

APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NA ESTIMAÇÃO DOS GASES DISSOLVIDOS EM ÓLEO MINERAL ISOLANTE A PARTIR DE DADOS FÍSICO-QUÍMICOS

FÁBIO R. BARBOSA¹, FRANCISCO A. P. ARAGÃO¹, PAULO R. O. BRAGA¹, MÁRCIO A. B. AMORA¹, SERGIO S. LIMA, ARTHUR P. S. BRAGA¹, CÍCERO M. TAVARES¹, OTACÍLIO M. ALMEIDA¹, LUCIANO A. C. LISBOA²

¹*Grupo de Pesquisa em Automação e Robótica (GPAR), Departamento de Engenharia Elétrica, Universidade Federal do Ceará, Caixa Postal 6001 – Campus do Pici, 60455-760 Fortaleza, CE, BRASIL*
E-mails: {fabio, aldinei, proberto, marcio, sergio, arthurp, cicero, otacilio}@dee.ufc.br

²*Companhia Hidro Elétrica do São Francisco (CHESF), Rua Delmiro Gouveia, 333 - Bongí, 50761-901, Recife, PE, BRASIL*
E-mails: lcalmon@chesf.gov.br

Abstract— In this paper, Artificial Neural Networks are used to solve a complex problem concerning to power transformers and characterized by non-linearity and hard dynamic modeling. The operation conditions and integrity of a power transformer can be detected by analysis of physical-chemical and chromatographic isolating oil, allowing establish procedures for operating and maintaining the equipment. However, while the costs of physical-chemical tests are smaller, the chromatographic analysis is more informative. This work presents an estimation study of the information that would be obtained in the chromatographic test from the physical-chemical analysis through Artificial Neural Networks. Thus, the power utilities can achieve greater reliability in the prediction of incipient failures at a lower cost. The results show this strategy to be a promising, with accuracy of 100% in best cases.

Keywords— Chromatograph, Physical-chemical, Incipient Failures, Transformers, Artificial Neural Network.

Resumo— Neste trabalho, Redes Neurais Artificiais são utilizadas para solucionar um problema complexo associado a transformadores de potência e caracterizado por não-linearidades e dinâmicas de difícil modelagem. As condições de funcionamento e integridade de um transformador de potência podem ser detectados a partir da análise de ensaios físico-químicos e cromatográficos do óleo isolante, permitindo definir procedimentos de operação e manutenção do equipamento. Entretanto, enquanto os custos do ensaio físico-químico são menores, o ensaio cromatográfico é mais informativo. Neste trabalho apresenta-se um estudo da estimação, utilizando Redes Neurais Artificiais, das informações que seriam obtidas no ensaio cromatográfico a partir de ensaios físico-químicos. Desta forma, as concessionárias de energia podem alcançar uma maior confiabilidade na previsão de falhas incipientes dos transformadores, a um custo menor. Os resultados obtidos demonstram ser promissora esta estratégia, com acerto de 100 % nos melhores casos.

Palavras-chave— Cromatografia, Físico-químico, Falhas Incipientes, Transformadores, Rede Neural Artificial.

1 Introdução

As Redes Neurais Artificiais (RNAs) [6, 16] têm sido empregadas com sucesso na modelagem e identificação de sistemas de natureza complexa. Técnicas que envolvem a aplicação de diferentes arquiteturas de RNAs (ex., *Multi-Layer Perceptron*, *Radial-Basis Function*, *Self-Organizing Maps*, Redes Recorrentes, entre outras) [6] têm sido propostas com sucesso para a detecção de falhas incipiente em transformadores de potência [2, 3, 7, 8, 12, 17, 18].

A qualidade dielétrica do óleo isolante de transformadores e as falhas incipientes de natureza térmica e elétrica destes equipamentos, podem ser determinadas a partir de ensaios físico-químico e cromatográfico [4, 7, 8, 14]. Estes ensaios são importantes para orientar o programa de manutenção das concessionárias. Entretanto, enquanto os custos do ensaio físico-químico são menores, o ensaio cromatográfico é mais informativo e, por isso, mais usual no diagnóstico de falhas em transformadores [2, 3, 12, 19] uma vez que fornece medidas quantitativas das concentrações de gases dissolvidos no óleo que indicam condi-

ções operacionais que comprometem a vida útil do transformador. Há, na literatura técnica, trabalhos que apontam para a correlação entre estes dois tipos de ensaios [9, 5, 14, 18], e este artigo propõe uma metodologia para explorar esta correlação ao estimar as concentrações dos gases dissolvidos no óleo isolante (normalmente obtidas do ensaio cromatográfico) em função das características físico-químicas da amostra. Esta proposta, traz redução econômica na previsão de falhas incipientes do transformador [2, 3, 7, 8, 12, 17, 18].

A relação entre grandezas físico-químicas e concentração de gases é implementada neste trabalho através de Redes Neurais Artificiais (RNA) [6, 16] que, a partir de exemplos, aprendem a realizar mapeamentos lineares ou não-lineares, sendo considerados aproximadores universais [6].

Este documento está organizado conforme segue. A Seção 2 comenta a relação entre as grandezas dos ensaios físico-químico e cromatográfico. A Seção 3 comenta a proposta de estimação dos gases dissolvidos utilizando RNA. A Seção 4 trata da definição dos atributos físico-químicos mais influentes na estimação dos gases dissolvidos. Os resultados obtidos são analisados na Seção 5, sendo apresentadas as conclu-

sões na Seção 6.

2 Relação entre as Grandezas dos Ensaio Físico-Químico e Cromatográfico

Algumas pesquisas procuram associar as características dielétricas anormais do óleo ao aparecimento de falhas internas [5, 9, 14, 18]. E podem estar relacionadas com a presença de radicais livres e de oxigênio dissolvido sob o efeito catalítico do cobre, iniciando o processo de degradação do óleo na medida do seu envelhecimento [5, 18].

Ensaio de espectroscopia dielétrica apresentam correlação entre o envelhecimento do óleo e o fator de perdas ($\tan \delta$). Amostras com características físico-químicas alteradas apresentam fator de perdas dependente da temperatura, conforme Figura 1 [14].

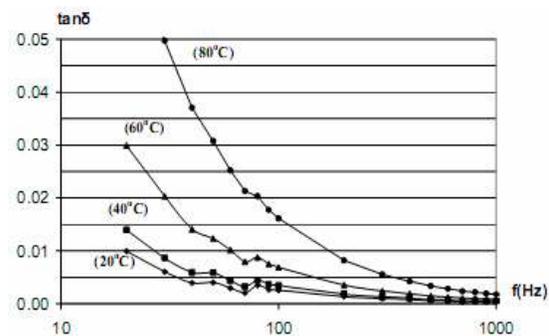


Figura 1 - Espectroscopia dielétrica de óleo isolante envelhecido [14].

Os estudos de Peyraque *et al.* (1998), demonstram que a condutividade do óleo, parâmetro complementar à rigidez dielétrica, mantém uma relação ascendente com a temperatura.

Sabe-se que o mecanismo de formação de gases no interior dos transformadores segue um modelo termodinâmico que associa a taxa de formação dos gases à temperatura na vizinhança do local onde ocorre a falha [7, 8].

Estas informações indicam que há probabilidade de se obter relações entre as características físico-químicas e cromatográficas. Porém, por não se dispor de uma forma clássica para estabelecer tais relações, a aplicação de RNA, podem fornecer resultados satisfatórios acerca do comportamento do isolamento líquido do transformador [9].

3. Estimação dos Gases Dissolvidos Utilizando uma Rede Neural Artificial

Considerando os resultados obtidos por Paraskevas *et al.* (2006), foram definidas as características físico-químicas que influenciam na qualidade do óleo isolante. O vetor de entrada a ser aplicado às RNA é constituído dos seguintes elementos: **Acidez, Rigidez Dielétrica, Teor de Água, Tensão Interfacial, Densidade e Fator de Potência do Óleo.**

A estimativa dos gases dissolvidos é obtida na saída da rede neural. Os gases estimados são os ne-

cessários para a execução do diagnóstico de falhas incipientes em transformadores [1, 2, 7, 8, 13, 17, 20]. Foram estimadas as concentrações dos seguintes gases: **Hidrogênio (H₂), Monóxido de Carbono (CO), Dióxido de Carbono (CO₂), Metano (CH₄), Etano (C₂H₆), Etileno (C₂H₄) e Acetileno (C₂H₂).**

Foi concebida uma RNA para estimar cada gás com apenas um neurônio de saída. A etapa de treinamento da rede está descrita na Seção 5.

Foram realizados testes para a estimativa dos gases dissolvidos no óleo do transformador a partir de análise físico-química com duas arquiteturas de RNA: (i) Rede MLP (*Multi Layer Perceptron*), com algoritmo de treinamento Levenberg-Marquardt [3] e (ii) Rede RBF (*Radial-Basis Function*) com estratégia incremental de neurônios [3, 12].

4. Definição dos Atributos Físico-Químicos mais Influentes na Estimativa do Gás Dissolvido

Na estimativa dos gases dissolvidos, surge, paralelamente, a questão de se identificar quais as características físico-químicas são relevantes para associação com os gases dissolvidos. Para esta tarefa, utiliza-se um algoritmo conhecido por busca exaustiva relacionado a um sistema adaptativo de inferência *neuro-fuzzy* (ANFIS) [10, 11].

Este tipo de sistema de inferência usa dados de entrada e saída para construir um sistema nebuloso onde as funções de pertinência são ajustáveis permitindo que o sistema aprenda dos próprios dados de modelagem.

Uma estrutura de modelo parametrizado é considerada como hipótese, relacionando as funções de pertinência de entrada e as regras para a função de pertinência de saída. Os dados de entrada e saída são utilizados para modificar os parâmetros das funções de pertinência de acordo com o critério de erro, durante um processo de treinamento.

Para a seleção do atributo mais influente dentre as seis entradas para estimativa dos gases dissolvidos é necessária a construção de seis ANFIS. Os dados de entrada e saída são organizados de forma que a primeira metade seja designada para o treinamento enquanto a segunda metade é dirigida à validação. O *overfitting* foi evitado quando há mesma dimensão dos valores de erro de treinamento e validação.

A entrada mais influente resultante da busca exaustiva é a que apresenta menor valor de erro de treinamento e valor de erro de validação concordante.

Entretanto, pode haver mais de um atributo físico-químico influente na relação com gás dissolvido no óleo. A busca exaustiva, então, constrói 15 modelos ANFIS relacionando os atributos dois a dois para definir quais modelos apresentam menores valores de erro de treinamento com erro de validação condizente.

Caso o erro mínimo de treinamento e validação seja reduzido significativamente, o sistema apresenta

duas entradas influentes. Na tentativa de se buscar mais uma entrada influente, a estratégia constrói 20 modelos ANFIS, com os atributos organizados aos trios, e os erros de treinamento e validação são analisados. Se não apresentam melhoras, então apenas duas entradas são mais influentes e necessárias para uma boa estimativa.

4.1 Atributos Mais Influentes

A aplicação do algoritmo de busca exaustiva para definição da entrada mais influente no hidrogênio dissolvido obteve a composição de modelos ANFIS da Tabela 1 que aponta a tensão interfacial como atributo mais influente na presença de hidrogênio dissolvido. Os erros de treinamento e de validação implicam na inexistência de *overfitting* indicando que é possível testar mais entradas: a Tabela 2 considera as duas e três entradas mais influentes.

Tabela 1 - Resultado da busca exaustiva - Hidrogênio.

Modelo ANFIS (Entrada)	Erro Treinamento	Erro Validação
Acidez	140,52	173,73
Rigidez Dielétrica	140,76	172,95
Teor de Água	140,84	173,00
Tensão Interfacial	138,35	170,97
Densidade	139,23	171,05
Fator de Potência	141,92	173,57

Tabela 2 - Atributos mais influentes - Hidrogênio.

Modelo ANFIS – Entrada	Erro Treinamento	Erro Validação
Rigidez Dielétrica – T. Interfacial	131,74	169,97
Rig. Dielétrica – T. Interf. – Teor Água	126,24	186,42

Da tabela 2, ocorre queda nos valores de erro quando outro atributo é acrescentado. No caso de três atributos como entrada, o treinamento melhora, mas o erro de validação aumenta, significando possível indicio de *overfitting*. A princípio, o atributo teor de água pode aperfeiçoar a estimativa, mas com perda de generalização indicando não ser mais vantajoso acrescentar entradas.

Seguindo o mesmo algoritmo apresentado para o hidrogênio, a busca exaustiva foi aplicada para monóxido e dióxido de carbono, metano, etileno, etano e acetileno. Os resultados seguem nas tabelas 3 a 8.

Tabela 3 - Atributos mais influentes - Monóxido de Carbono.

Modelo ANFIS – Entrada	Erro Treinamento	Erro Validação
Fator de Potência	255,26	247,06
Fator de Potência – Densidade	218,31	254,03
F. Potência – T. Inter. – Densidade	172,85	531,86

Tabela 4 - Atributos mais influentes - Dióxido de Carbono.

Modelo ANFIS – Entrada	Erro Treinamento	Erro Validação
Densidade	2052,51	2224,17
Tensão Interfacial – Densidade	1833,80	2413,57
R. Dielétrica – T. Inter. – Densidade	1588,79	2706,55

Tabela 5 - Atributos mais influentes - Metano.

Modelo ANFIS – Entrada	Erro Treinamento	Erro Validação
Fator de Potência	30,84	39,33
Fator de Potência – Densidade	27,61	38,62
F. Potência – Densid. – Rig. Dielétr.	23,20	77,73

Tabela 6 - Atributos mais influentes - Etileno.

Modelo ANFIS – Entrada	Erro Treinamento	Erro Validação
Tensão Interfacial	41,20	57,06
Fator de Potência – Tens. Interfacial	37,27	57,55
F. Potência – T. Inter. – Rig. Dielétr.	32,87	101,71

Tabela 7 - Atributos mais influentes - Etano.

Modelo ANFIS – Entrada	Erro Treinamento	Erro Validação
Fator de Potência	52,28	39,52
Fator de Potência – Densidade	36,99	32,88
F. Potência – Densid. – Rig. Dielétr.	25,82	69,54

Tabela 8 - Atributos mais influentes - Acetileno.

Modelo ANFIS – Entrada	Erro Treinamento	Erro Validação
Densidade	165,83	262,64
Rigidez Dielétrica – Densidade	159,03	255,92
T. Interfac. – Densid. – Rig. Dielétr.	150,02	256,77

Os resultados referentes ao acetileno revelam muita tendência ao *overfitting*, provavelmente devido à carência de dados. A estratégia apresenta dificuldades para desenvolver modelos bem sucedidos para o fim proposto de se estabelecer os atributos mais influenciadores para o acetileno dissolvido.

5. Análise dos Resultados

As 251 amostras de análises cromatográficas e físico-químicas foram extraídas de Barbosa (2008) para realização das etapas de treinamento, validação e testes das redes neurais desenvolvidas.

No projeto das RNA, os conjuntos de treinamento, validação e teste apresentam, respectivamente, 140, 60 e 51 amostras. A saída desejada é diagnóstico fornecido no laudo técnico do especialista responsável pela análise físico-química do óleo isolante.

O treinamento das redes neurais projetadas usa informações obtidas na seção 4. As redes foram testadas com 2 e 3 atributos de entrada. As tabelas 9 a 15 apresentam os valores do percentual de acerto para a MLP treinada pelo algoritmo Levenberg-Marquardt (identificado por LM) e a rede RBF Incremental (identificada por RBF-Inc) em função do número de neurônios utilizados na camada escondida nos conjuntos de dados de treinamento, validação e teste.

Tabela 9 - Percentual de acerto das redes neurais para estimação do Hidrogênio.

Algoritmo de Treinamento	Nº. de Neurônios na Camada Escondida	Diagnóstico Correto (%) 2 atributos / 3 atributos		
		Treinamento	Validação	Teste
LM	5	98,57 / 98,57	100,00 / 100,00	100,00 / 100,00
RBF-Inc	5	98,57 / 94,29	98,33 / 90,00	100,00 / 94,12
LM	15	98,57 / 98,57	98,33 / 95,00	100,00 / 98,04
RBF-Inc	15	98,57 / 98,57	100,00 / 100,00	100,00 / 100,00
LM	25	98,57 / 98,57	98,33 / 93,33	98,04 / 98,04
RBF-Inc	25	98,57 / 98,57	100,00 / 100,00	100,00 / 100,00
CONFIGURAÇÃO ADEQUADA		MLP-LM – 5 neurônios – 2 atributos		

Tabela 10 - Percentual de acerto das redes neurais para estimação do Monóxido de Carbono.

Algoritmo de Treinamento	Nº. de Neurônios na Camada Escondida	Diagnóstico Correto (%) 2 atributos / 3 atributos		
		Treinamento	Validação	Teste
LM	5	100,00 / 100,00	98,33 / 100,00	94,12 / 100,00
RBF-Inc	5	100,00 / 100,00	100,00 / 100,00	100,00 / 100,00
LM	15	100,00 / 100,00	98,33 / 98,33	96,08 / 98,04
RBF-Inc	15	100,00 / 100,00	100,00 / 100,00	100,00 / 100,00
LM	25	100,00 / 100,00	98,33 / 98,33	96,08 / 96,08
RBF-Inc	25	100,00 / 100,00	100,00 / 100,00	100,00 / 100,00
CONFIGURAÇÃO ADEQUADA		RBF – 5 neurônios – 2 atributos		

Tabela 11 - Percentual de acerto das redes neurais para estimação do Dióxido de Carbono.

Algoritmo de Treinamento	Nº. de Neurônios na Camada Escondida	Diagnóstico Correto (%) 2 atributos / 3 atributos		
		Treinamento	Validação	Teste
LM	5	100,00 / 100,00	100,00 / 100,00	100,00 / 100,00
RBF-Inc	5	100,00 / 100,00	100,00 / 100,00	100,00 / 100,00
LM	15	100,00 / 100,00	100,00 / 98,33	98,04 / 100,00
RBF-Inc	15	100,00 / 100,00	100,00 / 100,00	100,00 / 100,00
LM	25	100,00 / 100,00	100,00 / 98,33	98,04 / 96,08
RBF-Inc	25	100,00 / 100,00	100,00 / 100,00	100,00 / 100,00
CONFIGURAÇÃO ADEQUADA		MLP-LM – 5 neurônios – 2 atributos		

Tabela 12 - Percentual de acerto das redes neurais para estimação do Metano.

Algoritmo de Treinamento	Nº. de Neurônios na Camada Escondida	Diagnóstico Correto (%) 2 atributos / 3 atributos		
		Treinamento	Validação	Teste
LM	5	97,86 / 94,29	96,67 / 96,67	100,00 / 94,12
RBF-Inc	5	97,86 / 97,86	96,67 / 96,67	100,00 / 98,04
LM	15	97,86 / 92,14	96,67 / 96,67	100,00 / 90,20
RBF-Inc	15	97,86 / 97,86	96,67 / 96,67	100,00 / 100,00
LM	25	97,86 / 97,86	96,67 / 96,67	96,08 / 96,08
RBF-Inc	25	97,86 / 97,86	96,67 / 96,67	100,00 / 100,00
CONFIGURAÇÃO ADEQUADA		MLP-LM – 5 neurônios – 2 atributos		

Tabela 13 - Percentual de acerto das redes neurais para estimação do Etileno.

Algoritmo de Treinamento	Nº. de Neurônios na Camada Escondida	Diagnóstico Correto (%) 2 atributos / 3 atributos		
		Treinamento	Validação	Teste
LM	5	86,43 / 86,43	96,67 / 96,67	78,43 / 78,43
RBF-Inc	5	86,43 / 82,14	96,67 / 93,33	82,35 / 74,51
LM	15	86,43 / 86,43	96,67 / 96,67	76,47 / 80,39
RBF-Inc	15	86,43 / 86,43	96,67 / 96,67	82,35 / 82,35
LM	25	86,43 / 85,71	95,00 / 95,00	76,47 / 80,39
RBF-Inc	25	86,43 / 86,43	96,67 / 96,67	82,35 / 82,35
CONFIGURAÇÃO ADEQUADA		RBF – 5 neurônios – 2 atributos		

Tabela 14 - Percentual de acerto das redes neurais para estimação do Etano.

Algoritmo de Treinamento	Nº. de Neurônios na Camada Escondida	Diagnóstico Correto (%) 2 atributos / 3 atributos		
		Treinamento	Validação	Teste
LM	5	58,57 / 57,86	66,67 / 66,67	60,78 / 56,86
RBF-Inc	5	58,57 / 58,57	66,67 / 66,67	60,78 / 56,86
LM	15	58,57 / 55,71	66,67 / 58,33	60,78 / 43,14
RBF-Inc	15	58,57 / 58,57	66,67 / 66,67	60,78 / 60,78
LM	25	58,57 / 52,85	66,67 / 50,00	54,90 / 47,06
RBF-Inc	25	58,57 / 58,57	66,67 / 66,67	60,78 / 60,78
CONFIGURAÇÃO ADEQUADA		Resultados Insatisfatórios		

Tabela 15 - Percentual de acerto das redes neurais para estimação do Acetileno.

Algoritmo de Treinamento	Nº. de Neurônios na Camada Escondida	Diagnóstico Correto (%) 2 atributos / 3 atributos		
		Treinamento	Validação	Teste
LM	5	5,71 / 5,71	5,00 / 5,00	5,88 / 3,92
RBF-Inc	5	5,71 / 5,71	5,00 / 3,33	5,88 / 5,88
LM	15	5,71 / 5,71	5,00 / 5,00	3,92 / 5,88
RBF-Inc	15	5,71 / 5,71	5,00 / 5,00	5,88 / 5,88
LM	25	4,28 / 5,71	3,33 / 3,33	3,92 / 3,92
RBF-Inc	25	5,71 / 5,71	5,00 / 5,00	5,88 / 5,88
CONFIGURAÇÃO ADEQUADA		Resultados Insatisfatórios		

6. Conclusões

Neste artigo foram propostas e testadas duas estruturas de Redes Neurais objetivando a estimação de gases dissolvidos a partir das grandezas físico-químicas do óleo isolante de transformadores.

O algoritmo de busca exaustiva apresentou resultados positivos permitindo a identificação dos parâmetros dos ensaios físico-químicos mais influentes na condição de gases dissolvidos no óleo. A maior parte das estimações apresentou resultados satisfatórios com apenas duas características físico-químicas como entrada da rede neural. Isto otimiza o projeto da rede, simplificando os esforços computacionais, e melhora o desempenho, pois evita o aprendizado de detalhes provenientes de entradas irrelevantes.

Em termos de complexidade de estrutura da rede neural, conclui-se que redes MLP com apenas uma camada escondida formada por 5 neurônios torna a rede menos complexa para a tarefa de estimação dos gases dissolvidos no óleo e não compromete a eficiência da tarefa.

ência da tarefa.

É evidente a alta eficiência na estimação do hidrogênio, monóxido e dióxido de carbono e metano. Hidrogênio e metano aparecem dissolvidos no óleo quando há ocorrência de falhas térmicas que sobreaquecem o óleo e os óxidos de carbono são decorrentes de falhas que envolvem a celulose. A qualidade da estimação é explicada pelo fato da maior parte dos dados cromatográficos, que apresentam análise físico-química contemporânea, diagnosticarem falhas térmicas no transformador amostrado.

Pelo mesmo fato, é explicada a baixa qualidade da estimação dos gases mais pesados, como etano e acetileno, que são dissolvidos no óleo mediante falhas elétricas.

É necessário enfatizar que os resultados demonstram a existência do relacionamento entre as grandezas físico-químicas e cromatográficas. Esta relação pode ter seus estudos aprofundados de forma a promover um maior conhecimento das dinâmicas que envolvem as falhas internas do transformador e as qualidades dielétricas do óleo isolante. Surge a pos-

sibilidade de se instituir critérios preventivos acerca da degradação do óleo e das falhas incipientes em transformadores.

A partir das implementações apresentadas pode-se concluir que é possível acompanhar a evolução dos gases dissolvidos sem a realização de uma cromatografia completa, que em muitos casos é uma facilidade conveniente, devido à fácil disponibilidade dos testes físico-químicos.

Agradecimentos

Os autores expressam seus agradecimentos à Companhia Hidro Elétrica do São Francisco (CHESF) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio a esta pesquisa.

Referências Bibliográficas

- [1] ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. NBR 7274: Interpretação da Análise dos Gases de Transformadores em Serviço. Rio de Janeiro, RJ, 1982.
- [2] ALMEIDA, O. M.; BARBOSA, F. R.; AMORA, M. A. B.; BRAGA, P. R. O. Diagnóstico de Transformadores Utilizando Monitoramento On-line. Anais do XII ERIAC - Encontro Regional Ibero-Americano do CIGRÈ, Foz do Iguaçu, PR, 2007
- [3] BARBOSA, F. R. Monitoramento on-line e diagnóstico inteligente da qualidade dielétrica do isolamento líquido de transformadores de potência. Dissertação de Mestrado, UFC/CT/DEE - Departamento de Energia Elétrica, Fortaleza, CE, 2008.
- [4] CARGOL, T. A Overview of On-Line Oil Monitoring Technologies. Fourth Annual Weidmann-ACTI Technical Conference, San Antonio, USA, 2005.
- [5] FERGUSON, R.; LOBEIRAS, A.; SABOU, J. Suspended Particles in the Liquid Insulation of Aging Power Transformers. IEEE Electrical Insulation Magazine. vol. 18, v. 4, pp. 17-23, 2002.
- [6] HAYKIN, S. Redes Neurais: Princípios e Práticas. Trad. Paulo Martins Engel, 2ª ed., Porto Alegre, RS, Bookman, 2001.
- [7] INTERNATIONAL ELECTROTECHNICAL COMMISSION – IEC 60599. Mineral Oil-Impregnated Electrical Equipment in Service - Guide to the Interpretation of Dissolved and Free Gases Analysis. Geneva, Switzerland, 2. ed., 1999.
- [8] IEEE Guide for the Interpretation of Gases Generated in Oil-Immersed Transformers, IEEE Std C57.104-1991, 1991.
- [9] IMAMURA, M. M.; SILVA, I. N.; SOUZA, A. N. Uma Abordagem Neural para Análise dos Gases Dissolvidos em Óleo Isolante em Função das Grandezas Físico-Químicas. Anais do XIII CONGRESSO BRASILEIRO DE AUTOMÁTICA - CBA 2000, Florianópolis, pp. 2288-2293, 2000.
- [10] JANG, J. S. R. ANFIS: Adaptive - Network - based Fuzzy Inference Systems, IEEE Transactions on Systems, Man and Cybernetics, Vol. 23, No. 3, pp. 665 - 85, 1993.
- [11] JANG, J. S. R.; SUN, C. T. Neuro-fuzzy Modeling and Control, Proceedings of the IEEE, 1995.
- [12] LIMA, S. E. U. Diagnóstico Inteligente de Falhas Incipientes em Transformadores de Potência Utilizando a Análise dos Gases Dissolvidos em Óleo. Dissertação de Mestrado, UFC/CT/DEE - Departamento de Energia Elétrica, Fortaleza, CE, 2005.
- [13] MILASCH, M. Manutenção de Transformadores em Líquido Isolante. Edgar Blücher, São Paulo, SP, 1984.
- [14] PARASKEVAS, C. D.; VASSILIOU, P.; DERVOS, C. T. Temperature Dependent Dielectric Spectroscopy in Frequency Domain of High-voltage Transformer Oils Compared to Physicochemical Results, IEEE Transactions on Dielectrics and Electrical Insulation, vol. 13, no. 3, pp. 539-546, 2006.
- [15] PEYRAQUE, L.; BEROUAL, A.; BURET, F. Static Electrification of Pressboard/Oil Interface and Transient Phenomena. IEEE Transactions on Dielectrics and Electrical Insulation, vol. 5, no. 3, pp. 443-449, 1998.
- [16] RUMMELHART, D., HINTON, W. Learning Internal Representations by Error Propagation. In: Parallel Distributed Processing - MIT Press, Cambridge, MA, 1986.
- [17] VAN BOLHUIS, J. P.; GULSKI, E.; SMIT, J. J. Monitoring and Diagnostic of Transformer Solid Insulation. IEEE Transactions on Power Delivery, vol. 17, no. 3, p. 528-536, 2002.
- [18] WANG, M.; VANDERMAAR, A. J.; SRIVASTAVA, K. D. Review of Condition Assessment of Power Transformers in Service. IEEE Electrical Insulation Magazine, vol. 18, no. 6, pp. 12-25, 2002.
- [19] ZAENGL, W. S. Dielectric Spectroscopy in Time and Frequency Domain for HV Power Equipment, Part I: Theoretical Considerations, IEEE Electrical Insulation Magazine vol. 19, no. 5, pp 5-19, 2003.
- [20] ZIRBES, R.; ROLIM, J. G.; ZÜRN, H. H. Metodologias para Avaliação e Diagnóstico do Estado de Isolamentos de Papel Impregnado com Óleo Mineral. SBA Controle & Automação, vol. 16, no. 3, pp. 318-331, 2005.