

**Universidade Federal de Campina Grande**

**Centro de Ciências e Tecnologia - CCT**

**Programa de Pós-Graduação em Engenharia Elétrica**

Tese de Doutorado

***Caracterização de Atributos de Sinais para Utilização de Técnicas de Reconhecimento de Padrões na Avaliação do Isolamento de Instalações e de Equipamentos Elétricos.***

**José Maurício de Barros Bezerra**

Campina Grande  
Abril - 2004

---

---

**Universidade Federal de Campina Grande**

**Centro de Ciências e Tecnologia - CCT**

**Programa de Pós-Graduação em Engenharia Elétrica**

**José Maurício de Barros Bezerra**

---

***Caracterização de Atributos de Sinais para Utilização de Técnicas de Reconhecimento de Padrões na Avaliação do Isolamento de Instalações e de Equipamentos Elétricos.***

Tese de Doutorado submetida à Coordenação dos Cursos de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande como parte dos requisitos necessários para obtenção do grau de Doutor em Engenharia Elétrica.

Área de Concentração: Processamento da Informação

Orientadores:

Professor Gurdip Singh Deep  
Professor Antônio Marcus Nogueira Lima  
Professor Edson Guedes da Costa

Campina Grande

© José Maurício de Barros Bezerra, abril - 2004

---

Ficha catalográfica

B 547c Bezerra, José Maurício de Barros.  
2004 Caracterização de Atributos de Sinais para Diagnóstico do Isolamento de Instalações e Equipamentos Elétricos. / José Maurício de Barros Bezerra. - Campina Grande; UFCG, 2004.  
150p.: il.  
Inclui bibliografia.  
Tese (Doutorado) UFCG/DEE.

1. Técnicas de reconhecimento de padrões. 2. Fusão de dados. 3. Processamento digital de sinais. 4. Diagnóstico de isolamentos elétricos de alta tensão.

CDU 682.518.54

**DIGITALIZAÇÃO:**

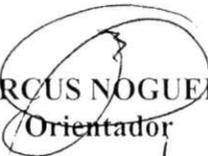
**SISTEMOTECA - UFCG**

CARACTERIZAÇÃO DE ATRIBUTOS DE SINAIS PARA  
UTILIZAÇÃO DE TÉCNICAS DE RECONHECIMENTO DE PADRÕES NA  
AVALIAÇÃO DO ISOLAMENTO DE INSTALAÇÕES E DE  
EQUIPAMENTOS ELÉTRICOS

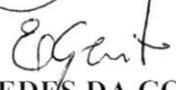
JOSÉ MAURÍCIO DE BARROS BEZERRA

Tese Aprovada em 23.04.2004

PROF. ANTONIO MARCUS NOGUEIRA LIMA, Dr., UFCG

  
Orientador

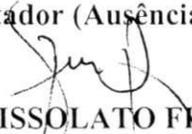
PROF. EDSON GUEDES DA COSTA, D.Sc., UFCG

  
Orientador

PROF. GURDIP SINGH DEEP, Ph.D., UFCG

Orientador (Ausência Justificada)

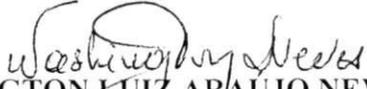
PROF. JOSÉ PISSOLATO FILHO, Dr., UNICAMP

  
Componente da Banca

PROF. IVAN JOSÉ DA SILVA LOPES, Ph.D., UFMG

  
Componente da Banca

PROF. WASHINGTON LUIZ ARAUJO NEVES, Ph.D., UFCG

  
Componente da Banca

PROF. FRANCISCO MARCOS DE ASSIS, Dr., UFCG

  
Componente da Banca

CAMPINA GRANDE – PB

ABRIL - 2004

### *Dedicatória*

*Esta obra é dedicada especialmente a minha esposa, Judith Santos de Souza Lima Bezerra, companheira fiel de todas as horas de árduas batalhas; aos meus pais, Mozart Bezerra Alves e Maria Luiza de Barros Bezerra (em memória), pelas sementes lançadas no sentido da construção do meu intelecto e aos meus filhos, Carlos Eduardo Lima Bezerra, Ricardo Lima Bezerra e Mônica Regina Lima Bezerra, para que as sementes se multipliquem na busca e aplicação de novos conhecimentos e que floresçam continuamente contribuindo desta forma para a transformação do nosso país em uma nação mais soberana e socialmente mais justa.*

## Agradecimentos

Ficam aqui registrados os agradecimentos a CAPES e ao PRONEX/CNPq pelo aporte de recursos necessários a concretização das pesquisas ora relatadas; aos Professores Deep, Antônio Marcus e Edson Guedes pelas incansáveis sessões de debates, avaliações e sugestões na condução de todo o projeto; ao Professor Manasses, do Departamento de Engenharia Mecânica/UFCG, por suas orientações iniciais para detalhamento do projeto mecânico da câmara de névoa; ao Professor Yogi, do mesmo departamento, pelas orientações necessárias ao processo de suprimento d'água e de ar comprimido à câmara de névoa; ao Professor Kepler, do Departamento de Engenharia Química/UFCG, pelo seu apoio no detalhamento dos processos para elaboração das soluções de poluição que foram posteriormente utilizadas nos isoladores submetidos a ensaios, como, também, pelo uso do laboratório de química, orientação e acompanhamento durante a constituição das soluções; ao Engenheiro Max, da CHESF/CG, pela liberação de isolador polimérico, pelos debates que auxiliaram na concepção da bucha polimérica, pelos ensaios preliminares realizados com o termovisor para testes de aquisição de imagens térmicas dos isoladores submetidos à tensão elétrica e névoa e pela liberação de imagens térmicas obtidas em inspeções de rotina no sistema de transmissão de energia elétrica da CHESF; ao Técnico Brandão, da CHESF/CG, alocado para dar suporte na captação das imagens térmicas anteriormente comentadas; a Engenheira Tereza, do Centro de Ensaios da CHESF, pela liberação do instrumento de ultra-som; a Escola Técnica Redentorista pela liberação de analisador de espectro para extração de atributos de sinais gerados por descargas superficiais a isoladores, na frequência de rádio; a CHESF/DML pela liberação de dados estatísticos sobre desempenho do sistema de transmissão quanto a falhas transitórias; ao Professor Freire e Técnicos Bianca e Emanuel, do Departamento de Engenharia Elétrica/UFCG, pelo projeto, montagem e testes do circuito de proteção ao digitalizador; ao Técnico Mecânico Danilo, do Departamento de Engenharia Elétrica/UFCG, pelo torneamento das peças/acessórios que compuseram a câmara de névoa; aos Técnicos Eduardo, Francisco, Adriano e Adalberto do Laboratório de Alta Tensão, do mesmo departamento, por todas as montagens elétricas realizadas naquele laboratório que permitiram a realização dos experimentos aqui comentados; aos professores Glauco e Rômulo do Departamento de Engenharia Elétrica/UFCG pelo apoio na inserção de antena de VHF como um dos sensores utilizados; ao jovem cientista Max Néri, estudante de engenharia elétrica da UFCG, pelo seu apoio na aquisição e digitalização dos sinais e a todo corpo docente, discente, técnico e administrativo da UFCG que direta ou indiretamente contribuíram para os resultados do projeto.

## Sumário

Capítulo 1: Introdução .....	15
Capítulo 2: Revisão Bibliográfica .....	24
2.1 Descargas em Isoladores Aéreos .....	25
2.2 Descargas em Isolantes Internos.....	26
Capítulo 3: Metodologia .....	32
3.1 Conceitos Preliminares de Reconhecimento de Padrões .....	33
3.2 Tipos de Atributos Extraídos .....	35
3.3 Técnicas Matemáticas Aplicadas.....	37
3.4 Estudo de Casos.....	37
3.4.1 Caso 1: Poluição em Isoladores.....	37
3.4.1.1 Sensor de Ultra Som .....	38
3.4.1.2 Sistema de Digitalização.....	38
3.4.1.3 Câmara de Névoa.....	39
3.4.1.4 Circuito de Proteção .....	40
3.4.1.5 Termovisor.....	43
3.4.1.6 Antena de VHF e Analisador de Espectro .....	44
3.4.1.7 Preparação das Amostras.....	44
3.4.1.8 Arranjo Experimental .....	45
3.4.1.9 Identificação da Tensão de Ensaio.....	46
3.4.1.10 Desenvolvimento dos Experimentos .....	53
3.4.1.11 Processamento das Informações .....	53
3.4.2 Caso 2: Defeitos em Isoladores Poliméricos .....	54
3.4.2.1 Circuito Experimental e seus Componentes.....	54
3.4.2.2 Preparação das Amostras.....	56
3.4.2.3 Procedimento dos Ensaios .....	56
3.4.2.4 Processamento das Informações .....	57
Capítulo 4: Análise e Discussão dos Resultados.....	62
4.1 Caso 1: Poluição em Isoladores.....	63
4.1.1 Sensor Térmico (termovisor).....	64
4.1.2 Sensor de VHF.....	67
4.1.3 Sensor de Ultra-som .....	69
4.1.3.1 Sinais de Ultra-som no Domínio do Tempo .....	69
4.1.3.2 Sinais de Ultra-som no Domínio da Freqüência.....	71
4.1.3.3 Sinais de Ultra-som. Avaliações a partir das Transformadas Wavelets .....	72
4.1.4 Sensor de Corrente de Fuga.....	77
4.1.4.1 Sinais de Corrente de Fuga no Domínio do Tempo.....	78
4.1.4.2 Sinais de Corrente de Fuga no Domínio da Freqüência .....	79
4.1.4.3 Sinais de Corrente de Fuga. Avaliações a partir das Transformadas Wavelets .....	80
4.1.5 Avaliação de Classificadores Não Lineares.....	83
4.1.6 Análise da Composição de Sinais e Sensores.....	88
4.1.7 Validação dos Modelos.....	92
4.1.8 Perspectivas Operacionais dos Classificadores.....	96
4.1.9 Avaliação do Estudo.....	102

4.2 Caso 2: Defeitos em Isoladores Poliméricos .....	102
4.2.1 Resultados Obtidos .....	102
4.2.2 Validação dos Modelos.....	105
4.2.3 Avaliação do Estudo .....	105
Capítulo 5: Conclusões .....	106
5.1 Contribuições de Caráter Técnico-científico .....	106
5.2 Contribuições de Caráter Tecnológico .....	108
5.3 Refinamentos Propostos para Continuidade das Pesquisas .....	111
5.4 Considerações Finais .....	111
Anexo.....	113
A.1 Técnicas Lineares de Reconhecimento de Padrões .....	113
A.1.1 Técnicas para Determinação do Classificador Linear .....	119
A.1.1.1 Técnica de Fisher .....	120
A.1.1.2 Técnica de Fisher para Seleção de Atributos.....	124
A.1.1.3 Técnica de Karhunen-Loève .....	125
A.1.1.4 Técnicas de Redes Neurais .....	129
A.2 Técnicas Não Lineares de Reconhecimento de Padrões.....	135
A.3 Extração de Atributos .....	138
A.3.1 Técnicas de Processamento Digital de Sinais.....	138
A.3.2 Transformada de Fourier .....	139
A.3.3 Transformada Wavelet.....	141
Bibliografia .....	145

## Índice de Figuras

Figura 1 – Desenvolvimento das descargas em uma unidade de isolador contaminado durante o ciclo de umedecimento: (a) descargas corona; (b) descargas pré-cintilação e (c) descargas de cintilação.....	16
Figura 2 – Estatística de falhas transitórias no sistema CHESF (período 1987 – 2002). Fonte: CHESF (2003).....	18
Figura 3 - Taxa de falhas transitórias no sistema CHESF, por poluição.....	19
Figura 4 – Regiões mais críticas de poluição no sistema CHESF.....	19
Figura 5 – Um sistema de reconhecimento de padrões.....	21
Figura 6 – Ilustração das grandezas básicas de descarga. Fonte: Gulski e Kreuger (1992).....	28
Figura 7 - Exemplo de regiões de decisão em um espaço bi-dimensional. Fonte: Slansky e Wassel (1981).....	35
Figura 8 – Ilustração do funcionamento do sistema de detecção de ultra-som. Fonte: BIDDLE (1990).....	38
Figura 9 – Foto da câmara de névoa: (a) vista da câmara ilustrando as suas alimentações de tensão elétrica, água e ar comprimido e captação da corrente de fuga; (b) bucha polimérica para passagem da alimentação de tensão elétrica; (c) par de bicos injetores.....	39
Figura 10 – Circuito de proteção do digitalizador: (a) lado acoplado a alta tensão; (b) lado acoplado a baixa tensão e isolado por acoplamento óptico e (c) filtragem/amplificação.....	41
Figura 11 – Diagrama de blocos do circuito de proteção.....	43
Figura 12 – Arranjo elétrico dos ensaios de poluição em isoladores.....	46
Figura 13 – Modelo computacional para cálculo de tensões de 50%.....	47
Figura 14 – Descargas parciais em bandas secas na superfície de isoladores. Fonte: Rizk (1981).....	48
Figura 15 – Propagação do arco no isolador poluído (a) tempo $t_1$ , (b) tempo $t_2$ .....	50
Figura 16 – Tensões de descarga para os isoladores: (a) padrão e (b) anti-poluição.....	52
Figura 17 – Circuito experimental para medição de descargas parciais.....	55
Figura 18 - Fotografia do arranjo experimental de detecção de descargas parciais. Fonte: Medeiros (2003).....	55
Figura 19 – Indicação e descrição dos defeitos em isoladores poliméricos.....	56
Figura 20 – Ilustração do objeto de ensaio (isolador polimérico).....	57
Figura 21 – Sinais “brutos” adquiridos.....	58
Figura 22 – Janela de fase sincronizada.....	58
Figura 23 – “Janelas de fase” registradas em seqüência.....	60
Figura 24 – Vetores de atributos para formação da matriz de atributos.....	61
Figura 25 – Apresentação das imagens térmicas e histogramas básicos para cada nível de poluição.....	65
Figura 26 – Desempenho do Classificador, para imagens térmicas, em função do número de faixas do histograma.....	66
Figura 27 – Espectro de frequência para sinais de VHF típicos.....	68
Figura 28 – Desempenho de classificador para sinais de VHF, em função do número de faixas no espectro.....	68
Figura 29 – Sinais típicos de ultra-som para diferentes níveis de poluição.....	69

Figura 30 – Histogramas típicos dos sinais de ultra-som no domínio do tempo.....	70
Figura 31 – Classificadores para o sinal de ultra-som no domínio do tempo.....	70
Figura 32 – Densidade espectral de potência para sinais típicos de ultra-som.....	71
Figura 33 – Avaliação de classificadores para o sinal de ultra-som no domínio da frequência. ....	71
Figura 34 - Visualização da decomposição de sinal típico de ultra-som em 6 níveis. Utilizada a wavelet bior3.1 .....	74
Figura 35 – Histogramas de sinais típicos de ultra-som decompostos por wavelets específicas.....	75
Figura 36 – Sinais típicos de corrente de fuga, com a presença de umidade.....	77
Figura 37 – Histogramas para sinais típicos de corrente de fuga, com presença de umidade.....	78
Figura 38 – Avaliação de classificadores para o sinal de corrente de fuga no domínio do tempo. ....	79
Figura 39 – Densidade espectral de potência para sinais típicos de ultra-som.....	79
Figura 40 – Avaliação de classificadores para o sinal de corrente de fuga no domínio da frequência. ....	80
Figura 41 – Histogramas de sinais típicos de corrente de fuga, decompostos por wavelets específicas.....	81
Figura 42 – Visualização da composição da matriz de atributos.....	88
Figura 43 – Sinal de ultra-som com simulação de ruídos.....	95
Figura 44 – Sinal de corrente de fuga com simulação de ruídos. ....	95
Figura 45 – Imagem térmica de cadeia de isoladores na subestação de Natal. ....	97
Figura 46 - Imagem térmica de cadeia de isoladores na Linha de Transmissão de 230 kV Santa Cruz – Natal. ....	97
Figura 47 – Visualização operacional do processo de classificação. ....	98
Figura 48 - Fluxograma para visualização operacional do processo de classificação...	99
Figura 49 – Evolução da indicação dos níveis de poluição.....	101
Figura 50 – Evolução do fator de correlação modificado: (a) isolador sem defeito e (b) isolador com defeito do tipo (a).....	103
Figura 51 – Evolução da assimetria: (a) isolador sem defeito e (b) isolador com defeito do tipo (a).....	103
Figura 52 – Evolução da curtose: (a) isolador sem defeito e (b) isolador com defeito do tipo (a).....	103
Figura 53 – Exemplificação da montagem do hiperplano. Fonte: Slansky e Wassel (1981).....	117
Figura 54 – A superfície de decisão $g(x)=0$ . Fonte: Slansky e Wassel (1981).....	118
Figura 55 – Relações de distâncias em um espaço bi-dimensional. Fonte: Slansky e Wassel (1981). ....	119
Figura 56 – Projeção de amostras sobre uma reta: (a) inadequada e (b) adequada. Fonte: Duda e Hart (1973). ....	120
Figura 57 - Representação geométrica de um classificador de mínima distância quadrada para três classes. Fonte: Anderson (1960). ....	128
Figura 58 – Representação de um neurônio simples. Fonte: Beale e Jackson (1991)..	130
Figura 59 – A função de ativação: (a) disparo em $\theta$ e (b) disparo em 0. Fonte: Beale e Jackson (1991). ....	131
Figura 60 – Detalhe do modelo básico. Fonte: Beale e Jackson (1991).....	132
Figura 61 – Evolução da rede neural de uma camada. Fonte: Beale e Jackson (1991).	133
Figura 62 – Classes linearmente inseparáveis. Fonte: Beale e Jackson (1991).....	134

Figura 63 - Exemplo de regiões de classificação indefinida. ....	134
Figura 64 – Funções de ativação: (a) linear, (b) log-sigmóide e (c) tan-sigmóide. ....	135
Figura 65 – Arquitetura básica de uma rede neural no Matlab (2000). ....	136

## Índice de Tabelas

Tabela 1 – Detalhamento da legenda do diagrama de estatística de falhas. ....	18
Tabela 2 – Tipos de Atributos Analisados. ....	35
Tabela 3 - Caracterização dos níveis de poluição - de acordo com EPRI (1975). ....	44
Tabela 4 - Valores escolhidos para elaboração das soluções. ....	45
Tabela 5 – Relação entre classes e conjuntos de treinamento. ....	64
Tabela 6 – Aplicação do Critério de Seleção de Fisher ao Conjunto de Atributos Associados a Imagens Térmicas. ....	66
Tabela 7 – Número de decomposição de sinais típicos de ultra-som. ....	72
Tabela 8 - Avaliação das Wavelets para decomposição de sinais de ultra-som. ....	76
Tabela 9 - Avaliação das Wavelets para decomposição de sinais de corrente de fuga. .	82
Tabela 10 – Avaliação de algoritmos de treinamento de redes neurais (duas camadas: um neurônio na primeira e na segunda camada; funções de transferência “tansig” nas duas camadas). ....	84
Tabela 11 – Avaliação de algoritmos de treinamento de redes neurais (duas camadas: um neurônio na primeira e na segunda camada; funções de transferência “logsig” nas duas camadas). ....	85
Tabela 12 – Número de iterações para o algoritmo de Levenberg-Marquardt (um neurônio na primeira e na segunda camada). ....	86
Tabela 13 – Número de iterações para o algoritmo de Levenberg-Marquardt (três neurônios na primeira e um neurônio na segunda camada). ....	86
Tabela 14 – Avaliação de algoritmos de treinamento de redes neurais (duas camadas: 1 neurônio na primeira e segunda camadas; funções de transferência “logsig” na primeira camada e “purelin” na segunda camada). ....	87
Tabela 15 - Resumo dos resultados obtidos (todas as composições). ....	90
Tabela 16 -Resumo dos resultados obtidos (composições apenas com a transformada wavelet do sinal de ultra-som). ....	91
Tabela 17 - Validação dos Resultados (sem simulação de ruídos). ....	93
Tabela 18 - Validação dos Resultados (com simulação de ruídos). ....	96
Tabela 19 – Identificação da ordem dos classificadores. ....	99
Tabela 20 – Estado do isolamento. ....	100
Tabela 21 – Avaliação operacional dos classificadores (ilustração). ....	101
Tabela 22 – Análise comparativa entre as técnicas de classificação (a partir dos parâmetros estatísticos das distribuições). ....	104
Tabela 23 - Análise comparativa entre as técnicas de classificação (a partir do uso direto das três últimas distribuições). ....	105
Tabela 24 – Relação das wavelets disponíveis no aplicativo Matlab (2000). ....	143

## Lista dos Símbolos Principais

$b_k$	Coeficientes da série de Fourier.
$c_j$	Classe $j$ de padrões.
$cc$	Fator de correlação cruzada.
$d$	Distância do padrão (representado pelo vetor de atributos $x$ ao hiperplano de separação das classes).
$D_i$	Distância entre uma amostra associada ao vetor $z$ e o vetor médio $\bar{z}_i$ de uma classe $i$ .
$f$	Frequência do sinal.
$f_h(x)$	Função de Heaviside.
$F_i$	Número de Fisher associado ao atributo $i$ .
$g_j$	Função discriminante $j$ .
$h$	Intervalo de Nyquist.
$H(r)$	Entropia de um sinal $r$ .
$H_n(\varphi)$	Número de descargas observadas em cada janela de fase, como uma função do ângulo de fase.
$H_{qn}(\varphi)$	Amplitude média, em cada janela de fase, como uma função do ângulo de fase, pC.
$i$	Corrente de entrada na camada poluída, A. Eventualmente esta letra também é usada em sub índice para representar componentes de um vetor. Tais situações estarão explicitadas no texto.
$\tilde{I}(\omega)$	Periodograma médio.
$J(w)$	Discriminante linear de Fisher.
$K_u$	Curtose (desvio em relação à distância normal).
$L$	Número de classes.
$m_i$	Média das amostras associadas à classe $i$ .
$\tilde{m}_i$	Média das amostras projetadas em uma reta associadas à classe $i$ .
$\hat{m}$	Estimador da média amostral.
$mcc$	Fator de correlação cruzada modificado.
$N$	Período fundamental do sinal original discreto no tempo.
$P_i$	Probabilidade de ocorrência da classe $i$ .
$q$	Dimensão da descarga parcial, pC.
$Q$	Assimetria das descargas.
$r$	Vetor padrão de entrada (sinais adquiridos através de sensores para o caso analisado no documento).
$(r_1, r_2, \dots, r_M)$	Componentes do vetor padrão de entrada.
$r(t)$	Sinal contínuo original.
$r[n]$	Sinal original discreto no tempo.
$R(j\omega)$	Transformada de Fourier de um sinal aperiódico.
$\mathcal{R}_{arc}$	Resistência do arco por unidade de comprimento, $\Omega/cm$ .
$\mathcal{R}_p$	Resistência da camada de poluição, $\Omega$ .
$\mathcal{R}_s$	Resistência interna da fonte de alimentação, $\Omega$ .

$s_i^2$	Variância amostral.
$S$	Matriz de covariância.
$\hat{S}$	Estimativa da matriz de covariância $S$ .
$S_k$	Assimetria em relação à distribuição normal.
$S_w$	Matriz de espalhamento interclasse.
$S_B$	Matriz de espalhamento intraclasse.
$t$	Tempo, s.
$T$	Período fundamental do sinal original contínuo no tempo.
$u$	Vetor atributo transformado por Karhunen-Loève.
$U_i$	Tensão de ignição associada ao ângulo de fase $\varphi_i$ , kV.
$v$	Vetor peso aumentado.
$V_s$	Tensão aplicada a um isolador sob teste, V.
$V_c$	Queda de tensão no catodo, V.
$V_a$	Queda de tensão no anodo, V.
$x$	Vetor de atributos.
$(x_1, x_2, \dots, x_N)$	Componentes do vetor de atributos.
$X$	Matriz de atributos.
$\bar{X}_{ij}$	Média dos atributos $x_i$ na classe $j$ , $j=1, 2$ .
$w_j$	Vetor peso associado à função discriminante $j$ .
$y$	Vetor de atributos aumentado.
$y$	Combinação linear dos componentes do vetor de atributos.
$z$	Vetor de atributos transformado por Karhunen-Loève e reduzido.
$\varphi$	Ângulo de fase.
$\Phi$	Assimetria de fase.
$\Phi_p$	Gradiente de tensão na região poluída do isolador, V/cm.
$\Phi_{arc}$	Gradiente de tensão no arco, V/cm.
$\{\Psi_i\}$	Base ortogonal de Karhunen-Loève.
$\Omega_x$	Espaço de atributos.
$\eta$	Vetor de atributos aumentado, com normalização de sinal.
$\eta$	Função ganho que controla a taxa de adaptação da rede neural.
$\omega_0$	Frequência angular fundamental.
$\Gamma$	Comprimento do arco, cm.
$v$	Velocidade de propagação do arco, cm/s.
$\Delta t$	Intervalo de tempo, s.
$\chi$	Conjunto de amostras.
$\wp$	Conjunto de amostras projetadas em uma reta.
$\sigma_{ij}$	Desvio padrão do atributo $x_i$ na classe $j$ , $j=1,2$ .
$\hat{\sigma}^2$	Estimador da variância amostral.
$\lambda_i$	Raiz característica $i$ (auto valor $i$ ).
$\varepsilon$	Mínimo erro quadrado.

## Resumo

*A contaminação de isoladores utilizados em linhas de transmissão de alta tensão é responsável por grande parte das falhas em um sistema de potência. Por outro lado, as descargas parciais no interior de materiais isolantes podem conduzir, cumulativamente, equipamentos elétricos a danos irreversíveis. Neste sentido, sistemas de aquisição de dados que viabilizem a monitoração de sinais relacionados com o nível de contaminação de isoladores ou com descargas parciais no interior de materiais isolantes podem ajudar na redução de falhas no sistema de potência. Diante das dificuldades de desenvolvimento de modelos analíticos específicos, foram utilizadas técnicas de reconhecimento de padrões para interpretar os sinais adquiridos e classificar o estado do isolamento sob monitoração. A principal ênfase das pesquisas desenvolvidas foi a caracterização dos atributos dos sinais monitorados, de tal forma a se obter um melhor desempenho do processo de reconhecimento. Com este propósito, foram utilizadas técnicas de processamento digital de sinais, transformações de Fourier e Wavelet para dar suporte à caracterização dos atributos. São descritas, ainda, diversas avaliações de sensibilidade quanto ao tipo e ao número de atributos caracterizados, como também são inseridos procedimentos para a escolha da wavelet mãe mais significativa para o reconhecimento dos sinais analisados. O trabalho apresenta dois estudos de caso. No primeiro deles, a metodologia é direcionada no sentido de se diagnosticar o nível de poluição em isoladores aéreos de alta tensão, através de técnicas lineares e não lineares de reconhecimento de padrões, a partir de sinais adquiridos de diversos sensores. Este caso pode ser caracterizado como uma análise de fusão de dados. No segundo, as técnicas de reconhecimento de padrões são utilizadas para o diagnóstico de defeitos presentes em isoladores poliméricos através do processamento de atributos de sinais de descargas parciais.*

## *Abstract*

*Contamination of outdoor insulators employed in the overhead high voltage transmission lines in the polluted geographic regions is one of major causes of electric power system failure. The partial discharges within the body of an insulation material also progressively lead to the irreversible deterioration in the performance of the electrical equipment. Data acquisition systems for automatically monitoring the signals related with insulator contamination levels as well as partial discharges, can help in reducing the electrical system failures. In view of the practical difficulties in the development of specific analytical models for these phenomena, signal pattern recognition techniques have been employed to interpret the acquired signals to classify the state of insulator contamination and predict the potential occurrence of system failure. The main emphasis of the present investigation is the characterization of the attributes of the monitored signal, with a view to obtain improved performance the existing pattern recognition techniques. Digital signal processing techniques like digital Fourier transforms and Wavelet transforms have been employed as an aid to characterize the signal attributes. Various evaluations of the number and types of the characterized signal attributes are described. The procedures are outlined for choosing the most significant mother wavelet to be utilized in the recognition of the pattern of the attributes of the acquired signals. Two case studies are presented. In the first one, a method is developed to predict the level of contamination of the overhead high voltage transmission line insulator strings based on linear and nonlinear pattern recognition of the attributes of the acquired signals. This case can be considered to represent an analysis of data fusion originating from multiple sensors employed for data monitoring. In the second case study, signal pattern recognition techniques are employed to diagnose the defects in polymeric insulators utilizing the attributes of the partial discharge signals.*

# Capítulo 1: Introdução

As falhas em isolamentos elétricos são as principais responsáveis por interrupções no fornecimento de energia elétrica aos diversos consumidores supridos por um sistema de potência. Para o caso específico de linhas de transmissão, por exemplo, conforme afirma Nigri (1999), o desempenho das instalações está diretamente relacionado com o desempenho dos seus isoladores. A introdução de tecnologias confiáveis que possibilite alertar as equipes de manutenção quanto a processo degenerativo de isolamentos representa, portanto, uma ação estratégica importante, tanto para a operação normal do sistema quanto para a sociedade que será poupada do infortúnio da falta intempestiva da energia.

As análises aqui empreendidas procuram introduzir técnicas de diagnóstico que possam ser utilizadas em ações preditivas voltadas para alertar quanto à necessidade de manutenções especiais antes que os equipamentos ou instalações venham a sofrer danos e/ou interrupção de suas condições normais de operação. Nos estudos de caso são dadas ênfases especiais aos isolamentos aéreos de subestações e de linhas de transmissão, como também a isolantes internos de equipamentos elétricos.

No que tange a isolamentos aéreos de sistemas de potência, os mesmos ficam expostos a intempéries características das regiões atravessadas por esses sistemas, em especial a poluição ambiental e industrial presentes. Com a presença da poluição e umidade ocorrem descargas superficiais aos isoladores. Conforme já descrevia o Project EHV (1968) essas descargas estão associadas à formação de “bandas secas”, as quais surgem em consequência da presença não uniforme da umidade ao longo da superfície do isolador. As tensões impostas a essas bandas secas redundam no surgimento de descargas sobre as mesmas, podendo ficar restritas ao local dessas bandas ou se desenvolverem sobre toda a superfície do isolador, resultando em uma descarga total do mesmo.

Nos experimentos realizados durante o Project EHV (1968) ficou evidenciado que, quando uma cadeia contaminada com sal é energizada em estado seco não existe evidência de cintilação. A corrente de fuga é tão pequena que praticamente toda corrente do isolador permanece capacitiva. Nesta ocasião o isolador possui a maior parte de sua suportabilidade como se estivesse limpo e seco. Com o surgimento da neblina, se forma um filme de umidade na superfície contaminada, ocorrendo, por conseguinte, um aumento gradual na amplitude da corrente de fuga. A fase da corrente de fuga muda para um tipo mais resistivo. Como o contaminante começa a conduzir levemente, centelhas de corona aparecem nas superfícies isolantes, como mostra a Figura 1-(a). Essas centelhas se formam no contorno da porcelana e do cimento do pino. Algumas vezes essas centelhas também se formam na saia interna do isolador e na cavidade entre a campânula e a porcelana.

Essas centelhas formam uma faixa azul circular, pouco intensa, com algumas faixas mais brilhantes interpassadas. Possuem um pequeno comprimento (0,64 a 1,27 cm), ocorrem próximo ao dielétrico e persistem continuamente. Uma corrente em torno de 1mA flui neste estágio. Se o contaminante for o sal, essas descargas necessitam energia térmica suficiente para excitar os íons de sódio e criar uma centelha amarela característica do componente sódio. As faixas de corona próximas à campânula freqüentemente desaparecem após um período curto quando a umidade se constitui na cavidade entre a campânula e a porcelana. Debaxo de cada unidade, uma das duas faixas de corona pode também definhir com uma umidade severa em progresso.

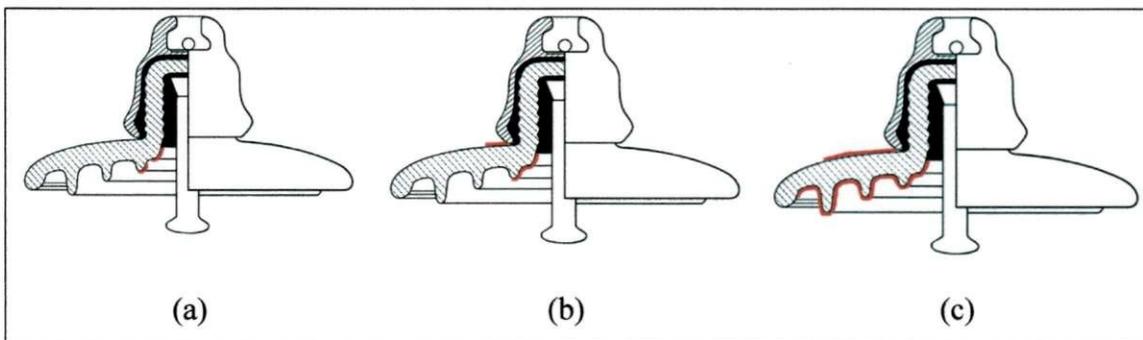


Figura 1 – Desenvolvimento das descargas em uma unidade de isolador contaminado durante o ciclo de umedecimento: (a) descargas corona; (b) descargas pré-cintilação e (c) descargas de cintilação.

Com a neblina contínua, dentro de um minuto ou mais, um tipo de descarga um pouco mais intensa aparece por debaixo da unidade de isolador como mostrado na Figura 1 (b). Essas descargas têm uma característica mais amarelada, a partir da parte central do cimento próxima a porcelana e sobre a menor saia. Ambos terminais do arco têm forma de escova, o que indica que eles absorvem as cargas superficiais das áreas próximas aos terminais. Desde que se trata de uma descarga capacitiva, o pulso máximo de corrente é limitado a 1-10nA e o tempo de faíscação é em microssegundos. Essas descargas podem disparar descargas similares no topo um pouco mais fortes que se iniciam sempre na campânula.

Posteriormente, a primeira descarga de cintilação real começa quando o depósito de umidade se intensifica (Figura 1-C). Ela deixa o pino e, no começo, termina na parte de dentro da saia interna. Essas descargas, usualmente, se mantêm por muitos ciclos. Se a contaminação e a tensão forem bastante adversas, as descargas se estenderão posteriormente sobre a saia interna e algumas vezes atingirão a saia central e externa. Essas descargas também disparam descargas solidárias da campânula. As amplitudes das correntes são da ordem de 10-1.000 mA. Quando os picos das amplitudes alcançam mais de 300 mA, o isolador será provavelmente submetido ao “flashover”. Todas essas constatações, descritas no Project EHV (1968), apesar de antigas, retratam com fidelidade as manifestações elétricas do isolamento submetido a poluição e umidade.

No que tange aos efeitos indesejáveis da presença da poluição em um sistema de transmissão, sintetizamos adiante as experiências da Flórida Power & Light, registradas por Richards e Renowden (1997): “após longo período seco, poucos dias com ventos fortes, virtualmente nenhuma cintilação acontece. existe um falso sentimento de tranquilidade; surge uma noite de tempo calmo, tarde da noite ou durante a madrugada, ocorrem múltiplas falhas por poluição”; os autores registraram a ocorrência de 198 eventos, no período de 20 a 29/12/91, 114 deles no dia de Natal, quando seriam esperadas apenas 17 ocorrências de causas diversas, durante este período; ressaltaram, ainda, que essas anomalias têm ocorrido a intervalos que variam entre três e sete anos, o que deve estar associado às características climatológicas da região, principalmente incidência de contaminantes, pluviometria e umidade.

Situações similares podem ser, também, observadas no Brasil, conforme dados da CHESF (2003) sintetizados na Figura 2, Tabela 1 e Figura 3.

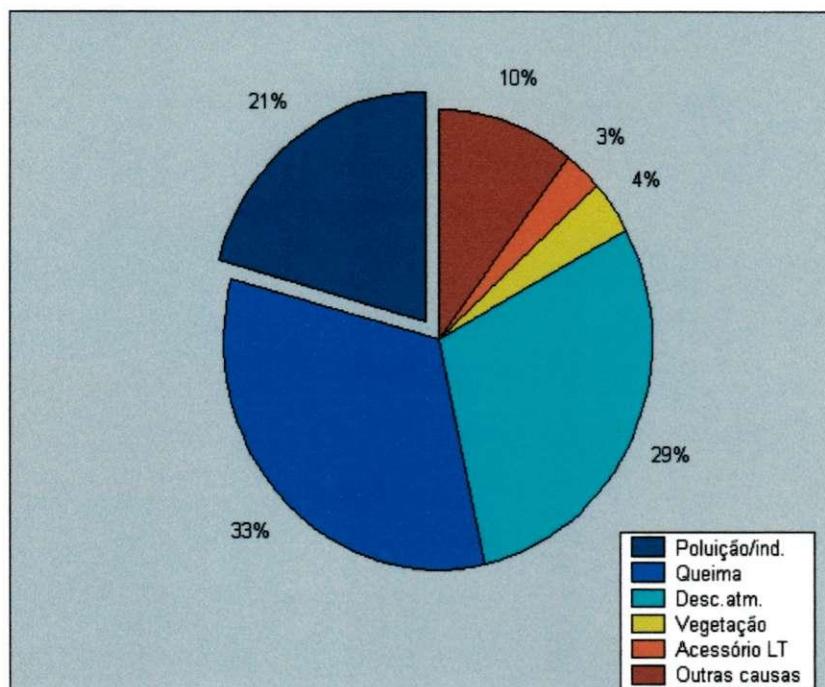


Figura 2 – Estatística de falhas transitórias<sup>1</sup> no sistema CHESF (período 1987 – 2002).  
Fonte: CHESF (2003).

Tabela 1 – Detalhamento da legenda do diagrama de estatística de falhas.

Identificação	Detalhamento
Poluição/ind	Poluição ambiental, marítima ou industrial da região.
Queima	Queima de canavial ou outra vegetação.
Desc. Atm.	Descarga atmosférica que incidiu sobre ou próximo da linha.
Vegetação	Vegetação que tocou o condutor.
Acessório LT	Acessório da linha de transmissão que se desprende e, em sua queda, tocou o condutor.
Outras causas	Evento não enquadrado nas categorias anteriores.

Observa-se, na Figura 3, que o sistema CHESF passa por um período de calmaria, semelhante às observações feitas por Richards e Renowden (1997), entretanto existem regiões que potencialmente estão sujeitas a falhas recorrentes, semelhantes às descritas anteriormente, conforme ilustrações contidas na Figura 4 a qual ilustra que o problema requer atenção continuada da empresa.<sup>2</sup>

<sup>1</sup> As falhas transitórias se caracterizam por não requererem a ação de equipes de manutenção para restabelecer as condições normais de operação da linha de transmissão, ou seja, representam falhas autorregenerativas.

<sup>2</sup> Diversas colocações foram feitas por Furtado et al. (2000), Régis et al (2001) e Bezerra et al. (2000 a, b e 2002), quando da contextualização da interação entre um sistema de transmissão de energia elétrica, o meio ambiente e os reflexos empresariais.

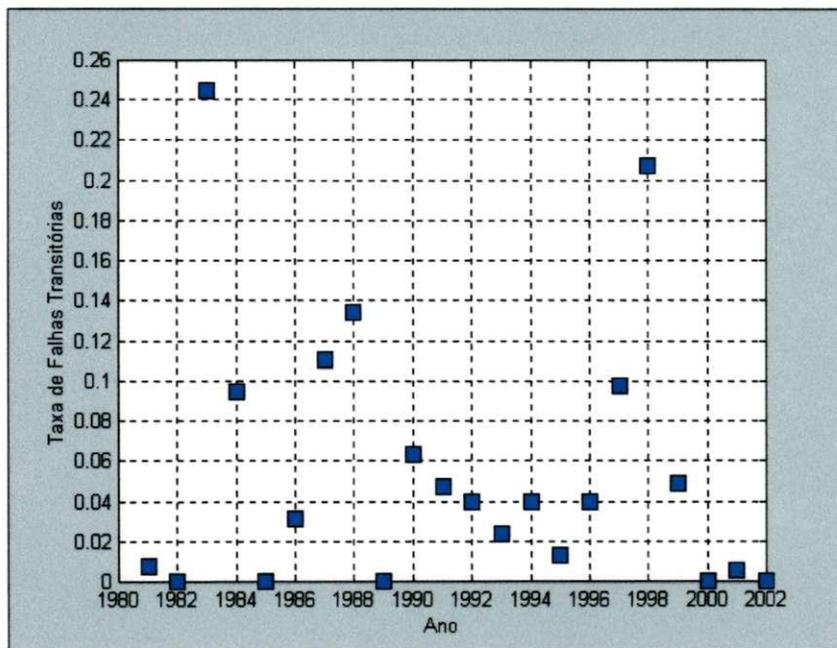


Figura 3 - Taxa de falhas transitórias no sistema CHESF, por poluição.

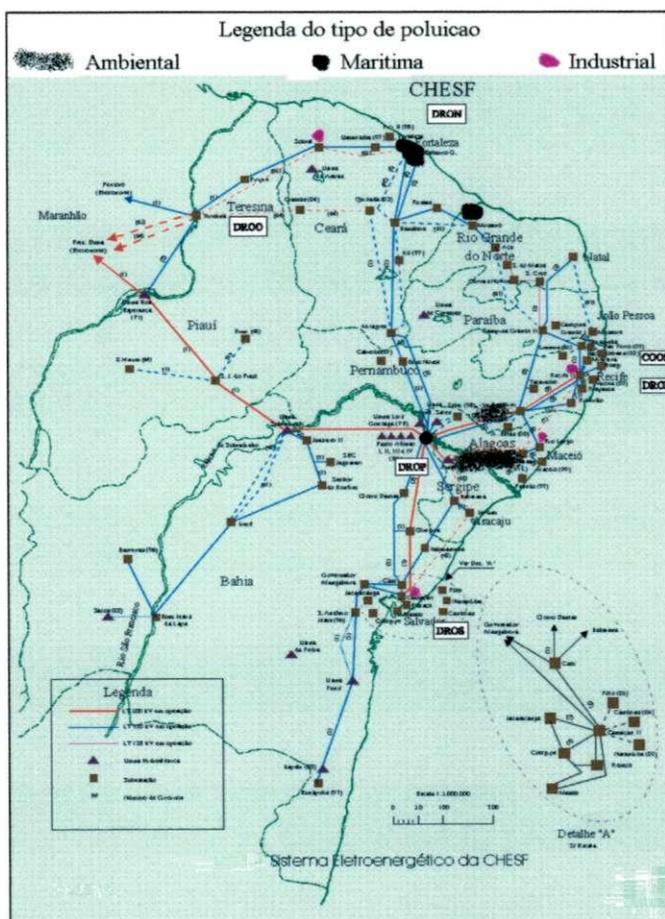


Figura 4 – Regiões mais críticas de poluição no sistema CHESF.

Por outro lado, em se tratando de equipamentos elétricos a preocupação reside na degradação de isolantes internos aos mesmos. Os sinais a serem monitorados estão associados a descargas parciais nos materiais utilizados. Conforme descrevem Satish e Gururaj (1993) este tipo de descarga ocorre quando o campo elétrico local excede o valor limite, resultando em uma ruptura do meio isolante circunvizinho. O efeito cumulativo das descargas leva a uma degradação cumulativa do isolamento. Segundo Kreuger (1989), descargas parciais são descargas elétricas que não contornam completamente o dielétrico, curto-circuitando os eletrodos. Em equipamentos elétricos, as descargas parciais são iniciadas devido à presença de defeitos na fabricação ou imposição de elevados estresses advindos de concepções inadequadas de projeto. Esses problemas são agravados quando da presença de contaminação e/ou objetos estranhos ao dielétrico.

Existem quatro tipos de descargas parciais: descargas internas, descargas superficiais, descargas corona e descargas em ramificação (que podem ser consideradas internas de origem específica). As descargas corona no ar não são perigosas, apesar de que o ozônio e nitritos formados a partir dessas descargas são capazes de prejudicar o isolamento, no longo prazo. As descargas superficiais são menos perigosas do que as internas porque são menos concentradas. As descargas internas são, em muitos casos cruciais para a vida útil do isolamento, uma vez que a ocorrência das mesmas deflagra um processo degenerativo irreversível, associado ao surgimento de gases e partículas que ficam confinados no dielétrico e, cumulativamente deterioram o mesmo, conduzindo a falha permanente do equipamento.

As dificuldades nas medições de descargas parciais estão associadas às interferências externas (usualmente de amplitude maior do que os sinais de descargas parciais propriamente ditos). Segundo Statish e Nazeneen (2003) essas interferências estão associadas a: sinais de rádio, pulsos oriundos de componentes de eletrônica de potência, descargas atmosféricas, arcos entre contatos metálicos, corona oriundo de sistemas de potência, arcos entre contatos móveis de máquinas rotativas, etc. Na filtragem dos ruídos os autores propõem a aplicação de transformadas Wavelet, as quais têm se mostrado muito efetivas.

A análise dos dados colhidos através de sensores utilizados para diagnosticar o estado de isolantes é uma tarefa que requer o suporte de ferramentas matemáticas e

computacionais, uma vez que os dados a serem analisados se constituem de sinais, os quais possuem padrões específicos que requerem o tratamento através de técnicas tradicionalmente aceitas e que agilize/automatize o diagnóstico diante da necessidade moderna de monitorações seguras em tempo real. Segundo descreve Danikas et al. (2003), as primeiras tentativas para avaliar tais processos de forma estruturada se concentraram, vários anos atrás, no desenvolvimento de sistemas especialistas. A identificação manual e codificação das regras necessárias para construir esses sistemas eram muito difíceis e exaustivas, diante, inclusive, das características determinísticas dessas regras. Além disso, como se detalha adiante, os sinais em foco têm um comportamento aleatório o que torna a questão ainda mais complexa. Segundo os mesmos autores, essas dificuldades têm conduzido a tratar o problema através de técnicas de reconhecimento de padrões. O uso dessas técnicas se constitui de uma ferramenta largamente utilizada com sucesso em diversos ramos da engenharia, paleontologia, química, etc. com propósitos similares. A utilização dessas técnicas para reconhecimento de descargas parciais foi proposta, entre outros, por Satish e Gururaj (1993) e Danikas et al (2003).

Um sistema de reconhecimento de padrões pode ser representado, simplificada, em diagrama de blocos, conforme ilustra a Figura 5, na qual o padrão de entrada (sinais adquiridos através dos sensores, para o caso analisado neste documento) constitui o vetor  $r$  ( $r_1, r_2, \dots, r_M$ ), o qual é submetido à rotina de extração de atributos. Os atributos extraídos através da rotina possibilitam a formação do vetor  $x$  ( $x_1, x_2, \dots, x_N$ ) denominado “vetor de atributos”, o qual é submetido ao classificador que propiciará a tomada de decisão necessária ao processo (diagnóstico do estado do isolamento para o caso em foco).

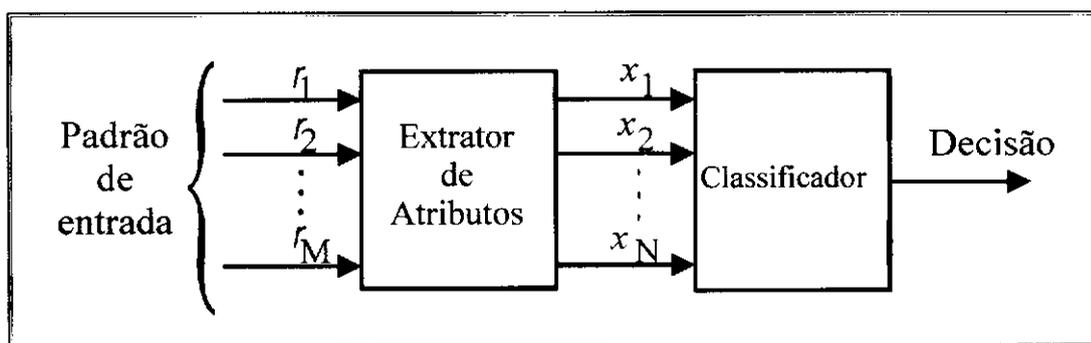


Figura 5 – Um sistema de reconhecimento de padrões.

Os atributos são aferições feitas sobre o padrão obtido, com o intuito de levantar características intrínsecas que viabilize a classificação dos padrões originais. Conforme descreve Schalkoff (1992), de uma forma mais ampla, atributos são todas as medições extraídas do padrão analisado, os quais podem ser simbólicos, numéricos ou ambos. Um exemplo de atributo simbólico é a cor e o de um numérico é o peso. As regras básicas estabelecidas pelo autor para a escolha dos atributos são:

- que sejam computacionalmente práticos;
- conduzam a bons resultados no processo de reconhecimento de padrões;
- reduza o processamento a uma quantidade tratável de dados sem descartar informações que ainda incorporem valor.

O processo de seleção de atributos envolve de certa forma um julgamento. Em alguns casos existem ferramentas matemáticas que ajudam a seleção. Em outros casos são tradicionalmente feitas simulações para identificar a contribuição final de cada atributo analisado.

A construção do sistema de reconhecimento ilustrado na Figura 5 requer, portanto, toda uma análise prévia no sentido de dotá-lo de condições necessárias a minimizar erros de decisão. Uma das etapas fundamentais está associada à caracterização dos atributos que compõem o vetor  $x$ . A contribuição central deste trabalho é fortalecer a citada etapa. A preocupação está voltada para, não apenas focar matematicamente a escolha/seleção dos atributos, mas, também assegurar que esta etapa privilegie atributos sem eliminar outros de significância físico-matemática essencial ao evento analisado. O trabalho descreve pesquisas de técnicas específicas que conduzem a minimizar esforços na escolha e seleção de atributos associados ao reconhecimento de padrões em sinais relacionados com a monitoração do estado de isolamentos. De uma forma geral, esses sinais têm características específicas a depender do tipo de isolamento utilizado e do tipo de defeito presente.

No desenvolvimento do trabalho é feita, inicialmente, uma revisão bibliográfica procurando explicitar os diversos enfoques utilizados na caracterização dos sinais acima mencionados. Posteriormente é introduzida a metodologia utilizada, quando são descritos os conceitos básicos de reconhecimento de padrões, as técnicas lineares e não

---

lineares de reconhecimento de padrões, as técnicas de extração de atributos no domínio do tempo, no domínio da frequência e através da transformada wavelet; são feitos, ainda, dois estudos de caso, sendo o primeiro deles associado ao diagnóstico de poluição em isoladores aéreos de alta tensão, e o segundo relacionado com a detecção de defeitos em isoladores poliméricos. A etapa seguinte faz uma análise e discussão dos resultados obtidos para cada um dos estudos de caso. O trabalho é finalizado com o encaminhamento das conclusões e proposta de refinamentos para pesquisas similares posteriores.

## Capítulo 2: Revisão Bibliográfica

O isolamento elétrico se constitui em um componente muito crítico em sistema de potência em alta tensão. Apesar dos avanços nas áreas de manufatura, processamento, otimização de projetos e controle de qualidade, os isoladores continuam a falhar quando em operação. Tal constatação foi ressaltada por Satish e Nazneen (2003), os quais registraram que a principal causa de falhas em sistemas de transmissão de energia elétrica se concentra em seus isoladores. Como decorrência as empresas de energia elétrica vêm dando atenção especial à pesquisa e desenvolvimento de técnicas que monitorem o estado de tais componentes. As pesquisas relatadas neste documento estão, portanto, em consonância com as preocupações emanadas pelas empresas de energia elétrica no sentido de tornar os seus sistemas de transmissão de energia mais confiáveis.

Diversos pesquisadores têm procurado analisar sinais oriundos de sensores direcionados para monitorar defeitos incipientes em isolamentos elétricos. Nessas pesquisas se procura avaliar os sinais adquiridos através de atributos. Nem sempre essas análises estão voltadas diretamente para a aplicação de técnicas formais de reconhecimento de padrões, mas o intuito é sempre de tirar conclusões sobre o comportamento dos fenômenos analisados e de certa forma classificá-los.

A revisão bibliográfica, apresentada a seguir, procura enfocar algumas pesquisas empreendidas na análise de padrões de sinais associados a descargas corona em equipamentos elétricos, destacando os diversos atributos utilizados. Os grupos de atributos enfocados a seguir já estão associados à origem física das descargas corona que se deseja classificar, ou seja: descargas superficiais a isoladores aéreos, utilizados rotineiramente em linhas de transmissão ou barramentos de subestações e descargas internas a isolamentos utilizados em equipamentos elétricos de subestações de alta

tensão. Esse agrupamento se justifica, tendo em vista a especificidade das técnicas de monitoramento utilizadas em cada um dos casos.

## **2.1 Descargas em Isoladores Aéreos**

Em pesquisas desenvolvidas por Fernando e Gubanski (1996), foram identificadas diferentes formas de onda de corrente de fuga em isoladores de porcelana, com revestimento especial, e poliméricos. As formas de onda resultantes foram gravadas após tempos diferentes de aplicação da poluição. São feitas análises dos resultados através da implementação de redes neurais em que o terceiro harmônico é citado como atributo mais significativo. Em pesquisa complementar feita pelos mesmos autores, em 1997, a rede neural citada anteriormente passou a ser treinada para inferir o terceiro e quinto harmônicos. Os autores procuraram introduzir as técnicas de redes neurais como uma alternativa a análises espectrais da corrente de fuga. Apesar das precisões apontadas, as técnicas tradicionais de Transformada de Fourier, para efeito de implementação de técnicas de reconhecimento de padrões, caracterizam-se como mais adequadas na formação de conjuntos de atributos extraídos diretamente dos sinais. Ou seja, o uso de redes neurais levaria a inferir tais espectros, os quais podem ser adquiridos diretamente.

Em outro artigo, Stewart et al. (1999) se concentraram em uma investigação das atividades de descargas parciais através do uso de antena para captar o espectro eletromagnético associado a essas descargas. Todo o contexto está baseado na premissa de que se o espectro eletromagnético das descargas parciais puder prover dados suficientes para caracterizar as possíveis atividades, então ele pode ser correlacionado com degradações em curso e promover meios para monitorar as condições de estruturas isolantes expostas ao tempo. As medições feitas na faixa de frequência de rádio identificaram atividades mais intensas em faixas superiores a 25 MHz, registrada pelos autores como limite (estabelecido em bibliografias anteriores), inferindo que as investigações fossem realizadas em uma faixa mais ampla (de 0 a 60 MHz). Apesar de tais técnicas se mostrarem alvissareiras, os resultados apresentados pelos autores podem ser considerados ainda embrionários.

As pesquisas implementadas por Bologna et al. (1999) enfocaram a corrente de fuga em cadeias de isoladores de disco submetidas à umidade e poluição leves, procurando identificar as condições que poderiam influir no mecanismo de descarga responsável por um número significativo de falhas no sistema de transmissão de energia elétrica nas classes de tensão de 220, 275 e 400 kV. Nessas análises foram utilizados os seguintes atributos associados às correntes de fuga: valor de pico negativo e positivo (os maiores valores em um intervalo de 10 minutos), valores médios (positivos e negativos), forma de onda dos valores de pico e o valor eficaz. Os atributos descritos pelos autores e associados a valores máximos, como será visto adiante, perdem o significado estatístico e devem ser descartados diante das características aleatórias do fenômeno analisado.

Por outro lado, Vazquez e Chavez (1999) analisaram a corrente de fuga para determinar os períodos para manutenção preventiva baseado no nível máximo da corrente de fuga que um isolador pode suportar até que ocorra a descarga. Mais uma vez, as características aleatórias do fenômeno devem ser consideradas para se evitar a utilização de tais tipos de atributo.

Em pesquisas desenvolvidas por Salam et al. (2001), os autores definiram pontos fracos em sistemas de transmissão (poluição em isoladores, micro-rugosidade em condutores e ferragens de isoladores) e passaram a registrar sinais acústicos gerados de cada um dos pontos, procurando fazer comparações entre as suas formas. Utilizaram análises espectrais do nível de pressão do som e os seguintes parâmetros estatísticos: valor médio, valor pico a pico e valor eficaz. Diante da praticidade e da correlação existente, as análises enfocadas pelos autores poderiam ser feitas diretamente dos sinais de tensão obtidos do sensor de ultra-som sem a necessidade de se calcular os níveis de pressão do som.

## **2.2 Descargas em Isolantes Internos**

Em isolamentos internos a equipamentos elétricos, Gulski e Kreuger (1992) procuram introduzir técnicas para aferição de descargas parciais registradas nesses componentes. Em análises quantitativas realizadas, os autores propuseram o seguinte agrupamento, em relação ao período de observação:

- grandezas básicas: observadas durante um ciclo de tensão;
- grandezas calculadas: valores integrados a partir das grandezas básicas observadas através de diversos ciclos de tensão;
- operadores estatísticos: parâmetros estatísticos extraídos das grandezas calculadas.

Na opinião dos autores, cada grandeza pode fornecer apenas informações parciais, conduzindo a que sejam observadas diversas grandezas para melhor caracterizar as descargas sob análise. São detalhadas, a seguir, as formas de obtenção das grandezas definidas anteriormente.

- **Grandezas Básicas**

Para registro das grandezas básicas, os valores momentâneos da tensão de ensaio e o sinal de descarga são registrados. Na Figura 6 são ilustradas as grandezas básicas a serem obtidas a partir do registro dos sinais. Pode ser verificado que, para os métodos de detecção usuais, a atividade elétrica da descarga parcial é representada apenas por três grandezas básicas independentes: a dimensão da descarga  $q_i$ , a tensão de ignição  $U_i$  e a posição da descarga relacionada com o ângulo de fase  $\varphi_i$  da tensão de ensaio. Se, durante um ciclo da tensão de ensaio, mais descargas ocorrem, diversas grandezas básicas ( $q_i$ ,  $U_i$  e  $\varphi_i$ ) podem ser obtidas.  $N_{q+}$  e  $N_{q-}$  representam o número de descargas registradas nos semiciclos positivo e negativo da tensão de ensaio, respectivamente.

- **Grandezas Calculadas**

Para o registro das grandezas calculadas, as grandezas básicas precisam ser observadas durante um intervalo de tempo maior do que um ciclo da tensão de ensaio (por exemplo, maior do que 100 ciclos). As grandezas precisam ser analisadas em função do tempo e do ângulo de fase. Os registros permitem avaliar as variações das grandezas básicas ao longo do tempo, tanto em amplitude quanto em localização de fase.

As grandezas como função do ângulo de fase representam a recorrência da descarga parcial relacionada ao ângulo de fase. Desta forma o ciclo da tensão de ensaio foi dividido em “janelas de fase” ao longo do eixo dos ângulos de fase (0 a 360°). Se as

observações forem feitas sobre vários ciclos de tensão, as seguintes grandezas podem ser calculadas:  $H_n(\varphi)$  - representa o número de descargas observadas em cada janela de fase, como uma função do ângulo de fase e  $H_{qn}(\varphi)$  - representa a amplitude média em cada janela de fase, como uma função do ângulo de fase.  $H_{qn}(\varphi)$  é calculada a partir do número total de descarga em cada janela de fase, dividida pelo número de descargas na mesma janela. Essas grandezas são calculadas, abrangendo todo o ciclo positivo e negativo, obtendo-se:  $H_n^+(\varphi)$ ,  $H_n^-(\varphi)$ ,  $H_{qn}^+(\varphi)$  e  $H_{qn}^-(\varphi)$ .

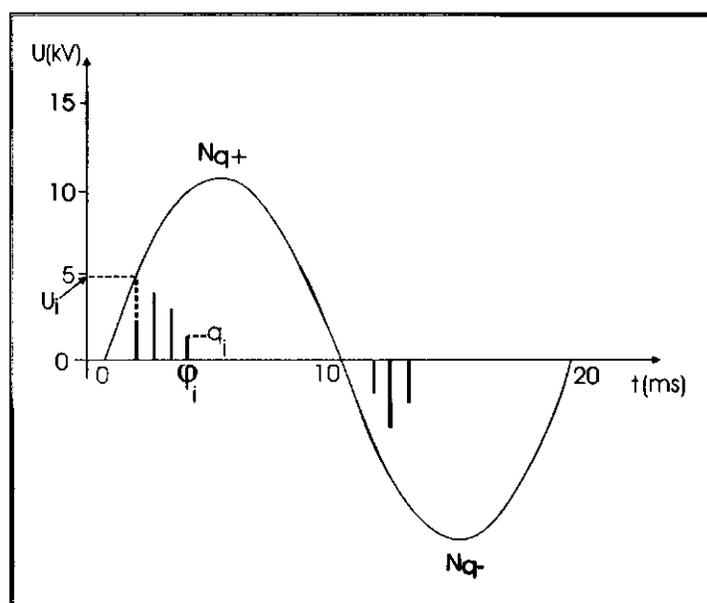


Figura 6 – Ilustração das grandezas básicas de descarga. Fonte: Gulski e Kreuger (1992).

- Operadores Estatísticos

Para analisar as diferenças das descargas nos meios ciclos da tensão de ensaio, os seguintes operadores estatísticos foram introduzidos:

- Assimetria das Descargas

A assimetria das descargas  $Q$  é o cociente do nível médio das descargas obtido a partir de  $H_{qn}^+(\varphi)$  e  $H_{qn}^-(\varphi)$ :

$$Q = \frac{Q_S^- / N^-}{Q_S^+ / N^+}, \quad (1)$$

sendo  $Q_S^+$  e  $Q_S^-$  a soma das descargas de  $H_{qn}^+(\varphi)$  e  $H_{qn}^-(\varphi)$ , respectivamente;  $N^+$  e  $N^-$  são os números de descargas obtidos a partir de  $H_n^+(\varphi)$  e  $H_n^-(\varphi)$ , respectivamente.

o Assimetria de Fase

A assimetria de fase  $\Phi$  é usada para estudar a diferença da tensão de início de descarga da distribuição  $H_{qn}(\varphi)$  no ciclo positivo e negativo:

$$\Phi = \frac{\varphi_{in}^-}{\varphi_{in}^+}, \quad (2)$$

sendo  $\varphi_{in}^+$  e  $\varphi_{in}^-$  as fases de início de descarga nos ciclos positivo e negativo.

o Fator de Correlação Cruzada

O fator de correlação cruzada (fcc) é usado para avaliar a diferença no formato das distribuições  $H_{qn}^+(\varphi)$  e  $H_{qn}^-(\varphi)$ . A seguinte equação é utilizada para calcular este fator:

$$fcc = \frac{\sum pq - \sum p \sum q / n1n2}{\left\{ \left[ \sum p^2 - \frac{(\sum p)^2}{n1} \right] \cdot \left[ \sum q^2 - \frac{(\sum q)^2}{n2} \right] \right\}^{1/2}}, \quad (3)$$

na qual  $p$  é a amplitude média de descarga em uma janela de fase no meio ciclo de tensão positivo;  $q$  é a amplitude média de descarga no meio ciclo de tensão negativo;  $n1$  e  $n2$  o número de posições de fase para cada meio ciclo positivo e negativo, respectivamente.

o Fator de Correlação Cruzada Modificado (mcc)

O fator (mcc) é usado para avaliar as diferenças entre a forma da descarga nos meios ciclos positivo e negativo:

$$mcc = \Phi Q fcc, \quad (4)$$

- o Assimetria em Relação à Distribuição Normal

$$S_k = \frac{\sum (x_i - \mu)^3 P_i}{\sigma^3}; \quad (5)$$

- o Curtose (grau de achatamento em relação à distribuição normal)

$$K_u = \frac{\sum (x_i - \mu)^4 P_i}{\sigma^4} - 3; \quad (6)$$

sendo  $x_i$  o valor discreto de  $x$ ,  $P_i$  a probabilidade de  $x_i$ ,  $\mu$  o valor médio da distribuição e  $\sigma$  o desvio padrão da distribuição.

Toda essa análise quantitativa introduzida por Gulski e Kreuger (1992) retrata uma preocupação de se buscar formas de classificar as descargas parciais registradas, diante de defeitos simulados para cada amostra. Apesar de as técnicas de reconhecimento de padrões não terem sido introduzidas nas análises realizadas pelos autores, a contribuição feita enseja a complementação das análises apresentadas através da introdução de tais técnicas, diante dos resultados gráficos obtidos.

Em outra pesquisa, Hoof e Patsch (1996) introduziram uma nova forma de obtenção de atributos de descargas parciais baseada em apenas um único parâmetro: a diferença de tensão entre pulsos consecutivos. Os autores afirmam que a distribuição local das cargas no espaço ou na superfície, e, por conseguinte, a influência de sua modificação, depende significativamente da geometria do espaçamento (“gap”) como também dos parâmetros físicos locais do material isolante. Como consequência, inferem que a diferença de tensão entre os pulsos de descarga consecutivos é sensível ao tipo do defeito no isolamento que causa o sinal de descarga parcial. A aplicação das diferenças conduz à obtenção de um subdomínio, no qual se procura identificar padrões para serem submetidos a um processo de reconhecimento. Este novo subdomínio se caracteriza por um espaço bidimensional representado por duas coordenadas ( $\Delta u_n \times \Delta u_{n-1}$ ) as quais estão associadas às diferenças entre os pulsos de tensão consecutivos, como já

---

mencionado. O modelo proposto pelos autores, diante da simplicidade de caracterização dos atributos de descargas parciais, requer análises complementares para se avaliar os seus resultados em comparação com outros modelos, a exemplo do de Gulski e Kreuger (1992), o qual se mostra mais elaborado.

Em pesquisas direcionadas para avaliar o processo inicial de envelhecimento de isoladores poliméricos, Lopes (2001) utilizou atributos associados aos valores máximos e médios das descargas parciais registradas. Uma observação importante citada pelo autor é que as análises de descargas parciais nas situações enfocadas nas pesquisas se mostraram bem mais efetivas do que as análises centradas unicamente na corrente de fuga. Essa constatação corrobora a necessidade de se avaliar a utilização de mais de um sensor na construção de processos de reconhecimento que requeiram maior precisão nos resultados finais. A utilização de múltiplos sensores na análise de fenômenos conduz a técnicas de fusão de dados descritas por Buxton et al. (2001) e Kleine-Ostmann e Bell (2001).

Portanto, como será visto adiante, as pesquisas empreendidas procuraram caracterizar atributos associados aos sinais monitorados de tal forma a embasar as técnicas de reconhecimento de padrões analisadas e conduzi-las a melhores resultados quanto ao diagnóstico do estado do isolamento.

## Capítulo 3: Metodologia

**A**s metodologias descritas ao longo deste capítulo procuram embasar a aplicação de técnicas de reconhecimento de padrões a sinais adquiridos a partir de sensores direcionados para monitorar o estado de isolamentos elétricos.

Conforme descrevem Jain et al. (1995), um sistema de reconhecimento de padrões pode ser visto como uma regra de decisão automática, a qual associa medições de um padrão a classes específicas. Um padrão é representado em termos de  $N$  atributos ou propriedades e é visto como um ponto em um espaço  $N$ -dimensional. O que se deseja é caracterizar esses atributos de tal forma que os vetores padrões pertencentes a diferentes classes venham a ocupar diferentes regiões no espaço de atributos. Ao serem fornecidas determinadas amostras de cada classe de padrão, pretende-se estabelecer fronteiras de decisão, no espaço de atributos, para separar os padrões que pertencem a classes distintas.

A caracterização dos atributos é crucial para o desempenho do sistema de reconhecimento. A caracterização dos atributos apropriados requer interação com profissionais que sejam especialistas na área de aplicação. Em vários problemas que envolvam padrões complexos, o número de atributos necessários para estabelecer uma fronteira de decisão razoável é muito grande.

Assim, neste capítulo da proposta de tese é apresentada a metodologia utilizada para diagnóstico de isolamento de instalações e equipamentos elétricos a partir de sinais adquiridos. Inicialmente são feitas considerações sobre as técnicas de reconhecimento de padrões (lineares e não lineares) utilizadas, posteriormente são abordadas as ferramentas matemáticas aplicadas para processamento dos sinais no domínio do tempo, no domínio da frequência e a partir da transformada wavelet. Em seguida são apresentadas as montagens elétricas empreendidas para implementação dos estudos de

caso enfocados. Alguns detalhes adicionais das metodologias de reconhecimento de padrões e processamento digital de sinais utilizados para dar suporte a caracterização e extração dos atributos encontram-se apresentados em Anexo.

### **3.1 Conceitos Preliminares de Reconhecimento de Padrões**

A partir das definições feitas por Sklansky e Wassel (1981), a classificação de padrões é um processo de informação e transformação. Isto é, um classificador transforma um conjunto relativamente grande de dados nebulosos em um pequeno conjunto de dados úteis. Não é surpresa, portanto, que máquinas, assim como seres vivos, possuam a capacidade de detectar e classificar padrões. Exemplos de tais máquinas que foram construídas e usadas efetivamente são: classificador de células do sangue, analisador de cromossomos, analisador de fotografias aéreas, analisador de vozes, leitor de zona postal, analisador de impressões digitais e analisador de radiografia. Cada vez mais estão sendo pesquisadas e introduzidas novas aplicações face à agilidade/automação de tarefas que muitas vezes não podem ser desenvolvidas pelo ser humano a exemplo de atividades em meios insalubres, como já citado, e/ou monitorações em tempo real com a necessidade de respostas imediatas, fruto de processamentos exaustivos.

Como definido, um classificador é um dispositivo que agrupa dados em categorias. Os dados são freqüentemente estruturados em vetores no *espaço de atributos*. Todo ponto neste espaço é chamado de *vetor de atributos*. Cada componente  $x_i$  do vetor  $x$  é usualmente uma característica ou propriedade de um objeto sob análise.

Ainda segundo Sklansky e Wassel (1981), o vetor de atributos em uma dada classe ocupa uma região no espaço de atributos chamada região de classe. É freqüentemente considerado que toda região de classe é demarcada. Uma outra consideração é que as regiões de classe não se sobrepõem (entretanto em muitos casos práticos, existem algumas sobreposições). Quando as regiões de classe não se sobrepõem, as classes são ditas *separáveis*. Se, para toda região de classe, um hiperplano pode ser colocado de tal forma que separe uma região de todas as outras regiões de classe, as classes são ditas *linearmente separáveis*. Muitos dos trabalhos recentes que utilizam a teoria de

classificação de padrões se concentram em classes linearmente separáveis. Ao mesmo tempo, um número significativo de trabalhos tem focado classes *não separáveis* e classes que não são linearmente separáveis.

O classificador relaciona todo vetor de atributos com uma *região de decisão* particular  $R_j$  no espaço de atributos  $\Omega_x$  através de um conjunto de *hiper-superfícies de decisão*. Cada um de tais relacionamentos pode ou não corresponder a uma correta ou desejável classificação. Um classificador treinável é um classificador que conduz a um número pequeno de classificações incorretas através do ajuste do conjunto de regiões de decisão  $\{R_j\}$  em resposta a observações em uma seqüência de vetores de atributos  $\{x_i\}$ . Essa seqüência de observações ocorre durante uma fase de aprendizado ou treinamento. Na Figura 7 são ilustradas tais regiões, na qual podem ser observadas as hiper-superfícies (linhas no espaço de atributos  $\Omega_x$ , bi-dimensional) que representam fronteiras entre as regiões de decisão. Na ilustração apresentada não foram consideradas possíveis sobre-posições entre essas regiões.

Por outro lado, durante a montagem dos vetores de atributos, as observações devem incluir informações que conduzam a classificar corretamente os vetores de atributos. Se as observações incluem dados para uma correta classificação, o treinamento é dito *supervisionado* ou *com um professor*. Esses dados para classificação correta são algumas vezes referenciados como reforços. Se nenhum reforço é incluído, o treinamento é chamado *sem supervisão* ou *sem professor*.

O procedimento ou algoritmo através do qual os membros do conjunto de regiões de decisão  $\{R_j\}$  são ajustados em resposta aos vetores de atributos observados é chamado *procedimento de treinamento*. Cada ajuste do conjunto de regiões de decisão  $\{R_j\}$  ocorre em resposta a um ou mais vetores de atributos. Cada um de tais ajustes, juntamente com as observações associadas e reforços é chamado *experimento*. O número de experimentos é um indicador da extensão do treinamento.

Depois que o classificador é treinado, ele é usualmente submetido a dados de entrada de classificação desconhecida. Este modo de operação do classificador é referenciado como *fase de trabalho* aqui também denominada de *etapa de validação* e *fase operacional*, enquanto que o modo durante o qual ocorre o treinamento é conhecido como *fase de treinamento*. O conjunto de vetores de atributos ou observações utilizado

como entrada durante a fase de treinamento é referenciado como *conjunto de treinamento*. Em alguns casos a fase de treinamento e a fase de trabalho podem coincidir ou se sobreporem. Esse é usualmente o caso no qual o treinamento é não supervisionado.

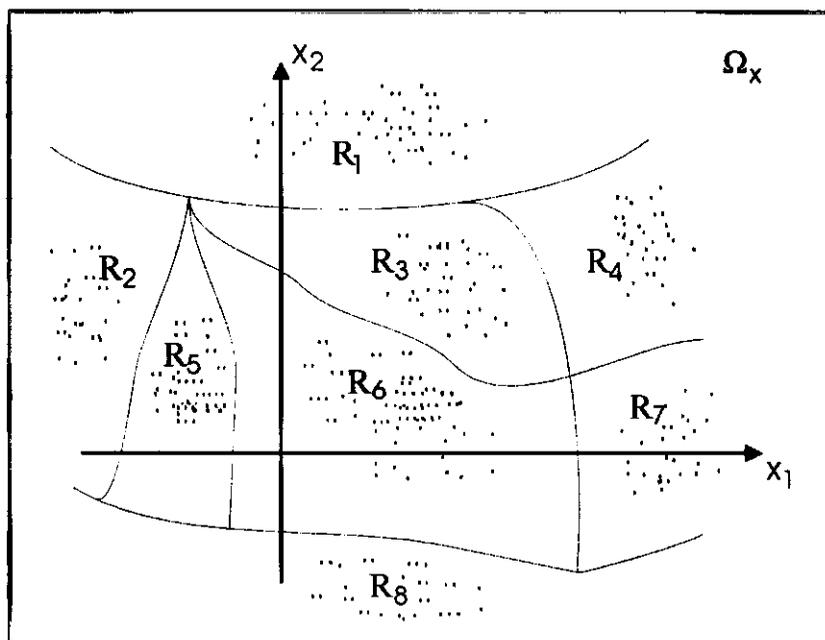


Figura 7 - Exemplo de regiões de decisão em um espaço bi-dimensional. Fonte: Slansky e Wassel (1981).

### 3.2 Tipos de Atributos Extraídos

Para efeito de montagem dos processos de classificação foram testados diversos tipos de atributos para cada um dos domínios enfocados. Na Tabela 2 são listados os atributos analisados.

Tabela 2 – Tipos de Atributos Analisados.

TEMPO	FREQÜÊNCIA	WAVELETS
Média	Faixas do espectro	Média
Curtose		Curtose
Assimetria	Energia total	Assimetria

Tabela 2 – Tipos de Atributos Analisados  
(continuação).

TEMPO	FREQÜÊNCIA	WAVELETS
Passagens por zero		Passagens por zero
Desvio padrão		Desvio padrão
Nº valores<zero		Nº valores<zero
Valor eficaz		Valor eficaz
Coefficiente de variação		Coefficiente de variação
Faixas do histograma		Faixas do histograma

Esses tipos de atributos são descritos a seguir:

- Média: média aritmética dos valores constituintes da variável sob análise;
- Curtose: parâmetro estatístico que mede o grau de achatamento da distribuição dos valores sob análise em relação à distribuição normal;
- Assimetria: parâmetro estatístico que mede o grau de desvio ou afastamento da simetria da distribuição dos valores sob análise em relação a distribuição normal;
- Passagens p/0: número de vezes em que o sinal sob análise passou por zero;
- Desvio padrão: desvio padrão dos valores sob análise;
- Nº valores<zero: número de valores do sinal sob análise menores do que zero;
- Valor eficaz: valor eficaz do sinal sob análise;
- Coeficiente de variação: percentual do desvio padrão em relação à média;
- Faixas do histograma: número de registros da variável sob análise contidos em faixas do histograma (o número de faixas a considerar será analisado no Capítulo 4);
- Faixas do espectro: energia contida por faixa do espectro de frequência (o número de faixas a considerar será analisado no Capítulo 4);
- Energia total: energia total contida no sinal sob análise.

### **3.3 Técnicas Matemáticas Aplicadas**

A modelagem matemática utilizada está associada às técnicas de processamento digital de sinais, transformadas de Fourier e Wavelet, as quais embasaram a aplicação das técnicas de reconhecimento de padrões. Foram avaliadas técnicas de reconhecimento lineares e não lineares. Dentre as técnicas lineares constantes da literatura, foram exploradas as técnicas de Fisher e Karhunen-Loève. A técnica não linear analisada foi a rede neural. Em anexo, podem ser encontrados detalhes quanto à metodologia inerente a cada uma dessas técnicas. Detalhes práticos quanto à aplicação da metodologia serão vistos nos tópicos adiante associados aos estudos de casos.

### **3.4 Estudo de Casos**

Foram estudados dois casos para avaliar a aplicação da metodologia mencionada em 3.3. O primeiro caso objetivou analisar o comportamento de isolamentos de alta tensão convencionais submetidos à poluição. O segundo caso teve o propósito de diagnosticar a presença de defeitos internos a isoladores poliméricos.

Os dispositivos utilizados serão descritos adiante, como também serão apresentados os circuitos experimentais implementados para cada um dos casos estudados, ressaltando-se as funções dos seus componentes.

#### **3.4.1 Caso 1: Poluição em Isoladores**

Procurou-se diagnosticar a poluição em isoladores a partir da aferição de sinais gerados em consequência das descargas superficiais em unidades submetidas à tensão elétrica, camada de contaminação artificial e umidade saturada. Foram adquiridos sinais de ultra-som, corrente de fuga, ruídos na faixa de VHF e a variação térmica da superfície isolante. Os diversos dispositivos utilizados são descritos a seguir.

### 3.4.1.1 Sensor de Ultra Som

Consiste de um instrumento o qual possui um indicador e um alto-falante, conectado a um sensor-transdutor de ultra-som para som audível, tubo detector direcional, dispositivo de concentração do som e adaptador para fixação do alto-falante à cabeça ou digitalizador. Na Figura 8, adaptada a partir do catálogo BIDDLE (1990), é ilustrado o sensor utilizado, na qual o tubo detector indicado amplifica os sinais internos ao tubo de captação e rejeita os externos. O transdutor de ultra-som é sensível a uma faixa de frequência de 35 a 45 kHz e faz a conversão dos sinais captados para sons audíveis, que são transmitidos para o digitalizador. Este mesmo transdutor é muito pouco sensível a sons audíveis, permitindo o seu uso em áreas com alta intensidade de ruídos de fundo na última faixa de frequência. O medidor de saída, para indicar a intensidade do ultra-som, é calibrado numa escala linear de 0 a 10, apresentando nível relativo. O diâmetro focal do tubo de captação é 30 cm, possuindo um alcance de 10 m.

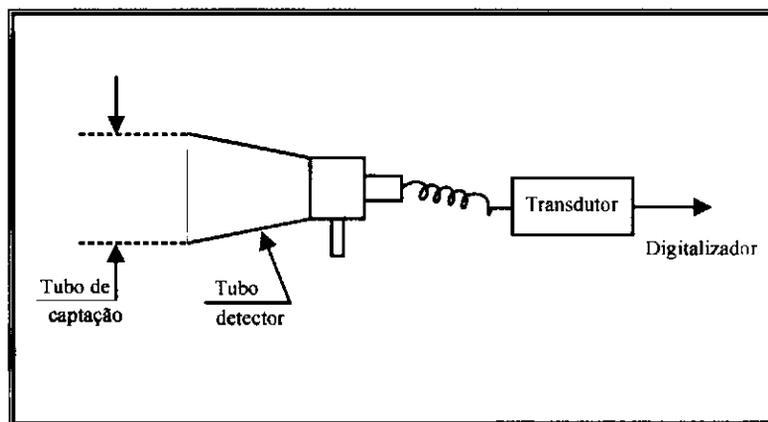


Figura 8 – Ilustração do funcionamento do sistema de detecção de ultra-som. Fonte: BIDDLE (1990).

### 3.4.1.2 Sistema de Digitalização

O sistema de digitalização, aqui descrito sinteticamente, consiste do "pacote" de Medições TD2301 da Tektronix (1992) o qual se compõe de instrumentações e programas computacionais. Os programas permitem a aquisição, gravação, processamento e análise de sinais, baseado no Digitalizador Programável RTD 710A da Tektronix. Os instrumentos incluem os seguintes componentes:

- digitalizador Programável RTD 710A da Tektronix;
- monitor X-Y Tektronix 620 para uso geral;
- controlador de sistema Tektronix PEP 301.

### 3.4.1.3 Câmara de Névoa

A câmara de névoa foi implementada, na UFCG, em conformidade com a IEC (1991), para controle da umidade reinante no ambiente sob teste, com o intuito de se obter maior fidelidade quando da geração do efeito “corona”, em relação às condições reais de campo. A câmara foi confeccionada em acrílico nas dimensões de  $0,90 \times 0,90 \times 1,40 \text{ m}^3$ , conforme encontra-se ilustrado na Figura 9 (a).

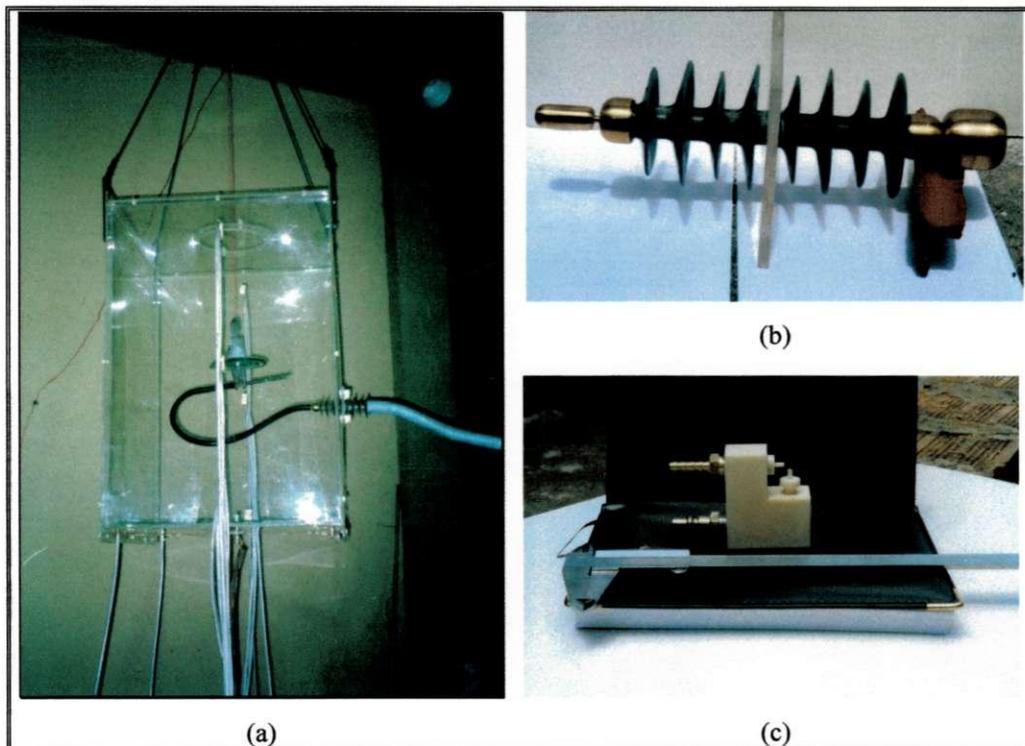


Figura 9 – Foto da câmara de névoa: (a) vista da câmara ilustrando as suas alimentações de tensão elétrica, água e ar comprimido e captação da corrente de fuga; (b) bucha polimérica para passagem da alimentação de tensão elétrica; (c) par de bicos injetores.

A entrada de tensão é feita através de bucha polimérica, ilustrada na Figura 9 (b), a qual foi desenvolvida a partir de isolador polimérico industrial, perfurado e transpassado por haste metálica com extremidades afixadas em conectores de latão com diâmetro aumentado e acabamento especial para evitar descargas corona indesejáveis. A opção

pela bucha polimérica foi feita após a identificação de descargas excessivas, na conexão inferior da câmara, inicialmente utilizada para alimentação da tensão de ensaio e posteriormente adaptada para aterramento da face inferior, onde é feita a drenagem da água depositada. O aterramento implementado permitiu, ainda, uma maior segurança a terceiros quanto a eventuais fugas de corrente através das mangueiras e fluidos de alimentação de água e ar comprimido. Em testes experimentais realizados registrou-se a suportabilidade da câmara a tensões de até 50 kV, sem a presença de umidade e até 15 kV, quando da formação da névoa limpa. O ponto frágil está associado à dimensão da bucha polimérica.

A extensão da suportabilidade pode ser alcançada através do redimensionamento da bucha desenvolvida. O isolador sob teste é colocado no centro da câmara e o seu aterramento é feito através de condutor que tem, também, o papel de sustentação mecânica do isolador. O condutor terra é responsável, ainda, por transmitir a corrente de fuga do isolador para ser devidamente registrada através do digitalizador, passando antes no circuito de proteção. A névoa salina é formada por seis pares de bicos injetores, colocados três a três em faces opostas. Na Figura 9 (b) é ilustrado um dos pares, no qual o bico horizontal é responsável pela alimentação de água e o vertical pela alimentação de ar comprimido. A névoa é formada a partir do encontro dos fluidos.

### 3.4.1.4 Circuito de Proteção

Apesar da segurança associada à limitação da tensão de ensaio um outro cuidado adicional se refere à utilização de circuito de proteção para evitar que eventuais curtos-circuitos no isolador ensaiado possam transferir uma tensão elevada para os instrumentos, em especial o digitalizador. Esse circuito se encontra ilustrado na Figura 10. Na figura, é possível observar que a proteção do digitalizador é realizada em três estágios principais.

No primeiro deles, a tensão de entrada no circuito é limitada por um varistor que entra em condução a 35 V. No segundo, são colocados dois diodos zener, “back to back”, que limitam a tensão em  $\pm 5,7$  V, conforme ilustrações feitas na Figura 10 (a).

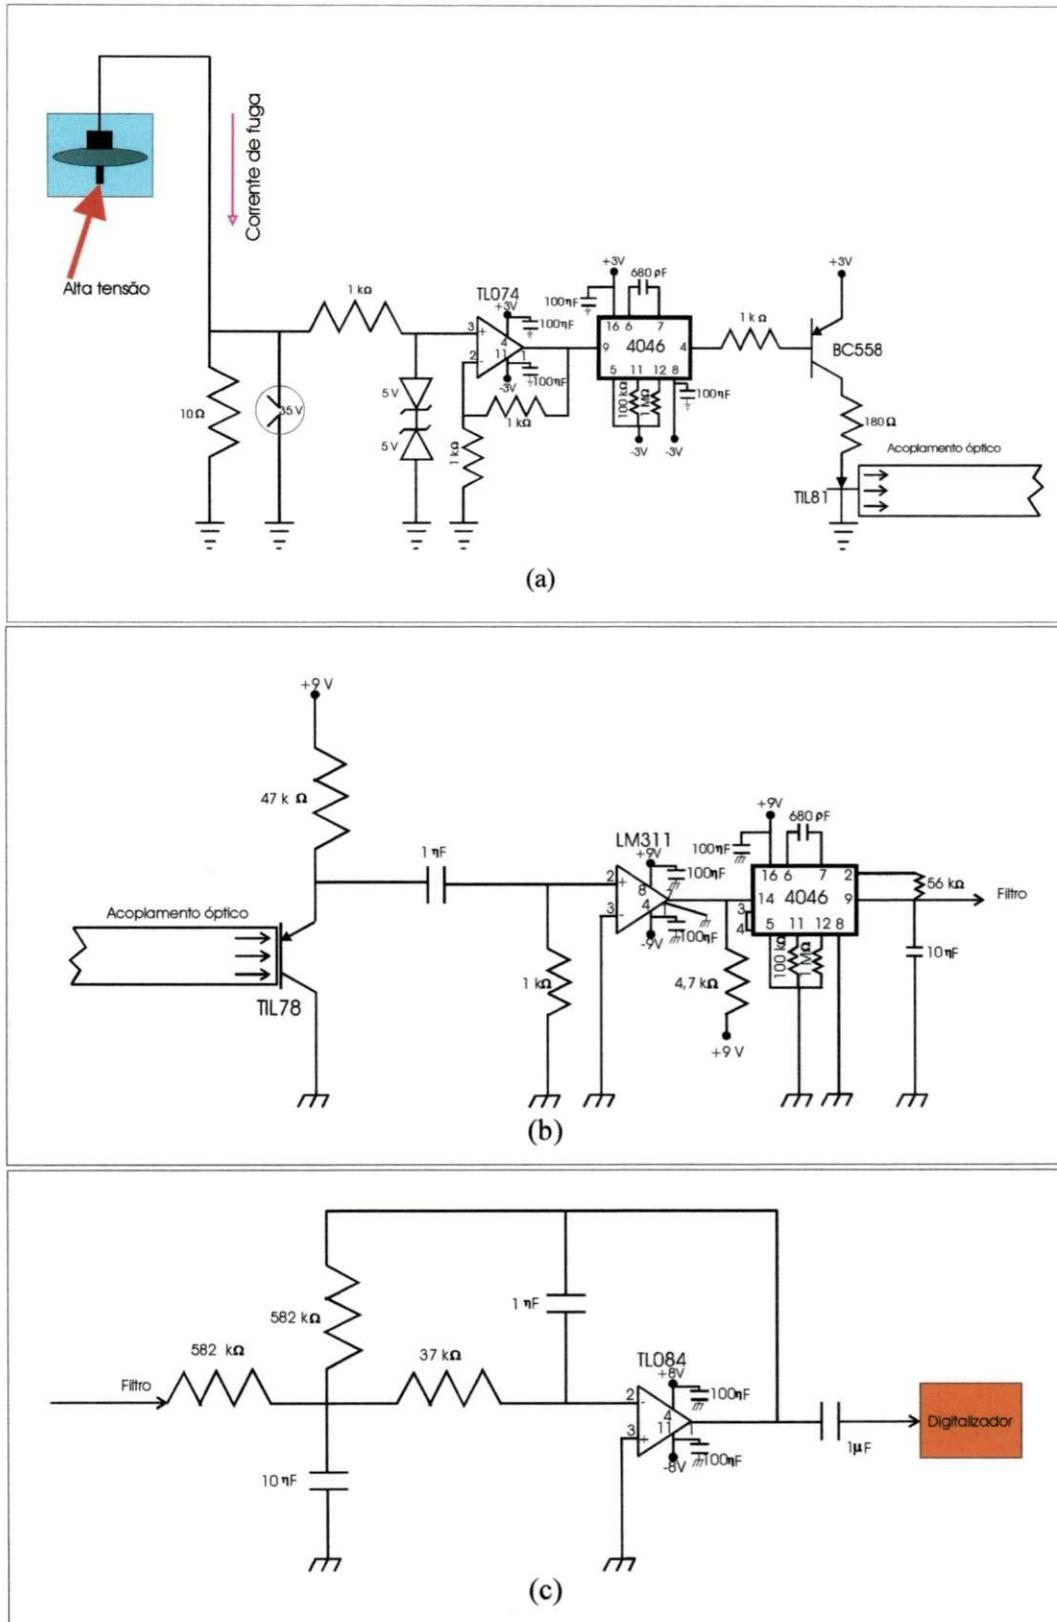


Figura 10 – Circuito de proteção do digitalizador: (a) lado acoplado a alta tensão; (b) lado acoplado a baixa tensão e isolado por acoplamento óptico e (c) filtragem/amplificação.

Na terceira etapa, a proteção é assegurada através da interrupção elétrica do circuito, realizada por um acoplamento óptico, conforme ilustrado na Figura 10 (b). Por intermédio do acoplamento, as possíveis sobretensões que venham a incidir no circuito do TIL81 ficarão restritas ao mesmo, uma vez que existe uma isolação elétrica entre o diodo foto-emissor TIL81 e o foto-transistor TIL78, protegendo desta forma a integridade elétrica do digitalizador. Os sinais de tensão entre  $-5,7$  e  $+5,7$  V são processados normalmente pelo circuito e recebidos pelo digitalizador. Nessas condições, tudo se passa como se o varistor e os diodos zener não estivessem presentes no circuito. A filtragem e amplificação são feitas na seção do circuito ilustrada na Figura 10 (c). Os demais componentes do circuito têm as funções descritas a seguir e podem ser visualizadas, também, através do diagrama de blocos ilustrado na Figura 11.

- **Circuito do diodo foto-emissor:**

- o amplificador operacional (TL074) amplifica o sinal de tensão com ganho 2;
- o conversor tensão frequência (4046) fornece, na sua saída, uma onda quadrada, cuja frequência é função da amplitude do sinal de entrada; a taxa de variação da frequência da onda quadrada é função da frequência da tensão analógica de entrada;
- o estágio de potência (transistor BC558) é usado para fornecer corrente suficiente ao diodo foto-emissor, pois o 4046 não tem capacidade de suprir a potência necessária ao citado diodo;
- o diodo foto-emissor (TIL81) converte o sinal elétrico de entrada em sinal óptico, o qual é transmitido para o foto-receptor;

- **Circuito do foto-receptor**

- o foto-transistor (TIL78) re-converte o sinal óptico recebido em um sinal elétrico;
- o comparador de tensão (LM311) reconstrói o sinal quadrado, em especial nas transições;
- o demodulador de frequência (4046) converte a frequência do sinal de entrada em tensão analógica;

- o o filtro passa baixa reduz o ruído da frequência portadora do sinal de saída do 4046 e o capacitor de 1  $\mu\text{F}$  faz com que o sinal na saída seja somente de corrente alternada; observa-se que foi levantado um ganho total de 1,3 vezes o sinal de entrada, na frequência de 60 Hz.

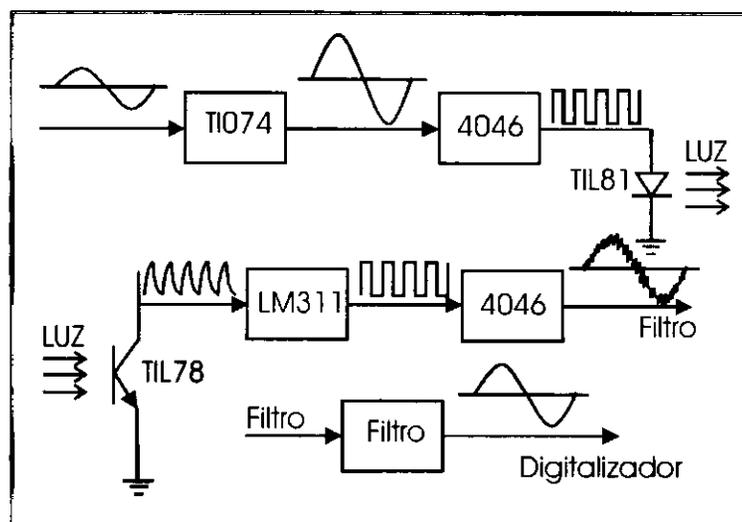


Figura 11 – Diagrama de blocos do circuito de proteção.

### 3.4.1.5 Termovisor

Foi utilizado o sistema de monitoração de infravermelho da AGEMA Thermovision 550, o qual é constituído de uma câmara de infravermelho, munida de objetiva de 20°, um cinto de baterias e outros diversos acessórios. A câmara de infravermelho constrói uma imagem a partir da radiação infravermelha emitida por um objeto. O fato da radiação ser função da temperatura da superfície do objeto torna possível o cálculo e indicação da temperatura ao longo do objeto. As imagens térmicas do objeto sob inspeção são arquivadas num cartão removível, permitindo que as mesmas possam ser analisadas em um computador, utilizando-se o programa de análise e relatório Irwin 5.0 da Agema (1996). Ressalta-se que, através do programa, é possível construir o histograma das temperaturas contidas nas imagens captadas o qual pode ser devidamente analisado para compor novos atributos a serem incorporados ao processo de reconhecimento.

### 3.4.1.6 Antena de VHF e Analisador de Espectro

A antena de VHF direcional utilizada permitia a captação de sinais na faixa de 20 a 100 Mz. Tal faixa não representava exatamente a faixa de interesse (0 a 60 Hz), conforme recomendações feitas por Stewart et al. (1999), o que pode conduzir a imprecisão no processo de reconhecimento a partir da utilização desta antena de VHF como elemento sensor. A antena foi acoplada ao analisador de espectro Tektronix (1994) equipado com porta GPIB, permitindo interface com o computador, viabilizando, portanto, a caracterização de novos atributos associados aos espectros adquiridos.

### 3.4.1.7 Preparação das Amostras

As amostras foram preparadas em conformidade com os critérios estabelecidos por EPRI (1975), conforme é detalhado na Tabela 3.

Tabela 3 - Caracterização dos níveis de poluição - de acordo com EPRI (1975).<sup>3</sup>

Níveis	Classificação	Faixa de ESDD (mg/cm <sup>2</sup> )
1	Atmosfera limpa.	0,00 – 0,032
2	Contaminação muito leve.	0,032 – 0,038
2'	Contaminação leve.	0,038-0,056
3	Contaminação pesada.	0,056 – 0,123
4	Contaminação muito pesada.	Maior que 0,123

Em função do agrupamento estabelecido na Tabela 3, foram aplicados níveis de poluição específicos em conformidade com os procedimentos descritos na IEC (1991), tendo-se optado pela Composição de Caulim para formação da solução aplicada sobre a superfície do isolador: 40 g de caulim, 1000 g de água destilada e quantidade de NaCl de pureza comercial necessária para produzir a condutividade apresentada na Tabela 4.

<sup>3</sup> A classe 2' foi definida, em complemento à caracterização de EPRI (1975), com o intuito de gerar amostras mais espaçadas/diversificadas e, desta forma, poder produzir conjuntos de treinamento para o processo de classificação dos sinais bem mais próximos de situações reais encontradas em isoladores de alta tensão presentes em um sistema de transmissão.

Tabela 4 - Valores escolhidos para elaboração das soluções.

Níveis	ESDD(mg/cm <sup>2</sup> )	Condutividade da suspensão (mS/cm)
1	0,025	10
2	0,035	14
2'	0,05	20
3	0,1	40
4	0,2	80

Após produção das soluções foram selecionados cinco isoladores de vidro de características geométricas idênticas para serem pulverizados superficialmente com as soluções adequadamente diluídas.

### 3.4.1.8 Arranjo Experimental

O arranjo experimental foi montado no Laboratório de Alta Tensão, agregando todos os componentes descritos anteriormente. Na Figura 12 é ilustrado o arranjo implementado, no qual pode ser observado que os sinais de corrente de fuga são obtidos de forma indireta, associados à tensão resultante da passagem da corrente no resistor  $R_{\Omega}$ . Todos os componentes encontram-se indicados na figura, ressaltando-se que o sensor de ultra-som, antena de VHF e termovisor não possuem ligação direta com o circuito de alta tensão que alimenta o objeto sobre ensaio (isolador poluído), fruto de suas características não invasivas. Os dados adquiridos através do digitalizador (sinais de corrente de fuga e ultra-som) foram gravados seqüencialmente no computador que controlava todo o processo de aquisição e encontra-se, também, identificado na figura. A aquisição dos sinais de VHF foi realizada diretamente a partir do analisador de espectro, controlado pelo computador. As imagens térmicas foram gravadas diretamente no termovisor. Os dois últimos equipamentos mencionados (digitalizador e computador) ficavam acondicionados em cabine de comando, na qual eram feitos todos os ajustes das tensões aplicadas e controle das aquisições dos sinais. A cabine ficava separada da plataforma de ensaios, em alta tensão, onde se alocavam os demais equipamentos.

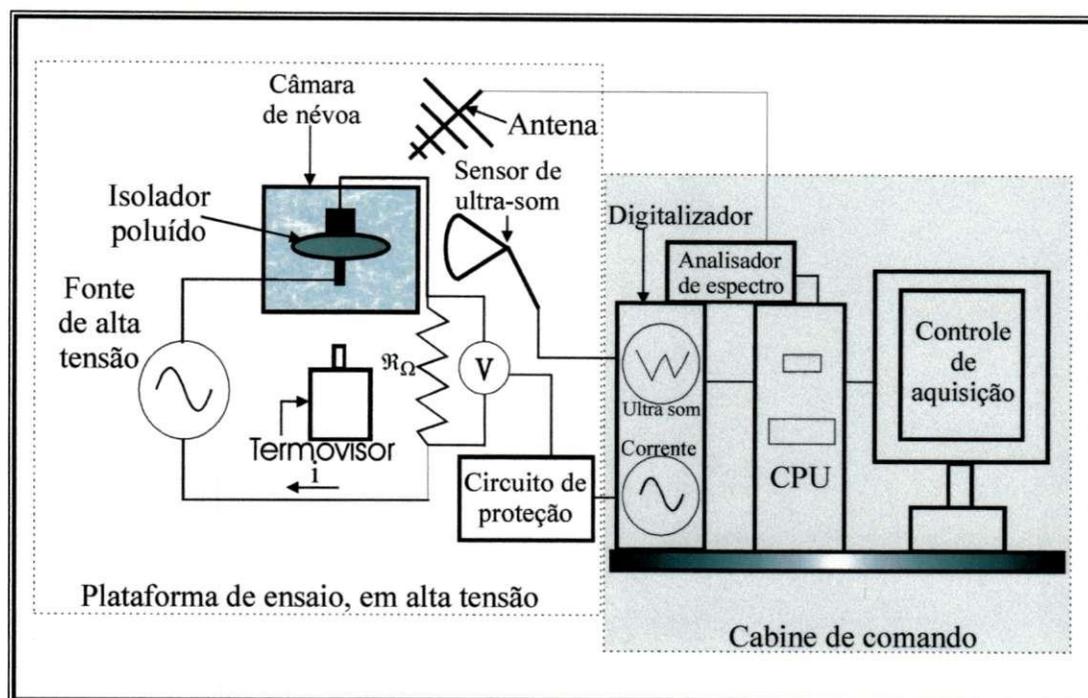


Figura 12 – Arranjo elétrico dos ensaios de poluição em isoladores.

### 3.4.1.9 Identificação da Tensão de Ensaio

A tensão de 7 kV (por unidade isolante) foi escolhida em função de análises prévias direcionadas no sentido de se identificar um valor limite que poderia ser aplicado sem o risco da ocorrência de curto circuito sobre o objeto ensaiado. Essa tensão foi devidamente aferida através dos modelos descritos por Rizk (1981) e Sundararajan e Gorur (1993), os quais foram adaptados/implementados para aferir a tensão de ensaio utilizada, conforme se descreve a seguir.

Para análise da tensão de descarga ( $V_{50\%}$ ), ou seja, a tensão que provoca a descarga total do isolador em 50% das aplicações, foi implementada rotina específica, conforme ilustrações contidas na Figura 13. Na rotina, são calculados os valores de tensão, em função do nível de poluição depositada, estando o mesmo submetido à névoa limpa (umidade saturada).

Os cálculos embutidos nessa rotina são realizados em conformidade com o circuito representativo da manifestação de arcos em bandas secas na superfície de unidades isolantes, ilustrado na Figura 14.

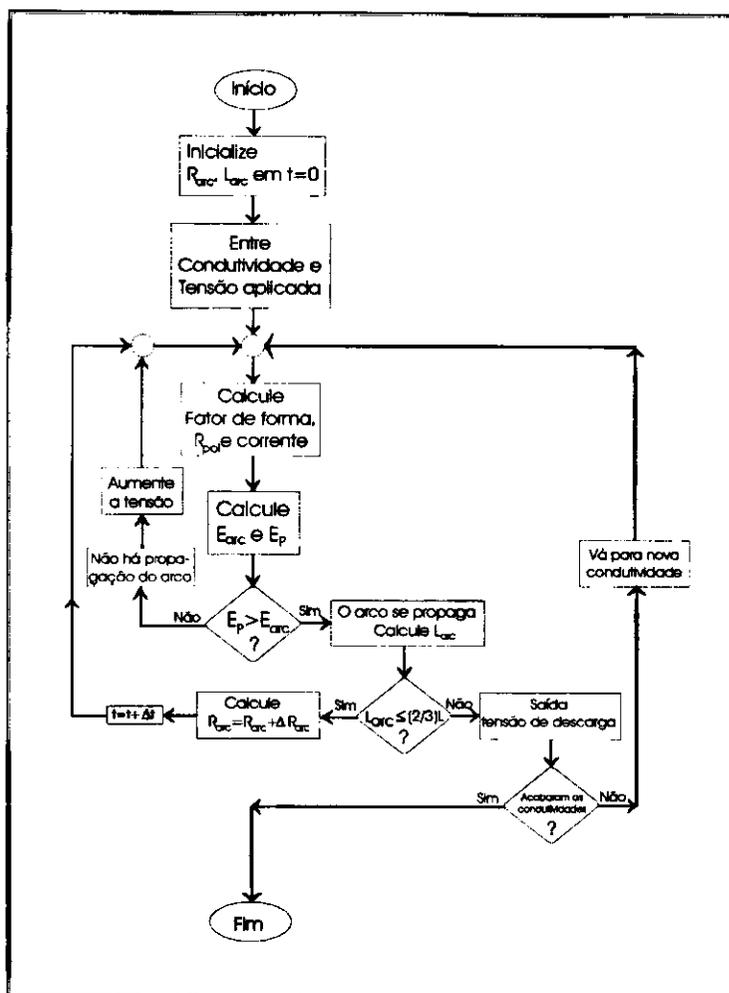


Figura 13 – Modelo computacional para cálculo de tensões de 50%.

Na ilustração contida na Figura 14, a tensão é aplicada a um isolador tipo bastão, em seus terminais metálicos. O isolador possui duas partes dielétricas distintas. Na primeira delas a superfície encontra-se poluída e úmida. Na segunda, a umidade superficial foi inicialmente extraída por aquecimento oriundo de correntes de fuga, nas proximidades da parte metálica da esquerda do isolador, formando bandas secas sobre o mesmo. Essas bandas secas, ao serem submetidas a tensões elétricas, podem dar origem a arcos, conforme ilustrado na Figura 14, em vermelho. O circuito, na parte inferior da figura, procura reproduzir o comportamento elétrico da situação descrita anteriormente, na qual  $R_p$  representa a resistência elétrica da superfície poluída e úmida e  $V_s$  a tensão aplicada. A modelagem matemática de Rizk (1981), posteriormente implementada computacionalmente por Sundararajan e Gorur (1993) e ilustrada na Figura 13, procura avaliar as condições da poluição e tensão aplicada que conduzirão à propagação do arco

elétrico iniciado. A seguir serão detalhadas as etapas contidas no algoritmo ilustrado na Figura 13.

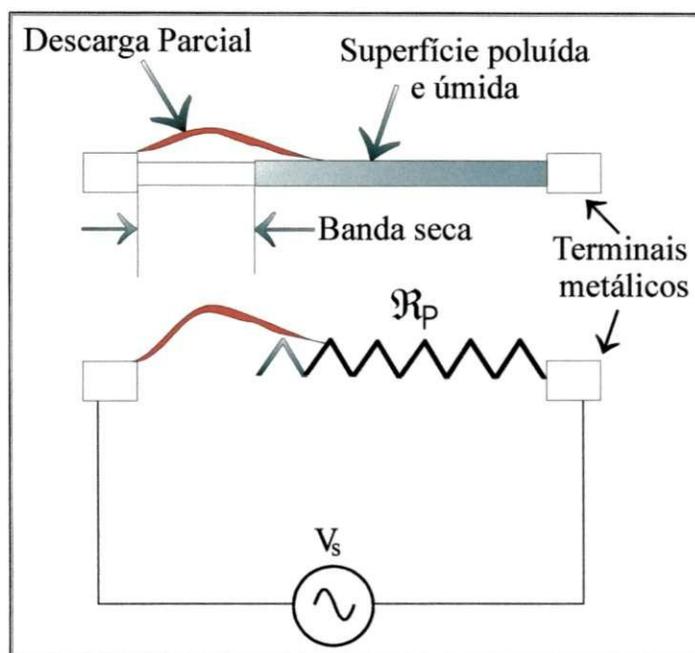


Figura 14 – Descargas parciais em bandas secas na superfície de isoladores. Fonte: Rizk (1981).

a) a equação da tensão é escrita como:

$$V_s = V_c + V_a + \mathfrak{R}_{arc} \cdot \Gamma_{arc} \cdot i + i(\mathfrak{R}_p + \mathfrak{R}_s) \quad (7)$$

sendo:

$V_s$  = a tensão aplicada [V],

$V_c$  = a queda de tensão no catodo [V],

$V_a$  = a queda de tensão no anodo [V],

$\mathfrak{R}_{arc}$  = resistência do arco por unidade de comprimento [ $\Omega/cm$ ],

$\Gamma_{arc}$  = comprimento do arco [cm],

$i$  = corrente de entrada na camada poluída [A],

$\mathfrak{R}_p$  = resistência da camada de poluição [ $\Omega$ ] e

$\mathfrak{R}_s$  = resistência interna da fonte supridora [ $\Omega$ ].

b) desprezando  $\mathfrak{R}_s$ , a corrente em cada instante é dada por:

$$i = \frac{V_s - (V_c + V_a)}{\mathfrak{R}_{arc}\Gamma_{arc} + \mathfrak{R}_p}; \quad (8)$$

no tempo  $t = 0$ , para uma dada severidade da poluição (em termos da condutividade da camada  $\delta$  [ $\mu\text{S}$ ]) e tensão aplicada  $V_s$  [V], a corrente é calculada usando os valores iniciais seguintes:

- $\Gamma_{arc} = 1/100$  da distância de escoamento<sup>4</sup> [cm],
- $\mathfrak{R}_{arc} = 100$  [ $\Omega/\text{cm}$ ],
- $V_c = 700$  [V] (constante),
- $V_a = 200$  [V] (constante),
- $\mathfrak{R}_p = \frac{1}{\delta}\xi$ , sendo  $\xi = \int_{\Gamma_{arc}}^{\Gamma_e} \frac{d\ell}{2\pi\phi_\ell}$ , no qual:
  - $\Gamma_e =$  distância de escoamento do isolador em cm,
  - $d\ell =$  valor incremental da distância de escoamento em cm,
  - $\phi_\ell =$  raio a cada incremento de distância  $d\ell$  em cm;

o fator de forma ( $\xi$ ) é calculado a todo intervalo de tempo, dependendo do comprimento do arco, através de técnica específica de integração numérica; a distância a ser percorrida pelo arco varia a cada instante, dependendo da propagação do mesmo. Isso é ilustrado da seguinte maneira: em um dado momento  $t_1$  a posição do arco é A (Figura 15-a), então o fator de forma é calculado para a porção A-B; no instante  $t_2 = t_1 + dt$  se o arco tiver se movido para uma nova posição A' (Figura 15-b), o fator de forma passa a ser calculado para a porção A' - B; desta maneira, a geometria é considerada a cada instante no cálculo da tensão de descarga;

<sup>4</sup> Distância de escoamento de um isolador é a menor distância existente, desde a parte metálica superior (campânula) até a parte metálica inferior (pino), contornando toda a superfície do dielétrico (corte vertical), segundo Fuchs (1979).

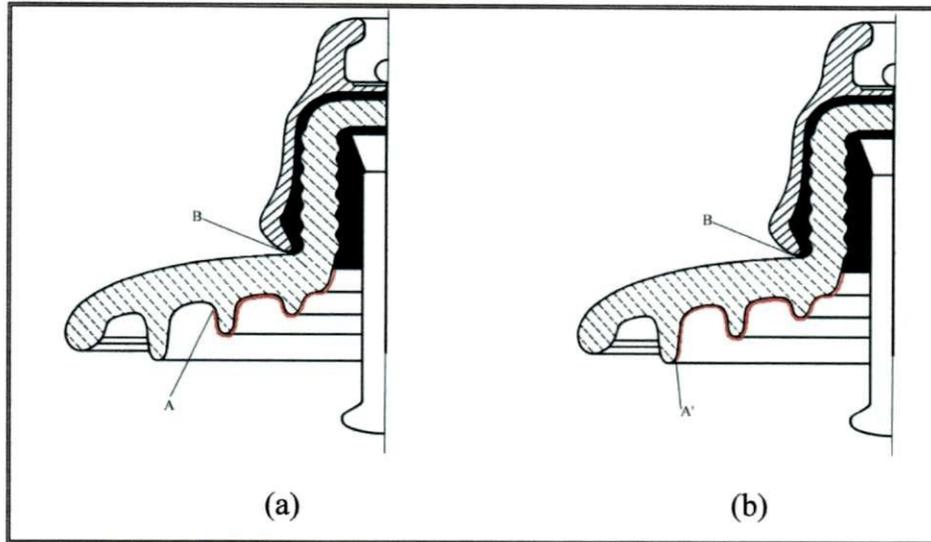


Figura 15 – Propagação do arco no isolador poluído (a) tempo  $t_1$ , (b) tempo  $t_2$ .

c) o gradiente de tensão do arco é calculado como:

$$\Phi_{\text{arc}} = \Lambda i^{-\gamma}, \quad (9)$$

sendo que  $\Lambda$  e  $\gamma$  são constantes (valores propostos pelos autores:  $\Lambda = 63$  e  $\gamma = 0,5$ );

d) o gradiente de tensão na superfície poluída é calculado da seguinte forma:

$$\Phi_p = \Lambda^{\frac{1}{\gamma+1}} \mathfrak{R}_{\text{pol}}^{\frac{\gamma}{\gamma+1}}, \quad (10)$$

no qual  $\mathfrak{R}_{\text{pol}}$  é a resistência uniforme da poluição por unidade de comprimento [ $\Omega/\text{cm}$ ], calculada como:

$$\mathfrak{R}_{\text{pol}} = \frac{\mathfrak{R}_p}{\Gamma - \Gamma_{\text{arc}}}; \quad (11)$$

e) o critério de propagação do arco é conferido, verificando se  $\Phi_p > \Phi_{\text{arc}}$ , ou seja, o arco se propagará se o gradiente de tensão a frente do arco, isto é o gradiente de tensão da camada de poluição, for maior do que o gradiente do arco; para esta condição, se o comprimento do arco for quase igual a distância de escoamento do isolador ( $\geq 2\Gamma/3$ ) isso representa a descarga total; caso o

comprimento do arco for menor do que  $2\Gamma/3$  e o critério de propagação do arco for satisfeito, a mudança dinâmica da resistência do arco é calculada, usando uma técnica numérica de diferenciação, como:

$$\frac{d\mathcal{R}_{\text{arc}}}{dt} = \frac{\mathcal{R}_{\text{arc}}}{\tau} - \frac{\mathcal{R}_{\text{arc}}^2 i^{\gamma+1}}{\tau \Lambda}, \quad (12)$$

sendo que  $\tau$  é a constante de tempo do arco considerada igual a 100  $\mu\text{s}$ ; a nova resistência do arco e a nova corrente são calculadas, conhecendo-se um novo fator de forma, uma nova resistência da poluição, etc; o critério de propagação do arco é conferido novamente para os novos valores; caso haja a descarga total a tensão crítica é obtida; se  $\Phi_{\text{arc}} \geq \Phi_p$ , então o arco se extingue; a tensão de alimentação é aumentada, as etapas anteriores são repetidas e a condição de propagação do arco é testada novamente; os autores utilizaram a seguinte equação para cálculo da velocidade de propagação do arco e conseqüente tempo de propagação:

$$v = 1,54 \times 10^{-4} \mathcal{R}_{\text{pol}}^{2,5} (i^4 - i_c^4) \text{ cm/s}, \quad (13)$$

na qual:  $i_c$  é a corrente crítica dada por  $\Phi_c/\mathcal{R}_{\text{pol}}$ ; o tempo de percurso para cada deslocamento do arco é dado por:

$$\Delta t = \frac{\Delta \Gamma_{\text{arc}}}{v}; \quad (14)$$

- f) as etapas anteriores são repetidas para todas as outras severidades de poluição desejadas. Na Figura 16 são ilustrados os resultados obtidos para o isolador padrão IEEE e anti-poluição, na figura são apresentados os valores de tensão de descarga (V50%), conhecida na literatura como tensão de “flashover”, em função da poluição depositada, estando a umidade relativa saturada (100%). Os níveis de poluição estão apresentados em  $\mu\text{S}$ . Segundo o CIGRÈ (1979), esses valores podem ser transformados para ESDD (densidade equivalente de sal depositado, em  $\text{mg}/\text{cm}^2$ ), através da seguinte relação:

$1\mu S = 10^{-2} \times ESDD$ . Pode ser verificado que a tensão de 7 kV representa um valor suportável para qualquer das amostras, independente do ESDD aplicado, para o caso de um isolador padrão, tendo sido esta a tensão escolhida para os ensaios analisados adiante.<sup>5</sup> A título ilustrativo, a figura mostra, ainda, como seria o comportamento de um isolador anti-poluição, o qual não foi objeto dos experimentos descritos a seguir.

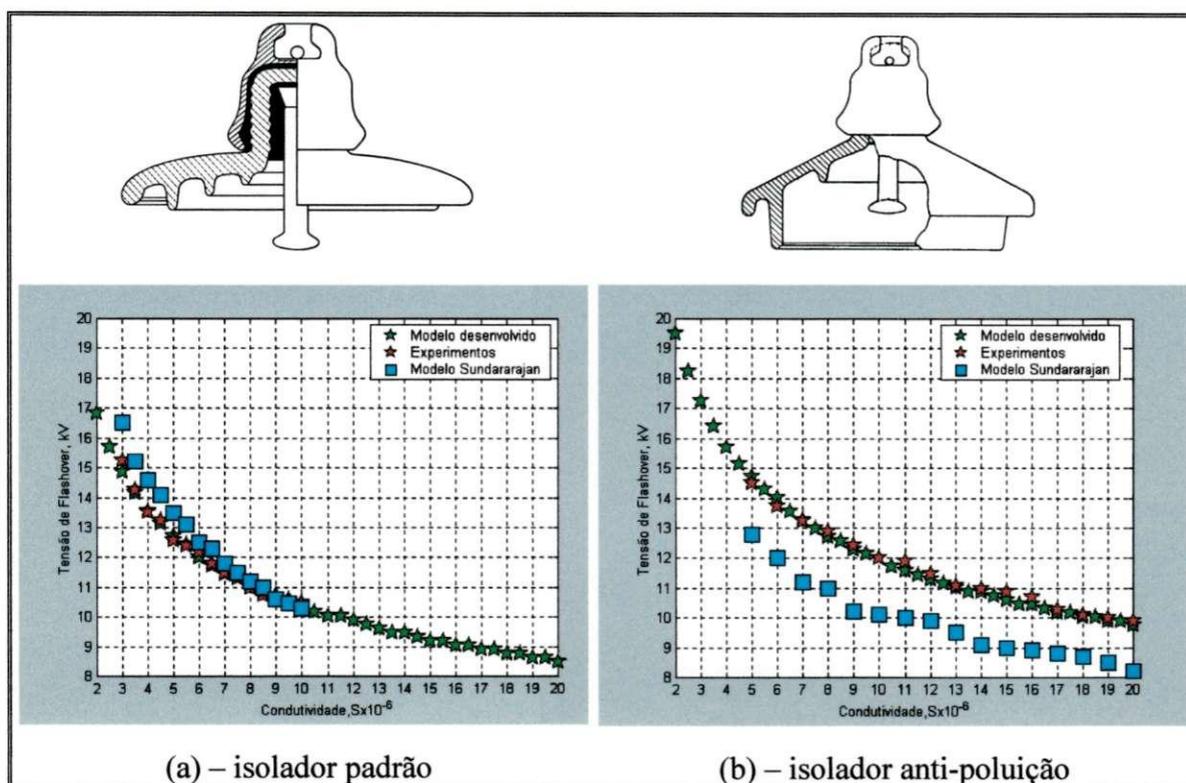


Figura 16 – Tensões de descarga para os isoladores: (a) padrão e (b) anti-poluição.

É importante ressaltar que, na rotina desenvolvida, foi utilizado o equacionamento do circuito elétrico de corrente alternada proposto por Rizk (1991) a cada iteração e não a solução aproximada indicada pelo autor, o que conduziu a maior precisão do modelo desenvolvido em relação ao descrito por Sundararajan e Gorur (1993), tendo como referência os resultados dos ensaios apresentados na Figura 16, em vermelho, os quais foram registrados pelos autores aqui referidos.

<sup>5</sup> Essas análises suscitaram estudos específicos quanto a suportabilidade de cadeias de isoladores poluídos e a distribuição de tensão ao longo da cadeia, conforme descrições feitas por Bezerra et al (2002 a), (2002 b) e (2003).

### **3.4.1.10 Desenvolvimento dos Experimentos**

Os experimentos foram conduzidos de tal forma que, inicialmente, através da câmara de névoa, era produzido um ambiente de umidade saturada em torno de duas unidades de isoladores, sobre as quais, previamente foram pulverizadas soluções contendo poluição nos níveis descritos na Tabela 4. A partir deste instante, era aplicada tensão elétrica até se atingir o nível de 14 kV, suficiente para produzir descargas superficiais sem conduzir o isolador a descarga total, conforme análises apresentadas em 3.4.1.9. Ressalta-se que, segundo Bezerra et al. (2003) a distribuição de tensão para as duas unidades é linear, representando, portanto, que cada unidade foi submetida à tensão de ensaio definida anteriormente, durante todo o experimento. Ao se atingir este nível de tensão, eram adquiridos os sinais de ultra-som, corrente de fuga e VHF. As imagens térmicas eram registradas 4 minutos após se atingir a tensão de 14 kV, uma vez que, observou-se previamente que esse era o tempo necessário para se estabelecer uma temperatura relativamente estável. Todos os sinais e imagens térmicas eram adquiridos em menos de dez minutos, em conformidade com os procedimentos recomendados pela IEC (1991).

### **3.4.1.11 Processamento das Informações**

Os sinais extraídos foram submetidos a processamentos preliminares que visaram constituir as bases necessárias para extração dos atributos básicos descritos anteriormente. Esses processamentos foram feitos a depender do tipo de sinal adquirido e procuraram viabilizar a constituição de um conjunto de dados que pudesse ser composto de forma adimensional e viabilizasse a avaliação comparativa entre os sensores utilizados e atributos caracterizados e extraídos para monitorar a evolução das descargas superficiais aos isoladores. A característica adimensional foi assegurada pela divisão de cada atributo pelo desvio padrão deste atributo em todo o conjunto de treinamento formado. Os processamentos implementados podem ser sintetizados da seguinte forma:

- submissão do sinal específico a rotina de extração de atributos;
- normalização dos atributos em relação ao seu desvio padrão;

- construção de funções discriminantes (lineares e não lineares) que viabilizarão a montagem dos classificadores;
- identificação de percentuais de acertos a partir do classificador construído.

Os procedimentos acima foram complementados através de rotinas específicas de validação, as quais incorporaram as funções discriminantes obtidas. A essas rotinas foi submetido novo conjunto de dados de tal forma a se testar a validade do classificador no sentido de diagnosticar estados desconhecidos do isolamento sob análise. Esses procedimentos serão detalhados através dos resultados apresentados a seguir. Ressalta-se que, para efeito de se avaliar a contribuição de sinais e atributos para o processo de classificação, foram feitas partições no conjunto de treinamento direcionadas para a aferição do percentual de acertos, utilizando-se atributos associados apenas a determinados sinais. A partir dessa estratégia foi viabilizada a avaliação de composições de sinais e sensores, utilizando-se sempre o percentual de acertos no diagnóstico como indicador de desempenho do classificador.

### **3.4.2 Caso 2: Defeitos em Isoladores Poliméricos**

Os isoladores poliméricos foram submetidos a defeitos artificiais que podem surgir, na prática, durante processos de montagens industriais associados à fabricação dos mesmos. Os ensaios foram desenvolvidos em laboratório de descargas parciais. A seguir são descritos os diversos componentes utilizados nos experimentos.

#### **3.4.2.1 Circuito Experimental e seus Componentes**

Os ensaios de descargas parciais foram implementados a partir do circuito específico ilustrado na Figura 17, em conformidade com a IEC (2000) e implementado por Néri (2002).

Este circuito é constituído das seguintes partes: mesa de controle (Ferranti), filtros de linha, transformador de 220 V/100 kV-10 kVA, detector de descargas parciais da Biddle, digitalizador RTD 710A da Tektronix, osciloscópio da Tektronix com duplo traço, capacitor de acoplamento ( $C_k$ ), com capacitância de 170 pF/100 kV e imune a

descargas parciais, amostras experimentais ( $C_t$ ), um resistor de  $39\text{ k}\Omega$  e um resistor de alta tensão de  $280\text{ M}\Omega$  e uma impedância de medição ( $Z_m$ ). Os dois resistores são conectados em série e formam um divisor de tensão resistivo. O divisor de tensão serve para monitorar o nível de tensão aplicado a amostra a uma relação de  $1/7180,5\text{ V}$ . Na Figura 18 é apresentada uma foto de uma parcela do citado circuito experimental, na qual podem ser verificados o transformador (componente de maior diâmetro), amostra sob teste (componente mais a esquerda), resistor (componente ao centro) e o capacitor de acoplamento (dispositivo na cor branca).

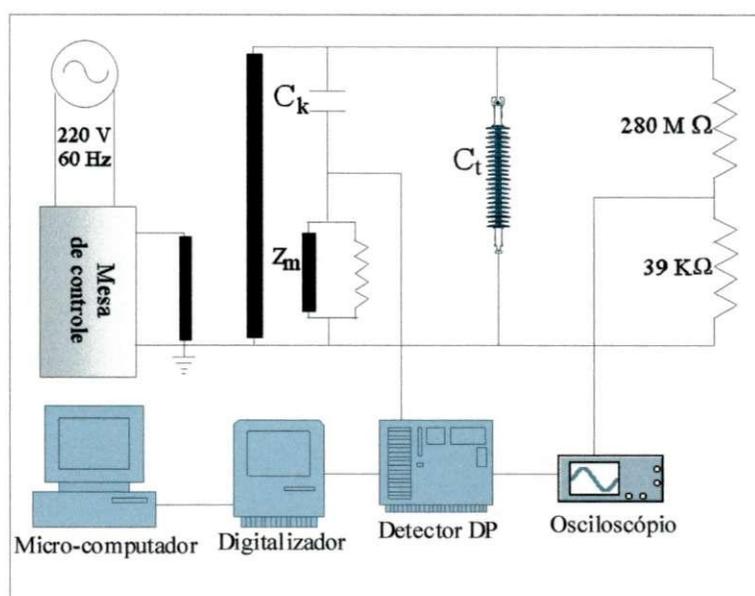


Figura 17 – Circuito experimental para medição de descargas parciais.



Figura 18 - Fotografia do arranjo experimental de detecção de descargas parciais. Fonte: Medeiros (2003).

### 3.4.2.2 Preparação das Amostras

Foram ensaiados isoladores poliméricos utilizados em linhas de transmissão de 69 kV. As avaliações foram feitas em 4 unidades, sendo que uma apresentava total integridade e foi considerada referencial; as demais unidades apresentavam três diferentes tipos de defeitos. Os defeitos descritos e ilustrados na Figura 19 foram basicamente de interface de materiais internos ou superficiais<sup>6</sup>:

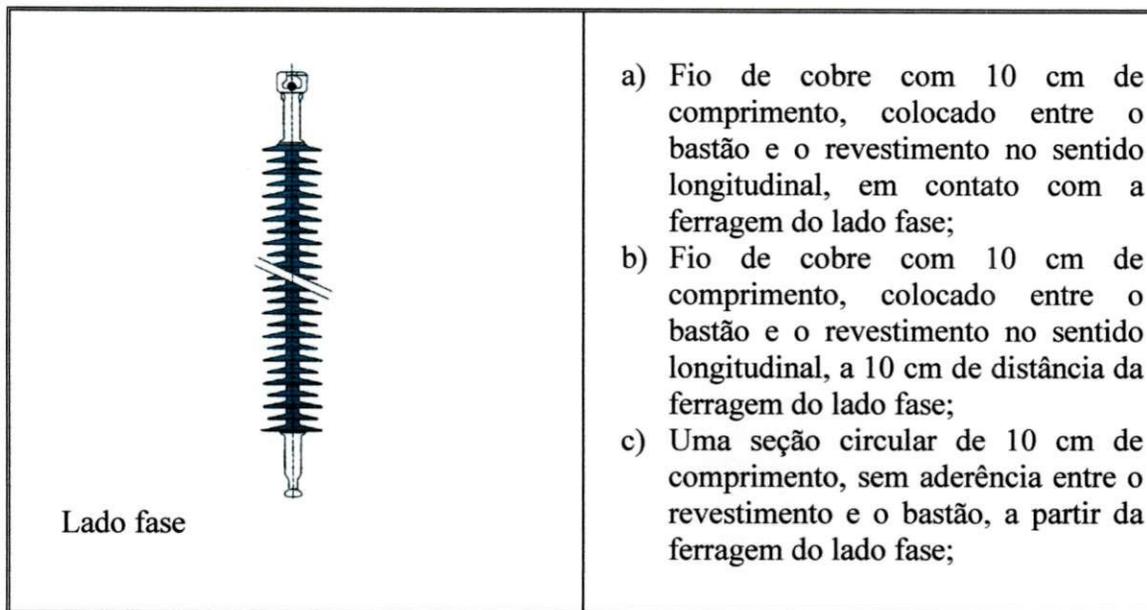


Figura 19 – Indicação e descrição dos defeitos em isoladores poliméricos.

### 3.4.2.3 Procedimento dos Ensaios

Os ensaios elétricos nos isoladores foram realizados em sala blindada. A tensão aplicada atingia, no máximo, valor de  $(69/\sqrt{3}) \times 1,5$  kV. Durante todo experimento foram monitorados os níveis de descargas parciais. Os ensaios tiveram a duração de 120 horas, para cada amostra, quando as tensões aplicadas às amostras e os níveis das descargas parciais foram devidamente registrados. A prescrição de 120 horas de ensaios, associada a uma tensão eficaz 50 % superior, estava direcionada no sentido de submeter o isolador a estresse que redundasse em envelhecimento precoce da unidade.

<sup>6</sup> Esse roteiro de ensaio é parte integrante de projeto de pesquisa e desenvolvimento conduzido em parceria (CEPEL/CHESF/UFCG). As amostras foram devidamente confeccionadas pelo fabricante (ELETROVIDRO).

Na Figura 20 é ilustrada parte da composição do arranjo elétrico para realização dos experimentos, na qual pode ser verificada a inclusão de uma das amostras (isolador polimérico) suspensa por barra horizontal aterrada, a qual está apoiada em colunas isolantes, estando todo o conjunto inserido em sala blindada para aquisição dos sinais de descargas parciais.

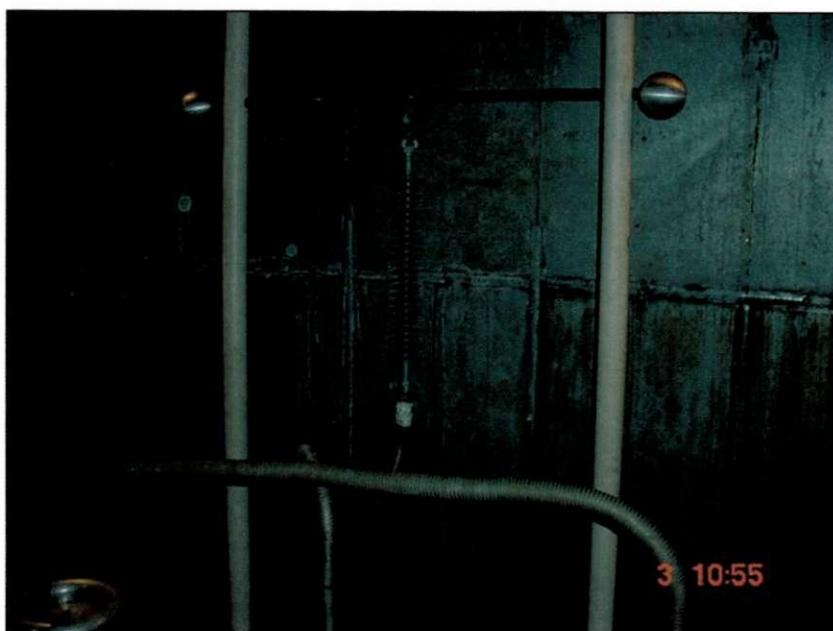


Figura 20 – Ilustração do objeto de ensaio (isolador polimérico).

#### 3.4.2.4 Processamento das Informações

Os sinais extraídos foram submetidos a processamentos preliminares que visaram estabelecer ajustes/sincronizações necessárias à extração dos atributos. Com este objetivo foram registrados, para cada janela de fase, três sinais: tensão aplicada à amostra, descargas parciais ocorridas e a senóide referencial do instrumento de descarga. Nas Figuras 21 e 22 são registradas duas janelas de fase, correspondentes a mais do que um ciclo de tensão, no primeiro caso, e a um ciclo de tensão, no segundo caso, sem sincronização e com sincronização, respectivamente, ilustrando a necessidade de se implementar os ajustes aqui registrados. A não sincronização dos sinais está associada, certamente, a reatâncias internas ao instrumento de medição das descargas que conduziram à necessidade dos ajustes digitais pós-aquisição.

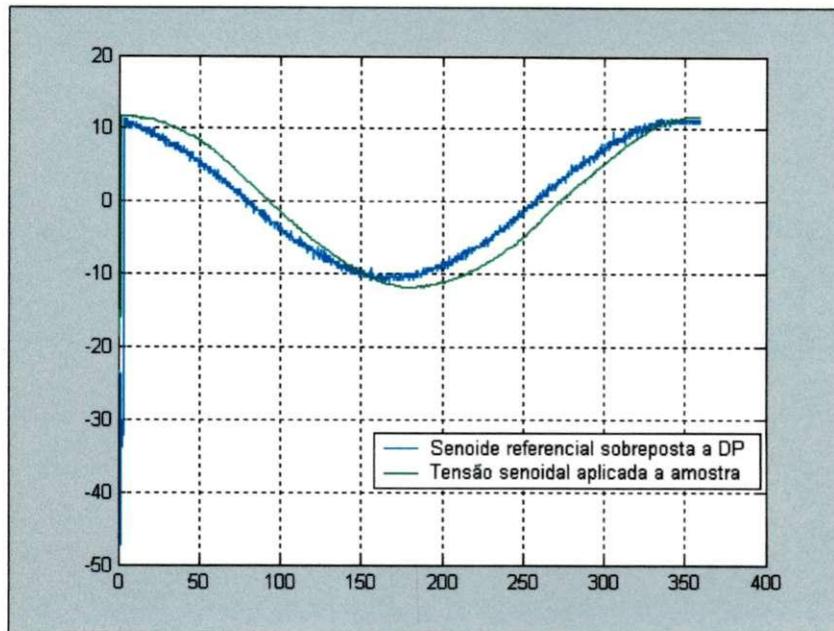


Figura 21 – Sinais “brutos” adquiridos.

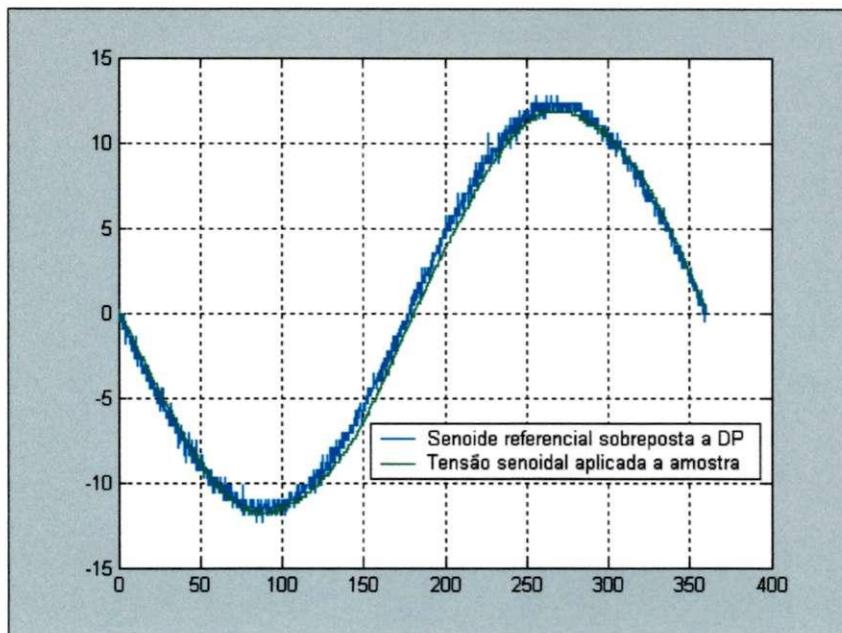


Figura 22 – Janela de fase sincronizada.

Só foram registradas as descargas superiores a 1 % do valor máximo das descargas registradas em cada janela de fase. Para efeito de montagem dos processos de classificação foram extraídas as distribuições das grandezas definidas por Gulski e Kreuger (1992), descritas em 2.2 e relacionadas a seguir.

- Número de descargas em cada semiciclo da tensão aplicada.
- Tensão de início da descarga em cada semiciclo da tensão aplicada.
- Número de descargas por fase (somatório para todos os ciclos de tensão).
- Soma das descargas médias (pC) por fase (somatório para todos os ciclos de tensão).
- Curtose calculada para a distribuição das descargas (integralizada hora a hora), para cada semiciclo.
- Assimetria calculada para a distribuição das descargas (integralizada hora a hora), para cada semiciclo.
- Fator de correlação modificado, integralizado hora a hora.

Para cada uma dessas distribuições foram extraídos os parâmetros estatísticos média e desvio padrão que passaram a constituir os atributos a serem submetidos ao processo de reconhecimento de padrões.

Uma outra alternativa utilizada para montagem dos classificadores levou a formação dos vetores de atributos a partir diretamente do uso das três últimas distribuições, sem o cálculo adicional dos parâmetros média e desvio padrão. Esta alternativa agrega mais valor ao processo de reconhecimento uma vez que as três últimas distribuições já integralizam as anteriores.

É importante enfatizar que as grandezas propostas por Gulski e Kreuger (1992) são construídas em função da análise de diversas “janelas de fase” que representam sinais adquiridos em seqüência, cada um deles representando as descargas parciais registradas ao longo de um ciclo completo da frequência fundamental. Na Figura 23 é ilustrado tal processo, na qual as “janelas de fase” são registradas em seqüência, mas não representam obrigatoriamente senóides contíguas, podendo, portanto, serem espaçadas adequadamente. O algoritmo que permitiu calcular as grandezas, á luz das propostas dos referidos autores contemplou as seguintes etapas, cabendo a ressalva de que toda a metodologia proposta teve que ser adaptada ao caso em análise e à implementação das técnicas de reconhecimento de padrões:

- (1) entrada dos sinais senoidais aplicados às amostras ( $r_{a1} \dots r_{an}$ ) e dos sinais de descarga registrados ( $r_{d1} \dots r_{dn}$ );

- (2) ajuste da sincronização entre os sinais;
- (3) construção dos vetores  $q$  (dimensão da descarga) e  $U$  (valor da tensão aplicada à amostra em que ocorrem descargas), devidamente referenciados pela fase em que ocorrem as descargas, para cada janela de fase;
- (4) cálculo dos vetores  $N_{q+}$  e  $N_{q-}$  (número de descargas em cada semi-ciclo positivo e negativo nas diversas janelas de fase);
- (5) cálculo dos vetores  $H_n^+(\varphi)$  e  $H_n^-(\varphi)$  (número de descargas observadas em cada janela de fase, como uma função do ângulo de fase), como também dos vetores  $H_{qn}^+(\varphi)$  e  $H_{qn}^-(\varphi)$  (amplitude média em cada janela de fase, como uma função do ângulo de fase = número total em cada janela de fase dividida pelo número de descargas na mesma janela);
- (6) cálculo dos operadores estatísticos ( $Q$ ,  $\Phi$ ,  $f_{cc}$ ,  $m_{cc}$ ,  $S_k$ ,  $K_u$ ) descritos no Capítulo 2.

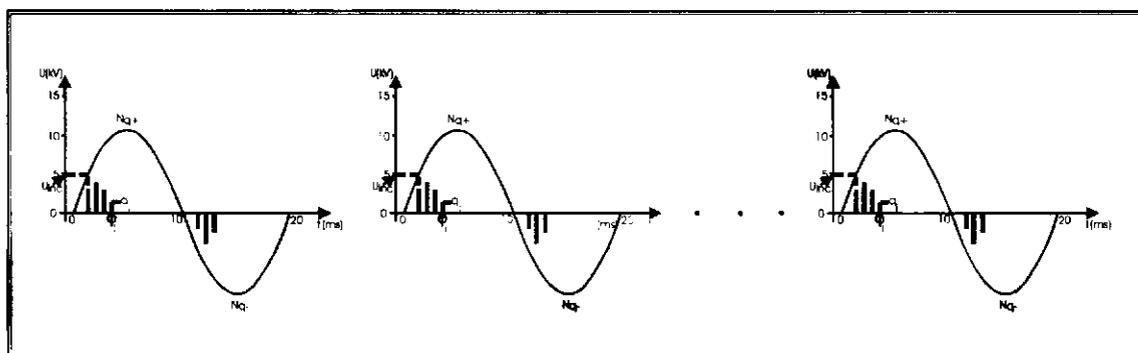


Figura 23 – “Janelas de fase” registradas em seqüência.

Definiu-se quatro classes em consonância com os tipos de defeitos pré-estabelecidos. A classe “0” refere-se à unidade sem defeitos. Adquiriu-se 800 sinais (equivalentes a um ciclo de 60 Hz, cada um deles) para cada amostra ensaiada, ao longo de 4 dias (96 horas). A matriz de atributos que será manipulada para formação dos conjuntos de treinamento foi construída a partir dos vetores de atributos ilustrados na Figura 24, na qual as colunas são compostas pelos atributos extraídos para cada amostra analisada.

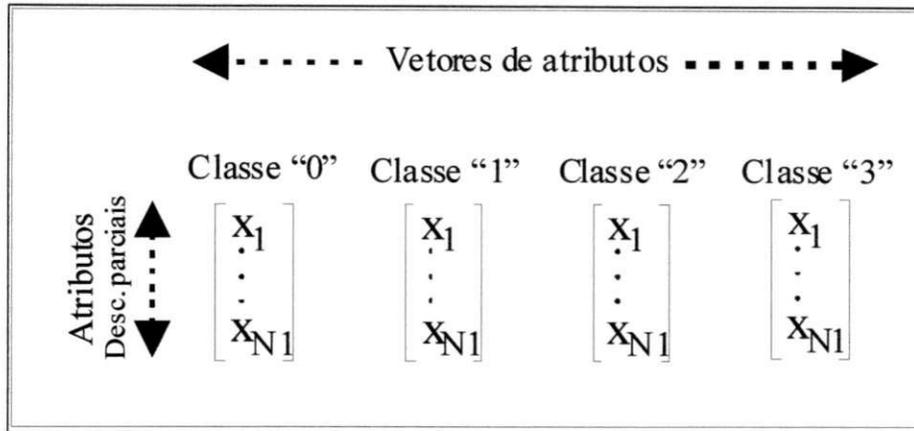


Figura 24 – Vetores de atributos para formação da matriz de atributos.

Toda metodologia descrita neste capítulo e detalhada em anexo, conduziu à construção do alicerce necessário à constituição da base de dados utilizada para a caracterização dos atributos e avaliação das técnicas de reconhecimento de padrões. No Capítulo 4 serão descritos e analisados os resultados alcançados a partir da base de dados construída.

## Capítulo 4: Análise e Discussão dos Resultados.

A partir do estudo dos casos descritos no Capítulo 3 foi possível adquirir sinais que conduziram a aplicação da metodologia apresentada, procurando aplicar as técnicas de processamento digital de sinais associadas às técnicas de reconhecimento de padrões no sentido de viabilizar a caracterização e avaliação de atributos mais significativos para o processo de diagnóstico de defeitos em isolamentos elétricos de alta tensão.

Foram analisados os resultados dos dois estudos de caso apresentados no Capítulo 3. No primeiro deles as análises se concentraram na avaliação do estado de isoladores submetidos à tensão elétrica, níveis de poluição pré-estabelecidos e umidade saturada. Para este caso, o objetivo foi identificar sensores e atributos que apresentassem melhores resultados no processo de classificação dos níveis de poluição presentes. Através dos estudos foi possível estruturar possíveis fusões da base de dados, identificando-se as utilizações múltiplas de instrumentos sensores que introduzissem resultados vantajosos no processo final de diagnóstico, como também explicitar situações em que tais composições conduzissem a resultados técnico-econômico insatisfatórios.

No segundo, a metodologia foi embasada no sentido de identificar a presença de defeitos pré-fabricados em isoladores poliméricos. Tais defeitos foram implementados diretamente por empresa fabricante, tendo-se como base situações resultantes de falhas de montagens industriais e já descritas no capítulo anterior.

Em ambos os casos, os dados foram organizados de tal forma a, inicialmente, conhecer melhor os sinais a serem analisados, para, posteriormente, avaliar os atributos a serem extraídos. Foram realizadas diversas simulações voltadas para avaliar a sensibilidade do processo de classificação aos atributos definidos. A seguir, são apresentados os resultados obtidos, para cada um dos casos, procurando-se estratificá-

los em função do tipo de sinal, sensor e/ou transformada utilizada. É importante já neste momento, registrar que as análises feitas quanto ao aumento no número de faixas do histograma utilizadas como atributos pode conduzir a uma melhora ou piora no desempenho do processo de classificação a depender da distribuição dos valores analisados (corrente, temperatura, etc.).

## **4.1 Caso 1: Poluição em Isoladores**

Para este caso, conforme foi adiantado no Capítulo 3, foram utilizados quatro tipos de sensores: termovisor, sensor de ultra-som, sensor de corrente de fuga e antena de VHF acoplada a analisador de espectro. A seguir os dados adquiridos serão apresentados e analisados, procurando-se, sempre que possível, utilizar as transformadas de Fourier e Wavelet para a extração de atributos específicos. Essas transformadas foram aplicadas aos sinais de ultra-som e corrente de fuga, os quais foram adquiridos diretamente no domínio do tempo, facilitando tais aplicações. Para o sinal de VHF as análises foram realizadas já no domínio da frequência a partir do espectro adquirido diretamente do analisador. Para as imagens térmicas foram feitas avaliações da distribuição da temperatura ao longo da superfície dos isoladores. diante, inclusive, da inércia térmica identificada no domínio do tempo, após 4 minutos decorridos a partir da aplicação da tensão de ensaio.

Os classificadores foram construídos, inicialmente, a partir das técnicas lineares de Fisher e Karhunen-Loève. Os conjuntos de treinamento foram organizados em conformidade com a Tabela 5. Nesta tabela pode ser observado que o conceito de classe se torna mais amplo. Foram atribuídas classes específicas que aglutinam as amostras submetidas aos diferentes níveis de poluição (0; 1; 2; 2'; 3; 4) na ordem apresentada na tabela. Essa forma de montagem dos conjuntos de treinamento permite que o processo de classificação identifique amostras sem poluição das demais amostras (conjunto 1<sup>o</sup>), amostras com poluição até o nível "1", das demais amostras (conjunto 2<sup>o</sup>), amostras com poluição até o nível "2", das demais amostras (conjunto 3<sup>o</sup>), etc. Os classificadores obtidos a partir dos conjuntos de treinamento permitem nortear mais adequadamente ações de manutenção, uma vez que eventuais processos de alarme poderão ser acionados em conformidade com a evolução dos níveis de poluição aferidos.

Tabela 5 – Relação entre classes e conjuntos de treinamento.

Classes		Conjunto de Treinamento
I	II	
0	1; 2; 2'; 3; 4	1 <sup>o</sup>
0; 1	2; 2'; 3; 4	2 <sup>o</sup>
0; 1; 2	2'; 3; 4	3 <sup>o</sup>
0; 1; 2; 2'	3; 4	4 <sup>o</sup>
0; 1; 2; 2'; 3	4	5 <sup>o</sup>

### 4.1.1 Sensor Térmico (termovisor)

Na Figura 25 são apresentados os resultados básicos obtidos a partir das imagens térmicas registradas pelo termovisor, para os níveis extremos de poluição definidos para composição das amostras (sem poluição e com poluição “4”). São apresentadas as imagens térmicas concentradas sobre os níveis mais intensos de temperatura superficial das unidades ensaiadas. A direita de cada imagem térmica são apresentados os histogramas das temperaturas registradas ao longo da superfície do isolador. Verifica-se que, com poluição mais intensa, o histograma registra a presença de temperaturas mais elevadas ao longo da superfície do isolador (espalhamento e deslocamento do histograma para a direita).

Foram definidos dois atributos básicos para caracterizar as imagens térmicas: físicos (diâmetro do círculo  $C_1$  que contorna externamente as maiores intensidades de temperatura e diâmetro do menor círculo  $C_2$  que toca as maiores intensidades de temperatura, conforme ilustra a Figura 25 (b)) e estatísticos (valor médio, desvio padrão e faixas do histograma da distribuição da temperatura ao longo da superfície do isolador). O número de faixas do histograma foi avaliado em conformidade com o percentual de acertos na classificação do estado do isolamento, utilizando-se apenas os atributos térmicos na construção desses classificadores. Na Figura 26 são registrados os casos analisados, na qual o eixo horizontal indica o conjunto de treinamento utilizado e o eixo vertical o percentual de acertos para cada um dos modelos de classificação aplicado. A legenda indica a técnica de classificação linear avaliada e o número de

faixas do histograma, onde KL indica a técnica de Karhunen-Loève e FS a técnica de Fisher. É importante ressaltar que o classificador é obtido em função do conjunto de treinamento e da técnica de classificação utilizada, cada ponto indicado na figura representa um classificador obtido.

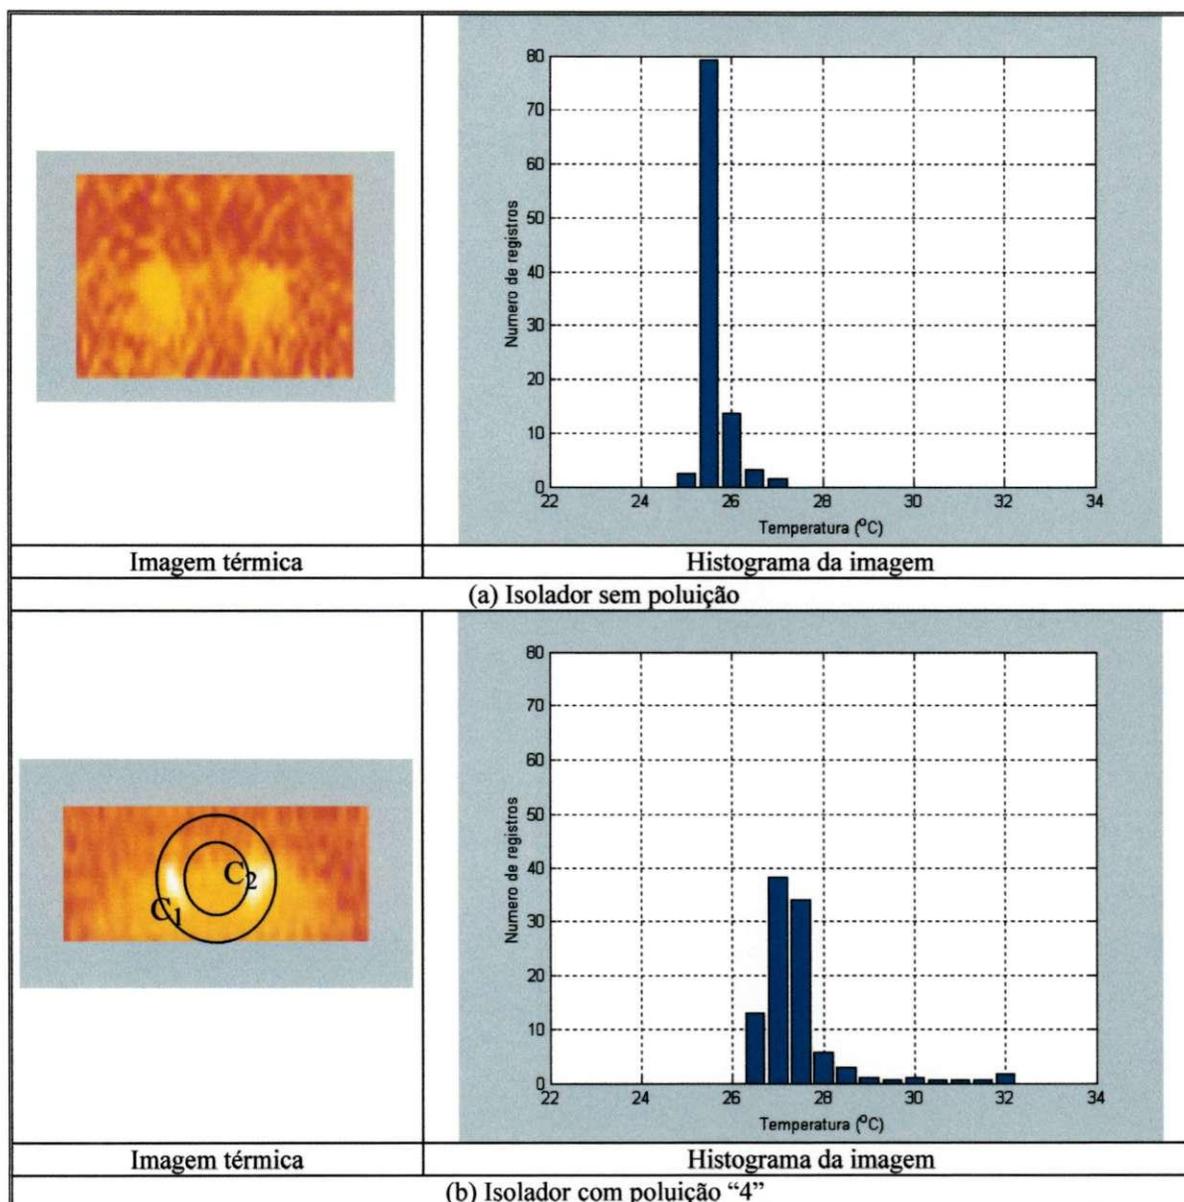


Figura 25 – Apresentação das imagens térmicas e histogramas básicos para cada nível de poluição.

É observado na figura que a utilização do maior número de faixas do histograma (56) melhora o desempenho do classificador a ser construído a partir dos atributos

térmicos indicados, entretanto apresenta saturação em relação a um aumento ainda maior neste número.

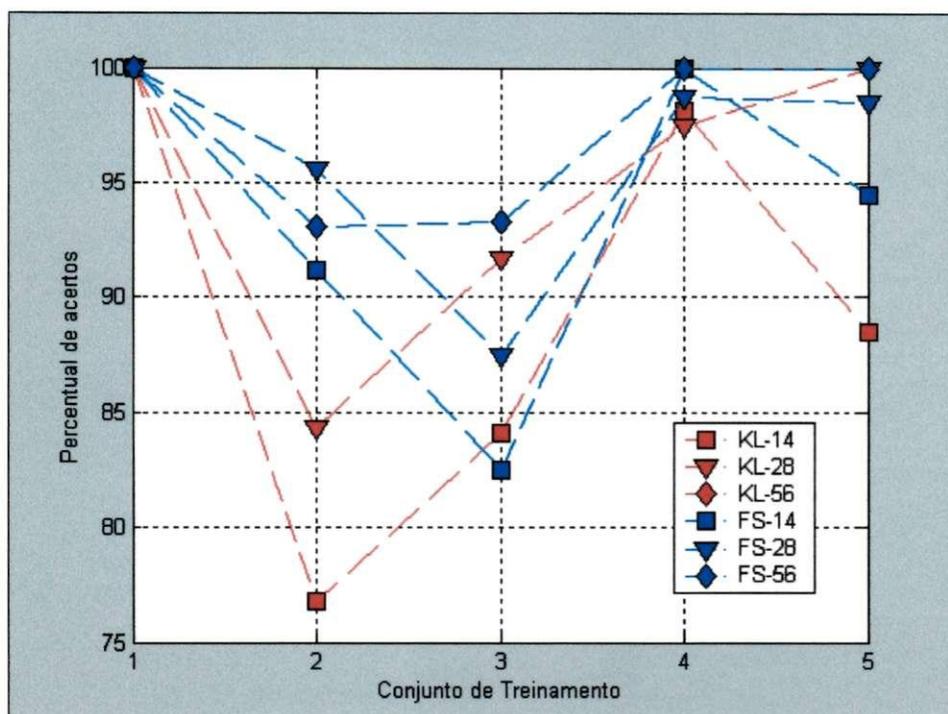


Figura 26 – Desempenho do Classificador, para imagens térmicas, em função do número de faixas do histograma.

Outra observação é que se poderia aplicar ao conjunto de atributos o critério de seleção de Fisher, o qual levaria a eliminar atributos não significativos, atendendo a critérios coadjuvantes de correlação e/ou número de atributos na seqüência indicada na Tabela 6. Tal procedimento não será considerado ao longo do trabalho, entretanto, em aplicações práticas que se deseje diminuir o espaço de atributos e/ou tempos de processamento, a redução indicada pelo critério de Fisher seria recomendada.

Tabela 6 – Aplicação do Critério de Seleção de Fisher ao Conjunto de Atributos Associados a Imagens Térmicas.

Atributo selecionado	Numero de Fisher	Atributo selecionado	Numero de Fisher
F23	1,155147	F28	0,347050
F25	0,918583	F31	0,328372
F39	0,907715	F13	0,306363

Tabela 6 – Aplicação do Critério de Seleção de Fisher ao Conjunto de Atributos Associados a Imagens Térmicas. (continuação)

Atributo selecionado	Numero de Fisher	Atributo selecionado	Numero de Fisher
F24	0,884422	F41	0,267945
F17	0,820741	F20	0,250778
DesvPad	0,794053	F34	0,183900
Media	0,791443	F29	0,180409
DimTerm1	0,751603	F36	0,132866
F16	0,661770	F10	0,129099
F15	0,630452	F9	0,129099
F42	0,622283	DimTerm2	0,127848
F26	0,619869	F30	0,127770
F27	0,604496	F33	0,109719
F43	0,559815	F21	0,101851
F18	0,525021	F38	0,095041
F40	0,516719	F11	0,093486
F22	0,488001	F19	0,044714
F32	0,404334	F12	0,039023
F37	0,381558	F35	0,020650
F14	0,359964		
Atributos que podem ser dispensados			
F56		F49	F7
F55		F48	F6
F54		F47	F5
F53		F46	F4
F52		F45	F3
F51		F44	F2
F50		F8	F1

Os atributos indicados como dispensáveis apresentaram valores idênticos para todas as classes analisadas, não fornecendo, desta forma, nenhuma contribuição para o processo de reconhecimento de padrões.

#### 4.1.2 Sensor de VHF

Na Figura 27 são apresentados os espectros de frequência característicos dos sinais de VHF obtidos para cada um dos experimentos para os níveis extremos de poluição depositada (sem poluição e nível de poluição “4”). É importante registrar que, nesses espectros, encontram-se presentes não apenas os ruídos provenientes das descargas superficiais, mas, também, diversos outros ruídos ambientais além dos sinais das estações de rádio de Campina Grande. No processo de classificação desenvolvido não se procurou eliminar os sinais dessas estações uma vez que as análises comparativas

implícitas ao processo passariam a considerar redundantes as faixas de frequência associadas aos mesmos.

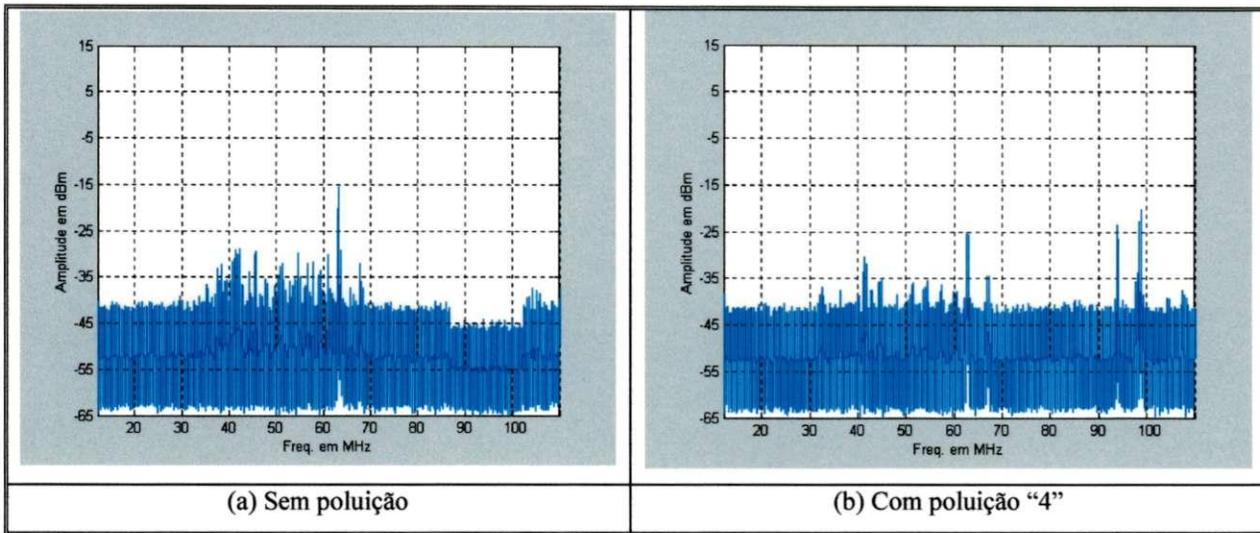


Figura 27 – Espectro de frequência para sinais de VHF típicos.

Na Figura 28 são apresentados os resultados obtidos para classificadores montados utilizando-se apenas atributos extraídos dos sinais de VHF (energia contida por faixa do espectro de frequência).

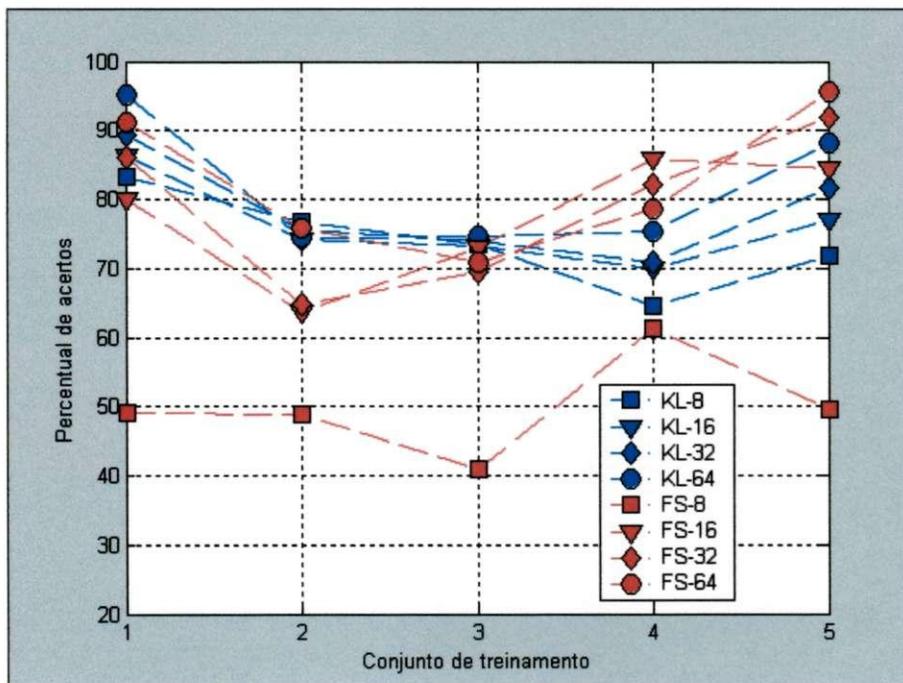


Figura 28 – Desempenho de classificador para sinais de VHF, em função do número de faixas no espectro.

No eixo horizontal, são identificados os conjuntos de treinamento utilizados e, no eixo vertical, o percentual de acertos obtido para cada um dos modelos de classificação aplicado. Foram avaliados números diferentes de faixas do espectro. Pode ser observado que 64 faixas do espectro de frequência levaram a um melhor desempenho do classificador, já com alguma saturação em relação à utilização de número de faixas maiores.

### 4.1.3 Sensor de Ultra-som

Na Figura 29 são apresentados sinais típicos de ultra-som adquiridos para os níveis extremos de poluição depositada. As análises relativas aos sinais de ultra-som foram divididas por domínio e/ou transformada aplicada, conforme são detalhados a seguir.

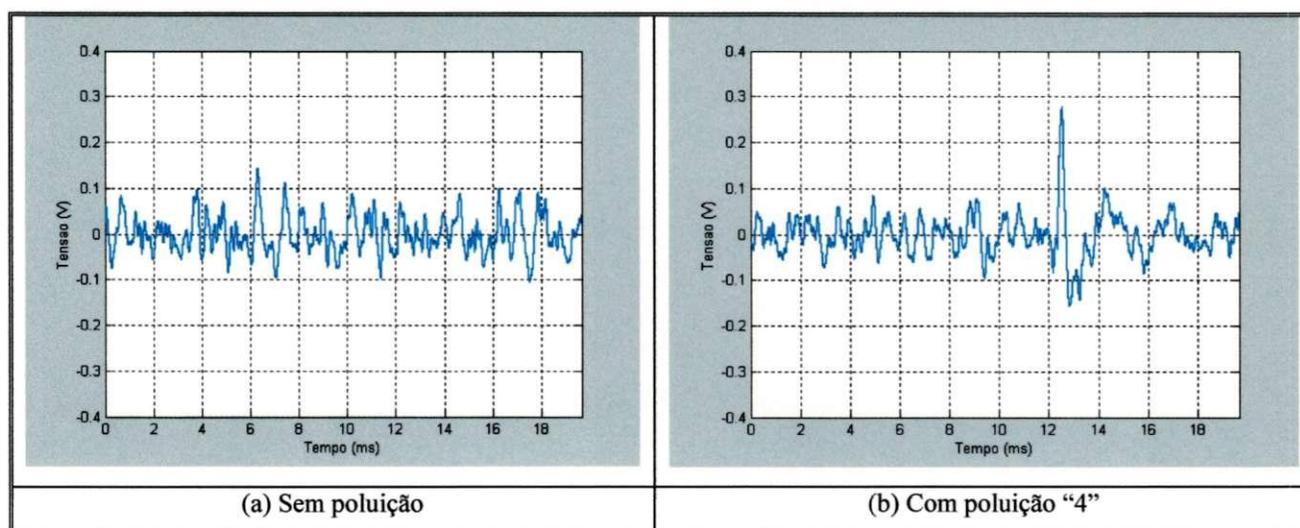


Figura 29 – Sinais típicos de ultra-som para diferentes níveis de poluição.

#### 4.1.3.1 Sinais de Ultra-som no Domínio do Tempo

Os sinais de ultra-som foram pré-analisados através de histogramas conforme ilustrações básicas apresentadas na Figura 30. No domínio do tempo foram extraídos os atributos relacionados na Tabela 2. O número de faixas do histograma foi avaliado em função da construção de classificadores apenas com atributos extraídos dos sinais de ultra-som no domínio do tempo, conforme registros feitos na Figura 31.

Os histogramas construídos permitiram identificar os limites extremos de -0,15 V a 0,15 V de variação da tensão associada aos sinais de ultra-som enfocados. A Figura 31 indica que 60 ou 80 faixas do histograma apresentam os melhores desempenhos no processo de classificação, para os atributos dos sinais de ultra-som no domínio do tempo.

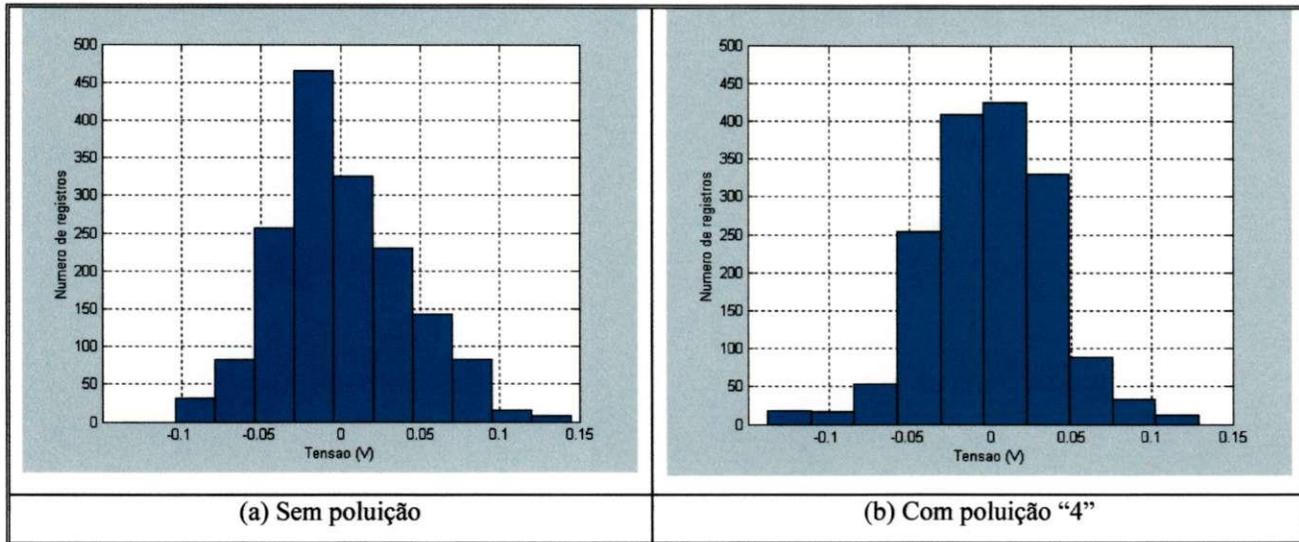


Figura 30 – Histogramas típicos dos sinais de ultra-som no domínio do tempo.

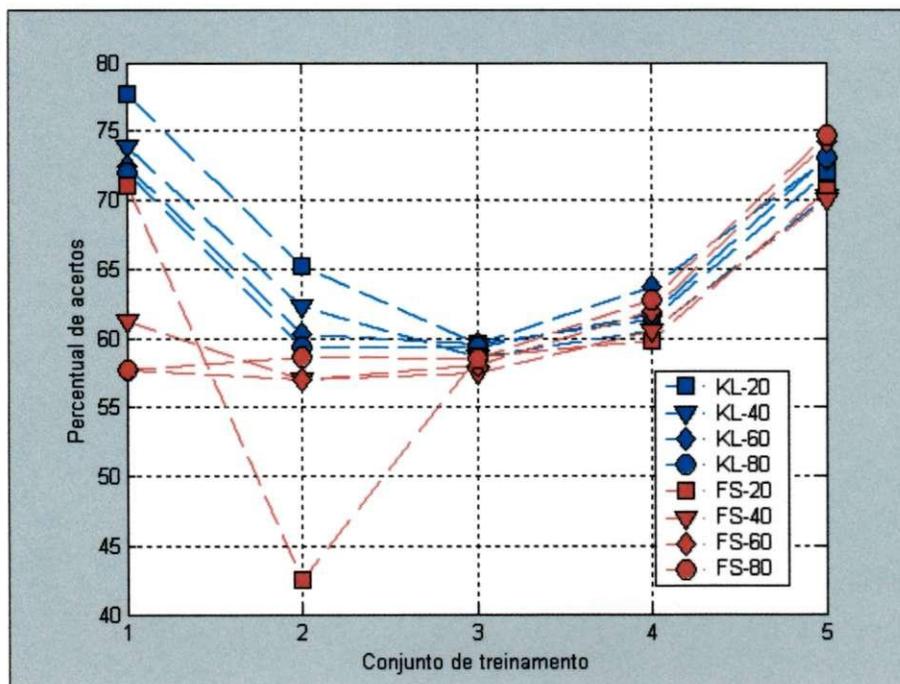


Figura 31 – Classificadores para o sinal de ultra-som no domínio do tempo.

### 4.1.3.2 Sinais de Ultra-som no Domínio da Frequência

No domínio da frequência foram construídas as densidades espectrais de potência ilustradas na Figura 32, de tal forma a direcionar a identificação de atributos.

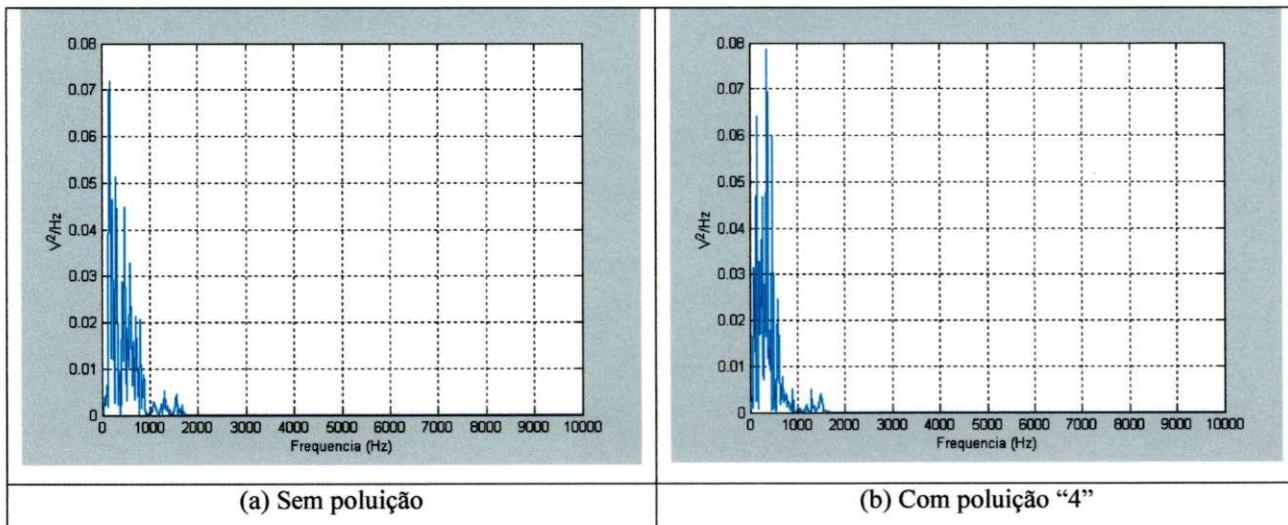


Figura 32 – Densidade espectral de potência para sinais típicos de ultra-som.

O número de faixas da densidade espectral de potência também foi avaliado para constituição de atributos do sinal de ultra-som no domínio da frequência, conforme se encontra ilustrado na Figura 33.

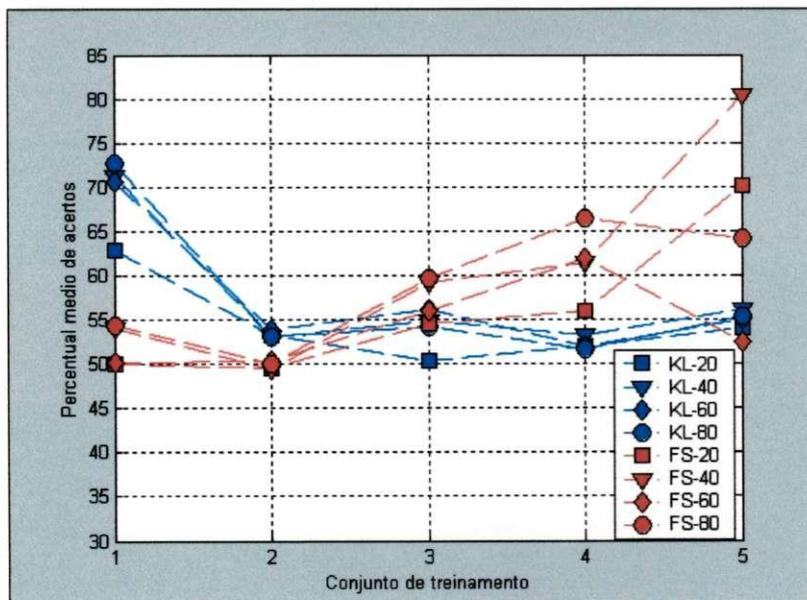


Figura 33 – Avaliação de classificadores para o sinal de ultra-som no domínio da frequência.

### 4.1.3.3 Sinais de Ultra-som. Avaliações a partir das Transformadas Wavelets

A Tabela 7 relaciona os níveis de decomposição obtida para os tipos de wavelet contidos no aplicativo Matlab (20000). Esta tabela foi construída para sinais típicos de ultra-som adquiridos para diferentes níveis de poluição, utilizando-se a limitação de entropia zero, conforme comentários feitos no Anexo.

Tabela 7 – Número de decomposição de sinais típicos de ultra-som.

Wavelet	Decomposição máxima do sinal típico para entropia $\leq 0$					
	Sem Pol.	Pol "1"	Pol "2"	Pol "2L"	Pol "3"	Pol "4"
db1	10	9	9	10	7	10
db2	8	7	7	8	8	8
db3	11	12	11	10	9	9
db4	8	7	7	8	7	8
db5	8	8	7	8	7	9
db6	8	7	8	8	9	9
db7	9	9	7	7	12	9
db8	9	9	8	7	8	9
db9	9	8	7	7	8	9
db10	8	7	7	7	8	8
sym2	8	7	7	8	8	8
sym3	11	12	11	10	9	9
sym4	10	8	8	10	9	9
sym5	9	7	9	9	9	9
sym6	10	8	8	8	9	10
sym7	9	8	8	8	9	9
sym8	9	8	8	8	8	10
dmey	9	9	8	8	9	10
coif1	9	9	9	8	8	8
coif2	9	8	7	8	9	10
coif3	9	8	8	7	8	9
coif4	8	8	7	8	8	9
coif5	9	8	8	7	8	9
bior1.1	10	9	9	10	7	10
bior1.3	9	8	8	9	7	9
bior1.5	9	7	8	8	7	9
bior2.2	8	8	8	8	7	8
bior2.4	8	8	8	8	7	9
bior2.6	9	8	8	8	7	9
bior2.8	9	7	8	7	7	9
bior3.1	6	6	6	6	6	7
bior3.3	7	6	6	6	7	7
bior3.5	7	6	6	7	7	7
bior3.7	7	6	7	6	7	7
bior3.9	7	6	7	6	7	7
bior4.4	8	8	8	8	8	9
bior5.5	9	8	8	9	10	10

Tabela 7 – Número de decomposição de sinais típicos de ultra-som (continuação).

Wavelet	Decomposição máxima do sinal típico para entropia $\leq 0$					
	Sem Pol.	Pol "1"	Pol "2"	Pol "2L"	Pol "3"	Pol "4"
bior6.8	9	7	8	7	7	9
rbio1.1	10	9	9	10	7	10
rbio1.3	9	8	9	9	8	10
rbio1.5	9	7	8	9	9	10
rbio2.2	8	9	8	8	8	9
rbio2.4	9	9	8	9	9	9
rbio2.6	9	8	8	8	8	9
rbio2.8	9	8	8	7	8	9
rbio3.5	8	7	8	7	7	8
rbio3.7	9	7	8	7	7	9
rbio3.9	8	7	8	7	7	9
rbio4.4	9	8	8	8	8	9
rbio5.5	7	6	7	7	8	8
rbio6.8	9	8	8	7	8	9

Na tabela são assinalados em amarelo os níveis de decomposição máxima, os quais foram aplicados para todas as wavelets mãe indicadas, independente do nível de poluição. Este critério possibilitou o atendimento à restrição da "entropia zero" uma vez que o nível máximo de decomposição para cada wavelet passou a ser assumido como sendo o nível mínimo encontrado em cada linha da tabela.

Para cada um dos níveis máximos ressaltados anteriormente foram avaliados os erros de decomposição e reconstituição dos sinais a partir das wavelets relacionadas na Tabela 7. Observou-se que o erro cometido nessa operação é inferior a  $10^{-15}$ , excetuando-se a wavelet "dmey" que apresentou, de forma atípica, um erro de  $2,38 \times 10^{-4}$ .

A título ilustrativo, na Figura 34 são apresentadas decomposições de sinal típico de ultra-som a partir da wavelet "bior3.1". Pode ser verificada a característica da transformada wavelet, na qual, para cada nível de decomposição, os detalhes contidos no sinal original são ampliados, sem perda dos referenciais no domínio do tempo. Para cada decomposição é possível, inclusive, se associar a frequência do sinal decomposto, incorporando, desta forma a característica peculiar tempo x frequência da transformada Wavelet.

Tabela 8 - Avaliação das Wavelets para decomposição de sinais de ultra-som.

20 Faixas		40 Faixas		60 Faixas	
Wavelet	Perc.Acertos	Wavelet	Perc.Acertos	Wavelet	Perc.Acertos
db5	64,10	rbio2.4	66,65	bior1.1	68,96
bior4.4	62,94	rbio1.3	66,07	db1	68,88
bior3.3	62,65	rbio1.1	65,90	rbio1.1	68,47
rbio1.3	62,04	bior1.1	65,87	bior2.2	67,88
rbio2.6	61,92	db1	65,86	bior4.4	67,49
bior5.5	61,71	db5	65,39	rbio1.3	67,25
rbio2.4	61,67	sym6	65,33	rbio2.4	66,62
bior3.1	61,65	bior3.3	65,32	db5	66,57
sym7	61,64	sym5	65,11	bior3.3	66,50
rbio1.5	61,62	db2	65,03	rbio3.1	66,37
bior2.8	61,45	sym2	64,89	sym7	66,17
sym5	61,44	sym7	64,67	sym8	66,14
coif3	61,04	rbio4.4	64,65	sym5	66,07
rbio6.8	60,90	rbio2.6	64,21	sym4	66,02
db1	60,85	bior2.8	64,16	rbio3.3	65,92
db7	60,82	bior6.8	64,07	rbio3.7	65,80
rbio4.4	60,75	bior5.5	63,90	bior3.7	65,60
rbio1.1	60,73	sym8	63,81	coif3	65,58
db4	60,72	bior3.1	63,80	rbio3.5	65,57
db3	60,67	bior3.7	63,78	bior5.5	65,39
sym3	60,67	rbio3.1	63,78	rbio2.2	65,38
bior1.3	60,64	db4	63,61	db3	65,33
rbio2.8	60,63	bior2.2	63,61	sym3	65,33
coif4	60,58	bior4.4	63,53	db6	65,29
bior1.1	60,56	rbio3.7	63,50	sym6	65,23
bior3.7	60,54	rbio1.5	63,44	rbio5.5	65,20
db6	60,52	db10	63,42	rbio2.6	65,17
rbio3.7	60,47	bior3.5	63,31	rbio4.4	65,14
bior2.2	60,44	coif3	63,09	bior1.5	65,03
db10	60,42	sym4	63,06	bior6.8	64,95
db9	60,38	db6	63,05	rbio1.5	64,95
bior1.5	60,37	bior2.6	62,97	bior3.5	64,91
sym8	60,36	db3	62,92	coif1	64,88
bior3.9	60,27	sym3	62,92	db10	64,82
sym6	60,26	coif1	62,89	db2	64,70
bior6.8	60,26	bior3.9	62,87	db4	64,68
bior2.4	60,03	db8	62,58	bior2.8	64,60
rbio3.3	60,03	bior1.3	62,47	bior3.9	64,47
coif2	59,83	coif2	62,45	db7	64,44
rbio3.9	59,83	db7	62,41	bior1.3	64,44
rbio3.1	59,70	rbio3.3	62,31	rbio3.9	64,35
db8	59,60	rbio6.8	62,17	sym2	64,33
bior2.6	59,36	rbio2.8	62,10	bior3.1	64,27
coif1	59,32	bior2.4	62,05	coif2	64,20
coif5	59,28	rbio3.9	61,78	bior2.4	63,90
sym4	59,26	rbio3.5	61,74	rbio6.8	63,72
rbio5.5	59,23	rbio5.5	61,66	bior2.6	63,60
bior3.5	59,01	db9	61,33	rbio2.8	63,48
rbio3.5	58,78	bior1.5	61,28	coif4	63,47

Tabela 8 - Avaliação das Wavelets para decomposição de sinais de ultra-som (continuação).

20 Faixas		40 Faixas		60 Faixas	
Wavelet	Perc.Acertos	Wavelet	Perc.Acertos	Wavelet	Perc.Acertos
db2	58,77	coif4	61,26	coif5	62,99
sym2	58,77	coif5	60,35	db9	62,35
rbio2.2	57,65	rbio2.2	59,81	db8	61,93
dmey	57,13	dmey	57,86	dmey	60,31

O fato da wavelet “dmey” ter apresentado o pior desempenho corrobora os resultados negativos obtidos através desta mesma wavelet, quando foram analisados os erros cometidos na decomposição e recomposição dos sinais. É importante ressaltar que não se deve caracterizar este resultado como demérito para a wavelet “dmey”, a qual pode apresentar excelentes desempenhos para outros tipos de sinais.

#### 4.1.4 Sensor de Corrente de Fuga

Na Figura 36 são apresentados sinais típicos de corrente de fuga, adquiridos em conformidade com os níveis extremos de poluição depositados. As análises relativas aos sinais de corrente de fuga também foram divididas por domínio e/ou transformada aplicada, conforme se detalha a seguir.

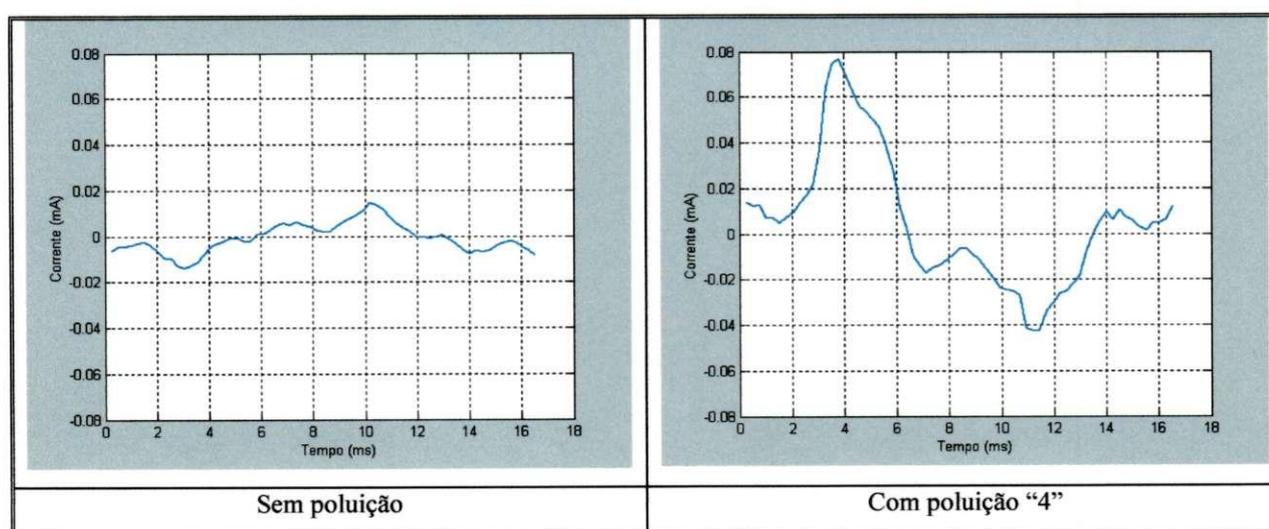


Figura 36 – Sinais típicos de corrente de fuga, com a presença de umidade.

#### 4.1.4.1 Sinais de Corrente de Fuga no Domínio do Tempo

Os sinais de corrente de fuga foram pré-analisados através de histogramas conforme ilustrações básicas apresentadas na Figura 37. Os histogramas construídos permitiram identificar os limites extremos de variação da corrente de fuga.

No domínio do tempo foram extraídos os atributos relacionados na Tabela 2. O número de faixas do histograma foi avaliado em função da construção de classificadores apenas com atributos extraídos dos sinais de corrente de fuga no domínio do tempo, conforme registros feitos na Figura 38. Nesta figura a avaliação foi feita em função do número de faixas do histograma, no que tange ao percentual de acertos de classificação, utilizando-se apenas a corrente de fuga no domínio do tempo para diagnosticar o isolador. Observa-se que o número de 80 faixas apresenta um melhor desempenho, já com alguma saturação presente.

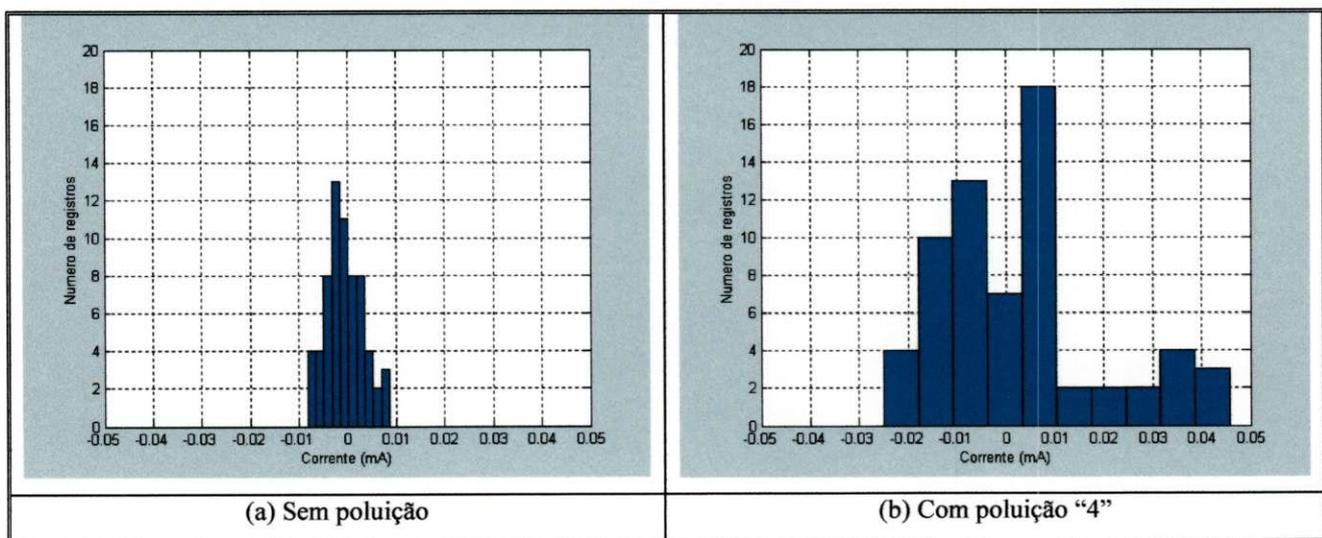


Figura 37 – Histogramas para sinais típicos de corrente de fuga, com presença de umidade.

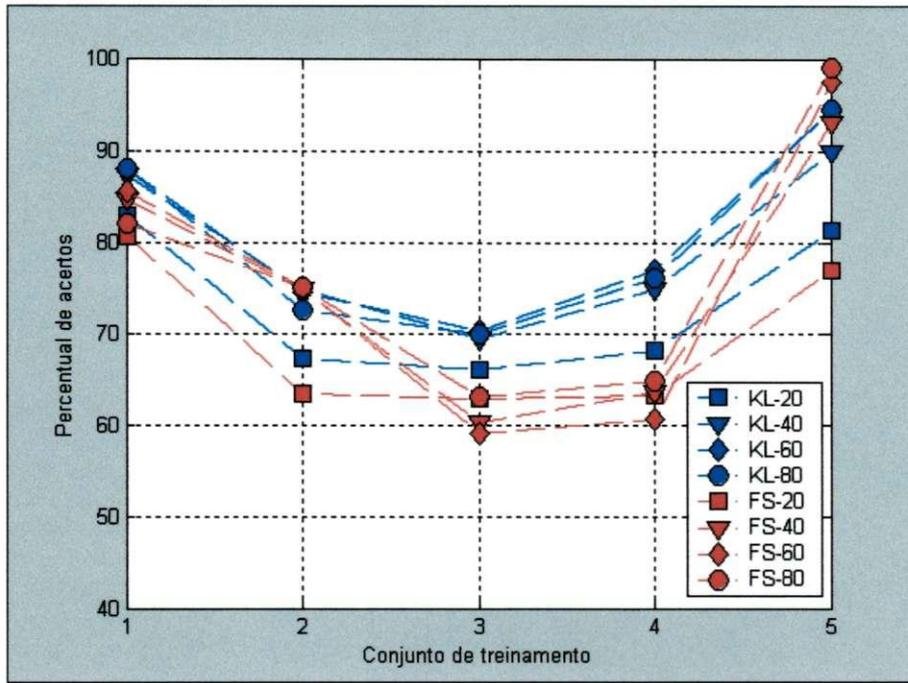


Figura 38 – Avaliação de classificadores para o sinal de corrente de fuga no domínio do tempo.

#### 4.1.4.2 Sinais de Corrente de Fuga no Domínio da Frequência

No domínio da frequência foram construídas as densidades espectrais de potência ilustradas na Figura 39, de tal forma a direcionar a identificação de atributos.

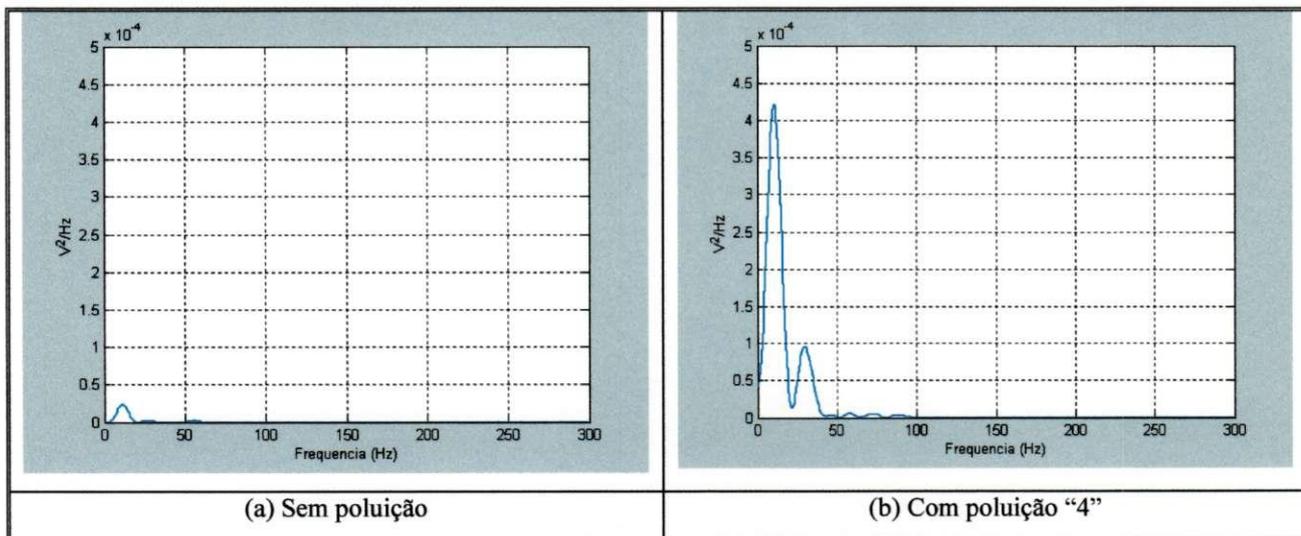


Figura 39 – Densidade espectral de potência para sinais típicos de ultra-som

O número de faixas da densidade espectral de potência foi avaliado para constituição de atributos do sinal de corrente de fuga no domínio da frequência, conforme se encontra ilustrado na Figura 40.

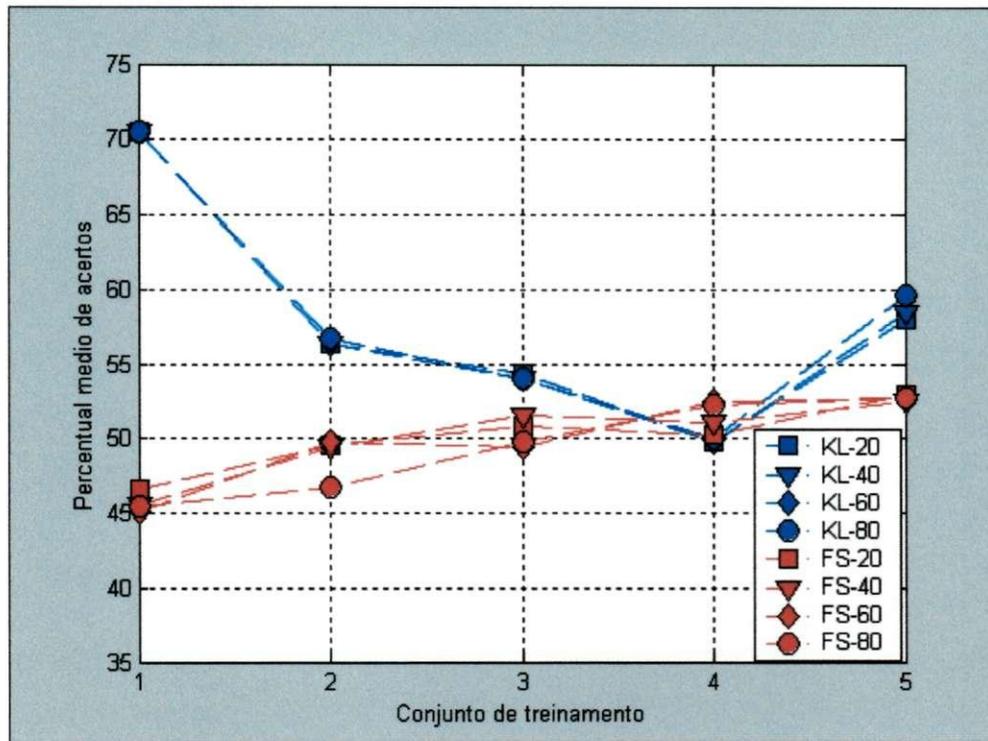


Figura 40 – Avaliação de classificadores para o sinal de corrente de fuga no domínio da frequência.

O classificador construído a partir da utilização de 80 faixas do histograma como atributos apresentou um desempenho melhor do que os demais.

#### 4.1.4.3 Sinais de Corrente de Fuga. Avaliações a partir das Transformadas Wavelets

Foram aplicados os mesmos critérios de decomposição introduzidos para os sinais de ultra-som. Observou-se que para o caso específico de corrente de fuga os níveis máximos de decomposição que atendeu aos critérios definidos anteriormente são todos iguais a dois.

Para cada um dos níveis de decomposição foram avaliados os erros de decomposição e reconstituição dos sinais a partir das wavelets relacionadas na Tabela 7.

Observou-se que o erro cometido nessa operação foi inferior a  $10^{-18}$ , excetuando-se, mais uma vez, a wavelet “dmey” que apresentou, de forma atípica, um erro de  $5,29 \times 10^{-6}$ .

Os histogramas apresentados na Figura 41 para sinais típicos de corrente de fuga, decompostos através de wavelets específicas, permitem aferir os limites extremos para extração de atributos estatísticos associados a faixas de histogramas de sinais de corrente de fuga decompostos.

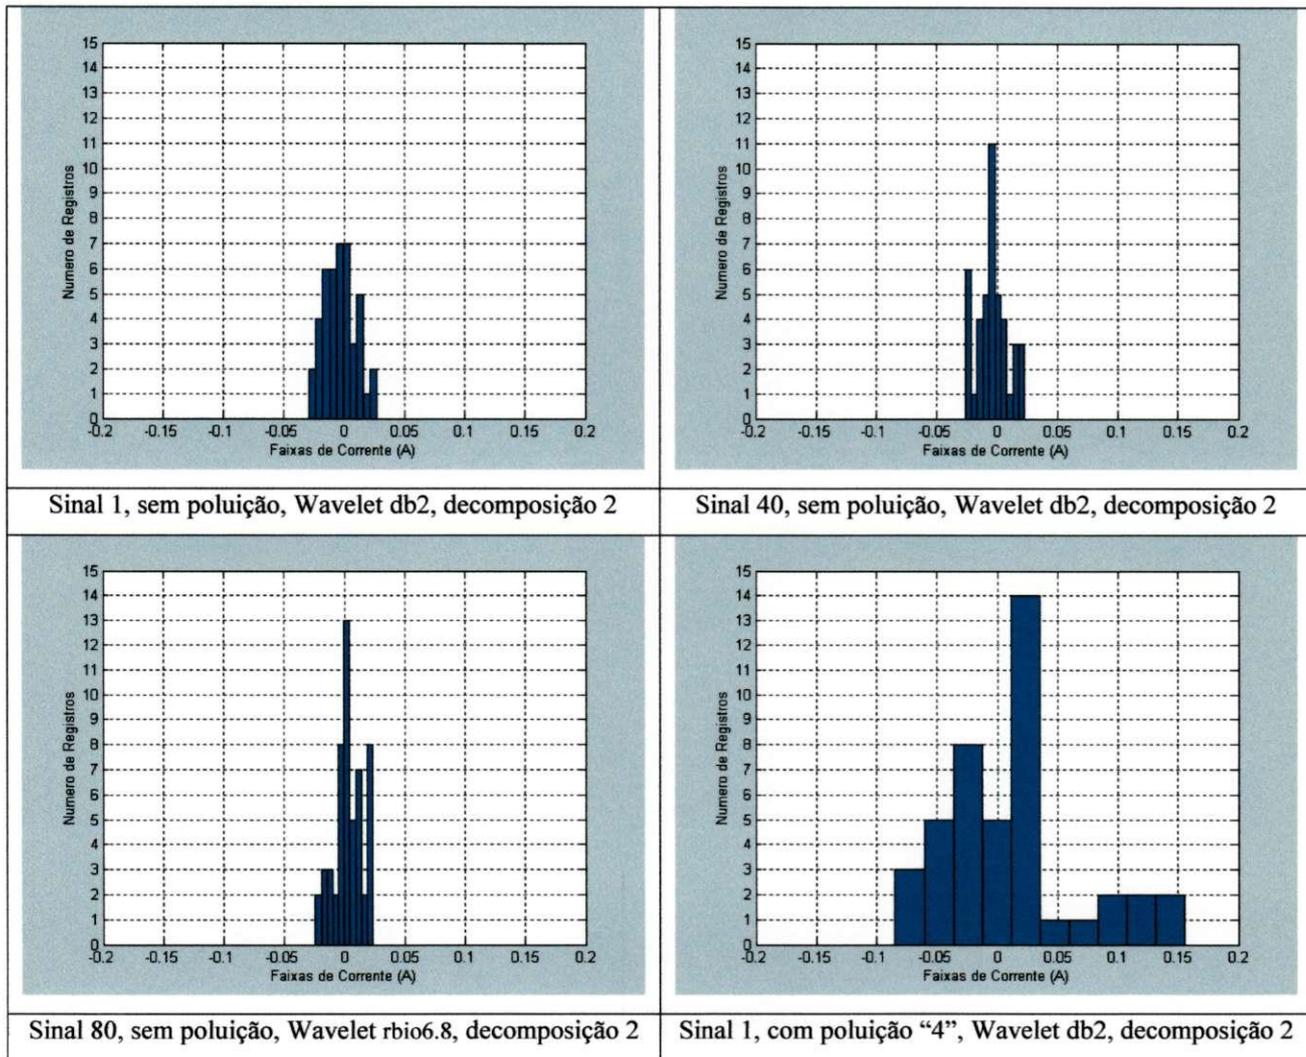


Figura 41 – Histogramas de sinais típicos de corrente de fuga, decompostos por wavelets específicas.

Utilizando-se números diferentes de faixas do histograma e as diversas wavelets disponíveis no aplicativo Matlab (2000), foi construída a Tabela 9, a qual relaciona, em ordem decrescente, o percentual médio de acertos em processo linear de classificação (Fisher e Kahunem-Loève). Nesta tabela, pode ser observado que a wavelet “db6” levou o processo de reconhecimento de padrões a apresentar o melhor percentual de acertos a partir de 60 faixas do histograma. Observa-se que a wavelet mãe “dmey” voltou a apresentar o pior desempenho para todas as opções de número de faixas do histograma, semelhantemente às constatações feitas para os sinais de ultra-som. Verificações similares já haviam sido registradas, também, para o caso da reconstituição dos sinais decompostos, quando a wavelet “dmey” apresentou os maiores erros nesta operação, tanto para os sinais de ultra-som quanto para os sinais de corrente de fuga.

Tabela 9 - Avaliação das Wavelets para decomposição de sinais de corrente de fuga.

20 Faixas		40 Faixas		60 Faixas	
Wavelet	Perc.Acertos	Wavelet	Perc.Acertos	Wavelet	Perc.Acertos
bior1.3	66,77	db2	68,56	db6	68,86
db6	66,48	sym2	68,55	bior1.3	68,77
bior2.2	66,44	rbio4.4	68,43	rbio5.5	67,90
db2	66,35	rbio5.5	67,88	db4	67,89
sym2	66,35	rbio2.4	67,80	bior3.3	67,81
bior3.1	66,30	bior4.4	67,62	bior2.6	67,76
db4	66,27	bior1.3	67,53	rbio3.3	67,76
bior3.3	66,09	bior3.3	67,43	bior2.2	67,70
rbio4.4	66,07	bior2.4	67,25	sym4	67,61
rbio5.5	65,99	rbio3.3	67,19	rbio1.3	67,59
rbio2.4	65,98	db7	67,15	bior3.1	67,47
rbio1.3	65,93	rbio3.1	67,11	bior1.5	67,32
sym4	65,87	bior3.1	67,08	rbio1.5	67,32
db3	65,76	bior3.7	66,95	coif1	67,27
sym3	65,76	rbio1.3	66,91	db7	67,22
coif1	65,74	db1	66,89	rbio4.4	67,20
db9	65,58	bior1.1	66,89	bior3.7	67,16
rbio3.1	65,56	rbio1.1	66,89	coif2	67,15
bior1.5	65,55	bior1.5	66,86	db2	67,01
bior2.6	65,54	bior2.2	66,74	sym2	67,01
db1	65,46	db4	66,67	db8	66,99
bior1.1	65,46	db10	66,66	bior3.9	66,87
rbio1.1	65,46	db6	66,50	db3	66,86
rbio3.3	65,27	rbio1.5	66,44	sym3	66,86
bior3.7	65,13	coif1	66,31	rbio3.1	66,77
rbio1.5	65,11	bior2.6	66,27	bior3.5	66,70
bior4.4	65,09	sym6	66,13	sym8	66,69
bior3.5	65,05	sym3	66,10	rbio2.4	66,67

Tabela 9 - Avaliação das Wavelets para decomposição de sinais de corrente de fuga (continuação).

20 Faixas		40 Faixas		60 Faixas	
SYM6	65,04	DB3	66,09	RBIO2.6	66,63
coif4	65,03	rbio6.8	66,09	bior2.4	66,62
db8	64,97	db5	66,05	sym5	66,58
db7	64,88	rbio2.8	66,00	db1	66,45
db5	64,86	bior5.5	65,98	bior1.1	66,45
coif2	64,86	sym8	65,82	rbio1.1	66,45
sym5	64,77	bior6.8	65,79	sym6	66,44
sym8	64,66	bior3.5	65,76	bior5.5	66,34
bior3.9	64,44	sym4	65,72	db5	66,29
db10	64,33	coif2	65,71	rbio2.2	66,22
bior2.4	64,26	sym5	65,55	sym7	66,21
sym7	64,19	db9	65,53	bior4.4	66,03
rbio2.2	64,12	bior2.8	65,53	db9	66,01
coif5	64,11	db8	65,47	rbio2.8	65,86
coif3	64,07	coif4	65,25	coif3	65,84
bior6.8	64,07	rbio2.2	65,23	rbio6.8	65,83
bior2.8	64,05	bior3.9	65,08	rbio3.7	65,40
rbio6.8	64,01	rbio3.5	64,98	coif4	65,33
rbio3.7	64,00	rbio3.7	64,90	bior6.8	65,16
bior5.5	63,97	sym7	64,83	bior2.8	65,09
rbio3.5	63,61	rbio2.6	64,71	db10	65,03
rbio2.6	63,49	coif3	63,88	rbio3.5	64,91
rbio3.9	63,46	coif5	63,77	rbio3.9	64,33
rbio2.8	63,33	rbio3.9	63,70	coif5	63,83
dmey	62,53	dmey	62,58	dmey	63,54

#### 4.1.5 Avaliação de Classificadores Não Lineares

Com o intuito de identificar o algoritmo de treinamento da rede neural que apresentasse melhor desempenho no processo final de classificação dos dados levantados, foram avaliados diversos algoritmos disponíveis no aplicativo Matlab (2000), conforme relacionados em anexo. O algoritmo de Levenberg-Marquardt apresentou melhor desempenho na classificação dos sinais básicos analisados (termovisor, corrente de fuga, enfocado por domínio, ultra-som, enfocada a transformação wavelet e espectro de frequência obtido através da antena de VHF e analisador de espectro), conforme pode ser verificado nas Tabelas 10 e 11. A representação dos sinais de ultra-som por seus atributos extraídos através da transformada wavelet foi motivada pelo maior percentual de acertos observados nas classificações feitas ao se utilizar técnicas lineares de classificação, conforme será visto adiante. Foram feitas avaliações na dimensão da rede no que tange ao número de

camadas e neurônios por camada, como também quanto às funções de ativação a se utilizar. Nas tabelas são registrados alguns dos melhores resultados obtidos. Na tabela 10 foi avaliada a função de transferência “tansig”.

Tabela 10 – Avaliação de algoritmos de treinamento de redes neurais (duas camadas: um neurônio na primeira e na segunda camada; funções de transferência “tansig” nas duas camadas).

Algoritmo	Iterações					
	Termovisor	Corrente			Som (wavelet)	Espectro
		Tempo	Frequência	Wavelet		
traingd	N	N	N	N	N	N
traingdm	N	N	N	N	N	N
traingda	N	N	N	N	N	N
traincgp	N	N	N	N	N	N
traingdx	N	N	N	N	N	N
trainrp	N	N	N	N	N	N
traincgf	128	N	N	N	209	N
traincgp	91	N	N	N	116	N
traincgb	77	N	N	N	54	N
trainscg	223	N	N	N	N	N
trainbfg	N	N	N	N	N	N
trainoss	88	N	N	N	N	N
trainlm	9	N	N	N	9	N

Observações: N significa que não houve convergência (o número de iterações foi limitado em 300 e foi utilizada a tolerância máxima de  $10^{-5}$  para o erro médio quadrático cometido quando o processo de treinamento da rede procura ajustar os pesos para se obter a informação de saída desejada).

Na Tabela 12 foi avaliada a mesma rede cujos resultados foram apresentados na Tabela 10, utilizando-se agora a função de ativação “logsig”, procurando-se aferir o desempenho dos diversos algoritmos de treinamento.

Tabela 11 – Avaliação de algoritmos de treinamento de redes neurais (duas camadas: um neurônio na primeira e na segunda camada; funções de transferência “logsig” nas duas camadas).

Algoritmo	Iterações					
	Termovisor	Corrente			Som (wavelet)	Espectro
		Tempo	Frequência	Wavelet		
traingd	N	N	N	N	N	N
traingdm	N	N	N	N	N	N
traingda	241	N	N	N	N	N
traingcp	227	N	N	N	239	N
traingdx	243	N	N	N	243	N
trainrp	35	N	N	N	51	N
traingcf	17	N	N	N	61	N
traingcp	13	N	N	N	39	N
traingcb	16	N	N	N	47	N
traingcg	33	N	N	N	59	N
trainbfg	26	N	N	N	63	N
trainoss	51	N	N	N	N	N
trainlm	8	N	N	N	9	8

As mesmas observações quanto à convergência e número de iterações feitas para a Tabela 10 também são válidas para a Tabela 11, lembrando-se que a letra “N” indica que não houve convergência para a tolerância e o número de iterações indicados anteriormente.

A partir da utilização do algoritmo de Levenberg-Marquardt foram construídas as Tabelas 12 e 13, com o intuito de avaliar a dimensão adequada da rede neural e as funções de transferência a serem utilizadas. Os resultados apresentados na tabela 12 foram obtidos a partir da utilização de uma rede com apenas um neurônio na primeira e na segunda camadas.

Tabela 12 – Número de iterações para o algoritmo de Levenberg-Marquardt (um neurônio na primeira e na segunda camada).

Função de transferência		Iterações					
		Termovisor	Corrente			Som (wave.)	Espectro
1ª camada	2ª camada		Tempo	Freq.	Wave.		
tansig	tansig	17	N	N	N	8	N
tansig	purelin	N	N	N	N	10	5
tansig	logsig	N	N	N	N	N	7
logsig	tansig	27	N	N	N	131	N
logsig	purelin	5	N	N	N	12	10
logsig	logsig	N	N	N	N	12	8

Os resultados apresentados Tabela 13 foram obtidos a partir da utilização do mesmo algoritmo de treinamento sobre uma rede com três neurônios na primeira camada e um neurônio na segunda camada.

Tabela 13 – Número de iterações para o algoritmo de Levenberg-Marquardt (três neurônios na primeira e um neurônio na segunda camada).

Função de transferência		Iterações					
		Termovisor	Corrente			Som (wave.)	Espectro
1ª camada	2ª camada		Tempo	Freq.	Wave.		
tansig	tansig	8	N	N	N	N	10
tansig	purelin	7	N	N	N	11	10
tansig	logsig	6	N	N	N	34	N
logsig	tansig	34	N	N	N	9	N
logsig	purelin	17	N	N	N	12	9
logsig	logsig	N	N	N	N	7	12

Observa-se que o uso da função de transferência “logsig” na primeira camada e “purelin” na segunda camada e apenas um neurônio nas duas camadas representa a melhor alternativa no que tange ao maior número de convergências e menor número de iterações, para os casos analisados. Para aferir o desempenho dos demais algoritmos de treinamento, à luz de uma rede com duas camadas, um neurônio em cada camada, utilizando-se a função de transferência “logsig” na primeira camada e “purelin” na segunda camada, foi construída a Tabela 14.

Tabela 14 – Avaliação de algoritmos de treinamento de redes neurais (duas camadas: 1 neurônio na primeira e segunda camadas; funções de transferência “logsig” na primeira camada e “purelin” na segunda camada).

Algoritmo	Iterações					
	Termovisor	Corrente			Som (wavelet)	Espectro
		Tempo	Frequência	Wavelet		
traingd	N	N	N	N	N	N
traingdm	N	N	N	N	N	N
traingda	N	N	N	N	N	N
traingdx	N	N	N	N	N	N
traingrp	N	N	N	N	100	N
traincgf	129	N	N	N	N	N
traincgp	N	N	N	N	153	N
traincgb	46	N	N	N	79	N
trainsicg	72	N	N	N	67	N
trainbfg	24	44	N	N	N	N
trainoss	214	N	N	N	N	N
<b>trainlm</b>	<b>5</b>	<b>N</b>	<b>N</b>	<b>N</b>	<b>12</b>	<b>10</b>

Observa-se que o algoritmo de treinamento “trainlm” obteve melhor desempenho para o conjunto de dados analisados.

### 4.1.6 Análise da Composição de Sinais e Sensores

A composição dos sinais e sensores foi viabilizada através da construção de matrizes que agreguem ordenadamente os vetores de atributos associados a cada sinal e/ou sensor específico. Na Figura 42 são ilustrados esses procedimentos.

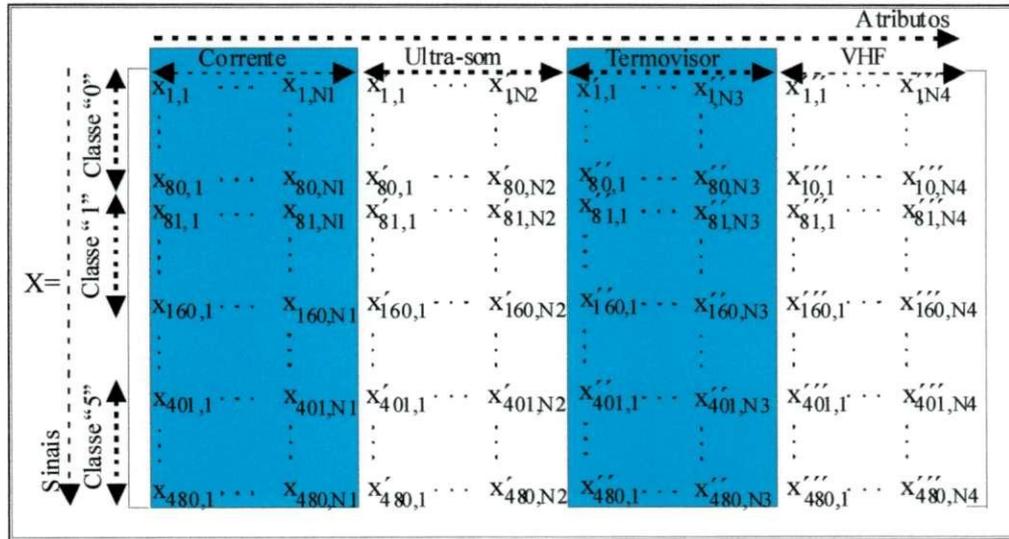


Figura 42 – Visualização da composição da matriz de atributos.

Com o intuito de avaliar o efeito da composição dos sinais e sensores foram feitas análises específicas no que tange a aglutinação dois a dois, três a três e de todos os sensores, avaliando-se, ainda, para o caso dos sinais de corrente de fuga e ultra-som, a composição dos atributos extraídos no domínio do tempo, no domínio da frequência, e através da transformada wavelet. A validade das composições foi aferida através do percentual de acertos dos classificadores lineares e não lineares montados a partir da matriz de atributos composta. Na Tabela 15 são resumidos os resultados obtidos. Para facilitar a leitura da tabela, são descritas adiante as informações contidas em cada uma das colunas:

- Coluna 1 (sensor / domínio): as informações contidas nesta coluna estão relacionadas com os sensores, cujos sinais foram utilizados para construção do classificador; observa-se que, na coluna, encontra-se indicado o domínio

específico objeto das análises; para tanto foram utilizadas as seguintes abreviaturas:

- Espect. – densidade espectral do sinal de VHF, obtido a partir da composição “antena / analisador de espectro”;
  - Term. – imagem térmica obtida a partir do termovisor;
  - Corr. – sinal de corrente de fuga;
  - Som – sinal de ultra-som;
  - Tempo – sinal analisado no domínio do tempo;
  - Freq. – sinal analisado no domínio da frequência;
  - Wave – sinal decomposto através da transformada Wavelet.
- 
- Coluna 2 (Dimensão) : estão indicadas as dimensões do espaço de atributos, quando se utiliza o sinal que se encontra indicado na coluna 1 para construção do classificador; observa-se que o primeiro número (6) está associado com a quantidade de amostras ensaiadas; o segundo (80) indica a quantidade de sinais adquiridos para cada amostra e o terceiro está associado com a quantidade de atributos extraídos do sinal ou sinais indicados na coluna 1.
  - Coluna 3 (Acertos): nesta coluna estão indicados os percentuais médios de acerto para cada modelo linear utilizado (Fisher ou Karhunen-Loève).
  - Coluna 4 (Modelo não linear): nesta coluna estão registrados os percentuais médios de acerto obtidos a partir da utilização da rede neural de duas camadas, um neurônio na primeira e segunda camadas, funções de transferência “logsig” na primeira camada e “purelin” na segunda camada e algoritmo de treinamento de Levenberg-Marquardt; estão registrados, também, o número de iterações para se obter o percentual médio de acertos e o erro médio quadrático ( $\sum dif^2$ ) cometido quando o processo de treinamento da rede procura ajustar os pesos para se obter a informação de saída desejada.

Tabela 15 - Resumo dos resultados obtidos (todas as composições).

Sensor / domínio	Dimensão	Acertos - modelo linear (%) (*)		Modelo não linear (**)		
		Fisher	K.Loève	Acertos (%)	$\sum \text{dif}^2$	Nº iterações
Espect.	6x80x64	82,4	81,5	96,7	$3,10 \times 10^{-02}$	35
Term.	6x80x60	96,9	96,1	100,0	$3,50 \times 10^{-06}$	8
Corr. (tempo)	6x80x88	76,8	80,2	84,4	$1,26 \times 10^{-01}$	20
Corr. (freq.)	6x80x21	50,1	57,8	70,4	$1,99 \times 10^{-01}$	20
Corr. (wave.)	6x80x68	67,0	70,4	73,5	$1,80 \times 10^{-01}$	10
Corrente	6x80x177	79,4	80,4	96,3	$3,60 \times 10^{-02}$	50
Som (tempo)	6x80x88	62,5	65,0	60,4	$2,39 \times 10^{-01}$	10
Som (freq.)	6x80x41	60,9	57,7	75,8	$1,74 \times 10^{-01}$	20
Som (wave.)	6x80x68	67,6	70,1	66,0	$2,24 \times 10^{-01}$	8
Som	6x80x197	63,4	67,1	86,0	$1,21 \times 10^{-01}$	20
Corr. X Espect.	6x80x241	91,8	91,0	100,0	$2,14 \times 10^{-06}$	8
Corr. X Som	6x80x374	75,9	79,5	97,3	$1,61 \times 10^{-02}$	10
Corr. X Term.	6x80x237	95,3	93,5	100,0	$2,25 \times 10^{-06}$	4
Som X Espect.	6x80x261	79,4	78,1	95,6	$4,12 \times 10^{-02}$	10
Som X Term.	6x80x257	89,1	88,2	100,0	$2,66 \times 10^{-06}$	8
Term. X Espect.	6x80x124	98,7	98,7	100,0	$5,16 \times 10^{-06}$	6
Corr. X Som X Espect.	6x80x438	86,4	87,7	99,8	$2,07 \times 10^{-03}$	5
Corr. X Som X Term.	6x80x434	90,9	90,1	97,9	$2,04 \times 10^{-02}$	20
Corr X Term X Espect.	6x80x301	98,2	98,1	100,0	$4,13 \times 10^{-06}$	10
Som X Term. X Espect.	6x80x321	94,6	94,6	100,0	$3,26 \times 10^{-06}$	4
Corr. X Som X Term. X Espect.	6x80x498	95,7	95,7	100,0	$2,55 \times 10^{-06}$	3

Uma leitura da primeira linha da Tabela 15, por exemplo, permite obter as seguintes informações: os classificadores foram construídos para a densidade espectral do sinal de VHF obtido a partir da composição “antena / analisador de espectro”; a dimensão do espaço de atributos resultante foi 6 x 80 x 64 (6 amostras de isoladores com diferentes níveis de poluição depositada, 80 sinais adquiridos para cada amostra e 64 atributos extraídos para cada sinal), cujas citações e avaliações foram feitas anteriormente; foram obtidos 82,4 e 81,5 como percentuais de acertos ao se aplicar os modelos de Fisher e Karhunen-Loève, respectivamente; a aplicação do modelo não linear conduziu ao percentual de 96,7 % de acertos, com erro médio quadrático de  $3,10 \times 10^{-2}$ , após 35 iterações.

Verifica-se na Tabela 15 que a aglutinação dos atributos de ultra-som extraídos através da transformada Wavelet com os atributos extraídos nos domínios do tempo e da frequência apresentaram queda no desempenho. Esta queda pode estar associada à sensibilidade do instrumento a ruídos no ambiente que foram minimizados através da transformada Wavelet, por intermédio de suas características de ressaltar variações dos

sinais, diferentemente dos sinais brutos aferidos no domínio do tempo e da frequência. A Tabela 16 foi construída para explicitar os valores que permitam reavaliar as composições anteriores, considerando agora que o sinal de ultra-som passou a ser representado apenas pelos atributos extraídos através da transformada Wavelet.

Tabela 16 -Resumo dos resultados obtidos (composições apenas com a transformada wavelet do sinal de ultra-som).

Sensor / domínio	Dimensão	Acertos - modelo linear (%) (*)		Modelo não linear (**)		
		Fisher	K.Loève	Acertos (%)	$\sum \text{dif}^2$	Nº iterações
Espect.	6x80x64	82,4	81,5	96,7	$3,10 \times 10^{-02}$	35
Term.	6x80x60	96,9	96,1	100,0	$3,50 \times 10^{-06}$	8
Corrente	6x80x177	79,4	80,4	96,3	$3,60 \times 10^{-02}$	50
Som (wave.)	6x80x68	67,6	70,1	66,0	$2,24 \times 10^{-01}$	8
Corr. X Espect.	6x80x241	94,0	94,0	100,0	$2,14 \times 10^{-06}$	8
Corr. X Som	6x80x245	81,8	80,8	74,2	$1,91 \times 10^{-01}$	20
Corr. X Term.	6x80x237	89,9	92,1	100,0	$2,25 \times 10^{-06}$	4
Som X Espect.	6x80x132	84,8	82,5	99,4	$6,21 \times 10^{-03}$	10
Som X Term.	6x80x128	97,4	96,9	98,9	$1,02 \times 10^{-02}$	23
Term. X Espect.	6x80x124	98,7	98,7	100,0	$5,16 \times 10^{-06}$	6
Corr. X Som X Espect.	6x80x309	92,7	91,3	100,0	$5,23 \times 10^{-06}$	8
Corr. X Som X Term.	6x80x305	95,8	93,6	93,7	$5,72 \times 10^{-02}$	10
Corr X Term X Espect.	6x80x301	98,2	98,1	100,0	$4,13 \times 10^{-06}$	10
Som X Term. X Espect.	6x80x301	98,9	98,6	100,0	$7,44 \times 10^{-06}$	6
Corr. X Som X Term. X Espect.	6x80x369	98,4	98,0	50,0	$2,50 \times 10^{-01}$	5

Observações:

- (\*) – foi considerada a média dos valores obtidos para cada um dos conjuntos de treinamento (1, 2, ..., 5);
- (\*\*) – com o intuito de simplificar a construção da tabela, registrou-se, apenas, os resultados obtidos para o conjunto de treinamento 3, o qual conduziu a menores percentuais de acerto, quando utilizados os modelos lineares;

Observa-se nesta tabela que houve uma melhora significativa nas novas composições. Por outro lado, é apontado na tabela que, apesar da melhor composição observada, a utilização conjunta de sensores para monitorar o fenômeno da poluição nem sempre é vantajosa. Em alguns casos aumenta-se significativamente a dimensão do espaço de atributos sem uma correspondente melhora no desempenho do processo de diagnóstico. Essas situações encontram-se ressaltadas na própria tabela, registrando-se em números vermelhos as composições desvantajosas e em números verdes as composições vantajosas. A título de exemplo verifica-se que a composição do sensor de corrente de fuga e termovisor conduziu a uma situação desvantajosa uma vez que o

percentual de acertos conjuntos (89,9 e 92,1) passou a ser menor do que quando da utilização do termovisor em separado (96,9 e 96,1). Em um outro exemplo, a composição do termovisor (term.) e VHF foi vantajosa, uma vez que o percentual de acertos conjunto (98,7 e 98,7) passou a ser maior do que quando os sensores diagnosticaram em separado (82,4 e 81,5 para o sensor de VHF e 96,9 e 96,1 para o termovisor).

Na tabela é observado, também, que a utilização de modelos não lineares pode conduzir a percentuais de acerto ainda maiores do que os obtidos para os modelos lineares. Entretanto, em alguns casos, sombreados na tabela, os modelos não lineares podem não convergir para determinadas tolerâncias definidas. É possível que outros modelos venham a superar especificamente determinados problemas de não convergência apontados na tabela.

Uma outra observação importante visualizada nesta tabela é que as melhores composições observadas foram entre os sensores de ultra-som, termovisor e VHF (espect). Mais importante ainda é que esses sensores são não invasivos, contrariamente aos sensores de corrente de fuga, fato que representa uma contribuição significativa aos processos de diagnóstico diante de sua relevância prática.

#### **4.1.7 Validação dos Modelos**

A validação dos modelos foi implementada através dos sinais adquiridos quando dos experimentos em laboratório. Naquela ocasião foram adquiridos 100 sinais utilizando-se os sensores de corrente de fuga, ultra-som e VHF para cada uma das amostras, sendo que 80 sinais foram processados para comporem o conjunto de treinamento e 20 sinais ficaram reservados para comporem o conjunto de teste que viabilizaram a fase de validação. Registra-se aqui que para o caso do termovisor foram adquiridas apenas 20 imagens térmicas para cada amostra, face à inércia térmica observada que implicaria em redundâncias desnecessárias caso fosse adquirido um número maior de imagens. Essas 20 imagens foram utilizadas tanto para o conjunto de treinamento quanto para o conjunto de testes.

Portanto, a partir do conjunto de treinamento foram construídos os classificadores que tiveram os respectivos desempenhos aferidos através dos valores constantes nas

Tabelas 15 e 16, anteriormente apresentadas. Os classificadores obtidos foram submetidos ao conjunto de testes (20 sinais adicionais obtidos para cada amostra) que compuseram a denominada fase de validação.

A validação foi realizada procurando-se aferir o percentual de acertos dos classificadores construídos para cada uma das composições enfocadas anteriormente, sendo que se optou por utilizar, para os sinais oriundos do sensor de ultra-som, apenas os atributos extraídos através da transformada Wavelet, diante dos melhores resultados obtidos, conforme já foi comentado. A validação foi, ainda, subdividida de tal forma a aferir o comportamento dos classificadores diante da presença de eventuais ruídos ambientais adicionais detectados pelos sensores de ultra-som e corrente de fuga. Na Tabela 17 são apresentados os resultados obtidos sem a simulação de ruídos adicionais, onde, na coluna treinamento, encontram-se transcritos os percentuais de acerto obtidos na fase de treinamento dos classificadores.

Tabela 17 - Validação dos Resultados (sem simulação de ruídos).

Sensor / domínio	% de acertos			
	Treinamento		Validação	
	Fisher	K.Loève	Fisher	K.Loève
Espect.	82,4	81,5	78,7	79,7
Term. (*)	96,9	96,1	96,5	96,4
Corrente	79,4	80,4	81,9	78,5
Som (wave.)	67,6	70,1	56,9	57,7
Corr. X Espect.	94,0	94,0	85,5	84,6
Corr. X Som	81,8	80,8	81,6	79,1
Corr. X Term. (**)	89,9	92,1	96,2	92,6
Som X Espect.	84,8	82,5	78,7	79,4
Som X Term. (**)	97,4	96,9	96,5	96,4
Term. X Espect.	98,7	98,7	97,8	97,4
Corr. X Som X Espect.	92,7	91,3	87,1	85,0
Corr. X Som X Term. (**)	95,8	93,6	92,3	92,3
Corr X Term X Espect (**)	98,2	98,1	97,9	96,0
Som X Term. X Espect. (**)	98,9	98,6	99,0	97,2
Corr. X Som X Term. X Espect. (**)	98,4	98,0	98,1	96,0

Observações:

- (\*) a validação desse classificador foi feita com o próprio conjunto de treinamento, servindo apenas para testar a rotina de validação;
- (\*\*) essas validações ficaram parcialmente prejudicadas pelo mesmo motivo;
- os percentuais de acerto são valores médios para todas as amostras analisadas.

Observa-se na tabela que, de uma forma geral, houve uma boa aderência entre os resultados obtidos através do conjunto de treinamento e os obtidos a partir do conjunto de teste. Registra-se, também, que a validação ficou parcialmente prejudicada pelo pequeno número de imagens térmicas obtidas, entretanto, a inércia térmica observada quando da realização dos ensaios, certamente não conduziria a disparidades nos resultados registrados na tabela, caso fossem seqüencialmente registradas outras imagens.

Para implementação do novo processo de validação foram adicionados sinais de ruído aos sinais de ultra-som e corrente de fuga originais. Para tanto foram simulados os sinais de ruído com componentes senoidais e amplitudes aleatórias, apresentados a seguir.

- Ruídos de ultra-som

$$r_s = 10^{-2} (\text{sen}(2\pi \times 200t) + \text{sen}((2\pi \times 520t)) + c\eta(t)), \quad (15)$$

na qual:

$r_s$  = sinal de ruído de ultra-som simulado (V);

$t$  – tempo (s);

$c\eta(t)$  - componente de amplitude variável aleatoriamente no tempo (V).

- Ruídos de corrente de fuga:

$$r_f = 10^{-2} (\text{sen}(2\pi \times 50t) + \text{sen}((2\pi \times 120t)) + c\eta_f(t)), \quad (16)$$

na qual:

$r_f$  = sinal de ruído de ultra-som simulado (A);

$t$  – tempo (s);

$c\eta_f(t)$  - componente de amplitude variável aleatoriamente no tempo (A).

Nas Figuras 43 e 44 são apresentadas composições típicas dos sinais de ultra-som e corrente de fuga com simulação dos ruídos formulados anteriormente.

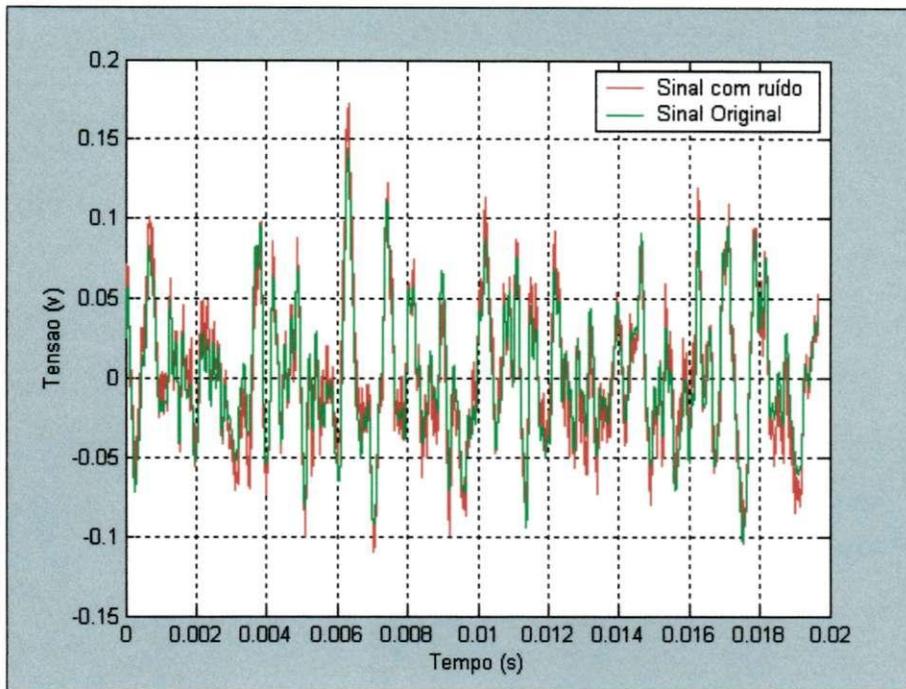


Figura 43 – Sinal de ultra-som com simulação de ruídos.

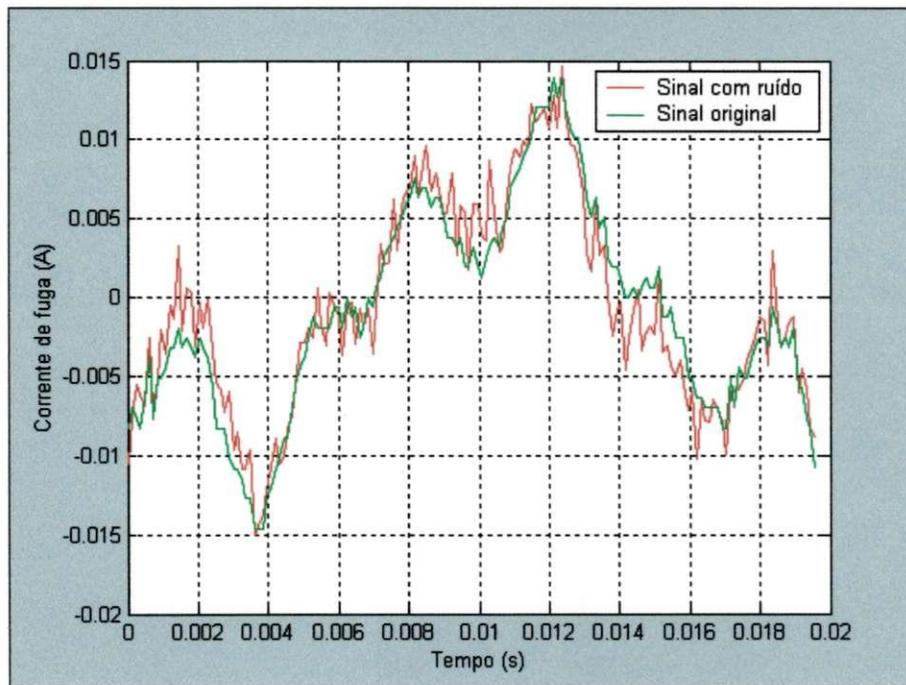


Figura 44 – Sinal de corrente de fuga com simulação de ruídos.

Na Tabela 18 são apresentados os resultados dos diversos classificadores construídos.

Tabela 18 - Validação dos Resultados (com simulação de ruídos).

Sensor / domínio	% de acertos			
	Treinamento		Validação	
	Fisher	K.Loève	Fisher	K.Loève
Espect.	82,4	81,5	82,4	81,5
Term.	96,9	96,1	96,9	96,1
Corrente	79,4	80,4	52,7	52,8
Som (wave.)	67,6	70,1	58,2	56,2
Corr. X Espect.	94,0	94,0	69,4	79,0
Corr. X Som	81,8	80,8	52,9	54,3
Corr. X Term.	89,9	92,1	88,5	96,9
Som X Espect.	84,8	82,5	76,9	79,0
Som X Term.	97,4	96,9	96,5	96,4
Term. X Espect.	98,7	98,7	97,8	97,4
Corr. X Som X Espect.	92,7	91,3	71,8	77,5
Corr. X Som X Term.	95,8	93,6	89,0	96,6
Corr X Term X Espect	98,2	98,1	97,4	97,7
Som X Term. X Espect.	98,9	98,6	98,0	97,4
Corr. X Som X Term. X Espect.	98,4	98,0	97,3	97,7

Nesta tabela se encontram assinalados em vermelho os casos em que os classificadores apresentaram queda acentuada de desempenho. Pode-se inferir que a queda observada está associada à presença dos ruídos simulados. Por outro lado, a composição com outros sinais que não foram corrompidos através de ruídos, e são imunes aos ruídos inseridos, mantiveram o desempenho esperado em relação ao treinamento inicialmente realizado.

#### 4.1.8 Perspectivas Operacionais dos Classificadores.

Com o intuito de se visualizar a implementação operacional dos classificadores em sistemas de transmissão de energia elétrica, foram enfocados dois pontos do sistema CHESF, nos quais as inspeções rotineiras com termovisor acusavam níveis discrepantes da temperatura superficial das cadeias de isoladores indicativos da manifestação de descargas superficiais motivadas pela presença de poluição sobre o dielétrico. O primeiro ponto foi observado na Subestação de Natal, operando em 230 kV. A inspeção de campo foi realizada às 18:30, do dia 14/12/2003, quando a umidade relativa e a temperatura ambiente eram 74% e 28°C, respectivamente. Essas informações seriam importantes para efeito de comparações e ajustes, quando de aferições em laboratório. Na Figura 45 se encontra registrada a imagem térmica captada na ocasião. Pode se

observar a cadeia de isoladores aquecida, principalmente no lado fase, onde a temperatura máxima atingia  $42,1^{\circ}\text{C}$ .

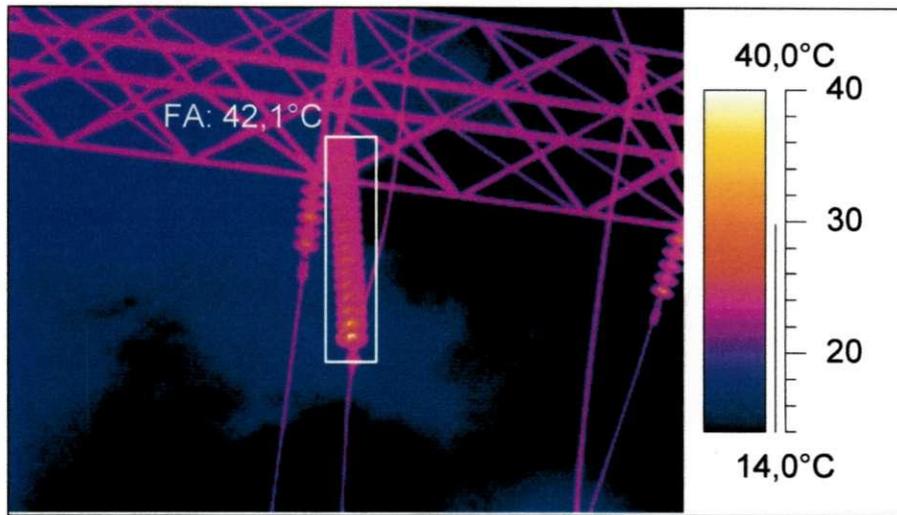


Figura 45 – Imagem térmica de cadeia de isoladores na subestação de Natal.

O segundo ponto foi registrado na estrutura N<sup>o</sup> 93/3 da Linha de Transmissão Santa Cruz – Natal, operando em 230 kV. A inspeção de campo foi realizada às 18:00 do dia 10/09/2003, quando a umidade relativa era de 73% e a temperatura ambiente de  $22,5^{\circ}\text{C}$ . Na Figura 46 encontra-se registrada a imagem térmica obtida, onde se observa que a temperatura na superfície do dielétrico atingia  $30,4^{\circ}\text{C}$ .

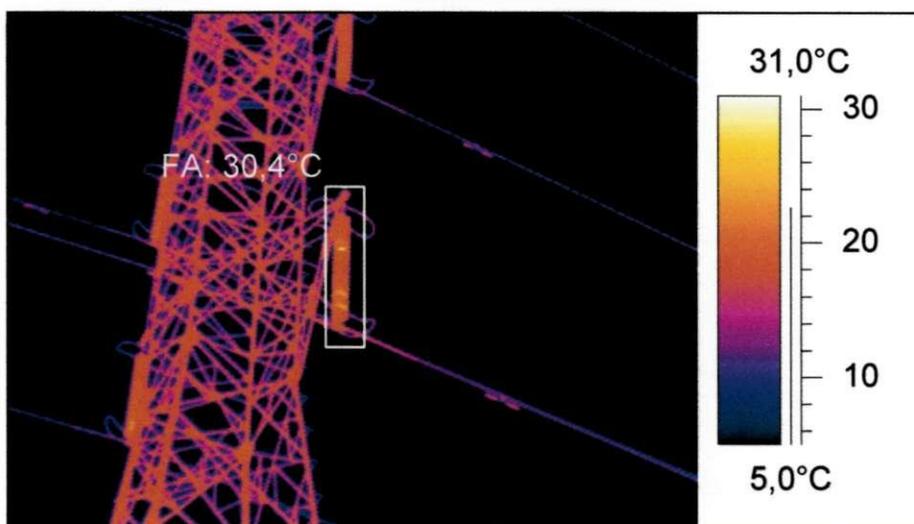


Figura 46 - Imagem térmica de cadeia de isoladores na Linha de Transmissão de 230 kV Santa Cruz – Natal.

Para aferição do estado dos isoladores através dos classificadores descritos anteriormente seriam realizados, inicialmente, ensaios químicos com o intuito de identificar o nível real de ESDD contido na superfície das unidades retiradas do campo. Para cada um dos locais do sistema de transmissão seriam escolhidas duas unidades para os ensaios químicos em conformidade com a IEC (1991).

Utilizando-se duas unidades retiradas de cada um dos locais seriam realizados ensaios elétricos no laboratório de alta tensão, quando as mesmas seriam submetidas à tensão de 14 kV e umidade saturada. 100 sinais de corrente de fuga, ultra-som e ruídos de VHF e 20 imagens térmicas seriam registrados para cada par de unidades ensaiadas.

Nesta etapa seria utilizado algoritmo específico de aferição, no qual o processo de classificação seria já implementado com um enfoque operacional, utilizando-se, gradativamente, os cinco classificadores para cada um dos casos e técnicas analisadas, levando a identificação do estado da poluição a indicações similares à analógica, conforme ilustra a Figura 47. Através deste enfoque, em uma aplicação prática, o processo de classificação poderia ser adaptado para disparar sistemas de alarme, quando a poluição atingisse níveis específicos de poluição preocupante em relação ao risco operacional do sistema de transmissão.

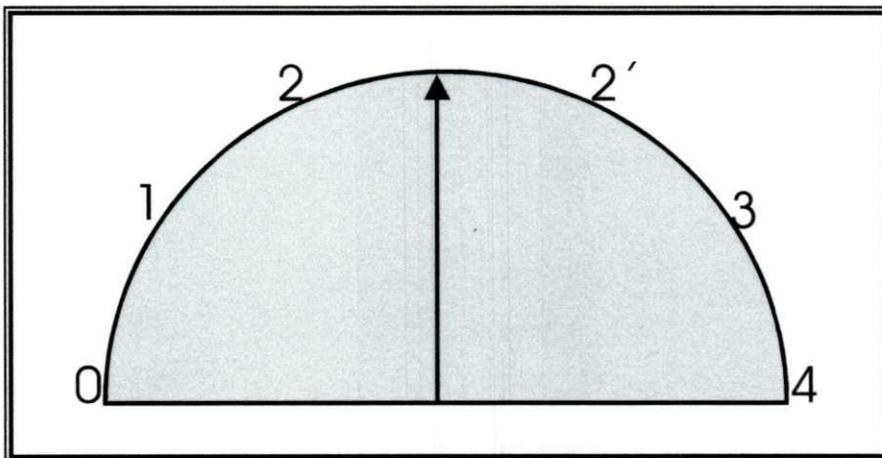


Figura 47 – Visualização operacional do processo de classificação.

O fluxograma apresentado na Figura 48 procura ilustrar o processamento que seria utilizado para construir a visualização operacional citada; atendendo às seguintes etapas:

- leitura do sinal monitorado;
- extração de atributos e normalização em relação ao desvio padrão de cada vetor de atributos constituinte do conjunto de treinamento;
- inicialização de contador associado ao classificador, na ordem indicada na Tabela 19;

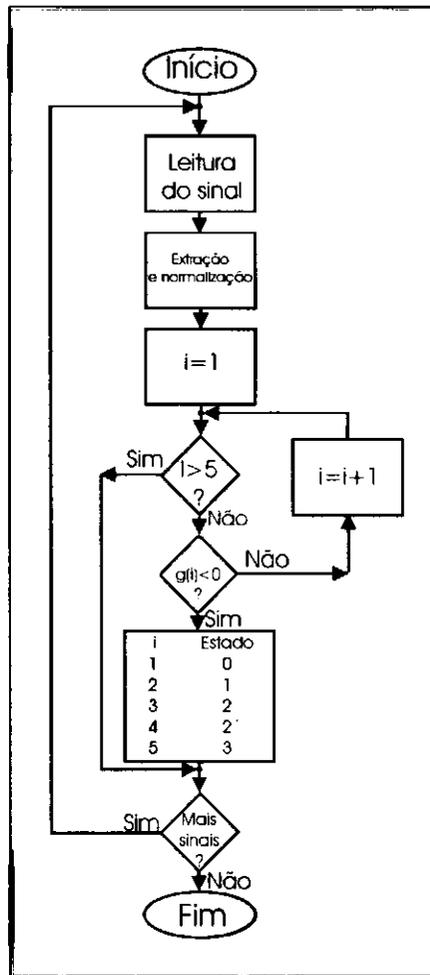


Figura 48 - Fluxograma para visualização operacional do processo de classificação.

Tabela 19 – Identificação da ordem dos classificadores.

Ordem	Classificador
1	(0)/(1,2,2',3,4)
2	(0,1)/(2,2',3,4)
3	(0,1,2)/(2',3,4)
4	(0,1,2,2')/(3,4)
5	(0,1,2,2',3)/(4)

- se o contador for maior que cinco procede-se nova leitura de sinal
- procede-se o teste da função discriminante  $g(i)$  em relação a zero: caso  $g(i) \leq 0$  o estado do isolamento estará associado à Tabela 20:

Tabela 20 – Estado do isolamento.

i	Estado (classe)
1	0
2	1
3	2
4	2'
5	3

Caso  $g(i) > 0$ , o contador  $i$  é incrementado e retorna-se ao passo IV.

1. O processo é interrompido, quando não houver mais sinais para monitorar.

A título de exemplo, na Figura 49 encontra-se ilustrada a evolução da indicação do estado operacional de um possível isolador retirado da linha de transmissão ou monitorado em tempo real, a partir de 100 sinais de corrente de ultra-som, avaliados sequencialmente, utilizando-se classificador construído em função de atributos extraídos a partir da transformada Wavelt, utilizando-se o enfoque acima mencionado, onde o nível 2 retrata o diagnóstico feito a partir dos ensaios químicos ou nível de poluição operacionalmente aceito. Nesta figura se observa o registro do nível “-1”. Esta indicação representa a situação de níveis “desconhecidos” que levariam o processo de reconhecimento a não emitir diagnóstico, conforme ilustrações conceituais apresentadas na Figura 64 do Anexo. Para cálculo do percentual de acertos esses casos seriam deduzidos do número total de sinais analisados.

Na Tabela 21 é apresentado o modelo de resultados que poderiam ser obtidos a partir do enfoque aqui mencionado.

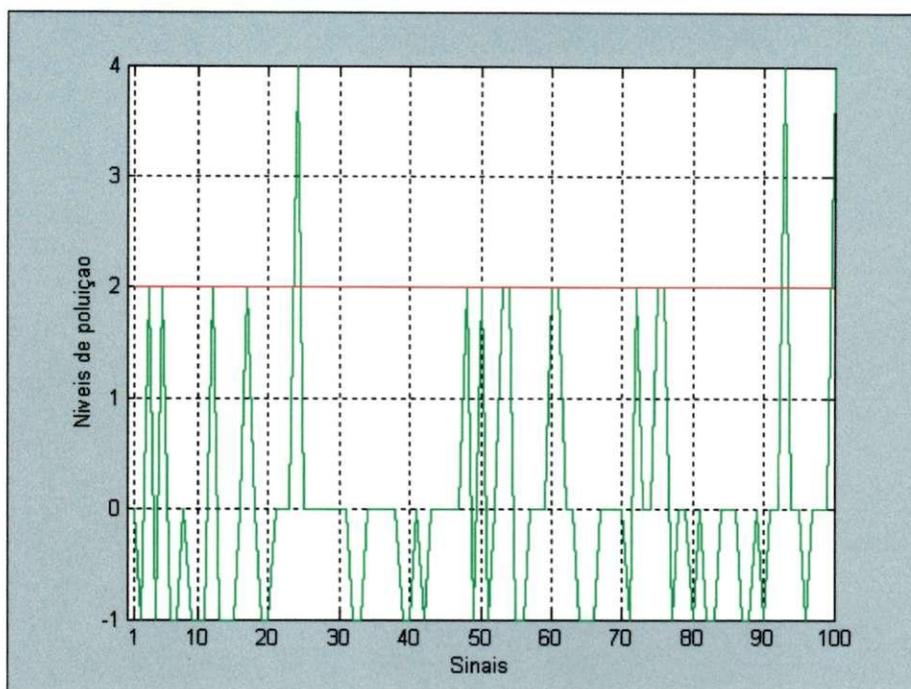


Figura 49 – Evolução da indicação dos níveis de poluição.

Tabela 21 – Avaliação operacional dos classificadores (ilustração).

Sensor / domínio	Unidades LT		Unidades SE	
	Classif. (%)	Acertos (%)	Classif. (%)	Acertos (%)
Espect.	*	*	*	*
Term.	*	*	*	*
Corrente	*	*	*	*
Som (wave.)	81	100	67	95,5
Corr. X Espect.	*	*	*	*
Corr. X Som	*	*	*	*
Corr. X Term.	*	*	*	*
Som X Espect.	*	*	*	*
Som X Term.	*	*	*	*
Term. X Espect.	*	*	*	*
Corr. X Som X Espect.	*	*	*	*
Corr. X Som X Term.	*	*	*	*
Corr X Term X Espect	*	*	*	*
Som X Term. X Espect.	*	*	*	*
Corr. X Som X Term. X Espect.	*	*	*	*

Através das análises realizadas na fase operacional ora descrita se poderia incorporar, inclusive, o seguinte procedimento: os casos levantados em campo que levassem o processo de diagnóstico a cometer erro deveriam ser incluídos no conjunto

de treinamento para que fossem realizados refinamentos na construção dos classificadores.

### **4.1.9 Avaliação do Estudo**

Em uma análise global desse estudo de caso foi possível identificar a validade da aplicação de técnicas de reconhecimento de padrões para dar suporte ao diagnóstico do estado do isolamento aéreo de sistemas de transmissão de energia. Observou-se que a utilização de sensores aplicados isoladamente ou em composição conduziu a percentuais de acerto no diagnóstico em torno de 90 %, o que representa uma constatação de cunho prático significativo.

## **4.2 Caso 2: Defeitos em Isoladores Poliméricos**

A extração dos atributos definidos por Gulski e Kreuger (1992) e descritos em 2.2 permite aplicar as técnicas de reconhecimento de padrões já delineadas anteriormente. Os atributos estarão diretamente associados às seguintes distribuições:

- Número de descargas em cada semiciclo da tensão aplicada.
- Tensão de início da descarga em cada semiciclo da tensão aplicada.
- Número de descargas por fase (somatório para todos os ciclos de tensão).
- Soma das descargas médias (pC) por fase (somatório para todos os ciclos de tensão).
- Curtose calculada para a distribuição das descargas (integralizada hora a hora), para cada semiciclo.
- Assimetria calculada para a distribuição das descargas (integralizada hora a hora), para cada semiciclo.
- Fator de correlação modificado, integralizado hora a hora.

### **4.2.1 Resultados Obtidos**

As Figuras 50 a 52 apresentam as evoluções das três últimas distribuições para duas amostras ensaiadas, ao longo dos quatro dias de experimento.

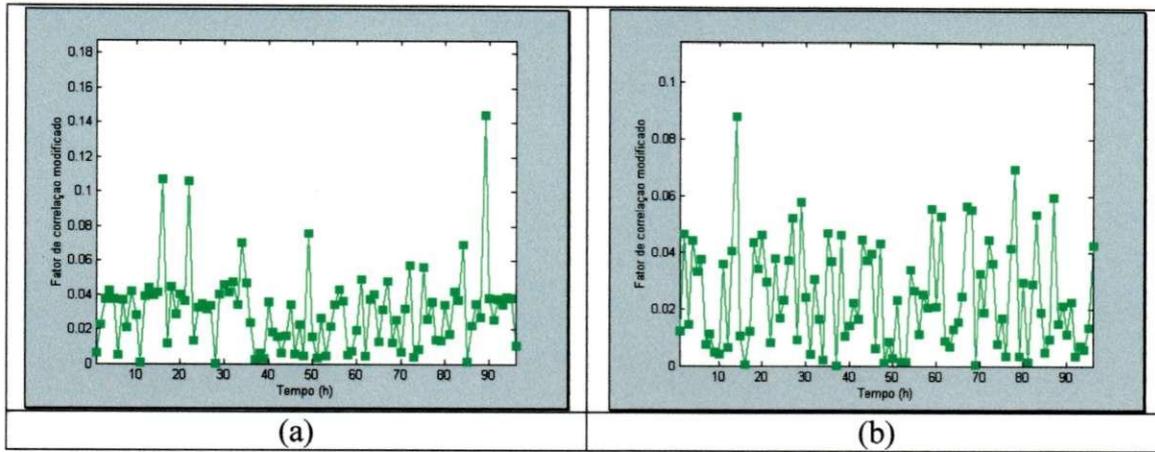


Figura 50 – Evolução do fator de correlação modificado: (a) isolador sem defeito e (b) isolador com defeito do tipo (a).

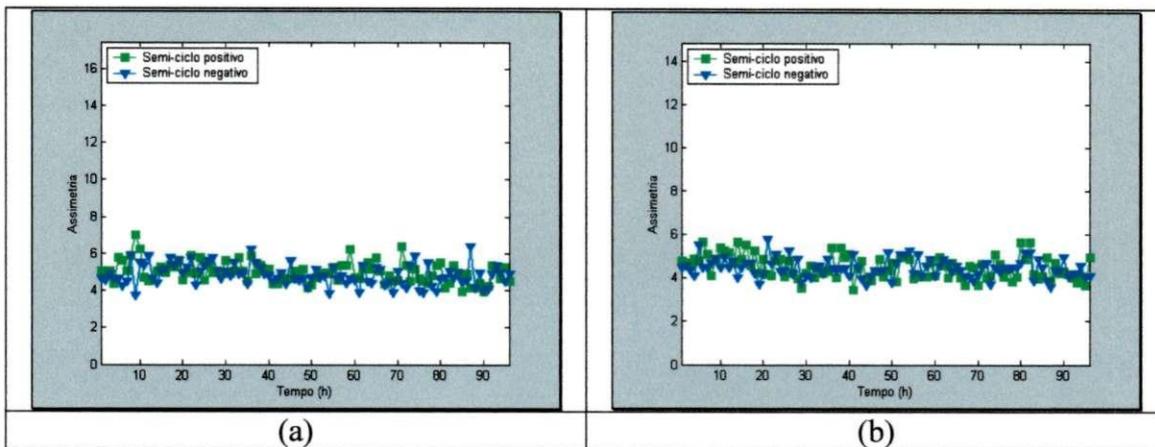


Figura 51 – Evolução da assimetria: (a) isolador sem defeito e (b) isolador com defeito do tipo (a).

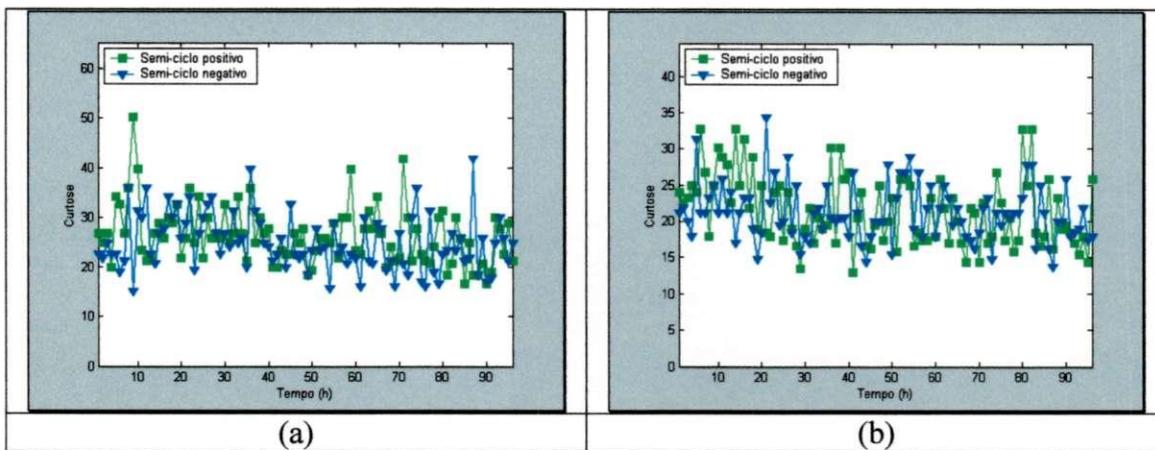


Figura 52 – Evolução da curtose: (a) isolador sem defeito e (b) isolador com defeito do tipo (a).

Observa-se aqui que apesar do roteiro de ensaio prescrever 5 dias, infelizmente o quinto dia ficou prejudicado para algumas amostras por incidentes diversos (falta de energia, queima de componentes do circuito, etc).

A aplicação das técnicas de classificação conduziram aos resultados apresentados na Tabela 22, na qual as técnicas lineares e não lineares são comparadas a partir do percentual de acertos no diagnóstico dos defeitos presentes nos isoladores ensaiados. Para montagem da tabela foram construídos classificadores a partir dos atributos “média” e “desvio padrão” extraídos das sete distribuições descritas anteriormente.

Tabela 22 – Análise comparativa entre as técnicas de classificação (a partir dos parâmetros estatísticos das distribuições).

Classes	Percentual de acertos	
	Modelo linear	Modelo não linear
Sem defeito	17	81
Defeito tipo (a)	33	80
Defeito tipo (b)	100	77
Defeito tipo (c)	100	76

Na construção dos classificadores não lineares, cujos resultados foram apresentados na Tabela 22, foram utilizados 1 neurônio na primeira camada, cinco na segunda camada, as funções de ativação “logsig” e “purelin” e o modelo de treinamento de Levenberg-Marquardt, os quais apresentaram melhor desempenho, diante dos demais parâmetros e modelos analisados. Pela tabela pode-se observar que houve dificuldade dos modelos lineares na classificação das unidades sem defeito e com defeito do tipo (a), levando aos menores percentuais de acerto (17 e 33, respectivamente).

Na Tabela 23 são apresentados os resultados obtidos a partir da utilização direta das três últimas distribuições apresentadas. Ou seja, nesta alternativa, os atributos passaram a ser cada um dos valores integralizados hora a hora, os quais compuseram as três últimas distribuições (curtose, assimetria e fator de correlação). Esta tabela foi construída a partir da mesma rede neural descrita anteriormente, alterando-se, apenas, os atributos de entrada. Observa-se, também, que os resultados obtidos para os modelos lineares apresentaram 100% de acerto no diagnóstico dos defeitos presentes nas

unidades, superando a dificuldade registrada, quando da análise da alternativa anterior. Os modelos não lineares não tiveram o mesmo sucesso, além de chegarem aos percentuais de acerto com uma tolerância próxima de  $10^{-1}$ , ou seja, para uma tolerância limite menor, esses modelos teriam problemas de convergência.

Tabela 23 - Análise comparativa entre as técnicas de classificação (a partir do uso direto das três últimas distribuições).

Classes	Percentual de acertos	
	Modelo linear	Modelo não linear
Sem defeito	100	75
Defeito tipo (a)	100	76
Defeito tipo (b)	100	77
Defeito tipo (c)	100	92

## 4.2.2 Validação dos Modelos

A validação dos modelos que conduziram aos resultados apresentados nas Tabelas 22 e 23 deve ser realizada a partir da submissão de novos sinais de descargas parciais aos classificadores construídos. Os sinais devem ser adquiridos através de ensaios similares sobre as mesmas amostras apresentadas, durante um período de ensaio de 4 dias. A utilização do mesmo período usado para aquisição dos sinais que subsidiaram a constituição do conjunto de treinamento se deve ao fato de que os atributos utilizados estão diretamente associados à integralização de parâmetros estatísticos computados ao longo do período de ensaio (96 horas, para o caso analisado).

## 4.2.3 Avaliação do Estudo

Neste estudo de caso, portanto, foi possível verificar, também, a validade da utilização das técnicas de reconhecimento de padrões para se diagnosticar a presença de defeitos internos a isoladores poliméricos. Chegou-se, inclusive, a construção de classificadores que conduziram a um perfeito diagnóstico das amostras analisadas, através de técnicas lineares.

## Capítulo 5: Conclusões

**A**s atenções direcionadas ao longo deste trabalho estavam sempre no sentido de se construir critérios e procedimentos que viabilizassem a identificação de atributos que venham a se caracterizar como efetivos em um processo de reconhecimento de padrões de sinais oriundos de descargas superficiais em isolantes externos ou descargas parciais (internas) em isolantes.

Foram utilizadas técnicas de processamento digital de sinais, transformações de Fourier e Wavelet para balizar a caracterização e extração dos atributos utilizados para construção dos diversos classificadores obtidos.

Ao longo de toda a pesquisa foi possível identificar contribuições significativas aderentes à contextualização estabelecida. A seguir serão destacadas as principais contribuições alcançadas, agrupando-as em função de suas características técnico-científicas ou tecnológicas.

### **5.1 Contribuições de Caráter Técnico-científico**

Neste grupo encontram-se descritas as contribuições de cunho metodológico, avaliação de modelos, aferição de sensibilidades, etc. As contribuições são explicitadas uma a uma, comentando-se especificamente os detalhes registrados no texto e associados a cada uma delas.

*A avaliação da contribuição dos atributos caracterizados para o processo de classificação em função do sensor, domínio ou transformada utilizada.*

Cada atributo caracterizado foi avaliado quanto a sua contribuição ao processo de classificação. Optou-se por construir classificadores específicos para cada sensor

---

analisado, como também, quando possível, foram feitas avaliações por domínio (tempo, frequência e a partir da transformada wavelet). A estratégia possibilitou aferir a contribuição não apenas dos sensores utilizados, como também dos diversos atributos caracterizados. A partir das análises individuais foi possível realizar as análises conjuntas, agregando os atributos mais significativos ao processo de reconhecimento dos sinais.

*As análises de sensibilidade do processo de classificação quanto ao número de faixas de histogramas e da densidade espectral de potência como atributos a se considerar no processo de reconhecimento.*

Nas análises individuais realizadas por tipo de sensor e por domínio foram avaliadas as sensibilidades do processo de reconhecimento à utilização de número crescente de faixas, tanto nos histogramas construídos no domínio do tempo, quanto nas densidades espectrais de potência dos sinais avaliados. As análises feitas permitiram verificar que, geralmente, se obtém uma melhora no processo de reconhecimento, quanto maior for o número de faixas utilizadas, observando-se algumas exceções e saturações neste número.

*O enriquecimento de informações através da utilização da transformada wavelet;*

A partir da decomposição dos sinais originais de corrente de fuga e ultra-som através da transformada Wavelet foi possível observar a validade dessa transformada, tendo em vista a melhora nos resultados finais de reconhecimento de padrões. Tais constatações estão certamente associadas às características inerentes à transformada Wavelet que permite realçar as oscilações contidas nos sinais sob análise. Neste contexto foi introduzido critério para limitar o número máximo de decomposições associado a aferição da informação (entropia) ainda incorporada aos sinais decompostos.

*A identificação da wavelet mãe que mais contribui para o processo de reconhecimento, para cada tipo de sinal analisado.*

Além da identificação da contribuição da transformada Wavelet para o processo de reconhecimento foi possível, também, investigar qual a wavelet mãe que mais se destacou neste papel. Verificou-se que as wavelets mãe “bior1.1” e “db6” apresentaram melhores resultados para os sinais de ultra-som e corrente de fuga, respectivamente.

#### *A avaliação de técnicas de construção de classificadores lineares e não lineares.*

As técnicas de construção de classificadores lineares analisadas (Fisher e Karhunen-Loève) apresentaram, de uma maneira geral, resultados semelhantes. Há de se ressaltar que a técnica de Karhunen-Loève já incorpora processo de redução da dimensionalidade do espaço de atributos, tendo-se utilizado fator de correlação de 0,97 que baliza esta redução, o qual pode ter contribuído para a semelhança dos resultados obtidos.

No tocante aos algoritmos para construção de classificadores não lineares o algoritmo de Levenberg-Marquardt apresentou melhor desempenho na classificação dos sinais básicos analisados (termovisor, corrente de fuga, enfocado por domínio, ultra-som, enfocada a transformação wavelet e espectro de frequência obtido através da antena de VHF e analisador de espectro). Observa-se, também, que o uso da função de transferência “logsig” na primeira camada e “purelin” na segunda camada e apenas um neurônio nas duas camadas representou a melhor alternativa no que tange ao maior número de convergências e menor número de iterações, para os casos analisados.

A análise conjunta dos dois tipos de técnicas de classificação (lineares e não lineares) permitiu identificar que a utilização de modelos não lineares pode conduzir a percentuais de acerto ainda maiores do que os obtidos para os modelos lineares. Entretanto, em alguns casos, os modelos não lineares podem não convergir para determinadas tolerâncias definidas.

## **5.2 Contribuições de Caráter Tecnológico**

Neste grupo encontram-se descritas as contribuições que incorporam valores a procedimentos operacionais empregados por empresas do setor de energia elétrica.

---

*A utilização de técnicas de reconhecimento de padrões para avaliar a fusão de dados oriundos de diferentes sensores e identificar as vantagens e desvantagens de tais fusões.*

A contribuição foi atingida a partir da montagem de experimentos voltados para avaliar o comportamento de isoladores submetidos a diferentes níveis de poluição e submetidos a umidade controlada através de câmara de névoa construída especificamente para desenvolvimento dos experimentos relatados. Foram utilizados quatro tipos de sensores: ultra-som, corrente de fuga e antena de VHF acoplada a analisador de espectro para monitorar a manifestação das descargas superficiais. Ficou constatado que a utilização conjunta de sensores para monitorar o fenômeno da poluição nem sempre é vantajosa. Em alguns casos aumenta-se significativamente a dimensão do espaço de atributos sem uma correspondente melhora no desempenho do processo de diagnóstico.

*A constatação de que sensores não invasivos podem conduzir a resultados semelhantes ou até melhores do que os obtidos a partir de sensores invasivos no diagnóstico de poluição em isoladores.*

A avaliação das junções de dados obtidos a partir dos sensores permitiu aferir os resultados dos processos de reconhecimento, utilizando-se diversas combinações. Os resultados obtidos apontaram que junções de sensores não invasivos para produzir o diagnóstico do estado de isoladores poluídos podem levar a resultados semelhantes ou até melhores do que os obtidos a partir do uso de sensores invasivos. A análise dos experimentos realizados apontou que a melhor composição observada foi entre os sensores de ultra-som, termovisor e VHF, todos não invasivos, fato que representa uma contribuição significativa aos processos de diagnóstico diante de sua relevância prática.

*A construção de classificadores para diagnosticar o nível de poluição de isoladores a partir de avaliações de imagens térmicas.*

A partir da caracterização de atributos para as imagens térmicas adquiridas foi possível construir classificadores para diagnosticar os níveis de poluição em isoladores, com percentuais médios de acerto superiores a 95%. Os resultados alcançados se revestem de grande importância, quando se considera que os termovisores são instrumentos utilizados largamente no setor elétrico para monitorar a temperatura de conexões elétricas. A aplicação realizada ao longo das pesquisas, além de abrir uma nova perspectiva de aplicação para o termovisor representa que a tecnologia pesquisada poderá ser implantada a baixos custos diante da difusão do uso desse tipo de sensor.

*A agregação de valores a sensores caracterizados como obsoletos e/ou de aplicações limitadas.*

Além da expansão da aplicação de sensores, já comentada anteriormente para o caso de termovisores, foi possível, ainda, agregar valores ao sensor de ultra-som, o qual, tradicionalmente, é utilizado para identificação de descargas internas a transformadores de potência, porém já é tido como obsoleto. Algumas dificuldades associadas a ruídos ambientais captados pelo sensor podem ser superadas, parcialmente, através da aplicação da transformada wavelet, já descritas acima.

*A obtenção de elevado grau de acertos no processo de diagnóstico de defeitos em isoladores poliméricos a partir de análise de sinais de descargas parciais.*

A aplicação de técnicas de reconhecimento de padrões aos atributos de descargas parciais definidos por Gulski e Kreuger (1992) possibilitou a obtenção de classificadores que apresentaram elevado nível de desempenho. Os classificadores construídos a partir de técnicas lineares alcançaram, inclusive, um desempenho superior aos construídos a partir de técnicas não lineares. No que tange a convergência das técnicas não lineares observou-se, mais uma vez, dificuldades quando da aplicação de tolerâncias específicas.

### **5.3 Refinamentos Propostos para Continuidade das Pesquisas**

São visualizados alguns refinamentos que podem ser implementados em futuras pesquisas similares a serem empreendidas, no aprofundamento do estudo dos casos analisados:

- para o estudo de caso N<sup>o</sup> 1 (poluição em isoladores):
  - utilização de antena de VHF que cubra todo o espectro de frequência de interesse (0 a 60 MHz);
  - revisão no sistema de ar comprimido direcionada para se aproximar mais das características preconizadas pela IEC (1991);
  - utilização de água desmineralizada para alimentação da câmara de névoa, uma vez que os valores da condutividade medida estavam no limiar máximo permitido pela IEC (1991).
  
- para o estudo de caso N<sup>o</sup> 2 (defeitos em isoladores poliméricos):
  - aplicação da transformada wavelet para filtrar os sinais de descargas parciais, realçando as suas variações, antes de serem submetidos às rotinas de extração de atributos;
  - inserção de sensores não invasivos para aferição das descargas parciais;
  - aquisição de mais dados, equivalentes a quatro dias de ensaios, que permitam consolidar a etapa de validação.

Além dos aspectos acima mencionados é importante ressaltar, ainda, a necessidade de que os modelos não lineares sejam mais explorados no sentido de se buscar alternativas, quando o procedimento de treinamento apresentar característica não convergente.

### **5.4 Considerações Finais**

Por fim, cabe registrar a validade da metodologia de reconhecimento de padrões aplicada diante dos resultados obtidos nos experimentos laboratoriais que conduziram à

---

caracterização e análises de atributos direcionados para a aferição do estado de isolamentos aéreos submetidos a poluição e isoladores poliméricos com defeitos de montagens industriais.

É importante enfatizar que a passagem da fase de protótipos concebidos em laboratório para a fase operacional dos classificadores construídos requer adequações adicionais, nas quais as amostras retiradas de sistemas de transmissão em operação (submetidas a intempéries) e que não forem bem classificadas necessitarão ser incorporadas ao conjunto de treinamento com o intuito de implementar ajustes iterativos que redundem no aprimoramento dos classificadores. Cabe ressaltar, também, que a metodologia utilizada pode ser adaptada a diversas outras aplicações semelhantes, abrindo uma perspectiva concreta de modernizações das técnicas de diagnóstico atualmente praticadas para monitoração de equipamentos e instalações elétricas.

## Anexo

Neste anexo são apresentados detalhes da metodologia utilizada para reconhecimento de padrões, como também para processamento digital dos sinais voltados para a caracterização dos atributos propostos ao longo das pesquisas realizadas.

### ***A.1 Técnicas Lineares de Reconhecimento de Padrões***

Como mencionado no texto, o conceito de classificação pode ser expresso em termos da partição do espaço de atributos. Uma das formas de realizar esta partição é através do uso de funções discriminantes. Tais funções são associadas a cada uma das classes e dão uma medida da separação entre elas.

Segundo Sklansky e Wassel (1981), uma função discriminante  $g_j$  é um mapeamento a partir do conjunto de vetores de atributos para um número real, sendo que cada valor de  $j$  está associado com uma região de decisão  $R_j$ . Então para cada vetor de padrões  $x$  existe um conjunto de valores  $\{g_j(x)\}$ . Usualmente, mas nem sempre, cada  $R_j$  está associado com uma região de classe  $c_j$ .

Em um classificador linear as funções discriminantes são lineares, representando hiper-superfícies de decisão, as quais são determinadas por um conjunto de funções discriminantes  $\{g_j(x)\}$ , como segue:

$$R_j = \{x | g_j(x) \geq g_i(x) \text{ para todo } i\}, \quad (17)$$

sendo  $g_j(x)$  da forma:

$$g_j(x) = w_j^T x + w_{j0}, \quad (18)$$

no qual  $w_j^t = (w_{j1}, \dots, w_{jd})^t$  representa o transposto do *vetor peso*  $w_j$ , então  $g_j(x)$  é uma *função discriminante linear* e o classificador é denominado *classificador linear*. Ainda segundo Sklansky e Wassel (1981), uma vantagem dos classificadores lineares sobre os não lineares é que os procedimentos de treinamento disponíveis para classificadores lineares são relativamente simples e bem compreendidos, e o número de pesos  $w_{ji}$  a serem ajustados durante a fase de treinamento é relativamente pequeno.

Em algumas situações se torna mais adequado expressar as funções discriminantes lineares em termos de vetores aumentados. Um vetor de atributos aumentado é definido por  $y = (x_0, x_1, x_2, \dots, x_N)^t$ , sendo na maioria dos casos  $x_0 = 1$ . O vetor peso aumentado é definido por  $v = (w_0, w_1, \dots, w_N)^t$ . Desta forma, em um espaço de atributos aumentados, a equação (8) se torna:

$$g_j(y) = v_j^t y. \quad (19)$$

Supondo que  $N$  atributos tenham sido extraídos a partir de cada padrão de entrada, cada conjunto de  $N$  atributos é considerado um vetor de atributos  $x$ , e pode ser representado por um ponto no espaço de atributos  $\Omega_X$ , de dimensão  $N$ . O problema da classificação é associar cada possível vetor ou ponto no espaço de atributos a uma classe de padrões apropriada. Conceitualmente, as funções discriminantes podem ser caracterizadas da maneira descrita a seguir.

Sejam  $c_1, c_2, \dots, c_k$  especificados como as  $k$  possíveis classes de padrões a serem reconhecidos, e  $x = [x_1, x_2, \dots, x_N]^t$  o vetor de atributos, no qual  $x_i$  representa o  $i$ -ésimo atributo medido. Uma função discriminante

$$\begin{aligned} g_j(x) : \Omega_x &\rightarrow \mathbb{R} \\ x &\rightarrow g_j(x), \end{aligned} \quad (20)$$

associada à classe  $c_j$ , ( $j=1,2, \dots, k$ ) é tal que se o padrão de entrada representado pelo vetor de atributos  $x$  pertence à classe  $c_i$  ( $x \in c_i$ ), então o valor de  $g_i(x)$  deve ser o maior. Isto é, para todo  $x \in c_i$ ,

$$g_i(x) > g_j(x), i, j = 1, 2, \dots, k, i \neq j. \quad (21)$$

Assim, no espaço de atributos  $\Omega_x$ , a fronteira da partição, chamada fronteira (ou superfície) de decisão, entre as regiões associadas com as classes  $c_i$  e  $c_j$ , respectivamente, é expressa pela seguinte equação:

$$g_i(x) - g_j(x) = 0. \quad (22)$$

Para a situação em que apenas duas classes estejam presentes, dado um vetor de atributos  $x$ , a regra de decisão será:

$$\text{Se } g_1(x) > g_2(x), \text{ então } x \in c_1; \quad (23)$$

$$\text{Se } g_1(x) < g_2(x), \text{ então } x \in c_2. \quad (24)$$

Se  $g_1(x) = g_2(x)$ ,  $x$  pode ser classificado em  $c_1$  ou  $c_2$ , uma vez que  $g_1(x) - g_2(x) = 0$ . Tal situação caracteriza que  $x$  está na superfície de decisão, no caso um hiperplano. Para duas classes, portanto, uma função pode ser usada, em vez de duas, a qual é definida da seguinte forma:

$$g(x) = g_1(x) - g_2(x). \quad (25)$$

Assim, a regra de decisão passa a ser:

$$\text{Se } g(x) > 0, \text{ então } x \in c_1; \quad (26)$$

$$\text{Se } g(x) < 0, \text{ então } x \in c_2. \quad (27)$$

A equação  $g(x) = 0$  define a superfície que separa os pontos associados a  $c_1$  dos pontos associados a  $c_2$ . Em geral o hiperplano de separação, divide o espaço de

atributos em dois semi-espacos: a região de decisão  $R_1$ , para  $c_1$ , e a região de decisão  $R_2$ , para  $c_2$ .

O exemplo a seguir traça, no espaço  $\Omega_x$ , o hiperplano parametrizado pelo vetor peso aumentado  $v^t = (2, 2, -1)$ . Portanto, o hiperplano será definido por  $g(x) = v^t y = 0$ , ou seja:

$$v^t y = (2, 2, -1) \begin{pmatrix} 1 \\ x_1 \\ x_2 \end{pmatrix} = 2 + 2x_1 - x_2.$$

O hiperplano obtido encontra-se ilustrado na Figura 53. Os componentes de  $v$ , exceto  $v_0$ , determinam o vetor peso  $w$ . Portanto  $w^t = (2, -1)$ , como indicado na figura. A região  $R_1$  é definida como o conjunto  $\{x \mid v^t y < 0\}$ . Similarmente  $R_2 = \{x \mid v^t y > 0\}$ . Essas regiões também são ilustradas na figura.

A equação  $g(x) = 0$  define a superfície de decisão que separa os pontos pertencentes a  $c_1$  dos pontos pertencentes a  $c_2$ . Se  $x_1$  e  $x_2$  estão ambos na superfície de decisão, então:

$$w^t x_1 + w_0 = w^t x_2 + w_0, \quad (28)$$

ou

$$w^t (x_1 - x_2) = 0, \quad (29)$$

desta forma  $w$  é normal a qualquer vetor que repouse no hiperplano. Em geral, o hiperplano ( $H$ , definido a partir de  $g(x) = 0$ ) divide o espaço de atributos  $\Omega_x$  em dois meio espaços, conforme encontra-se ilustrado na Figura 54. Desde que  $g(x) > 0$  se  $x$  estiver em  $R_1$  segue que o vetor normal  $w$  aponta para  $R_1$ . É comum afirmar que todo  $x$  em  $R_1$  está no lado positivo de  $\Omega_x$ , e todo  $x$  em  $R_2$  está no lado negativo.

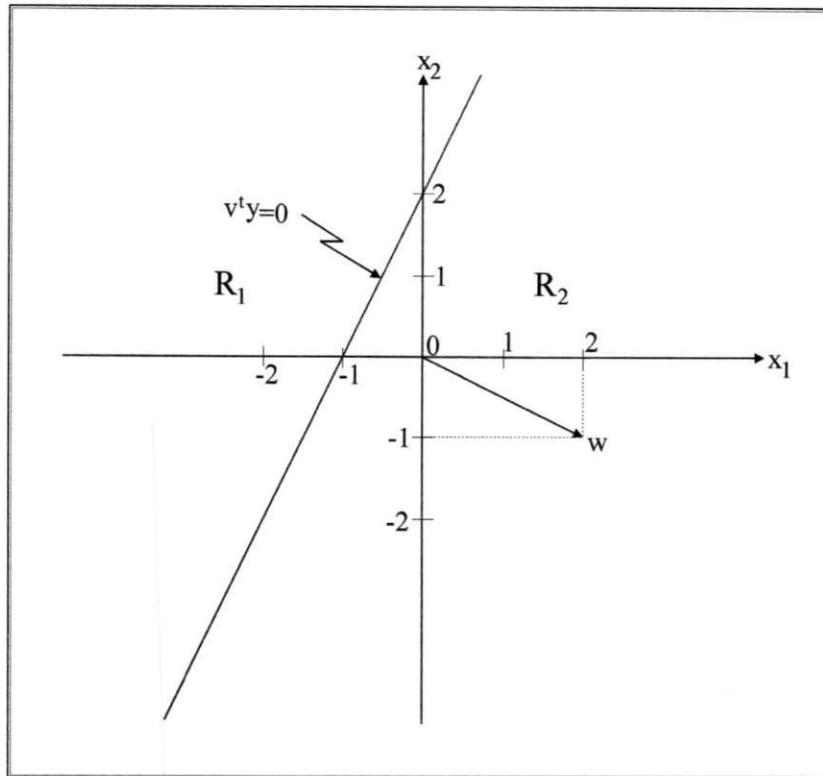


Figura 53 – Exemplificação da montagem do hiperplano. Fonte: Slansky e Wassel (1981).

A função discriminante  $g(x)$  fornece uma medida algébrica da distância de  $x$  ao hiperplano. Se  $x$  for expresso como:

$$x = x_p + d \frac{w}{\|w\|}, \quad (30)$$

na qual  $x_p$  é a projeção normal de  $x$  sobre  $H$ , e  $d$  é a distância algébrica desejada, positiva se  $x$  estiver no lado positivo e negativa se  $x$  estiver no lado negativo. Então, desde que  $g(x_p) = 0$ ,

$$g(x) = w^t x + w_0 = d \|w\|, \quad (31)$$

$$g(x) = w^t x + w_0 = d \|w\|, \quad (32)$$

ou:

$$d = \frac{g(x)}{\|w\|} = \frac{v^t y}{\|w\|}. \quad (33)$$

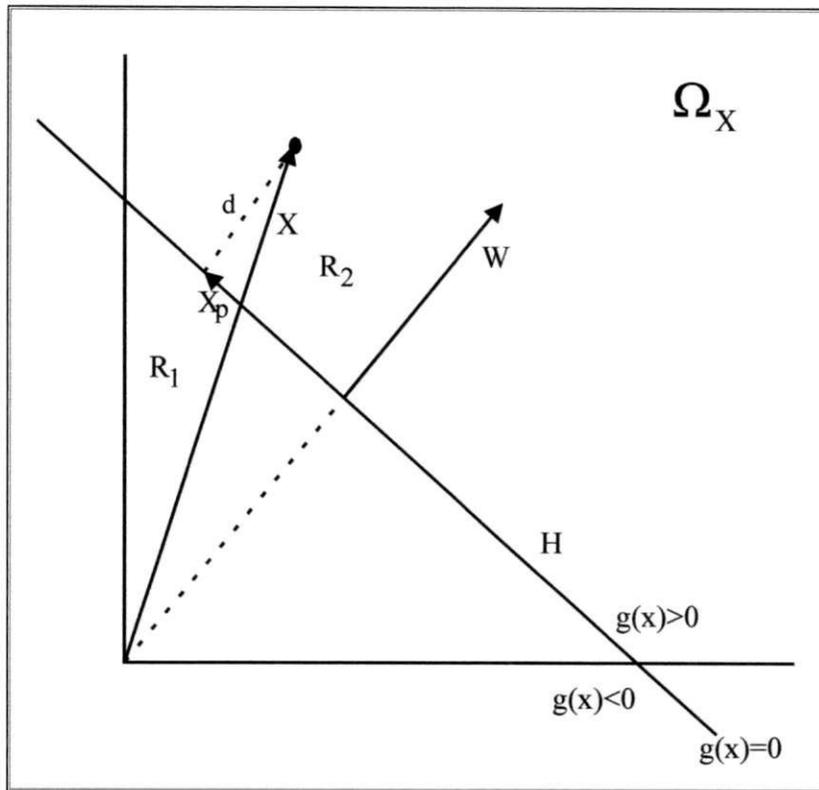


Figura 54 – A superfície de decisão  $g(x)=0$ . Fonte: Slansky e Wassel (1981).

Na Figura 55 são ilustradas algumas outras relações de distâncias em um espaço de atributos bi-dimensional. É possível observar que  $w^t x / \|w\|$ ,  $-w_0 / \|w\|$ , e  $v^t y / \|w\|$  representam distâncias sinalizadas positiva ou negativa, indicando, respectivamente a mesma direção ou direção oposta a de  $w$ .

Algumas vezes é conveniente representar o vetor atributo aumentado  $y$  por:

$$\eta = \begin{cases} -y, & \text{se } x \in c_1 \\ y, & \text{se } x \in c_2 \end{cases}, \quad (34)$$

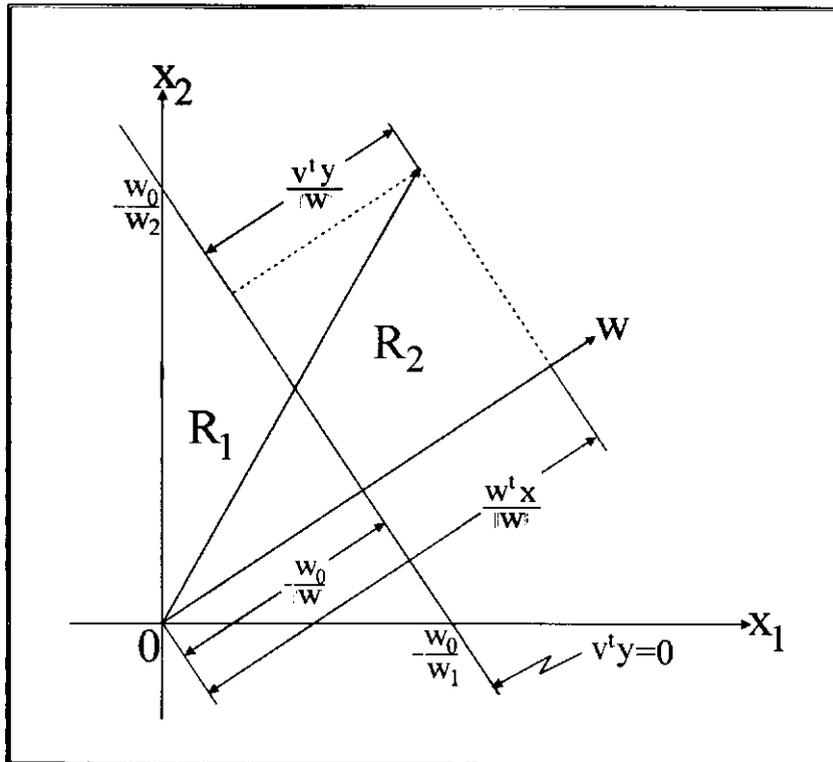


Figura 55 – Relações de distâncias em um espaço bi-dimensional. Fonte: Slansky e Wassel (1981).

na qual  $\eta$  é denominado vetor atributo aumentado com normalização de sinal. Com esta notação, a inequação de classificação é reduzida a:

$$v^t \eta > 0, \quad (35)$$

para um  $\eta$  que é determinado pelo vetor de atributos a partir das classes  $c_1$  e  $c_2$ .

### A.1.1 Técnicas para Determinação do Classificador Linear

Diversas técnicas têm sido desenvolvidas para reduzir a dimensionalidade do espaço de atributos de tal forma a se obter um problema mais tratável. A seguir serão abordadas 3 técnicas clássicas para determinação de classificadores lineares: Fisher, Karhunen-Loève e Redes Neurais.

### A.1.1.1 Técnica de Fisher

A técnica de Fisher pertence a um grupo que procura reduzir a dimensionalidade do problema a apenas uma dimensão. Desse grupo fazem parte, também as técnicas de Incremento Proporcional, Fração Fixada, Gradiente decrescente e Ho-Kashyap. A maioria dessas técnicas baseia-se em processos iterativos, onde o vetor normal  $V$  é ajustado constantemente, em função de um conjunto de treinamento, até atingir um ponto ótimo de classificação. Apenas a técnica de Fisher está fundamentada num método direto, tendo apenas que resolver um sistema de equações lineares de dimensão igual a dimensão do espaço de características

A técnica procura projetar as amostras em uma linha, conforme pode ser visualizado na Figura 56.

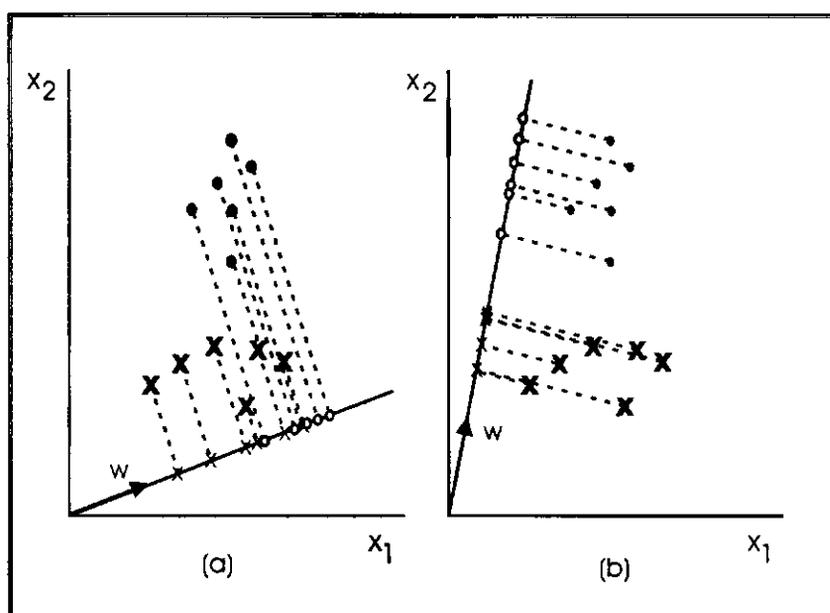


Figura 56 – Projeção de amostras sobre uma reta: (a) inadequada e (b) adequada. Fonte: Duda e Hart (1973).

É importante observar que, mesmo se as amostras estiverem bem separadas no espaço original, a projeção das mesmas em uma linha arbitrária poderá produzir uma mistura entre as classes, conforme pode ser observado na figura. Entretanto, movendo a linha, pode ser encontrada uma orientação para a qual a projeção das amostras apresente uma boa separação. Esse é o objetivo das análises discriminantes clássicas.

Suponha que se possui um conjunto de  $n$  amostras de dimensão  $N$  ( $x_1, \dots, x_n$ ),  $n_1$  no subconjunto  $\chi_1$  rotulado por  $c_1$  e  $n_2$  no subconjunto  $\chi_2$  rotulado por  $c_2$ . Se formarmos uma combinação linear dos componentes de  $x$ , obtemos o escalar:

$$y = w^t x, \quad (36)$$

e um conjunto correspondente de  $n$  amostras  $y_1, \dots, y_n$ , divididos em dois subconjuntos  $\phi_1$  e  $\phi_2$ . Geometricamente, se  $\|w\| = 1$ , cada  $y_i$  é a projeção do  $x_i$  correspondente em uma linha na direção de  $w$ . Se imaginarmos que as amostras associadas a  $c_1$  e as amostras associadas a  $c_2$  estão agrupadas separadamente, desejamos que as projeções sobre a linha resultem em uma boa separação e não um indesejável entrelaçamento entre as amostras, conforme é ilustrado na Figura 56 (a).

Uma medida da separação entre as amostras projetadas é a diferença da média das amostras. Se  $m_i$  é a média das amostras obtidas por:

$$m_i = \frac{1}{n_i} \sum_{x \in \chi_i} x, \quad (37)$$

então, a média das amostras projetadas é dada por:

$$\tilde{m}_i = \frac{1}{n_i} \sum_{y \in \phi_i} y = \frac{1}{n_i} \sum_{x \in \chi_i} w^t x = w^t m_i, \quad (38)$$

portanto, segue que  $|\tilde{m}_1 - \tilde{m}_2| = |w^t(m_1 - m_2)|$ , e que podemos tornar essa diferença tão grande quanto necessitamos através da escolha apropriada de  $w$ . Para obter uma boa separação dos dados projetados é necessário que a diferença entre as médias seja grande em relação a alguma medida do desvio padrão para cada classe. Em vez da formação de variâncias amostrais, foi definido o espalhamento para as amostras, da seguinte forma:

$$s_i^2 = \sum_{y \in \phi_i} (y - m_i)^2. \quad (39)$$

Então  $(\tilde{s}_1^2 + \tilde{s}_2^2)/n$  é uma estimativa da variância dos dados agrupados e  $\tilde{s}_1^2 + \tilde{s}_2^2$  é denominado espalhamento interclasses para os dados projetados. O discriminante linear de Fisher é, então, definido como a função linear  $w^t x$  para a qual a função critério:

$$J(w) = \frac{|\tilde{m}_1 - \tilde{m}_2|^2}{\tilde{s}_1^2 + \tilde{s}_2^2} \quad (40)$$

é máxima. Para obter  $J$  como uma função explícita de  $w$ , são definidas as matrizes de espalhamento  $S_i$  e  $S_w$  da seguinte forma:

$$S_i = \sum_{x \in \chi_i} (x - m_i)(x - m_i)^t, \quad (41)$$

e

$$S_w = S_1 + S_2. \quad (42)$$

Então,

$$\tilde{s}_i^2 = \sum_{x \in \chi_i} (w^t x - w^t m_i)^2 = \sum_{x \in \chi_i} w^t (x - m_i)(x - m_i)^t w = w^t S_i w. \quad (43)$$

De tal forma que:

$$\tilde{s}_1^2 + \tilde{s}_2^2 = w^t S_w w. \quad (44)$$

Similarmente,

$$(\tilde{m}_1 - \tilde{m}_2)^2 = (w^t m_1 - w^t m_2)^2 = w^t (m_1 - m_2)(m_1 - m_2)^t w = w^t S_B w, \quad (45)$$

sendo:

$$S_B = (m_1 - m_2)(m_1 - m_2)^t. \quad (46)$$

A matriz  $S_W$  é denominada matriz de espalhamento interclasse e  $S_B$  é denominada matriz de espalhamento intraclases. Na forma matricial, a função critério  $J$  pode ser escrita como:

$$J(w) = \frac{w^t S_B w}{w^t S_W w}. \quad (47)$$

Pode ser mostrado que o vetor  $w$  que maximiza  $J$  deve satisfazer a seguinte equação, segundo Duda e Hart (1973):

$$S_B w = \lambda S_W w, \quad (48)$$

o qual representa um problema generalizado de autovalores. Se  $S_W$  for não singular (o que geralmente é verdadeiro, caso  $n > N$ ) o problema se torna de autovalores convencional, permitindo escrever:

$$S_W^{-1} S_B w = \lambda w. \quad (49)$$

No nosso caso particular, não é necessário resolver a equação anterior para os autovalores e auto-vetores de  $S_W^{-1} S_B$  devido ao fato de que  $S_B w$  está sempre na direção de  $m_1 - m_2$ . Desde que o fator de escala de  $w$  não tem significado, a solução pode ser escrita diretamente como:

$$w = S_W^{-1}(m_1 - m_2). \quad (50)$$

Portanto, a equação (39) representa o discriminante linear de Fisher, a função linear com a maior relação entre o espalhamento intraclasses e interclasse.

### A.1.1.2 Técnica de Fisher para Seleção de Atributos

Como vimos, matematicamente, cada padrão de entrada pode ser representado por um vetor de dimensão  $N$ , cujas coordenadas são parâmetros que procuram fornecer informações sobre o fenômeno em estudo, ou seja, são valores que procuram representar características do referido fenômeno.

É comum  $N$  ser razoavelmente grande, caracterizando a necessidade de uma seleção de atributos, eliminando-se o máximo de redundâncias, para que se tenha conseqüentemente uma redução significativa da dimensão dos vetores. Além disso, os atributos selecionados no espaço reduzido podem ser melhores reunidos no espaço de atributos e, possivelmente, admitir superfícies de decisão mais simples. Esta etapa do processo recebe a denominação de *seleção de atributos*. Ela é de grande importância, desde que os atributos selecionados devem assegurar uma boa representação dos padrões originais para que os possíveis erros de classificação sejam minimizados.

Uma maneira bem simples e imediata de fazer uma seleção de atributos é através do critério de Fisher modificado. Este critério fornece uma medida do erro de classificação que pode surgir quando a variável  $x_i$  é utilizada como atributo. Quanto maior for  $F_i$ , menor será a probabilidade de ocorrer um erro de classificação, usando a variável  $x_i$ .

$$F_i = \frac{|\bar{X}_{i1} - \bar{X}_{i2}|}{\sigma_{i1} + \sigma_{i2}}, i = 1, \dots, N, \quad (51)$$

na qual:

$\bar{X}_{ij}$  = média dos valores do atributo  $x_i$  na classe  $j$ ,  $j = 1, 2$ ;

$\sigma_{ij}$  = desvio padrão do atributo  $x_i$  na classe  $j$ ,  $j = 1, 2$ .

Ao se colocar os números de Fisher ( $F_i$ ,  $i=1, \dots, N$ ), obtidos para todos os atributos, em ordem decrescente, a seleção pode ser realizada de duas maneiras: atribuindo-se o valor mínimo de  $F_i$  ou definindo-se o número máximo de atributos a serem considerados. Cada atributo escolhido pode eliminar outros, desde que o coeficiente de correlação seja maior do que algum valor pré-estabelecido (80 %, por exemplo). A grande vantagem de usar esta técnica é se levar em consideração tanto as informações interclasses, como intraclasses. Outra vantagem está associada à estimativa da validade do atributo analisado no processo de classificação.

### A.1.1.3 Técnica de Karhunen-Loève

A transformação de Karhunen-Loève é equivalente a uma rotação da base, segundo a direção definida por um novo conjunto de vetores ortogonais, o qual aumenta a condição para separação das classes e incorpora a redução de atributos. Segundo Fukunaga (1972), a transformação está contida na categoria de transformações rotacionais e, a exemplo das transformações diagonais descritas anteriormente para a técnica de Fisher, ela fornece informações intraclasses. Este método pode ser considerado um caso particular da análise de componentes principais adaptado para a classificação das amostras.

Em geral, para se obter uma boa transformação, adota-se um critério de otimização, entre eles destacam-se o *mínimo erro quadrado* e a *entropia*. Estes critérios associados às transformações têm por objetivo auxiliar a discriminação das classes existentes, de maneira a maximizar as distâncias interclasses e a minimizar as distâncias intraclasses. A transformada Karhunen-Loève procura otimizar o mínimo erro quadrado

Na realidade, a transformação do espaço de representação dos padrões aumenta a possibilidade de separação dos conjuntos de padrões. Uma boa separação no espaço de atributos resultará em grandes simplificações ao classificador.

Segundo Anderson (1960), a extração de atributos via transformada Karhunen-Loève pode ser implementada da seguinte forma: seja  $\{X\}$  um conjunto de vetores, obtidos por amostragem, de uma classe de sinais aleatórios. Um representante de  $\{X\}$  é dado por  $x_j = (x_{j,1}, x_{j,2} \dots x_{j,N})$ . A amostra  $x_j$  pode ser aproximada por:

$$x_j = y_{j,1}\psi_1 + y_{j,2}\psi_2 + \dots + y_{j,k}\psi_k = \sum_{i=1}^k y_{j,i}\psi_i \quad k < N, \quad (52)$$

$$y_{j,i} = x_j^t \psi_i \quad i = 1, 2, \dots, k, \quad (53)$$

sendo  $N$  o número total de atributos da amostra e  $k$  é o número de atributos utilizados na aproximação.

Por definição, o mínimo erro quadrado,  $\varepsilon$ , é dado pela expressão:

$$\varepsilon = \left( \sum_{i=1}^N y_{j,i}\psi_i - \sum_{i=1}^k y_{j,i}\psi_i \right)^2. \quad (54)$$

Anderson (1960) mostrou que:

$$\varepsilon = \sum_{i=k+1}^N \psi_i^t S \psi_i. \quad (55)$$

Segundo Anderson (1960),  $\{\psi_i\}$  constitui a base ortogonal de Karhunen-Loève, os elementos  $\psi_i$  são determinados a partir dos autovetores de  $S$ , de acordo com a equação:

$$S\psi_i = \lambda_i\psi_i, \quad (56)$$

na qual  $\lambda_i$  são os autovalores da matriz de covariância. De tal forma que o erro de truncamento é minimizado pela equação:

$$\text{Min}_{\{\psi_i\}} \varepsilon = \sum_{i=k+1}^N \lambda_i. \quad (57)$$

Isto significa que, se utilizarmos apenas  $k$  autovetores para a representação de funções, o erro de truncamento será a soma dos autovalores da matriz de covariância, sendo dado pela equação acima. A amostra  $x_j$ , escrita em termos dos auto-vetores da matriz de covariância, é denominada expansão Karhunen-Loève. A correspondente

transformação ortogonal inversa,  $(y_{j,i} = x_j^t \psi_i \quad i=1,2,\dots,k)$ , é chamada transformada Karhunen-Loève.

A transformação apresentada pode ser utilizada para reconhecimento de padrões. O processo de amostragem fornece uma seqüência de valores que definem o padrão dado  $r$   $(r_1, r_2, \dots, r_M)$ . Portanto, após este processo, o padrão de entrada é tratado como um vetor  $M$ -dimensional.

Obtido o vetor, correspondente ao padrão de entrada, inicia-se o processo de extração de atributos, obtendo-se o vetor  $x$   $(x_1, x_2, \dots, x_N)$ . O estágio seguinte consiste na transformação Karhunen-Loève dos valores de entrada, esta provê um mapeamento um para um, transformando o vetor de atributos  $x$   $(x_1, x_2, \dots, x_N)$  em outro  $u$   $(u_1, u_2, \dots, u_N)$ , de mesma dimensão.

Na prática, a dimensão dos padrões,  $N$ , é muito grande, sendo necessária sua redução. Portanto, o estágio de extração de atributos é complementado através da escolha dos componente mais significativos do vetor transformado  $y$ . O resultado da etapa será um vetor  $z$ ,  $(z_1, z_2, \dots, z_k)$ , com  $k$  componentes de  $y$ , tal que  $k \ll N$ . Esta redução de dimensionalidade é alcançada segundo os critérios que norteiam a transformada Karhunen-Loève, de maneira que o erro seja tão pequeno quanto se deseja e facilmente calculado conforme descrito anteriormente.

A matriz de covariância desenvolvida por classe é dada por:

$$S = P_1 S_1 + P_2 S_2 + \dots + P_M S_M, \quad (58)$$

sendo  $S_i$  a matriz de covariância da  $i$ -ésima classe e  $P_i$  a probabilidade de ocorrência da classe  $c_i$  (é assumido que esta probabilidade é igual a  $\frac{1}{L}$ , sendo  $L$  o número de classes envolvidas). A transformada Karhunen-Loève é dada pelo conjunto dos autovetores extraídos da matriz de covariância,  $S$ , a qual foi representada por  $T$ .

Portanto, a transformação do espaço de atributos é dada por:

$$u = Tx, \quad (59)$$

portanto, a fixação dos  $k$  primeiros componentes de  $u$ , associados as maiores variâncias, permite obter o vetor  $z$  ( $z_1, z_2, \dots, z_k$ ) que pode ser denominado de “vetor de atributos transformado e reduzido”.

Através da técnica de Karhunen-Loève é possível construir e treinar um classificador que seja capaz de localizar automaticamente a classe a que pertence um determinado padrão, associado ao seu vetor de atributos transformado e reduzido  $z$ .

O classificador pode ser projetado baseado no critério de mínima distância quadrada, o qual é definido a partir da seguinte regra: um padrão associado ao vetor  $z$  é dito pertencente a classe  $c_i$  se  $z$  é mais próximo a  $\bar{z}_i$ , sendo que  $c_i$  corresponde a classe  $i$  e  $\bar{z}_i$  é o vetor médio da classe  $c_i$ .

Na Figura 57 é ilustrado o processo de classificação para três classes ( $c_1, c_2$  e  $c_3$ ). Neste caso, o padrão associado ao vetor  $z$  será reconhecido como elemento pertencente a classe  $c_2$ .

Representando  $D_i^2$  a distância quadrada entre  $z$  e os  $\bar{z}_i$ , a fórmula para o cálculo da distância é dada por:

$$D_i^2 = \|z - \bar{z}_i\|^2 = (z - \bar{z}_i)(z - \bar{z}_i)^t \quad i = 1, \dots, L, \quad (60)$$

sendo que  $z$  é o vetor associado ao padrão a ser classificado e  $\bar{z}_i$  é o vetor médio da classe  $i$ ,  $L$  é o número de classes.

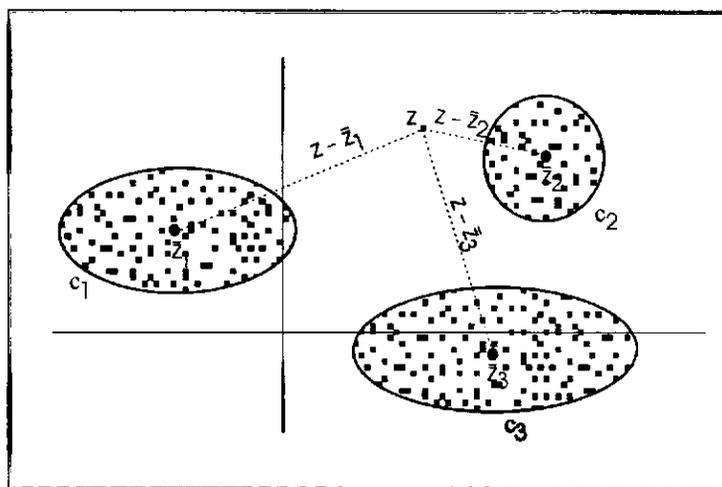


Figura 57 - Representação geométrica de um classificador de mínima distância quadrada para três classes. Fonte: Anderson (1960).

A equação anterior pode ser re-escrita da seguinte forma:

$$D_i^2 = \|z\|^2 - 2\left(\bar{z}_i z^t - \frac{1}{2}\|\bar{z}_i\|^2\right) \quad i = 1, \dots, L. \quad (61)$$

Observando a equação acima,  $D_i^2$  é mínimo quando o termo  $\left(\bar{z}_i z^t - \frac{1}{2}\|\bar{z}_i\|^2\right)$  é máximo. Assim, para se obter o classificador baseado na mínima distância é necessário apenas calcular este termo. Desta forma, podemos descrever o classificador pela seguinte função discriminante:

$$g_i(z) = \bar{z}_i z^t - \frac{1}{2}\|\bar{z}_i\|^2 \quad i = 1, \dots, L, \quad (62)$$

na qual o termo  $\|\bar{z}_i\|^2/2$  é conhecido por limiar.

A partir da formulação acima, portanto, o classificador calcula  $L$  valores reais  $g_1(z), g_2(z), \dots, g_L(z)$  e os compara. O padrão associado ao vetor  $z$  pertence a classe  $c_i$  quando  $g_i(z)$  for o maior valor encontrado entre os  $g_i(z)$  para  $i = 1, 2, \dots, L$ .

### A.1.1.4 Técnicas de Redes Neurais

Segundo Beale e Jackson (1991), reconhecimento de padrões é uma das áreas dominantes das aplicações de redes neurais. Essas redes podem ser constituídas de várias camadas, associadas aos números de neurônios utilizados. Quando da utilização de uma única camada (apenas um neurônio) a rede passa a ter uma aplicação restrita a classificação de padrões linearmente separáveis.

Na constituição de uma rede de uma camada se procura identificar as características de um simples neurônio e como ele pode ser modelado. A função básica de um neurônio biológico é adicionar informações de entrada e produzir uma saída, se essa soma for maior do que um determinado valor conhecido como “condição de disparo”. Na Figura 58 é ilustrado, já numa visão matemática, a representação de um neurônio.

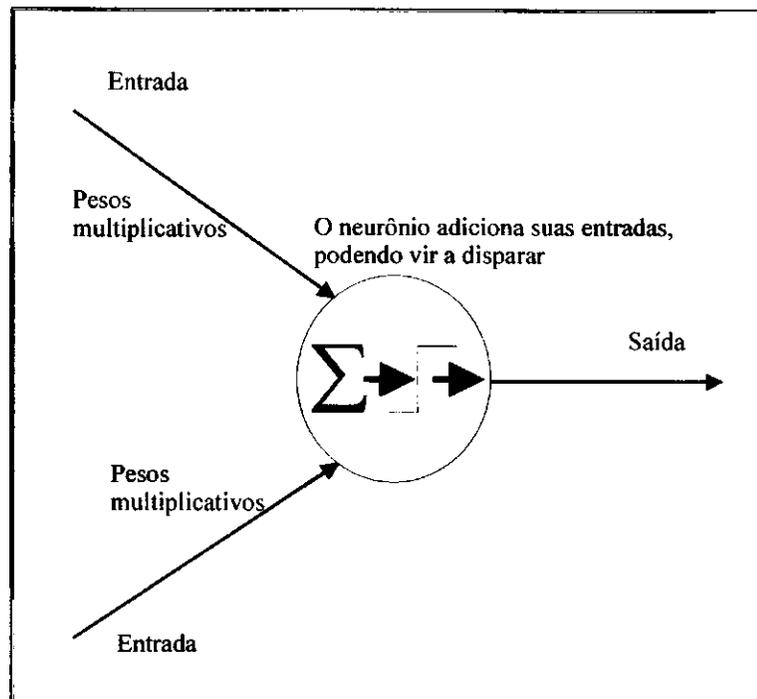


Figura 58 – Representação de um neurônio simples. Fonte: Beale e Jackson (1991).

Como pode ser observado, o neurônio produz uma soma ponderada de suas entradas, compara essa soma com o nível de disparo e se torna ativo unicamente se esse nível é excedido. Matematicamente, se houverem “N” entradas, então serão necessários “N” pesos associados a essas entradas. A entrada total pode ser formulada da seguinte maneira:

$$g(x) = \sum_{i=1}^N w_i x_i, \quad (63)$$

sendo que:

$g(x)$  é o valor da saída;

$w_i$  é o peso associado à entrada “i”;

$x_i$  é o valor da entrada “i”.

Essa soma, portanto, deve ser comparada com um certo valor intrínseco ao neurônio; o valor de disparo. O disparo é realizado após um processo de comparação feito pelo neurônio. Se a soma das entradas multiplicadas por seus respectivos pesos for

maior do que o valor de disparo então a saída é 1, se for menor, a saída é zero. Isso pode ser visualizado graficamente na Figura 59, sendo que o eixo dos x representa a entrada e o eixo dos y representa a saída. A função que descreve este comportamento é denominada função de ativação.

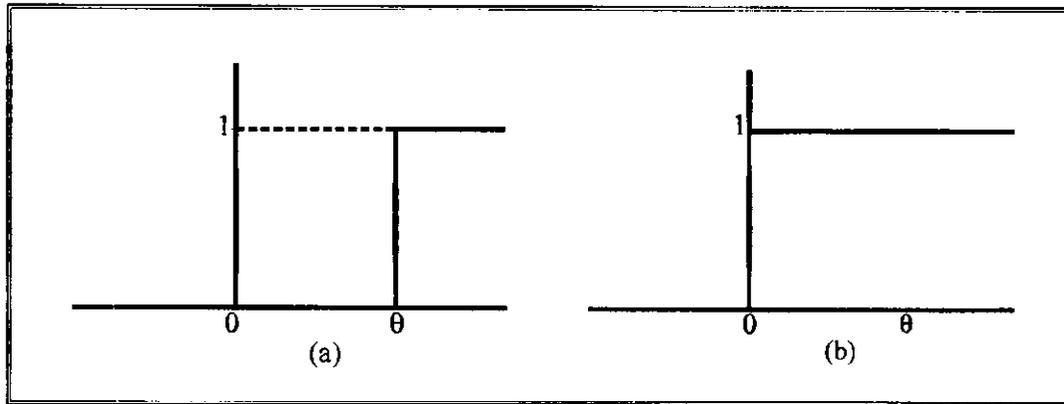


Figura 59 – A função de ativação: (a) disparo em  $\theta$  e (b) disparo em 0. Fonte: Beale e Jackson (1991).

Equivalentemente, o valor de disparo pode ser subtraído da soma ponderada, e o valor resultante comparado com zero. Neste caso, conforme é ilustrado na figura, o disparo passa a ocorrer na origem dos eixos. Para essa nova situação, pode ser escrito:

$$g(x) = f_h \left[ \sum_{i=1}^N w_i x_i - \theta \right], \quad (64)$$

na qual  $\theta$  é o valor de disparo e  $f_h$  é uma função degrau (conhecida como função de Heaviside) e:

$$\begin{aligned} f_h(x) &= 1 \text{ se } x > 0, \\ f_h(x) &= 0 \text{ se } x \leq 0, \end{aligned} \quad (65)$$

note que a função produz unicamente 1 ou 0, de tal forma que o neurônio estará ativo ou inativo.

Se for utilizado o artifício de estabelecer uma tendência ao neurônio, pode se definir uma entrada extra (“0”), a qual é sempre colocada ativa, com um peso que representa a tendência aplicada ao neurônio. A equação que descreve a saída pode então ser escrita como:

$$g(x) = f_h \left[ \sum_{i=0}^N w_i x_i \right]. \quad (66)$$

Observa-se que o limite inferior do somatório foi mudado de 1 para 0 e que o valor da entrada  $x_0$  é sempre assumida igual a 1. Vide ilustração na Figura 60.

No processo de treinamento, os pesos das entradas ativas devem ser aumentados, quando a intenção é que a saída seja ativa e diminuir esses pesos quando a intenção é que a saída seja inativa. Isso define a regra básica de treinamento.

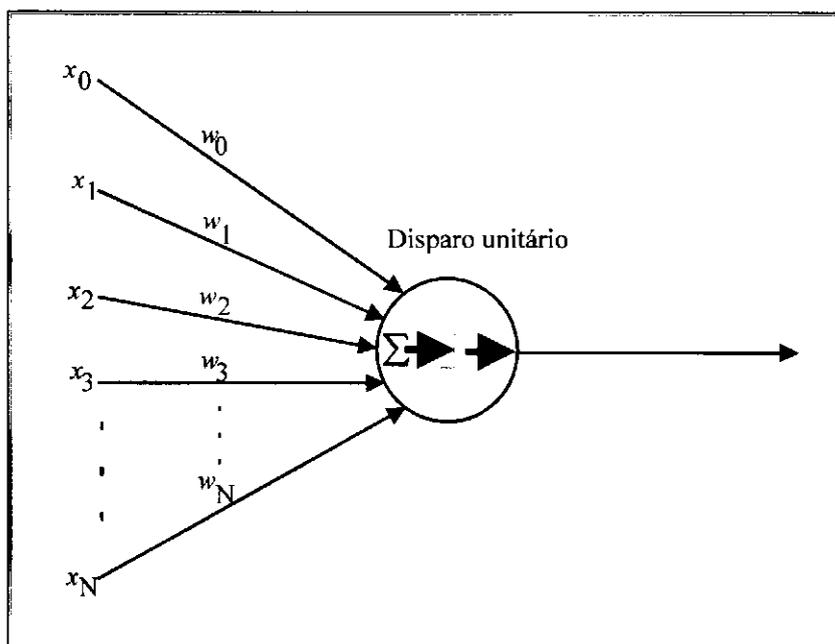


Figura 60 – Detalhe do modelo básico. Fonte: Beale e Jackson (1991).

O comportamento do processo de classificação através de redes neurais de uma camada pode ser visualizado através da Figura 61, na qual o processo de aprendizado inicia em uma posição aleatória incorreta associada à linha 0 até a posições corretas ilustradas pelas linhas 10, 20 e 30. Observe que o processo não procura otimizar as distâncias entre as amostras associadas à classe ilustrada por pequenos quadrados pretos da classe ilustrada por pequenas circunferências.

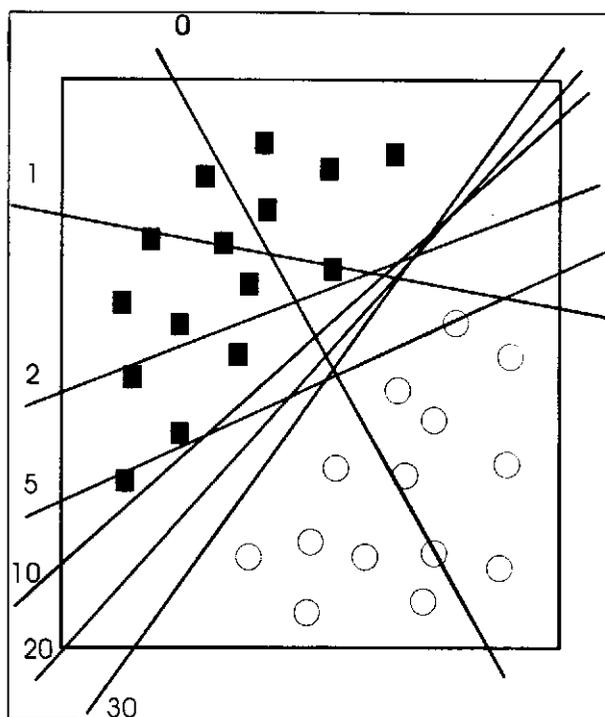


Figura 61 – Evolução da rede neural de uma camada. Fonte: Beale e Jackson (1991).

Por outro lado, a rede neural de apenas uma camada apresenta limitações para casos específicos. Um exemplo clássico descrito por Beale e Jackson (1991) conduz à seguinte situação: um sistema apresenta o resultado 1 sempre quando for submetido a entradas diferentes (0,1 ou 1,0) e apresenta resultado igual a 0 sempre que as entradas forem iguais (0,0 ou 1,1). Na Figura 62 são ilustrados os resultados de tal sistema, na qual os círculos mais escuros representam entradas que produzem saídas iguais a 1. Portanto as duas classes distintas apresentadas em tons de cinza diferentes não são linearmente separáveis, ou seja, não é possível construir retas que separe as duas classes adequadamente, conforme pode ser visualizado nas linhas tracejadas ilustradas, remetendo a soluções mais elaboradas que serão analisadas no próximo tópico. Este problema, aqui montado para redes neurais de uma camada, também seria válido para os classificadores lineares analisados anteriormente (Fisher e Karhunen-Loève). Tais situações serão solucionáveis apenas através de classificadores não lineares.

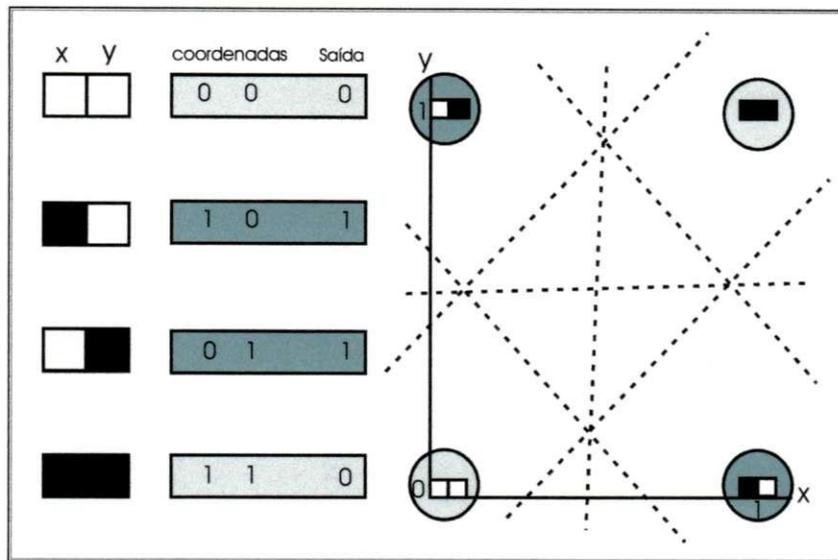


Figura 62 – Classes linearmente inseparáveis. Fonte: Beale e Jackson (1991).

Uma outra limitação a ser considerada é que as técnicas de classificação lineares podem, também, conduzir a situações de indefinição. As situações de classificações indefinidas são descritas por Duda e Hart (1973) e ilustradas na Figura 63 (a) e (b), através das áreas sombreadas.

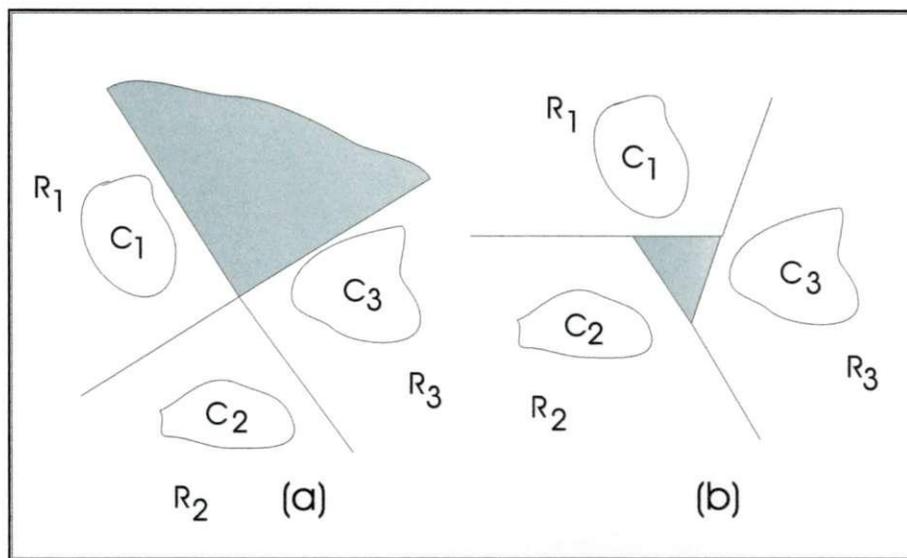


Figura 63 - Exemplo de regiões de classificação indefinida.

## A.2 Técnicas Não Lineares de Reconhecimento de Padrões

As técnicas de projeto de classificadores discutidas até aqui estavam restritas a superfícies de decisão lineares (hiperplanos). Em diversas situações práticas, tais hiperplanos não permitem a desejada separação de tal forma que uma superfície de decisão não linear se torna necessária. Um exemplo de tais situações foi ilustrado na Figura 62.

A utilização de redes neurais para solucionar os tipos de problema não lineares tem se tornado mais usual ultimamente. Esta técnica busca a implementação de um novo tipo de classificador através da construção de múltiplas camadas do modelo básico do neurônio anteriormente analisado. A implementação de uma rede de múltiplas camadas conduz a que as saídas dos neurônios de uma camada passem a representar entradas para novos neurônios em uma outra camada. Esta solução, descrita por Beale e Jackson (1991) requer adaptações que habilitem a nova rede a serem treinadas. Tais adaptações passam pela redefinição da função de ativação, tornando a região de transição mais atenuada. Três alternativas de função de ativação são apresentadas na Figura 64.

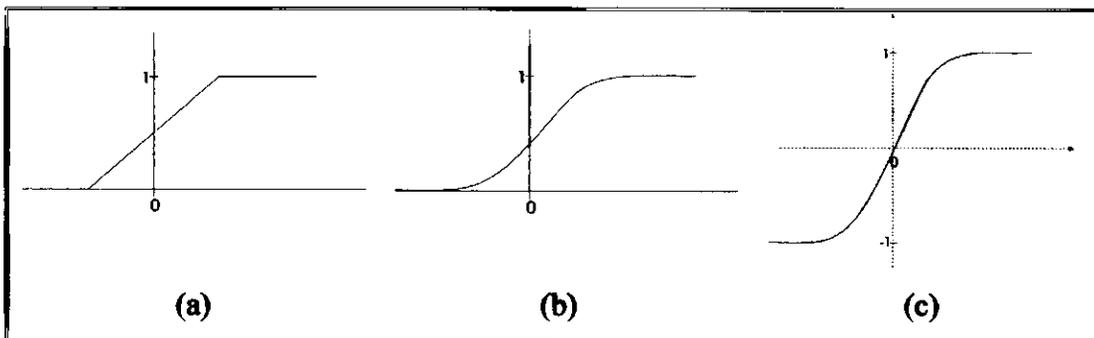


Figura 64 – Funções de ativação: (a) linear, (b) log-sigmóide e (c) tan-sigmóide.

Nos três casos, o valor da saída será praticamente um se a soma ponderada exceder bastante o valor de ativação e, inversamente, será zero ou menos 1 se a soma ponderada for muito menor que o valor da ativação. Entretanto, no caso em que a ativação e a soma ponderada forem aproximadamente os mesmos, a saída do neurônio

terá um valor entre os dois extremos. Isso significa que a saída do neurônio estará relacionada com as entradas de uma forma mais útil e informativa.

Nesse novo modelo os neurônios são arranjados em três camadas denominadas “entrada”, “saída” e “intermediária” ou “oculta”. As funções de transição para os neurônios são dos tipos apresentados na Figura 64.

Segundo informações contidas no manual do Matlab (2000), a rede neural é implementada atendendo a arquitetura básica ilustrada na Figura 65.

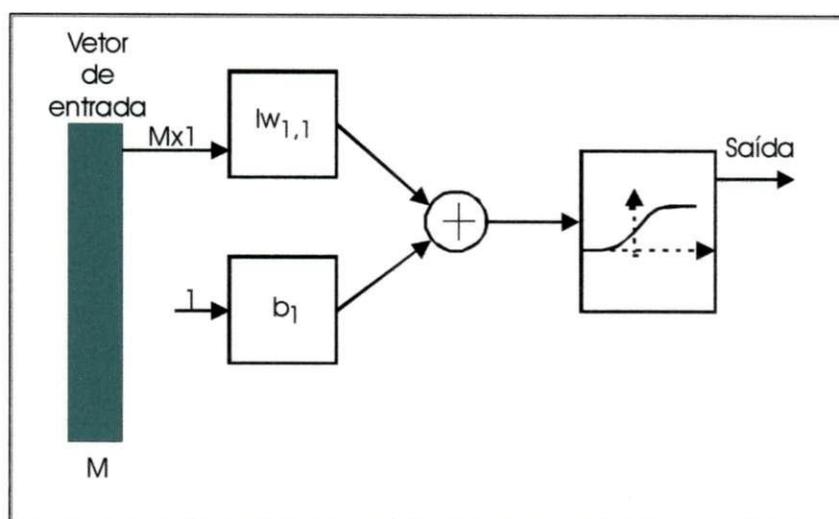


Figura 65 – Arquitetura básica de uma rede neural no Matlab (2000).

Nesta figura,  $M$  representa o número de elementos do vetor de entrada,  $b_1$  o viés e  $w$  o vetor peso. A saída é calculada através da aplicação da função de ativação:

$$\text{Saída} = \text{logsig}(Iw_{1,1} \cdot x + b_1). \quad (67)$$

A arquitetura básica apresentada pode ser composta em diversas camadas de tal forma a atender ao problema a ser analisado. O processo de treinamento da rede é denominado “regra delta generalizada” ou “regra retro-propagação (back propagation)” e requer um conjunto de treinamento que traduza o comportamento esperado da rede – vetor de entrada  $p$  e vetor objetivo  $t$ . Durante o processo de treinamento, o vetor peso  $w$  e o vetor de viés  $b$  são iterativamente ajustados para melhorar o desempenho da rede. A

função desempenho é normalmente traduzida pelo erro médio quadrático entre a saída da rede e o vetor objetivo  $t$ .

Existem diversos algoritmos de treinamento. Todos eles usam o gradiente da função desempenho para determinar como ajustar os vetores peso e de viés de tal forma a melhorar o desempenho da rede. O gradiente é determinado através da técnica “back propagation”, a qual é implementada por intermédio de avaliações retroativas ao longo da rede. Existem diversas variações dessa técnica. A implementação mais simples consiste em atualizar os vetores peso e de viés na direção na qual a função erro decresce mais rapidamente – o negativo do gradiente. Uma iteração desse algoritmo pode ser escrita como:

$$w_{k+1} = w_k - \alpha_k \delta_k, \quad (68)$$

onde  $w_k$  é o vetor de pesos e viés corrente,  $\delta_k$  é o gradiente corrente e  $\alpha_k$  é a taxa de aprendizagem.

No manual do Matlab (2000) são descritas duas maneiras nas quais os algoritmos de gradiente descendentes podem ser implementados: modo incremental e modo retroativo. No modo incremental, o gradiente é calculado e os vetores de peso e viés são atualizados após a aplicação dos vetores de entrada na rede. No modo retroativo todos os vetores de entrada são aplicados antes dos vetores de peso e viés serem atualizados. Na referência aqui citada são descritos diversos algoritmos que procuram treinar a rede a partir dessa última técnica. Para a base de dados constituída foram testados os seguintes algoritmos, cujos resultados serão apresentados e discutidos no Capítulo 4:

- `traingd` – Batch Gradient Descent;
- `traingdm` - Batch Gradient Descent with momentum;
- `traingda` – Variable Learning Rate;
- `traingdx` – variação do algoritmo anterior;
- `traingrp` – Resilient Backpropagation;
- `traingcf` – Fletcher-Reeves Update;
- `traingcp` – Polak-Ribière Update ;
- `traingcb` – Powell-Beale Restarts;

- `trainscg` – Scaled Conjugate Gradient;
- `trainbfgf` – BFGS Algorithm;
- `trainoss` – One Step Secant Algorithm;
- `trainlm` – Levenberg-Marquardt.

## **A.3 Extração de Atributos**

Sempre que possível, procurou-se extrair atributos para cada um dos domínios: tempo, frequência e a partir das transformadas wavelets. Os tópicos a seguir abordam os procedimentos matemáticos utilizados em cada uma dessas situações, fazendo uma introdução preliminar às técnicas de processamento digital de sinais.

### **A.3.1 Técnicas de Processamento Digital de Sinais**

O advento de computadores digitais providos de capacidade de processamento cada vez maiores, o desenvolvimento de algoritmos mais eficazes e as novas pesquisas científicas que incorporaram modelos matemáticos ainda mais robustos têm permitido que a análise e processamento de sinais sejam implementados computacionalmente, permitindo, inclusive, monitorações em tempo real de diversos fenômenos elétricos, ações essas que, até pouco tempo atrás, caracterizavam-se como impensáveis.

No processamento digital de sinais, duas ferramentas assumem importantes papéis: a transformada de Fourier e as transformadas wavelets, sendo que estas últimas vêm assumindo um papel de destaque diante de sua habilidade de realizar análise local, isto é, analisar uma minúscula área de um sinal de grandes proporções.

Além das transformadas, alguns aspectos fundamentais de processamento digital de sinais serão abordados nos tópicos a seguir, tais como o processo de aquisição associado às análises de erros de *amostragem, quantização e truncamento*.

Os erros de amostragem no processamento digital de sinais estão associados à taxa de aquisição de dados estabelecida. Tal taxa define o ponto instantâneo no qual os dados devem ser registrados. Deve-se procurar efetuar a amostragem a intervalos igualmente

espaçados com o cuidado de se evitar a deformação do sinal (“aliasing”), segundo descrevem Oppenheim e Schafer (1999).

Os erros de quantização, conforme descreve Oppenheim et al. (1997), estão associados ao processo de conversão analógico-digital (A/D). Um conversor A/D ideal converte um sinal contínuo no tempo para um sinal discreto no tempo, sendo que cada amostra é conhecida com precisão infinita. O erro de quantização é cometido quando do arredondamento para o nível de quantização mais próximo do valor real amostrado.

O erro de truncamento está associado ao comprimento finito para armazenamento binário das palavras no digitalizador. Existe uma correlação direta entre a capacidade de memória e o comprimento das palavras (bits) e conseqüentemente o custo dos dispositivos.

### **A.3.2 Transformada de Fourier**

Segundo Oppenheim e Willsky (1983), o desenvolvimento das análises de Fourier tem uma longa história envolvendo uma grande quantidade de indivíduos e a investigação de diversos fenômenos físicos distintos. O conceito do uso de “somas trigonométricas” para descrever fenômenos periódicos remonta, no mínimo, à era dos babilônios, os quais usaram tais idéias para predizer eventos astronômicos. A história moderna associada ao tema começou em 1748 com L. Euler que examinou o movimento da vibração de molas. Suas teorias foram criticadas por Bernoulli, em 1753, e por J. L. Lagrange, em 1759. Em 1807, Jean Baptiste Joseph Fourier apresentou seus estudos que tiveram um dos maiores impactos no desenvolvimento da matemática, os quais têm sido e ainda são de grande importância em uma larga faixa de aplicações científicas e de engenharia.

Um aspecto importante a se considerar na aplicação das transformadas de Fourier aos sinais elétrico sob análise está associado a suas características aleatórias. Nesse contexto, ao estabelecer classes de processos estocásticos, Priestley (1996) estabeleceu duas categorias:

- a) processos que são estacionários no mínimo até a ordem dois;
- b) demais processos.

Conforme descreveu o mesmo autor, um processo é estacionário até a ordem dois se: (i) ele tem o mesmo valor médio, em todo intervalo de tempo; (ii) ele tem a mesma variância, em todo intervalo de tempo e (iii) a covariância entre os valores em dois momentos,  $i$  e  $j$ , depende unicamente de  $(i-j)$  e não da localização dos dois momentos especificamente.

Para ilustrar essa distinção o autor listou alguns exemplos práticos de cada um dos tipos estabelecidos, nos quais os ruídos provenientes de circuitos elétricos pertencem à categoria (a), podendo ser considerados estacionários.

Com este mesmo enfoque, Oppenheim e Schaffer (1999) afirmam que processos estocásticos são, freqüentemente, utilizados para modelar sinais, quando o processo que gera o sinal é muito complexo para uma modelagem determinística razoável. Tipicamente, quando a entrada para um sistema linear invariante no tempo é modelado como um processo estocástico estacionário, muitas das características essenciais da entrada e da saída são representadas adequadamente por médias, variância, funções de auto-correlação ou densidade espectral de potência. Conseqüentemente, é de particular interesse estimar essas grandezas para um determinado sinal. Um estimador típico para o valor médio de um processo aleatório de um segmento de comprimento finito de dados  $M$  é a média amostral, definida como:

$$\hat{m}_x = \frac{1}{M} \sum_{n=0}^{M-1} r[n]. \quad (69)$$

Similarmente, um estimador típico da variância é a variância amostral, definida como:

$$\hat{\sigma}^2 = \frac{1}{M-1} \sum_{n=0}^{M-1} (r[n] - \hat{m}_x)^2. \quad (70)$$

Para o caso do espectro de potência, existem duas formas básicas para a sua estimação:

- análise do periodograma (baseado na transformação direta de Fourier de segmentos de comprimento finito do sinal), e
- cálculo da transformada de Fourier da estimativa da seqüência de auto-covariâncias do sinal.

Em qualquer um dos casos, o interesse é obter estimadores consistentes e não tendenciosos. Infelizmente, a análise de tais estimadores é muito difícil e, geralmente, apenas análises aproximadas podem ser obtidas. Nesse contexto, é importante introduzir uma ressalva associada ao enfoque feito por Ljung (1999), o qual demonstra que o espectro de um sinal  $r[n]$ ,  $n=1, \dots, M$ , enfocado como determinístico, coincide com o enfoque estocástico, quando  $M$  tende para infinito. A partir dessa premissa, a densidade espectral de potência do sinal sob análise foi obtida através da operacionalização computacional do seguinte par de transformada de Fourier, válidos para sinais discretos no tempo:

$$r[n] = \frac{1}{2\pi} \int_{2\pi} R(e^{j\omega}) \cdot e^{j\omega n} d\omega, \quad (71)$$

$$R(e^{j\omega}) = \sum_{n=-\infty}^{+\infty} r[n] \cdot e^{-j\omega n}. \quad (72)$$

### A.3.3 Transformada Wavelet

As transformadas Wavelets se constituem em uma nova tecnologia que procura realizar algo além do que a transformada de Fourier possibilita. Segundo Burrus et al. (1998), diferentemente da transformada de Fourier, na qual o sinal é decomposto em bases senoidais, na transformada wavelet as bases de decomposição são sinais que podem ter diversas formas, porém todas oriundas de translações e escalonamentos de uma base mãe  $\psi(t)$ , chamada função wavelet mãe.

$$f(t) = \sum_k \sum_j b_{j,k} \cdot \psi_{j,k}(t). \quad (73)$$

Nesta equação,  $\psi_{j,k}(t)$  é a Transformada Wavelet Discreta (TWD). A transformada é dita discreta porque as funções  $\psi_{j,k}(t)$  são obtidas por escalonamentos e translações discretas de  $\psi(t)$ , na forma:

$$\psi_{j,k}(t) = 2^{j/2} \cdot \psi(2^j \cdot t - k), \quad (74)$$

sendo os coeficientes  $b_{j,k}$  obtidos pelo produto interno<sup>7</sup>:

$$b_{j,k} = \langle f(t), \psi_{j,k}(t) \rangle = \int f(t) \psi_{j,k}(t) dt. \quad (75)$$

O produto interno, nada mais é do que uma comparação entre as funções  $f(t)$  e  $\psi_{j,k}(t)$ . Na função  $\psi_{j,k}(t)$ , o parâmetro  $j$  escala a função  $\psi(t)$ , e conseqüentemente determina o conteúdo de freqüência do sinal, obedecendo assim à propriedade do escalonamento da Transformada de Fourier. A Equação (76) representa essa propriedade:

$$f(t/a) \Leftrightarrow F(b\omega). \quad (76)$$

Ou seja, alargando-se uma função no tempo, estreita-se o seu espectro de freqüência e vice-versa. E, assim, ocorre um deslocamento da freqüência média da função  $F(\omega)$ . Tendo em vista essas considerações, pode-se concluir que variando  $j$  na Equação (92), varia-se todo espectro de freqüência. O coeficiente  $b_{j,k}$  caracteriza, de maneira satisfatória, o sinal  $f(t)$  em relação ao espectro. Também na Equação (74), o parâmetro  $k$  desloca  $\psi_{j,k}(t)$  no tempo. Assim, o produto interno da Equação (75) permite que se observem e se analisem fenômenos rápidos no tempo que estão contidos no sinal.

Uma maneira mais eficiente, em termos de algoritmo computacional, para caracterizar um sinal é desmembrar a Equação (73), nas Equações (77) e (78):

$$f(t) = \sum_{k=-\infty}^{\infty} c(k) \varphi_k(t) + \sum_{j=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} d(j,k) \psi_{j,k}(t), \quad (77)$$

em que,

$$\varphi_k(t) = \varphi(t-k). \quad (78)$$

A função  $\varphi(t)$  é conhecida como função escala. A função escala serve inicialmente para uma caracterização mais grosseira do sinal, enquanto as funções wavelets  $\psi_{j,k}(t)$

<sup>7</sup> Os sinais  $\langle \cdot \rangle$  representam o produto interno entre as funções internas aos mesmos.

refinam a caracterização. Os coeficientes  $c(k)$  e  $d(j,k)$  são determinados pelos produtos internos, os quais estão representados matematicamente nas Equações (79) e (80):

$$c(k) = \int f(t) \phi_k(t) dt, \quad (79)$$

$$d(j, k) = \int g(t) \psi_{j,k}(t) dt. \quad (80)$$

As funções escala e wavelet possuem uma relação biunívoca, ou seja, quando se determina uma delas, a outra também será definida.

Diversas famílias de wavelets são descritas na literatura. Através do aplicativo Matlab (2000), por exemplo, é possível o processamento de até 53 tipos diferentes de wavelets, conforme se encontram relacionados na Tabela 24.

Tabela 24 – Relação das wavelets disponíveis no aplicativo Matlab (2000).

FAMÍLIA DAS WAVELETS		
Código	Descrição	Sub-código dos Componentes da família
db	Wavelets Daubechies.	1; 2; 3; 4; 5; 6; 7; 8; 9; 10.
sym	Wavelets Symlets.	2; 3; 4; 5; 6; 7; 8.
coif	Wavelets Coiflets.	1; 2; 3; 4; 5.
bior	Wavelets bi-ortogonal.	1.1; 1.3; 1.5; 2.2; 2.4; 2.6; 2.8; 3.1; 3.3; 3.5; 3.7; 3.9; 4.4; 5.5; 6.8.
rbio	Wavelets bi-ortogonal reversa	1.1; 1.3; 1.5; 2.2; 2.4; 2.6; 2.8; 3.1; 3.3; 3.5; 3.7; 3.9; 4.4; 5.5; 6.8.
dmey	Aproximação discreta da Wavelet de Meyer	-

O Capítulo 4 apresenta resultados obtidos através do manuseio dessas ferramentas matemáticas, no sentido de processar os sinais adquiridos, extrair atributos dos sinais e utilizar técnicas de classificação. Uma etapa a ser avaliada é a escolha da “wavelet mãe” que conduza ao melhor resultado no processo de reconhecimento, como também o nível máximo de decomposição do sinal. Segundo Burrus et al. (1998), a decomposição é feita em níveis nos quais cada um deles incorpora dois parcelamentos do sinal denominados de “aproximação” e “detalhe”. Teoricamente, o processo de decomposição poderia se dar indefinidamente, entretanto, na prática, é aplicado número adequado de decomposição baseado em critério que avalie a informação contida em cada sinal decomposto, interrompendo o processo quando o novo sinal decomposto não incorporar refinamento significativo. Um dos critérios utilizados para aferir a

---

informação contida no sinal decomposto é através do cálculo da entropia. Segundo Cover e Thomas (1991), a entropia é definida como a informação média de uma fonte. Dentre diversas formulações contidas no aplicativo Matlab (2000), foi escolhida a modelagem de Shannon.

A partir da aplicação da transformada Wavelet, o sinal decomposto estará mais refinado, quanto menor a entropia. O nível mínimo de entropia pode ser, então, definido como critério para interrupção do processo de decomposição. A última parcela encontrada deve ser o foco para obtenção de padrões a serem submetidos ao processo de reconhecimento.

## **Bibliografia**

- AGEMA, Thermovision 550. Manual de Operação. 1996.**
- ANDERSON, T. W., An Introduction to Multivariate Statistical Analysis. John Wiley & Sons, Inc. 1960.**
- BEALE, R. e JACKSON, T., Neural Computing. Adam Hilger, Bristol, Philadelphia and New York, 1991.**
- BEZERRA, J. M. B., Aplicação de Técnicas de Reconhecimento de Padrões no Diagnóstico de Defeitos em Linhas de Transmissão. Dissertação defendida no Mestrado de Engenharia Elétrica e Sistemas do Centro de Tecnologia e Geociências da UFPE, Recife, PE, Brasil. 1995.**
- BEZERRA, J. M. B. e SILVA, A. F. D., Use of Pattern Recognition Techniques in Transmission Lines Defects Monitoring. IEEE/KTH Stockholm Power Tech Conference., pp 22-27. 1995.**
- BEZERRA, J.M.B. Diagnóstico de Linhas de Transmissão com Vistas a Implementação do Processo de Recapitação. III-ENEAT – Encontro Nacional de Engenharia de Alta Tensão. 2000a. Anais em CD.**
- BEZERRA, J.M.B.; REGIS, O. E LICOLIN, E. Aplicação de Termovisores de Última Geração no Controle e Ampliação da Ampacidade de Linhas de Transmissão. VII-SEPOPE – Symposium of Specialists in Electric Operational and Expansion Planning. 2000b. Anais em CD.**
- BEZERRA, J. M. B.; DEEP, S. S. e LIMA, A. M. N., Application of Risk Criteria on Transmission System Insulation Upgrade. IEEE Conference on Electrical Insulation and Dielectric Phenomena. México. Anais em CD e cadastrado no IEEE/xplore. 2002a.**

- BEZERRA, J. M. B.; LIMA, A. M. N.; DEEP, G. S., **The Application of Finite Elements to Accident Risk Evaluation in Hot Line EHV Insulators Maintenance**. V INDUSCON – Conferencia de Aplicações Industriais. Salvador/BA. Anais em CD. 2002b.
- BEZERRA, J. M. B.; LIMA, A. M. N.; DEEP, G. S. e COSTA, E. G., **Estudo da Distribuição de Tensão em Cadeias de Isoladores Aéreos de Alta Tensão em Ambientes Poluídos**. XVII SNPTEE – Seminário Nacional de Produção e Transmissão de Energia Elétrica, realizado em Uberlândia, MG, Brasil. 2003a.
- BOLOGNA, F. F; BRITTEN, A. C.; WATRIDGE, G. e STEVENS, D. J. e GRIGORAKIS, G., **Leakage Currents on Lightly Polluted on 275 kV Glass Disc Insulator String in Condition of Light Wetting**. IEEE, pp 739-742. 1999.
- BIDDLE, **Leak and Corona Detection**. Bulletin 56-1a. 1990.
- BURRUS, C. S., GROPINATH, R. A. e GUO, H., **Introduction to Wavelet Transforms**, Primeira Edição, Prentice Hall, Inc., Upper Saddle River, NJ. 1998.
- BUXTON, B.F.; LANGDON, W.B. e BARRET, S. J. **Data Fusion by Intelligent Classifier Combination**. *Measurement and Control*. vol 34, No. 8, October 2001, p 229-234.
- CHESF, **Relatório de Desempenho de Linhas de Transmissão**. Documento interno. 2003.
- CIGRÉ, Grupo de Trabalho 04 do Comitê de Estudos N<sup>o</sup> 33, **A Critical Comparison of Artificial Pollution Test Method for HV Insulators**. *ELECTRA*, N<sup>o</sup> 64. 1979.
- COVER, T. M. e THOMAS, J. A., **Elements of Information Theory**. John Wiley and Sons, Inc., Canada. 1991.
- DANIKAS, M. G.; GAO, N. e ARO, M., **Partial Discharge Recognition Using Neural Networks: a Review**. *Electrical Engineering*. Springer-Verlag, pp 87-93. 2003.
- DUDA, R. O. e HART, P. E., **Pattern Classification and Scene Analysis**. John Wiley & Sons, New York, NY, USA. 1973.
- EPRI - Electric Power Research Institute, **Transmission Line Reference Book 345 kV and Above**. Fred Weidner & Son Printers, Inc., New York, NY, USA. 1975

- FERNANDO, M. A. R. M. e GUBANSKI, S. M., **Leakage Current Patterns on Artificially Polluted Composite Insulators**. IEEE Conference on Electrical Insulation and Dielectric Phenomena, San Francisco, USA, pp 394-397. 1996.
- FERNANDO, M. A. R. M. e GUBANSKI, S. M. **Analysis of Leakage Current Wave Forms for Field-aged and New Composite Insulators**. IEEE Conference on Electrical Insulation and Dielectric Phenomena, pp 350-353. 1997.
- FUKUNAGA, K., **Introduction to Statistical Pattern Recognition**. Academic Press, New York, NY, USA. 1972.
- FUCHS, R. D., **Transmissão de Energia Elétrica. Linhas Aéreas**. Livros Técnicos e Científicos Editora S.A, São Paulo, SP, Brasil. 1979.
- FURTADO, R.C.; BEZERRA, J.M.B.; SOARES, F.G.; DACONTI, J.R. **The Incorporation of Environmental Costs into the Planning of a Power System Interconnection in Brazil**. Biental CIGRE. 2000.
- GULSKI, E. e KREUGER, F. H., **Computer-aid Recognition of Discharge Sources**. IEEE Transactions on Electrical Insulation, Vol. 27, N<sup>o</sup> 1, pp 82-92. 1992.
- HOEL, P. G. **Estatística Matemática**. Trad. de Othon Guilherme Pinto Bravo. Editora Guanabara Dois S. A. Quarta edição, S. A., Rio de Janeiro, RJ. 1980.
- HOOF, M. e PATCH, R., **Voltage – Difference Analysis, a Tool for Partial Discharge Source Identification**. International Symposium on Electrical Insulation, Montreal, Quebec, Canada, pp 401-406. IEEE. 1996.
- IEC 60270, **High-voltage Test Techniques – Partial Discharge Measurements**. IEC. 2000.
- IEC 507, **Artificial Pollution Tests on High-Voltage Insulators to be used on a.c. Systems**. Segunda edição. IEC. 1991.
- IEC 815, **Guide for The Selection of Insulators in Respect of Polluted Conditions**. IEC. 1986.
- JAIN, R., KASTURI, R. e SCHUNCK, B. G., **Machine Vision**. McGraw-Hill, Inc., New York, NY, USA. 1995.
- KLEINE-OSTMAM, T. e BELL. A. E. **A Data Fusion Architecture for Enhanced Position Estimation in Wireless Networks**. IEEE Communications Letters, Vol. 5, No. 8, August 2001, p 343-345.

- KREUGER, F. H., **Partial Discharge Detection in High-Voltage Equipment**. Butterworth & Co. (Publishers) Ltd., London, UK. 1989.
- LJUNG, L., **System Identification. Theory for The User**. Prentice Hall PRT. Information and System Science Series, Upper Saddle River, NJ, USA. 1999.
- LOPES, I. J. S., **A Study of Surface Discharges During the Early Ageing of Silicone Rubber Insulation Using Partial Discharge Analysis**. Tese de Doutorado. Universidade de Waterloo, Canada. 2001.
- MATLAB, **The Language of Technical Computing**. Version 6.0. 2000.
- MEDEIROS, M. A. A., **Projeto e Implementação de um Circuito Para Detecção e Aquisição de Dados de Descargas Parciais em Sistemas Convencionais**. Dissertação de Mestrado. COPELE/UFCG, Campina Grande, PB, Brasil. 2003.
- NERI, M. G. G., **Um Sistema Computadorizado para Medição de Descargas Parciais**. PIBIC/CNPq/UFCG. Relatório Final. Campina Grande, PB, Brasil. 2002.
- NIGRI, A. I., **Desempenho de Linhas de Transmissão. Ponto de Vista da Manutenção**. XV-SNPTEE – Seminário Nacional de Produção e Transmissão de Energia Elétrica, Foz do Iguaçu, PR, Brasil, anais em CD. 1999.
- OPPENHEIM, A. V. e Willsky A. S. com Nawab H. S., **Signals & Systems**. Prentice Hall Signal Processing Series, Upper Saddle River, NJ, USA. 1983.
- OPPENHEIM, A. V. e Schafer, R. W. com Buck, J. R., **Discrete-Time Signal Processing**. Prentice Hall Signal Processing Series, Upper Saddle River, NJ, USA. 1999.
- PRIESTLEY, M. B., **Spectral Analysis and Time Series – Probability and Mathematical Statistics, Vol. II**. Academic Press Inc., San Diego, Ca, USA. 1996.
- PROJECT EHV, **EHV Transmission Line Reference Book**. Edison Electric Institute, New York, NY, USA. 1968.
- RÉGIS, O.; FREIRE, A.R.F.; BEZERRA, J.M.B. **Sobrecarga em Ativos do Agente de Transmissão**. XVI-SNPTEE. 2001.
- RICHARDS, C. N. e RENOWDEN J. D., **Development of a Remote Insulator Contamination Monitoring System**. IEEE Transactions on Power Delivery, Vol. 12, No. 1, pp 389 – 397. 1997.

- RIZK, F. A. M., **Mathematical Models for Pollution Flashover**. Electra, Vol. 78, pp. 71-103. 1981.
- SALAM, M.A.; SATTAR S. A.; SAYED, Y. e GHALLY, M., **Early Detection of Weak Points in MEEC Distribution System**. IEEE pp 2541 - 2545. 2001.
- SATISH, L. e NAZNEEN, B., **Wavelet-based Denoising of Partial Discharge Signals Buried in Excessive Noise and Interference**. IEEE Transaction on Dielectrics and Electrical Insulation, pp 354 – 367. abril/2003.
- SATISH, L. e GURURAJ, B. I., **Partial Discharge Pattern Classification Using Multilayer Neural Networks**. IEE Proceedings – A., Vol. 140, pp 323 – 330. 1993.
- SILVA, D., **Estudo Qualitativo de Técnicas Lineares de Seleção de Atributos: Uma Aplicação em Sistemas de Potência**. Dissertação de Mestrado, UFPE, Recife, PE, Brasil.1990.
- SCHALKOFF, R., **Pattern Recognition Statistical, Structural and Neural Approaches**. John Wiley and Sons, Inc., Canada. 1992.
- SLANSKY, J. e WASSEL, G. N., **Pattern Classifier and Trainable Machines**. Spring – Verlag New York Inc., NY, USA. 1981.
- SHIM, J. J S. e SIEW, W. H., **Digital Signal Processing Applied to the Detection of Partial Discharge: an Overview**. IEEE Electrical Insulation Magazine, Vol. 16, No 3, pp 6-12. 2000.
- STEWART, B. G.; HEMPURN, D. M; KEMP, I. J.; NESBIT, A. e WATSON, J., **Detection and Characterization of Partial Discharge Activity on Outdoor High Voltage Insulating Structures by RF Antenna Measurement Techniques**. High Voltage Engineering Symposium, Conference Publication N<sup>o</sup> 467, pp 5.188 – 5.191. 1999.
- SUNDARARAJAN, R. e GORUR R. S., **Dynamic Arc Modeling of Pollution Flashover of Insulators under dc Voltage**. IEEE Transactions on Electrical Insulation, Vol. 28, No. 2, pp 209 – 218. April 1993.
- TEKTRONIX, **Spectrum Analyzer 2714. User Manual**. 1994.
- TEKTRONIX, **Getting Started with the TD2301/S45D010. Measurement Software**. Product Group 45. 1992.

- 
- VAZQUEZ; I. R e CHAVEZ, J. L. F., **Criteria for the Diagnostic of Polluted Ceramic Insulators Based on the Leakage Current Monitoring Technique.** IEEE Conference on Electrical Insulation and Dielectric Phenomena, pp 715 – 718. 1999.