

Sistema Caracterizador Híbrido para Identificar Descargas Parciais em Transformadores de Potência

Walter M. Cuenca^{1,2}, Alain F. Levy¹, José M. Seixas²

1. CEPEL/ACET, PO Box 68007 CEP 21944-970 Rio de Janeiro - Brasil

2. COPPE/EE/UFRJ, P. 68504, Rio de Janeiro 21945-970, Brasil

martin@cepel.br alain@cepel.br seixas@lps.ufrj.br

Abstract

The partial discharge detection and localization in power transformers is addressed by the use of a simplified experimental model (for partial discharge generation) and a hybrid signal processing technique. The experimental model is obtained using test cells for which partial discharge signals are generated. Experimental data were collected in laboratory by extensive measurement on those test cells. The detection efficiency for partial discharges is shown to be above 97 %, using optimal lineal filtering and neural processing.

1. Introdução

As empresas de energia elétrica estão prestando cada vez mais atenção na preservação de seus equipamentos mais importantes (e mais custosos), especialmente transformadores de potência, para garantir um serviço contínuo de energia elétrica.

O forte crescimento da demanda faz com que os transformadores de potência trabalhem com sobrecarga por períodos de tempo longos, aumentando os riscos de falha, sobreaquecimentos e degradação dos materiais isolantes, causando a perda acelerada de suas propriedades elétricas e mecânicas. Estes fatores contribuem para uma possível formação de descargas parciais (DP's).

Uma das preocupações do pessoal técnico envolvido na operação de equipamentos elétricos de alta tensão é evitar o envelhecimento prematuro dos isolamentos, assim como manter o nível de proteção, prevenindo riscos de falhas severas, e o aumento das saídas de serviço não programadas. Um maneira de reduzir estes riscos é realizar medições periódicas, por meio de testes de DP's, os quais são avaliados por especialistas e instrumentação sofisticada. Entretanto, a tomada de decisão vem se dando muito mais por experiência do que por uma análise sofisticada dos dados [1].

As descargas parciais são sucessões de descargas elétricas incompletas, rápidas e intermitentes na ordem de nano-segundo (Figura 1.a), que ocorrem pela proximidade entre duas partes condutoras de eletricidade e um meio isolante, através do efeito de ionização em cavidades gasosas no interior dos materiais isolantes sólidos e líquidos. Tais descargas também podem ocorrer na

zona de contato de isolantes sólidos (dielétricos) e superfícies metálicas submetidas a tensão elétrica [2].

DP's em transformadores de potência têm sido pesquisadas por várias décadas, formando-se várias linhas de pesquisa em medição e detecção, assim como localização. Métodos de medição e detecção de DP's são descritos nas Normas IEC-270 e são geralmente adotados pela comunidade técnica [3]. Localização de DP's tem sido pesquisada pelos métodos acústicos (ultra som), mas ainda com resultados insatisfatórios, visto que os sinais acústicos podem ser extremamente atenuados, para DP's próximas dos enrolamentos.

Realmente, medir descargas parciais em transformadores de potência requer várias condições, tais como: baixo nível de ruído, adequada calibração do equipamento e sensibilidade de medição. A realização de uma medição de DP's em transformadores é dificultada pela acessibilidade nos circuitos internos e a complexidade destes circuitos, altamente indutivos. Todas estas características afetam os sinais de DP's, contribuindo na sua deformação e atenuação. As medições de DP's também são afetadas por ruídos contaminadores que se propagam por condução e irradiação [1].

Um novo problema surge após uma dada detecção ou localização de descarga parcial: Será que o instrumento de medição obteve real sucesso em medir a descarga parcial? Em que local ela está ocorrendo? Quais materiais estão envolvidos? São perguntas difíceis de responder e que dificultam uma decisão concreta do especialista.

A técnica desenvolvida pelos modelos experimentais trata os problemas de detecção e localização em forma cooperativa. Esta se baseia na construção de células teste (Figura 1.b), como objetivo de reproduzir DP's localizadas. A vantagem desta técnica é que se tem uma base de conhecimento a priori (local da fonte de descarga e materiais envolvidos), de tal forma que as células de padrões de ocorrência de DP's possam ser associadas a determinados locais reais de um transformador.

Nas pesquisas desenvolvidas no Centro de Pesquisas de Energia Elétrica (CEPEL), foram adotadas três células básicas, denominadas Ponta Flutuante (FL), Ponta Plano (PP) e Ponta Terra (PT), mostradas na Figura 1.b, respectivamente. Estas células foram confeccionadas para representar fontes padrões de DP's localizadas em transformadores de potência com óleo mineral isolante [1],[4].

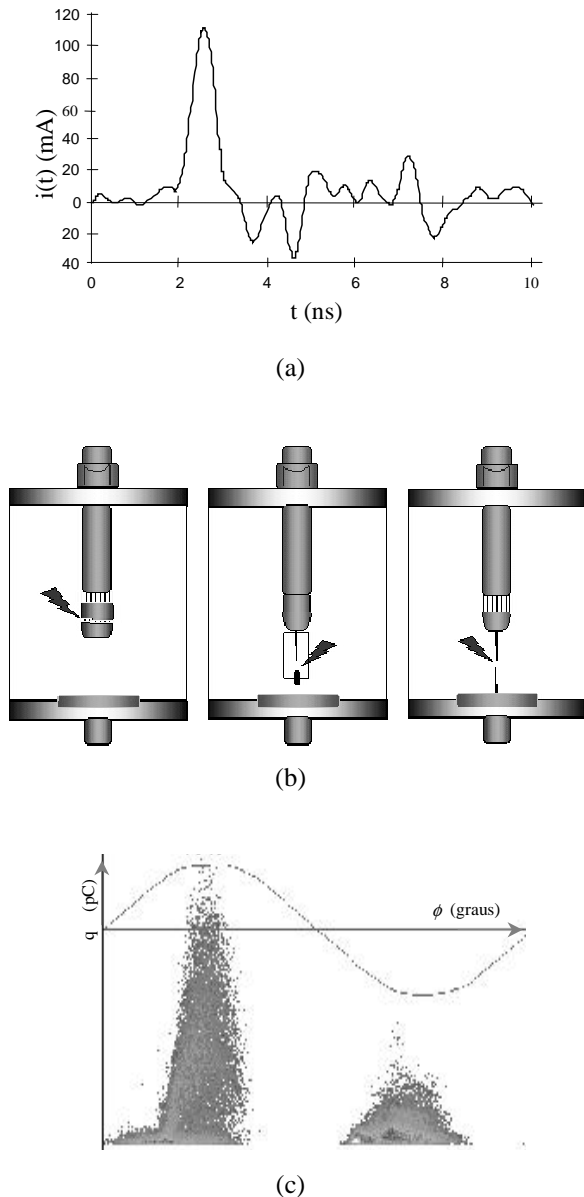


Figura 1: Sinais de DP's. (a) pulsos intermitentes medidos em ultra alta frequência, (b) modelos experimentais e (c) mapa característico de DP's gerados por modelos experimentais.

O instrumento de medição "ICM System", da Power Diagnostix Systems, foi utilizado para todas as atividades experimentais realizadas. Este instrumento emprega a técnica de medição de carga aparente, especificada na norma IEC 270. Os procedimentos de medição e calibração do equipamento estão descritos na referência [5]. O ICM converte os sinais elétricos em sinais digitais na forma de Mapas [4], os quais têm a particularidade de relacionar a amplitude, ângulo de fase e taxa de repetição (ϕ, q, N) em forma de mapas de assinaturas das DP's dispostas de forma bidimensional (Figura 1.c). Neste caso, a taxa de repetição (N) é codificada em cores normalizadas (16 cores), as amplitudes q (vertical) são picos máximos dos pulsos de descargas atingidos a

partir de janelas ajustadas em 20 μ s de duração e ϕ (horizontal) é o ângulo de fase da tensão onde se desenvolvem as descargas.

Diversos trabalhos têm sido apresentados na literatura aplicando redes neurais artificiais, lógica *fuzzy*, *fractal features* e sistemas *neuro-fuzzy* para detecção, reconhecimento e classificação de fontes de DP's, amplamente referenciadas em [6] e [1]. Estes trabalhos enfatizam a procura entre as técnicas pesquisadas a de melhor desempenho, abordam modelos e formas geométricas de geração de DP's, especialmente em dielétricos sólidos (cavidades gasosas e *trees* elétricos). Trabalhos recentes usam os três parâmetros relevantes (ϕ, q, N) e suas projeções para caracterizar DP's em meios dielétricos gasosos (SF6, óleo mineral e ar [1], [7]).

O modelo estilizado, envolvendo óleo mineral de transformadores de potência tem sido pouco pesquisado pela comunidade científica, devido a suas características particulares e difíceis de se obter modelos consistentes. No entanto, em [1], este modelo é associado às zonas críticas, possíveis de se encontrar DP's, através de modelos experimentais realizados em laboratório.

Neste trabalho, desenvolve-se um classificador híbrido de padrões de DP's, conjugando um filtro casado e uma rede neural artificial. Dados pré-processados dos mapas de assinaturas alimentam o classificador, cuja performance é comparada com aquela obtida por meio de uma análise de componentes principais (PCA) restrita a sete componentes [8].

Na próxima seção estão descritos os modelos experimentais de DP's e o pré-processamento desenvolvido. Na Seção 3 desenvolve-se o projeto do classificador híbrido e é avaliado o seu desempenho. As conclusões do trabalho se encontram na Seção 4.

2. Modelos experimentais simplificados

Os modelos experimentais foram construídos de acordo com as seguintes características [1]:

Ponta flutuante: *descarga no eletrodo intermediário. Esta configuração representa descargas induzidas envolvendo o enrolamento de alta e baixa tensão e descargas entre camadas de bobinas.*

Ponta plano: *descarga no eletrodo de alta tensão. Esta célula representa descarga parcial envolvendo condutor de alta tensão e objeto condutor flutuante, bucha do transformador e grampos, mal contato nos conectores de alta tensão e os enrolamentos.*

Ponta terra: *descargas no eletrodo aterrado. Esta célula representa descargas entre a bucha e o tanque aterrado do transformador, na bobina de alta ou baixa tensão e núcleo. Também pode envolver grampos de fixação, conectores, tirantes, jugo superior ou inferior aterrados.*

A Figura 2 mostra mapas característicos correspondentes a cada modelo de padrão, utilizados no conjunto de treino do sistema discriminador híbrido.




Figura 2: Mapas característicos originais: (a) padrão FL, (b) padrão PP e (c) padrão PT.

A fonte de informação provém das três células características, dispostas na forma de mapas digitais cuja primeira compactação de informação se ilustra na Figura 3. A redução da matriz primitiva $[P]$ de dimensões 256×256 , que contém um mapa original de distribuição das taxas de repetição das DP's, faz com que cada bloco 8×8 gere um elemento (r_{ij}) da matriz reduzida $[R]$ de dimensões 32×32 . Matematicamente, esta matriz reduzida é construída pela seguinte expressão:

Dado:

$$[P] \rightarrow \mathfrak{R}^{n \times n}, n = 256 \text{ e } [R] \rightarrow \mathfrak{R}^{m \times m}, m = 32;$$

$$[P] = \begin{bmatrix} P_{(1,1)} & P_{(1,2)} & \cdots & P_{(1,256)} \\ P_{(2,1)} & P_{(2,2)} & \cdots & P_{(2,256)} \\ \vdots & \vdots & \ddots & \vdots \\ P_{(256,1)} & P_{(256,2)} & \cdots & P_{(256,256)} \end{bmatrix},$$

$$[R] = \begin{bmatrix} r_{(1,1)} & r_{(1,2)} & \cdots & r_{(1,32)} \\ r_{(2,1)} & r_{(2,2)} & \cdots & r_{(2,32)} \\ \vdots & \vdots & \ddots & \vdots \\ r_{(32,1)} & r_{(32,2)} & \cdots & r_{(32,32)} \end{bmatrix} \quad (1)$$

Onde:

$$r_{ij} = \sum_{u=k1}^{k1+7} \sum_{v=k2}^{k2+7} P_{(u,v)},$$

$$k1 = 8(i-1) + 1 \text{ e } k2 = 8(j-1) + 1 \quad (2)$$

e i, j variam de 1 até 32.




Figura 3: Processo de compactação de dados. Cada bloco de (8×8) da matriz primitiva (256×256) é compactado numa cela da matriz reduzida (32×32).

Este pré-processamento dos dados de DP's teve a finalidade de reduzir o esforço computacional, apresentando pequenas perdas não relevantes da característica e forma do padrão de DP's.

Os dados disponíveis foram divididos de forma a compor os conjuntos de treinamento e teste do discriminador híbrido:

- 35 eventos para o padrão FL, dos quais foram escolhidos 20 vetores para treino e 15 para teste.
- 55 eventos para o padrão PP, dos quais foram escolhidos 26 vetores para treino e 29ⁱ para teste.
- 25 eventos para o padrão PT, dos quais foram escolhidos 15 vetores para treino e 10ⁱⁱ para teste.

O problema de detecção e localização de DP's resume-se, então, em identificar e associar um mapa de DP's qualquer, dado pela matriz $[R]$, num dos três tipos de padrão e, como projeção futura, identificar e localizar uma ocorrência de DP's num transformador real.

Neste trabalho os dados compactados acima apresentados servirão como sinais de entrada para o sistema discriminador híbrido.

3. Sistema Discriminador Híbrido de sinais

Este sistema foi implementado na base de filtros casados (MF) e redes neurais artificiais (ANN), com a finalidade de se obter um discriminador cooperativo e robusto. Na primeira etapa, foram implementados filtros casados baseados na teoria dos sistemas lineares de filtragem ótima [9], [10]. Na segunda etapa foi implementada uma ANN do tipo multicamadas e sem realimentação, treinada por *backpropagation* [11]. A escolha deste tipo de rede baseou-se em comparações realizadas em [1], [6], onde esta apresentou melhor desempenho.

Por um lado, se tem sinais de DP's que se caracterizam por serem pulsos intermitentes de corrente, desenvolvidos em janelas de tempo ($> 5 \mu s$), onde cada forma de onda dos pulsos pode ser considerada como uma **amostra** estatística, e o conjunto destas amostras será uma **coleção** ou *ensemble* de funções. Então, um mapa característico (ex.: Figura 1c) representa a resposta para um conjunto de amostras, determinando um **evento** no instante em que é registrada pelo medidor ICM. O mapeamento destes eventos aleatórios em períodos de tempo constante é um processo estocástico.

Por outro lado os filtros casados são importantes na teoria de decisão, e usualmente são considerados dois casos: filtros casados com ruído aditivo branco e filtro casado generalizado para ruído aditivo colorido. No caso de ruído colorido, o MF inclui um filtro branqueador na entrada, que torna branco o ruído à sua saída. A figura de mérito da relação sinal-ruído R_0 é usada para avaliar o desempenho de tal sistema discriminador. Su-

ⁱ O padrão PP apresenta eventos com muito ruído e baixas taxas de descargas, escolhendo-se apenas 26 mais representativos para treino.

ⁱⁱ O padrão PT tem poucas amostras devido à dificuldade de medir com baixa densidade de descargas.

pondo-se que o sinal a detectar seja determinístico, $s(t)$, e se encontra mascarado pela presença de ruído do tipo aditivo, $n(t)$, as seguintes considerações norteiam o projeto dos filtros casados, assumindo o caso mais genérico de ruído colorido:

- Para o filtro branqueador de entrada, os sinais de entrada e saída são, respectivamente (ver Figura 4):

$$v(t) = s(t) + n(t), \quad (3)$$

$$v_0(t) = s_0(t) + n_0(t), \quad (4)$$

Como o MF inclui um filtro branqueador, $n_0(t)$ é um ruído branco. Além disso, neste caso de ruído colorido, o filtro deverá estar casado para $s_0(t)$, que passe a ser o sinal desejado.

- O sistema deve ser linear e invariante no tempo, com resposta ao impulso $h(T-t)$, sendo T a duração do sinal desejado.
- O critério de otimização será:

$$R_0 = \frac{|s_0(t_1)|^2}{E\{n_0^2(t_1)\}} \quad (5)$$

A relação sinal-ruído da saída R_0 atingirá um máximo em algum instante t_1 . Onde $|s_0(t_1)|^2$ é a potência do sinal de saída e $E\{n_0^2(t_1)\}$ o valor médio quadrado de $n_0(t)$, usado como potência do ruído de saída. O sistema linear $h(t)$ que realiza a maximização do R_0 é chamado de "FILTRO CASADO", tendo uma resposta ao impulso (Figura 4).




Figura 4: Filtro casado linear.

$$h[t] = s_0[T-t] \quad (6)$$

Ou seja, a resposta ao impulso para o filtro casado é a imagem espelhada do sinal desejado, deslocada da sua duração, por razões de causalidade [10].

Neste trabalho, assumimos a hipótese simplificadora de que os sinais desejados sejam conhecidos e não aleatórios, visto que a flutuação dos sinais de DP's são reduzidas. Isto facilita o projeto de MF, que, então, segue a equação (6). Assumimos ainda que tais sinais de DP's tenham sido distorcidos por ruídos no processo de coleta e armazenamento. Assume-se, inicialmente, que o ruído existente em DP's seja branco, o que elimina o projeto do filtro branqueador e faz $s_0(t) = s(t)$.

O filtro casado geralmente é usado para sinais no tempo. As medições de DP's, provenientes das células teste, não são amostrados no tempo, mas, pode-se considerar que, em cada cela da matriz $[R]$, são armazenados sinais de DP's com três características fundamentais: ângulo de fase da tensão, amplitude e taxa de repetição

(ϕ, q, N) expressas numericamente. Estas podem ser rearranjadas, sem considerar a relação de vizinhança, na forma de vetor, sem perder a referência ϕ , representando o sinal a detectar.

A aproximação do sinal determinístico é obtida calculando-se os sinais médios para as descargas do tipo FL, PP e PT. Para detectar cada padrão de DP, projetam-se três filtros casados, um para cada classe de descarga parcial. Em outras palavras um sinal *array* (1024 componentes) será casado com a taxa de acumulação (N) média depositada em cada célula da matrix $[R]$.




Figura 5: Sistema discriminador híbrido: MF+ANN

O sistema discriminador usa três filtros casados, que funcionam como pré-processamento da informação e uma rede neural, que realiza a tarefa final de discriminação. Esta rede neural é constituída de três neurônios na primeira camada e , dez neurônios na camada intermediária e três neurônios na camada de saída z (Ver Figura 5).

Os filtros têm resposta ao impulso $h_{FL}[\cdot]$ para eventos r de eletrodo FL, $h_{PP}[\cdot]$ para PP e $h_{PT}[\cdot]$ para PT, obtida pela imagem espelhada do vetor de energia média (com 1024 amostras cada) depositada em cada célula.

Em termos de normalização dos sinais de entrada, deve-se atender às exigências dos MF's, para os quais os sinais para os padrões de entrada devem estar normalizados em energia, e , por outro lado, deve-se atender aos requerimentos da ANN, que possui funções não lineares como ganho dos neurônios, que podem produzir saturação para os padrões de entrada. Neste sentido, devemos adotar um procedimento de normalização adequado e simples.

Sabe-se que a energia do sinal de padrões pode ser calculada de:

$$E = \int_0^T [s(t)]^2 dt, \text{ ou } E = \int_0^T s(t)h(T-t)dt \quad (7)$$

onde $h(t) = s(T-t)$, $0 < t < T$, assumindo um sinal de entrada de energia E , e uma energia unitária à saída do filtro, o fator de normalização para cada padrão será:

$$K = \frac{1}{\sqrt{E}} \quad (8)$$

onde, para padrões discreto:

$$E = \sum_{i=1}^N s_0^2[i] \quad (9)$$

Desta maneira, a normalização em energia à saída do MF se adapta também à faixa dinâmica do classificador neural.

3.1. Resultados do Sistema Caracterizador Híbrido

O Sistema discriminador avalia os sinais pré-processados para as células de teste, identificando a classe de padrão de DP's. Primeiramente, os eventos de teste são processados no nível máximo dos filtros casados quando $t = T$. A Figura 6 mostra as saídas dos filtros h_{FL} , h_{PP} e h_{PT} , quando os sinais de entrada são do tipo FL. Observa-se que as respostas são notavelmente diferenciadas por cada filtro, de tal modo que um separador linear (limiar) pode ser suficiente para discriminar os eventos FL dos demais.




Figura 6: Saídas dos filtros h_{FL} , h_{PP} e h_{PT} quando o sinal de entrada é FL.

As Figuras 7 e 8 mostram as saídas dos filtros h_{FL} , h_{PP} e h_{PT} quando os sinais de entrada são do tipo PP e PT, respectivamente. Nestes casos não podem ser implementados facilmente limiares lineares. Uma opção é subdividir em vários limiares, mas estes tornam complicado o problema de classificação de padrões de DP's, podendo resultar numa classificação ineficiente. Portanto, uma combinação neural das saídas dos filtros pode explorar, de forma não linear, as correlações existentes para as respostas casadas, otimizando o desempenho de classificações.

A Tabela 1 mostra as eficiências alcançadas pela rede neural, a partir das amostras instantâneas das saídas dos MF's, no instante $t = T$ (1024 amostras). Observa-se que, para os padrões FL e PP, atinge-se 100 % de eficiência, relativo aos 15 e 29 eventos disponíveis para estes, enquanto que o padrão PT foi reconhecido em 70 % dos casos, com relação aos 10 eventos de teste. Analisando a eficiência global do sistema caracterizador híbrido, che-

ga-se a 97 % de eficiência total, relativa às 54 amostras de teste

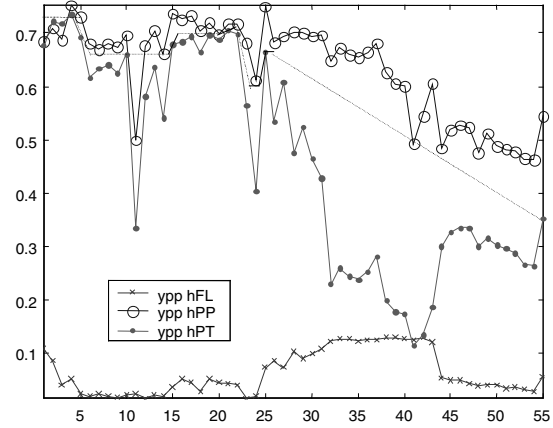


Figura 7: Saídas dos filtros h_{FL} , h_{PP} e h_{PT} quando o sinal de entrada é PP.




Figura 8: Saídas dos filtros h_{FL} , h_{PP} e h_{PT} quando o sinal de entrada é PT.

Tabela 1: Eficiência parcial alcançada por cada padrão na saída da rede neural.

Padrões	Saída FL	Saída PP	Saída PT
Teste FL (15)	100 %	0 %	0 %
Teste PP (29)	0 %	100 %	0 %
Teste PT (10)	0 %	30 %	70 %

Tabela 2: Comparação de desempenhos entre as técnicas de reconhecimento padrão (PCA+ANN) e o discriminador híbrido (MF+ANN)

Padrões	PCA+ANN	MF+ANN
FL (15)	93 %	100 %
PP (29)	100 %	100 %
PT (10)	70 %	70 %
Total	93 %	97 %

Na Tabela 2, são mostrados os resultados de duas técnicas utilizadas no tratamento de dados para sinais de DP's. Observa-se que o sistema (MF+ANN) identificou uma amostra a mais dos padrões de DP's, em relação ao sistema de reconhecimento de padrões (PCA+ANN) usado em [8]. A diferença nas eficiências totais (97 % para 93%) observadas não são conclusivas, haja vista as incertezas estatísticas presentes no número de amostras experimentais reduzido. Portanto, admite-se que ambas técnicas tiveram desempenhos parecidos.

4. Conclusões

O sistema discriminador híbrido MF+ANN pode ser utilizado para avaliar a qualidade e caracterização dos modelos experimentais em descargas parciais. Com base na amostra experimental recolhida, uma eficiência de 97 % na identificação das descargas parciais foi obtida. Este discriminador híbrido provou, desta maneira, ter um desempenho praticamente similar ao sistemas discriminador neural baseado numa análise de componentes principais.

5. Agradecimentos

Os autores agradecem ao apoio do CNPq, FAPERJ e CEPEL a este projeto.

Referências

- [1] Huamán Cuenca, W. "Aplicação de Sistemas inteligentes no Reconhecimento de Padrões de DP's em Transformadores de Potência". *Tese de Mestrado, Programa de Engenharia Elétrica UFRJ-COPPE* 1998.
- [2] R. Bartnicas, "Corona Discharge Processes in Voids". In: R. Bartnicas, E. McMahon, *Engineering Dielectrics: Corona Measurement and Interpretation* Vol. 1, chapter 2, Philadelphia, ASTM STP 669, 1979.
- [3] IEC Publication 270, "Partial Discharge Measurement" Second Edition, 1981.
- [4] Levy, A. *et al.*, "Avaliação do Efeito de Propagação de Memória no Desempenho de Materiais Elétricos - Medição de DP em Ultra-Alta Frequência ao Ar Ambiente e Óleo Isolante", *Relatório Técnico ACET-095/97*, Fev. 1997.
- [5] Levy, A. *et al.*, "Utilização do Sistema de Descargas Parciais ICM System da Power Diagnostix Systems", *Procedimento Específico CEPEL no. 3530-3007-070*, jan. 1997.
- [6] K. B. Cho et al. "Survey and Evaluation of Neuro-fuzzy-Logic Theory to Partial Discharge Pattern Classification Application", *Cigré* pp. 15/21/33-18, 1996.
- [7] H. P. Amorin, et al "Recognition of Partial Discharge of High Voltage Electrical Equipment Using Neural Network" *ISP'99* pp. 216-220, Rio de Janeiro, Brazil 1999.
- [8] Walter M., Jose M. Seixas, Alain F. "Análise de Componentes Principais para Identificar Descargas Parciais em Transformadores de Potência", *VI Brazilian Symposium on Neural Networks, Aplicações Cuenca46*, Rio de Janeiro, Nov. 2000.
- [9] K.S. Shanmugan, AM Breipoh, *Random Signal Detection, Estimate and Data Analysis*, John Wiley & Sons, 1988.
- [10] A. Whalen, *Detection of Signal in Noise*, Academic Press, Inc. New York 1971.
- [11] Simon Haykin, *Neural Network: A Comprehensive Foundation*, 2da. Edition ISBN 0-02-352761-7 Prentice Hall, 1999.