.

Parâmetros	**Métodos**	**EQM Treinamento**	**EQM Validação**	**EQM Teste**	**EC no Teste**
Corrente	MLP (LM)	0.0017	0.0082	0.0074	5.1 %
Corrente	MLP (RProp)	0.0059	0.0168	0.0137	9.0 %
Corrente	RBF	0.0030	0.0243	0.0308	21.4 %
Corrente	PNN	0.0080	0.0222	0.0256	12.8 %
Tensão	MLP (LM)	0.0044	0.0181	0.0217	11.5 %
Tensão	MLP (RProp)	0.0135	0.0301	0.0215	11.1 %
Tensão	RBF	0.0030	0.2089	0.0378	23.5 %
Tensão	PNN	0.0037	0.0239	0.0265	13.2 %

7.2 **Localização dos instantes de incidências das faltas**

7.2.1 Primeira Abordagem - Localização caso MLP

Nesta abordagem também foi criada uma rede neural MLP com 27 entradas, 2 camadas intermediárias com o número dos neurônios escolhidos de forma aleatória e 13 saídas que correspondem às localidades onde as faltas ocorreram, conforme descrito no capítulo 6, seção 6.3. Chegou-se à situação onde não se tornava necessário aumentar o número de neurônios das camadas ocultas, pois a redução do erro de classificação tornou-se irrisória.

7.2.1.1 Parâmetro da Fundamental de Corrente

O melhor treinamento convergiu em 32 épocas com o MSE de $19.16x10^{-3}$ como mostrado na Figura 69 e o melhor desempenho obtido no conjunto de treinamento que foi realizado com o número total de 702 registros foram: 609 acertos com porcentagem de 86.8% e 93 erros com porcentagem de 13.2% para o algoritmo de treinamento Levenberg-Marquardt. Já para o algoritmo Resiliente foram: 654 acertos com porcentagem de 93.2% e 48 erros com porcentagem de 6.8%. As matrizes de confusões do treinamento podem ser vistas na Figura 71 e na Figura 72.

O conjunto de validação foi avaliado com 234 registros e obteve 186 acertos com porcentagem de 79.5% e 48 erros com porcentagem de 20.5% para o algoritmo de treinamento Levenberg-Marquardt. O algoritmo Resiliente obteve 188 acertos com porcentagem de 80.3% e 46 erros com porcentagem de 19.7%. As matrizes de confusões da validação podem ser vistas na Figura 73 e na Figura 74.

O conjunto de teste também foi avaliado com 234 registros e obteve 188 acertos com porcentagem de 80.3% e 46 erros com porcentagem de 19.7% para o algoritmo de treinamento Levenberg-Marquardt e para o algoritmo Resiliente obteve 200 acertos com porcentagem de 85.5% e 34 erros com porcentagem de 14.5%.

Na matriz de confusão Figura 75, o classificador estimou a classe de entrada 11 (P03) como sendo as classes de saídas 1 (P13), 5 (P09), 6 (P08), 7 (P07), 10 (P04), 12 (P02), e 13 (P01) e as classes de entradas 6 (P08), 10 (P04), 11 (P03) e 13 (P01) como sendo a classe saída 12 (P02).

Na matriz de confusão Figura 76, o classificador estimou as classes de entradas 5 (P09), 7 (P07), 8 (P06) e 12 (P02) como sendo a classe de saída 4 (P10).

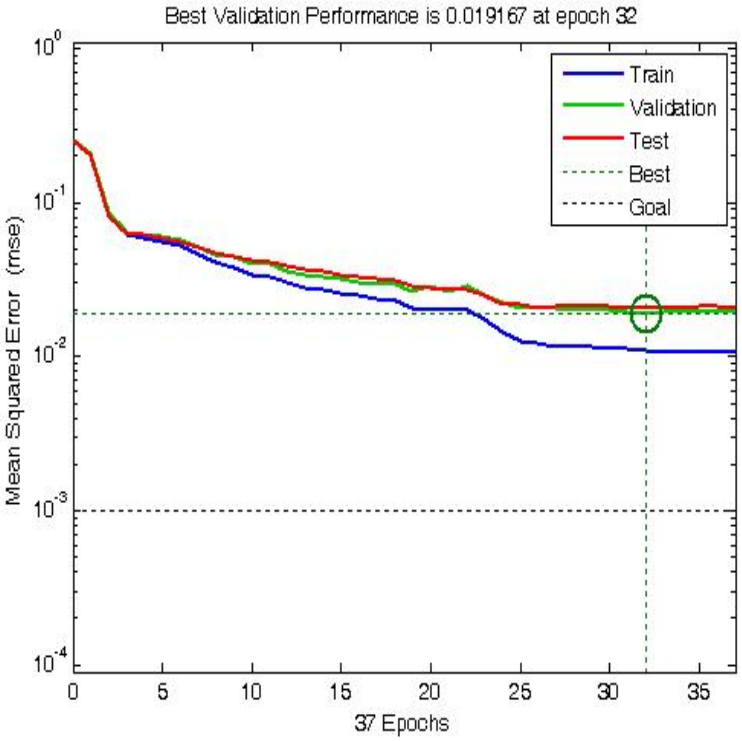

Figura 69 - Treinamento da localização do instante de incidência das faltas caso Levenberg-Marquardt.

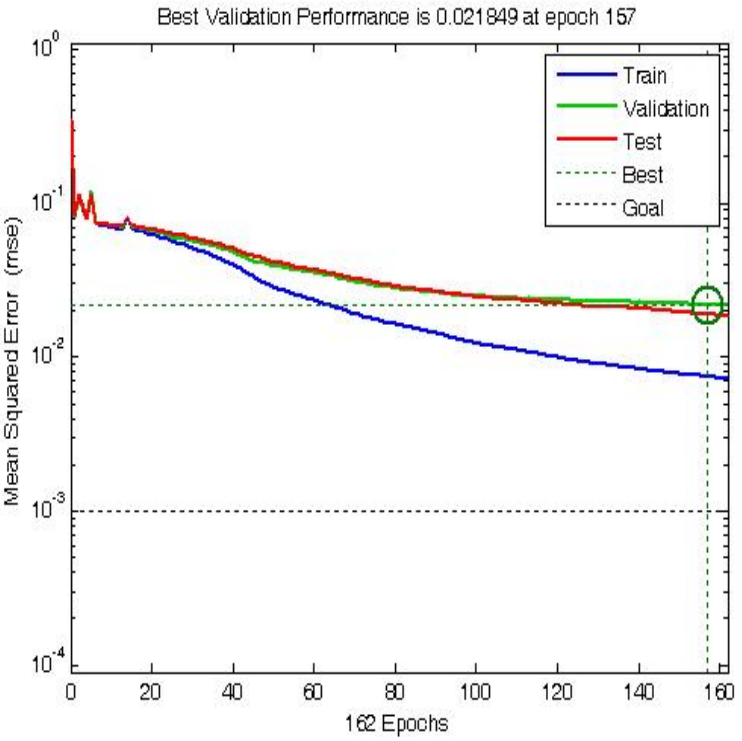

Figura 70 - Treinamento da localização do instante de incidência das faltas caso Resilient.

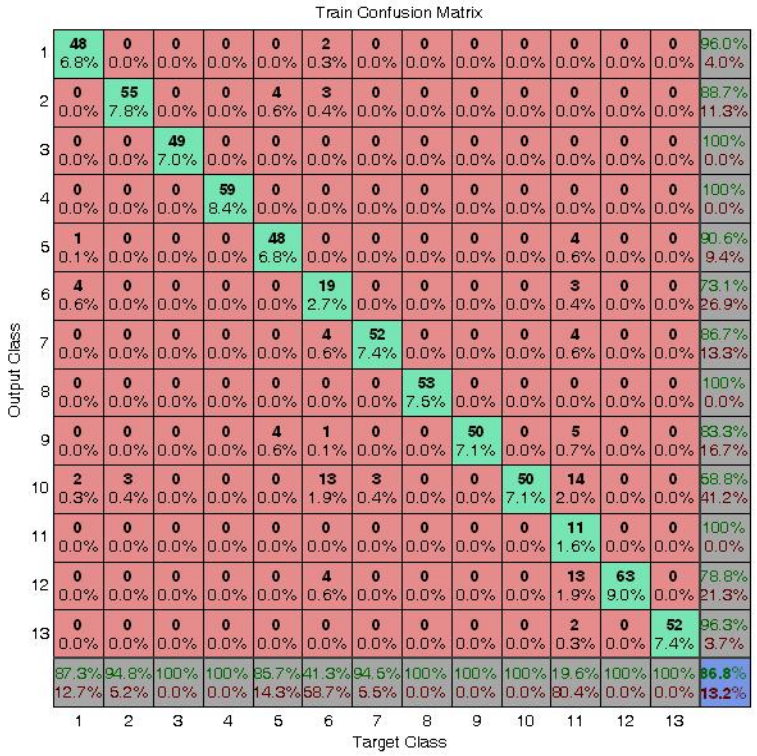

Figura 71 - Matriz de Confusão de Treinamento da RNA 2 usando os parâmetros de corrente caso Levenberg-Marquardt.

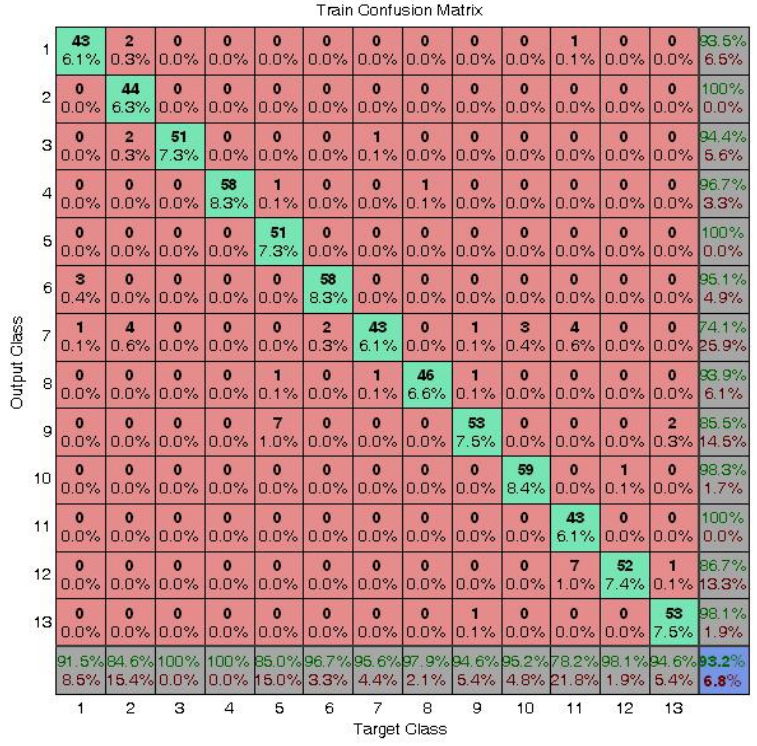

Figura 72 - Matriz de Confusão de Treinamento da RNA 2 usando os parâmetros de corrente caso Resilient.

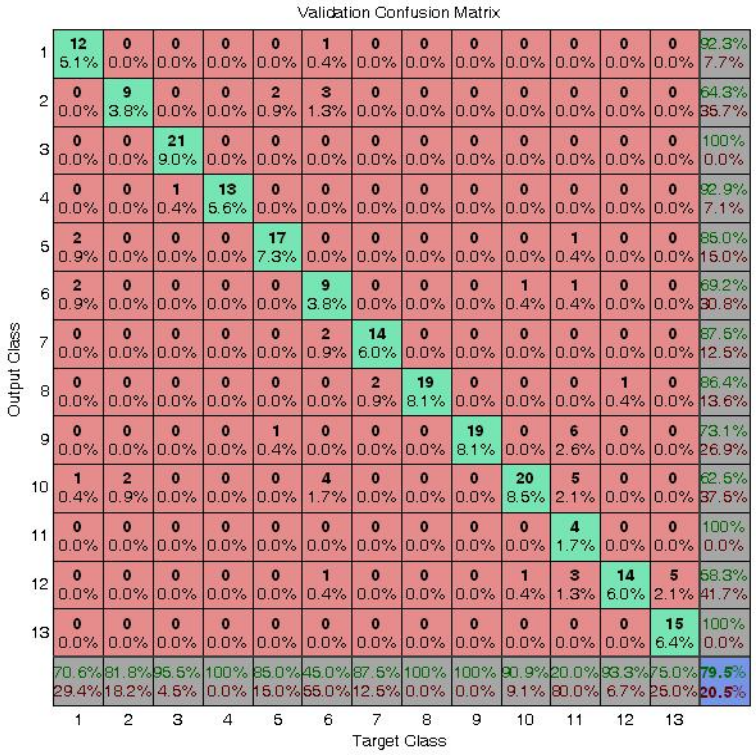

Figura 73 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de corrente caso Levenberg-Marquardt.

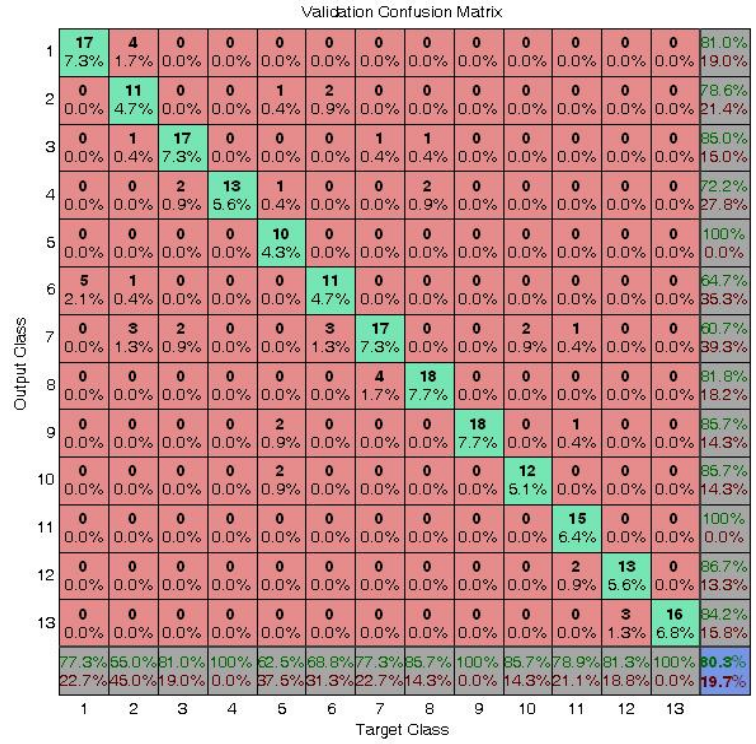

Figura 74 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de corrente caso Resilient.

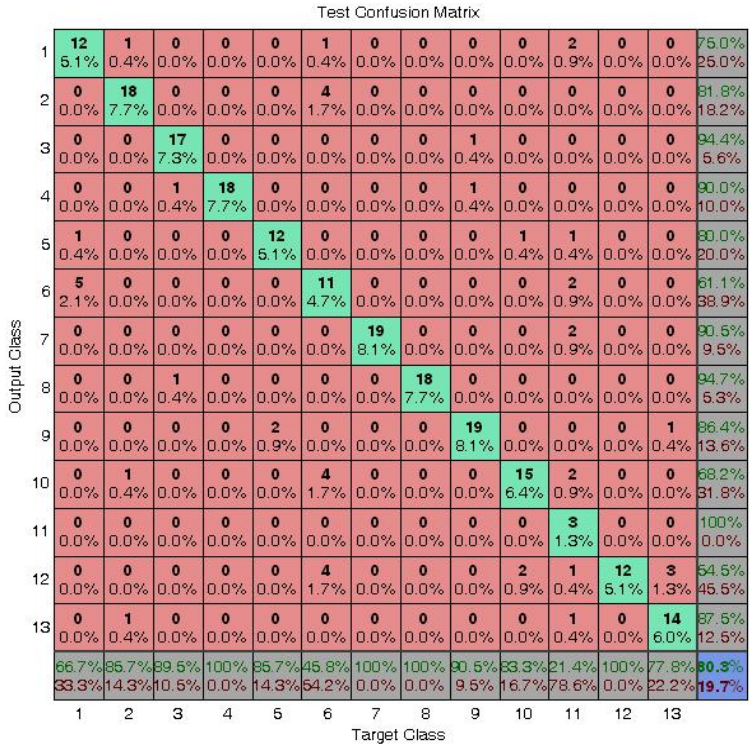

Figura 75 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de corrente caso Levenberg-Marquardt.

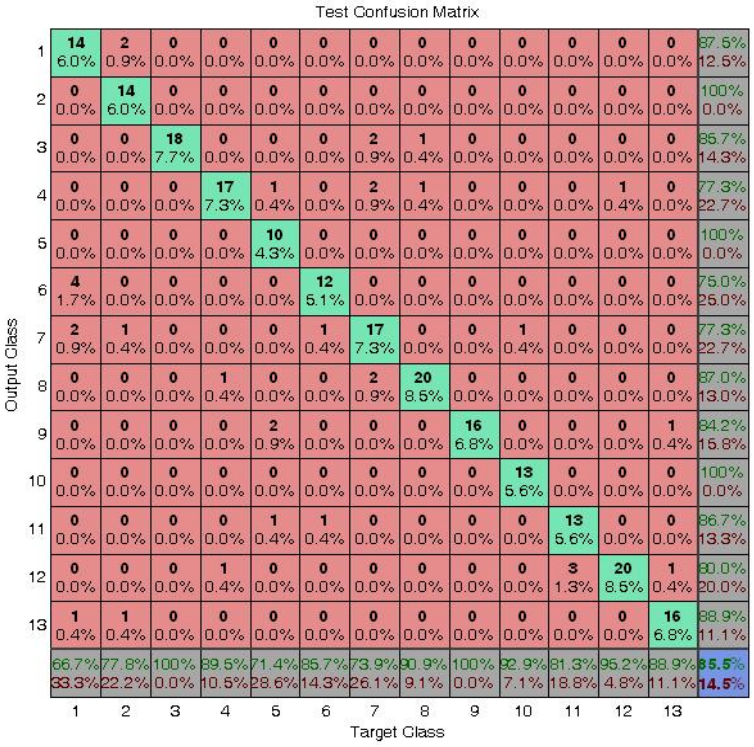

Figura 76 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de corrente caso Resilient.

7.2.1.2 Parâmetro da Fundamental de Tensão

O melhor treinamento convergiu em 27 épocas com o MSE de $25.50x10^{-3}$ como mostrado na Figura 77 e o melhor desempenho obtido no conjunto de treinamento que foi realizado com o número total de 702 registros foram: 581 acertos com porcentagem de 82.8% e 121 erros com porcentagem de 17.2% para o algoritmo de treinamento Levenberg-Marquardt. Já para o algoritmo Resiliente foram: 599 acertos com porcentagem de 85.3% e 103 erros com porcentagem de 14.7%. As matrizes de confusões do treinamento podem ser vistas na Figura 79 e na Figura 80.

O conjunto de validação foi avaliado com 234 registros e obteve 176 acertos com porcentagem de 75.2% e 58 erros com porcentagem de 24.8% para o algoritmo de treinamento Levenberg-Marquardt. O algoritmo Resiliente obteve 178 acertos com porcentagem de 76.1% e 56 erros com porcentagem de 23.9%. As matrizes de confusões da validação podem ser vistas na Figura 81 e na Figura 82.

O conjunto de teste também foi avaliado com 234 registros e obteve 179 acertos com porcentagem de 76.5% e 55 erros com porcentagem de 23.5% para o algoritmo de treinamento Levenberg-Marquardt e para o algoritmo Resiliente obteve 185 acertos com porcentagem de 79.1% e 49 erros com porcentagem de 20.9%.

Na matriz de confusão Figura 83, o classificador estimou a classe de entrada 1 (P13) como sendo as classes de saídas 2 (P12), 3 (P11), 5 (P09), 6 (P08) e 7 (P07), a classe de entrada 8 (P06) como sendo as classes de saídas 4 (P), 7 (P07), 9 (P05), 12 (P02) e 13 (P01) e a maioria das classes de entradas como sendo as classes de saídas 6 (P08) e 7 (P07).

Na matriz de confusão Figura 84, o classificador estimou a classe de entrada 7 (P07) como sendo as classes de saídas 1 (P13), 3 (P11), 5 (P09) e 8 (P06) e a maioria das classe de entradas como sendo as classes de saídas 5 (P09) e 8 (P06).

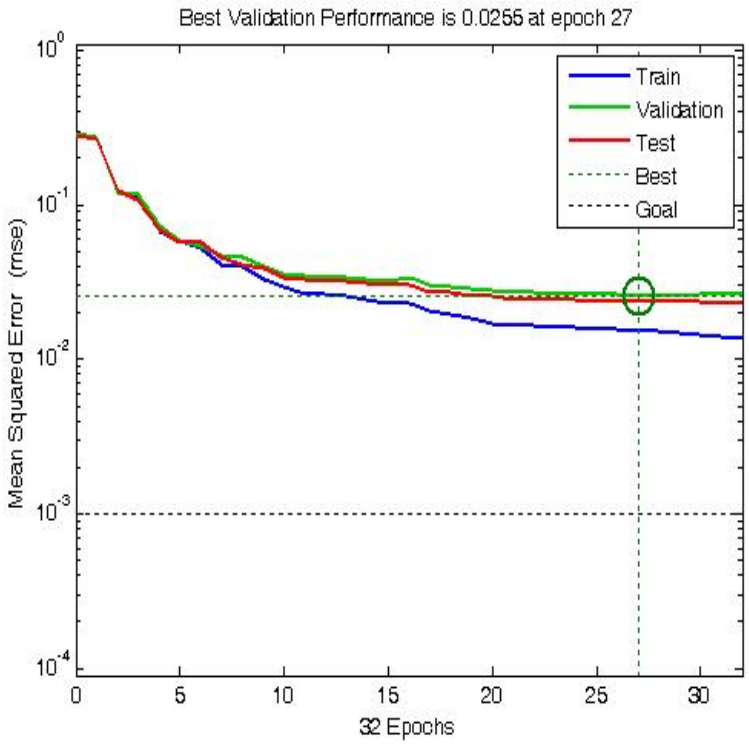

Figura 77 - Treinamento da localização do instante de incidência das faltas caso Levenberg-Marquardt.

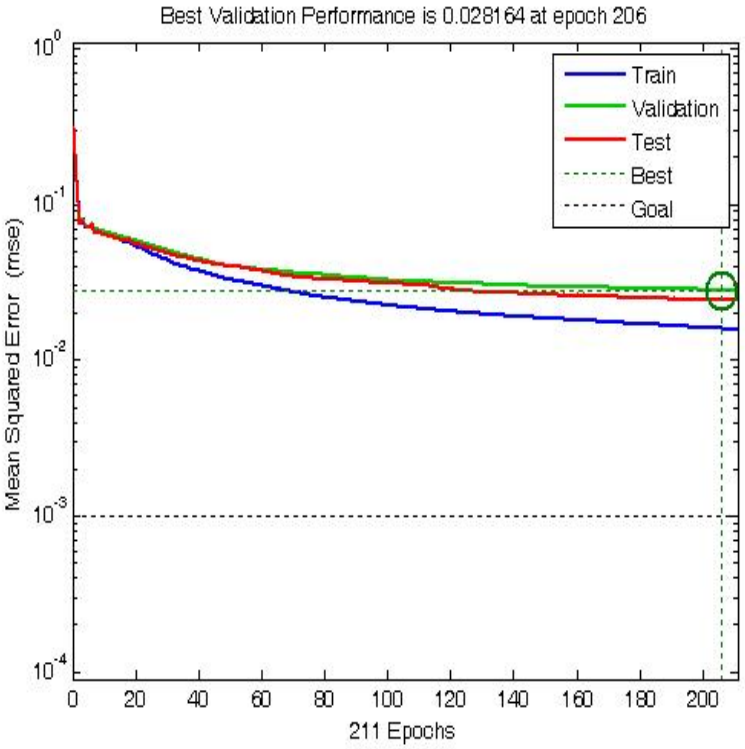

Figura 78 - Treinamento da localização do instante de incidência das faltas caso Resilient.

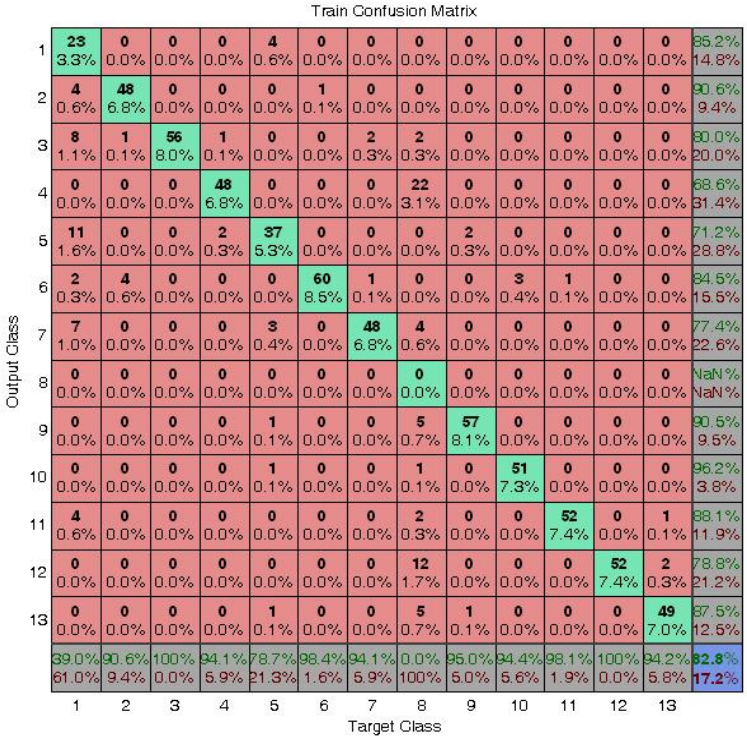

Figura 79 - Matriz de Confusão de Treinamento da RNA 2 usando os parâmetros de tensão caso Levenberg-Marquardt.

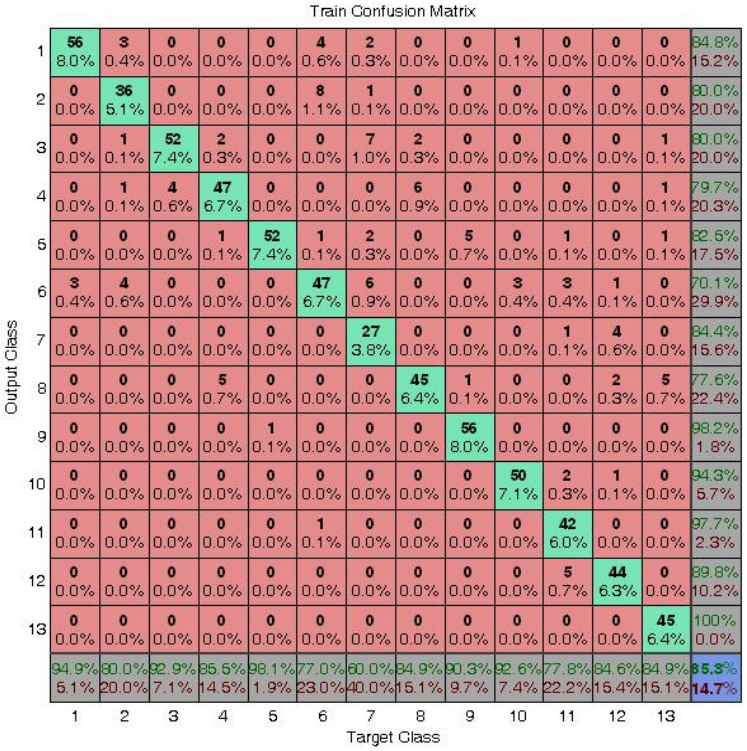

Figura 80 - Matriz de Confusão de Treinamento da RNA 2 usando os parâmetros de tensão caso Resilient.

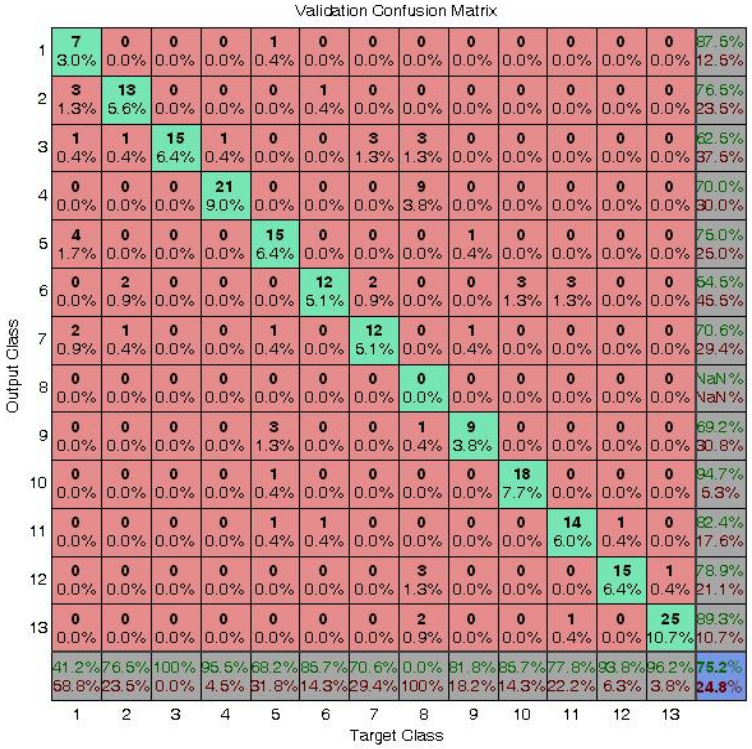

Figura 81 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de tensão caso Levenberg-Marquardt.

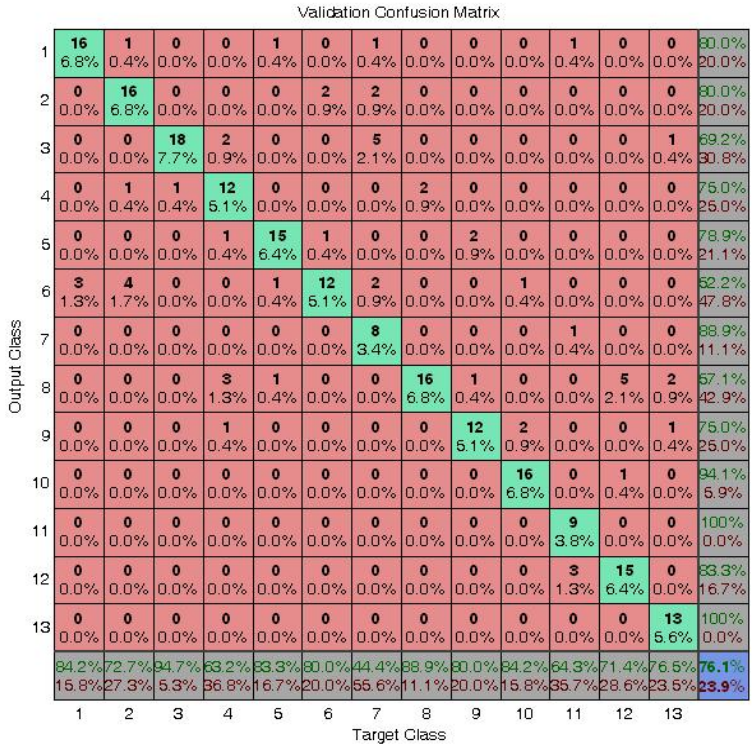

Figura 82 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de tensão caso Resilient.

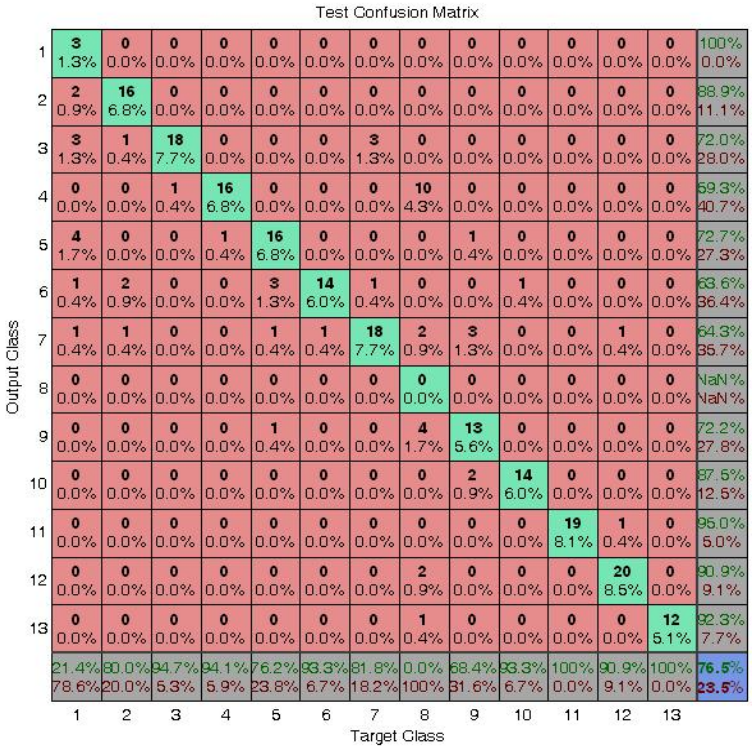

Figura 83 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de tensão caso Levenberg-Marquardt.

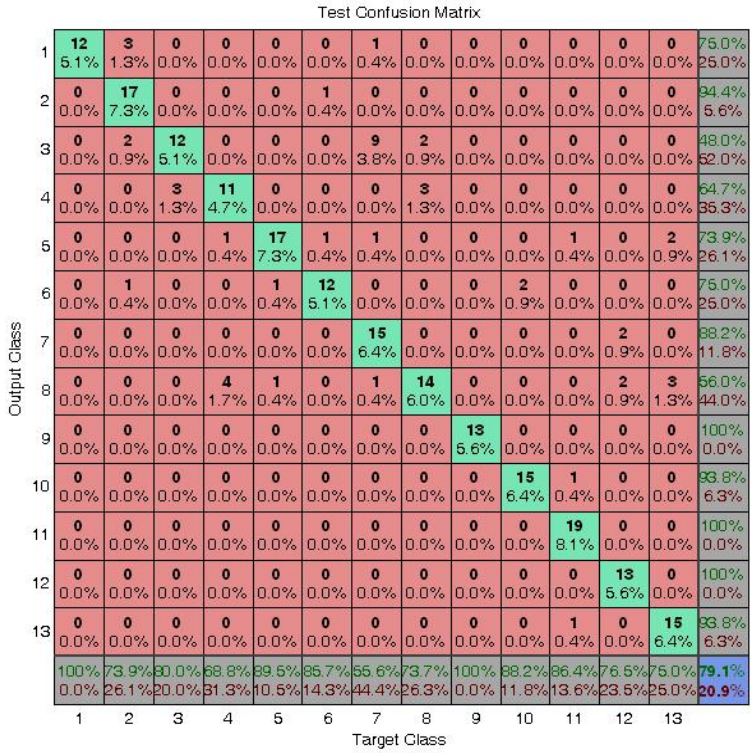

Figura 84 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de tensão caso Resilient.

7.2.2 Segunda Abordagem - Localização caso RBF

7.2.2.1 Parâmetro da Fundamental de Corrente

O melhor treinamento convergiu em 360 épocas com o MSE de 0.0033 como mostrado na Figura 85 e o melhor desempenho obtido no conjunto de treinamento que foi realizado com o número total de 702 registros foram: 688 acertos com porcentagem de 98.0% e 14 erros com porcentagem de 2.0%.

O conjunto de validação foi avaliado com 234 registros e obteve 184 acertos com porcentagem de 78.6% e 50 erros com porcentagem de 21.4% e o conjunto de teste também foi avaliado com 234 registros e obteve 177 acertos com porcentagem de 75.6% e 57 erros com porcentagem de 24.4%.

As matriz de confusão do treinamento e validação podem ser vistas na Figura 86 e na Figura 87. Na matriz de confusão do teste Figura 88, é possível observar que o classificador estimou a maioria das classes de entradas como sendo a classe de saída 6 (P08).

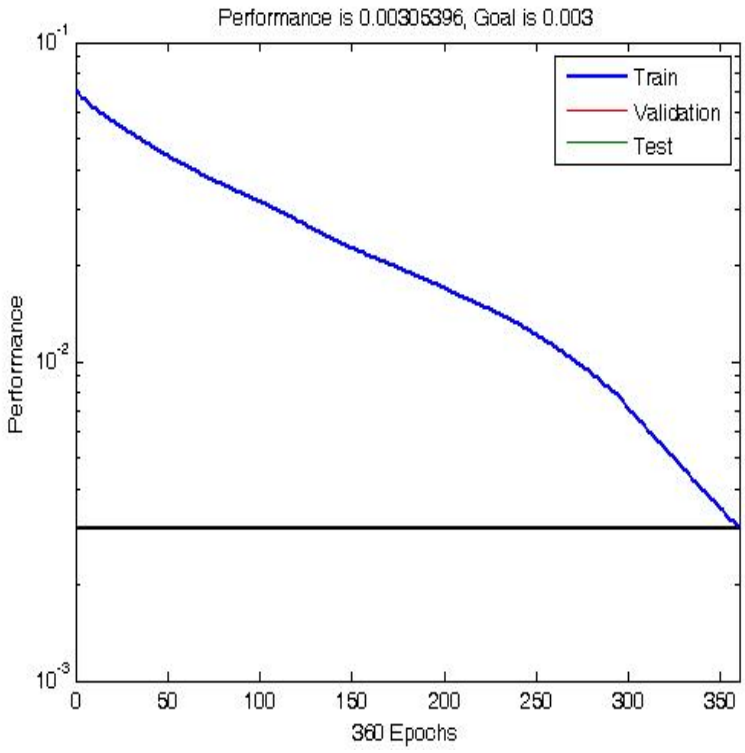

Figura 85 - Treinamento da localização do instante de incidência das faltas caso RBF.

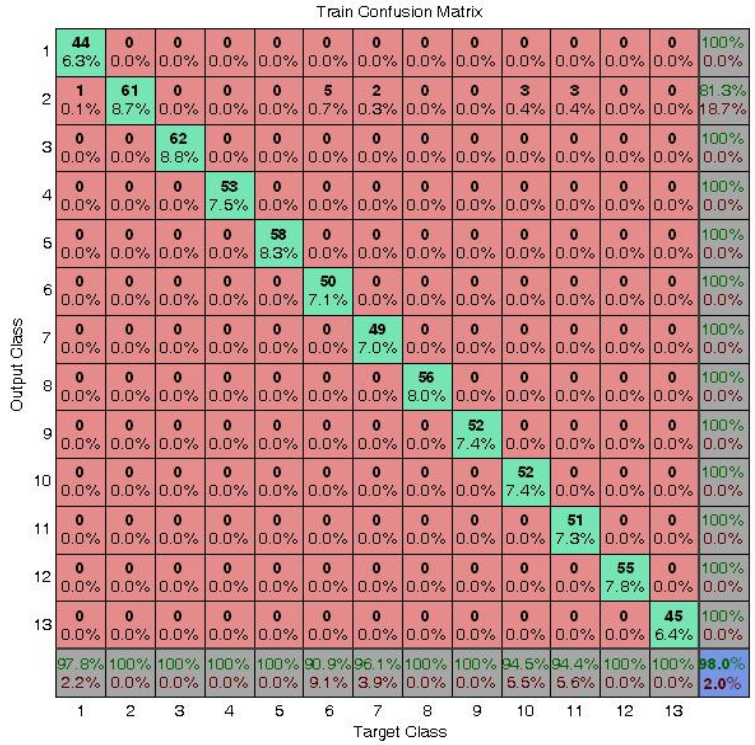

Figura 86 - Matriz de Confusão de Treinamento da RNA 2 usando os parâmetros de corrente caso RBF.

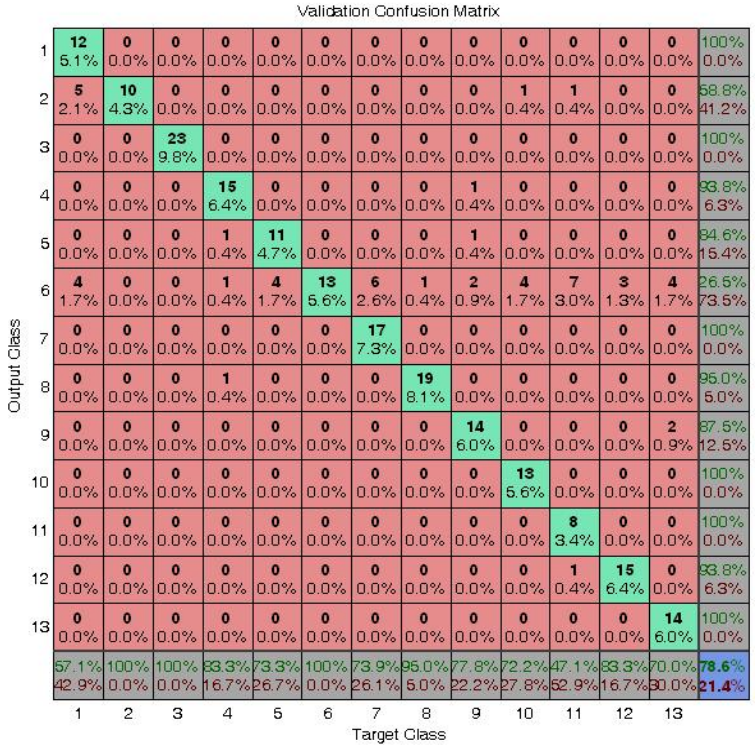

Figura 87 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de corrente caso RBF.

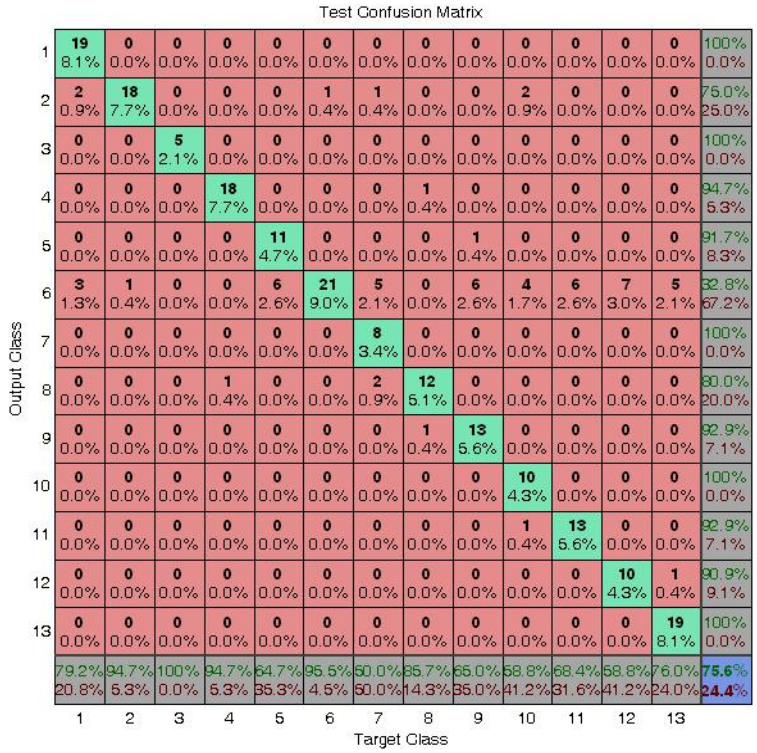

Figura 88 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de corrente caso RBF.

7.2.2.2 Parâmetro da Fundamental de Tensão

O melhor treinamento convergiu em 460 épocas com o MSE de 0.0033 como mostrado na Figura 89 e o melhor desempenho obtido no conjunto de treinamento que foi realizado com o número total de 702 registros foram: 686 acertos com porcentagem de 97.7% e 16 erros com porcentagem de 2.3%.

O conjunto de validação foi avaliado com 234 registros e obteve 179 acertos com porcentagem de 76.5% e 55 erros com porcentagem de 23.5% e o conjunto de teste também foi avaliado com 234 registros e obteve 177 acertos com porcentagem de 75.6% e 57 erros com porcentagem de 24.4%.

As matriz de confusão do treinamento e validação podem ser vistas na Figura 90 e na Figura 91. Na matriz de confusão do teste Figura 92, é possível observar que o classificador estimou a maioria das classes de entradas como sendo a classe de saída 8 (P06) e a classe de entrada 2 (P12) como sendo as classes de saídas 1 (P13), 3 (P11), 4 (P10), 6 (P08) e 8 (P06).

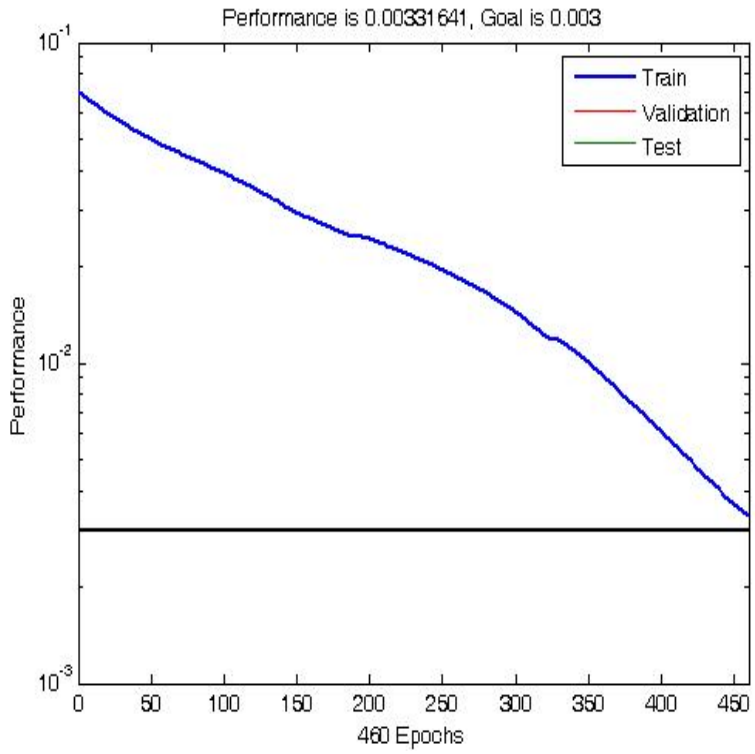

Figura 89 - Treinamento da localização do instante de incidência das faltas caso RBF.

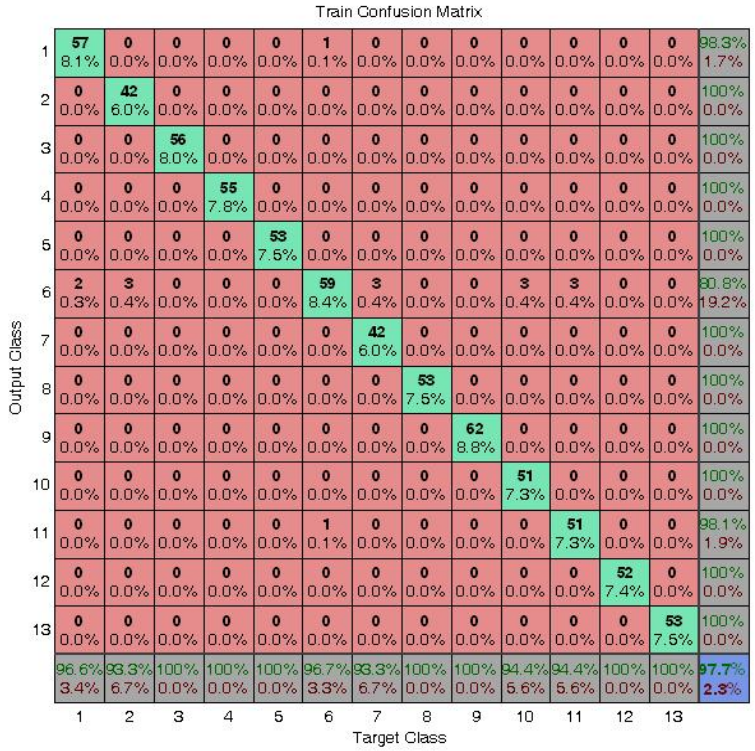

Figura 90 - Matriz de Confusão do treinamento da RNA 2 usando os parâmetros de tensão caso RBF.

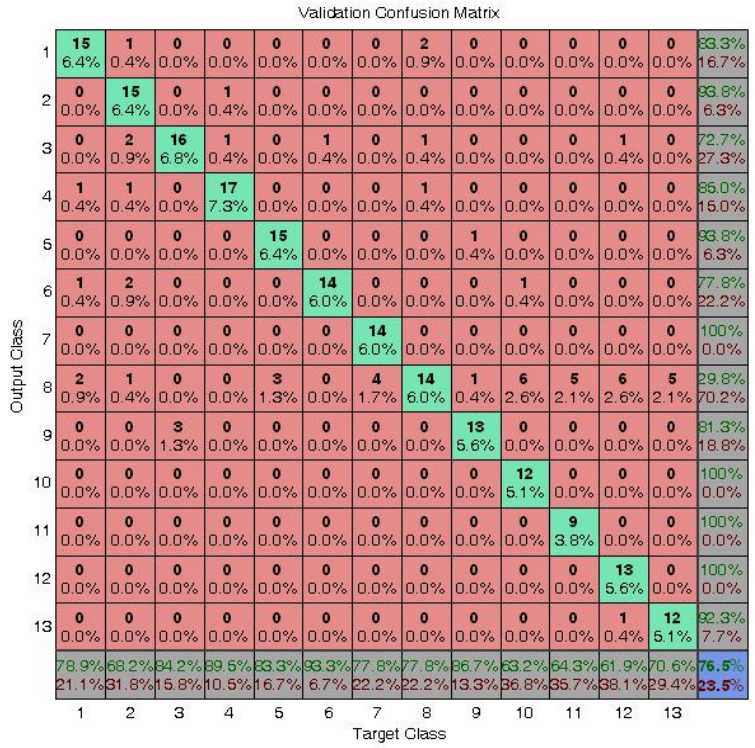

Figura 91 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de tensão caso RBF.

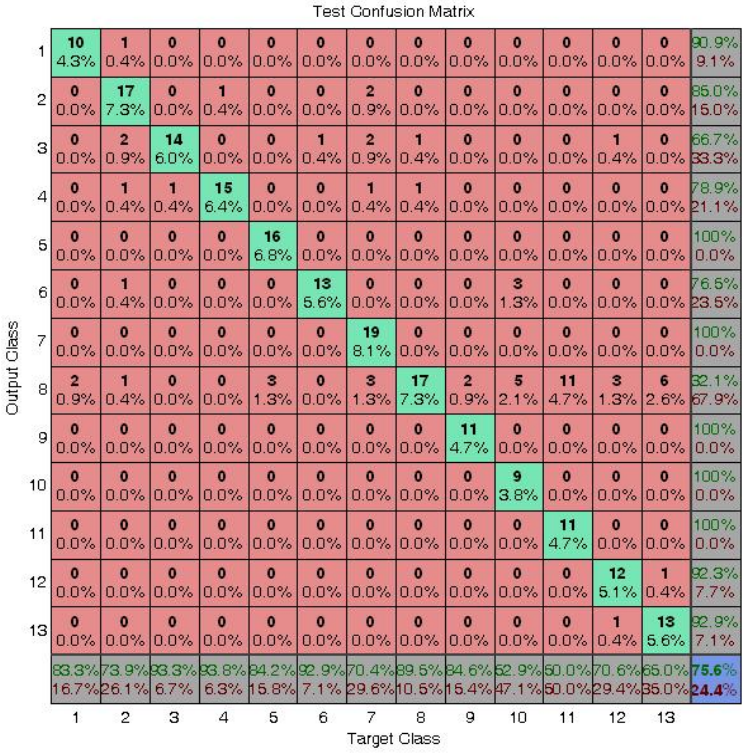

Figura 92 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de tensão caso RBF.

7.2.3 Terceira Abordagem - Localização caso PNN

7.2.3.1 Parâmetro da Fundamental de Corrente

O melhor desempenho obtido no conjunto de treinamento que foi realizado com o número total de 702 registros foram: 665 acertos com porcentagem de 94.7% e 37 erros com porcentagem de 5.3%.

O conjunto de validação foi avaliado com 234 registros e obteve 199 acertos com porcentagem de 85.0% e 35 erros com porcentagem de 15.0% e o conjunto de teste também foi avaliado com 234 registros e obteve 193 acertos com porcentagem de 82.5% e 41 erros com porcentagem de 17.5%.

As matriz de confusão do treinamento e validação podem ser vistas na Figura 93 e na Figura 94. Na matriz de confusão do teste Figura 95, é possível observar que o classificador estimou as classes de entradas 1 (P13), 6 (P08), 7 (P07) e 10 (P04) como sendo a classe de saída 2 (P12) e a classe de entrada 10 (P04) como sendo a classes de saídas 2 (P12), 5 (P09), 6 (P08) e 11 (P03).

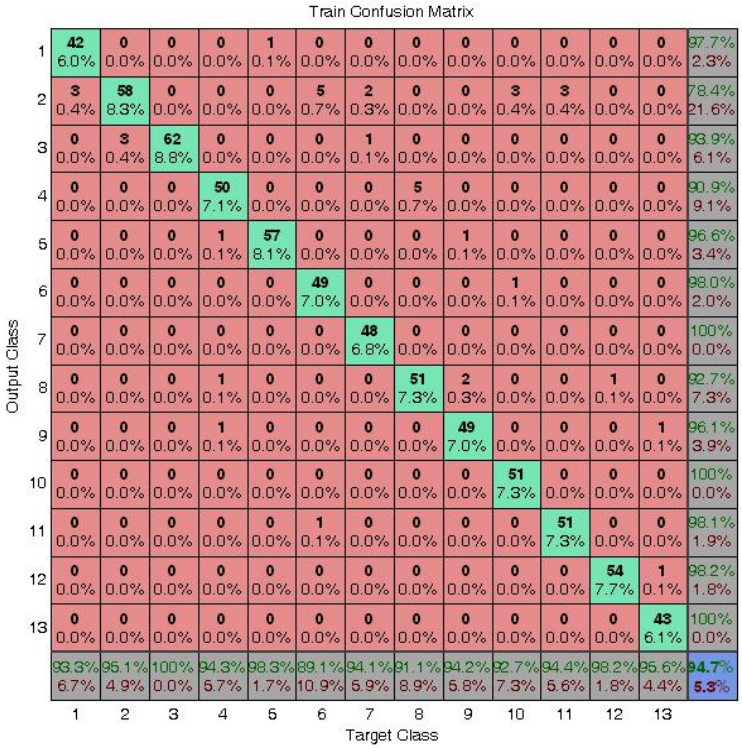

Figura 93 - Matriz de Confusão de Treinamento da RNA 2 usando os parâmetros de corrente caso PNN.

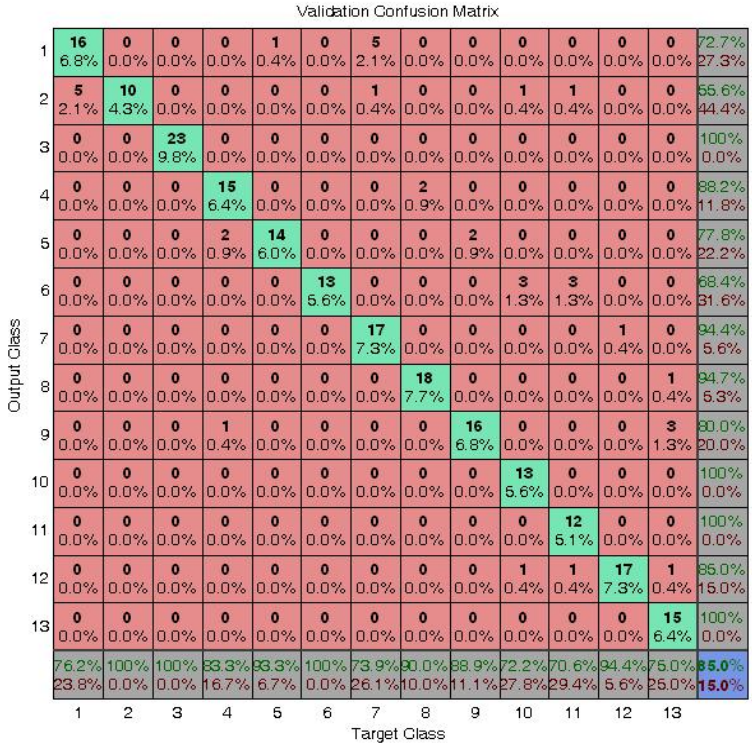

Figura 94 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de corrente caso PNN.

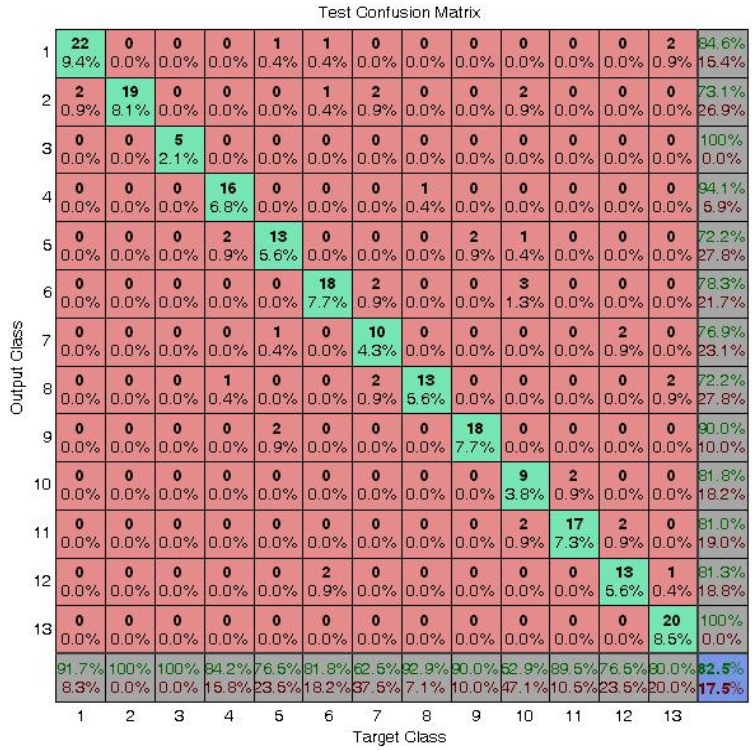

Figura 95 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de corrente caso PNN.

7.2.3.2 Parâmetro da Fundamental de Tensão

O melhor desempenho obtido no conjunto de treinamento que foi realizado com o número total de 702 registros foram: 687 acertos com porcentagem de 97.9% e 15 erros com porcentagem de 2.1%.

O conjunto de validação foi avaliado com 234 registros e obteve 198 acertos com porcentagem de 84.6% e 36 erros com porcentagem de 15.4% e o conjunto de teste também foi avaliado com 234 registros e obteve 196 acertos com porcentagem de 83.8% e 38 erros com porcentagem de 16.2%.

As matriz de confusão do treinamento e validação podem ser vistas na Figura 96 e na Figura 97. Na matriz de confusão do teste Figura 98, é possível observar que o classificador estimou a classe de entrada 7 (P07) como sendo as classes de saídas 2 (P12), 3 (P11), 4 (P10), 8 (P06) e 11 (P03) e a maioria das classes de entradas como sendo as classes de saídas 3 (P11) e 4 (P10).

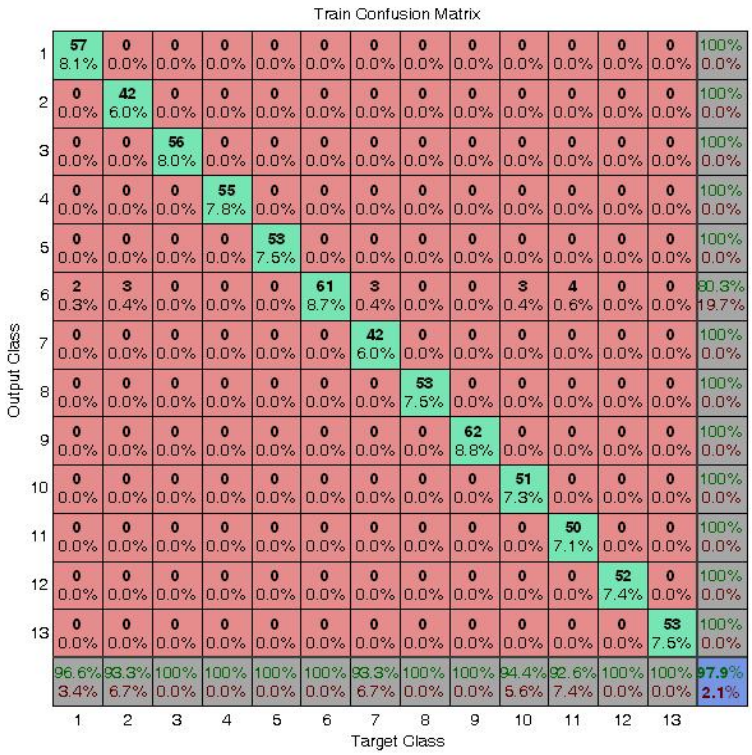

Figura 96 - Matriz de Confusão de Treinamento da RNA 2 usando os parâmetros de tensão caso PNN.

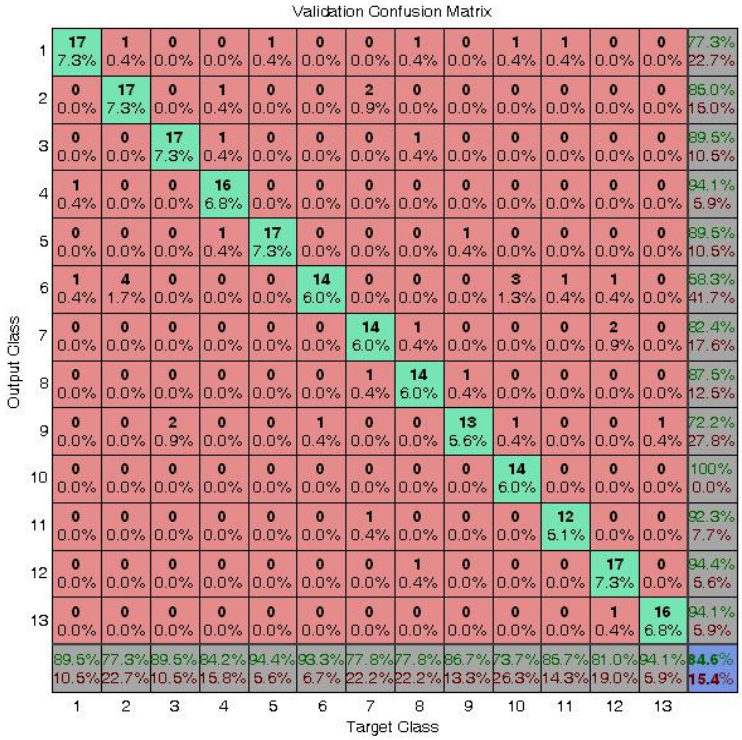

Figura 97 - Matriz de Confusão da validação da RNA 2 usando os parâmetros de tensão caso PNN.

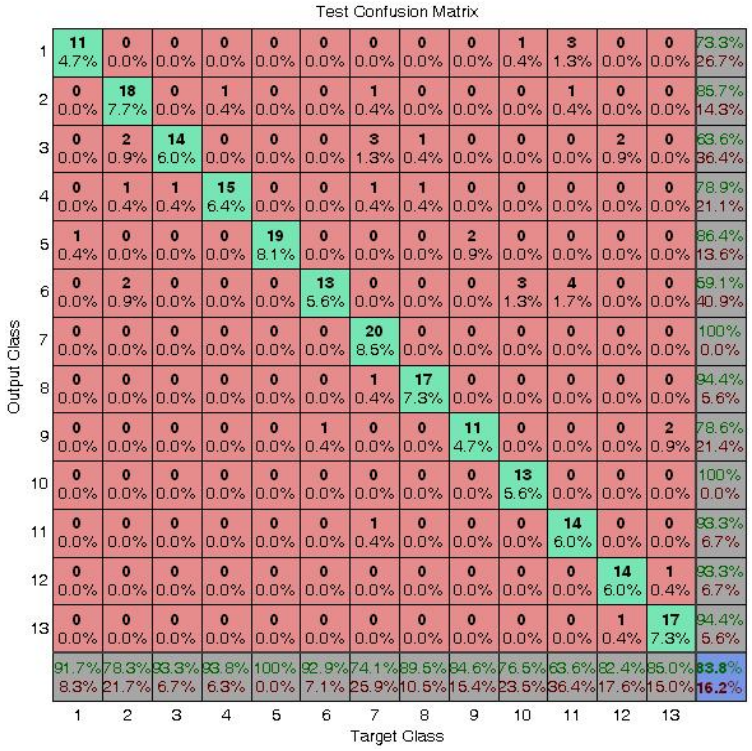

Figura 98 - Matriz de Confusão do teste da RNA 2 usando os parâmetros de tensão caso PNN.

7.2.4 Comparação dos Resultados da Localização

Com a aplicação de diferentes classificadores descritos nas seções anteriores para o mesmo problema, a Tabela 14 apresenta o desempenho obtido para a acurácia do treinamento, validação e teste.

O treinamento obteve um desempenho superior a 82% para todos os métodos dos parâmetros de corrente e tensão, demostrando a eficiência da generalização das redes neurais.

Na validação os parâmetros de corrente tiveram um desempenho acima de 78% em todos os métodos e o desempenho dos parâmetros de tensão variaram entre 75.2% e 84.6%, demostrando a baixa capacidade de avaliar a generalização das redes em comparação aos parâmetros de corrente.

No teste os parâmetros de corrente tiveram um desempenho acima de 75% em todos os métodos e o desempenho dos parâmetros de tensão variaram entre 76.5% e 83.8%. Os teste dos classificadores não foram satisfatórios para os parâmetros de tensão comparados como os parâmetros de corrente.

Tabela 14 - Desempenho das RNA 2 utilizando diferentes métodos.

Parâmetros	**Métodos**	**Acurácia Treinamento**	**Acurácia Validação**	**Acurácia Teste**
Corrente	MLP (LM)	86.8 %	79.5 %	80.3 %
Corrente	MLP (RProp)	93.2 %	80.3 %	85.5 %
Corrente	RBF	98.0 %	78.6 %	75.6 %
Corrente	PNN	94.7 %	85.0 %	82.5 %
Tensão	MLP (LM)	82.8 %	75.2 %	76.5 %
Tensão	MLP (RProp)	85.3 %	76.1 %	79.1 %
Tensão	RBF	97.7 %	76.5 %	75.6 %
Tensão	PNN	97.9 %	84.6 %	83.8 %

Pode ser observado na Tabela 15 que o erro de classificação nos testes foram melhores para os parâmetros de corrente, que variaram entre 14.5% e 24.4%, do que os parâmetros de tensão, que variaram entre 16.2% e 24.4%.

Tabela 15 - Desempenho das RNA 2 utilizando diferentes métodos.

Parâmetros	**Métodos**	**EQM Treinamento**	**EQM Validação**	**EQM Teste**	**EC no Teste**
Corrente	MLP (LM)	0.0109	0.0206	0.0192	19.7 %
Corrente	MLP (RProp)	0.0075	0.0218	0.0189	14.5 %
Corrente	RBF	0.0030	0.0258	0.0240	24.4 %
Corrente	PNN	0.0081	0.0230	0.0270	17.5 %
Tensão	MLP (LM)	0.0154	0.0255	0.0234	23.5 %
Tensão	MLP (RProp)	0.0159	0.0283	0.0243	20.9 %
Tensão	RBF	0.0030	0.0298	0.0301	24.4 %
Tensão	PNN	0.0033	0.0237	0.0250	16.2 %

8 CONCLUSÕES E TRABALHOS FUTUROS

Conclusões Finais

A confiabilidade e a disponibilidade no fornecimento de energia elétrica são necessária para a vida contemporânea. Distúrbios no fornecimento de energia elétrica devem ser evitados e, quando isto não for possível, deve-se prever a rápida recuperação do fornecimento.

A identificação e a localização do tipo de distúrbio em um sistema de distribuição de energia elétrica é muito importante para a manutenção da confiabilidade e disponibilidade do sistema, permitindo providenciar o reparo do fornecimento de energia já quando os primeiros sinais de distúrbios sejam detectados.

Pelos resultados apresentados na metodologia de detecção do instante de incidência da falta aqui estudada, verificou-se que, o algoritmo proposto em [32] obteve um excelente desempenho na detecção das faltas.

Com os parâmetros da fundamental extraídos do algoritmo de detecção, utilizou-se três arquiteturas de redes neurais artificiais para realizar a identificação do tipo das faltas e a localização do instante de incidência dos distúrbios e a comparação do desempenho dessas redes neurais foram realizadas através do erro médio quadrático, erro de classificação e Matriz de Confusão.

Medir adequadamente o desempenho de classificadores, através da taxa de erro (ou precisão) assume um papel importante no sistema de distribuição de energia elétrica, uma vez que o objetivo consiste em construir classificadores com baixa taxa de erro para novos exemplos apresentados as rede neurais.

A utilização de redes neurais mostra-se apropriada para a solução deste tipo de problema, pois neste caso a modelagem analítica seria muito complexa para ser utilizada e redes neurais fornecem ferramentas para modelar o sistema de maneira simplificada e concisa.

As redes MLP são as redes mais utilizadas para criação de sistemas de reconhecimento de padrões de distúrbios na distribuição de energia elétrica, dessa forma elas foram escolhidas para que seus resultados servissem de referência para os obtidos com redes RBF

e PNN.

A rede PNN apresentou um erro de classificação no conjunto de teste dos parâmetros da fundamental de corrente de 12.8% para a identificação dos tipos das faltas; já para localização do instante de incidência das faltas, apresentou um erro de classificação de 17.5%. Estes foram os menores erros obtidos entre todos as redes PNN criadas, entretanto mesmo para os menores erros de classificação, os testes mostram que os classificadores criados foram um pouco melhores do que os classificadores criados com a arquitetura MLP (Levenberg-Marquardt) para a estratégia de localização.

A rede PNN apresenta a vantagem do tempo de treinamento ser menor, porém a grande desvantagem, quando a comparamos com as outras redes, é a necessidade de criar um nó na camada escondida para cada padrão de entrada levando a necessidade de possuir um sistema com mais recursos.

A maneira adotada para o treinamento da rede RBF foi o treinamento incremental e este treinamento vai adicionando os nós na camada escondida um a um até que o critério de parada *GOAL*, que é o erro desejado, seja alcançado, porém estas redes apresentam uma desvantagem que é o longo tempo de treinamento. O erro de classificação do conjunto de teste dos parâmetros da fundamental de corrente para a identificação dos tipos das faltas foi 21.4% e para localização do instante de incidência das faltas foi 24.4%. O desempenho dessas redes não foram superiores ao desempenho das redes PNN e MLP.

As redes MLP foram treinadas utilizando os algoritmos: Resilient e Levenberg-Marquardt. O menor erro de classificação no conjunto de teste dos parâmetros da fundamental de corrente para a identificação dos tipos das faltas foi 5.1% (Levenberg-Marquardt) e para a localização do instante de incidência das faltas foi 14.5% (Resilient). O desempenho dessas redes foram superiores ao desempenho das outra topologias para a estratégia de identificação.

A grande vantagem encontrada para se utilizar redes MLP é que os classificadores criados apresentam o menor número de nós nas camadas intermediárias, porém a quantidade de parâmetros que podem ser investigados e o tempo de treinamento são desvantagens quando comparados as redes RBF e PNN.

Todas as três arquiteturas obtiveram mais de 78.6% de acerto na identificação do tipo da falta e 75.6% na localização para o conjunto de teste do parâmetro de corrente e no máximo 88.9% de acerto na identificação do tipo da falta e 83.8% na localização para o conjunto de teste do parâmetro de tensão.

Pelas matrizes de confusões é possível constatar que as classes 5, 6 e 8 que correspondem as fases BCG, ACG e CG respectivamente, possuem maiores erros entre as classes na identificação das faltas e as classes 6, 7 e 8 que correspondem aos pontos de incidências 8, 7 e 6 respectivamente, possuem maiores erros entre as classes na localização dos distúrbios.

Foram constatados através dos testes e dos parâmetros de comparações, citados no capítulo 7, que para os parâmetros extraídos para a fundamental de tensão, tiveram resultados inferiores aos parâmetros extraídos para a fundamental de corrente, como já era esperado.

Conforme as análises realizadas, o problema de identificação do tipo da falta é mais simples do que a localização da mesma, e a identificação do tipo da falta fornece melhores resultados na classificação em relação aos resultados obtidos para a localização dos distúrbios.

Trabalhos Futuros

De modo a aperfeiçoar a metodologia proposta, tornando-a mais abrangente e confiável, propõem-se algumas sugestões de trabalhos a serem realizados futuramente:

- Utilizar uma quantidade maior de registradores digitais de perturbações (RDP) na rede de distribuição de energia elétrica com o objetivo de diversificar o banco de dados para uma melhor generalização das RNAs;
- Estudo da topologia Máquina de Comitê bem como de outros algoritmos de aprendizagem buscando a configuração que possa melhorar a capacidade de classificação dos distúrbios da rede elétrica;

- Combinação dos dados de tensão e corrente para a classificação das faltas;
- Decomposição dos sinais correspondentes às tensões e correntes utilizando a técnica adaptativa que obtém uma representação do sinal em termos de senóides amortecidas parametrizáveis cujas frequências estão em múltiplos da fundamental;
- Usar as transformadas de wavelets para extrair informações de sinais em outas bandas de frequências/escalas.
- Utilizar componentes de sequência positiva para análise comparativa.

REFERÊNCIAS

[1] Agência Nacional de Energia Elétrica. Estabelece as Disposição Relativas à Continuidade da Distribuição de Energia Elétrica às Unidades Consumidoras - Resolução 024/2000, 2000.

[2] Agência Nacional de Energia Elétrica. Estabelece de Forma Atualizada e Consolidada, as Disposições Relativas à Conformidade dos Níveis de Tensão de Energia Elétrica em Regime Permanente - Resolução 505/2001, 2001.

[3] Agência Nacional de Energia Elétrica. Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - PRODIST. Disponível em: http://www.aneel.gov.br/82.htm., 2007.

[4] Agência Nacional de Energia Elétrica. Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - Módulo 8, Qualidade da Energia Elétrica, 2010.

[5] Al-Dabbagh, M., and Al-Dabbagh, L. Neural Networks Based Algorithm for Detecting High Impedance Faults on Power Distribution lines. *Internacional Joint Conference on Neural Networks, USA 5* (July 1999), 3386–3390.

[6] Barros, F. G. N., dos Santos Fonseca, W. A., Bezerra, U., Nunes, M., das M. Machado, R., and Moutinho, J. Identificação e Classificação Automática de Faltas em Sistema de Energia Elétrica e Comparação de Metodologia de Redes Neurais Artificiais no Processo de classificação. *XIII Encuentro Regional Iberoamericano de Cigré-Argentina* (Mayo 2009).

[7] Bollen, M. H. J. *Understanding Power Quality Problems: Voltage Sags and Interruptions*. Wiley-IEEE Press, 1995.

[8] Bollen, M. H. J., and Gu, I. Y. H. *Signal Processing of Power Quality Disturbances*. Wiley-IEEE Press, 2006.

[9] Carvalho, P. L. Uma Contribuição ao Estudo da Depressão de Tensão. Master's thesis, Universidade Federal de Itajubá, 1997.

[10] CIGRE and CIRED and UIE Joint Working Group C4.110. Voltage Dip Immunity of Equipment and Installations, 2010.

[11] Dag, O., and Ucak, C. Fault Classification for Power Distribution Systems via a Combined Wavelet-Neural Approach. *International Conference on Power System Technology - POWERCON, Singapore 21*, 24 (November 2004), 1309–1314.

[12] de Pádua Braga, A., de Leon F. de Carvalho, A. P., and Ludermir, T. B. *Redes Neurais Artificiais: Teoria e Aplicações*. LTC, 2000.

[13] de Souza, F. A. Detecção de Falhas em Sistema de Distribuição de Energia Elétrica Usando Dispositivos Programáveis. Master's thesis, Universidade Estadual Paulista, 2008.

[14] Dennis Woodford. Introduction to PSCAD V3. Manitoba HVDC Research Center Inc: User's Guide, 2001.

[15] Dugan, R. C., Santoso, S., McGranaghan, M. F., and Beaty, H. W. *Electrical Power Systems Quality*. McGraw-Hill, 2012.

[16] Ferreira, A. A. Caracterização e Análise de Variação de Tensão de Curta Duração. Master's thesis, Universidade Estadual de Campinas, 2002.

[17] Haykin, S. *Redes Neurais: Princípios e Prática*. Bookman, 2001.

[18] Howard B.Demuth and Mark Hudson Beale and Martin T. Hagan. MATLAB Neural Network Toolbox 7: User's Guide, 1996.

[19] IEC - International Electrotechnical Commission. Generic immunity standard for industrial environments - IEC 61000. , 1999.

[20] IEEE-SA Standards Board. Recommended Practice for Monitoring Electric Power Quality, 1995.

[21] IEEE-SA Standards Board. Recommended Practice for Evaluating Power System Compatibility with Electronic Process Equipment, 1998.

[22] IEEE-SA Standards Board. IEEE Standard Common Format for Transient Data Exchange (COMTRADE) for Power Systems, 1999.

[23] Information Tecnology Industry Council. Technical Committee 3 (TC3) of the Information Technology Industry Council - ITI/CBEMA. Disponível em: http://www.itic.org., 2000.

[24] Jones, C. V. *The Unified Theory of Electrical Machines*. Plenum Press, 1967.

[25] Kaura, V., and Blasko, V. Operation of a Phase Locked Loop Under Distorted Utility Conditions. *IEEE Transactions on Industry Applications 33*, 1 (February 1997), 58–63.

[26] Keyhani, R., Deriche, M., and Palmer, E. A High Impedance Fault Detector using a Neural Network and Subband Decomposition. *6th International, Symposium on Signal Processing and its Applications, Malaysia 2* (August 2001), 458–461.

[27] Kovács, Z. L. *Redes Neurais Artificiais: Fundamentos e Aplicações*. Collegium Cognitio, 1996.

[28] Élito dos Reis Matos. Um Método para Detecção e Classificação de Curtos-Circuitos em Redes de Distribuição de Energia Elétrica Baseado na Transformada de Fourier e em Redes Neurais Artificiais. Master's thesis, Universidade Estadual Paulista, 2009.

[29] Lorenzi, A. *Aplicação de Redes Neurais Artificiais para Estimativa da Resistência à Compressão do Concreto a Partir da Velocidade de Propagação de Pulso Ultra-Sônico*. PhD thesis, Universidade Federal do Rio de Grande do Sul, 2009.

[30] Lovisolo, L., Figueiredo, K. T., de Menezes Laporte, L., Neto, J. A. M., and dos Santos Rocha, J. C. Location of Faults Generating Short Duration Voltage Variations in Distribution Systems Regions from Records Captured at one Point and Decomposed into Damped Sinusoids. *IET Generation, Transmission & Distribution - aceito para publicação*.

[31] Lovisolo, L., Figueiredo, K. T., de Menezes Laporte, L., Neto, J. A. M., and dos Santos Rocha, J. C. Localização de Faltas em um Sistema de Distribuição de Energia Usando Redes Neurais Aplicada à Decomposição em Senóides Amortecidas dos Registros de Faltas Correspondentes a VTCDs Capturados no Alimentador. *VIII CBQEE - Conferência Brasileira sobre Qualidade da Energia Elétrica* (Agosto 2009).

[32] Lovisolo, L., Neto, J. A. M., Ortiz, A., and Aredes, M. Análise Comparativa do Desempenho de Algorítmos de Sistemas de Sincronismos (PLL - Phase Lock Loop). *Revista EletroEvolução - Sistema de Potência, Cigré-Brasil 10*, 51 (Junho 2008), 37–43.

[33] Lovisolo, L., and Samir Ahmad Mussa and João Amin Moor Neto. Avaliação dos Parâmetros de Qualidade de Energia para Identificação de Falhas e Pertubações na Rede de Distribuição - Relatório Técnico do Projeto de P&D, 2010.

[34] Maia, R. M. Característica das Variações de Tensão de Curta Duração e seus Impactos em uma Indústria Alimentícia. Master's thesis, Universidade Federal de Minas Gerais, 2011.

[35] Martins, L. S., Martins, J., Alegia, C., and Pires, V. F. A Network Distribution Power System Fault Location Based on Neural Eigenvalue Algorithm. *Bologna Power Tech Conference, Italy* (June 2003).

[36] Mirzaei, M., Kadir, M. A. A., Moazami, E., and Hizam, H. Review of Fault Location Methods for Distribution Power System. *Australian Journal of Basic and Applied Sciences 3*, 3 (September 2009), 2670–2676.

[37] Morales, G., Mora, J., and Carrillo, G. A Complete Fault Location Formulation for Distribution Systems Using the k-nearest Neighbors for Regression and Classification. *IEEE/PES Transmission and Distribution Conference and Exposition: Latin America* (November 2010), 810–815.

[38] Moreto, M. Localização de Faltas de Alta Impedância em Sistemas de Distribuição de Energia: Uma Metodologia Baseada em Redes Neurais Artificiais. Master's thesis, Universidade Federal do Rio Grande do Sul, 2005.

[39] Operador Nacional do Sistema Elétrico. Gerenciamento dos Indicadores de Desempenho da Rede Básica e dos Barramentos dos Tranformadores de Fronteira, e de seus Componentes - Submódulo 2.8. Disponível em: http://www.ons.org.br., 2010.

[40] Parzen, E. On Estimation of a Probability Density Function and Mode. *The Annals of Mathematical Statistics, Ohaio 33* (September 1962), 1065–1076.

[41] Pereira, R. A. F. *Localização de Faltas em Alimentadores de Distribuição de Energia Elétrica Usando Medições Esparsas de Tensões.* PhD thesis, Universidade Estadual Paulista, 2007.

[42] Pinheiro, J. R. G., Ulson, J. A. C., and de Souza Campos, F. Sistema de Medição para Localização de Faltas em Alimentadores de Distribuição de Energia Elétrica Baseado em Redes de Sensores se Fio Padrão IEEE 802.15.4. *9th IEEE/IAS International Conference on Industry Applications, Brasil* (November 2010).

[43] Pourahmadi-Nakhli, M., and Safavi, A. A. Path Characteristic Frequency-Based Fault Locating in Radial Distribution Systems Using Wavelets and Neural Networks. *IEEE Transactions on Power Delivery 26*, 2 (April 2011), 772–781.

[44] Sechi, D. L., Bruno Brondani Toller, D. P. B., and Sperandio, M. Localização de Falhas em Redes de Distribuição de Energia Elétrica. *XXIV CRICTE - Congresso Regional de Iniciação Científica e Tecnológia em Engenharia* (Setembro 2010).

[45] Semiconductor Equipment and Materials Institute. Specification for Semiconductor Processing Equipment Voltage Sag Immunity Standards - SEMI F47. Disponível em: http://www.semi.org., 2006.

[46] Silva, J. A. M. Análise Comparativa de Resultados de Simulação de Afundamentos de Tensão Utilizando Programas de Curto-Circuito e de Transitórios Eletromagnéticos. Master's thesis, Universidade Federal de Itajubá, 2004.

[47] Stewart, J. *Cálculo.* Thomsom, 2010.

[48] Stroustrup, B. The Design of C++. *C/C++ User Jounal* (May 2005).

[49] Thukaram, D., Khincha, H. P., and Vijaynarasimha, H. P. Artificial Neural Network and Support Vector Machine Approach for Locating Faults in Radial Distribution Systems. *IEEE Transactions on Power Delivery 20*, 2 (April 2005), 710–721.

[50] Turam Gonen. *Electric Power Distribution System Engineering.* CRC Press, 2007.

[51] Usida, W. F., Oleskovicz, M., Rodrigues, L. C. P., and Coury, D. V. Análise Qualitativa no Monitoramento Automático dos Eventos de Tensão de Curta Duração. *Revita Controle & Automação 20*, 3 (Agosto 2009), 323–334.

[52] Villanueva, W. J. P. Comitê de Máquinas em Predição de Séries Temporais. Master's thesis, Universidade Estadual de Campinas, 2006.

[53] Visconti, I., Ross, R., de Souza, L., and Leitão, J. Validação de Programa de Identificação de VTCD Oriundas de Aplicações de Curto-Circuitos. *XI SEPOPE - Simpósio de Especialista em Planejamento da Operação e Expansão Elétrica, Brasil* (Março 2009).

ANEXO A

Especificação do Alimentador

Dados da Subestação

Subestação: Salto

Barra BSO 23B

Dados da Barra:

$Z1 = 0.4401^o 83.08[\Omega]$

$Z0 = 0.3967^o 85.00[\Omega]$

Corrente de Curto:

Trifásico - 5703[A]

Bifásico - 4938[A]

Fase-Terra - 5897[A]

Dados do Alimentador

Alimentador: BSO-01

Carregamento: 246[A]

Tensão de Despacho: 24,3[kV]

Fator de Potência: 0.90

Trechos:

1 - Saída de SE - CD 1124: Cabo 4/0[CA]

Distância: 4300[m]

2 - CD 1124 - CD 1095: Cabo 1/0[CA]

Distância: 2260[m]

3 - CD 1095 - CD 1466: Cabo 4/0[CA]

Distância: 2250[m]

Resistividade de Terra - 100[Ωm]

ANEXO B

Diagrama Unifilar - Primeira Parte

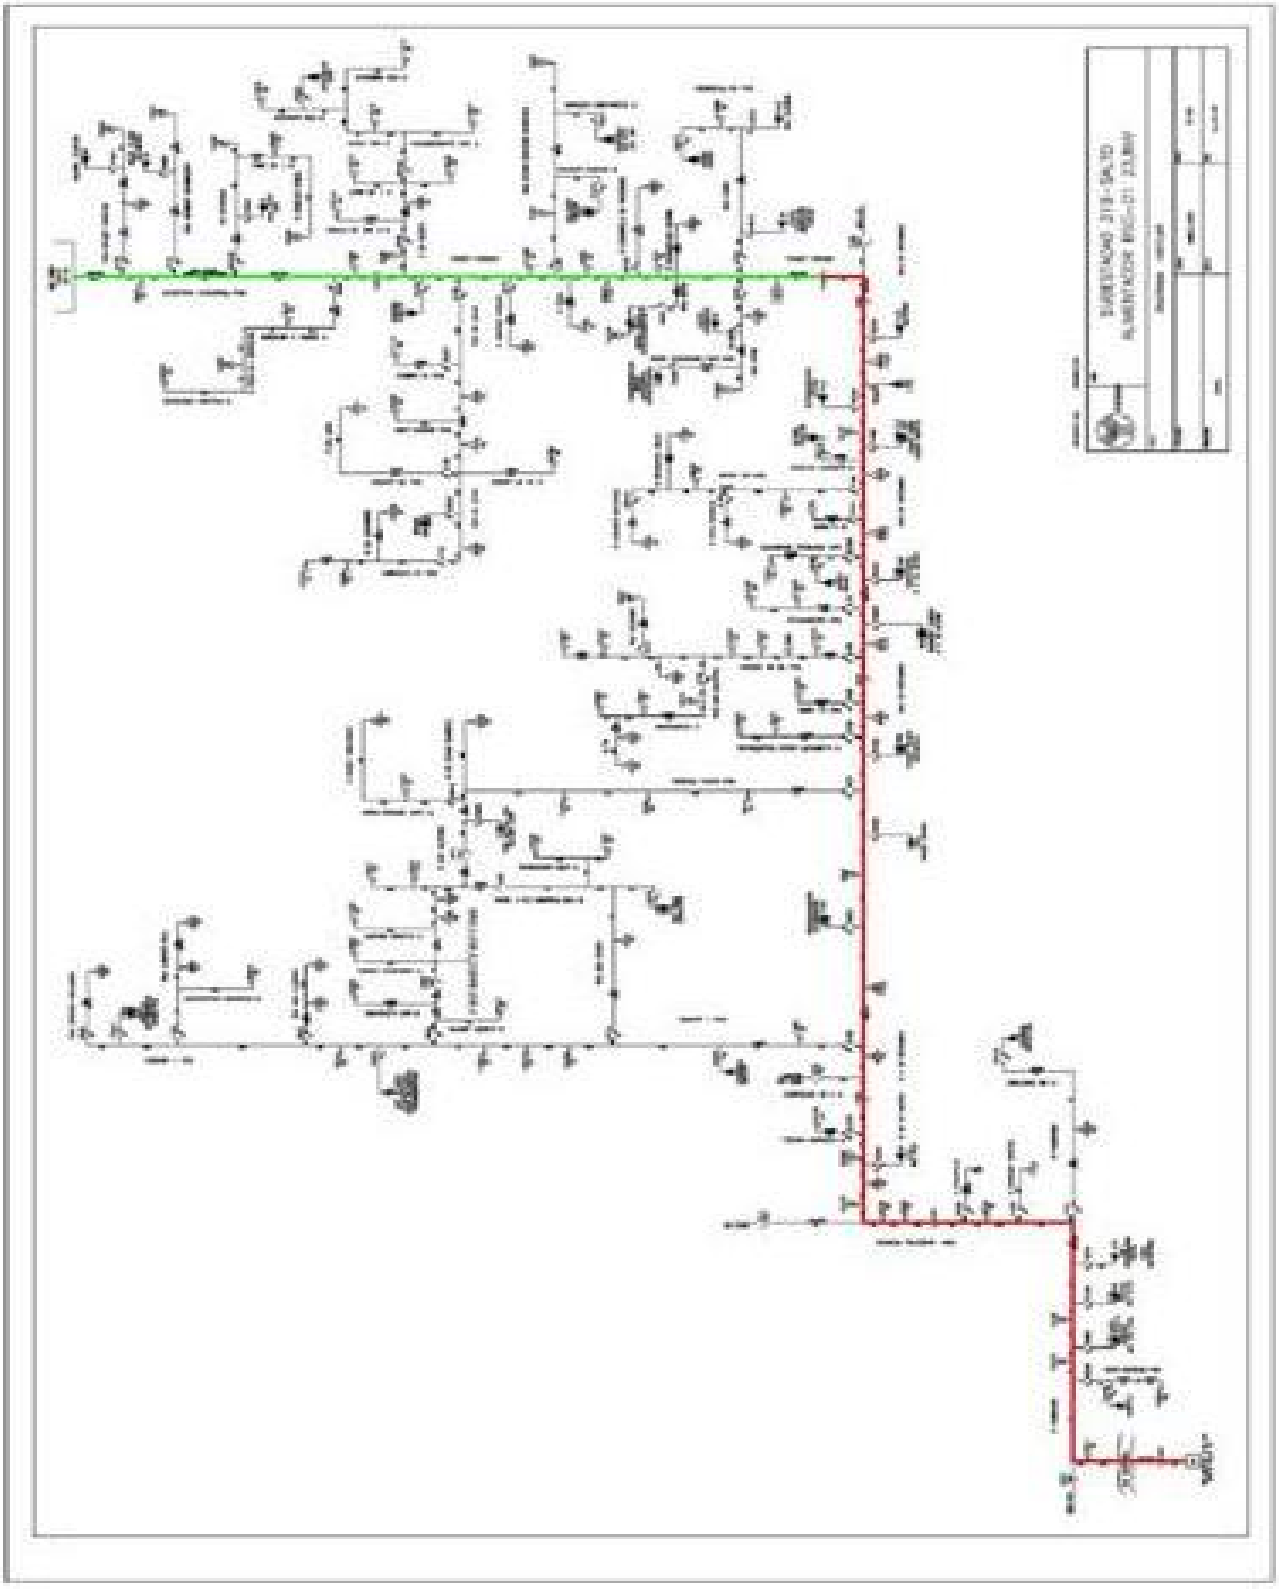

Figura 99 - Diagrama unifilar do alimentador - Primeira Parte.

ANEXO C

Diagrama Unifilar - Segunda Parte

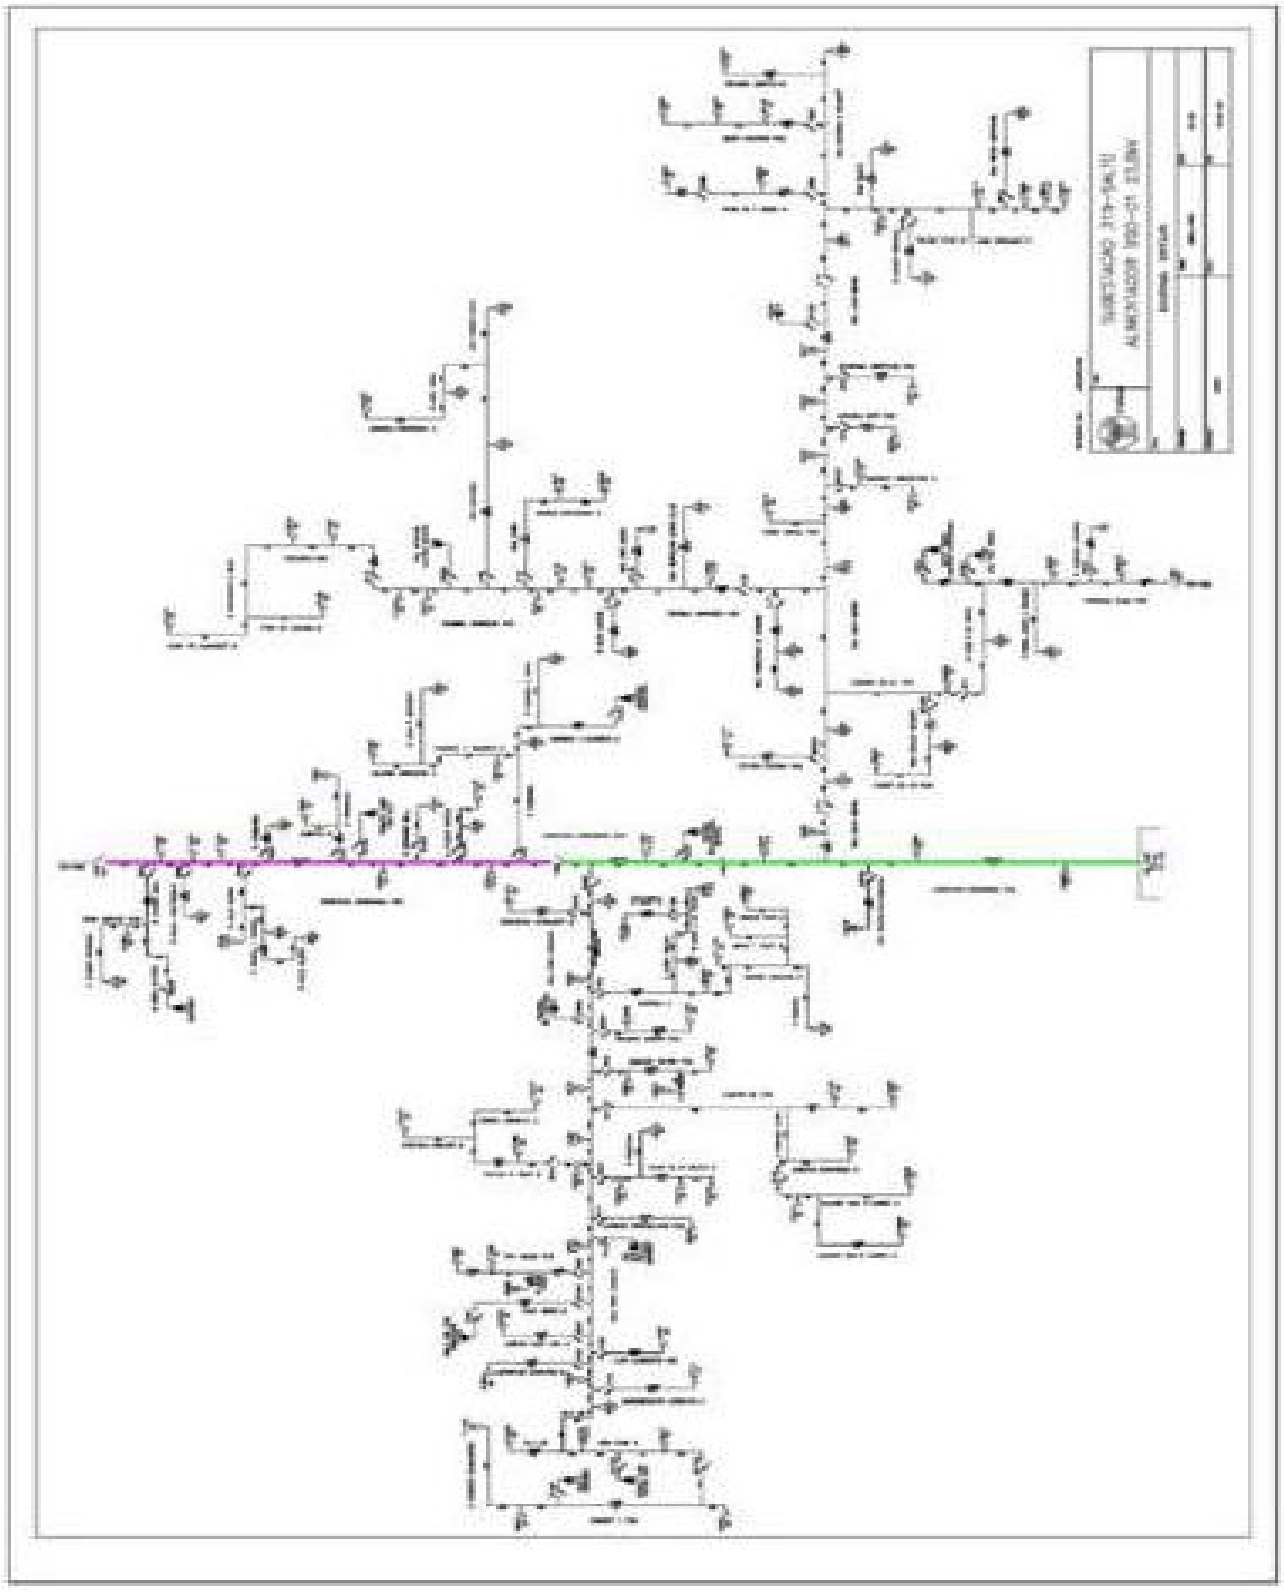

Figura 100 - Diagrama unifilar do alimentador - Segunda Parte.