

# UMA ABORDAGEM NEURAL RELACIONANDO FENÔMENOS FÍSICO-QUÍMICOS E GASOSOS COM O PROCESSO DE ENVELHECIMENTO DO TRANSFORMADOR

ANDRÉ N. DE SOUZA, MARIA G. ZAGO, PEDRO DA COSTA JR, PAULO R. AGUIAR

*Laboratório de Sistemas de Potência e Técnicas Inteligentes, DEE, FE, Universidade Estadual Paulista  
CP 473, CEP 17033-360, Bauru, SP, BRASIL +55-14-31036115*

E-mails: andrejau@feb.unesp.br, mgzago@uol.com.br, costajr@feb.unesp.br,  
aguiarpr@feb.unesp.br

**Abstract**— This work presents a new approach to mapping the processes related to transformer oil ageing by using Artificial Neural Networks. The concentration of hydrogen ( $H_2$ ), methane ( $CH_4$ ) and carbon dioxide ( $CO_2$ ) were the input variables while the dielectric rigidity was the output variable. These variables were chosen based on previous knowledge of the influence of each one on the oil degradation process. Simulations to validate the approach proposed in this work were carried out by employing the criterion of the minimum possible error between the expected outputs and the outputs provided by the Neural Network. Successive simulations were developed with the best Neural Network selected in order to drawing conclusions on the influence of each variable studied. The results show an intrinsic relationship between the physical-chemical and gaseous variables in the transformer oil ageing process. This relationship can be useful to decrease the number of experimental tests.

**Keywords**— Artificial Neural Network, Transformers, Oil, Gas, Process Control.

**Resumo**— Este trabalho descreve uma abordagem utilizando Redes Neurais Artificiais para o mapeamento de processos referentes ao envelhecimento do óleo mineral isolante de transformadores. As variáveis de entrada foram compostas pelas concentrações de hidrogênio ( $H_2$ ), metano ( $CH_4$ ) e dióxido de carbono ( $CO_2$ ) e a saída, pela Rigidez Dielétrica. Essas variáveis foram escolhidas baseando-se em um conhecimento prévio da influência isolada de cada uma delas no processo de degradação do óleo. Foram realizadas simulações para validar a abordagem proposta balizando-se no menor erro relativo possível entre as saídas desejadas e as generalizadas pela rede. Depois de validada a arquitetura neural, foram realizadas sucessivas simulações a fim de se obter uma conclusão sobre a influência de cada variável estudada no processo. Os resultados evidenciam que existe um relacionamento intrínseco entre grandezas físico-químicas e gasosas no processo de envelhecimento do óleo dos transformadores. Esse relacionamento pode ser útil para a diminuição de ensaios experimentais.

**Palavras-chave**— Redes Neurais Artificiais, Transformadores, Óleo Isolante, Gases, Controle de Processo

## 1 Introdução

Atualmente, o diagnóstico do desempenho de um transformador em um sistema elétrico é estabelecido em função de resultados de ensaios laboratoriais do óleo isolante (físico-químicos e cromatográficos) que indicam a presença de contaminantes ou de subprodutos de reações de oxidação. Os fatores físico-químicos indicam a condição do óleo, estabelecendo a necessidade de regeneração ou troca do mesmo. Por outro lado, a análise cromatográfica é uma técnica muito útil no estudo dos gases dissolvidos no óleo isolante, e por isso, o seu emprego tem contribuído para um melhor diagnóstico (Souza, 2005a).

No entanto, constata-se uma carência de investigações mais abrangentes sobre a aplicação efetiva de ferramentas computacionais para otimizar a avaliação dos processos de envelhecimento do transformador, permitindo dessa forma, agregar valor na tomada de decisão em relação a processos de manutenção ou troca do equipamento.

Pesquisas têm comprovado a influência direta dos fatores físico-químicos como indicadores do grau de envelhecimento do óleo. No entanto, ainda não existe um consenso sobre a influência específica dos ensaios no processo de degradação do óleo, devido à dificuldade em estabelecer a influência particular de cada variável para uma possível mode-

ragem matemática do problema, pois na maioria das vezes o comportamento destas variáveis é não linear e de difícil identificação (Souza, 2005b).

A predição de falhas em transformadores tem sido uma tônica onde a avaliação do estado do papel de isolamento de um transformador pode ser assegurada pela análise da degradação específica de produtos do papel, tais como:  $CO$ ,  $CO_2$  e compostos furânicos. Contudo, ainda é difícil diferenciar uma falta incipiente do envelhecimento normal de um equipamento. Existe a necessidade de desenvolver ferramentas de diagnósticos mais precisas (Dong, 2004).

Desta forma, a pesquisa nessa área tem como principal objetivo desenvolver técnicas e ferramentas computacionais que, de forma prática, auxiliem na análise do comportamento do óleo isolante utilizado nos transformadores, contribuindo assim, para o aumento de sua vida útil.

## 2 Contextualização do Problema

Como já se sabe, o diagnóstico do estado e das condições de operação dos transformadores é de fundamental importância para a operação econômica e confiável dos sistemas elétricos. Por isso, conhecer os processos de deterioração e dispor de meios tecnicamente significativos e economicamente viáveis é extremamente importante para evitar que a ocorrência de falhas ou problemas de manutenção compro-

meta a confiabilidade ou disponibilidade do equipamento, bem como a diminuição de sua vida útil.

O óleo deteriorado apresenta componentes resultantes de sua oxidação, enquanto que o óleo contaminado apresenta água e outras substâncias estranhas à sua composição. O processo de degradação do óleo mineral apresenta três fases ou graus de degradação.

Primeiramente, tem-se a formação de peróxidos quimicamente instáveis que liberam oxigênio e formam os compostos oxi-celulósicos com o papel isolante. A fase intermediária caracteriza-se pela formação de gases e na fase final, há a formação de borra, uma substância resinosa resultante da polimerização a partir de ácidos e outros compostos. Os gases dissolvidos em óleos isolantes provêm de defeitos no interior do transformador, e a composição desses gases pode ser relacionada ao tipo e gravidade do defeito. A identificação e quantificação desse defeito são utilizadas para a realização de um planejamento da manutenção (Dong, 2004).

O método do gás chave baseia-se no fato de que, quando há uma falha em evolução no transformador, a concentração dos gases a ela associada ultrapassa os valores normais de degradação da isolação em relação aos níveis estabelecidos em ensaio de laboratório. Gás chave é a denominação do gás que caracteriza determinado tipo de falha. A Tabela 1 apresenta uma correlação dos perfis de composição de gases com as falhas (Unsworth, 1990).

Tabela 1. Perfis de composição de gases e falhas.

Falha	Gás chave
Arco	acetileno
Descargas Parciais	hidrogênio
Óleo Superaquecido	etileno
Celulose Superaquecida	monóxido de carbono
Eletrólise	hidrogênio

A identificação dos gases formados fica mais fácil quando houver apenas um tipo de falha, porém, podem ocorrer diversos tipos de falhas simultâneas ou consecutivas, que geram uma mistura de gases diferente daquela encontrada quando apenas um tipo de falha acontece.

Como observado na Tabela 1, quando ocorre formação de arco, o gás chave é o acetileno, pois grandes quantidades deste gás e de hidrogênio são produzidas, com pequenas quantidades de metano e etileno (IEC-599, 1978).

As descargas parciais de baixa energia produzem hidrogênio (gás chave), com pequenas quantidades de etano e etileno. Quantidades comparáveis de monóxido e dióxido de carbono podem resultar de descargas em celulose. O óleo superaquecido produz etileno (gás chave) e metano, juntamente com quantidades menores de hidrogênio e etano. Traços de acetileno podem ser formados se a falha for severa ou se envolver contatos elétricos. No caso de um superaquecimento da celulose, haverá liberação de

grandes quantidades de dióxido e monóxido de carbono, e caso a falha envolva uma estrutura impregnada de óleo, haverá a formação também de metano e etileno. O processo de eletrólise da água resulta na formação de grandes quantidades de hidrogênio (gás chave) com pequenas quantidades dos outros gases combustíveis (IEC-599, 1978).

Estudos sobre o óleo isolante mostram que os gases mais significativos produzidos pela decomposição do óleo são o hidrogênio ( $H_2$ ), o metano ( $CH_4$ ), o etano ( $C_2H_6$ ), o etileno ( $C_2H_4$ ) e o acetileno ( $C_2H_2$ ). O dióxido de carbono ( $CO_2$ ) está relacionado com o aparecimento de água no óleo, uma vez que quando o óleo é aquecido até determinada temperatura, originam-se água, CO e  $CO_2$  (Unsworth, 1990).

Dentre os gases escolhidos, o hidrogênio ( $H_2$ ) e o metano ( $CH_4$ ) estão associados com a formação do arco elétrico, sendo o primeiro em maior quantidade e o segundo em menor quantidade. O dióxido de carbono ( $CO_2$ ) está associado às propriedades elétricas do óleo por ser diretamente associado à presença de água, a qual representa um papel preponderante no processo de perda de rigidez dielétrica, como constatado em estudos correlatos (Souza, 2005b).

A tensão dielétrica de ruptura de um líquido isolante é definida como a medida da habilidade do líquido resistir à tensão elétrica sem falhar. Seu valor é dado em  $kV/0,1''$  e pode indicar a presença de agentes contaminantes como água, poeira, fibras celulósicas úmidas ou partículas condutoras no líquido isolante. Por outro lado, um alto valor de rigidez dielétrica não significa necessariamente a ausência de agentes contaminantes, mas, pode indicar que a concentração destes não seja suficientemente grande para afetar significativamente a tensão média de ruptura do líquido testado (Souza, 2005b).

Em muitos problemas de modelagem de fenômenos pode ocorrer que as informações disponíveis sejam insuficientes para construir equações matemáticas que representem o comportamento do fenômeno em estudo. Pode-se solucionar esta limitação usando uma abordagem baseada em modelos, como é o caso das Redes Neurais, em que a rede é treinada para abstrair equações que geram determinado fenômeno.

Dentro deste panorama, a identificação precisa dos tipos de falhas e defeitos em transformadores utilizando Redes Neurais Artificiais, pode ser vista como uma ferramenta eficiente que fornece alternativas às metodologias convencionais (experimentais e estatísticas), podendo gerar resultados expressivos, principalmente devido às características intrínsecas da técnica, como a capacidade de generalização e integração com outras ferramentas computacionais.

### 3 Configuração e Treinamento da Rede Neural

Neste trabalho foi utilizada uma rede Perceptron Multicamadas para identificar processos de envelhecimento do óleo isolante de transformadores.

Neste sentido foram realizados exaustivos treinamentos e simulações considerando-se como entradas as concentrações dos gases H<sub>2</sub>, CH<sub>4</sub> e CO<sub>2</sub> e saída à rigidez dielétrica. Nessas simulações variou-se o número de camadas, o número de neurônios em cada camada, a função de ativação e o algoritmo de treinamento, de maneira a se obter uma rede neural que melhor generalizasse as saídas para entradas não utilizadas no conjunto de treinamento. Assim, foi considerada a seguinte arquitetura de Rede Neural Artificial:

- Arquitetura: *Perceptron* Multicamadas;
- Número de Camadas Ocultas: 2;
- Número de Neurônios das Camadas Ocultas: 15 (*1ª camada*) e 10 (*2ª camada*)
- Algoritmo de Treinamento: *Traingd*;
- Funções de Ativação: *Tangente-Sigmóid*;
- Erro Quadrático Médio: 0,556338;
- Vetores de Treinamento: 100; e
- Vetores de Teste: 15.

A Figura 1 mostra um diagrama da arquitetura de Rede Neural Artificial proposta.

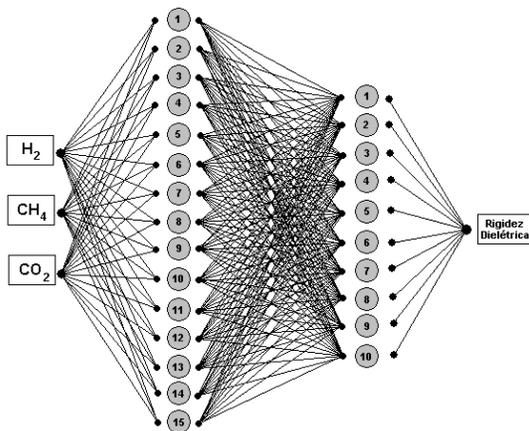


Figura 1. Arquitetura neural desenvolvida para o problema.

Basicamente, o treinamento da Rede Neural Artificial consiste no sucessivo estímulo da rede por um conjunto de valores formando pares de entradas e correspondentes saídas (Hagan, 1994). Isto consiste de aprendizado supervisionado, pois as saídas da rede são comparadas com as saídas desejadas em um processo iterativo que busca a minimização do erro quadrático médio. A Rede Neural Artificial foi implementada, utilizando-se o programa MATLAB. Dessa maneira, foi realizado um treinamento com um total de 10.000 iterações (épocas).

Após a realização da fase de treinamento da rede, foi efetuado o teste para a sua validação com os ensaios previamente separados exclusivamente para este fim e que não participaram do treinamento. Este fato possibilita evidenciar a capacidade de generalização da Rede Neural.

Uma maneira de se analisar os resultados dos testes de validação da Rede Neural consiste na análise dos erros relativos e do erro relativo médio.

Observa-se que os erros fornecidos na Tabela 1 são todos inferiores a 10%, e o erro relativo médio é de 5,0339%. Este valor pode ser considerado baixo em função da complexidade do fenômeno, e, portanto, pode-se dizer que a Rede Neural adquiriu a capacidade de generalização, fato este confirmado com dados não utilizados durante o treinamento.

Tabela 2. Valores de rigidez dielétrica generalizados pela rede e erro relativo.

Rigidez Dielétrica (kV/0,1'') (Real)	Rigidez Dielétrica (kV/0,1'') (RNA)	Erro Relativo (%)
49,000	45,825	6,479
51,000	47,698	6,474
45,000	43,783	2,704
45,000	46,076	2,392
45,000	48,352	7,449
41,000	38,713	5,577
37,000	38,838	4,967
46,000	46,394	0,857
45,000	41,950	6,777
48,000	44,411	7,477
45,000	41,376	8,054
47,000	45,249	3,725
45,000	45,761	1,691
41,000	42,082	2,638
18,000	16,516	8,245
Erro Relativo Médio: 5,0339 %		

O gráfico da Figura 2 ilustra melhor a Tabela 1. Nele estão os valores de rigidez dielétrica reais e os obtidos com a rede, juntamente com os respectivos erros.

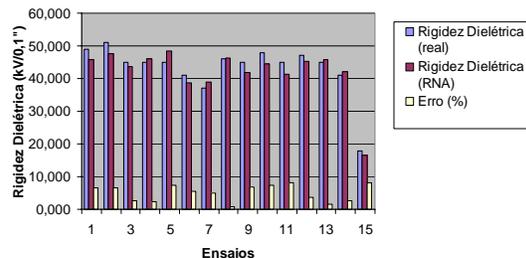


Figura 2. Valores reais de rigidez dielétrica, valores generalizados e erro relativo.

Analisando-se os resultados do teste de validação, conclui-se que a rede aprendeu a solução do problema proposto em relação ao domínio considerado. Assim, a rede treinada poderá ser utilizada para estimar e identificar processos referentes ao envelhecimento do óleo isolante de transformadores, relacionando alguns gases com o comportamento da rigidez dielétrica.

#### 4 Resultados da Arquitetura Neural Desenvolvida e Discussões

O objetivo desta pesquisa é desenvolver uma Rede Neural Artificial para identificar processos de envelhecimento do óleo mineral isolante de transformadores. Entretanto, esse processo é de difícil identificação, pois diversas variáveis interagem em conjunto e cada uma influencia de maneira diferente no processo de perda da rigidez dielétrica. Tendo isso em vista, deve-se adotar um método de análise que permita identificar o comportamento da rigidez dielétrica frente a cada uma das outras variáveis ( $H_2$ ,  $CH_4$  e  $CO_2$ ), porém, considerando que elas interagem entre si.

Dessa maneira, traçaram-se às curvas da rigidez dielétrica versus as concentrações de cada gás. Quando uma variável (gás) era analisada, as outras duas eram mantidas constantes e fixadas em determinados valores dentro do conjunto de treinamento. Assim foram obtidas duas curvas para cada variável em um mesmo sistema de eixos.

Os resultados podem ser observados nos itens a seguir.

##### 4.1 Comportamento da Rigidez Dielétrica Frente à Variação da Concentração de Hidrogênio

Nesta simulação, manteve-se fixo os valores de concentrações dos gases metano e dióxido de carbono de acordo com os valores abaixo.

- metano ( $CH_4$ ): 2 ppm e 32 ppm
- dióxido de carbono ( $CO_2$ ): 280 ppm e 4194 ppm

Foram traçadas duas curvas da rigidez dielétrica versus a concentração de  $H_2$ , que podem ser observadas na Figura 3.

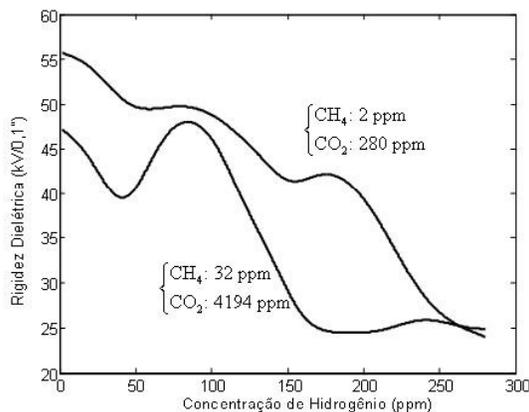


Figura 3. Rigidez Dielétrica versus concentração de  $H_2$ .

A análise do gráfico da Figura 3 consiste em avaliar o comportamento geral das curvas de rigidez dielétrica versus a concentração de  $H_2$ . Dessa maneira, pode-se dizer que as curvas apresentam um comportamento decrescente. Esse fato está completamen-

te coerente, uma vez que a literatura relaciona o hidrogênio com a formação do arco elétrico (IEEE-C57, 1991). Dessa maneira, há de se esperar que o aumento da concentração de  $H_2$  conduza a uma diminuição da rigidez dielétrica. O comportamento aparentemente não linear deste processo (como pode ser observado nas duas curvas) denota a complexidade do problema e deve-se à interação entre a influência de cada gás no processo. Em determinados intervalos, a segunda curva ( $CH_4=32$  ppm e  $CO_2=4194$  ppm) é crescente. Esse tipo de comportamento pode ser devido à influência de outro gás, mas também pode significar número muito reduzido de amostras disponíveis para treinamento da rede.

Nessas simulações ficou constatada a dependência direta do gás hidrogênio no comportamento da rigidez dielétrica.

##### 4.2 Comportamento da Rigidez Dielétrica Frente à Variação da Concentração de Metano

Para a análise do comportamento da rigidez dielétrica em relação à concentração do  $CH_4$  fixaram-se os seguintes valores de concentrações dos gases  $H_2$  e  $CO_2$ .

- hidrogênio ( $H_2$ ): 2 ppm e 280 ppm
- dióxido de carbono ( $CO_2$ ): 280 ppm e 14286 ppm

Foram traçadas as curvas da rigidez dielétrica versus a concentração de  $CH_4$ , que podem ser observadas na Figura 4.

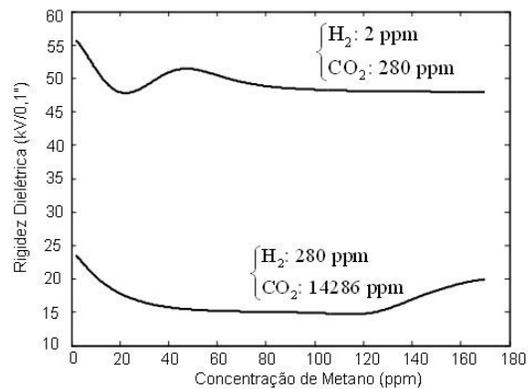


Figura 4. Rigidez Dielétrica versus concentração de  $CH_4$ .

A partir da Figura 4, observa-se que ambas as curvas apresentam comportamento decrescente. Isso, novamente está coerente com o que se conhece na literatura (Milasch, 1984). O metano também está associado à ocorrência do arco elétrico, porém com menos intensidade do que o hidrogênio. Isso pode ser verificado pela queda mais suave da rigidez dielétrica como observado nesta figura, indicando que a influência do  $H_2$  sobre o processo é superior à influência do  $CH_4$ . Na segunda curva ( $H_2=280$  ppm e  $CO_2=14286$  ppm) nota-se um crescimento a partir do valor de 120 ppm de concentração de  $CH_4$ . Isso pode

ser devido à influência do CO<sub>2</sub>, que para esta curva está com valor elevado. O CO<sub>2</sub> é um gás associado ao sobreaquecimento do óleo, e, portanto à presença de água. Entretanto, o aquecimento acentuado pode levar à formação de água no estado gasoso, diminuindo a sua concentração do estado líquido. Como os estudos anteriores mostraram que a água é preponderante no processo de perda da rigidez dielétrica, esse fato pode levar a uma diminuição da mesma, mas apenas em elevadas concentrações de CO<sub>2</sub>.

#### 4.3 Comportamento da Rigidez Dielétrica Frente à Variação da Concentração de Dióxido de Carbono

Procedendo-se da mesma maneira, fixaram-se os seguintes valores.

- hidrogênio (H<sub>2</sub>): 45,8 ppm e 280 ppm
- metano (CH<sub>4</sub>): 32 ppm e 170 ppm

Após efetuada a simulação com estes dados, foram construídas as curvas que podem ser visualizadas na Figura 5.

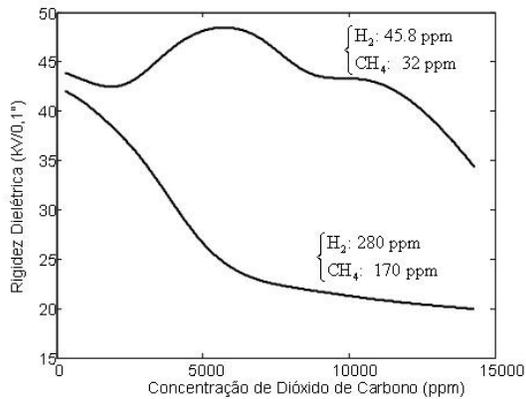


Figura 5. Rigidez Dielétrica versus concentração de CO<sub>2</sub>.

A Figura 6 mostra o comportamento da rigidez dielétrica frente à variação do CO<sub>2</sub>. Esse gás está associado ao aquecimento excessivo do óleo e, portanto, à presença de água. O comportamento geral das curvas também é decrescente, o que condiz com a influência esperada desses gases sobre o processo.

Neste caso ficou evidenciada a preponderância da concentração do hidrogênio e do metano neste processo. Observa-se na curva superior uma pequena instabilidade (oscilação) que se define como decrescente na curva inferior em função da concentração do hidrogênio e do metano.

## 5 Conclusão

Esta pesquisa apresentou uma arquitetura neural para avaliar processos de envelhecimento do óleo isolante de transformadores. O teste de validação da Rede Neural, bem como os resultados que mostram o comportamento da rigidez dielétrica em relação à

concentração dos três gases estudados são promissores e justifica os esforços em se obter uma abordagem neural para o problema. A rede foi capaz de generalizar as saídas para as entradas não utilizadas durante a fase de treinamento, e os resultados das análises ficaram coerentes com o que se conhece na literatura. O treinamento de uma rede é um processo empírico, ou seja, não existe uma metodologia ou um algoritmo que norteie a escolha de uma arquitetura neural apropriada para abordar determinado tipo de problema. Dessa forma, diversos treinamentos e testes levaram à escolha da atual arquitetura.

O fator inovador desta pesquisa está na possibilidade de estimar parâmetros físico-químicos (rigidez dielétrica) em função de ensaios cromatográficos (gases) de maneira integrada. Levando-se em conta esta conjectura, pode-se vislumbrar a possibilidade da diminuição de alguns ensaios em campo.

A pesquisa está em franco desenvolvimento utilizando mais dados de ensaios experimentais e novas arquiteturas no sentido de melhorar a avaliação do processo de envelhecimento do transformador.

## Referências Bibliográficas

- Dong, M. et al. (2004). Synthetic Furfural Analysis for Transformer Ageing. Electrical Insulation and Dielectric Phenomena. CEIDP-2004 Annual Report Conference, pp. 245–248.
- Hagan, M. T., Menhaj, M. B. (1994) Training Feedforward Networks With the Marquardt Algorithm. IEEE Trans. On Neural Networks, Vol. 5, pp. 989-993.
- IEC Publication 599 (1978). Interpretation of the Analysis of Gases in Transformers and Other Oil-Filled Electrical Equipment in Service.
- IEEE-C57 (1991). Guide for Interpretation of Gases Generated in Oil-Immersed Transformers, ANSI/IEEE Standard C57.104.
- Milasch, M. (1984). Manutenção de Transformadores em Líquido Isolante, Ed. Blücher, SP.
- Souza, A. N. (2005). Avaliação Integrada das Condições de Envelhecimento de Transformadores Usando uma Abordagem Neural. Bauru, 104 p. Tese de Livre Docência – FEB, Universidade Estadual Paulista Júlio de Mesquita Filho.
- Souza, A. N., Zago, M. G., Saavedra, O. R., Costa Jr, P. (2005). Uma Abordagem Neural Para Otimizar a Avaliação de Processos Físico-Químicos Relacionados ao Envelhecimento do Transformador. VII SBAI/II IEEE LARS, São Luis, CD.
- Unsworth, J and F. Mitchell. (1990) Degradation of Electrical Insulating Paper Monitored With High Performance Liquid Chromatography. IEEE Transactions on Electrical Insulating, Vol. 25, pp. 737-746.