



GRUPO VIII

GRUPO DE ESTUDO DE SUBESTAÇÕES E EQUIPAMENTOS ELÉTRICOS (GSE)

**AValiação DO NÍVEL DE CONTAMINAÇÃO DO ÓLEO DE TRANSFORMADORES
ATRAVÉS DE REDES NEURAIS ARTIFICIAIS**

Ivan Nunes da Silva*

André Nunes de Souza Maria Goretti Zago N. de Souza

Carlos Falcão

Mário Eduardo Bordon

UNESP – Universidade Estadual Paulista

RESUMO

Neste trabalho apresenta-se o desenvolvimento de uma nova metodologia através de redes neurais artificiais para avaliar o nível de contaminação do óleo mineral utilizado em transformadores.

Esta abordagem concentra-se também em estimar o grau de envelhecimento relativo dos transformadores em função das grandezas que representam a degradação do papel e do óleo mineral isolante.

Os resultados obtidos nas simulações comprovam que a técnica desenvolvida pode ser utilizada como um instrumento alternativo para tornar o planejamento da manutenção mais adequado, possibilitando assim a diminuição dos custos envolvidos nestas operações.

PALAVRAS-CHAVE

Subestações, Óleo mineral, Envelhecimento de equipamentos, Redes neurais artificiais.

1.0 - INTRODUÇÃO

O óleo mineral é um líquido muito empregado em transformadores, disjuntores, chaves elétricas, reatores, etc. Além de apresentar uma rigidez dielétrica de aproximadamente cinco vezes superior a do ar, o óleo mineral possui uma elevada capacidade térmica e um excelente coeficiente de transmissão de calor, além de apresentar uma rigidez dielétrica de aproximadamente cinco vezes superior a do ar.

Atualmente, a análise do desempenho dos transformadores nos sistemas de energia elétrica é estabelecido em função do nível de contaminação do óleo mineral. Esta análise tem como premissa uma avaliação quantitativa e qualitativa dos produtos de degradação presentes no óleo mineral, bem como os processos que aceleram o seu envelhecimento, tais como: agentes oxidantes, variações de temperatura, pressão, umidade, entre outros.

Diante desta constatação, é de suma importância a realização de pesquisas com o intuito de determinar com precisão quais as reais causas da contaminação do óleo isolante e quais as implicações nas suas propriedades físico-químicas. Assim, o relacionamento existente entre os produtos de degradação do papel isolante e do óleo mineral poderá ser utilizado para determinar o grau de envelhecimento dos equipamentos.

Neste contexto, o mapeamento de processos de contaminação do óleo mineral através das Redes Neurais Artificiais (RNA) pode ser visto como uma ferramenta que fornece alternativas às metodologias convencionais de ensaios, gerando resultados motivadores, principalmente devido às características intrínsecas da técnica, tais como a capacidade de generalização e a facilidade de integração com outras ferramentas computacionais.

Uma rede neural artificial é um sistema dinâmico que consiste de vários elementos processadores simples

que exploram arquiteturas de computação inerentemente paralelas e adaptativas.

Este artigo é organizado como segue. Na Seção 2 é apresentado os principais meios de contaminação do óleo. A Seção 3 introduz os fundamentos básicos de Redes Neurais Artificiais. Na Seção 4, a abordagem neural é apresentada. A Seção 5 fornece os resultados e simulações para o problema proposto. Finalmente, as conclusões e os pontos chaves deste artigo são apresentados na Seção 6.

2.0 – CONTAMINAÇÃO DO ÓLEO ISOLANTE

O óleo contaminado é aquele que apresenta água e outras substâncias estranhas, sendo que estes produtos não fazem parte da sua composição. Por outro lado, o óleo deteriorado é aquele que apresenta produtos resultantes da sua oxidação [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. Finalmente, a fase final é a formação de borra, que geralmente, consiste em uma substância resinosa resultante da polimerização a partir de ácidos e outros compostos.

Esse processo de degradação do óleo isolante resulta na alteração de suas propriedades físicas e elétricas, tais como:

- i-) aumento da viscosidade;
- ii-) aumento da acidez;
- iii-) diminuição da tensão interfacial;
- iv-) aumento de dissolução d'água;
- v-) diminuição da rigidez dielétrica, entre outras.

Esta lista de alterações evidenciam o início do processo de degradação do óleo.

2.1 – Oxidação do óleo

Um dos processos que contribuem para a contaminação do óleo é a sua oxidação, a qual é iniciada quando o oxigênio entra em combinação com os hidrocarbonetos instáveis (impurezas), na presença de catalisadores como ferro, cobre, água, etc. Esses catalisadores são encontrados dentro do transformador, sendo que a água exerce um papel determinante nesse processo de catalisação.

Para evitar a oxidação do óleo são utilizados inibidores naturais que são representados pelos compostos

orgânicos de enxofre termicamente estáveis e o inibidor sintético diterciário-butilparacresol (DBPC) [2].

2.2 – Gases dissolvidos no óleo

Os gases dissolvidos em óleos isolantes são provenientes de defeitos no interior do transformador. O relacionamento desses gases pode ser classificado em função do tipo de defeito, e a sua formação pode indicar a gravidade do defeito. Geralmente, a identificação e a quantificação dos tipos de gases são usadas para a realização de um planejamento da manutenção.

A Tabela 1 apresenta o relacionamento da origem dos gases com o possível tipo de defeito.

TABELA 1 – RELAÇÃO ENTRE GASES E TIPOS DE DEFEITOS

Defeito	Tipos de Gases	Materiais
Corona	H ₂	Óleo
	H ₂ , CO, CO ₂	Papel
Pirólise	CH ₄ , C ₂ H ₆ , C ₂ H ₄ , H ₂	Óleo
	CO, CO ₂	Papel
Formação de Arcos	H ₂ , C ₂ H ₂ , CH ₄ , C ₂ H ₆ , C ₂ H ₄	Óleo e Papel

O principal indicador de envelhecimento em um transformador é o teor furfural dissolvido no óleo, pois é um composto que é gerado exclusivamente durante o processo de decomposição do papel isolante [3,4]. A técnica utilizada para avaliação do teor furfural é a cromatografia, que consiste na análise de pequenas amostras de gás com grande precisão e sensibilidade, sendo capaz, portanto, de identificar algum defeito incipiente através de seus resultados.

Seu princípio básico de funcionamento consiste em se passar o fluido com os gases que se deseja separar através de um meio estacionário, onde os componentes gasosos interagem com esse meio. As diferentes interações dos componentes resultarão em diferentes velocidades de percurso que, com o auxílio de um gás quimicamente inerte em relação aos demais (gás de arraste), faz com que ocorra a separação necessária [5].

3.0 – FUNDAMENTOS DE REDES NEURAS ARTIFICIAIS

A habilidade de Redes Neurais Artificiais (RNA) em mapear relacionamentos funcionais as tornam uma abordagem atrativa que pode ser utilizada em diversos tipos de problemas [6]. Esta característica é

particularmente importante 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.

As características que tornam a metodologia de redes neurais artificiais atrativa do ponto de vista da solução de problemas são:

- Capacidade de aprender através da experiência.
- Desempenho eficiente em processos onde há ausência de conhecimento explícito sobre como identificar uma solução factível.
- Não necessidade de identificação de eventuais modelos matemáticos que descrevem o comportamento do sistema analisado.
- Elevada imunidade ao ruído, isto é, o desempenho da rede não entra em colapso em presença de eventuais informações incorretas ou ausentes.

Neste artigo, redes neurais do tipo perceptron são utilizadas para mapear o relacionamento entre o grau de envelhecimento de transformadores com as diversas variáveis que indicam uma degradação do papel e do óleo mineral isolante.




FIGURA 1 – A Rede Neural do Tipo Perceptron

Uma rede perceptron típica, com ‘m’ entradas e ‘p’ saídas, é ilustrada na Figura 1, onde cada círculo representa um neurônio artificial. A arquitetura feedforward da rede perceptron multicamadas implica que o fluxo de informações é executado em um única direção, não possuindo retroalimentação entre os neurônios. A camada inicial, onde as informações são introduzidas na rede, é denominada camada de entrada; enquanto a última camada, responsável pela resposta da rede, é denominada camada de saída. Todas as outras camadas intermediárias são chamadas de camadas escondidas.




FIGURA 2 – O Neurônio Artificial

Cada neurônio da rede pode ser modelado como mostrado na Figura 2. A equação que descreve o comportamento do neurônio é dada por (1):

$$y = g\left(\sum_{i=1}^n w_i x_i + b\right) \quad (1)$$

onde:

- ‘n’ é o número de entradas do neurônio.
- w_i é o peso associado com a i-ésima entrada.
- b é o limiar associado ao neurônio.
- x_i é a i-ésima entrada do neurônio.
- $g(\cdot)$ é a função de ativação do neurônio.
- y é a saída do neurônio.

O processo de treinamento da rede consiste na apresentação sucessivas de pares de dados que correspondem às entradas e saídas do processo.

Quando um vetor de entrada é aplicado, a saída da rede é comparada com o respectivo padrão de saída, a diferença (erro) é então propagada em sentido inverso ao fluxo de informações da rede (das saídas para as entradas) e os pesos são alterados com o objetivo de minimizar a função erro. Este algoritmo de treinamento da rede é conhecido como “backpropagation” [7].

A função erro a ser minimizada no processo de treinamento é o erro quadrático médio (E_{AV}) o qual é obtido a partir da soma dos erros quadráticos relativos a todos os padrões de entradas utilizados no conjunto de treinamento da rede, ou seja:

$$E_{AV} = \frac{1}{N} \sum_{k=1}^N E(k) \quad (2)$$

onde N é o número de vetores de treinamento e $E(k)$ é o valor instantâneo da soma dos erros quadráticos (em relação ao k-ésimo padrão de treinamento) de todos os neurônios da camada de saída da rede, ou seja:

$$E(k) = \frac{1}{2} \sum_{j=1}^p (d_j(k) - y_j(k))^2 \quad (3)$$

Para cada padrão de entrada, $E(k)$ é minimizado com relação ao vetor de pesos \mathbf{w} , isto é:

$$\frac{\partial E(k)}{\partial w_{ji}^l} = 0 \quad (4)$$

onde \mathbf{w} é o peso conectado o j -ésimo neurônio da l -ésima camada ao i -ésimo neurônio da camada ($l-1$). Finalmente, os pesos da rede são alterados utilizando a seguinte equação:

$$w_{ji}^l(k+1) = w_{ji}^l(k) - \eta \frac{\partial E(k)}{\partial w_{ji}^l(k)} \quad (5)$$

onde η é uma constante que especifica a taxa de aprendizagem do algoritmo backpropagation.

4.0 – A ABORDAGEM NEURAL

A abordagem neural desenvolvida consiste em utilizar uma rede neural do tipo Perceptron com somente uma camada escondida. As variáveis que compõem cada vetor de entrada da rede são definidas pelas grandezas que indicam os teores dos produtos que representam a degradação do papel e do óleo mineral isolante. Estas grandezas são identificadas a partir das seguintes propriedades:

- Teor de 2-FAL (2-Furfuraldeído) presente no óleo (ppm).
- Volume de CO presente no óleo (litros).
- Tensão interfacial das moléculas do óleo (dyn/cm).
- Índice de acidez do óleo (mg KOH/g).

O vetor de saída da rede é composta por apenas uma variável a qual representa o nível de envelhecimento do transformador, ou seja:

- Grau de envelhecimento relativo (GER).

O grau de envelhecimento relativo fornece, em função dos valores de entradas, um valor entre 0 e 1 que indica o quão mais velho está um transformador em relação a todos os outros do conjunto.

A arquitetura da rede neural utilizada para estimar o grau de envelhecimento relativo de transformadores é ilustrada na Figura 3.

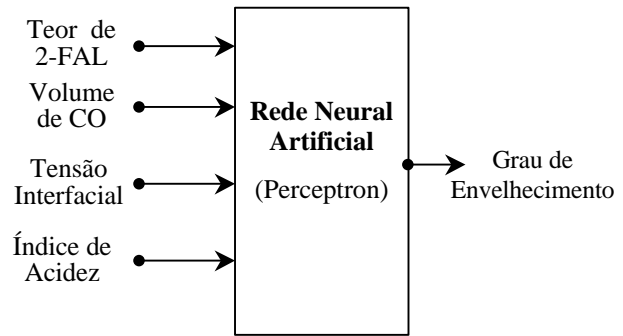


FIGURA 3 – Arquitetura da Rede Perceptron

O treinamento da rede foi feita a partir dos resultados obtidos em [8] e que são relativos aos ensaios de 41 transformadores de potência, separados em oito grupos, como mostrado na Tabela 2.

TABELA 2 – GRUPO DE TRANSFORMADORES

Grupo	Ano de Fabricação	Tensão Superior (kV)	Potência Primária
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	1969/70	230	70
G7	1964	230	33
G8	1969	230	33

Após o treinamento da rede, vários conjuntos de transformadores foram testados com o objetivo de avaliar o grau de envelhecimento relativo entre eles.

Os resultados destas simulações são apresentados na próxima seção.

5.0 – RESULTADOS DE SIMULAÇÃO

O primeiro conjunto de transformadores a serem testados é composto de 7 transformadores (Trafo) com o mesmo ano de fabricação (1979/1980) e que pertencem ao grupo G1.

Os valores do teor de 2-Furfuraldeído (2-FAL), do volume de CO (CO), da tensão interfacial (TI), e do índice de acidez (IA) são fornecidos na Tabela 3.

O grau de envelhecimento relativo (GER) computado pela rede em relação a cada transformador está também apresentado na Tabela 3.

TABELA 3 – PRIMEIRO CONJUNTO DE TRANSFORMADORES

Trafo	2-FAL	CO	TI	IA	GER
T1/G1	0,03	8,536	42,3	0,01	0,1706
T2/G1	0,03	3,696	42,3	0,01	0,1470
T3/G1	0,03	2,420	39,5	0,01	0,1928
T4/G1	0,01	4,730	42,6	0,01	0,0495
T5/G1	0,02	5,588	40,3	0,01	0,0972
T6/G1	0,04	5,060	43,3	0,01	0,2419
T7G1	0,04	4,202	40,9	0,01	0,2674

A partir dos resultados do grau de envelhecimento relativo (GER) computados pela rede (Tabela 3), nota-se que a ordem crescente de envelhecimento relativo dos transformadores obedece a seguinte seqüência: T4 < T5 < T2 < T1 < T3 < T6 < T7.

Observa-se, a partir da Tabela 3, que realmente os transformadores T6 e T7 são os transformadores relativamente mais velhos, pois os teores de 2-FAL destes transformadores são mais elevados que os demais.

O segundo conjunto de transformadores é composto por 7 equipamentos que pertencem aos grupos G3 e G4. A Tabela 4 fornece as características dos transformadores e o grau de envelhecimento relativo entre eles.

TABELA 4 – SEGUNDO CONJUNTO DE TRANSFORMADORES

Trafo	2-FAL	CO	TI	IA	GER
T1/G3	0,33	1,742	39,9	0,01	0,5828
T2/G3	0,29	1,740	43,1	0,01	0,5374
T3/G3	1,15	2,060	34,8	0,03	0,9062
T4/G3	0,80	1,526	39,2	0,02	0,8289
T5/G4	2,94	2,786	30,0	0,03	0,9514
T6/G4	2,77	2,269	30,6	0,04	0,9267
T7G4	0,48	2,072	37,6	0,01	0,7111

Para o segundo conjunto de transformadores, a partir dos resultados do grau de envelhecimento relativo (GER) computados pela rede (Tabela 4), nota-se que a ordem crescente de envelhecimento relativo entre todos os transformadores obedece a seguinte seqüência: T2 < T1 < T7 < T4 < T3 < T6 < T5.

Entre os transformadores apenas do grupo 3 (G3), a ordem crescente de envelhecimento é dado por: T2 < T1 < T4 < T3; enquanto para os transformadores do grupo G4, a seqüência crescente de envelhecimento é especificada por: T7 < T6 < T5.

TABELA 5 – TERCEIRO CONJUNTO DE TRANSFORMADORES

Trafo	2-FAL	CO	TI	IA	GER
T1/G1	0,02	3,454	41,9	0,01	0,070
T2/G1	0,02	5,588	40,3	0,01	0,097
T3/G2	0,34	1,488	31,0	0,02	0,609
T4/G2	0,44	1,242	31,3	0,03	0,683
T5/G3	0,33	1,742	39,9	0,01	0,583
T6/G4	0,48	2,072	37,6	0,01	0,711
T7/G5	0,37	16,329	15,7	0,21	0,634
T8/G6	0,23	17,200	27,6	0,05	0,512
T9/G6	0,08	14,700	32,3	0,03	0,390
T10/G7	0,39	9,300	40,9	0,03	0,659

O terceiro conjunto de transformadores é composto por 10 equipamentos que pertencem aos diversos grupos da Tabela 2. As características dos transformadores e o grau de envelhecimento relativo entre eles é fornecido na Tabela 5.

A partir da Tabela 5, observa-se que o grau de envelhecimento relativo entre todos os transformadores de diferentes grupos é dado por: T1 < T2 < T9 < T8 < T5 < T3 < T7 < T10 < T4 < T6.

É importante observar que o aprendizado incorporado na rede detecta que a variável mais importante no processo de identificação do grau de envelhecimento dos transformadores é o teor de 2-Furfuraldeído contido na amostra.

6.0 – CONCLUSÕES

Neste artigo é desenvolvido uma abordagem neural para computar o grau de envelhecimento relativo entre vários tipos de transformadores pertencentes a um determinado conjunto. O treinamento da rede é baseado na avaliação do nível de contaminação do óleo em função das características de degradação do papel isolante advindos de testes laboratoriais.

Além de fornecer uma nova metodologia a este assunto, a abordagem desenvolvida pode ser utilizada como um instrumento eficiente e alternativo para a tomada de decisões estratégicas, especialmente quando há vários transformadores que podem suprir uma eventual necessidade.

Os resultados expressivos obtidos pelas simulações indicam que a abordagem proposta é uma ferramenta inovadora e poderosa a qual pode ser utilizada com sucesso nestes tipos de problemas.

7.0 – BIBLIOGRAFIA

- (1) MILAN, M. Manutenção de transformadores em líquido isolante. Ed. Edgar Blucher Ltda, 1984.
- (2) LEVY, N. M., OLIVEIRA, V. P., NACHVALGER, E. E. Técnica de diagnóstico da isolação celulósica em transformadores. *Eletricidade Moderna*, pp. 75-82, Julho 1998..
- (3) UNSWORTH, J., MITCHELL, F. Degradation of electrical insulating paper monitored with high performance liquid chromatography. *IEEE Transactions on Electrical Insulating*. Vol. 25, parte 4, pp. 737-46, 1990.
- (4) DE PABLO, A., ANDRESON, R. et al. Furanic compounds analysis as a tool for diagnostic and maintenance of oil-paper insulation systems. *Symposium Berlin of CIGRE*, Paper 110-09, 1993.
- (5) BURTON, P. J. et al. Applications of liquid chromatography to the analysis of furfural of electrical insulating materials. *CIGRE*, Paper 15-08, 1988.
- (6) SILVA, I. N. Uma abordagem neuro-nebulosa para otimização de sistemas e identificação robusta. Tese de Doutorado. DCA/FEE/UNICAMP, Campinas-SP, Dezembro 1997.
- (7) HAYKIN, S. *Neural Networks – A Comprehensive Foundation*. Macmillan, New York, 1994.
- (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.

AGRADECIMENTOS

Os autores agradecem à FAPESP pelo suporte financeiro (Proc. 98/08480) e a Indústria e Com. de Transformadores Zago (INCOTRAZA) pelo apoio técnico.