



UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

LOCALIZAÇÃO DE CADEIAS DE ISOLADORES DEFEITUOSAS EM LINHAS DE TRANSMISSÃO ATRAVÉS DE REDES NEURAIS

RENATO MASSONI CAPELINI

Dissertação submetida ao Programa de Pós-Graduação em
Engenharia Elétrica como parte dos requisitos para obtenção do
título de Mestre em Ciências em Engenharia Elétrica

Orientador: Prof. Dr. Manuel Luis Barreira Martinez

Universidade Federal de Itajubá

Co-Orientador: Prof. Dr. José Feliciano Adami

*Faculdade de Engenharia de Guaratinguetá – Universidade Estadual
Paulista*

Itajubá, Setembro de 2011

Ficha catalográfica elaborada pela Biblioteca Mauá –
Bibliotecária Margareth Ribeiro- CRB_6/1700

C238l

Capelini, Renato Massoni

Localização de cadeias de isoladores defeituosas em linhas de transmissão através de redes neurais / Renato Massoni Capelini. -- Itajubá, (MG) : [s.n.], 2011.

99 p. : il.

Orientador: Prof. Dr. Manuel Luís Barreira Martinez.

Coorientador: Prof. Dr. José Feliciano Adami.

Dissertação (Mestrado) – Universidade Federal de Itajubá.

1. Redes neurais. 2. Linhas de transmissão. 3. Efeito corona. 4. Cadeia de isoladores. I. Martinez, Manuel Luís Barreira, orient. II. Adami, José Feliciano, coorient. III. Universidade Federal de Itajubá. IV. Título.

DEDICATÓRIA

Aos meus pais, Maurício e Leila,

e

à minha irmã Claudia.

AGRADECIMENTOS

Aos meus pais, Maurílio e Leila, por estarem sempre ao meu lado, tanto nos momentos de glória como nos momentos de dificuldade. Por lutarem incessantemente, abrindo mão de conquistas materiais para investir na educação e bem-estar dos filhos.

À minha irmã Claudia, pelo carinho, companheirismo e incentivo.

Aos velhos e novos amigos de Itajubá e da UNIFEI, pelo incentivo e apoio.

Aos amigos da república, por formarem uma verdadeira família e proporcionar momentos de alegria e descontração.

Aos professores Manuel Luis Barreira Martinez e José Feliciano Adami, pela orientação e confiança em meu trabalho.

Ao colega e amigo Marcel Fernando da Costa Parentoni, por principalmente incentivar meu retorno aos estudos.

Aos colegas do Laboratório de Alta Tensão, pela confiança, cooperação e aprendizado.

À UNIFEI, pelo ensino e estrutura disponibilizados.

A todos aqueles que de alguma forma contribuíram para que este trabalho fosse realizado.

RESUMO

Esta dissertação de mestrado tem como objetivo descrever o desenvolvimento de um método de identificação e localização remota de cadeias de isoladores defeituosas em linhas de transmissão. Tal método aproveita a geração de descargas parciais resultantes do efeito corona nessas cadeias, cujas formas de onda dependem de onde essas descargas parciais ocorrem.

Dessa forma, é mostrado ao longo desse trabalho o desenvolvimento de programas baseados em redes neurais destinados ao reconhecimento dos padrões de formas de onda de descargas parciais, permitindo assim sua associação com o ponto de ocorrência do efeito corona.

São discutidos os ensaios mais relevantes realizados em laboratório, onde foi utilizada uma linha de transmissão artificial, a qual representa uma linha de transmissão real de 69 [kV] e 48 [km] de extensão. A esta linha de transmissão foi conectada uma cadeia de isoladores configurável dotada de um dispositivo de reprodução de efeito corona.

Além disso, é mostrada a possibilidade de aplicação do transformador de corrente como um acoplador capacitivo, sendo utilizado na aquisição dos sinais gerados pelas descargas parciais de corona.

Ao final, são discutidos os resultados obtidos e propostos desenvolvimentos futuros.

Palavras-chave: Redes Neurais, Linhas de Transmissão, Efeito Corona, Cadeia de Isoladores

ABSTRACT

The objective of this dissertation is to discuss the development of a method for remote identification and location of damaged insulator strings in transmission lines. The analysis of the partial discharges due to corona effect generated in the damaged insulator strings is the basis of this method, once the waveforms of these partial discharges change with the position where they occurs.

It is discussed the development of a software for waveform recognition, based on neural networks. This software associates the waveform of a partial discharge with its location.

Thus, the tests performed with the software in an artificial transmission line in the laboratory are analyzed. This artificial transmission line represents a real transmission line with rated voltage of 69 [kV] and 48 [km] of length. Using the available taps along the line, insulator strings can be connected to the system and, through the use of a corona effect reproduction device, partial discharges are generated.

This dissertation shows as well a new application for the current transformers. Using the capacitance between the phase and the metal body, they can be used as capacitive couplers for the signal acquisition.

Finally, the results are analyzed and new steps are suggested for future developments.

Keywords: Neural Networks, Transmission Line, Corona Effect, Insulator Strings

SUMÁRIO

1. Introdução.....	1
1.1 Considerações Iniciais.....	2
1.2 Relevância do Tema	2
1.3 Objetivos	3
1.4 Estrutura.....	3
2. Instalações de Laboratório Utilizadas no Desenvolvimento do Método Proposto... 5	
2.1 Considerações Iniciais.....	6
2.2 O Efeito Corona.....	6
2.3 Sistema Elétrico Inicial	7
2.4 Sistema Modificado	9
2.4.1 Inclusão da Linha de Transmissão.....	9
2.4.2 Utilização do Transformador de Corrente como Acoplador Capacitivo.....	12
2.5 Sistema Montado em Laboratório.....	15
2.5.1 Transformador de Relação Variável (Variac)	17
2.5.2 Transformador de Potência.....	18
2.5.3 Bobina de Bloqueio.....	19
2.5.4 Transformador de Corrente.....	20
2.5.4 Linha de Transmissão.....	22
2.5.5 Cadeia de Isoladores	24
2.5.6 Reator	27
2.5.7 Transdutor de Corrente.....	28
2.5.8 Placa de Aquisição	30
2.6 Considerações Finais	31
3. Técnicas Utilizadas.....	32
3.1 Considerações Iniciais.....	33
3.2 Redes Neurais Artificiais	33
3.2.1 Introdução.....	33
3.2.2 O Sistema Biológico.....	34
3.2.3 O Neurônio Artificial	35
3.2.4 Arquiteturas de Rede	38
3.2.5 Aprendizagem.....	40
3.3 Tratamento de Sinais	42
3.3.1 Tratamento por Corte do Sinal.....	42
3.3.2 Tratamento por Filtragem Convencional	43
3.3.3 Tratamento por Compressão – <i>Linear Predictive Coding (LPC)</i>	44

3.4 Considerações Finais	45
4. Método Proposto	46
4.1 Considerações Iniciais.....	47
4.2 Filosofia do Método	47
4.3 Sistemática de Ensaios em Laboratório	52
4.3.1 Montagem de Banco de Dados e Treinamento das Redes Neurais	52
4.3.2 Ensaios de Desempenho dos Programas	55
4.4 Considerações Finais	56
5. Desenvolvimento da Ferramenta Computacional.....	57
5.1 Considerações Iniciais.....	58
5.2 Configuração das Redes Neurais	58
5.3 Ensaios de Identificação Realizados com Sinais Tratados por LPC	60
5.3.1 Ensaio nº 1	60
5.3.2 Ensaio nº 2	65
5.3.3 Ensaio nº 3	67
5.3.4 Ensaio nº 4	68
5.4 Ensaios de Identificação Realizados sem Tratamento por LPC.....	72
5.4.1 Ensaio nº 5	72
5.4.2 Ensaio nº 6	75
5.4.3 Ensaio nº 7	78
5.5 Ensaios de Localização.....	80
5.5.1 Ensaio nº 8	81
5.5.2 Ensaio nº 9	83
5.6 Considerações Finais	88
6. Conclusões.....	90
6.1 Conclusões	91
6.2 Publicações.....	94
6.3 Sugestões para Trabalhos Futuros.....	95
7. Referências Bibliográficas	96

LISTA DE FIGURAS

Figura 2.1 - Reprodução do efeito corona por Adami (2008).....	7
Figura 2.2 - Circuito elétrico equivalente da cadeia de isoladores com garfo para reprodução do efeito corona.	8
Figura 2.3 - Esquema elétrico do sistema utilizado por Adami (2008).....	8
Figura 2.4 - Descarga parcial obtida por Adami (2008).....	9
Figura 2.5 - Circuito π nominal de uma linha de transmissão (Fuchs, 1973).....	10
Figura 2.6 - Linha artificial criada a partir de circuitos π nominais (Fuchs, 1973).	10
Figura 2.7 - Sistema derivado do utilizado por Adami (2008).....	11
Figura 2.8 - Esquema simplificado de um TPC.	12
Figura 2.9 - Primeiro ensaio com o Franalyzer®: ensaio de resposta em frequência em um capacitor conhecido.	13
Figura 2.10 - Comportamento da corrente entre fase e carcaça do TC Asea IMBD 72 A1.	14
Figura 2.11 - Comportamento da corrente entre fase e carcaça do TC Areva QDR-145/2.	14
Figura 2.12 - Diagrama esquemático do sistema montado em laboratório.....	15
Figura 2.13 - Sistema montado em laboratório.	16
Figura 2.14 - Transformador de Relação Variável (Variac).	17
Figura 2.15 - Transformador de Potência.....	18
Figura 2.16 - Bobina de bloqueio com dispositivo de sintonia em destaque.....	19
Figura 2.17 - Circuito paralelo ressonante da bobina de bloqueio.....	20
Figura 2.18 - TC 1 conectado no início da linha de transmissão.	21
Figura 2.19 - TC 2 conectado no final da linha de transmissão.....	22
Figura 2.20 - Linha de transmissão formada por elementos π	23
Figura 2.21 - Taps de indutor utilizado em um dos elementos π	23
Figura 2.22 - Cadeia de isoladores de porcelana utilizada nos ensaios.	25
Figura 2.23 - Reprodução do efeito corona.....	25
Figura 2.24 - Descarga parcial durante reprodução do efeito corona.....	26
Figura 2.25 - Reator configurável por taps.....	27
Figura 2.26 - Transdutor de corrente.	29
Figura 2.27 - Diagrama dimensional do núcleo de ferrite NU-40/27/11-IP6 extraído do catálogo da Thornton.....	29
Figura 2.28 - Placa de aquisição e computador realizando aquisição de dados.....	30
Figura 3.1 - Neurônio típico (Thibodeau, 2002).....	34
Figura 3.2 - Neurônio artificial não-linear (Haykin, 2001).	35
Figura 3.3 - Efeito da tendência b_k (Haykin, 2001).	36
Figura 3.4 - Funções de ativação: função de limiar (a), função linear por partes (b) e função sigmóide (c) (Haykin, 2001).....	37
Figura 3.5 - Rede alimentada adiante com camada única (de neurônios).....	39
Figura 3.6 - Rede alimentada diretamente com múltiplas camadas.	39
Figura 3.7 - Rede recorrente.....	40
Figura 3.8 - Principais passos da aprendizagem da rede neural.....	41
Figura 3.9 - Aprendizagem supervisionada (Haykin, 2001).....	41
Figura 3.10 - Aprendizagem não-supervisionada (Haykin, 2001).....	42
Figura 3.11 - Forma de onda típica adquirida em uma janela de 5 μ s].....	43

Figura 3.12 - Espectro de freqüências típico dos sinais de descargas parciais gerados pelo dispositivo de reprodução de efeito corona.	44
Figura 4.1 - Padrão de forma de onda gerada por descarga parcial com a cadeia de isoladores conectada ao tap 1.	47
Figura 4.2 - Padrão de forma de onda gerada por descarga parcial com a cadeia de isoladores conectada ao tap 2.	48
Figura 4.3 - Padrão de forma de onda gerada por descarga parcial com a cadeia de isoladores conectada ao tap 3.	49
Figura 4.4 - Padrão de forma de onda gerada por descarga parcial com a cadeia de isoladores conectada ao tap 4.	49
Figura 4.5 - Padrão de forma de onda gerada por descarga parcial com a cadeia de isoladores conectada ao tap 4 e dispositivo de reprodução de efeito corona em posição diferente das anteriores.	50
Figura 4.6 - Diagrama de funcionamento básico do método proposto.	51
Figura 4.7 - Fluxograma da montagem de banco de dados de sinais para treinamento ou ensaio das redes neurais.	54
Figura 4.8 - Fluxograma do treinamento das redes neurais.	55
Figura 4.9 - Fluxograma do ensaio de desempenho dos programas.	56
Figura 5.1 - Aplicativo para treinamento de redes neurais do Matlab®.	59
Figura 5.2 - Gráfico de desempenho do treinamento de uma rede neural.	60
Figura 5.3 - Cadeia de isoladores de porcelana com um dos isoladores quebrado.	61
Figura 5.4 - Esquema das cadeias de isoladores utilizadas no Ensaio 1.	61
Figura 5.5 - Fluxograma do treinamento das redes neurais do Ensaio nº 1, onde n é a quantidade de sinais contidos no banco de dados e k a quantidade de redes neurais.	63
Figura 5.6 - Fluxograma da etapa de diagnóstico do programa do Ensaio nº 1, onde n é a quantidade de sinais submetidos ao reconhecimento.	63
Figura 5.7 - Resposta do programa para o reconhecimento dos 20 sinais de ensaio.	64
Figura 5.8 - Situações contempladas pelas classes de padrões do Ensaio 2.	66
Figura 5.9 - Resposta do programa para o reconhecimento dos 150 sinais de ensaio.	66
Figura 5.10 - Resposta do programa para o reconhecimento dos 60 sinais de ensaio.	68
Figura 5.11 - Situações contempladas pelas classes de padrões do Ensaio 4.	70
Figura 5.12 - Resposta do programa para o reconhecimento dos 75 sinais de ensaio.	71
Figura 5.13 - Fluxograma do treinamento das redes neurais sem LPC do Ensaio nº 5, onde n é a quantidade de sinais contidos no banco de dados e k a quantidade de redes neurais.	72
Figura 5.14 - Fluxograma da etapa de diagnóstico do programa sem LPC do Ensaio nº 5, onde n é a quantidade de sinais submetidos ao reconhecimento.	73
Figura 5.15 - Resposta do programa para o reconhecimento dos 60 sinais de ensaio.	74
Figura 5.16 - Ensaios nº 3 e nº 5.	74
Figura 5.17 - Resposta do programa para o reconhecimento dos 72 sinais de ensaio (com LPC).	76
Figura 5.18 - Resposta do programa para o reconhecimento dos 72 sinais de ensaio (sem LPC).	77

Figura 5.19 - Ensaio n° 4 e n° 6.	77
Figura 5.20 - Resposta do programa formado somente pela rede neural problemática para o reconhecimento dos 72 sinais de ensaio.	79
Figura 5.21 - Resposta do programa sem a rede neural problemática para o reconhecimento dos 72 sinais de ensaio.	80
Figura 5.22 - Fluxograma do treinamento das redes neurais do Ensaio ° 8, onde n é a quantidade de sinais contidos no banco de dados e k a quantidade de redes neurais.	81
Figura 5.23 - Fluxograma da etapa de diagnóstico do programa do Ensaio n° 8, onde n é a quantidade de sinais submetidos ao reconhecimento.	82
Figura 5.24 - Resposta do programa para a localização da cadeia de isoladores ao longo da linha de transmissão.	83
Figura 5.25 - Algoritmo de redução de amostras dos sinais: <i>Filtro de Porcentagem</i> . ..	84
Figura 5.26 - Exemplo de aplicação dos algoritmos FFT e filtro de porcentagem sobre um sinal de descarga parcial.	85
Figura 5.27 - - Fluxograma do treinamento das redes neurais do Ensaio n° 9, onde n é a quantidade de sinais contidos no banco de dados e k a quantidade de redes neurais.	86
Figura 5.28 - Fluxograma da etapa de diagnóstico do programa do Ensaio n° 9, onde n é a quantidade de sinais submetidos ao reconhecimento.	87
Figura 5.29 - Resultado do Ensaio n° 9.	88

LISTA DE TABELAS

Tabela 2.1 - Especificações do Variac	17
Tabela 2.2 - Especificações do Transformador de Potência	19
Tabela 2.3 - Faixas de corte da bobina de bloqueio.....	20
Tabela 2.4 - Especificações do TC 1.	21
Tabela 2.5 - Especificações do TC 2.	22
Tabela 2.6 - Especificações dos indutores.....	24
Tabela 2.7 - Especificações dos capacitores.	24
Tabela 2.8 - Especificações dos Isoladores de Porcelana.	26
Tabela 2.9 - Especificações do reator.....	28
Tabela 2.10 - Possíveis configurações do reator.	28
Tabela 2.11 - Especificações do transdutor de corrente.	30
Tabela 2.12 - Especificações da placa de aquisição.....	31
Tabela 5.1 – Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio nº 1.	62
Tabela 5.2 - Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio nº 2.	65
Tabela 5.3 - Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio nº 3.	67
Tabela 5.4 - Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio nº 4.	69
Tabela 5.5 – Desempenho do programa frente aos novos padrões.	70
Tabela 5.6 - Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio nº 5.	73
Tabela 5.7 - Diferença de esforço computacional entre os Ensaio nº 3 e nº 5.	75
Tabela 5.8 - Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio nº 6.	76
Tabela 5.9 – Diferenças de desempenho entre os programas utilizados nos Ensaio nº 4 e nº 6.	78
Tabela 5.10 - Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio nº 8.	82
Tabela 5.11 Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio nº 9	86

LISTA DE ABREVIATURAS E SÍMBOLOS

B	Constante generalizada dos quadripolos
b_k	Tendência de um neurônio
BB	Bobina de Bloqueio
CI	Cadeia de Isoladores
CIGRÉ	Conseil International dês Grands Réseaux Électriques
CIREN	International Conference on Electricity Distribution
CRT	Cathode Ray Tube
$e[n]$	Erro entre a amostra estimada e a amostra real
ERIAC	Encontro Ibero-Americano do CIGRÉ
FIR	Finite Impulse Response
G	Condutância
I_{cc}	Corrente de Curto-Circuito
IEC	International Electrotechnical Commission
INDUSCON	International Conference on Industry Application
k	Neurônio
LPC	Linear Predictive Coding
M	Sistema de aquisição de dados
P	Quantidade de amostras anteriores utilizadas pelo LPC
R	Resistência
RE	Resistor
RN	Rede Neural
T1	Variac
T2	Transformador de potência
TC	Transformador de Corrente
TC artificial	Transformador de corrente conectado ao início da linha de transmissão
TC 2 artificial	Transformador de corrente conectado ao final da linha de transmissão

TPC	Transformador de Potencial Capacitivo
TPI	Transformador de Potencial Indutivo
U	Tensão da rede
u_k	Combinação linear das entradas de um neurônio
v_k	Campo local induzido de um neurônio
w_{kx}	Pesos sinápticos de um neurônio
X_L	Reatância indutiva
$x[n]$	Amostra real
$\hat{x}[n]$	Amostra estimada
x_x	Entradas de um neurônio
Y	Admitância
y_k	Saída de um neurônio
Z	Impedância
$\varphi, \varphi(v)$	Função de ativação de um neurônio
π	Célula PI de uma linha de transmissão artificial

Capítulo 1

Introdução

1.1 Considerações Iniciais

Neste capítulo são apresentados os principais objetivos desta dissertação de mestrado, assim como a estrutura utilizada em seu desenvolvimento.

1.2 Relevância do Tema

As linhas de transmissão são consideradas as “artérias” de um sistema elétrico, sendo responsáveis pelo transporte de toda a energia elétrica gerada nas usinas até os locais de sua utilização. A distância entre os locais de geração e de consumo é, na grande maioria dos casos, muito grande, exigindo a construção de linhas de transmissão de dezenas ou centenas de quilômetros que operem com a mais alta confiabilidade, uma vez que a saída de operação de uma linha de transmissão devido a uma falha pode causar enormes prejuízos econômicos e sociais a um país.

Desta forma, é essencial que se realize uma perfeita manutenção das linhas de transmissão, o que requer grande quantidade de recursos humanos e financeiros. A inspeção uma linha de transmissão, seja com a finalidade de prevenir ou corrigir um problema, é uma atividade presencial, exigindo o deslocamento de equipes de manutenção por grandes distâncias, muitas vezes em terrenos acidentados e de difícil acesso. São empregados neste tipo de atividade equipamentos e veículos caros, como câmeras de infravermelho e detecção de corona, utilitários 4 x 4 e até mesmo helicópteros.

Ainda que estes equipamentos tenham evoluído muito nas últimas décadas, tornando a manutenção das linhas de transmissão mais eficiente no que diz respeito ao seu tempo de execução e custo, fica evidente a necessidade de se desenvolver novos métodos e tecnologias capazes de, se não eliminar a necessidade da inspeção presencial, ao menos reduzir substancialmente a sua necessidade, poupando assim uma grande quantidade de recursos e tornando o sistema de transmissão mais confiável.

Atualmente existem no mercado alguns equipamentos capazes de detectar remotamente faltas elétricas, porém ainda são poucos e têm custo muito elevado. Além disso, não são capazes de detectar problemas que resultem em correntes de pequena magnitude, como aquelas geradas por descargas parciais, por exemplo. A fim de transpor estas limitações, novos métodos de detecção de falhas elétricas têm sido pesquisados. O desenvolvimento pleno desses novos métodos deve gerar

grandes oportunidades de negócios para fabricantes de equipamentos de proteção, além de levar a manutenção das linhas de transmissão a um novo e mais elevado patamar de qualidade, reduzindo drasticamente o ônus para as concessionárias e tornando o sistema elétrico mais confiável.

1.3 Objetivos

Este trabalho tem como principais objetivos:

- Reproduzir o efeito corona em laboratório através de um dispositivo acoplado a cadeia de isoladores, possibilitando a avaliação das características das formas de onda deste tipo de descarga parcial e também o desenvolvimento dos programas de reconhecimento de padrões;
- Investigar a relação entre o padrão das formas de onda geradas pelas descargas parciais do efeito corona e o local de ocorrência das mesmas. A existência de tal relação é um ponto chave deste trabalho, permitindo o desenvolvimento do método proposto;
- Verificar a possibilidade de se utilizar a capacitância entre a fase e a carcaça de um transformador de corrente como elemento de acoplamento para aquisição de sinais de alta frequência;
- Desenvolver um método destinado a identificar e localizar defeitos em cadeias de isoladores mediante o reconhecimento dos padrões das formas de onda geradas pelo efeito corona. Para este desenvolvimento são utilizados algoritmos de tratamento de sinais e inteligência artificial, cujos desempenhos são avaliados através de ensaios em laboratório.

1.4 Estrutura

Esta dissertação está estruturada em seis capítulos:

- 1 Introdução
- 2 Instalações de Laboratório Utilizadas no Desenvolvimento do Método Proposto

- 3 Técnicas Utilizadas
- 4 Método Proposto
- 5 Desenvolvimento da Ferramenta Computacional
- 6 Conclusões

No Capítulo 1 é comentada a motivação deste trabalho, mostrando a relevância do desenvolvimento do método no cenário técnico-econômico.

No Capítulo 2 estão as informações detalhadas sobre as instalações de laboratório utilizadas, incluindo o transformador de corrente em sua nova aplicação.

O capítulo 3 comenta as técnicas utilizadas no desenvolvimento do método proposto, provendo embasamento teórico sobre redes neurais e alguns algoritmos para tratamento de sinais.

O método proposto é explicado no capítulo 4, onde são comentadas a sua filosofia de funcionamento e a sistemática de ensaios de laboratório.

O desenvolvimento dos programas de identificação e localização de descargas parciais de Corona, baseados em redes neurais e dotados também de ferramentas para tratamento de sinais, é tratado no Capítulo 5.

Por fim, o Capítulo 6 apresenta as conclusões dessa dissertação e indica sugestões para trabalhos futuros.

Instalações de Laboratório
Utilizadas no
Desenvolvimento do Método
Proposto

2.1 Considerações Iniciais

Este capítulo mostra as instalações de laboratório utilizadas no desenvolvimento deste trabalho, comentando sobre a pertinência de cada um dos equipamentos e suas particularidades.

2.2 O Efeito Corona

O efeito corona é um tipo de descarga parcial que ocorre quando se tem na atmosfera um gradiente de potencial de valor superior ao gradiente de potencial disruptivo do ar. Ocorre então o processo de ionização dos gases presentes no ar, onde elétrons livres são acelerados pelo campo elétrico e que, por sua vez, podem gerar outros elétrons livres através do processo de colisão com átomos desses gases. A colisão dos elétrons livres com átomos também pode fazer com que esses sejam excitados de forma a alterar seus estados de energia, onde os elétrons que os orbitam passam a bandas mais externas. Porém, esses átomos podem retornar ao seu estado anterior, liberando o excesso de energia na forma de ondas eletromagnéticas e sonoras, fato que também pode ocorrer quando se tem a colisão de um elétron livre com um íon positivo.

Os equipamentos e dispositivos elétricos que trabalham com um nível de tensão considerável, tais como muflas, isoladores e os próprios cabos elétricos, são projetados de forma a evitar deformações no campo elétrico que possam resultar em valores inadmissíveis de gradientes de potencial. Reduz-se assim o risco de aparecimento do efeito corona, o qual resulta em diversos malefícios para o componente ou equipamento em questão e mesmo para o sistema elétrico. Dentre estes malefícios, podem ser citados a corrosão das partes metálicas de cadeias de isoladores, perdas de energia ao longo de uma linha de transmissão e radio interferência em equipamentos eletrônicos localizados em suas imediações, como receptores de rádio e televisão.

No caso de cadeias de isoladores, foco desse trabalho, o surgimento do efeito corona está associado a anomalias nas mesmas. Estas anomalias podem ser desde pequenos defeitos de fabricação, passando pelo envelhecimento natural do equipamento a quebras causadas por atos de vandalismo. Causas a parte, é fato que cadeias de isoladores problemáticas devem ser substituídas a fim de se evitar

problemas mais graves no futuro, como a queda de condutores e ocorrência de faltas elétricas, com possível interrupção do fornecimento de energia elétrica.

2.3 Sistema Elétrico Inicial

Na tese de doutorado de Adami (2008) é mostrado um método para reproduzir o efeito corona a partir da redução da capacidade de isolamento de um isolador dentro da cadeia. Isso foi conseguido mediante o uso de um garfo metálico colocado entre a campânula e o pino do isolador, conforme mostra a Figura 2.1.



Figura 2.1 - Reprodução do efeito corona por Adami (2008).

O circuito elétrico equivalente da cadeia de isoladores (Figura 2.2), dotada do garfo metálico, é baseada na modelagem utilizada por Pavlik (1989).

Os valores dos elementos do circuito foram obtidos através de medições realizadas por Adami (2008), sendo a capacitância e a resistência de cada isolador, respectivamente, $C_i = 61,5$ [pF] e $R_i = 154$ [M Ω], e a capacitância entre o isolador e a torre $C_t = 5$ [pF].

Os ensaios iniciais realizados com este método consistiam em aplicar uma tensão de 50 [kV] sobre a cadeia, fazendo com que houvesse a incidência de descargas parciais ao se aproximar o garfo metálico de um dos isoladores. Através de um capacitor de acoplamento os sinais de alta frequência gerados por estas descargas parciais puderam ser capturados, como mostra o esquema elétrico da Figura 2.3. Na Figura 2.4 tem-se um exemplo de descarga parcial obtida através desse método.




Figura 2.2 - Circuito elétrico equivalente da cadeia de isoladores com garfo para reprodução do efeito corona.

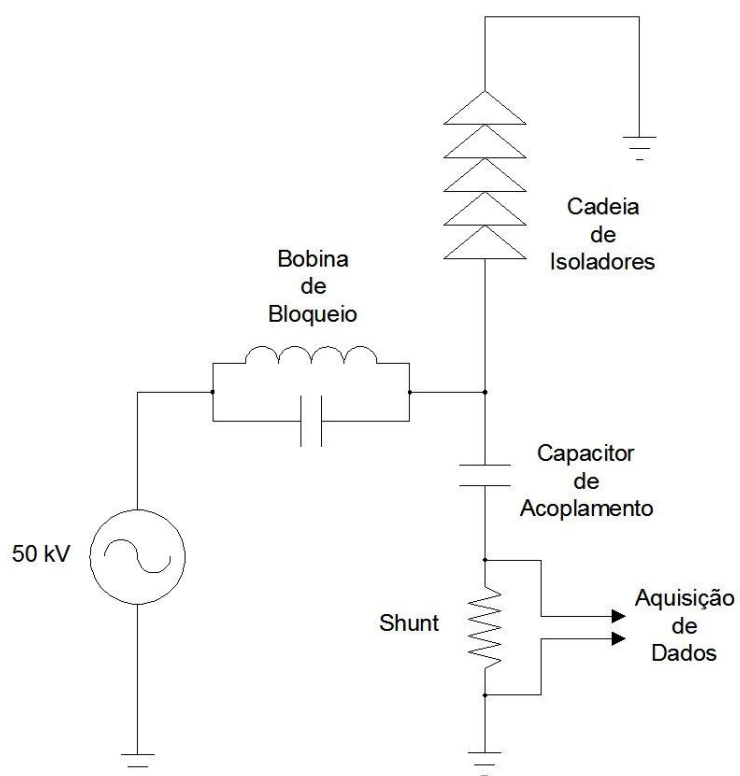


Figura 2.3 - Esquema elétrico do sistema utilizado por Adami (2008).

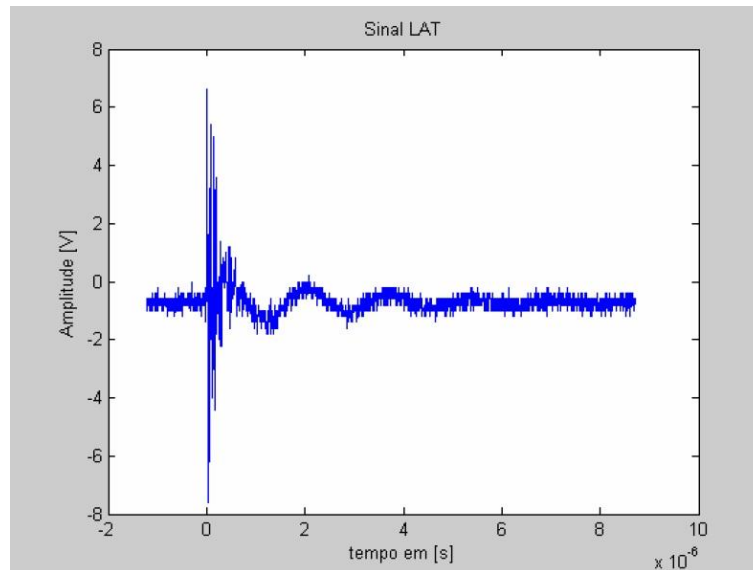


Figura 2.4 - Descarga parcial obtida por Adami (2008).

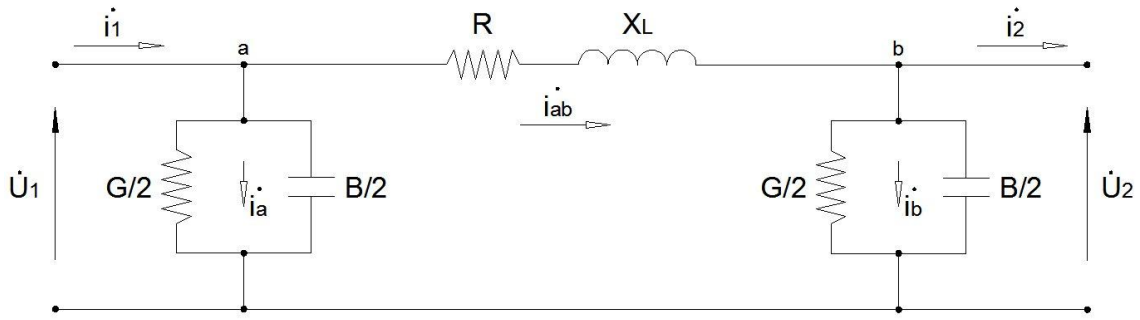
O método desenvolvido neste presente trabalho parte do sistema mostrado na Figura 2.3, tendo sido reproduzido em laboratório com resultados similares aos obtidos por Adami (2008). Os itens seguintes tratam de diversas modificações realizadas nesse sistema com a finalidade de se obter um modelo mais adequado à proposta desse trabalho.

2.4 Sistema Modificado

2.4.1 Inclusão da Linha de Transmissão

Para que um dos objetivos deste trabalho fosse cumprido foi necessário acoplar uma linha de transmissão artificial formada por células π ao sistema inicial da Figura 2.3. Assim, ao se reproduzir o efeito corona na cadeia de isoladores os sinais de descarga parcial viajam pela linha de transmissão, sendo capturados em um determinado ponto através de um acoplador capacitivo, como mostra a Figura 2.7.


Sabe-se que uma linha de transmissão pode ser representada por um circuito equivalente de parâmetros concentrados, o circuito π nominal, como mostrado na Figura 2.5, onde os parâmetros R e X_L compõem o ramo série do modelo e G e B compõem o ramo paralelo. No caso de linhas curtas, o ramo paralelo do modelo pode ser desprezado. Esse modelo pode ser descrito através das equações (1.1) e (1.2) (Fuchs, 1973).

Figura 2.5 - Circuito π nominal de uma linha de transmissão (Fuchs, 1973).

$$\dot{U}_1 = \dot{U}_2 \left(1 + \frac{\dot{Z}\dot{Y}}{2} \right) + \dot{I}_2 \dot{Z} \quad [V] \quad (1.1)$$

$$\dot{I}_1 = \dot{I}_2 \left(1 + \frac{\dot{Z}\dot{Y}}{2} \right) + \dot{U}_2 \dot{Y} \left(1 + \frac{\dot{Z}\dot{Y}}{4} \right) \quad [A] \quad (1.2)$$

Porém, quando se deseja analisar fenômenos transitórios, o circuito π nominal torna-se inadequado, pois nessa condição é necessário que se leve em consideração a distribuição dos parâmetros ao longo da linha de transmissão. Assim, para esses casos utiliza-se a linha artificial, a qual consiste de uma associação de células, como mostra a Figura 2.6 (Fuchs, 1973).

Figura 2.6 - Linha artificial criada a partir de circuitos π nominais (Fuchs, 1973).

Cada célula da linha artificial representa o circuito π nominal de um trecho de determinado comprimento da linha de transmissão, isto é, para cada célula tem-se:

$$\dot{Z}_i = \frac{\dot{Z}}{n} \quad (1.3)$$

$$\dot{Y}_i = \frac{\dot{Y}}{n} \quad (1.4)$$

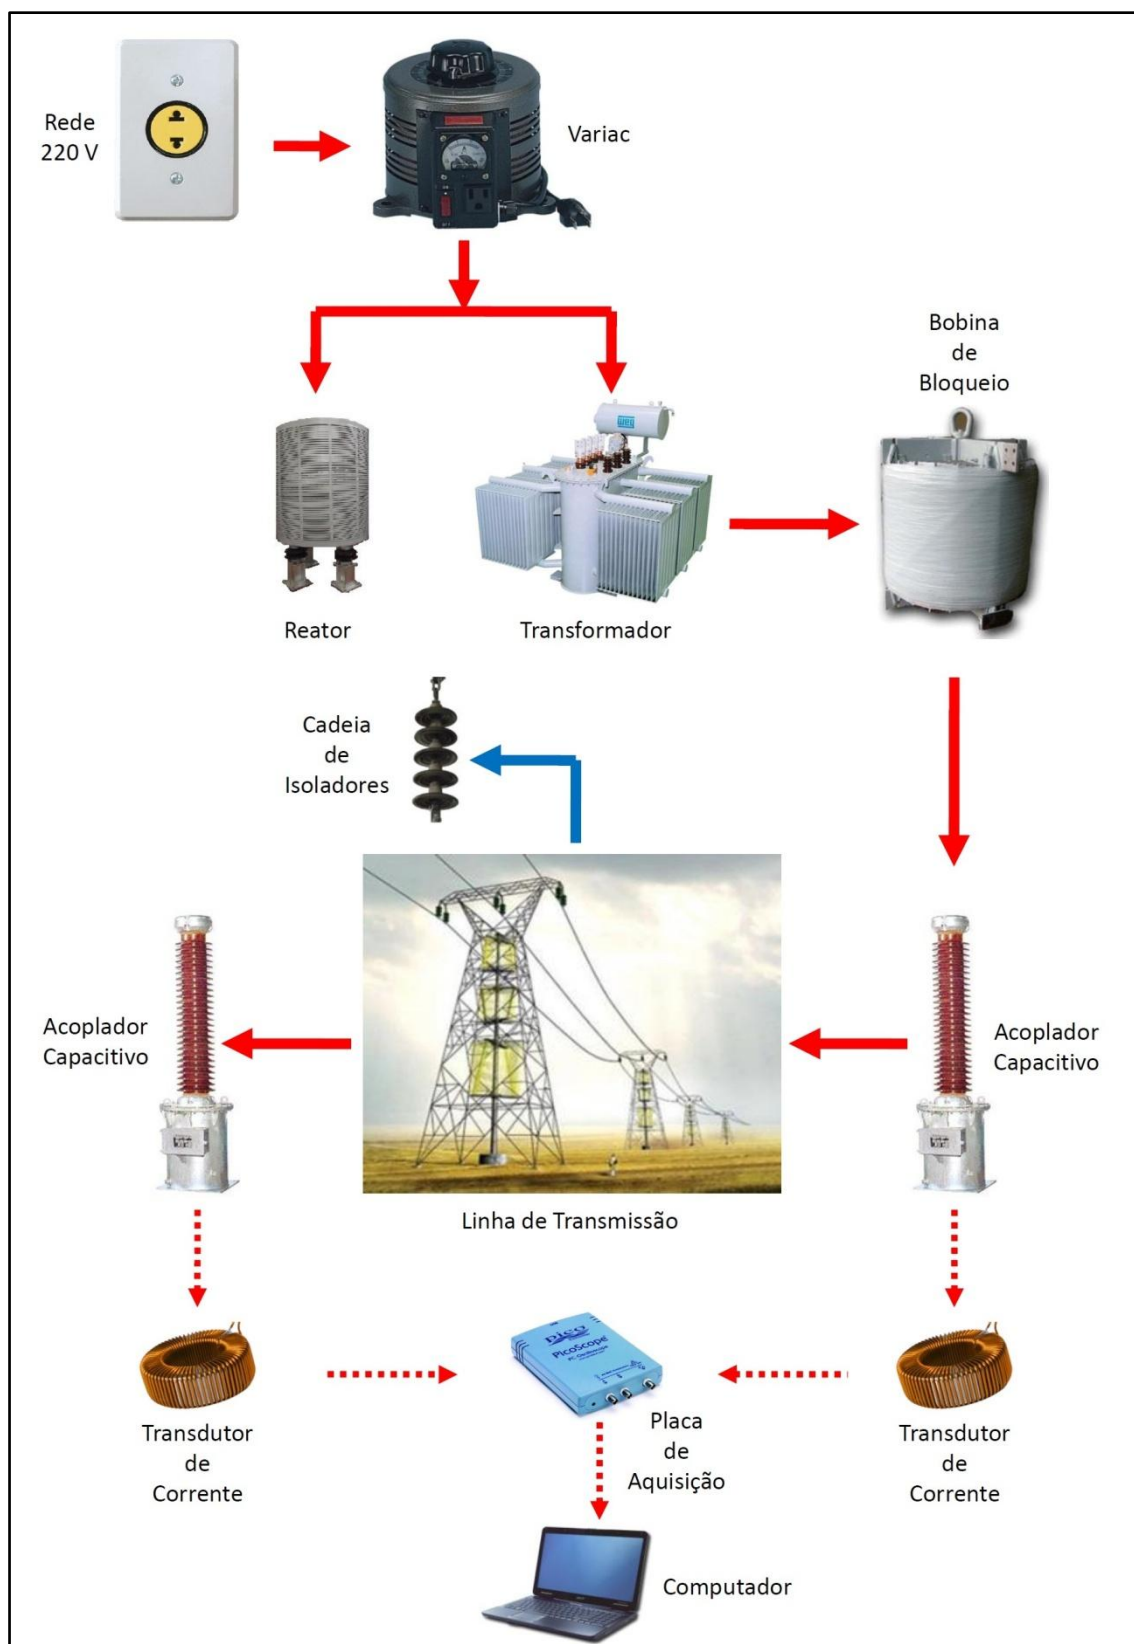


Figura 2.7 - Sistema derivado do utilizado por Adami (2008).

O sistema da Figura 2.7 conta ainda com uma bobina de bloqueio, responsável por confinar os sinais de alta frequência dentro de uma área específica da linha de transmissão. Isso torna sua topologia similar àquelas utilizadas em sistemas de transmissão de energia dotados de comunicação por *Power Line Carrier* (PLC). Nesse tipo de sistema, ondas portadoras de alta frequência, tipicamente entre 30 [kHz] a 500 [kHz], carregam informações de voz ou dados através dos cabos de média e alta tensão. Para que estes sinais viajem apenas dentro de uma determinada região da linha de transmissão, as extremidades dessa região são dotadas de bobinas de bloqueio, que oferecem elevada impedância na faixa de frequência desses sinais. Um acoplador capacitivo é então utilizado para drenar os sinais, oferecendo um caminho de baixa impedância para o sistema de aquisição de dados.

2.4.2 Utilização do Transformador de Corrente como Acoplador Capacitivo

Os acopladores capacitivos normalmente utilizados nas linhas de transmissão são os Transformadores de Potencial Capacitivos (TPC), equipamentos constituídos de um divisor capacitivo acoplado a um transformador de potencial indutivo (TPI), como mostra o esquema simplificado da Figura 2.8.




Figura 2.8 - Esquema simplificado de um TPC.

No esquema da Figura 2.8, os capacitores em série C1 e C2 formam um divisor de tensão capacitivo, o qual tem a função de reduzir o valor de tensão para um patamar adequado para o transformador de potencial indutivo, que por sua vez reduz a tensão para níveis compatíveis com instrumentos de medição e proteção. A bobina de dreno BD tem a função de oferecer baixa impedância à frequência nominal do sistema e alta impedância para frequências que estejam na faixa do sistema PLC. Assim, a bobina de dreno provê um caminho para o sinal de 60 [Hz], possibilitando a aplicação de tensão no TPI, ao passo que bloqueia este mesmo caminho para os

sinais de PLC, forçando-os a fluir pelo terminal identificado como *Carrier*. A esse terminal está acoplada a caixa de sintonia e em seguida o equipamento de PLC. A caixa de sintonia tem a função de oferecer baixa impedância para o sinal de PLC e alta impedância para o sinal de 60 [Hz], além de realizar o casamento de impedância entre o cabo coaxial que a liga ao equipamento de PLC e a linha de transmissão.

Porém, os TPCs possuem um custo de aquisição elevado e não são facilmente encontrados em campo, o que torna sua utilização no método proposto neste trabalho um tanto complicada. Desta forma, cogitou-se a utilização da capacitância entre a fase e a carcaça do Transformador de Corrente (TC) como elemento acoplador, uma vez que os TCs são abundantemente encontrados em campo, além de possuírem custo de aquisição menor quando comparados com os TPCs. Entretanto, foi necessário averiguar o comportamento dessa capacitância a fim de comprovar sua eficiência para esta aplicação. Assim, foram realizados ensaios de resposta em frequência em diversos transformadores de corrente, dos quais duas unidades têm seu comportamento mostrado neste trabalho. Para esses ensaios, foi utilizado o equipamento Omicron Franalyzer[®] (Figura 2.9), desenvolvido originalmente para ensaios de resposta em frequência de transformadores de potência.



Figura 2.9 - Primeiro ensaio com o Franalyzer[®]: ensaio de resposta em frequência em um capacitor conhecido.

A Figura 2.10 mostra o resultado do ensaio do TC Asea IMBD 72 A1, para uso em linhas de 69 [kV], onde é possível observar o comportamento da corrente que flui pela capacitância entre fase e carcaça, com variação de frequência de 20 [Hz] a 20 [MHz].




Figura 2.10 - Comportamento da corrente entre fase e carcaça do TC Asea IMBD 72 A1.

A Figura 2.11 mostra o resultado do mesmo ensaio realizado no TC Areva QDR-145/2, para uso em 145 [kV].




Figura 2.11 - Comportamento da corrente entre fase e carcaça do TC Areva QDR-145/2.

Observando-se as duas figuras anteriores, é possível notar que as regiões compreendidas entre as fases dos TCs e suas respectivas carcaças comportam-se,

isoladores fiquem restritos apenas à linha de transmissão, além de evitar que sinais de alta frequência presentes na rede entrem no sistema.

No diagrama pode-se observar que os acopladores capacitivos são representados por dois transformadores de corrente, TC1 e TC2. Ambos os TCs são utilizados para a aquisição de sinais de descargas parciais geradas na cadeia de isoladores com dispositivo de reprodução de efeito corona, porém esta aquisição não é realizada de forma simultânea. O método proposto necessita apenas de um acoplador capacitivo, sendo que foram utilizados dois TCs, um no início e outro no final da linha de transmissão, para verificar o desempenho de modelos distintos quando utilizados para esta função, além de observar o comportamento dos sinais quando capturados em posições diferentes da linha de transmissão.

Junto de cada TC está acoplado o sistema de aquisição de dados, representado pela letra M. Esse sistema é composto por transdutor de corrente, placa de aquisição e computador, sendo que a placa de aquisição e o computador são compartilhados pelos dois TCs, uma vez que a placa possui dois canais de entrada. Os transdutores de corrente consistem em pequenos TCs do tipo janela formados por núcleos retangulares de ferrite, os quais envolvem os cabos de aterramento da carcaça dos TCs. Os sinais capturados pelos transdutores de corrente são enviados para a placa de aquisição, que os digitaliza e envia para o computador. No computador os sinais são analisados pelos programas de identificação e localização de cadeias de isoladores danificadas.




Figura 2.13 - Sistema montado em laboratório.

Os itens seguintes tratam das especificações dos componentes desse sistema.

2.5.1 Transformador de Relação Variável (Variac)

Apesar da linha de transmissão montada com circuitos π representar uma linha de transmissão real de 69 [kV], esta tensão não pode ser aplicada em laboratório devido às limitações de seus componentes. Desta forma, optou-se por utilizar um autotransformador de relação de transformação variável, mais conhecido como Variac, cujas especificações estão na Tabela 2.1:

Tabela 2.1 - Especificações do Variac

Autotransformador de Relação Variável	
Fabricante	Sociedade Técnica Paulista LTDA.
Modelo	VM - 260
Tensão de Entrada [V]	220
Frequência de Entrada [Hz]	60
Tensão de Saída [V]	0 a 240
Frequência de Saída [Hz]	60
Potência Nominal [kVA]	6
Número de Fases	1

Para a realização dos ensaios uma tensão máxima de saída de 110 [V] foi utilizada, garantindo um bom funcionamento do sistema e mantendo uma margem de segurança com relação aos valores máximos suportados pelos equipamentos componentes da linha de transmissão. O Variac, juntamente com seu painel de comando, é mostrado na Figura 2.14:



Figura 2.14 - Transformador de Relação Variável (Variac).

O painel de comando é dotado de dispositivos de comando, proteção e medição, disponibilizando valores de tensão e corrente aplicados ao transformador. A proteção é realizada por dispositivos contra curto-circuito e sobrecarga. Além disso, o sistema todo é desligado quando a porta da baia onde o mesmo está localizado é aberta, garantindo a segurança das pessoas que o operam.

2.5.2 Transformador de Potência

Para que alta tensão seja aplicada à linha de transmissão é necessária a utilização de um transformador elevador (Figura 2.15), cujas especificações estão na Tabela 2.2.



Figura 2.15 - Transformador de Potência.

Como a ligação escolhida é 240 [V]: 35 [kV] e levando-se em conta que a tensão máxima aplicada ao lado de baixa tensão é de 110 [V], no lado de alta tensão tem-se aproximadamente 16 [kV] de tensão máxima aplicada.

Tabela 2.2 - Especificações do Transformador de Potência

Transformador de Potência	
Tipo	Aéreo Convencional / Óleo
Fabricante	Itaipu Transformadores
Modelo	791572401
Número de Fases	1 (Fase-Terra)
Potência [kVA]	125
Baixa Tensão [V]	240 / 120
Alta Tensão [kV]	35
Polaridade	Subtrativa
Impedância de Curto Circuito [%]	4,64

2.5.3 Bobina de Bloqueio

A bobina de bloqueio, mostrada na Figura 2.16, consiste em um filtro corta-faixa destinado a bloquear uma determinada faixa de frequência de modo a confinar sinais os sinais de descargas parciais à de linha de transmissão e evitar que outros sinais de frequência similar provenientes da rede penetrem no sistema.



Figura 2.16 - Bobina de bloqueio com dispositivo de sintonia em destaque.

. Tal função é realizada por um circuito paralelo ressonante, cuja topologia é mostrada na Figura 2.17 e seus valores configuráveis mostrados na Tabela 2.3.




Figura 2.17 - Circuito paralelo ressonante da bobina de bloqueio.

Tabela 2.3 - Faixas de corte da bobina de bloqueio.

Faixa de Bloqueio [kHz]	L1 [mH]	L2 [mH]	C1 [nF]	C2 [nF]	R [Ω]
78 a 135	0,2910	1,4582	8,2664	1,6497	420
112 a 300	0,2910	0,4570	2,5906	1,6497	420
300 a 500	0,2910	0,1024	0,5803	1,6497	420

2.5.4 Transformador de Corrente

O transformador de corrente é utilizado no desenvolvimento deste trabalho como acoplador capacitivo apenas, isto é, sua função primária é desprezada. No caso, foram utilizadas duas unidades para ensaio, uma no início da linha de transmissão (Figura 2.18) e outra em seu final (Figura 2.19), cujas especificações encontram-se na Tabela 2.4 e na Tabela 2.5:

Tabela 2.4 - Especificações do TC 1.

Transformador de Corrente 1 – Início da Linha de Transmissão	
Fabricante	ASEA
Modelo	IMBD 72 A1
Tensão Nominal [kV]	69
Frequência Nominal [Hz]	60
Relações de Transformação	40/5, 80/5



Figura 2.18 - TC 1 conectado no início da linha de transmissão.

Tabela 2.5 - Especificações do TC 2.

Transformador de Corrente 2 – Final da Linha de Transmissão	
Fabricante	Alsthom
Modelo	IH 72,5 24
Tensão Nominal [kV]	72,5
Frequência Nominal [Hz]	60
Relações de Transformação	500/5, 250/5, 125/5, 62,5/5



Figura 2.19 - TC 2 conectado no final da linha de transmissão.

2.5.4 Linha de Transmissão

A linha de transmissão artificial, a qual representa uma linha de transmissão real de 69[kV] e aproximadamente 48 [km], é formada por uma associação de circuitos

π que, por sua vez, são montados a partir de indutores e capacitores, como pode ser visto na Figura 2.20.



Figura 2.20 - Linha de transmissão formada por elementos π .

Os indutores e capacitores estão dispostos na forma de pares montados sobre plataformas móveis, trazendo flexibilidade à topologia da linha de transmissão. Além disso, cada indutor possui quatro taps, o que permite sua utilização com 25%, 50%, 75% ou 100% de seu valor nominal, conforme mostra a Figura 2.21.



Figura 2.21 - Taps de indutor utilizado em um dos elementos π .

A existência destes taps permite que a cadeia de isoladores seja acoplada a 48 posições ao longo da linha de transmissão, fato de suma importância para a realização dos ensaios.

A Tabela 2.6 e a Tabela 2.7 contêm as especificações dos indutores e dos capacitores que compõem a linha de transmissão.

Tabela 2.6 - Especificações dos indutores.

Indutores (Reatores Limitadores de Corrente)	
Fabricante	Areva
Modelo	LCT-16200/10
Indutância Nominal [mH]	$16.2 \pm 3\%$
Taps [%]	-75, -50, -25, 0
Frequência Nominal [Hz]	60
Corrente Nominal [A]	10
Tensão Nominal [V]	600
Potência Nominal [kVAr]	0,61
Icc Térmica [kA]/[s]	0,1 / 1
Icc Dinâmica [kA]	0,255
Impedância Nominal [Ω]	6,107

Tabela 2.7 - Especificações dos capacitores.

Capacitores	
Fabricante	IESA
Modelo	VDC
Capacitância Nominal [μF]	0,02
Tensão Nominal [kVdc]	50

2.5.5 Cadeia de Isoladores

Formada por 5 isoladores de porcelana (Figura 2.22), a cadeia de isoladores utilizada no desenvolvimento desse trabalho é dotada de um dispositivo de reprodução de efeito corona. Este dispositivo, como mostra a Figura 2.23, é formado por um condutor de alumínio montado entre o pino e a campânula de um dos isoladores, resultando em uma drástica redução da isolação do isolador em questão e, por conseguinte, da cadeia como um todo.



Figura 2.22 - Cadeia de isoladores de porcelana utilizada nos ensaios.

Fixada no teto do laboratório e devidamente aterrada, a cadeia de isoladores é conectada aos taps dos indutores da linha de transmissão artificial através de um condutor de alumínio nu. Sua localização, no centro do sistema, permite a rápida mudança de configuração dos ensaios.



Figura 2.23 - Reprodução do efeito corona.

Na Figura 2.24 pode-se observar a descarga parcial entre uma das extremidades do condutor de alumínio e a campânula de um dos isoladores da cadeia. Alterando-se a distância entre o condutor e a campânula é possível variar a frequência de ocorrência das descargas parciais assim como sua amplitude, sendo que durante o desenvolvimento deste trabalho essa distância foi mantida sem alterações.




Figura 2.24 - Descarga parcial durante reprodução do efeito corona.

A Tabela 2.8 contém as especificações dos isoladores de disco utilizados na composição da cadeia de isoladores:

Tabela 2.8 - Especificações dos Isoladores de Porcelana.

Isolador de Suspensão (Disco)	
Fabricante	Isoladores Santana S.A.
Modelo	DI 33C34
Material Dielétrico	Porcelana Aluminosa
Tipo de Fixação	Concha - Bola
Norma	IEC
Passo [mm]	146
Diâmetro [mm]	254
Distância de Escoamento [mm]	320
Ruptura Eletromecânica Combinada [kN]	80
Carga de Ensaio de Rotina [kN]	32
Tensão Suportável de Impulso [kV]	110
Perfuração Sob Óleo [kV]	130
Tensão Crítica de Impulso Mínima a 50% [kV]	120
Tensão Crítica de Impulso Mínima a 50% [kV]	125
Tensão Disruptiva a Freqüência Industrial Mínima – Seco [kV]	78
Tensão Disruptiva a Freqüência Industrial Mínima – Sob Chuva [kV]	45
Tensão Suportável a Freqüência Industrial [kV]	70
Tensão Suportável a Freqüência Industrial [kV]	40

A fim de atestar a independência do sistema de reprodução de efeito corona do tipo de material utilizado na confecção dos isoladores, foram realizados alguns ensaios com outras duas cadeias de isoladores: uma formada por isoladores de vidro e outra formada tanto por isoladores de vidro quanto de porcelana. Em ambos os casos não houve alteração no padrão da descarga parcial gerada que afetasse o desempenho dos programas de identificação e localização de cadeias de isoladores danificadas.

2.5.6 Reator

A linha de transmissão artificial utilizada no desenvolvimento desse trabalho, como visto no diagrama esquemático da Figura 2.12, opera sem carga. Sabendo-se que este tipo de linha de transmissão tem caráter fortemente capacitivo, ao ser energizada a linha de transmissão representa para a rede uma carga capacitiva de valor considerável.

Com a finalidade de adequar o sistema à capacidade de fornecimento da rede e reduzir o consumo de energia reativa, foi instalado um reator em paralelo com o lado de baixa tensão do transformador. O reator pode ser configurado para trabalhar com 11 valores de indutância através de taps, como mostra a Figura 2.25, tornando possível o uso de frações da linha de transmissão artificial.



Figura 2.25 - Reator configurável por taps.

Suas especificações e possibilidades de configuração são mostradas, respectivamente, na Tabela 2.9 e na Tabela 2.10.

Tabela 2.9 - Especificações do reator.

Reator	
Fabricante	Areva
Modelo	SHED-1200/600
Indutância Nominal [mH]	1,218
Tensão Nominal [kV]	0,470
Frequência Nominal [Hz]	60
Corrente Nominal [A]	600
Potência Nominal [kVAr]	163
Icc Térmica [kA]/[s]	1 / 1
Icc Dinâmica [kA]	2,6

Tabela 2.10 - Possíveis configurações do reator.

Configuração do Reator	
Tap	Indutância [mH]
1	1,218
2	1,095
3	0,974
4	0,854
5	0,708
6	0,593
7	0,484
8	0,352
9	0,233
10	0,126
11	0,054

2.5.7 Transdutor de Corrente

O transdutor de corrente utilizado consiste em um pequeno transformador de corrente do tipo janela baseado em um núcleo de ferrite (Figura 2.26). O mesmo é instalado de forma a envolver o cabo de aterramento da carcaça do TC, isto é, é magneticamente conectado ao terminal secundário do acoplador capacitivo. Os sinais de descargas parciais capturados pelo transdutor são enviados à placa de aquisição através de um cabo coaxial blindado RGC-59.



Figura 2.26 - Transdutor de corrente.

As características básicas deste transdutor são mostradas na Tabela 2.11, juntamente com o diagrama dimensional da Figura 2.27.




Figura 2.27 - Diagrama dimensional do núcleo de ferrite NU-40/27/11-IP6 extraído do catálogo da Thornton.

Tabela 2.11 - Especificações do transdutor de corrente.

Transdutor de Corrente			
Informações Gerais		Dimensões	[mm]
Modelo do Núcleo	NU-40/27/11-IP6	A	39,60
Fabricante do Núcleo	Thornton Eletrônica Ltda.	B	25,00
Material do Núcleo	IP6	C	17,90
Massa do Núcleo [g]	34,00	D	27,40
Número de Espiras do Primário	Variável	E	3,20
Número de Espiras do Secundário	9	F	11,20

2.5.8 Placa de Aquisição

Para realizar a aquisição dos sinais de descargas parciais gerados na cadeia de isoladores utilizou-se uma placa de aquisição modelo PicoScope 3205 (Figura 2.28), a qual funciona como um osciloscópio digital quando utilizada com o Software PicoScope 6, fornecido com a mesma. Existe ainda a opção de se desenvolver um software específico para a aplicação, já que também é fornecido com o equipamento um kit de desenvolvimento para linguagem C/C++, porém tal desenvolvimento não foi necessário uma vez que o software PicoScope 6 supre todas as necessidades.




Figura 2.28 - Placa de aquisição e computador realizando aquisição de dados.

Por possuir dois canais de entrada, foi possível analisar as diferenças entre os sinais quando capturados no início ou no final da linha de transmissão, através do TC1 e do TC2 respectivamente.

A Tabela 2.1 contém as especificações básicas da placa PicoScope 3205.

Tabela 2.12 - Especificações da placa de aquisição.

PicoScope 3205	
Fabricante	PicoTechnology Limited
Largura de Banda [Mhz]	100
Taxa de Amostragem [MS/s]	100
Resolução Vertical [bits]	8
Base de Tempo	2 [ns/div] a 50 [s/div]
Range	10 [mV/div] a 2 [V/div]
Canais	2 canais de entrada; 1 canal de trigger externo/gerador de função
Conexão com o Computador	USB 2.0

2.6 Considerações Finais

Este capítulo apresentou o funcionamento geral do sistema montado em laboratório, explicando a função de cada um de seus componentes. De grande importância para este trabalho, viu-se como é realizada a reprodução de descargas parciais de efeito corona e também como estas são capturadas pelos transformadores de corrente, que neste caso atuam como acopladores capacitivos.

Capítulo 3

Técnicas Utilizadas

3.1 Considerações Iniciais

Este capítulo apresenta as técnicas utilizadas na construção dos programas de identificação e localização de cadeias de isoladores danificadas. São mostradas as técnicas de tratamento de sinais aplicadas aos sinais de descargas parciais antes de serem utilizados pelos programas de reconhecimento de padrões, necessárias para que se minimize o esforço computacional e utilização de memória. Também é provido embasamento teórico de redes neurais, que é a técnica de inteligência artificial utilizada para o reconhecimento de padrões.

3.2 Redes Neurais Artificiais

3.2.1 Introdução

As redes neurais artificiais, chamadas somente de redes neurais a partir desse ponto, consistem em uma técnica de Inteligência Artificial baseada em uma modelagem simplificada do sistema nervoso humano. Assim como o cérebro humano, são capazes de *aprender* sobre o seu ambiente de atuação, assimilando conhecimento para uso posterior. Dentre suas características pode-se citar:

- Capacidade de *generalizar*, isto é, de fornecer resultados corretos a partir de entradas não exatamente iguais às utilizadas durante seu *aprendizado*;
- Possuem estrutura maciçamente distribuída, isto é, seu conhecimento adquirido é armazenado de forma “pulverizada”, o que torna as redes neurais muito tolerantes a falhas;
- Permitem a avaliação da confiabilidade de seus resultados, resultando em algoritmos de tomadas de decisão mais confiáveis;
- Conseguem se adaptar facilmente às novas condições do meio, permitindo a criação de sistemas altamente estáveis;
- A complexidade de sua estrutura não permite a fácil visualização de sua base de conhecimento, sendo muitas vezes encaradas como “caixas pretas”;

- Seu treinamento (*aprendizado*) pode demandar muito tempo e exigir um hardware de alta capacidade computacional;

Devido a sua natureza, as redes neurais têm tido êxito considerável quando aplicadas a tarefas de reconhecimento de padrões e classificação, mas seu uso não se limita a isso. Também são utilizadas na previsão de séries temporais, aproximação de funções, entre outros. Seu campo de aplicação é cada vez maior, tendo rompido os limites das ciências exatas, sendo utilizadas atualmente também em áreas como medicina, economia e ciências sociais.

3.2.2 O Sistema Biológico

De modo grosseiro pode-se dizer que o sistema nervoso humano é composto por uma central de processamento, o cérebro, e por sensores e atuadores. O cérebro, por sua vez, é formado por uma enorme quantidade de unidades básicas de processamento denominadas *neurônios*. Uma representação de um neurônio típico pode ser observada na Figura 3.1.




Figura 3.1 - Neurônio típico (Thibodeau, 2002).

Os neurônios são constituídos por três partes: corpo celular, dentritos e axônio. Os dentritos são responsáveis por receber impulsos elétricos (informações) e enviá-los ao corpo celular para que sejam processados. O resultado desse processamento é também um impulso elétrico, o qual é propagado através do axônio. O local de conexão entre um neurônio e outro é chamado de *sinapse*, e através deste os neurônios são interligados paralelamente, formando a rede neural Biológica (Thibodeau, 2002).

Um neurônio pode ser comparado com uma unidade de operação básica de silício. Nesse caso, tem-se que, em média, um neurônio é cerca de um milhão de vezes mais lento que um circuito de silício (10^{-9} [s/operação] x 10^{-3} [s/operação]), porém gasta 10 bilhões de vezes menos energia (10^{-16} [J/operação.s] x 10^{-6} [J/operação.s]). Ainda assim o cérebro humano é muito mais rápido que qualquer computador já construído, compensando a baixa velocidade dos neurônios através da associação em paralelo dos mesmos. A rede neural do cérebro humano é composta por aproximadamente 10 bilhões de neurônios e 60 trilhões de sinapses, resultando na formação de uma estrutura maciçamente paralela. O processamento de informações nessa estrutura é, portanto, bem diferente daquele realizado nos atuais computadores, onde as informações são processadas de maneira seqüencial. Também é bastante diferente a forma com que as informações são armazenadas, uma vez que no cérebro humano as informações são organizadas de acordo com suas características e estão distribuídas ao longo da estrutura (Haykin, 2001).

3.2.3 O Neurônio Artificial

Inspirado no neurônio biológico e desenvolvido a partir de trabalhos conjuntos entre profissionais das áreas de ciências biológicas, humanas e exatas, o neurônio artificial pode ser definido como sendo a unidade de processamento fundamental de uma rede neural. Sua representação gráfica pode ser vista na Figura 3.2:

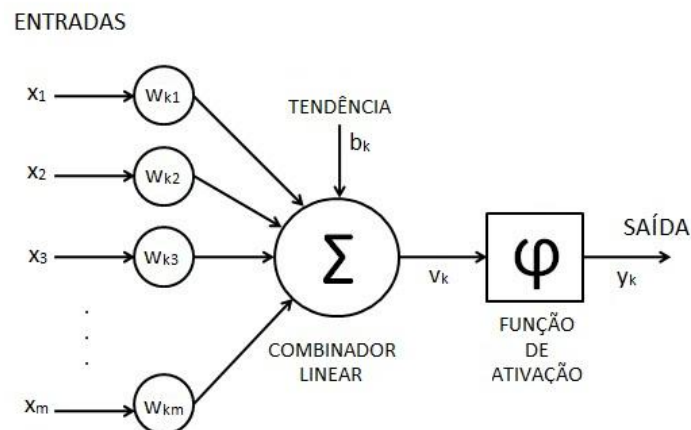


Figura 3.2 - Neurônio artificial não-linear (Haykin, 2001).

O neurônio artificial recebe os sinais a serem processados através de conexões chamadas *sinapses*, análogas às dos neurônios biológicos. Estes sinais são ponderados pelos *pesos sinápticos*, que podem assumir valores positivos ou negativos, ao contrário de seus correspondentes biológicos. Os sinais ponderados são então enviados a um somador (*combinador linear*) e o resultado, que pode ter seu

valor deslocado pela tendência (*bias*), é limitado pela *função de ativação*, que será discutida mais adiante. Esse neurônio pode ser representado pelas equações (3.1) e (3.2):

$$u_k = \sum_{j=1}^m w_{kj} \cdot x_j \quad (3.1)$$

$$y_k = \varphi(u_k + b_k) \quad (3.2)$$

onde k é o neurônio que compõe determinada rede neural, x_j são os sinais de entrada, w_{kj} são os pesos sinápticos do neurônio, u_k é a combinação linear das entradas, b_k é a tendência e φ é a função de ativação, como pode ser observado na Figura 3.2. A equação (3.2) fica mais clara ao se observar graficamente seu efeito sobre a combinação linear das entradas devidamente ponderadas pelos pesos sinápticos, como mostra a Figura 3.3:




Figura 3.3 - Efeito da tendência b_k (Haykin, 2001).

onde v_k , denominado campo local induzido, é a saída do combinador linear deslocada pela tendência b_k , podendo ser representado pela equação (3.3):

$$v_k = u_k + b_k \quad (3.3)$$

A função de ativação φ pode assumir diversas formas, dentre as quais se destacam três tipos básicos: função de limiar (a), função linear por partes (b) e função sigmóide (c), representadas na Figura 3.4:

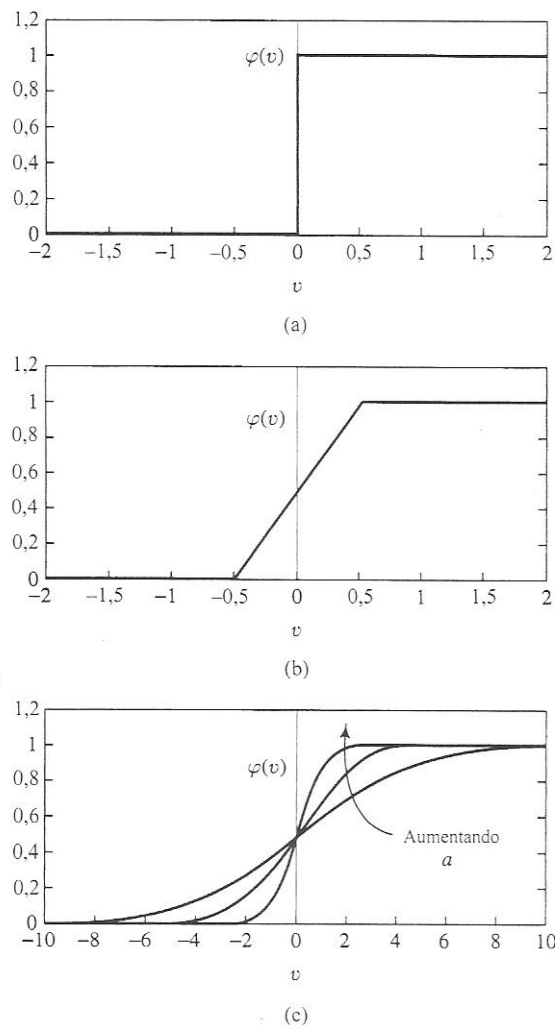


Figura 3.4 - Funções de ativação: função de limiar (a), função linear por partes (b) e função sigmóide (c) (Haykin, 2001).

A função de limiar, também chamada de função de Heaviside, é descrita pela equação (3.4):

$$y_k = \begin{cases} 1 & \text{se } v_k \geq 0 \\ 0 & \text{se } v_k < 0 \end{cases} \quad (3.4)$$

onde v_k é o campo local induzido do neurônio, representado pela equação (3.5):

$$v_k = \sum_{j=1}^m w_{kj} + b_k \quad (3.5)$$

O neurônio dotado deste tipo de função de ativação é conhecido como *modelo de McCulloch-Pitts*, sendo oriundo do trabalho pioneiro destes dois cientistas no campo de neurocomputação.

A função linear por partes é representada pela equação (3.6):

$$\varphi = \begin{cases} 1, v \geq +1/2 \\ v, +1/2 > v > -1/2 \\ 0, v \leq -1/2 \end{cases} \quad (3.6)$$

sendo que a mesma pode ser entendida como sendo uma aproximação de um amplificador não-linear.

Enfim, a equação (3.7) representa um tipo função sigmóide (função logística),

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (3.7)$$

onde a é o parâmetro de inclinação da função.

A função sigmóide é a mais utilizada na construção de redes neurais, apresentando como vantagens em relação aos outros dois tipos anteriormente mostrados a disponibilidade de um intervalo de valores contínuos entre 0 e 1 e o fato de ser diferenciável.

3.2.4 Arquiteturas de Rede

A arquitetura de uma rede neural é o modo como seus neurônios estão interligados, sendo que dela depende fortemente o processo de aprendizagem. Existem três tipos fundamentais de arquitetura de rede: a rede alimentada adiante com camada única, a rede alimentada diretamente com múltiplas camadas e a rede recorrente.

A mais simples das arquiteturas é a rede alimentada adiante com camada única, exemplificada na Figura 3.5:




Figura 3.5 - Rede alimentada adiante com camada única (de neurônios).

Este tipo de arquitetura é formado por uma camada de nós de entrada e por uma camada de neurônios de saída, sendo que a informação se propaga apenas para frente.

A rede alimentada diretamente com múltiplas camadas ainda trabalha com a propagação da informação em uma só direção, porém é dotada de camadas intermediárias (ou ocultas) entre as camadas de entrada e de saída, tornando a rede capaz de extrair estatísticas de ordem elevada. A Figura 3.6 exemplifica uma rede deste tipo dita *totalmente conectada*, isto é, um neurônio de uma camada está conectado a todos os outros das camadas adjacentes. Caso esta condição não seja verdadeira, a rede é chamada de *parcialmente conectada*.




Figura 3.6 - Rede alimentada diretamente com múltiplas camadas.

Com maior capacidade de aprendizado, a rede recorrente é caracterizada pela presença de pelo menos um laço de realimentação, como exemplifica a Figura 3.7:




Figura 3.7 - Rede recorrente.

Os laços de realimentação, dotados de elementos de atraso unitário, fazem com que esse tipo de rede tenha comportamento dinâmico não-linear.

3.2.5 Aprendizagem

Uma das habilidades mais importantes de uma rede neural é a capacidade de *aprender*, isto é, capturar informações do seu ambiente de forma a melhorar o seu desempenho.

De uma forma um pouco mais formal, pode-se dizer que a *aprendizagem* é o processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre (Haykin, 2001).

Durante o processo de aprendizagem três passos principais são cumpridos, como mostra a Figura 3.8:




Figura 3.8 - Principais passos da aprendizagem da rede neural.

onde os parâmetros livres são os pesos w_{kj} e as tendências b_k dos neurônios.

A aprendizagem de uma rede neural pode ser *supervisionada* ou *não-supervisionada*. Quando realizada de forma supervisionada, como mostra a Figura 3.9, a rede neural aprende através de um conjunto de exemplos entrada-saída.

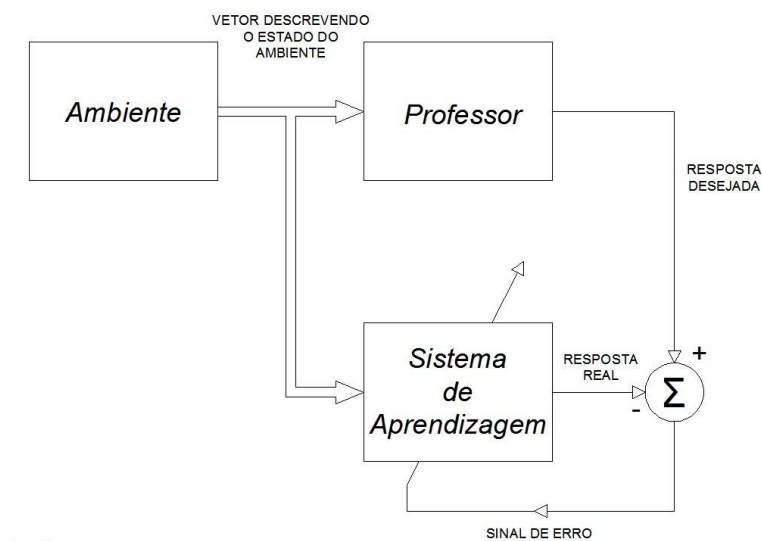


Figura 3.9 - Aprendizagem supervisionada (Haykin, 2001).

Por exemplo, suponha-se que a intenção seja ensinar a rede a reconhecer os caracteres R, M e C e que cada um destes caracteres seja representado por um vetor. Com relação à topologia da rede, neste exemplo, tem-se que a quantidade de nós da camada de entrada é numericamente igual à dimensão dos vetores que representam os caracteres, ao passo que a camada de saída possui três neurônios. Cada neurônio de saída representa um caractere, sendo a sua saída igual a um quando seu respectivo caractere é reconhecido e zero quando o mesmo não é reconhecido. Assim, o processo de aprendizado (*treinamento*) consiste em apresentar a rede, através de um *professor*, os vetores que representam os caracteres e as respectivas saídas desejadas, de forma que a rede ajuste seus parâmetros internos. Depois de treinada, a rede deve ser capaz de reconhecer os caracteres mesmo que estes não sejam exatamente iguais aos utilizados no treinamento, isto é, deve ser capaz de

reconhecer o mesmo caractere escrito por várias *caligrafias*. Isso é a capacidade de *generalizar*.

Já na aprendizagem não-supervisionada, representada na Figura 3.10, não há um professor para auxiliar o treinamento. Nesse caso, existem condições para se realizar uma medida da qualidade do aprendizado da rede, sendo que os parâmetros livres são ajustados a partir dessa medida.




Figura 3.10 - Aprendizagem não-supervisionada (Haykin, 2001).

3.3 Tratamento de Sinais

A placa de aquisição utilizada na digitalização dos sinais de descargas parciais, a PicoScope 3205, trabalhou com sua capacidade máxima durante os ensaios de desenvolvimento das redes neurais. Assim, sendo sua taxa de amostragem 100 [MS/s] e a janela de aquisição igual a 5 [µs], cada sinal digitalizado foi representado por 500 amostras, ou seja, um vetor contendo 500 valores.

Tal quantidade de amostras exige um esforço computacional muito grande no treinamento das redes neurais. Dessa forma, foi necessário tratar os sinais adquiridos antes de enviá-los para o treinamento das redes neurais, filtrando-os, comprimindo-os ou mesmo cortando partes menos relevantes de suas formas de onda através de algoritmos que são tratados nos itens seguintes.

3.3.1 Tratamento por Corte do Sinal

A grande maioria dos arquivos gravados pela placa de aquisição apresentava forma de onda semelhante ao da Figura 3.11:

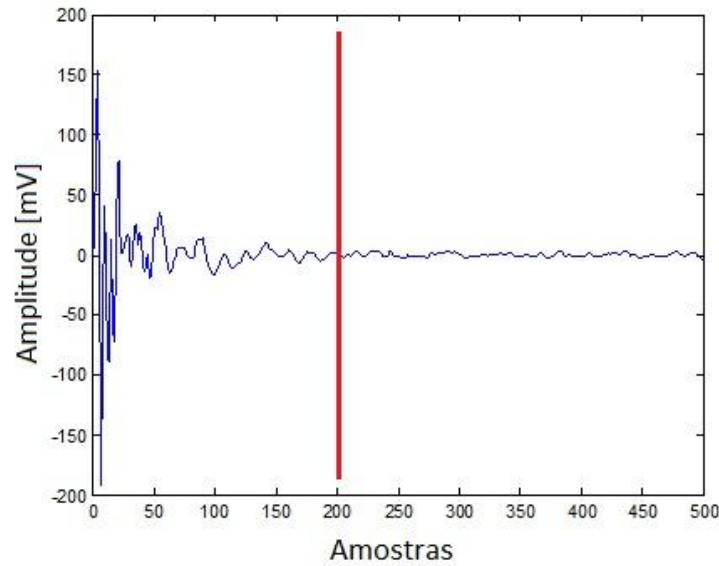


Figura 3.11 - Forma de onda típica adquirida em uma janela de 5 μ s.

Pode-se então observar que a parte relevante do sinal, em média, está situada até a amostra de número 200, ou seja, o sinal é composto em sua maioria por informações inúteis. Este excesso de informações tende a deixar o treinamento das redes neurais bem mais lento, assim como o reconhecimento de padrões, ainda que este caso seja bem menos crítico.

Desta forma, um dos métodos utilizados para aliviar o esforço computacional realizado pelas redes neurais foi eliminar a parte do sinal que continha informações irrelevantes, cortando-o a partir da amostra de número 201.

3.3.2 Tratamento por Filtragem Convencional

Outra forma de tornar o processamento da rede neural mais rápido é a filtragem dos sinais antes do treinamento, eliminando informações de frequências de amplitude irrelevante.

Observando-se o espectro de frequências típico da Figura 3.12, vê-se que a partir de 40 [MHz] aproximadamente as componentes do sinal apresentam amplitudes muito baixas se comparadas àquelas de maior amplitude. Assim, é plausível que as informações destas componentes sejam ceifadas do sinal. É possível ainda, dependendo do caso, eliminar algumas componentes relevantes do sinal sem grandes perdas de desempenho da rede neural no que se refere ao reconhecimento. Dessa forma, consegue-se tornar o treinamento ainda mais rápido.




Figura 3.12 - Espectro de frequências típico dos sinais de descargas parciais gerados pelo dispositivo de reprodução de efeito corona.

3.3.3 Tratamento por Compressão – *Linear Predictive Coding (LPC)*

O LPC, geralmente traduzido na literatura como *Codificação por Predição Linear*, é um dos métodos mais utilizados na compressão de voz, tendo sido criado em meados da década de 1960 no laboratório Bell Labs (Park, 2010). Por ter sido originalmente desenvolvido para voz humana, a qual ainda é sua aplicação principal, é classificado como sendo um tipo de *vocoder*. Os *vocoders* são codificadores de voz, muito utilizados em sistemas de telefonia, sendo sua função representar os sinais de voz por determinados parâmetros. A vantagem da codificação é que o conjunto de parâmetros ocupa uma menor quantidade de dados em relação ao sinal original, facilitando a transmissão dos mesmos.

A filosofia desse método de compressão é representar uma amostra $x[n]$ pela combinação linear de P amostras anteriores, configurando um filtro tipo FIR, como mostra a equação (3.8):

$$\hat{x}[n] = \sum_{k=1}^{k=P} a_k \cdot x[n-k] \quad (3.8)$$

onde $\hat{x}[n]$ é a amostra estimada, $x[n-k]$ são as amostras anteriores e a_k são os pesos das amostras anteriores, isto é, os coeficientes da combinação linear (Park, 2010).

De forma a minimizar os erros de estimação, os coeficientes a_k são ajustados de acordo com a equação (3.9):

$$e[n] = x[n] - \hat{x}[n] \quad (3.9)$$

onde $x[n]$ é a amostra real.

3.4 Considerações Finais

As técnicas mostradas nesse capítulo são fundamentais para o desenvolvimento dos algoritmos dos programas utilizados para o reconhecimento de padrões de descargas parciais. Porém, as técnicas de filtragem de sinais não são imprescindíveis para o funcionamento dos programas, fato a ser tratado no Capítulo 5.

Capítulo 4

Método Proposto

4.1 Considerações Iniciais

Este capítulo explica o método proposto, mostrando como as redes neurais são aplicadas na identificação e localização de cadeias de isoladores.

4.2 Filosofia do Método

Durante a reprodução do ensaio realizado por Adami (2008), executado conforme o esquema elétrico da Figura 2.3, foi observado que existe um padrão nas formas de onda das descargas parciais geradas com o auxílio do garfo metálico. Notou-se também que esse padrão é alterado conforme a posição do garfo metálico na cadeia de isoladores.

O mesmo comportamento foi observado durante os ensaios realizados no sistema modificado, mostrado no esquema elétrico da Figura 2.12. Isto é, o padrão da forma de onda das descargas parciais capturadas através dos TCs é alterado conforme a posição do dispositivo de reprodução de efeito corona na cadeia de isoladores e também conforme a localização da cadeia de isoladores na linha de transmissão artificial. Como exemplo, seja o sistema apresentado na Figura 4.1:

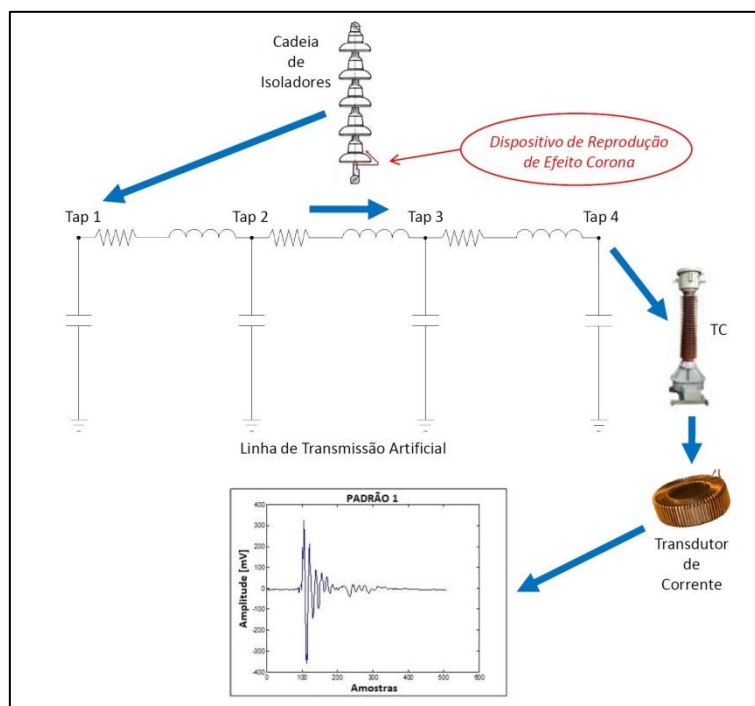


Figura 4.1 - Padrão de forma de onda gerada por descarga parcial com a cadeia de isoladores conectada ao tap 1.

O exemplo da Figura 4.1 mostra um sistema composto por uma linha de transmissão artificial com quatro taps disponíveis, onde é possível acoplar uma cadeia de isoladores dotada de dispositivo de reprodução de efeito corona. Esse dispositivo, por sua vez, pode ser instalado em qualquer um dos cinco isoladores da cadeia.

Uma vez energizado o sistema, sinais de descargas parciais são gerados na cadeia de isoladores, percorrendo a linha de transmissão e sendo finalmente capturados através do TC. O circuito elétrico formado entre o dispositivo de reprodução de efeito corona e o transdutor de corrente influencia no padrão da forma de onda das descargas parciais capturadas, ou seja, uma vez alterado esse circuito, o padrão da forma de onda também muda.

No caso da Figura 4.1 é mostrado um exemplo do padrão de forma de onda relacionado à configuração em questão: dispositivo de reprodução de efeito corona conectado ao quinto isolador, contando-se os isoladores do topo da cadeia para a sua base, e cadeia de isoladores conectada ao tap 1.

Ao se alterar a localização da cadeia de isoladores para o tap 2, mantendo-se a posição do dispositivo de reprodução de efeito corona na cadeia de isoladores, observa-se a mudança de padrão nas formas de onda capturadas, como mostra a Figura 4.2.

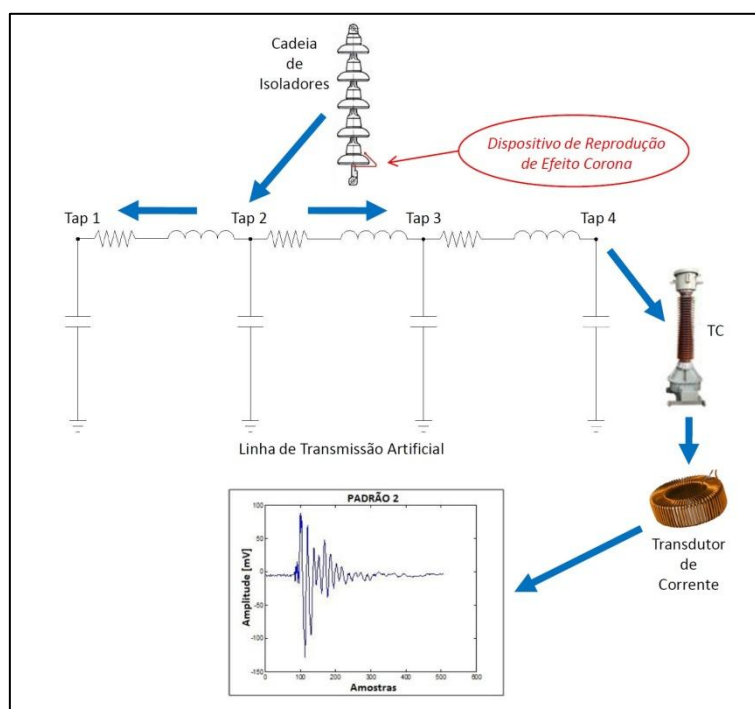


Figura 4.2 - Padrão de forma de onda gerada por descarga parcial com a cadeia de isoladores conectada ao tap 2.

O mesmo pode ser notado na Figura 4.3 e Figura 4.4, onde a localização da cadeia de isoladores é novamente alterada, sendo conectada aos taps 3 e 4, respectivamente.

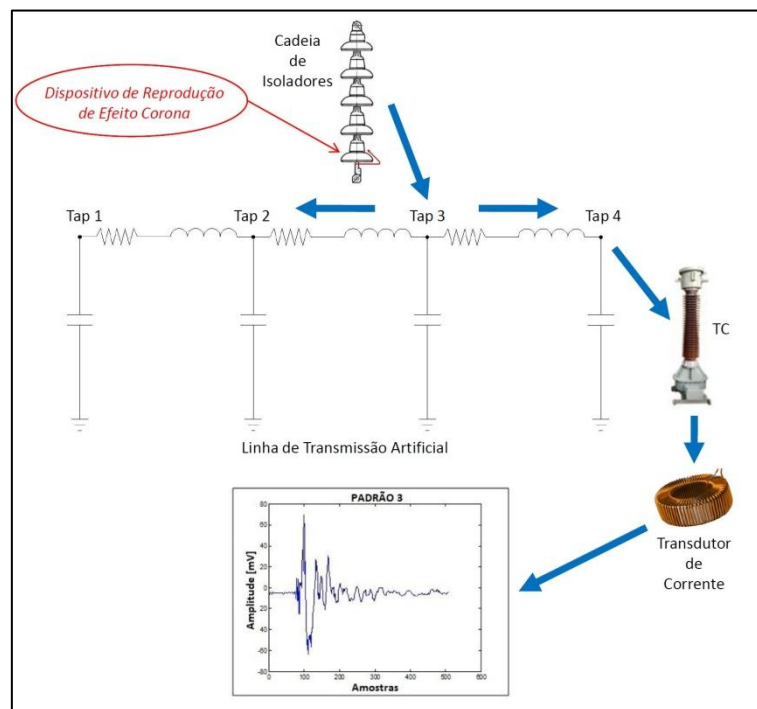


Figura 4.3 - Padrão de forma de onda gerada por descarga parcial com a cadeia de isoladores conectada ao tap 3.

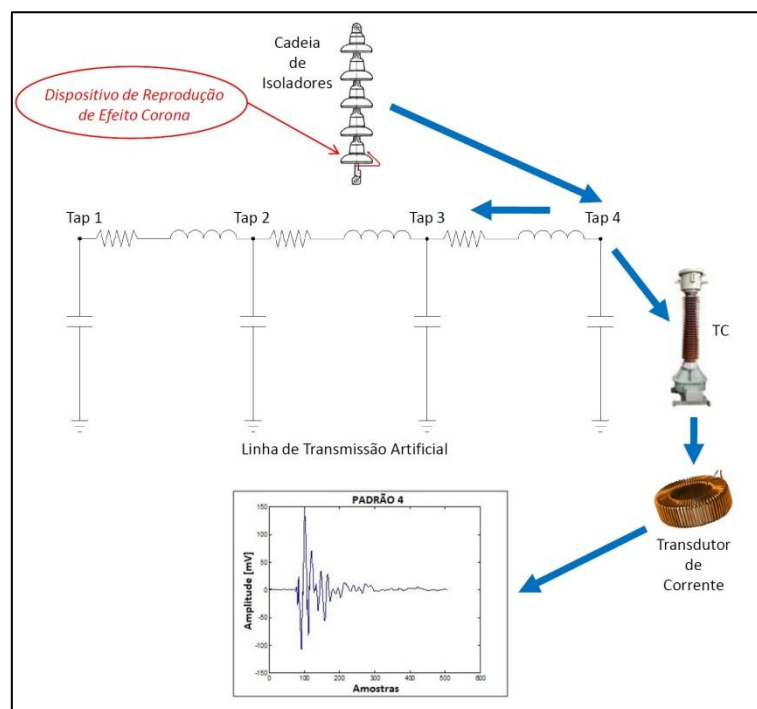


Figura 4.4 - Padrão de forma de onda gerada por descarga parcial com a cadeia de isoladores conectada ao tap 4.

Mantendo-se a localização da cadeia de isoladores no tap 4, como mostrado na Figura 4.4, e alterando a posição do dispositivo de reprodução de efeito corona para o segundo isolador tem-se um novo padrão de forma de onda, como mostra a Figura 4.5

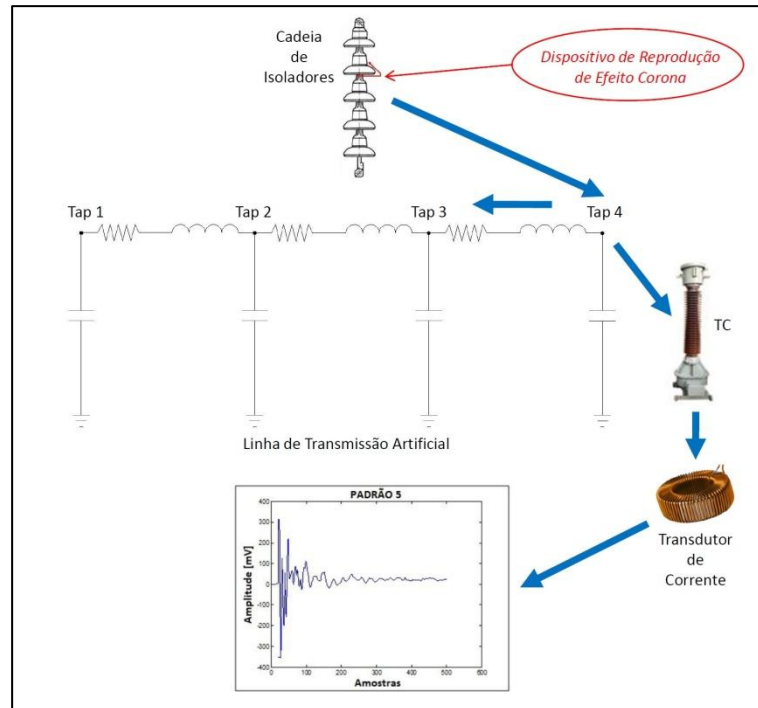


Figura 4.5 - Padrão de forma de onda gerada por descarga parcial com a cadeia de isoladores conectada ao tap 4 e dispositivo de reprodução de efeito corona em posição diferente das anteriores.

Assim, viu-se a possibilidade de se identificar a origem das descargas parciais na cadeia de isoladores e também localizar a própria cadeia de isoladores na linha de transmissão através dos padrões de forma de onda gerados.

Para tal, seria necessário empregar uma ferramenta computacional que permitisse o reconhecimento desses padrões de forma de onda, sendo que para essa função foram escolhidas as redes neurais devido ao seu histórico positivo neste tipo de aplicação.

Dessa forma, o método desenvolvido neste trabalho propõe a identificação e localização de cadeias de isoladores danificadas em linhas de transmissão através da associação dos padrões das formas de onda de descargas parciais com a origem das mesmas. O diagrama de funcionamento básico do método é mostrado na Figura 4.6:

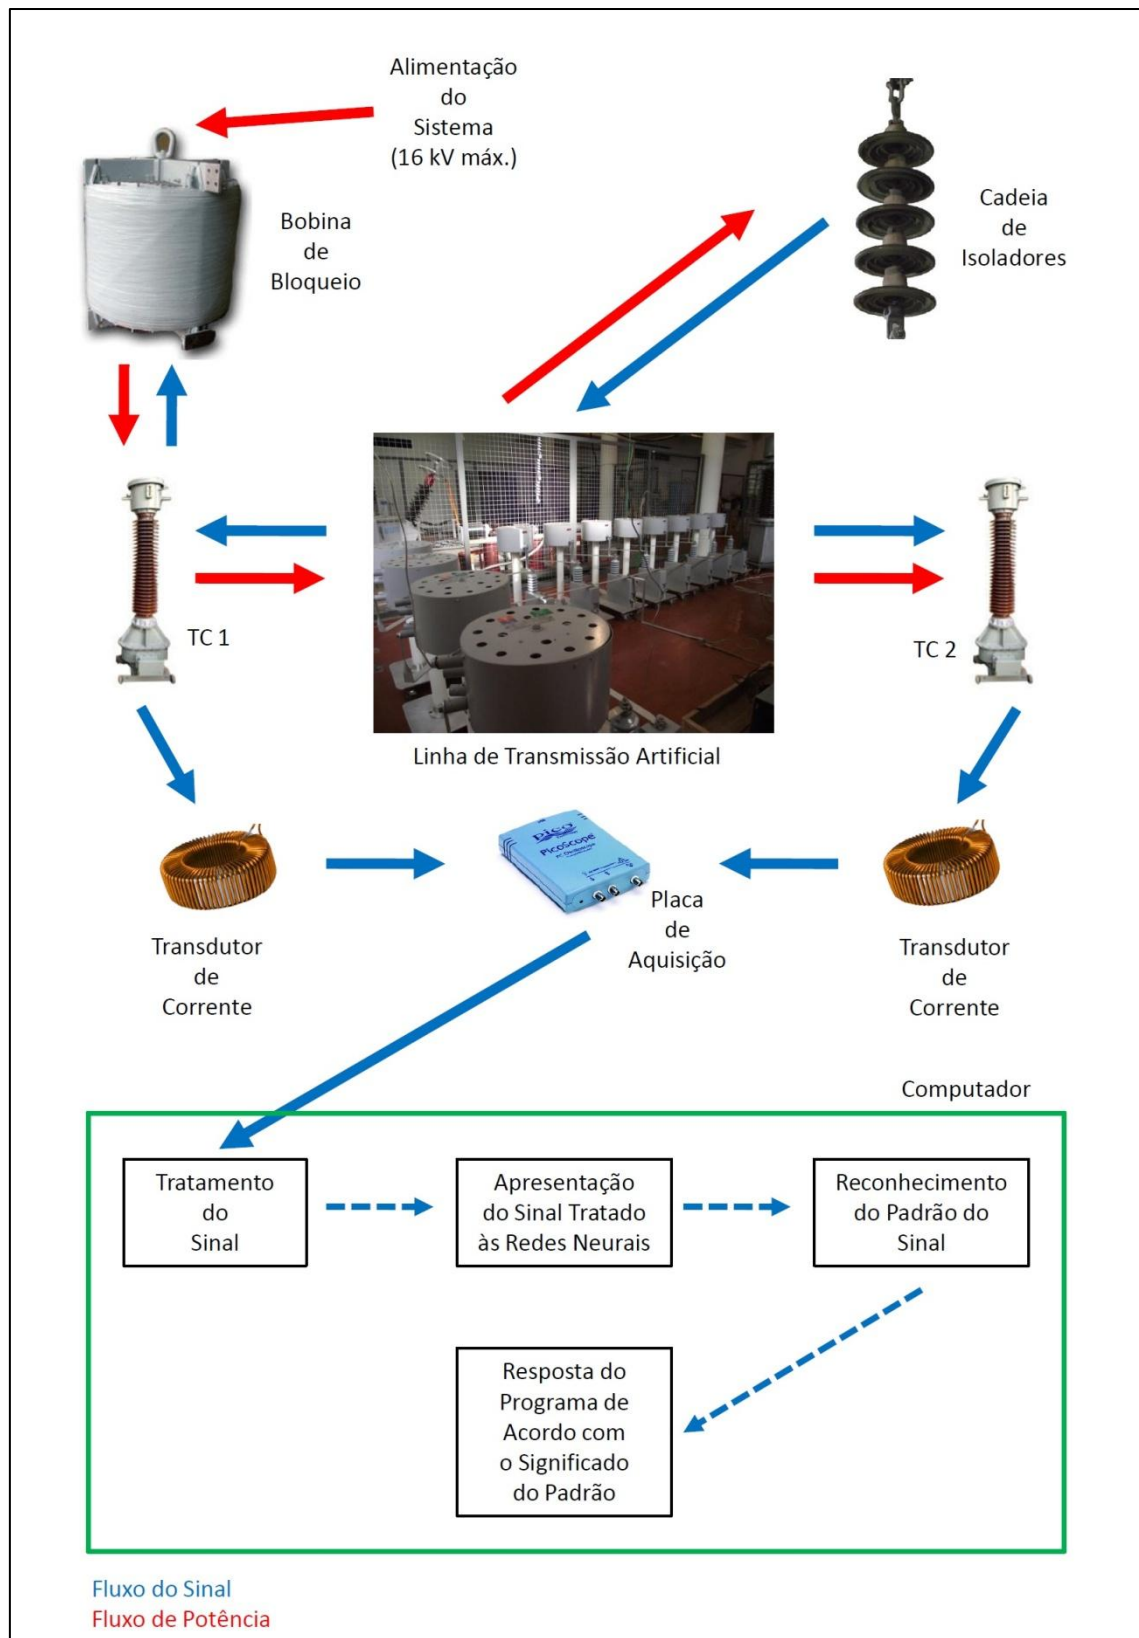


Figura 4.6 - Diagrama de funcionamento básico do método proposto.

Na Figura 4.6 são mostrados, além do sistema físico já comentado, os passos mais importantes realizados pelo programa de reconhecimento de padrões. Como dito

no Capítulo 3, existe a necessidade de se tratar os sinais de descargas parciais de modo que o processamento dos mesmos pelas redes neurais não exija um esforço computacional excessivo. Assim, os sinais são filtrados e/ou comprimidos, tendo seu número de amostras reduzido a um valor tal que o esforço computacional realizado pelas redes neurais se situe em um patamar aceitável. Em seguida, os sinais são enviados às redes neurais para que estas identifiquem a qual padrão de forma de onda pertence cada um desses sinais. Uma vez identificado o padrão, o programa gera um diagnóstico associando o padrão à situação conhecida. Por exemplo, no caso do programa reconhecer o padrão de forma de onda da Figura 4.5, o mesmo geraria um diagnóstico informando que o sinal analisado seria proveniente do segundo isolador da cadeia de isoladores localizada no tap 4.

Porém, para que as redes neurais possam reconhecer os padrões de formas de onda, é necessário que elas conheçam previamente esses padrões, ou seja, as redes neurais devem ser passar por uma etapa de treinamento antes de executarem sua função. O modo como o conhecimento utilizado para treinar as redes é gerado é tratado no item seguinte.

4.3 Sistemática de Ensaios em Laboratório

4.3.1 Montagem de Banco de Dados e Treinamento das Redes Neurais

As redes neurais utilizadas para o reconhecimento dos padrões de descargas parciais foram treinadas de modo supervisionado, isto é, exemplos de padrões a serem reconhecidos foram apresentados a rede de forma que estas pudessem aprender a reconhecê-los.

Para exemplificar o procedimento adotado, seja a seguinte situação: suponha-se que o objetivo de uma determinada rede neural seja reconhecer descargas parciais provenientes de cadeias de isoladores conectadas aos pontos A, B e C de uma linha de transmissão. Para que isso seja possível é necessário que à mesma sejam apresentados exemplos destas descargas. Assim, cadeias de isoladores dotadas do dispositivo de reprodução de efeito corona devem ser conectadas a esses pontos de forma que os sinais gerados pelas descargas parciais possam viajar pela linha de transmissão e serem capturados pelo sistema de aquisição. Uma vez capturados, esses sinais podem ser utilizados no treinamento da rede neural. Este consiste em apresentar os sinais capturados à entrada da rede neural e indicar a saída desejada, de modo que os pesos sinápticos e tendências sejam ajustados. Depois de treinada, a

rede neural é capaz de reconhecer sinais provenientes dos pontos A, B e C da linha de transmissão, tendo condições de indicar a localização das cadeias de isoladores danificadas conectadas a estes pontos. Qualquer outro tipo de sinal proveniente destes ou de outros pontos não deve ser reconhecido, uma vez que não fazem parte da base de conhecimento da rede neural.

As descargas parciais do exemplo acima podem ser geradas em diversas posições da cadeia de isoladores, isto é, podem ter origem nos diversos isoladores que compõem a cadeia. Assim, para que a rede neural seja capaz de reconhecer todos os padrões de descargas parciais que possam ser gerados em uma cadeia de isoladores instalada em uma determinada posição da linha de transmissão, exemplos de todos os sinais devem fazer parte do conjunto de sinais de treinamento.

Dessa forma, a montagem dos bancos de dados que contém os sinais utilizados no treinamento das redes neurais seguem os passos mostrados no fluxograma da Figura 4.7.

Uma vez montado o banco de dados, seus sinais devem ser tratados e então enviados às redes neurais para treinamento seguindo a sistemática do fluxograma mostrado na Figura 4.8.

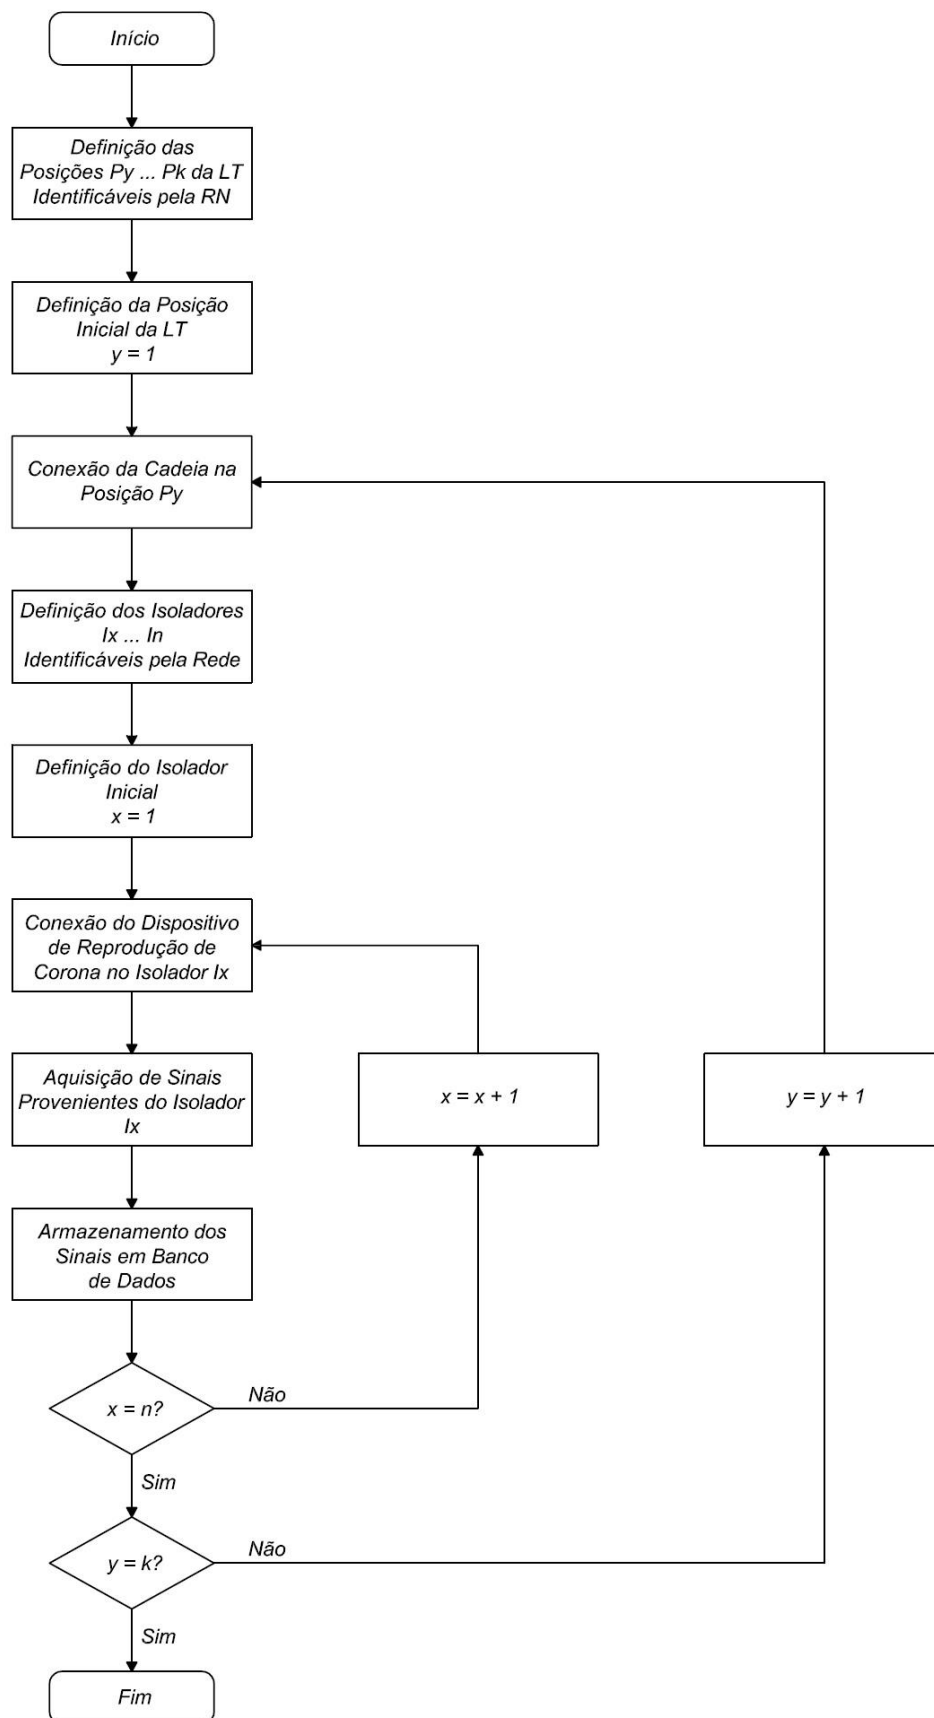


Figura 4.7 - Fluxograma da montagem de banco de dados de sinais para treinamento ou ensaio das redes neurais.

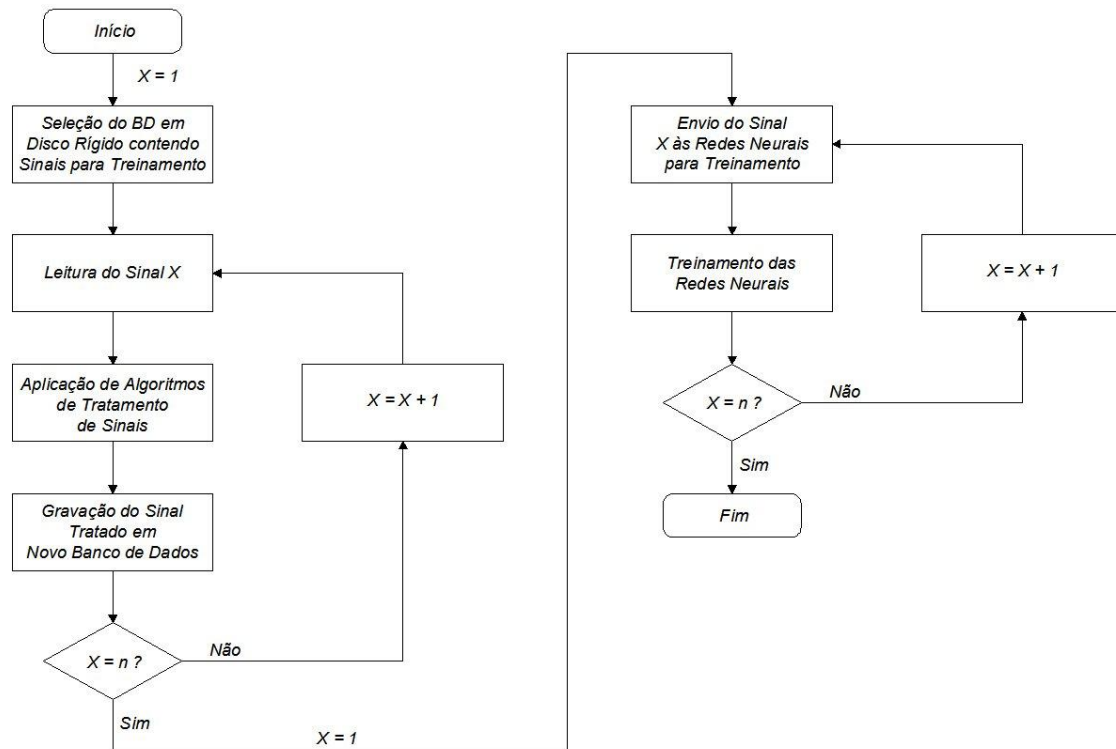


Figura 4.8 - Fluxograma do treinamento das redes neurais.

4.3.2 Ensaios de Desempenho dos Programas

Uma vez treinadas as redes neurais é necessário que se verifique o desempenho do programa criado. Isso é feito realizando-se uma nova coleta de sinais de descargas parciais geradas de todas as situações possíveis previstas no programa, criando-se um banco de dados de ensaio, seguindo os passos do fluxograma da Figura 4.7. O uso de sinais do banco de dados montado para treinamento das redes neurais não é recomendado, uma vez que não permite a correta avaliação da capacidade de generalização das redes neurais.

O fluxograma da Figura 4.9 mostra os passos para os ensaios de desempenho dos programas de reconhecimento de padrões, sendo que o tratamento de sinais deve ser exatamente o mesmo utilizado na etapa de treinamento das redes neurais.

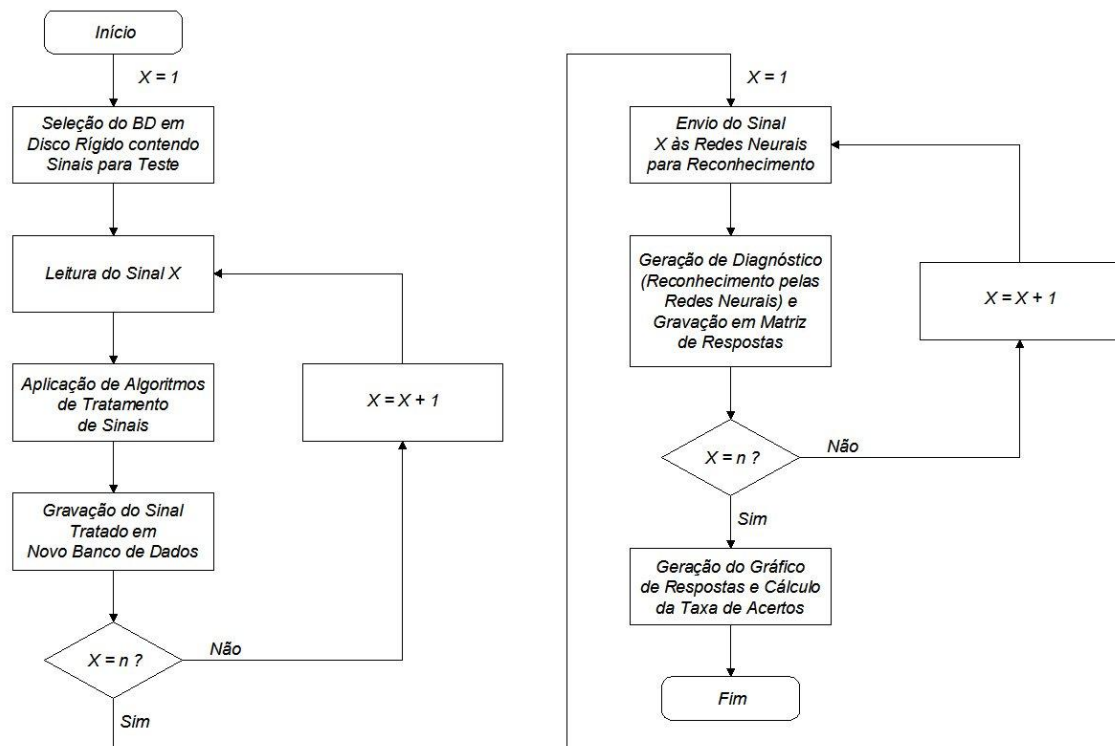


Figura 4.9 - Fluxograma do ensaio de desempenho dos programas.

4.4 Considerações Finais

Este capítulo tratou do método proposto, mostrando porque ele é possível e como deve ser aplicado. Também foram mostrados os passos básicos para os ensaios de laboratório, tanto para treinamento das redes neurais como para o ensaio de desempenho das mesmas.

Desenvolvimento da Ferramenta Computacional

5.1 Considerações Iniciais

É tratado neste capítulo o desenvolvimento da ferramenta computacional utilizada no reconhecimento de padrões de descargas parciais de Corona, baseada em redes neurais e toda desenvolvida em Matlab® 7.9.0. Além da estrutura dos programas criados, são descritos e analisados os ensaios realizados em laboratório.

5.2 Configuração das Redes Neurais

As redes neurais utilizadas possuem as seguintes características básicas:

- Número de nós da camada de entrada dependente da quantidade de amostras dos sinais utilizados: *um nó por amostra*;
- Número de neurônios da camada de saída dependente da quantidade de padrões analisados: *um neurônio por padrão*;
- Uma camada oculta contendo 20 neurônios;
- Função de ativação do tipo *Tangente Sigmóide* para todos os neurônios;
- Algoritmo de treinamento utilizado: *Gradiente Conjugado Escalonado*;
- Medição de desempenho: *Erro Médio Quadrático*.

Este tipo de rede neural é específica para reconhecimento de padrões e está disponível no Matlab® através do comando *newpr*.

O treinamento das redes neurais é realizado através do comando *train*, o qual executa um aplicativo que visa facilitar a análise do treinamento. A tela principal deste aplicativo é exemplificada na Figura 5.1:

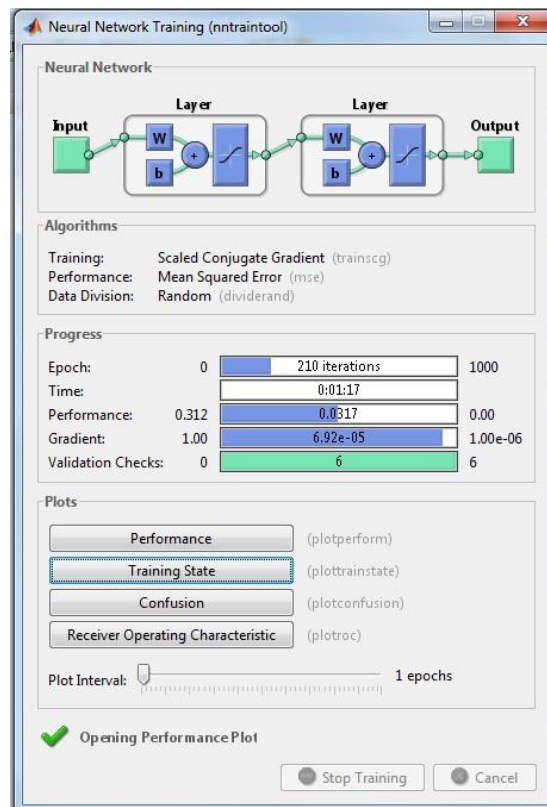


Figura 5.1 - Aplicativo para treinamento de redes neurais do Matlab®.

Com ele é possível visualizar as informações mais importantes relacionadas ao treinamento das redes neurais, tais como números de iterações realizadas (épocas), desempenho do treinamento e o tempo gasto em sua execução. O aplicativo divide o conjunto de vetores a ser utilizado para o treinamento em três partes, sendo:

- 60% efetivamente utilizado para o treinamento da rede (padrões a serem aprendidos);
- 20% destinado a verificar a evolução da capacidade de generalização e interromper o treinamento antes que ocorra o *overfitting*;
- 20% utilizado para testar o desempenho da rede neural após o treinamento.

O *overfitting* acontece quando a quantidade de dados apresentados à rede neural durante seu treinamento está acima de um determinado limite, acarretando na perda da capacidade de generalização. Em uma analogia simplista, pode-se comparar o *overfitting* ao fato de um estudante, devido ao excesso de estudo, *decorar* a resolução de um tipo de exercício em detrimento do raciocínio. Se uma nova variável for inserida no exercício provavelmente o estudante não conseguirá resolvê-lo corretamente, isto é, perde-se a capacidade de generalizar.

A Figura 5.2 exemplifica o gráfico de desempenho do treinamento de uma rede neural (*performance*). Nela é possível observar a convergência do erro médio quadrático em direção ao valor estipulado ao decorrer da execução das iterações. Uma vez que o valor estipulado é atingido, o treinamento é encerrado.




Figura 5.2 - Gráfico de desempenho do treinamento de uma rede neural.

5.3 Ensaios de Identificação Realizados com Sinais Tratados por LPC

Os ensaios descritos nos itens seguintes foram realizados utilizando-se os coeficientes gerados pelos LPC ao invés das amostras dos sinais, isto é, cada sinal foi representado por um vetor de 20 elementos, ante o vetor de 500 elementos coletado originalmente. Com isso, o esforço computacional necessário para principalmente se treinar as redes neurais foi consideravelmente reduzido.

5.3.1 Ensaio nº 1

Este foi o primeiro dos ensaios realizados com programas para reconhecimento de padrões de descargas parciais. O objetivo principal foi verificar o comportamento das redes neurais escolhidas frente à identificação de dois padrões distintos de descargas parciais, os quais são gerados das seguintes formas:

- Padrão 1: descarga parcial proveniente da reprodução de efeito corona em uma cadeia de isoladores intacta (cadeia tipo A);

- Padrão 2: descarga parcial proveniente da reprodução de efeito corona em uma cadeia de isoladores com um dos isoladores quebrado, como mostra a Figura 5.3 (cadeia tipo B).



Figura 5.3 - Cadeia de isoladores de porcelana com um dos isoladores quebrado.

As situações descritas acima são representadas na Figura 5.4:




Figura 5.4 - Esquema das cadeias de isoladores utilizadas no Ensaio 1.

onde a cadeia de isoladores A está em perfeitas condições e a cadeia de isoladores B possui seu isolador nº 4 quebrado. Ambas as cadeias de isoladores foram conectadas

ao mesmo tap da linha de transmissão (não simultaneamente) e o dispositivo de reprodução de efeito corona foi instalado no isolador nº 5.

Para o treinamento das redes neurais foi montado um banco de dados contendo 800 sinais provenientes da cadeia de isoladores A e 800 sinais provenientes da cadeia de isoladores B. Todos estes sinais foram submetidos a tratamento antes de seguirem para o treinamento das redes neurais. Tal tratamento consistiu de:

- Aplicação de filtro passa-faixa do tipo elíptico, com frequências de corte inferior e superior iguais a, respectivamente, 1 [MHz] e 10 [MHz];
- Compressão por LPC com utilização 20 coeficientes. Os vetores contendo estes coeficientes foram os dados efetivamente apresentados as redes neurais.

Com a finalidade de reduzir os erros de diagnóstico do programa, decidiu-se utilizar várias redes neurais ao invés de somente uma, sendo que os resultados das mesmas foram combinados de modo a formar um resultado final. Isto foi realizado através da média aritmética das respostas. Ao todo foram utilizadas 20 redes neurais idênticas na composição do programa, sendo que todas elas foram treinadas com os mesmos dados. A etapa de treinamento das redes neurais está representada no fluxograma da Figura 5.5.

Após o treinamento das redes neurais, foram coletados 20 sinais para ensaio do programa, os quais estão especificados na Tabela 5.1.

Tabela 5.1 – Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio nº 1.

Sinais para Verificação de Desempenho – Ensaio nº 1	
Sinais Provenientes da Cadeia de Isoladores A (intacta)	Sinais Provenientes da Cadeia de Isoladores B (danificada)
1, 2, 3, 5, 6, 8, 9, 10, 12, 13, 14, 15, 16, 17, 18 e 20	4, 7, 11 e 19

Estes sinais foram então apresentados ao programa, que realizou o processo de reconhecimento dos padrões de forma de onda conforme o fluxograma da Figura 5.6.

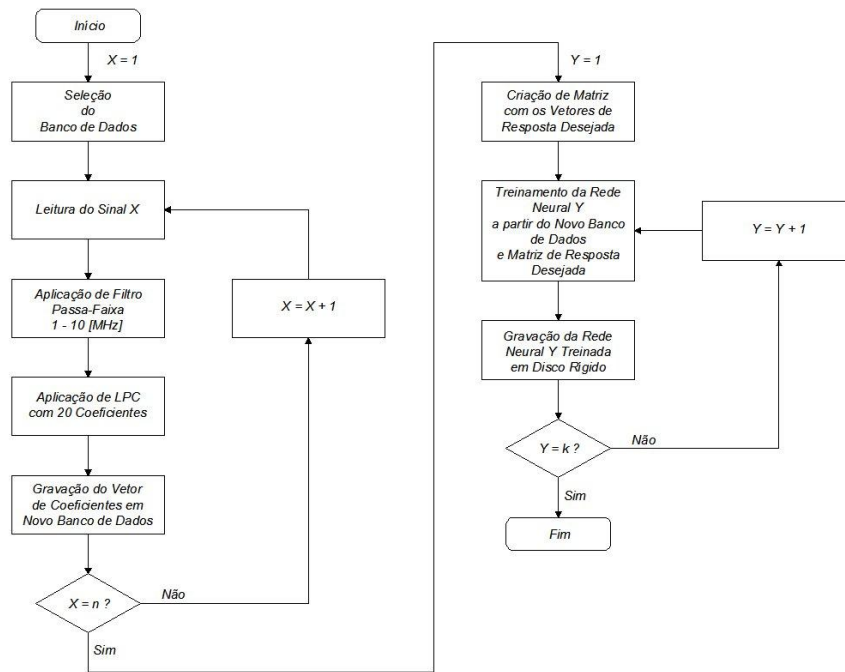


Figura 5.5 - Fluxograma do treinamento das redes neurais do Ensaio nº 1, onde n é a quantidade de sinais contidos no banco de dados e k a quantidade de redes neurais.

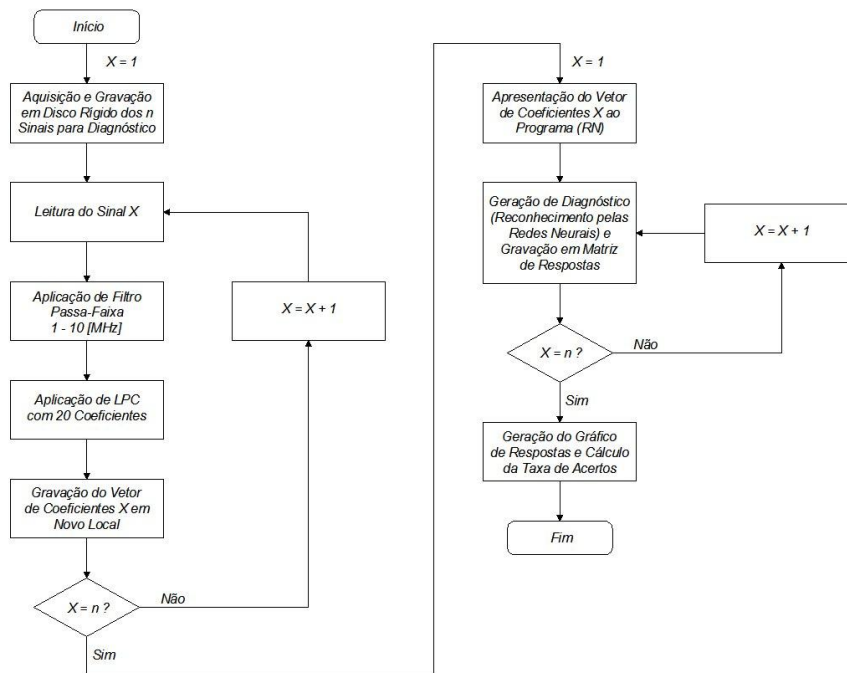


Figura 5.6 - Fluxograma da etapa de diagnóstico do programa do Ensaio nº 1, onde n é a quantidade de sinais submetidos ao reconhecimento.

A resposta obtida é mostrada no gráfico da Figura 5.7:




Figura 5.7 - Resposta do programa para o reconhecimento dos 20 sinais de ensaio.

O eixo vertical do gráfico é a *chance* que um sinal tem de pertencer a determinado padrão em uma escala de zero a cem pontos. No eixo horizontal têm-se os vinte sinais de ensaio e em suas respectivas posições são apresentadas duas barras de chance: a barra azul, que representa a chance do sinal ter sido gerado na cadeia A (intacta) e a barra vermelha, que representa a chance do sinal ter sido gerado na cadeia B (danificada). Dessa forma, a maior barra determina a qual padrão pertence o sinal.

Comparando-se o gráfico de resposta com a Tabela 5.1, é possível dizer que o programa diagnosticou corretamente a grande maioria dos sinais. Foi dada uma resposta completamente errada para o sinal 19 e no caso do sinal 4 a resposta foi correta, porém com alto grau de incerteza, já que as chances do sinal ter sido gerado nas cadeias A e B foram informadas como sendo praticamente iguais. Assim, se considerarmos as respostas com alto grau de incerteza como erradas, o ensaio obteve uma taxa de acerto de 90%.

Respostas erradas ou com pouca certeza ocorreram porque as redes neurais não conseguiram reconhecer com exatidão cada padrão, chegando ao ponto de informar que um determinado sinal, para efeito prático, pertence a dois padrões distintos, como no caso do sinal 4. A causa mais provável disso é a dimensão muito reduzida do banco de dados, isto é, a quantidade de exemplos das duas situações em

questão pode não ter sido suficiente para um aprendizado satisfatório das redes neurais. Assim, decidiu-se utilizar bancos de dados maiores nos ensaios subsequentes.

5.3.2 Ensaio n° 2

No segundo ensaio o objetivo também foi identificar se um sinal pertencia a uma de duas classes de padrões possíveis, sendo estes similares aos do Ensaio n° 1, porém com as seguintes alterações:

- Classe de padrões gerados na cadeia de isoladores A (intacta): composta de sinais gerados pelo dispositivo de reprodução de efeito corona instalado em todos os isoladores intercaladamente;
- Classe de padrões gerados na cadeia de isoladores B (um dos isoladores danificado): composta de sinais gerados pelo dispositivo de reprodução de efeito corona instalado em todos os isoladores intactos intercaladamente. A posição do isolador danificado também foi intercalada.

As situações informadas acima estão representadas na Figura 5.8.

Foi então montado um banco de dados para treinamento das redes neurais contendo 6.000 sinais provenientes da cadeia de isoladores A e 24.000 sinais provenientes da cadeia de isoladores B, respeitando as situações descritas. O treinamento das redes neurais foi realizado conforme o fluxograma da Figura 5.5.

Em seguida, foram gerados e gravados 150 sinais para verificação de desempenho do programa (Tabela 5.2), os quais foram apresentados ao mesmo para diagnóstico, realizado conforme o fluxograma da Figura 5.6.

Tabela 5.2 - Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio n° 2.

Sinais para Verificação de Desempenho – Ensaio n° 2	
Sinais Provenientes da Cadeia de Isoladores A (intacta)	Sinais Provenientes da Cadeia de Isoladores B (danificada)
1 a 30	31 a 150

Os resultados obtidos pelo programa podem ser visualizados no gráfico da Figura 5.9

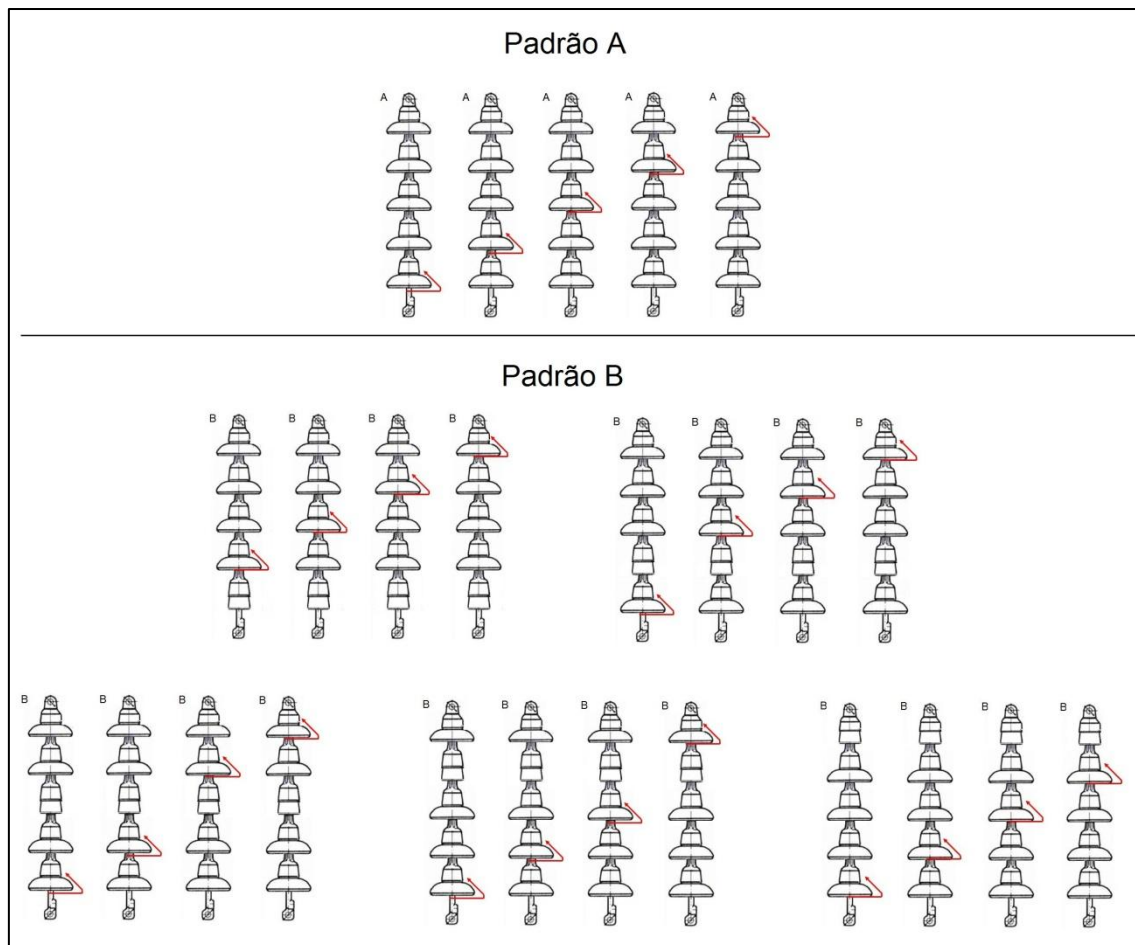


Figura 5.8 - Situações contempladas pelas classes de padrões do Ensaio 2.




Figura 5.9 - Resposta do programa para o reconhecimento dos 150 sinais de ensaio.

Ao se observar o resultado deste ensaio é possível notar uma grande diferença de desempenho do programa conforme o padrão reconhecido. Vê-se que no diagnóstico dos sinais de 1 a 30, gerados em uma cadeia de isoladores do tipo A (intacta), houve considerável quantidade de respostas erradas ou com algo grau de incerteza, com uma taxa de acerto de 20%. Já no diagnóstico dos sinais de 31 a 150, gerados em uma cadeia de isoladores do tipo B, houve apenas uma resposta errada, além de três respostas corretas com um considerável grau de incerteza, resultando em uma taxa de acerto de 97%. A taxa de acerto geral foi de 81%.

Esse desequilíbrio de desempenho pode ser creditado principalmente ao fato do banco de dados utilizado no treinamento das redes neurais ser assimétrico, isto é, conter diferentes quantidades de exemplos dos padrões a serem aprendidos pelas redes neurais. Neste caso, as redes neurais adquiriram um conhecimento muito maior sobre o padrão de sinal gerado na cadeia do tipo B, resultando em uma taxa de acerto 4,8 maior para este caso em relação ao reconhecimento dos sinais oriundos da cadeia do tipo A.

5.3.3 Ensaio n° 3

Este ensaio consistiu em uma evolução do Ensaio n° 2, sendo que o banco de dados para treinamento das redes neurais foi modificado da seguinte forma:

- A quantidade de sinais provenientes da cadeia de isoladores A foi mantida em 6.000;
- A quantidade de sinais provenientes da cadeia de isoladores B foi alterada de 24.000 para 6.000, de forma que o banco de dados se tornasse simétrico.

O treinamento foi então realizado mantendo-se os passos descritos no fluxograma da Figura 5.5. Então, 60 sinais foram coletados para o ensaio de desempenho do programa, os quais são identificados na Tabela 5.3:

Tabela 5.3 - Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio n° 3.

Sinais para Verificação de Desempenho – Ensaio n° 3	
Sinais Provenientes da Cadeia de Isoladores A (intacta)	Sinais Provenientes da Cadeia de Isoladores B (danificada)
1 a 30	31 a 60

Após serem apresentados ao programa para reconhecimento, conforme o fluxograma da Figura 5.6, foi emitido o seguinte diagnóstico (Figura 5.10):




Figura 5.10 - Resposta do programa para o reconhecimento dos 60 sinais de ensaio.

Do gráfico de resultados nota-se que o desempenho do programa foi bastante similar para ambos os padrões, sendo que tanto no reconhecimento dos sinais provenientes da cadeia de isoladores A quanto no reconhecimento dos sinais provenientes da cadeia de isoladores B a taxa de acerto foi de 83%.

5.3.4 Ensaio n° 4

O objetivo deste ensaio foi verificar o quão preciso poderia ser o programa desenvolvido, mantendo-se as configurações das redes neurais utilizadas nos ensaios anteriores.

Para tal, o programa foi alterado para identificar se o sinal analisado tinha origem em uma cadeia de isoladores do tipo A (intacta) ou do tipo B (danificada) e, além disso, neste último caso, deveria ser identificado em qual isolador a descarga parcial havia sido gerada. Dessa forma, as situações reproduzidas continuaram sendo

aquelas descritas na Figura 5.8, do Ensaio nº 2, porém os sinais gerados foram organizados de forma diferente.

Assim, um banco de dados utilizado para treinamento das redes neurais foi montado com as seguintes características:

- 3.000 sinais gerados em uma cadeia de isoladores do tipo A em todos os isoladores não simultaneamente, de forma a representar um padrão a ser ensinado as redes neurais;
- 2.400 sinais gerados em uma cadeia de isoladores do tipo B em todos os isoladores não simultaneamente, devidamente agrupados por posição do isolador quebrado, não importando a posição do isolador onde a descarga parcial foi gerada. O objetivo desta organização foi criar cinco novos padrões a serem ensinados as redes neurais, substituindo o padrão único de sinais provenientes de cadeias de isoladores do tipo B utilizado nos ensaios até então.

Os padrões contemplados pelo banco de dados são mostrados na Figura 5.11 .

As redes neurais foram então treinadas seguindo os passos descritos no fluxograma da Figura 5.5. Em seguida, 75 sinais foram coletados para verificação de desempenho do programa, identificados na Tabela 5.4.

Tabela 5.4 - Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio nº 4.

Sinais para Verificação de Desempenho – Ensaio nº 4					
Sinais Provenientes da Cadeia de Isoladores A (intacta)	Sinais Provenientes da Cadeia de Isoladores B (danificada)				
	Posição do Isolador Quebrado				
	1	2	3	4	5
1 a 15	16 a 27	28 a 39	40 a 51	52 a 63	64 a 75

Os sinais foram então submetidos ao diagnóstico conforme o fluxograma da Figura 5.6, sendo obtidos os seguintes resultados (Figura 5.12).

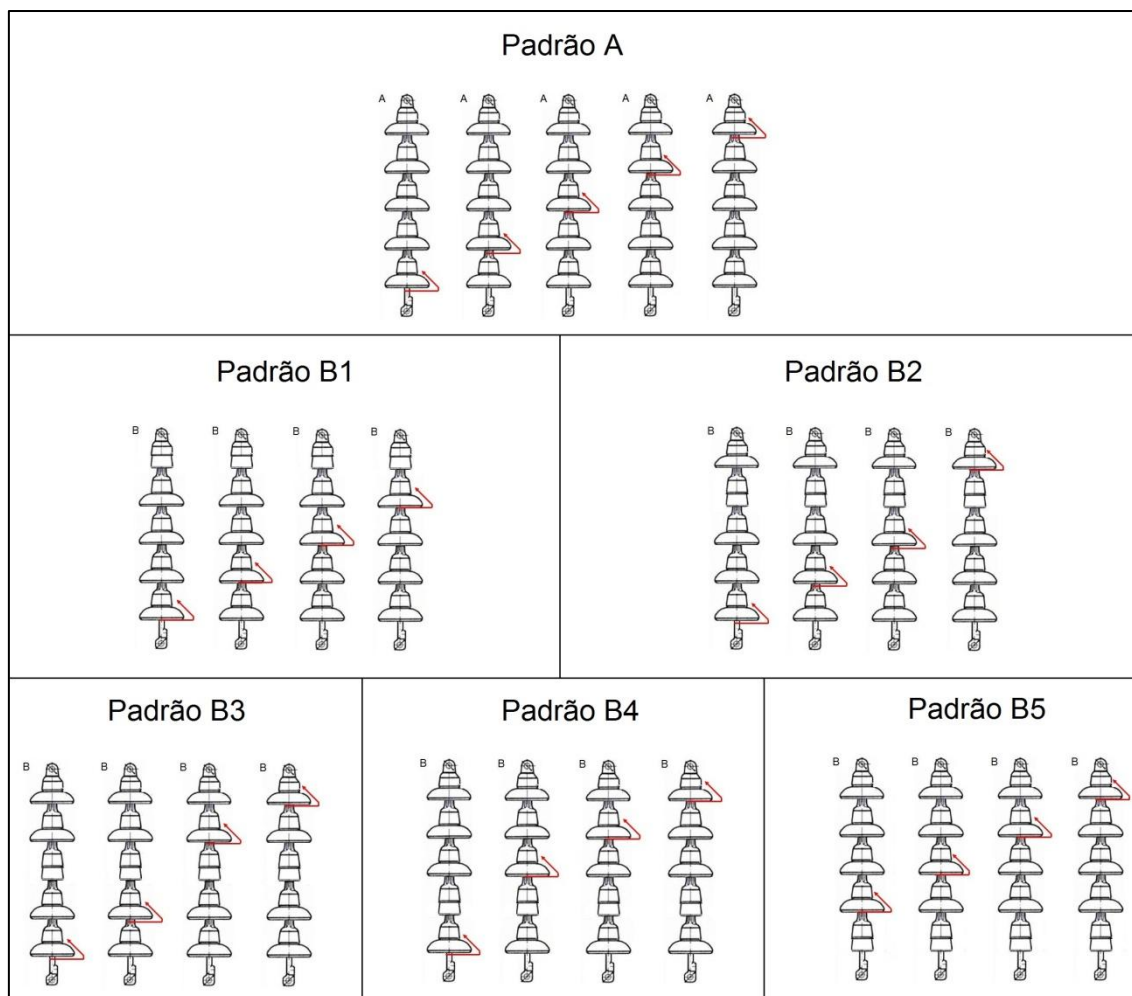


Figura 5.11 - Situações contempladas pelas classes de padrões do Ensaio 4.

Do gráfico da Figura 5.12 pode-se ver que a taxa de acerto variou bastante de acordo com o padrão de sinal, sendo as mesmas quantificadas na Tabela 5.5.

Tabela 5.5 – Desempenho do programa frente aos novos padrões.

Taxa de Acerto em % – Ensaio n° 4					
Sinais Provenientes da Cadeia de Isoladores A (intacta)	Sinais Provenientes da Cadeia de Isoladores B (danificada)				
	Posição do Isolador Quebrado				
	1	2	3	4	5
93	83	50	67	42	67




Figura 5.12 - Resposta do programa para o reconhecimento dos 75 sinais de ensaio.

Ainda que a taxa de acerto tenha superado o patamar de 80% em apenas dois dos seis casos, os demais resultados ainda são de certa relevância, podendo-se considerar este programa como de relativo sucesso. A causa mais provável para este desempenho é a pouca quantidade de sinais provenientes da cadeia de isoladores tipo B utilizados para o treinamento das redes neurais, 480 sinais por caso, ao passo que no caso da cadeia de isoladores tipo A foram utilizados 3.000 sinais.

Ainda assim, o ensaio mostrou ser possível identificar o isolador danificado dentro da cadeia a qual pertence, apesar de tal capacidade não ser de grande valor prático, uma vez que no caso de uma cadeia de isoladores ser diagnosticada como problemática a mesma é substituída por completo.

5.4 Ensaios de Identificação Realizados sem Tratamento por LPC

A utilização do LPC na compressão dos sinais, como já comentado, implica na representação de um sinal através de um vetor de 20 elementos em substituição ao vetor original de 500 elementos. Isto faz com que as redes neurais necessitem aprender apenas 4% da quantidade original de informação, o que se traduz em um enorme ganho computacional. Porém, esta drástica redução da quantidade de informação acarreta em uma perda considerável de capacidade de reconhecimento do programa.

Dessa forma, novos ensaios foram realizados sem a utilização do LPC, embora mantendo os outros métodos de tratamento de sinais. Os ensaios, assim como as análises de seus resultados, são mostrados nos itens a seguir.

5.4.1 Ensaio nº 5

Este ensaio consiste na repetição do Ensaio nº 3, porém os passos de treinamento e reconhecimento foram alterados conforme mostram os seguintes fluxogramas (Figura 5.13 e Figura 5.14).

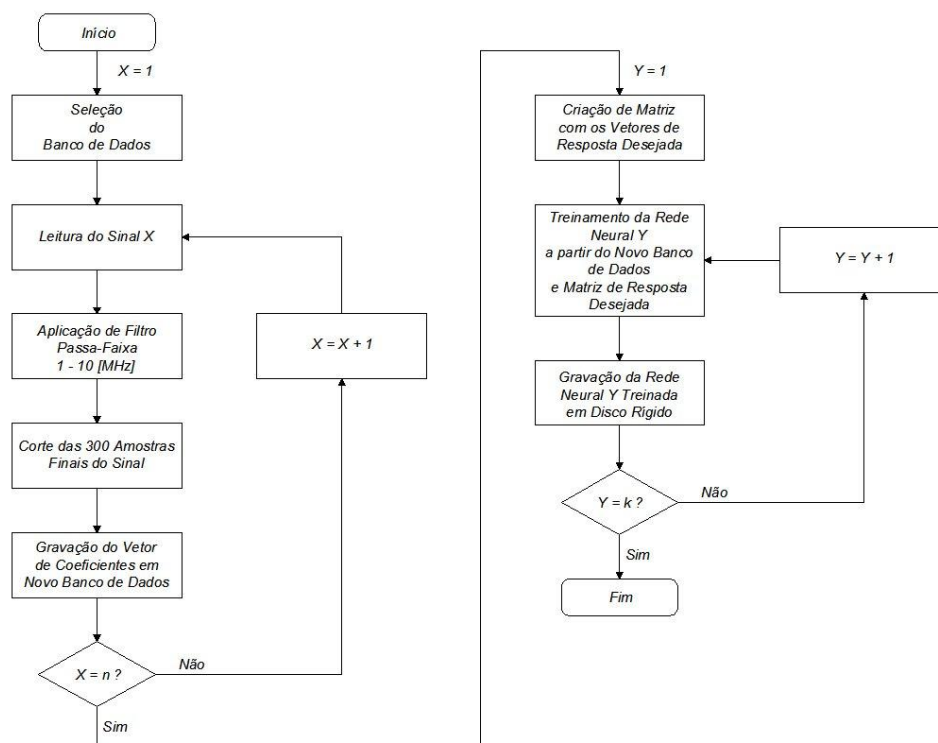


Figura 5.13 - Fluxograma do treinamento das redes neurais sem LPC do Ensaio nº 5, onde n é a quantidade de sinais contidos no banco de dados e k a quantidade de redes neurais.

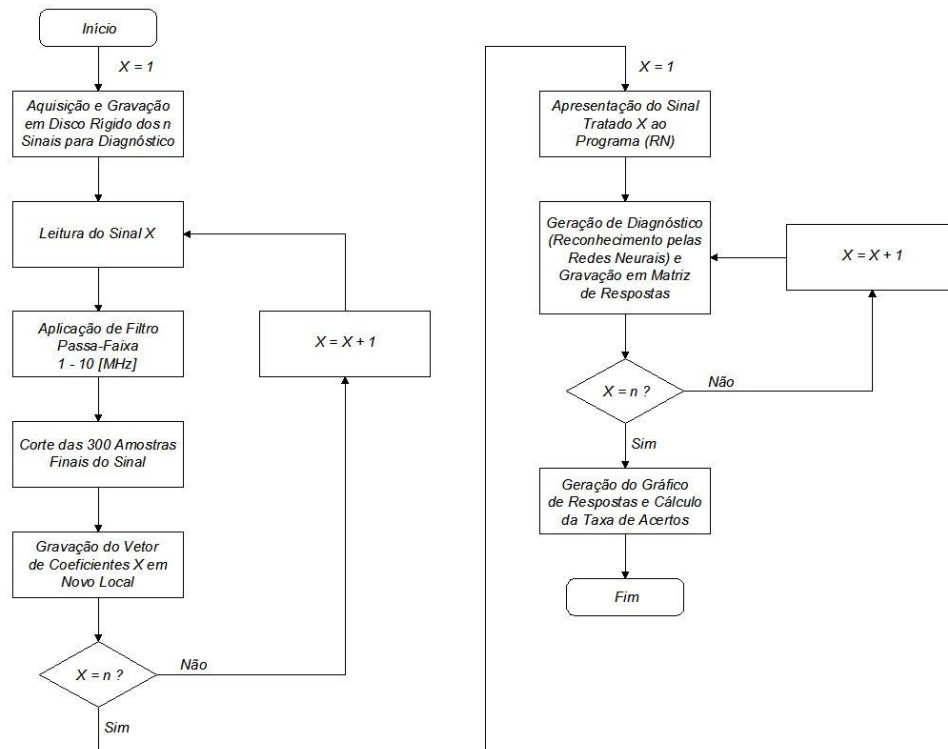


Figura 5.14 - Fluxograma da etapa de diagnóstico do programa sem LPC do Ensaio nº 5, onde n é a quantidade de sinais submetidos ao reconhecimento.

Os sinais utilizados para treinamento das redes neurais e para posterior verificação de desempenho foram exatamente os mesmos utilizados no Ensaio nº 3, ou seja, o banco de dados para treinamento foi composto de:

- 6.000 sinais provenientes da cadeia de isoladores A (intacta);
- 6.000 sinais provenientes da cadeia de isoladores B (danificada).

Da mesma forma, os sinais para ensaio de desempenho do programa são mostrados na Tabela 5.6:

Tabela 5.6 - Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio nº 5.

Sinais para Verificação de Desempenho – Ensaio nº 5	
Sinais Provenientes da Cadeia de Isoladores A (intacta)	Sinais Provenientes da Cadeia de Isoladores B (danificada)
1 a 30	31 a 60

Os resultados obtidos pelo diagnóstico do programa podem então ser observados na Figura 5.15:




Figura 5.15 - Resposta do programa para o reconhecimento dos 60 sinais de ensaio.

Para facilitar a comparação entre os resultados dos Ensaio n° 3 e n° 5, seus respectivos resultados são colocados lado a lado na Figura 5.16:




Figura 5.16 - Ensaio n° 3 e n° 5.

Da Figura 5.16 pode-se observar a diferença entre os resultados obtidos nos Ensaio n° 3 e n° 5. Com resultado visivelmente superior, o Ensaio n° 5 obteve uma taxa de acerto de 100%, enquanto que no caso do Ensaio n° 3 a taxa de acerto foi de 83%. Além disso, as respostas obtidas no Ensaio n° 5 apresentaram um grau de incerteza menor que no caso do Ensaio n° 3.

Com relação ao esforço computacional e utilização de recursos de memória em disco rígido, o programa utilizado neste ensaio foi muito mais exigente que aquele utilizado no Ensaio n° 3, conforme pode ser visto na Tabela 5.7.

Tabela 5.7 - Diferença de esforço computacional entre os Ensaio n° 3 e n° 5.

	Ensaio n° 3	Ensaio n° 5	Diferença do Ensaio ° 5 em Relação ao Ensaio n° 3
Tamanho do Banco de Dados no Disco Rígido Após Tratamento dos Sinais [MB]	4	100	25 vezes maior
Tamanho das Redes Neurais em Disco Rígido [MB]	28	894	32 vezes maior
Tempo de Treinamento das Redes Neurais [minutos]	8	55	7 vezes maior
Tempo de Reconhecimento [segundos]	0,5	8	16 vezes maior

5.4.2 Ensaio n° 6

O segundo ensaio com algoritmos sem LPC é baseado no Ensaio n° 4, onde o objetivo era identificar se a descarga parcial tinha origem em uma cadeia do tipo A (intacta) ou do tipo B (danificada). No caso de ser proveniente desta última, o programa ainda identificava qual a posição do isolador danificado na cadeia. Os padrões identificados neste ensaio são mostrados na Figura 5.11.

Como o Ensaio n° 4 foi realizado com um banco de dados assimétrico optou-se por refazê-lo, com LPC, com um banco de dados simétrico, sendo formado por:

- 2.400 sinais gerados em uma cadeia de isoladores do tipo A em todos os isoladores não simultaneamente, de forma a representar um padrão a ser ensinado as redes neurais;
- 2.400 sinais gerados em uma cadeia de isoladores do tipo B em todos os isoladores não simultaneamente, devidamente agrupados por

posição do isolador quebrado, não importando a posição do isolador onde a descarga parcial foi gerada. O objetivo desta organização foi criar cinco novos padrões a serem ensinados as redes neurais, substituindo o padrão único de sinais provenientes de cadeias de isoladores do tipo B utilizado nos ensaios até então.

Para a verificação de desempenho do programa 72 sinais foram coletados, os quais são identificados na Tabela 5.8.

Tabela 5.8 - Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio nº 6.

Sinais para Verificação de Desempenho – Ensaio nº 6					
Sinais Provenientes da Cadeia de Isoladores A (intacta)	Sinais Provenientes da Cadeia de Isoladores B (danificada)				
	Posição do Isolador Quebrado				
	1	2	3	4	5
1 a 12	13 a 24	25 a 36	37 a 48	49 a 60	61 a 72

Os resultados obtidos no diagnóstico podem ser vistos na Figura 5.17.




Figura 5.17 - Resposta do programa para o reconhecimento dos 72 sinais de ensaio (com LPC).

Em seguida, realizou-se o mesmo ensaio sem o uso de LPC, conforme os fluxogramas de treinamento e reconhecimento mostrados na Figura 5.13 e na Figura 5.14, sendo obtidos os resultados mostrados na Figura 5.18.




Figura 5.18 - Resposta do programa para o reconhecimento dos 72 sinais de ensaio (sem LPC).

Observando-se a Figura 5.19 pode-se comparar os resultados obtidos nos ensaios realizados com e sem o uso de LPC.

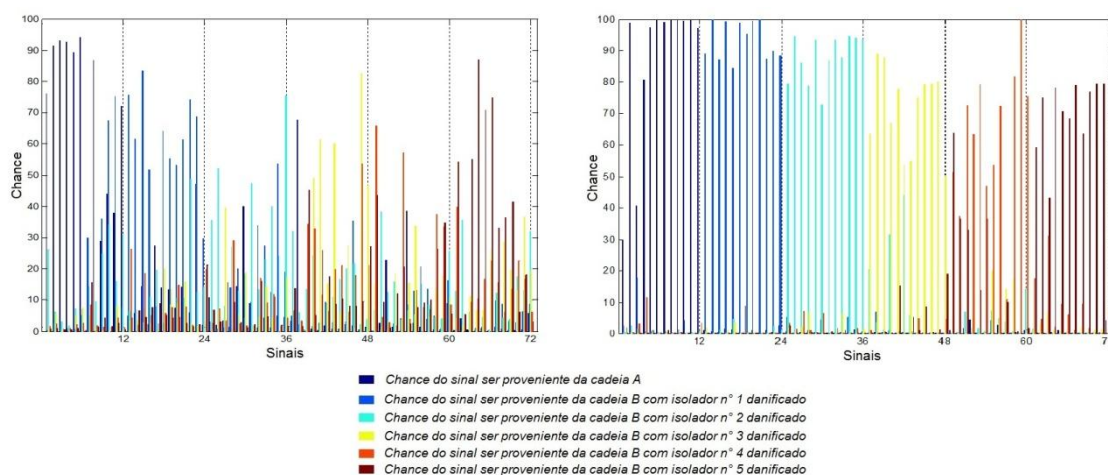


Figura 5.19 - Ensaio n° 4 e n° 6.

Observando-se os resultados de ambos os ensaios é possível notar a superioridade da capacidade de reconhecimento do programa treinado sem o uso de LPC. Esta superioridade está quantificada na Tabela 5.9:

Tabela 5.9 – Diferenças de desempenho entre os programas utilizados nos Ensaio n° 4 e n° 6.

Taxa de Acerto em %						
Ensaio	Sinais Provenientes da Cadeia de Isoladores A (intacta)	Sinais Provenientes da Cadeia de Isoladores B (danificada)				
		Posição do Isolador Quebrado				
		1	2	3	4	5
n° 4 (com LPC)	58	92	42	58	33	67
n° 6 (sem LPC)	100	100	100	100	83	100

5.4.3 Ensaio n° 7

O Ensaio n° 6, conforme mostra a Tabela 5.9, resultou em uma taxa de acerto geral muito próxima de 100%. Este patamar só não foi atingido devido à taxa de acerto de 83% obtida no reconhecimento do padrão formado pelos sinais provenientes da cadeia de isoladores B com o isolador n° 4 danificado.

Tal fato levou a uma investigação dos motivos pelos quais este padrão foi o único a não ser 100% reconhecido. Esta investigação consistiu na análise dos resultados individuais de cada uma das vinte redes neurais utilizadas no programa, sendo que uma destas foi identificada como problemática devido aos seus resultados que não convergiam com os resultados das demais.

A Figura 5.20 mostra o resultado obtido pelo programa do Ensaio n° 6 configurado para realizar o diagnóstico dos sinais de verificação de desempenho da Tabela 5.8 utilizando somente a rede neural problemática:




Figura 5.20 - Resposta do programa formado somente pela rede neural problemática para o reconhecimento dos 72 sinais de ensaio.

Uma vez identificada a rede neural problemática, a mesma foi desabilitada e o programa foi testado novamente com as redes neurais remanescentes, levando aos resultados de diagnóstico mostrados na Figura 5.21.

Dos resultados da Figura 5.21 pode-se observar que a retirada da rede neural problemática do programa levou a uma melhora da qualidade do diagnóstico, sendo que a taxa de acerto geral foi de 100%.




Figura 5.21 - Resposta do programa sem a rede neural problemática para o reconhecimento dos 72 sinais de ensaio.

5.5 Ensaios de Localização

Depois de experimentadas diversas configurações de programa nos ensaios anteriores e tendo verificado quais as mais adequadas para este tipo de aplicação, a sistemática dos ensaios foi alterada para diagnosticar a localização de cadeias de isoladores danificadas em uma linha de transmissão.

Dessa forma, o local de instalação da cadeia de isoladores na linha de transmissão deixou de ser fixa e passou a variar nos ensaios seguintes.

5.5.1 Ensaio nº 8

Este ensaio utilizou a linha de transmissão tratada no item 2.5, porém foram utilizados para este ensaio apenas seis dos quarenta e oito taps disponíveis. A cadeia de isoladores utilizada foi uma cadeia do tipo A (intacta), de porcelana, também tratada nesse mesmo item. A esta cadeia foi acoplado o dispositivo de reprodução de efeito corona, o qual se manteve na mesma posição durante todo o ensaio.

Assim, foi definido que os padrões a serem reconhecidos seriam aqueles formados pelos sinais de descarga parcial provenientes da cadeia de isoladores conectada a um dos seis taps. Como já comentado anteriormente no Capítulo 3, o padrão do sinal é alterado conforme a se altera a posição de origem da descarga parcial na cadeia de isoladores e a localização desta ao longo da linha de transmissão.

O banco de dados utilizado para o treinamento das redes neurais foi montado com 1.000 sinais para cada padrão, sendo que a estes foram aplicados o filtro passa-faixa, porém não foi utilizado o tratamento por corte do sinal, uma vez que todas as 500 amostras pareciam ser relevantes. O tratamento por LPC também não foi utilizado. A etapa de treinamento pode ser visualizada no fluxograma da Figura 5.22.

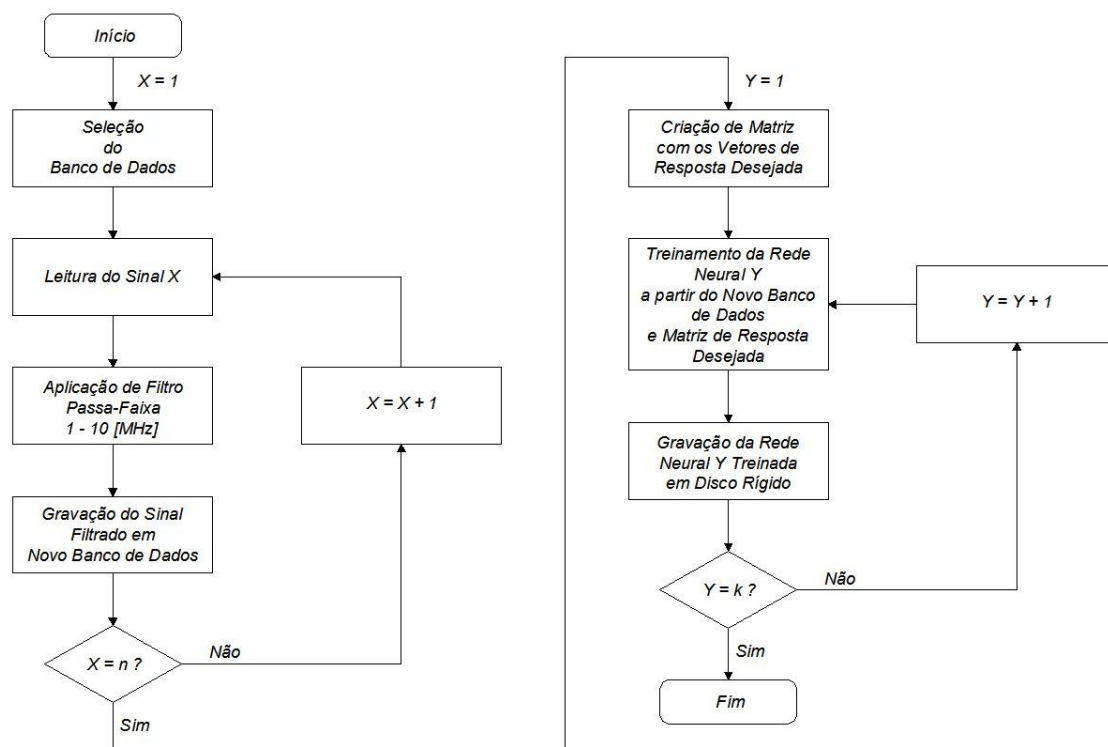


Figura 5.22 - Fluxograma do treinamento das redes neurais do Ensaio nº 8, onde n é a quantidade de sinais contidos no banco de dados e k a quantidade de redes neurais.

Após o treinamento foram submetidos 60 sinais (Tabela 5.10) para verificação de desempenho do programa, etapa esta representada pelo fluxograma da Figura 5.23.

Tabela 5.10 - Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio nº 8.

Sinais para Verificação de Desempenho – Ensaio nº 8						
Localização da Cadeia de Isoladores na Linha de Transmissão	km 01	km 08	km 15	km 22	km 29	km 36
Sinais	1 a 10	11 a 20	21 a 30	31 a 40	41 a 50	51 a 60

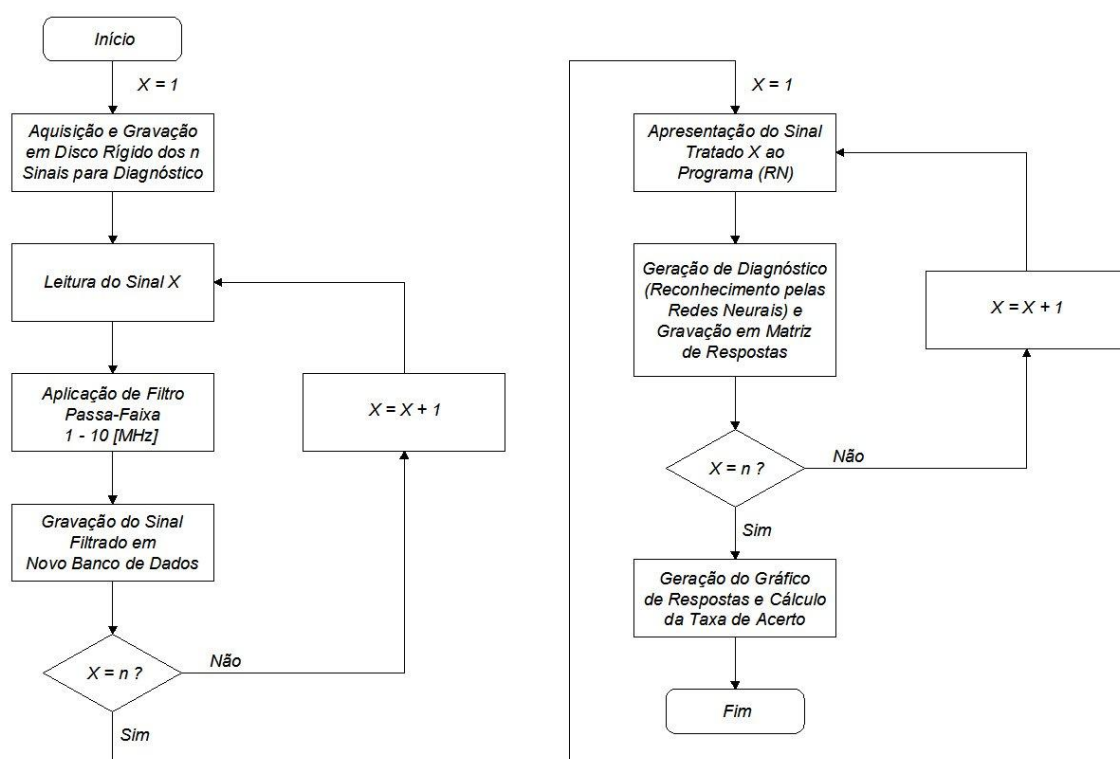


Figura 5.23 - Fluxograma da etapa de diagnóstico do programa do Ensaio nº 8, onde n é a quantidade de sinais submetidos ao reconhecimento.

O resultado pode ser visualizado no gráfico da Figura 5.24, onde se observa que o programa obteve uma taxa de acerto de 100%, fornecendo diagnósticos com baixo grau de incerteza.




Figura 5.24 - Resposta do programa para a localização da cadeia de isoladores ao longo da linha de transmissão.

5.5.2 Ensaio n° 9

Como visto no item anterior, o Ensaio n° 8 contou com a utilização de apenas um filtro passa-faixa para o tratamento de sinais, isto é, foi mantida a quantidade de 500 amostras por sinal. Isso levou a uma taxa de acerto de 100%, porém, como já comentado no item 5.4, a utilização dos sinais com o número original de amostras exige um esforço computacional muitas vezes impraticável.

Assim, um segundo ensaio de localização foi realizado tomando-se como base o Ensaio n° 8, dessa vez utilizando um algoritmo desenvolvido nesse trabalho para redução do número de amostras. Esse algoritmo, chamado de *filtro de porcentagem*, pode ser entendido através do fluxograma da Figura 5.25:

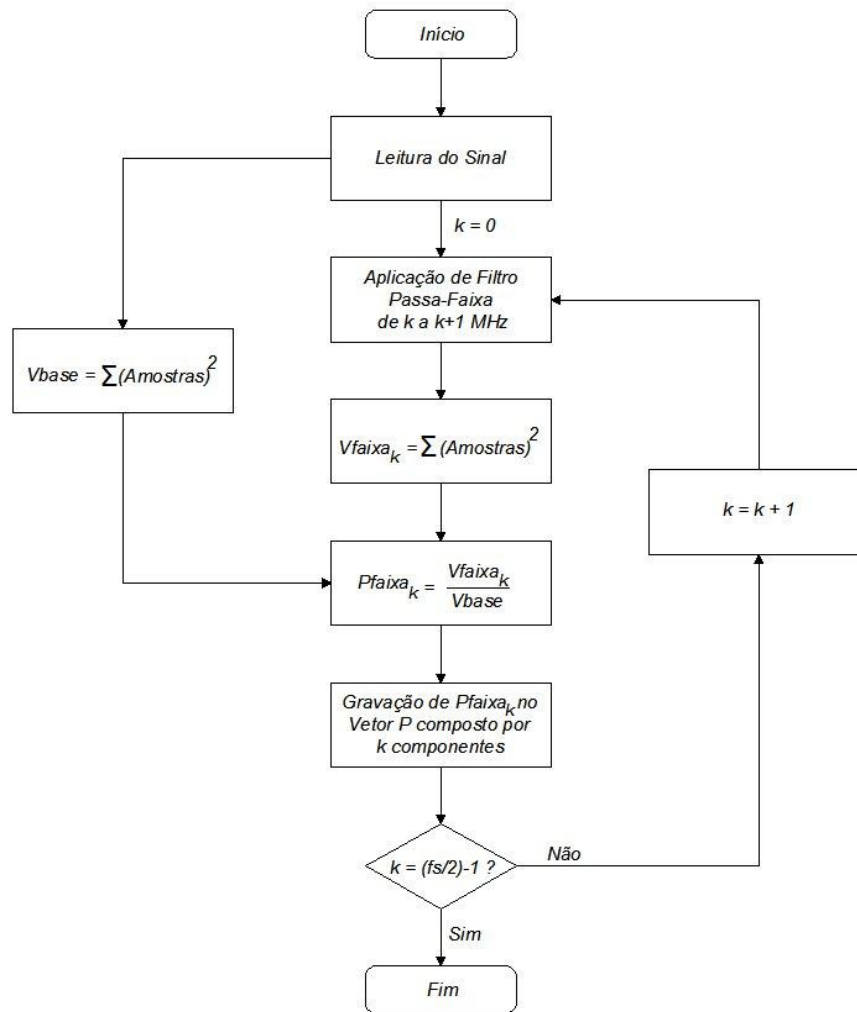


Figura 5.25 - Algoritmo de redução de amostras dos sinais: *Filtro de Porcentagem*.

O filtro de porcentagem representa um sinal por valores de intensidade de faixas de frequência com largura de 1 [MHz]. Como os sinais utilizados neste trabalho foram digitalizados a uma taxa de 100 [MS/s], respeitando-se o teorema de Nyquist tem-se que a máxima faixa de frequência analisada é de 49 a 50 [MHz]. Assim, o sinal filtrado por esta técnica é representado por um vetor de cinquenta valores, isto é, o sinal é reduzido para 10% de seu tamanho original. A Figura 5.26 mostra um exemplo de um sinal seguido dos gráficos gerados pela aplicação dos algoritmos de FFT e filtro de porcentagem. Nessa figura é possível observar a proximidade de resultados entre estes dois algoritmos.

Para a realização do ensaio foram escolhidos doze taps da linha de transmissão artificiais, criando-se um banco de dados com 1.000 sinais para cada tap seguindo os passos descritos no fluxograma da Figura 5.27. O dispositivo de reprodução de efeito corona permaneceu fixo em um isolador durante todo o ensaio.

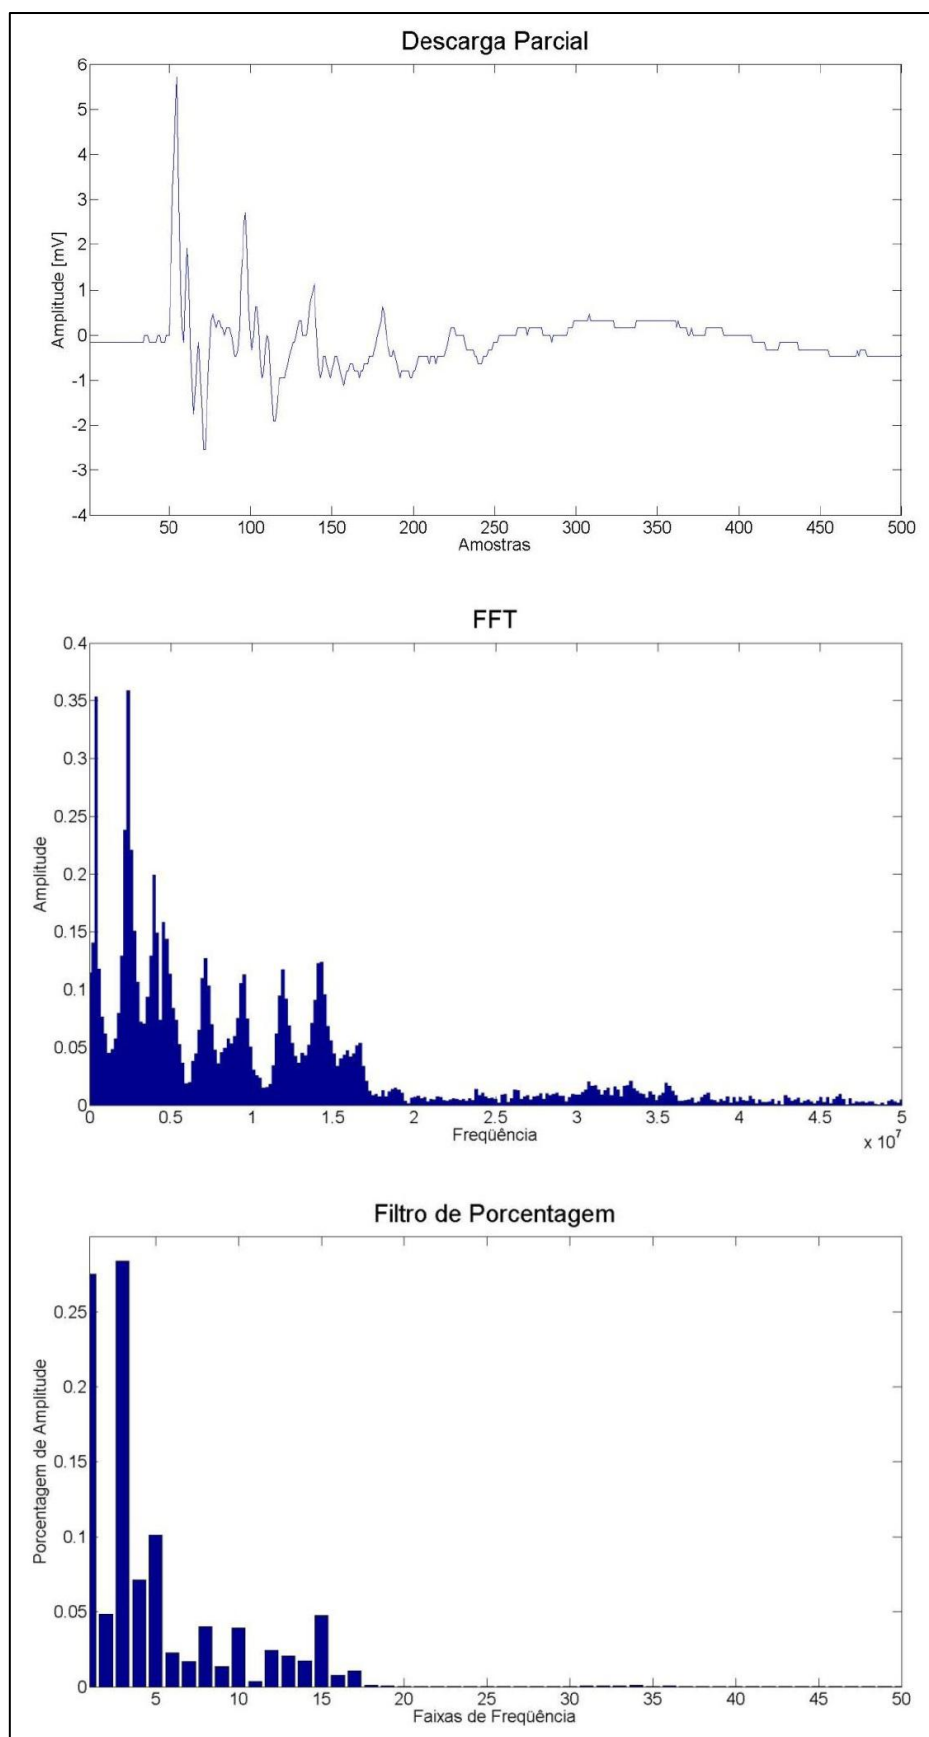


Figura 5.26 - Exemplo de aplicação dos algoritmos FFT e filtro de porcentagem sobre um sinal de descarga parcial.

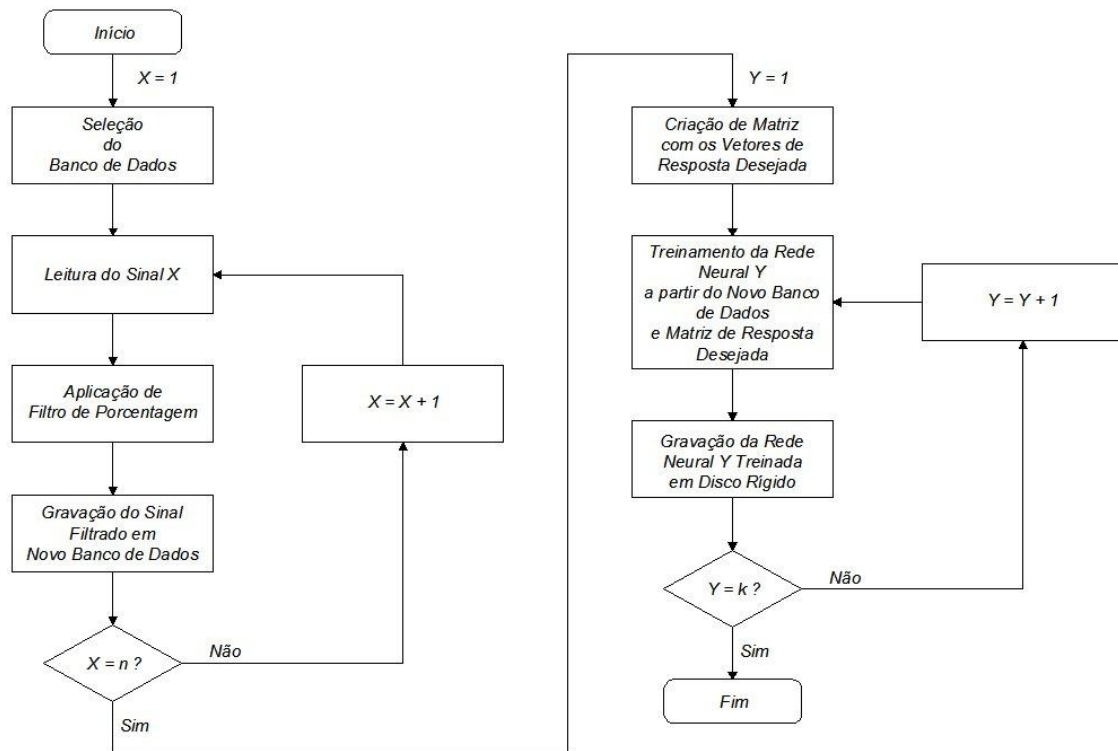


Figura 5.27 - - Fluxograma do treinamento das redes neurais do Ensaio nº 9, onde n é a quantidade de sinais contidos no banco de dados e k a quantidade de redes neurais.

Um conjunto de 120 sinais (Tabela 5.11) não pertencentes ao banco de dados de treinamento das redes neurais foi utilizado para o ensaio de desempenho do programa.

Tabela 5.11 Sinais utilizados para verificação de desempenho do programa utilizado no Ensaio nº 9

Sinais para Verificação de Desempenho – Ensaio nº 9	
Sinais	Localização da Cadeia de Isoladores na Linha de Transmissão
1 a 10	km 01
11 a 20	km 04
21 a 30	km 07
31 a 40	km 11
41 a 50	km 15
51 a 60	km 18
61 a 70	km 22
71 a 80	km 25
81 a 90	km 29
91 a 100	km 32
101 a 110	km 36
111 a 120	km 39

A etapa de reconhecimento de padrões foi realizada conforme o fluxograma da Figura 5.28.

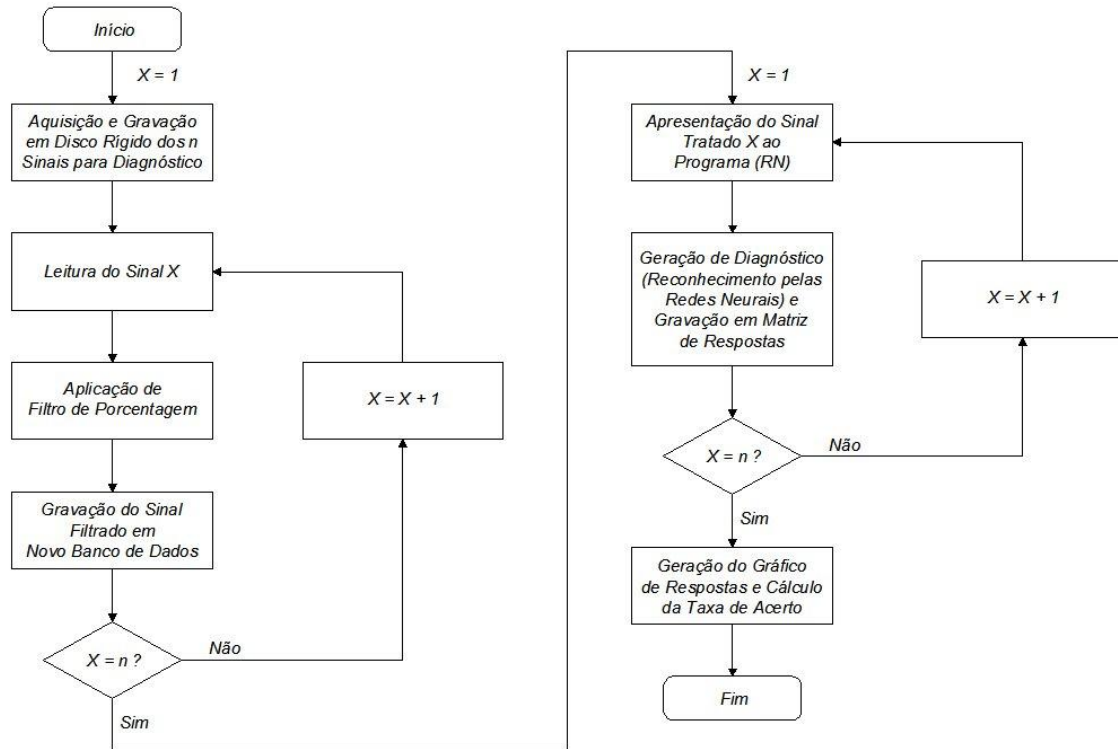


Figura 5.28 - Fluxograma da etapa de diagnóstico do programa do Ensaio nº 9, onde n é a quantidade de sinais submetidos ao reconhecimento.

O diagnóstico dos sinais de ensaio de desempenho é mostrado no gráfico da Figura 5.29, onde é possível notar que não houve redução sensível da qualidade das respostas em relação ao Ensaio nº 8. A taxa de acerto foi de 100% e as respostas apresentaram baixo grau de incerteza.

Os resultados obtidos nesse ensaio mostram que para se obter uma alta qualidade no diagnóstico dos sinais não é necessário que se trabalhe com o sinal puro, penalizando o computador.




Figura 5.29 - Resultado do Ensaio nº 9.

5.6 Considerações Finais

Os ensaios descritos neste capítulo mostraram as diferentes configurações possíveis dos programas e da sistemática utilizada em laboratório, além dos resultados obtidos com cada uma delas. As observações são válidas tanto para o caso dos ensaios de identificação quanto para o caso dos ensaios de localização, uma vez que a diferença básica entre eles é o circuito elétrico compreendido entre a descarga parcial e o acoplador capacitivo.

Pode ser observada durante os ensaios uma relação entre a qualidade do diagnóstico e o esforço computacional necessário para tal, sendo que se mostrou possível um equilíbrio entre esses dois parâmetros, como no caso do Ensaio nº 9.

Capítulo 6

Conclusões

6.1 Conclusões

Esta dissertação de mestrado propôs um método de localização de cadeias de isoladores danificadas através do reconhecimento da forma onda de descargas parciais geradas pelo efeito corona presente nestas cadeias. Tal método permite a inspeção das cadeias de isoladores de forma remota, algo ainda não realizado por nenhum produto comercial até o presente momento. A inspeção remota destes equipamentos pode elevar o grau de confiabilidade das linhas de transmissão a um patamar mais elevado, além de reduzir drasticamente os custos com as inspeções presenciais.

O reconhecimento dos padrões de formas de onda das descargas parciais foi realizado através de redes neurais. Estas redes neurais constituíram a parte principal de diversos programas dotados também de funções para tratamento de sinais. Totalmente desenvolvidos em Matlab®, os programas se mostraram robustos e confiáveis, porém notou-se que o ambiente Matlab® não confere rapidez de processamento e economia de recursos aos seus programas.

Também foi mostrada a possibilidade de se realizar a aquisição de sinais através da carcaça dos TCs, eliminando-se a necessidade do uso de capacitores de acoplamento ou TPCs. Isso se traduz em uma grande economia na compra e manutenção de equipamentos, além de tornar mais prática a aquisição de sinais.

O Capítulo 5 mostrou nove ensaios realizados durante o desenvolvimento do método, sendo utilizados em cada um deles configurações específicas de sistemática de ensaio e funcionamento do programa de reconhecimento de padrões. Esses ensaios foram agrupados conforme a utilização ou não de algoritmo de compressão de dados (LPC) e conforme o objetivo do reconhecimento de padrões: identificação do isolador danificado na cadeia de isoladores ou localização desta na linha de transmissão.

No primeiro ensaio realizado, o Ensaio nº 1, o objetivo foi identificar dois padrões de formas de onda: sinais gerados em uma cadeia de isoladores intacta e sinais gerados em uma cadeia de isoladores com um dos isoladores danificado. Com o dispositivo de reprodução de efeito corona instalado sempre na mesma posição e com a cadeia de isoladores conectada sempre no mesmo tap da linha de transmissão, foram coletados 800 sinais de cada padrão para treinamento das redes neurais e outros 20 sinais para ensaio de desempenho do programa. Submetidos ao

reconhecimento pelas redes neurais, 95% desses 20 sinais foram diagnosticados corretamente. A incerteza nas respostas, porém, foi alta para alguns casos, significando que o conhecimento das redes neurais não tinha atingido um patamar suficiente para distinguir satisfatoriamente todos os sinais. O reduzido banco de dados para treinamento das redes neurais e a perda de informação devido à filtragem e compressão dos sinais por LPC pode ter sido determinante para este comportamento do programa.

O Ensaio n° 2, onde também foram utilizadas filtragem e compressão por LPC, consistiu em uma evolução do ensaio anterior. Cada padrão a ser reconhecido pelas redes neurais foi formado pelo agrupamento de padrões distintos, isto é, as redes neurais foram treinadas para responder com a mesma saída para um conjunto de entradas diferentes. No caso, o objetivo foi identificar se um sinal de descarga parcial tinha origem em uma cadeia de isoladores intacta ou em uma cadeia de isoladores contendo um de seus isoladores danificado. Porém, diferentemente do Ensaio n° 1, houve variação tanto da posição do isolador quebrado quanto do dispositivo de reprodução de efeito corona. Para o treinamento das redes neurais foi montado um banco de dados com 30.000 sinais, sendo 6.000 deles provenientes da cadeia de isoladores intacta e os demais provenientes da cadeia de isoladores danificada. Um conjunto de 30 sinais provenientes da cadeia de isoladores intacta e 120 sinais provenientes da cadeia de isoladores danificada foi utilizado para verificar o desempenho do programa, sendo que a taxa de acerto para o reconhecimento de padrões foi de 20% para o caso dos sinais gerados na cadeia de isoladores intacta e 97% para os sinais gerados na cadeia de isoladores danificada. Tal diferença de desempenho entre o reconhecimento desses dois padrões pode ser creditada ao notável desequilíbrio do banco de dados. Tal desequilíbrio fez com que as redes neurais aprendessem mais sobre um padrão, prejudicando o reconhecimento do outro.

Essa deficiência foi sanada no Ensaio n° 3, o qual consistiu em uma repetição do Ensaio n° 2, porém com um banco de dados equilibrado. Para ambos os padrões foram utilizados 6.000 sinais para o treinamento das redes neurais. Já para o ensaio de desempenho do programa, 60 sinais foram coletados, sendo metade de cada padrão, obtidendo-se uma taxa de 83% para ambos os casos. Ainda assim, como no Ensaio n° 2, várias situações foram diagnosticadas com um alto grau de incerteza.

O Ensaio n° 4 foi realizado para se verificar o quão preciso poderia ser o sistema desenvolvido. Ainda contando com filtragem e compressão por LPC, o objetivo era identificar de qual cadeia de isoladores o sinal era proveniente e, no caso

desta ser a cadeia de isoladores danificada, o programa deveria diagnosticar também em qual dos isoladores a descarga parcial havia sido gerada. As Redes neurais foram treinadas com um banco de dados desequilibrado, formado por 3.000 sinais gerados na cadeia de isoladores intacta e 2.400 sinais gerados na cadeia de isoladores danificada, sendo que neste último caso a quantidade de sinais foi simetricamente distribuída entre os cinco padrões possíveis dessa cadeia de isoladores. Para o ensaio de desempenho do programa foram coletados 15 sinais provenientes da cadeia de isoladores intacta e 12 sinais para cada um dos cinco padrões da cadeia de isoladores danificada, sendo que a taxa de acerto nestes casos foram, respectivamente, 93%, 83%, 50%, 67%, 42% e 67%. Apesar da diferença na qualidade dos diagnósticos, já esperado devido ao desequilíbrio do banco de dados, mostrou-se que o método possui precisão suficiente para identificar o isolador danificado na cadeia, embora tal capacidade não apresente vantagem prática no que tange a manutenção de linhas de transmissão, uma vez que as cadeias de isoladores danificadas são substituídas por completo.

De forma a verificar a influência do uso do LPC na qualidade dos diagnósticos, foram realizados alguns ensaios com os sinais tratados por filtragem, porém sem a utilização de compressão. O Ensaio n° 5 foi o primeiro desses, sendo que o mesmo consistiu na reprodução do Ensaio n° 3. A verificação de desempenho do programa resultou em taxas de acerto de 100% para o caso da cadeia de isoladores intacta e 83% para o caso da cadeia de isoladores danificada, uma melhora de 20% sobre o reconhecimento do padrão do primeiro caso. Para o caso da cadeia de isoladores danificada, o desempenho foi mantido.

O Ensaio n° 6 consistiu na repetição dupla do Ensaio n° 4: uma com a aplicação de LPC e com banco de dados alterado de forma a melhorar o equilíbrio do treinamento das redes neurais e outra similar, porém sem o uso de LPC. Sendo os bancos de dados utilizados idênticos, pode-se afirmar que diferença obtida no desempenho de ambos os programas realizados no Ensaio n° 6 foi devida somente à utilização ou não desse algoritmo de compressão. A eliminação do LPC contribuiu para uma melhora geral dos diagnósticos em 67%, sendo que apenas um padrão não teve 100% dos seus sinais identificados corretamente. A taxa de acerto geral foi 83%.

No Ensaio n° 7, o último de identificação realizado, foi feita uma varredura nas redes neurais treinadas no Ensaio n° 6 com o objetivo de encontrar o motivo de um dos padrões não ter 100% de seus sinais reconhecidos. Executando o programa com uma rede neural por vez, ao invés de utilizar as vinte redes neurais em conjunto, foi

possível identificar uma rede neural cujos resultados não eram coerentes com os demais. Eliminando-se essa rede neural e executando o programa novamente, isto é, com as redes neurais restantes em conjunto, obteve-se então uma taxa de acerto geral de 100%. Isso confirma que a utilização de diversas redes neurais em conjunto tende a evitar ou amenizar erros ocorridos durante as etapas de treinamento e/ou reconhecimento de padrões.

Finalizados os ensaios de identificação, foram realizados dois ensaios de localização de cadeias de isoladores na linha de transmissão artificial. O primeiro deles, o Ensaio nº 8, foi realizado sem a compressão dos sinais por LPC, porém filtragem convencional foi mantida. O objetivo era localizar a cadeia de isoladores danificada em seis posições possíveis na linha de transmissão. Para tal, foi criado um banco de dados com 1.000 sinais para cada caso, sendo dispositivo de reprodução de efeito corona mantido em posição fixa. Com 60 sinais coletados para o ensaio de desempenho, obteve-se uma taxa de acerto de 100%, cuja qualidade pode ser creditada principalmente ao fato de se utilizar os sinais sem compressão.

Como sinais formados por um número elevado de amostras, no caso 500, não são utilizados na prática, no Ensaio nº 9 repetiu-se o ensaio anterior, porém com o uso de um algoritmo de redução de amostras chamado de *filtro de porcentagem*, desenvolvido neste trabalho. Esse filtro reduz o número de amostras de 500 para 50, ou seja, o sinal é reduzido para 10% de seu tamanho original. Utilizando um banco de dados que contemplava doze posições da linha de transmissão, isto é, doze padrões a serem reconhecidos, as redes neurais foram treinadas e 120 sinais foram coletados para o ensaio de desempenho. O diagnóstico foi realizado com uma taxa de acerto de 100%, mostrando que não é necessário se utilizar o sinal sem compressão para se obter tal patamar de qualidade de resposta.

6.2 Publicações

O desenvolvimento deste trabalho gerou, além desta dissertação de mestrado, quatro artigos publicados e apresentados em congressos:

- *Deteção de Defeitos em Isoladores e Faltas em Linhas de Transmissão Através de TCs e Redes Neurais*, no IX International Conference on Industry Application (INDUSCON), 2010;

- *Método de Captura de Sinais Provenientes de Isoladores Danificados por Meio do Aterramento do Transformador de Corrente*, no XXVI International Sodebras Congress, 2011;
- *Utilização da Infraestrutura Existente nas Saídas de Linha para Monitoramento de Cadeias de Isoladores de Linha de Transmissão*, no XIV Encontro Ibero-Americano do CIGRÉ (ERIAC), 2011;
- *The Use of Artificial Neural Networks for Identification and Location of Defective Insulators in Power Lines Through Current Transformers*, no 21st International Conference on Electricity Distribution (CIRED), 2011.

6.3 Sugestões para Trabalhos Futuros

Sugere-se para continuação deste trabalho:

- Testar novos algoritmos de tratamento de sinais, tanto relacionados a filtragem como compressão;
- Utilizar outros tipos de redes neurais, puras ou associadas com outras técnicas de inteligência artificial, formando sistemas híbridos;
- Encontrar as características-chave dos sinais de descargas parciais, isto é, aquelas que efetivamente tornam os sinais diferentes entre si perante as redes neurais;
- Entendidas as características-chave dos sinais, tentar reproduzi-los em simulações. O sucesso desta etapa irá permitir que se treine as redes neurais sem a necessidade de se montar os bancos de dados com sinais obtidos em campo;
- Estudar alterações nos projetos de transformadores de corrente de forma que a capacitância entre fase a carcaça seja de alguma forma padronizada.

Referências Bibliográficas

ADAMI, J. F. *Detecção de identificação de arcos de contorno em cadeias de isoladores de linhas de transmissão utilizando técnicas de processamento de sinais*. 2008. Tese (Doutorado em Engenharia Elétrica) – Instituto de Sistemas Elétricos e Energia, Universidade Federal de Itajubá, Itajubá. 2008.

AL-TAI, M. A., ELAYYAN, H. S. B., GERMAN, D. M., HADDAD, A., HARID, N., WATERS, R. T. *The simulation of surge Corona on transmission lines*. IEEE Transactions on Power Delivery, Vol. 4, No. 2, April 1989.

BARROS JR, W. H. *Detecção, classificação e localização de fontes de descargas parciais em cabos de alta tensão usando redes neurais, exame de partículas e o método LN-FDTD*. 2008. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Pará. Belém, 2008.

CÂNDIDO, C. K. S. S., *Classificação de distúrbios na rede elétrica usando redes neurais e wavelets*. 2008. Tese (Doutorado em Engenharia Elétrica) – Centro de Tecnologia, Universidade Federal do Rio Grande do Norte. Natal, 2008.

CARNEIRO JR, S., DOMMEL, H. W., MARTI, J. R., BARROS, H. M. *Na efficient procedure for the implementation of Corona models in electromagnetic transients programs*. IEEE Transactions on Power Delivery, Vol. 9, No. 2, April 1994.

CHENG, Y., LI, C. *Study of Corona discharge pattern on high voltage transmission lines for inspecting faulty porcelain insulators*. IEEE Transactions on Power Delivery, Vol. 23, No. 2, April 2008.

CORVATO, C. D. P. *Classificação de sinais de voz utilizando a transformada wavelet packet e redes neurais artificiais*. 2004. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Rio Grande do Sul. Porto Alegre, 2004.

FERREIRA, T. V., GERMANO, A. D., VILAR, P. B., COSTA, E. G., BEZERRA, J. M. B. *Diagnóstico de isoladores baseado na emissão de ruídos ultra-sônicos*. XIII Encontro Ibero-Americano do CIGRÉ - ERIAC, 2009.

FUCHS, R. D. *Linhas aéreas de transmissão de energia elétrica*. Itajubá: Escola Federal de Engenharia de Itajubá, 1973.

HAYKIN, S. *Redes neurais: princípios e prática*. 2 ed. Ontario: Bookman, 2001.

HEDMAN, D. E. *Teoria das linhas de transmissão, Vol I & II*. Santa Maria: Centrais Elétricas Brasileiras S.A. & Universidade Federal de Santa Maria, 1979.

GIOVANINI, R., COURY, D. V. *Classificação rápida de faltas em sistemas elétricos utilizando redes neurais artificiais*. IV Congresso Brasileiro de Redes Neurais, 1999.

GOMES, C. R. *Localização de falhas em linhas de transmissão utilizando decomposição harmônica e redes neurais artificiais*. 2006. Dissertação (Mestrado em Engenharia Elétrica) – Centro Tecnológico, Universidade Federal do Pará. Belém, 2006.

JORGE, D. C., COURY, D. V., CARVALHO, A. C. P. L. F. *Localização de faltas em linhas de transmissão de energia elétrica utilizando reconhecimento de padrões*. IV Congresso Brasileiro de Redes Neurais, 1999.

KONDRATH, N., KAZIMIERCZUK, K. M. *Bandwidth of current transformers*. IEEE Transactions on Instrumentation and Measurement, Vol. 58, No. 6, June 2009.

MALANGE, F. C. V. *Rede neuro-fuzzy-wavelet para detecção e classificação de anomalias de tensão em sistemas elétricos de potência*. 2010. Tese (Doutorado em Engenharia Elétrica) – Universidade Estadual Paulista. Ilha Solteira, 2010.

MELLO, D. R., CARDOSO, J. A. D., GONÇALVES, P. P. *Avaliação do desempenho de cadeias de isoladores para linhas de transmissão quanto à radiointerferência*. III Simpósio Brasileiro de Sistemas Elétricos - SBSE, 2010.

MELLO, D. R., CARDOSO, J. A. D., RODRIGUES, J. A. P., SILVA, F. D., GARCIA, R. W. *Estudos sobre o desempenho de cadeias de isoladores para redes de distribuição com isoladores quebrados ou perfurados*. XIII Encontro Ibero-Americano do CIGRÉ - ERIAC, 2009.

MIRANDA, G. C. *Uma contribuição ao estudo do efeito Corona em linhas de transmissão utilizando o método de elementos finitos*. 1994. Tese (Doutorado em Engenharia Elétrica) – Universidade Estadual de Campinas. Campinas, 1994.

PARK, T. H. *Introduction to signal processing: computer musical speaking*. World Scientific Publishing Co., 2010.

PAVLIK, B.L. *Tecnologia da ferragem para linhas de AT e EAT*. São Paulo: Editorial Gente, 1989.

TADEUSIEWICZ, R., WSZOLEK, T., IZWORSKI, A., WSZOLEK, W. *Recognition of defects in high voltage transmission lines using the acoustic signal of Corona effect*. IEEE, 2000.

THIBODEAU, G. A. , PATTON, K. T. *Estrutura e funções do corpo humano*. 11 ed. Manole, 2002. p. 162 – 167

VELOSO, G. F. C., SILVA, L. E. B., NORONHA, I., TORRES, G. L., SANTO JR, D. E. *Detecção de descargas parciais em transformadores de potência utilizando transformada wavelet*. VIII International Conference on Industry Applications - INDUSCON, 2008.