

Avaliação de Sensor de Ultra-Som como Técnica Preditiva na Manutenção de Subestações e Linhas de Transmissão e Distribuição

J. M. B. Bezerra, R. R. B. Aquino, J. B. Oliveira, O. Nóbrega, T. M. A. Silveira, E. G. Costa, M. G. G. Néri, T. V. Ferreira, J. L. P. Dantas e P. L. Mendonça

Resumo – Este artigo resume os resultados alcançados com o estudo para aplicação de sensor de ultra-som como técnica preditiva na manutenção de subestações e linhas de transmissão e distribuição. Foram constituídas amostras a partir de isoladores adquiridos e submetidos previamente a ensaios de raios x. Essas amostras, após pré-classificação como “com defeito” ou “sem defeito”, foram submetidas a ensaios elétricos, durante os quais se constituiu banco de sinais de ultra-som. Esse banco viabilizou a construção de conjunto de treinamento para elaboração de sistema de diagnóstico. Na montagem desse sistema foram testadas diversas técnicas de reconhecimento de padrões: Fisher, Karhunen-Loève, redes neurais artificiais lineares e não lineares, como também a aplicação de diversos atributos dos sinais adquiridos. O artigo descreve protótipo montado a partir da técnica de classificação que apresentou melhor desempenho. São feitas, ainda, considerações quanto a refinamentos que podem ser incorporados a futuras versões do processo de diagnóstico implementado.

Palavras-chave – Diagnóstico de defeitos; Isoladores da alta tensão; Reconhecimento de padrões; Redes neurais artificiais; Sensor de ultra-som.

I. INTRODUÇÃO

A monitoração de componentes elétricos de um sistema de potência, através de processos visuais ou de sensores

Este trabalho foi desenvolvido no âmbito do Programa de Pesquisa e Desenvolvimento Tecnológico do Setor de Energia Elétrica regulado pela ANEEL e consta dos Anais do V Congresso de Inovação Tecnológica em Energia Elétrica (V CITENEL), realizado em Belém/PA, no período de 22 a 24 de junho de 2009.

Os autores agradecem a todo o apoio da CELPE e ANEEL, através do Programa de Pesquisa e Desenvolvimento do Setor Elétrico, o que viabilizou o aporte dos recursos necessários ao Projeto de Pesquisa e Desenvolvimento, cujos resultados obtidos estão registrados neste artigo técnico.

J. M. B. Bezerra trabalha na Universidade Federal de Pernambuco (e-mail: jmhb@ufpe.br).

R. R. B. Aquino trabalha na Universidade Federal de Pernambuco (e-mail: rriba@ufpe.br).

J. B. Oliveira é mestrando do PPGEE da Universidade Federal de Pernambuco (e-mail: josinaldo.bezerra@gmail.com).

O. Nóbrega é doutorando do PPGEE da Universidade Federal de Pernambuco (e-mail: otoninobrega@hotmail.com).

E. G. Costa trabalha na Universidade Federal de Campina Grande (e-mail: edson@dee.ufcg.edu.br).

M. G. G. Néri é doutorando do COPELE da Universidade Federal de Campina Grande (e-mail: maxneri@dee.ufcg.edu.br).

T. V. Ferreira é doutorando do COPELE da Universidade Federal de Campina Grande (e-mail: tarsovillela@yahoo.com.br).

J. L. P. Dantas é engenheiro da Companhia Energética de Pernambuco (e-mail: dantas@celpe.com.br).

P. L. Mendonça é engenheiro da Companhia Energética de Pernambuco (e-mail: phillip@celpe.com.br).

especiais representa uma ação preditiva de grande valia no sentido de se evitar falhas que comprometam o fornecimento normal de energia elétrica à sociedade.

Neste contexto, as falhas em isolamentos elétricos são as principais responsáveis por interrupções no suprimento adequado aos diversos consumidores. De uma forma mais enfática pode ser afirmado que o desempenho das instalações está diretamente relacionado com o desempenho do seu sistema de isolamento. A introdução de tecnologias confiáveis que possibilitem identificar o desenvolvimento de 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.

A avaliação do sensor de ultra-som para monitorar tais defeitos prende-se ao fato de que o dispositivo já existe na CELPE e é de baixo custo, quando comparado com outros sensores (ultra-violeta, termovisor, etc) além do que esses sensores mais elaborados também possuem as suas limitações técnicas. Optou-se, inclusive, em centrar esforços na monitoração de unidades isolantes uma vez que se tinha uma expectativa maior quanto a bons resultados através da monitoração de defeitos internos nos isoladores, aplicando tais sensores.

O artigo descreve inicialmente a metodologia utilizada, introduzindo as técnicas de reconhecimento de padrões aplicadas e os diversos atributos testados. Posteriormente são descritos os ensaios de raios x realizados e as montagens elétricas implementadas para aquisição dos sinais de ultra-som. Em seguida é apresentada a estrutura do banco de sinais constituído para viabilizar a montagem dos conjuntos de treinamento. Em etapa posterior são apresentados os resultados adquiridos através da aplicação das técnicas de reconhecimento de padrões introduzidas, fazendo-se análise crítica dos diagnósticos apresentados. Em seguida é comentado o protótipo de sistema de diagnóstico montado a partir da técnica de classificação que apresentou melhor desempenho, quando são apresentados, também, resultados obtidos em inspeções realizadas na rede elétrica da UFPE. O artigo é concluído, fazendo-se comentários finais sobre o uso de sensores de ultra-som como técnica de diagnóstico de defeitos em isoladores de alta tensão e, ainda, encaminhando diversos refinamentos que podem ser implementados em versões posteriores do sistema de diagnóstico desenvolvido.

Os resultados obtidos neste artigo foram obtidos ao longo da execução do projeto “Estudo de alternativa ao sistema de aterramento utilizado nos sistemas elétricos de distribuição”

código ANEEL: 0043-008/2005. O projeto teve início no Ciclo 2004/2005 finalizando no Ciclo 2005/2006, executado pela Universidade Federal de Pernambuco, tendo a Universidade Federal de Campina Grande como entidade consultora e suporte financeiro da Companhia Energética de Pernambuco.

II. METODOLOGIA UTILIZADA

O processo de diagnóstico foi construído a partir da aplicação de técnicas de reconhecimento de padrões. Um sistema de reconhecimento de padrões pode ser representado, simplificada, em diagrama de blocos, conforme ilustra a Figura 1 [1]. Nesta figura, o padrão de entrada (sinais adquiridos através dos sensores, para o caso analisado) 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). Neste contexto, um classificador pode ser definido como um dispositivo que agrupa dados em categorias. Os dados são freqüentemente estruturados em vetores no espaço de atributos. Todo ponto neste espaço está diretamente associado com um vetor de atributos. Cada componente x_i do vetor x é usualmente uma característica ou propriedade de um objeto sob análise.




Figura 1 – Um sistema de reconhecimento de padrões.

A construção do sistema de reconhecimento ilustrado na Figura 1 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 e análise criteriosa da técnica de reconhecimento de padrões a ser utilizada. De uma forma ampla as técnicas de classificação podem ser divididas em lineares e não lineares.

A. Técnicas Lineares de Reconhecimento de Padrões

Como descrito anteriormente, o conceito de classificação pode ser expresso em termos do particionamento do espaço de atributos. Uma das formas de se realizar este particionamento é através do uso de funções discriminantes. Tais funções são associadas a cada uma das classes e dão uma medida da separação entre elas.

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:

$$R_j = \{x | g_j(x) \geq g_i(x) \text{ para todo } i\}, \quad (1)$$

sendo $g_j(x)$ da forma:

$$g_j(x) = w_j^T x + w_{j0}, \quad (2)$$

no qual $w_j^t = (w_{j1}, \dots, w_{jd})^t$ denota o transposto do vetor peso w_j , então $g_j(x)$ é uma função discriminante linear e o classificador é denominado classificador linear. Diversas técnicas estão disponíveis na literatura para construção dessas funções discriminantes. Neste projeto foram avaliadas as técnicas de Fisher, componentes principais e Kahunen-Loève [1], [2], [3].

As redes neurais também podem ser aplicadas como técnicas lineares de classificação. As Redes neurais artificiais (RNA) são sistemas paralelos distribuídos compostos por unidade de processamento simples (nodos) que calculam determinadas funções matemáticas, lineares ou não lineares. Esta forma de computação não-algorítmica é caracterizada por sistema que, relembram a estrutura do cérebro humano. O grande apelo destes modelos está em sua capacidade de “aprender”, generalizar ou extrair regras automaticamente de conjuntos de dados complexos [4] e [5].

Neste projeto foram utilizados quatro modelos neurais para criar os classificadores neurais: dois lineares e dois não lineares. Os modelos lineares são criados a partir de neurônios artificiais lineares ajustados através do algoritmo de mínimo quadrado médio (LMS). Já os modelos não lineares, são criados através das redes Perceptrons de múltiplas camadas (MLP) treinadas com algoritmo de treinamento de Levenberg Marquadt (LM) [6].

Também foi utilizado o método estatístico de validação cruzada múltipla para evitar conclusões distorcidas sobre os classificadores criados a partir das redes neurais. A validação cruzada múltipla consiste em criar dez experimentos, nos quais os exemplos fornecidos aos conjuntos de treinamentos e de testes são sempre diferentes, tentando melhor distribuir os dados entre os conjuntos. Isto porque, uma seleção tendenciosa dos conjuntos de treinamento e teste pode influenciar no resultado final do classificador.

As redes Lineares são semelhantes às redes perceptron de uma única camada, diferenciando apenas na função de ativação, já que as redes perceptrons usam funções limitadas, enquanto as lineares, funções lineares.

Assim como os perceptrons, as redes lineares só têm a capacidade de resolver problemas linearmente separáveis. As redes lineares são ajustadas a partir de exemplos contendo padrões de entradas e saídas através de um aprendizado supervisionado. Este tipo de aprendizado consiste em minimizar o erro durante a etapa de treinamento (ajuste) conforme ilustrado na Figura 2. Para cada vetor de entrada você pode calcular erro produzido pela rede através da diferença entre o valor calculado e o valor desejado. Desta forma, os pesos são ajustados para minimizar o erro durante o treinamento.

Um neurônio artificial linear representado pela Figura 3 é caracterizado pela função de ativação linear em sua saída,

que calcula uma combinação linear entre os pesos e sua entrada mais o bias (b).

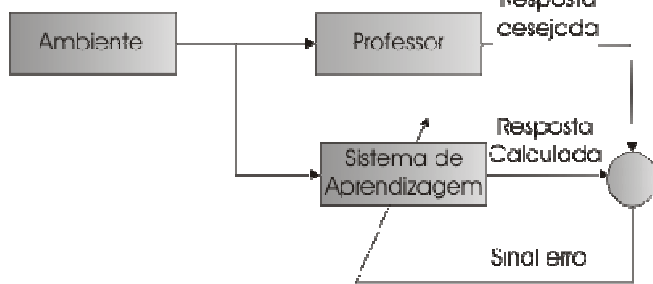


Figura 2 – Processo de aprendizado supervisionado

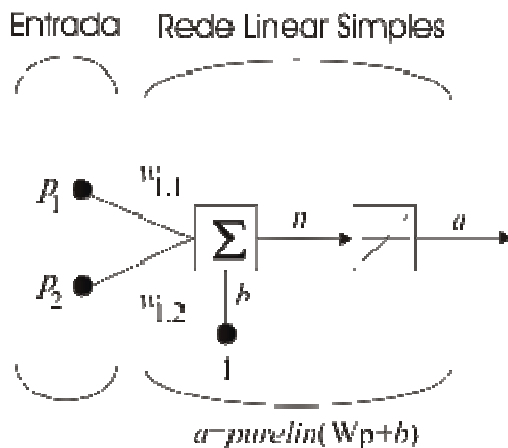


Figura 3 – Neurônio artificial linear

Onde:

- p_i representa o i -ésimo elemento do vetor de entrada;
- $w_{1,i}$ representam os valores dos pesos da i -ésima conexão do neurônio com a i -ésima entrada;
- b representam o bias;
- a representa a saída da função de ativação linear.

Obs: a função linear na Figura 3 é representada pela função *purelin*, que é calculada conforme a equação abaixo [2] e [3].

$$a = w_{1,1}p_1 + w_{1,2}p_2 + b, \quad (3)$$

Geometricamente o neurônio linear, com duas entradas, é representado pelo gráfico da Figura 4. Neste gráfico observa-se que os vetores de entradas sobre o plano acima da reta (plano cinza) fornecem valores de ativação maior que zero ($a > 0$), enquanto vetores abaixo da reta (plano branco) fornecem valores de ativação menor que zero ($a < 0$). Usando estas características das redes lineares, pode ser criado um classificador de duas classes distintas linearmente separáveis, em que valores de $a > 0$ representam uma determinada classe enquanto $a < 0$ representa a outra.




Figura 4 – Representação gráfica de um neurônio linear

O Algoritmo mais conhecido para minimizar os erros durante o treinamento das redes lineares é o LMS (Least Mean Square), também conhecido como o algoritmo de aprendizagem de Widrow-Hoff. Este algoritmo usa as equações (4) e (5) para atualizar os pesos e bias [4], [5].

$$W(k+1) = W(k) + 2\alpha e(k)p^T(k), \quad (4)$$

$$b(k+1) = b(k) + 2\alpha e(k), \quad (5)$$

Onde:

- α taxa de aprendizagem;
- e erro calculado no k -ésimo exemplo apresentado;

Obs:

- Se α é grande demais pode causar instabilidade durante o processo de treinamento, porém se α é pequeno demais o treinamento pode ser proibitivamente lento. Portanto, o uso do algoritmo LMS exige uma escolha adequado de α .

Os classificadores neurais lineares usados neste trabalho (RNA 1 e RNA 2) utilizam 80 % dos exemplos para o conjunto de treinamento e os demais 20 % para o conjunto de teste. Este conjunto de teste é usado apenas para estimar a performance destes classificadores quando em operação real.

No modelo RNA1 as classes são representadas com apenas 1 neurônio na saída das RNA, isto é, 0 quando a classe indicada for a Classe 0 e 1 quando indicar a Classe1. Este modelo é representado pela Figura 5.

Na montagem dos classificadores destes modelos foram avaliadas três arquiteturas de redes diferentes: rede 1 com 5 neurônios ocultos, rede 2 com 6 neurônios e rede 3 com 7 neurônios.

Além de avaliar, mesmo de maneira incipiente, a influência da arquitetura das RNA no desenvolvimento dos classificadores neurais, também foi analisado o impacto das inicializações dos pesos durante os treinamentos através de 10 inicializações aleatórias para a mesma rede [7], [8].




Figura 5 – Arquitetura RNA do Modelo 1

Desta forma, foram realizados 30 treinamentos das redes neurais deste modelo, onde, no término de cada um dos treinamentos, as redes eram simuladas para o conjunto de teste. Este conjunto é totalmente distinto do conjunto de treinamento, sendo, portanto usado para estimar o erro de classificação (EC) do modelo.

Na construção do modelo RNA2 foi utilizada uma rede neural linear com dois neurônios artificial. Este modelo é similar ao método de Karhunen-Loève, diferenciando apenas nos cálculos dos parâmetros (ajuste do modelo).

Para classificadores criados através deste modelo, a representação das classes de saídas é realizada atribuindo o valor (1,-1) para classe sem descargas internas e (-1,1) para classe com descargas internas.

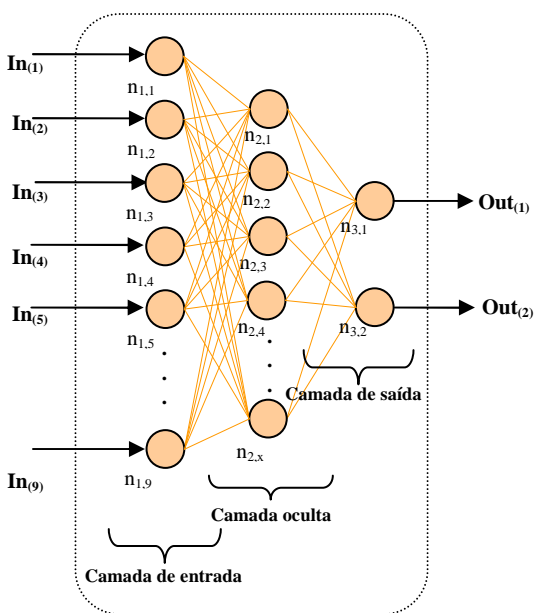


Figura 6 – Arquitetura RNA do Modelo 2

Diferentemente do modelo 1, neste modelo as classes de saídas são codificadas a partir de 2 neurônios: (0,1) quando se quer indicar a Classe 0 e (1,0) para indicar a Classe 1. Na Figura 6 encontra-se ilustrado este modelo.

De maneira similar ao modelo 1, aqui também foram avaliadas três redes distintas: rede 1 com 5 neurônios ocultos, rede 2 com 6 neurônios e a rede 3 com 7 neurônios ocultos. Sendo todas estas redes inicializadas 10 vezes pelo mesmo motivo já explicado para o modelo anterior.

B. Técnicas não Lineares de Reconhecimento de Padrões

No desenvolvimento dos classificadores não lineares são usadas as redes do tipo perceptrons de múltiplas camadas (MLP). Estas redes têm sido aplicadas com sucesso para resolver diversos problemas de difíceis classificações.

As redes MLP são redes do tipo feedforward, ou seja, o processamento da informação se dá no sentido progressivo. Tipicamente, a rede consiste de um conjunto de unidades sensoriais (nós de fonte) que constituem a camada de entrada, uma ou mais camadas ocultas de nós computacionais (neurônios artificiais) e camada de saída de nós computacionais. O sinal de entrada se propaga para frente através da rede camada a camada.

As redes MLP utilizadas no desenvolvimento dos classificadores não lineares são constituídas de três camadas: camada de entrada, camada de oculta e camada de saída. Estes classificadores receberam o nome de não lineares porque utilizam funções de ativações não lineares do tipo tansig representado pela Figura 7.




Figura 7 - TanSig (Sigmoid Transfer Function)

Os dois classificadores não lineares apresentados neste trabalho se diferenciam na maneira de representar as classes: isoladores com descargas internas e isoladores sem descargas.

O primeiro modelo de classificador desenvolvido usa apenas um neurônio para representar as classes de saídas, enquanto o segundo utiliza dois neurônios, esses modelos foram enominados RNA3 e RNA4, respectivamente.

Além disto, os modelos de classificação RNA 3 e RNA 4 necessitam determinar o número mais adequado de neurônios na camada oculta, para isto foi realizado o processo de validação cruzada. Este processo utiliza o erro médio quadrático (MSE) como critério de seleção.

Desta forma os dados para constituir estes modelos requer uma distribuição um pouco diferente da usada pelos modelos RNA1 e RNA 2, em que 80 % dos dados foram para treinamento e 20% para teste. Para os modelos RNA 3 e RNA 4 as partições dos conjuntos foram realizadas da seguinte maneira:

- Conjunto de treinamento, formado de 60% do total de padrões, os quais foram usados nos treinamentos dos modelos neurais;
- Conjunto de validação, formado de 20% dos padrões, sendo este usado para supervisionar o treinamento com o intuito de aumentar as generalizações dos modelos;
- Conjunto de teste, formado de 20% dos padrões, usado para avaliar as performances dos modelos neurais.

C. Caracterização e Escolha de Atributos

Diversos atributos foram avaliados conjuntamente com a aplicação dos modelos de classificação, Na Tabela 1 são listados os atributos analisados.

Tabela I – Tipos de Atributos Analisados.

Tempo	Frequência	Wavelets
Média	Faixas do espectro	Média
Curtose		Curtose
Deformação	Energia total	Deformação
Passagens p/0		Passagens p/0
Desvio padrão		Desvio padrão
Nº valores<zero		Nº valores<zero
Valor eficaz		Valor eficaz
Coef. de variação		Coef. de variação
Faixas histograma		Faixas 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 achatamento da distribuição dos valores sob análise em relação a distribuição normal;
- Deformação: parâmetro estatístico que mede o estreitamento 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;
- Faixas do espectro: energia contida por faixa do espectro de frequência;
- Energia total: energia total contida no sinal sob análise.

Adicionalmente, foram analisados os atributos associados

ao cálculo do centróide tendo em vista o desempenho na formação dos modelos neurais. Esta consiste em calcular os centróides e as áreas da parte superior, inferior e total do sinal, a partir das Equações 5 e 6, conforme ilustrado graficamente na Figura 8.

$$\bar{x} = \frac{\int_a^b x \cdot f(x) dx}{\int_a^b f(x) dx}, \quad (6)$$

$$\bar{y} = \frac{\int_c^d y \cdot g(x) dx}{\int_c^d g(x) dx}. \quad (7)$$

Além do cálculo dos centróides e das áreas, os dados foram normalizados através da Equação (8) para evitar que os neurônios das redes saturassem, dificultando o aprendizado durante os treinamentos.

$$\bar{x} = \frac{0,1 \cdot (x_{\max} - x) - 0,9 \cdot (x_{\min} - x)}{x_{\max} - x_{\min}}. \quad (8)$$




Figura 8 – Centróides de um dos sinais de ultra-som

III. ENSAIOS REALIZADOS

Foram adquiridos 254 isoladores poliméricos para a tensão nominal de 13,8 kV, sendo 200 do fabricante Vicentino's e 54 do fabricante PLP. Todas essas amostras foram submetidas a ensaios de raios x para identificar a presença de possíveis defeitos (bolhas internas). A Figura 9 exemplifica uma imagem gerada a partir dos ensaios de raios x. Depois de classificados nas classes “com defeito” ou “sem defeito”, em função da existência de bolhas detectadas nos ensaios de raios x, os isoladores foram submetidos a ensaios elétricos. Os ensaios constaram de aplicar tensão de 3,5 p.u. e 3 p.u., durante 10 minutos. Após esse tempo eram registrados os sinais de ultra-som oriundo dos isoladores ensaiados.




Figura 9 – imagem de isolador submetido a ensaio de raios x

Na Figura 10 encontra-se ilustrada a montagem elétrica realizada. Observa-se, nesta figura, que os ensaios também eram monitorados por detector de descargas parciais e por instrumento de detecção de corona (DayCor). Tais instrumentos eram auxiliares no sentido de procurar assegurar a existência de descargas internas ao isolador sem que houvesse geração de descargas corona. Essa preocupação conduziu a refinamentos diversos nas montagens de tal forma a se procurar forçar a geração de descargas nas bolhas internas ao isolador sem provocar o efeito corona indesejável para o experimento. A montagem final obtida encontra-se ilustrada na Figura 11. Na Figura 12 encontra-se registrado o posicionamento do sensor de ultra-som para aquisição dos sinais [1], [9].




Figura 10 – Montagem elétrica realizada



Figura 11 – Arranjo elétrico para minimizar a geração de descargas corona



Figura 12 – Sensor de ultra-som posicionado para aquisição dos sinais.

Após a aquisição dos sinais, foram feitas análises específicas para se constituir o conjunto de treinamento. Como foram gravados sinais para a tensão de 3 e 3,5 p.u., todas as imagens gravadas através do DayCor foram avaliadas visualmente com o intuito de se aferir a intensidade do efeito corona ainda presente e, eventualmente, se rejeitar algumas amostras adquiridas. Na Figura 13 encontra-se ilustrada uma das imagens obtidas através do DayCor. Tais análises permitiram constituir novos conjuntos de sinais caracterizados como aptos e não aptos. Além dos sinais individuais também foi construído banco de sinais associados à presença normal de ruídos corona na tensão nominal da rede trifásica. Na Figura 14 encontra-se ilustrado o arranjo concebido, o qual foi montado, escolhendo-se aleatoriamente isoladores classificados como “sem defeitos”. Tais montagens foram feitas 10 vezes, gerando-se 30 sinais de corona, associados a cada um dos isoladores dos arranjos. A função desses sinais foi de constituir banco de sinais com ruído, a partir do qual, foi escolhido, também aleatoriamente, um deles para ser somado aos sinais obtidos para as descargas internas, simulando-se desta forma a existência simultânea dos dois fenômenos: descargas internas nas bolhas e descargas corona na tensão nominal. Esta condição está mais condizente com situações reais encontradas no campo.



Figura 13 – Registro de descargas corona através do DayCor



Figura 14 – Arranjo trifásico

IV. ESTRUTURAÇÃO DO BANCO DE SINAIS

Para a elaboração dos modelos de diagnóstico de isoladores ficaram disponíveis, portanto, conjuntos de base de dados, montados a partir dos resultados obtidos nos ensaios com uso dos 200 isoladores Vincentino's e 54 PLP. Sendo que para esses 254 isoladores, nestes conjuntos estão isoladores "Bons e Ruins". Foram realizados dois conjuntos de ensaios: o primeiro a 3,0 p.u. e o segundo a 3,5 p.u. Com intuito de avaliar a importância e interferência do efeito corona em todas as medições de ultra-som. Através das análises posteriores, com suporte das imagens geradas pelo DayCor, o conjunto de ensaios na tensão de 3,5 p.u. foi considerado, como também algumas amostras colhidas na classe de tensão de 3,0 p.u.

Nas análises visuais das imagens geradas, feitas uma a uma, nas quais os níveis de corona foram classificados como 0 ou 1 (nível baixo), sendo consideradas "aptas", e os que obtiveram 2 ou 3 (nível alto), foram consideradas "não aptas". Na Figura 15 é mostrado o resumo quantitativo de todos os dados que foram disponibilizados para a construção dos modelos de Classificação, os quadros sombreados indicam os sinais que participaram do conjunto de treinamento.

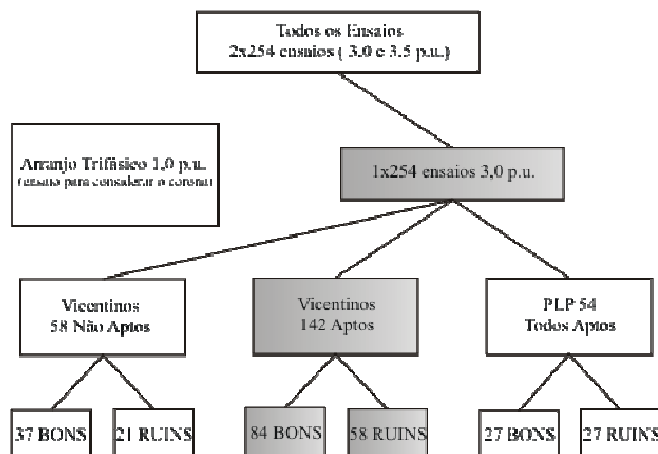


Figura 15 – Resumo quantitativo da base de dados

V. ANÁLISE DOS RESULTADOS

Na Tabela 2 são apresentados os resultados obtidos na fase de treinamento para a melhor rede montada (RNA4). Pode ser observado que os atributos relacionados com a centróide conduziram ao melhor resultado no processo de classificação.

Tabela II – Resultados obtidos para a rede RNA4

Atributos	Perfor- mance	% Acerto Treinamento		
		Classe 1	Classe 2	Total
Todos	Melhor	74.55	57.42	65.98
	Média	74.56	57.59	66.08
	Desv.Pad.	1.91	1.74	1.38
Parâmetros estatísticos	Melhor	86.06	69.70	77.88
	Média	84.47	69.38	76.92
	Desv.Pad.	4.24	3.31	2.56
Centróide	Melhor	88.03	67.42	77.73
	Média	77.79	62.38	70.08
	Desv.Pad.	26.78	14.54	7.41
Frequência	Melhor	81.06	47.73	64.39
	Média	72.29	53.23	62.76
	Desv.Pad.	25.52	16.63	4.46
Wavelets	Melhor	78.33	56.21	67.27
	Média	78.24	55.29	66.77
	Desv.Pad.	2.68	2.48	0.98

Apesar do bom resultado apresentado, quando do treinamento, a rede não registrou boa generalização quando de testes utilizando amostras que não participaram do conjunto de treinamento.

VI. PROTÓTIPO DE SISTEMA DE DIAGNÓSTICO

Mesmo para o melhor classificador montado, utilizando-se os atributos mais significativos extraídos a partir da centróide dos sinais, observou-se dificuldades na generalização da rede. Tal dificuldade foi atribuída aos defeitos incipientes que se pretendia identificar. Conforme já comentado, como estratégia para forçar as descargas parciais que ocorrem em isoladores com bolhas internas, durante os experimentos se procurou estressar os isoladores previamente classificados através de ensaios de raios x através da aplicação de uma tensão duas vezes maior que a nominal do isolador ($3 \text{ p.u.} = 3 \times 13.8/1,73 = 23,93 \text{ kV}$), durante 10 minutos. Essa estratégia pode não ter sido suficiente para forçar a manifestação significativa do evento. Até mesmo para esta tensão foi difícil evitar a manifestação do efeito corona, mesmo utilizando tubos especiais e esferas de equalização dos potenciais. Além desses cuidados também se monitorou os experimentos com o equipamento DayCor, o qual direcionou a eliminação de algumas amostras do conjunto de treinamento, nas quais foram observadas manifestações acentuadas do efeito corona.

Apesar dessas constatações e da dificuldade de generalização da rede, foi montado processo de diagnóstico a partir da melhor técnica de classificação obtida, com o intuito de se explicitar o objetivo final a ser alcançado. Através de testes preliminares da rotina de diagnóstico, denominada "IsoDiagnosis" foi possível se identificar, na rede de 13.8 kV da UFPE, isoladores que apresentaram sinais de ultra-som característicos de unidades defeituosas. Essas unidades precisam ser retiradas e aferidas através de ensaios de raios x e elétricos adicionais. Inspeções similares às executadas na rede da UFPE precisam ser estendidas também para a rede da CELPE para se avaliar o desempenho da versão do sistema de diagnóstico desenvolvido.

VII. CONCLUSÕES

A partir dos resultados obtidos pode ser observado que o estágio alcançado pelo projeto pode ser considerado satisfatório, mas não conclusivo. As pesquisas precisam ser continuadas, atentando-se para os seguintes refinamentos:

- escolher rede de 13.8 kV na qual possam ser instalados os isoladores previamente classificados através dos ensaios de raios x; tais isoladores precisam ser criteriosamente identificados na rede para monitorações posteriores;
- adquirir sinais de ultra-som, a cada três meses, a partir de cada um dos isoladores instalados e treinar uma nova rede a partir desse novo conjunto de treinamento, no qual os sinais estarão associados aos isoladores estressados naturalmente e a uma tensão nominal; nessas condições o efeito corona terá bem menos influência sobre os ruídos de ultra-som adquiridos;
- repetir tais procedimentos durante um ano;
- cada nova rede treinada deve ser devidamente testada no que se refere principalmente à generalização do diagnóstico apresentado.

A partir dessas implementações, certamente a consecução de um processo de diagnóstico ainda mais confiável será

alcançada. É importante ressaltar a versatilidade do processo, simulada a partir do protótipo montado, o qual pode ser ainda mais portátil e envolver recursos materiais e humanos ainda menores.

Ao se perseguir os aprimoramentos recomendados estarão sendo dados passos importantes na incorporação de uma ferramenta preventiva de grande valor para assegurar a continuidade das redes de distribuição de energia elétrica, através da intervenção prévia da manutenção, antes que falhas, indisponibilidades e acidentes venham a ocorrer.

VIII. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Bezerra, J. M. B. "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, Universidade Federal de Campina Grande, 2004.
- [2] Bezerra, J.M.B., Lima, A.M.N., Deep, G.S., Costa, E.G., Freire, R.C.S., Técnicas de Diagnóstico de Poluição em Isoladores Aéreos de Alta Tensão. XVII-SNPTEE, 2003.
- [3] Aquino R. R. B., Bezerra, J. M. B., Santos, G. S. M., Neto, O. N., Lira, M. M. S. Ferreira, A. A., Oliveira, J. B. "Aplicação de Redes Neurais para Diagnóstico de Poluição em Isoladores de Alta Tensão", XIX SNPTEE, Rio de Janeiro/RJ, 2007.
- [4] Haykin, S. Redes Neurais: Princípios e Prática. BOOKMAN Editora S.A, 2001.
- [5] Braga, A.P., Ludermir, T.B., Carvalho, A.C.P.L.F., Redes Neurais Artificiais: Teoria e aplicações. LTC Editora, 2000.
- [6] HAGAN, M. T., MENHAJ, M. B., Training Feedforward Networks with Marquardt Algorithm. IEEE Transactions on Neural Networks, Vol 5, NO. 6, November 1994, p. 989-993.
- [7] Lira, M. M. S., Aquino, R. R. B., Ferreira A. A., Carvalho Jr., M. A., Lira, C. A. B. O. "Improving Disturbance Classification by Combining Multiple Artificial Neural Networks". IEEE World Congress on Computational Intelligence/ IJCNN, Vancouver-Canada. IEEE Xplore, p. 3436-3442, 2006.
- [8] Ferreira, A. A. Comparação de arquiteturas de redes neurais para sistemas de reconhecimento de padrões em narizes artificiais. Dissertação de mestrado, UFPE, Recife-PE, 2004.
- [9] IEC 60270, High-voltage Test Techniques – Partial Discharge Measurements. IEC. 2000.