



GSE/023

21 a 26 de Outubro de 2001
Campinas - São Paulo - Brasil

GRUPO VIII

GRUPO DE ESTUDO DE SUBESTAÇÕES E EQUIPAMENTOS ELÉTRICOS – GSE

TÉCNICAS DE SISTEMAS INTELIGENTES APLICADAS NA IDENTIFICAÇÃO DO ENVELHECIMENTO DE TRANSFORMADORES

Ivan N. da Silva(*)

André N. de Souza

José Alfredo C. Ulson

Rogério A. Flauzino

UNESP

UNESP

UNESP

UNESP

RESUMO

Este artigo tem por objetivo o desenvolvimento de metodologias alternativas para a estimação do grau de envelhecimento relativo de transformadores, tendo como base os resultados advindos de análises físico-químicas efetuadas no óleo mineral isolante do equipamento. A partir destas análises, propõe-se a estimação do grau de envelhecimento de transformadores através de abordagens que combinem redes neurais artificiais e sistemas de inferência nebulosa. Uma análise dos resultados obtidos pelas abordagens propostas é executada para validar a metodologia utilizada.

PALAVRAS-CHAVE: Transformadores, Sistemas Inteligentes, Redes Neurais Artificiais, Sistemas de Inferência Nebulosos.

1.0 - INTRODUÇÃO

A função dos óleos isolantes em um transformador é propiciar isolamento elétrico e permitir a transferência de calor (refrigeração) entre suas partes componentes. Como isolante elétrico deverá substituir o ar entre as partes ativas, preenchendo todos os espaços vazios e oferecer alta rigidez dielétrica e baixa condutividade. O óleo isolante é constituído de uma mistura de hidrocarbonetos (saturados parafínicos e naftênicos, aromáticos) em sua maioria, e de não hidrocarbonetos, também chamados de heterocompostos (compostos de Nitrogênio, compostos de Enxofre), em pequenas proporções.

Normalmente, o óleo deteriorado é aquele que apresenta produtos resultantes de sua oxidação,

enquanto o óleo contaminado é aquele que apresenta água e outras substâncias estranhas, que não fazem parte de sua composição [1]. O processo de degradação do óleo mineral pode ser apresentado em três fases distintas. A fase inicial caracteriza-se pela formação de peróxidos quimicamente instáveis, os quais liberam oxigênio e formam os compostos oxi-celulósicos com o papel isolante. A fase intermediária caracteriza-se pela formação de gases e finalmente, na fase final, a formação de borra, que geralmente consiste em uma substância resinosa resultante da polimerização a partir de ácidos e outros compostos.

O diagnóstico do estado e das condições de operação dos transformadores é de fundamental importância na operação confiável e econômica dos sistemas. O envelhecimento e desgaste dos transformadores determinam o fim de sua vida útil, na medida em que a ocorrência de falhas ou problemas crescentes de manutenção comprometem a confiabilidade ou disponibilidade do equipamento. Conhecer os mecanismos de deterioração e dispor de meios tecnicamente significativos e economicamente aplicáveis, permite correlacioná-los com a evolução dos equipamentos em serviço.

Muitos pesquisadores no assunto reconhecem que a melhor maneira de testar os óleos isolantes é colocá-los em serviço e acompanhar seu comportamento [1].

Por outro lado, o desenvolvimento de ferramentas eficientes na estimação de parâmetros que possibilitem uma manutenção preditiva é de suma importância para que sejam preservadas as condições operacionais do sistema. A manutenção preditiva permite também o

(*) Universidade Estadual Paulista – UNESP
Departamento de Engenharia Elétrica – DEE
CP 473, CEP 17033-360, Bauru-SP, Fax (14) 221-6116
Fone (14) 221-6115, E-mail: ivan@bauru.unesp.br

acompanhamento do processo de envelhecimento do equipamento, com perspectivas de estender sua vida útil ou, quando possível, determinar o tempo de vida remanescente.

Porém, a principal dificuldade encontrada na estimação do grau de envelhecimento de transformadores refere-se à dificuldade de obter modelos matemáticos que relacione este índice em função das propriedades físico-químicas associadas ao óleo isolante. No entanto, algumas hipóteses referentes à forma como o envelhecimento se processa, tendo como base alguns índices e teores encontrados na análise do óleo mineral isolante, podem ser utilizadas na formulação de metodologias alternativas que levem estas análises em consideração.

Desta forma, utiliza-se técnicas de sistemas inteligentes para estimação do grau de envelhecimento relativo de transformadores. Mais especificamente, redes neurais artificiais e sistemas de inferência nebulosos são aplicados na estimação do grau de envelhecimento de transformadores.

2.0 - CONCEITOS DE SISTEMAS NEBULOSOS E REDES NEURAIIS ARTIFICIAIS

Os sistemas inteligentes são constituídos por uma combinação de técnicas de modelagem e computação, cujo objetivo primário é alcançar tratabilidade, robustez, baixo custo e alto MIQ (Quociente de Inteligência de Máquina), através de uma exploração da abstração do conhecimento e da tolerância à imprecisão e incerteza.

Nessa combinação, os principais constituintes dos Sistemas Inteligentes são: as Redes Neurais Artificiais (Artificial Neural Networks) [2], os Sistemas de Inferência Nebulosos (Fuzzy Logic) [3], a Computação Evolutiva/Algoritmos Genéticos (Genetic Algorithms) [4], os Sistemas Caóticos [5] e o Raciocínio Probabilístico. Dentro deste contexto, as redes neurais se preocupam principalmente com a teoria da aprendizagem e aquisição do conhecimento, a lógica nebulosa com a exploração da imprecisão e do raciocínio aproximado, e a computação evolutiva (algoritmos genéticos) com o gerenciamento de processos de otimização baseado em mecanismos seletivos naturais. Está se tornando cada vez mais evidente que em muitos casos é vantajoso empregar a combinação dessas técnicas em vez de uma ou outra exclusivamente.

2.1 Sistemas de inferência nebulosos

Os sistemas de inferência nebulosos, juntamente com a lógica nebulosa, podem ser aceitos como a melhor

ferramenta para modelar o raciocínio humano, que é aproximado e parcial em sua essência.

A teoria dos conjuntos nebulosos e a lógica nebulosa objetivam modelar os modos de representação e raciocínio imprecisos que têm um papel essencial na tomada de decisões racionais em ambientes de imprecisão e incerteza. A diversificação de tecnologias advindas da lógica nebulosa tem também permitido sua aplicação em diversas áreas do conhecimento. Técnicas de sistemas nebulosos são especialmente utilizadas nos casos onde não existem modelos matemáticos capazes de descrever precisamente o processo estudado.

Estas técnicas fornecem uma estrutura poderosa para manipular informações aproximadas. Assim, o processo pode ser controlado a partir de um conjunto de regras nebulosas do tipo “Se-Então”, capaz de tratar (coordenar) conhecimentos incompletos, incertos ou mesmo conflitantes [3]. A teoria de modelagem e controle nebuloso trata do relacionamento entre entradas e saídas, agregando vários parâmetros de processo e de controle. Os sistemas de controle resultantes proporcionam um resultado mais acurado, além de um desempenho estável e robusto.

Na teoria de conjuntos nebulosos, considera-se inicialmente um universo de discurso U , onde ‘ u ’ é um elemento genérico. Um conjunto nebuloso F , definido neste universo, é caracterizado por uma função de pertinência $\mu_F(\cdot)$ sobre o intervalo $[0,1]$. O grau de pertinência do elemento ‘ u ’ ao conjunto F é dado pelo valor $\mu_F(u)$. Assim, considerando dois conjuntos nebulosos A e B em U , com funções de pertinência μ_A e μ_B , respectivamente, as operações básicas de união, interseção e complemento, podem ser definidas através de suas funções de pertinência por:

$$\text{União: } \mu_{A \cup B} = \max\{ \mu_A(u), \mu_B(u) \} \quad (1)$$

$$\text{Interseção: } \mu_{A \cap B} = \min\{ \mu_A(u), \mu_B(u) \} \quad (2)$$

$$\text{Complemento: } \mu_{\bar{A}}(u) = 1 - \mu_A(u) \quad (3)$$

Um sistema de decisão nebuloso, ou controlador nebuloso, é então formado por um conjunto de regras de controle, às quais se associam implicações nebulosas utilizando as operações precedentes. Uma regra nebulosa típica ‘Se (x é A_i e y é B_i) então (z é C_i)’ é implementada como uma implicação (relação) nebulosa R_i , cuja função de pertinência μ_{R_i} pode ser definida por :

$$\begin{aligned} \mu_{R_i} &\stackrel{\Delta}{=} \mu_{(A_i \text{ e } B_i \rightarrow C_i)}(u,v,w) \\ &= [\mu_{A_i}(u) \text{ e } \mu_{B_i}(v)] \rightarrow \mu_{C_i}(w) \end{aligned}$$

onde $A_i \underline{e} B_i$ é um conjunto nebuloso $A_i \times B_i$ em $U \times V$; $R_i = (A_i \underline{e} B_i) \rightarrow C_i$ é uma relação nebulosa em $U \times V \times W$; e o operador (\rightarrow) indica a função de implicação nebulosa. Considerando regras do tipo ‘Se ($u \in A_i$) então ($v \in B_i$)’, a função de pertinência μ_{R_i} é :

$$\mu_{R_i} = \min\{ \mu_{A_i}(u) , \mu_{B_i}(v) \}; u \in U , v \in V \quad (4)$$

Em um sistema nebuloso, cada regra nebulosa é representada por uma relação nebulosa. Quando um sistema nebuloso é caracterizado por um conjunto de regras, a relação nebulosa R , representando uma combinação de todas as regras nebulosas R_i pertencentes ao sistema, é definida através de um operador de agregação de regras:

$$R = \text{agreg}(R_1 , R_2 , \dots , R_n) \quad (5)$$

onde n é o número de regras do sistema nebuloso. O operador de agregação é interpretado, usualmente, como um operador de união.

Utilizando-se a regra de inferência composicional de Zadeh, dada a relação R , de U a V , e um conjunto nebuloso de U denotado por A' ; o conjunto nebuloso B' de V , inferido a partir de A' , tem função de pertinência definida por (procedimento max-min):

$$\mu_{B'}(v) = \max\{ \min(\mu_{A'}(u) , \mu_R(u,v)) \}; u \in U , v \in V \quad (6)$$

Para cada regra, o grau de ativação da ação de controle é calculado de acordo com o resultado da combinação de seus antecedentes e consequentes. Todas as regras, com elementos tendo valores verdade não nulos, são ativadas.

Após a aplicação do procedimento de inferência, a ação de controle final consiste da agregação (união) de todas as contribuições proporcionadas por cada regra ativada [3]. O valor ‘crisp’ (não nebuloso) da saída é normalmente calculado pelo método do centro de área (CDA), dado por:

$$CDA = \frac{\sum_{k=1}^m \mu_{B'}(v_k) \cdot v_k}{\sum_{k=1}^m \mu_{B'}(v_k)} \quad (7)$$

onde n é o número de níveis de quantização da saída, ou seja, o número de segmentos gerados pela discretização do universo de discurso.

2.2 Redes neurais artificiais

As Redes Neurais Artificiais (RNA) são um paradigma computacional descrevendo sistemas de processamento paralelos com grande número de unidades simples de processamento interconectadas. A justificativa

principal para a utilização de redes neurais artificiais na solução de problemas complexos e variados é a não necessidade de dispor do modelo matemático que represente o relacionamento entre as variáveis de entrada e saída.

Tais técnicas computacionais apresentam um modelo computacional inspirado na estrutura neural de organismos inteligentes e que podem adquirir conhecimento através da própria experiência. Uma das mais importantes propriedades das Redes Neurais é a habilidade de aprender a partir de seu ambiente objetivando melhorar seu desempenho. O aprendizado ocorre quando a rede consegue generalizar soluções para um determinado tipo de problema.

A característica mais significativa de redes neurais, compostas por apenas uma camada escondida, está em sua habilidade de aproximar qualquer função contínua não linear.

Para funções não contínuas em seu domínio, há portanto a necessidade de incrementar o número de camadas escondidas. Esta habilidade das redes neurais as tem feito útil para modelar sistemas não lineares, particularmente, quando o relacionamento entre as variáveis do processo é não linear e/ou não bem definido, tornando assim difícil a sua modelagem por técnicas convencionais.

Neste trabalho, uma rede neural do tipo perceptron multicamadas, idêntica àquela usada em [6], é utilizada para identificar o relacionamento existente entre as grandezas obtidas a partir dos ensaios físico-químicos com o grau de envelhecimento de transformadores.

3.0 - A METODOLOGIA DESENVOLVIDA

As variáveis que compõem cada vetor de entrada do sistema de inferência nebuloso e das redes neurais artificiais são definidas pelas grandezas que indicam os teores e índices dos produtos que influenciam diretamente no envelhecimento do transformador, ou seja, aqueles que causam a degradação do papel e do óleo isolante. Estas grandezas podem ser definidas como sendo:

- Teor de 2-FAL (2-Furfuraldeído) presente no óleo (ppm).
- Volume de CO presente no óleo (l).
- Tensão Interfacial (TI) das moléculas do óleo (dyn/cm).
- Índice de acidez (IA) do óleo (mgKOH/g).

A variável de saída dos sistemas neurais e nebulosos sempre foi o Grau de Envelhecimento Relativo (GER), que devido à sua normalização ficou dentro do domínio de [0,1], sendo que quanto maior o GER

maior será o envelhecimento relativo de cada transformador.

A abordagem nebulosa desenvolvida consiste em utilizar um sistema de inferência nebulosa do tipo Sugeno. A escolha deste tipo em especial deve-se ao fato desta arquitetura apresentar uma maior eficiência computacional e uma representação mais compacta do conhecimento se comparado com outras arquiteturas nebulosas, além de ser possível um emprego de técnicas de otimização com maior facilidade. Outros pontos positivos da arquitetura Sugeno é a garantia de continuidade da saída do sistema já que, as funções de pertinência das variáveis de saída são ou lineares ou constantes. Uma descrição mais detalhada desta arquitetura pode ser encontrada em [3].

Além de uma maior uniformidade nos valores de suas respostas de saída e demais características técnicas acima mencionadas, o emprego desta classe de sistema nebuloso permite que, através de técnicas adaptativas o sistema nebuloso se ajuste de forma a relacionar de maneira adequada as variáveis de entradas às saídas. Um método eficiente para este propósito, denominado por ANFIS (Adaptative Neuro-Fuzzy Inference System) pode ser considerada como uma rotina de adaptação de grande importância, principalmente, para sistemas nebulosos do tipo Sugeno. A método ANFIS utiliza um algoritmo de aprendizado híbrido que combina as técnicas dos mínimos quadrados com o método de retropropagação utilizado no treinamento de redes neurais artificiais e, desta forma, os parâmetros das funções de pertinência são ajustados até que se atinja a precisão desejada. Um descrição mais detalhada deste método pode ser encontrada em [7].

As variáveis do espaço de entrada do sistema foram convertidas para conjuntos nebulosos, pelo processo de fuzzificação, através de funções gaussianas. Mais precisamente, cada variável foi fuzzificada tendo como base três curvas gaussianas definidas no universo de discurso de cada variável. As curvas das funções de pertinência ajustadas segundo o método empregado podem ser verificadas na Figura 1.

A base de regras de inferência foi constituída por três regras que podem descritas como:

- Se (2-FAL é Baixo) e (CO é Médio) e (TI é Alto) e (IA é Alto) então (GER é Médio);
- Se (2-FAL é Alto) e (CO é Baixo) e (TI é Médio) e (IA é Médio) então (GER é Alto);
- Se (2-FAL é Médio) e (CO é Baixo) e (TI é Baixo) e (IA é Baixo) então (GER é Baixo).




FIGURA 1 – Funções de pertinência ajustadas

Depois de processadas as regras de inferência o resultado de cada uma é agregado aos demais, fornecendo assim, uma região nebulosa. Através do método do centro de área, esta região é convertida para um valor não nebuloso, ou seja, um valor ‘crisp’.

A avaliação do grau de envelhecimento relativo do transformador é feito com base no índice GER, que segundo este, um transformador será mais envelhecido quanto maior for seu índice do GER.

Para o sistema neural, a metodologia utilizada é idêntica àquela apresentada em [6].

4.0 - RESULTADOS DE SIMULAÇÃO

O sistema de inferência nebulosa e a rede neural artificial teve como fonte de dados de treinamento os resultados obtidos em [8], bem como as hipóteses levantadas em [2] referentes ao envelhecimento de transformadores, segundo os índices e teores dos fatores determinantes para o seu envelhecimento.

Os dados avaliados são relativos aos ensaios de 41 transformadores de potência, separados em oito grupos, como mostrado na Tabela 1.

TABELA 1 – Grupo de transformadores

Grupo	Ano de Fabricação	Tensão Superior (kV)	Potência Primária (MVA)
G1	1979/1980	550	155
G2	1959	69	3,33
G3	1956	69	3,33
G4	1930	69	1,66
G5	1930	69	1,66
G6	1969/1970	230	70
G7	1964	230	33
G8	1969	230	33

Para a avaliação do grau de envelhecimento relativo dos transformadores não é interessante que o estudo seja feito em grupos separados, pois a categorização dos dados não seria uma garantia de que cada grupo possuiria transformadores em que o grau de envelhecimento relativo esteja dentro de uma faixa específica, sendo que as hipóteses conhecidas podem não ser todas verdadeiras, além de não garantir que existam outras hipóteses referentes ao processo. Desta forma, as simulações apresentadas foram feitas levando em consideração os dados anteriormente descritos, onde os grupos mencionados na Tabela 1 tem a finalidade de apenas simplificar a apresentação dos resultados obtidos.

Assim, são apresentados nesta seção os resultados referentes a três grupos de transformadores. No

primeiro conjunto foram tomados transformadores do grupo G1 indicados na Tabela 1. Na Tabela 2 são demonstrados os resultados fornecidos pelo sistema de inferência nebulosa e pela rede neural. Todas as análises das tabelas são executadas pelos valores dados na coluna “GER (Médio)”, os quais são obtidos a partir da média entre os valores obtidos pela abordagem fuzzy {GER (Fuzzy)} e neural {GER (RNA)}.

TABELA 2 - Primeiro conjunto de transformadores

Trafo	2-FAL	CO	TI	IA	GER (Fuzzy)	GER (RNA)	GER (Médio)
T1/G1	0,03	8,536	42,3	0,01	0,1715	0,1706	0,1711
T2/G1	0,03	3,696	42,3	0,01	0,1463	0,1470	0,1467
T3/G1	0,03	2,420	39,5	0,01	0,1611	0,1928	0,1770
T4/G1	0,01	4,730	42,6	0,01	0,0924	0,0495	0,0710
T5/G1	0,02	5,588	40,3	0,01	0,1298	0,0972	0,1135
T6/G1	0,04	5,060	43,3	0,01	0,1752	0,2419	0,2086
T7/G1	0,04	4,202	40,9	0,01	0,1748	0,2674	0,2211

A partir dos resultados do grau de envelhecimento relativo fornecidos pelas abordagens propostas e apresentados na Tabela 2, pode-se ordenar os transformadores segundo seu GER da seguinte maneira: $T4 < T5 < T2 < T1 < T3 < T6 < T7$. Pode-se observar que os resultados fornecidos condizem com o esperado, por exemplo a avaliação dos transformadores T6 e T7 como sendo os mais envelhecidos do conjunto procede, pois são estes os equipamentos que possuem o maior índice de 2-FAL.

O segundo grupo de transformadores foram compostos por equipamentos dos grupos G3 e G4. As características destes transformadores bem como seu grau de envelhecimento relativo é expresso na Tabela 3.

TABELA 3 - Segundo conjunto de transformadores

Trafo	2-FAL	CO	TI	IA	GER (Fuzzy)	GER (RNA)	GER Médio
T1/G3	0,33	1,742	39,9	0,01	0,6093	0,5828	0,5961
T2/G3	0,29	1,740	43,1	0,01	0,5901	0,5374	0,5638
T3/G3	1,15	2,060	34,8	0,03	0,8694	0,9062	0,8878
T4/G3	0,80	1,526	39,2	0,02	0,8250	0,8289	0,8270
T5/G4	2,94	2,786	30,0	0,03	0,9397	0,9514	0,9456
T6/G4	2,77	2,269	30,6	0,04	0,9530	0,9267	0,9399
T7/G4	0,48	2,072	37,6	0,01	0,7082	0,7111	0,7097

A partir do grau de envelhecimento relativo estimado pelo sistema nebuloso é possível observar que a seqüência crescente de envelhecimento destes equipamentos pode ser dada como: $T2 < T1 < T7 < T4 < T3 < T6 < T5$.

E finalmente, no terceiro conjunto de transformadores em estudo, foram comparados o grau de envelhecimento de transformadores pertencentes a todos os grupos da Tabela 1. Na Tabela 4 são

apresentadas as características do óleo isolante de cada equipamento bem como seu GER.

TABELA 4 - Terceiro conjunto de transformadores

Trafo	2-FAL	CO	TI	IA	GER (Fuzzy)	GER (RNA)	GER (Médio)
T1/G1	0,02	3,454	41,9	0,01	0,1215	0,070	0,0958
T2/G1	0,02	5,588	40,3	0,01	0,1298	0,097	0,1134
T3/G2	0,34	1,488	31,0	0,02	0,6212	0,609	0,6151
T4/G2	0,44	1,242	31,3	0,03	0,6736	0,683	0,6783
T5/G3	0,33	1,742	39,9	0,01	0,6093	0,583	0,5962
T6/G4	0,48	2,072	37,6	0,01	0,7082	0,711	0,7096
T7/G5	0,37	16,32	15,7	0,37	0,6250	0,634	0,6295
T8/G6	0,23	17,20	27,6	0,05	0,5035	0,512	0,5078
T9/G6	0,08	14,70	32,3	0,03	0,3707	0,390	0,3804
T10/G7	0,39	9,300	40,9	0,03	0,6387	0,659	0,6489

A avaliação do grau de envelhecimento dos transformadores do terceiro conjunto de equipamentos, avaliados na Tabela 4, permite que a classificação crescente do envelhecimento seja feita da seguinte maneira: T1 < T2 < T9 < T8 < T5 < T3 < T7 < T10 < T4 < T6.

Analisando a resposta do sistema nebuloso e neural para cada variável específica é possível observar como elas influenciam no processo de degradação dos transformadores. Observa-se que o acréscimo mais significativo no grau de envelhecimento é determinado em grande parte pelo incremento da concentração do 2-furfuraldeído.

Portanto, pode ser observado que o grau de influência que o teor de 2-furfuraldeído exerce sobre o envelhecimento destes equipamento é muito significativo quando comparado com os demais fatores que regem este processo, tais como a concentração de monóxido de carbono, tensão interfacial e índice de acidez. Logo, um sistema que necessita da monitoração do estado de seus equipamentos, no caso transformadores, deve dedicar especial atenção às variações na concentração de 2-furfuraldeído presentes no óleo mineral isolante dos mesmos.

5.0 - CONCLUSÕES

Os resultados obtidos demonstram que a partir de um sistema nebuloso simples com apenas três regras de inferência ou através de uma rede neural artificial com somente uma única camada escondida, é possível uma estimativa expressiva do grau de envelhecimento relativo dos transformadores. Desta forma, devido a simplicidade dos métodos apresentados e a qualidade dos resultados obtidos em cada abordagem, é possível a implementação destes sistemas inteligentes com o objetivo de contribuir para uma manutenção mais adequada do sistema de energia elétrica.

Além de fornecer uma nova metodologia para a identificação do grau de envelhecimento de transformadores, a abordagem desenvolvida pode ser empregada como um instrumento eficiente e alternativo para a tomada de decisões estratégicas, principalmente quando existem diversos transformadores em um sistema. Os resultados de simulação comprovam a validade da abordagem proposta.

6.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) MILASCH, M. Manutenção de Transformadores em Líquido Isolante. Ed. Edgar Blucher Ltda, 1984.
- (2) HAYKIN, S. Neural Networks – A Comprehensive Foundation. Macmillan, New York, 1994.
- (3) PEDRYCZ, W., GOMIDE, F. A. C. An Introduction to Fuzzy Sets – Analysis and Design. MIT Press, Cambridge, Massachusetts, 1998.
- (4) MITCHELL, M. An Introduction to Genetic Algorithms. MIT Press, Cambridge, Massachusetts, 1996.
- (5) FREEMAN, W. J., YAO, Y. Chaos in the byodynamics of the pattern recognition by neural networks. Proc. of International Joint Conference on Neural Networks, vol. 1, pp. 243-246, Washington, DC, 1990.
- (6) SILVA, I. N., et al. Intelligent system applied in diagnosis of transformer oil. Proc. of 8th International Conference on Dielectric Materials, Measurements and Applications, London, 2000.
- (7) JANG, J.-S. R. ANFIS: Adaptive-network-based fuzzy inference systems. IEEE Transactions on Systems, Man, and Cybernetics, Vol. 23, No. 3, pp. 665-685, May 1993.
- (8) DIOGO, A. C. T. Avaliação da vida útil residual de transformadores de potência através da cromatografia líquida de alto desempenho. III CLAGTEE, pp. 486-489, 1997.
- (9) LEVY, N. M., OLIVEIRA, V. P., NACHVALGER, E. E. Técnica de diagnóstico da isolamento celulósica em transformadores. Eletricidade Moderna, pp. 75-82, Julho 1998.

AGRADECIMENTOS

Os autores agradecem à FAPESP pelo suporte financeiro (Proc. 98/08480) e ao CNPq pela concessão de bolsa de pesquisa.